



T.C.
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI
DOKTORA PROGRAMI

BEYİN BİLGİSAYAR ARAYÜZ (BBA)
SİSTEMLERİ İÇİN YENİ BİR YAKLAŞIM
DOKTORA TEZİ

Sefa AYDIN

Birinci Danışman: Doç. Dr. Levent GÖKREM

İkinci Danışman: Doç. Dr. Mesut MELEK

TOKAT- 2025



Bu tez çalışması;

Türkiye Sağlık Enstitüleri Başkanlığı (TÜSEB) tarafından Acil Araştırma ve Geliştirme Projelerini Destekleme Programı, Doktora Öğrencilerine Yönelik A Grubu Acil Ar-ge Proje Çağrısı kapsamında (Proje No:36126) ve Tokat Gaziosmanpaşa Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü (BAP) tarafından (Proje No:2023/86) desteklenmiştir.

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Levent GÖKREM danışmanlığında hazırlamış olduğum “Beyin Bilgisayar Arayüz (BBA) Sistemleri için Yeni Bir Yaklaşım” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

17/06/2025

Sefa AYDIN

JÜRİ KABUL VE ONAY

Sefa AYDIN tarafından hazırlanan “**Beyin Bilgisayar Arayüz (BBA) Sistemleri için Yeni Bir Yaklaşım**” adlı tez çalışmasının savunma sınavı 17/06/2025 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Mekatronik Mühendisliği Anabilim dalında Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri	(Unvanı, Adı Soyadı)	İmzası
Üye (Başkan)		
Üye		
Üye		
Üye		
Üye (Danışman)		

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

Eđitim hayatım boyunca tecrübelerinden istifade etme řansı bulduğum birinci danışmanım Doç. Dr. Levent GÖKREM'e, doktora eğitimim süresince bilgi birikiminden her anlamda yararlandığım ikinci danışmanım Doç. Dr. Mesut MELEK'e

Ve hayatım boyunca her daim sevgisi ve fedakârlıklarıyla en büyük destekçilerim olan kıymetli annem Yeter AYDIN ve babam Hakan AYDIN'a, yüzümüzün her zaman gülmesine sebep olan hayatımızın neşesi kardeşim Mustafa AYDIN'a, bu zorlu süreç boyunca her anlamda yanımda olan olan eşim Nurgül AYDIN'a ithafen...

ÖNSÖZ

Beyin Bilgisayar Arayüz (BBA) sistemleri üzerine yürütülen bu tez çalışmasında, Elektroensefalografi (EEG) ve Elektrokülografi (EOG) sinyallerinin birlikte değerlendirildiği, kullanıcı konforunu önceleyen ve gerçek dünya uygulamalarına uygun hibrit bir BBA sisteminin tasarlanması amaçlanmıştır. İki farklı EEG cihazı kullanılarak gerçekleştirilen deneyler sonucunda hem teknik başarı hem de kullanım ergonomisi açısından dengeli ve uygulanabilir bir sistem ortaya konmuştur.

Görsel uyaranların uzun süreli kullanımda oluşturabileceği rahatsızlıkları en aza indirmek, istemsiz komut risklerini ortadan kaldırmak, kullanılan kanal sayısını düşürmek ve oturumlar arası kararsızlık problemini çözmek bu çalışmanın temel motivasyon kaynakları olmuştur. Geliştirilen sistem, yalnızca teknik doğruluğu değil, aynı zamanda kullanıcı dostu bir etkileşim yapısını da gözeterek, literatürdeki klasik BBA uygulamalarına alternatif bir yaklaşım sunmuştur.

Bu yolculuk boyunca bana ilham veren, destek olan ve katkı sağlayan kıymetli danışmanlarım Doç. Dr. Levent GÖKREM ve Doç. Dr. Mesut MELEK'e en içten teşekkürlerimi sunarım. Akademik danışmanlarımdan rehberliği, katılımcıların sabrı ve ailemin koşulsuz desteği, bu çalışmanın başarıya ulaşmasında belirleyici rol oynamıştır. Bilimin yalnızca bilgi üretmek değil, aynı zamanda hayatı kolaylaştırmak olduğuna inanan biri olarak, bu çalışmanın gelecekte erişilebilir teknolojilere katkı sağlamasını diliyorum.

Saygılarımla,

Sefa AYDIN
TOKAT-2025

ÖZET

BEYİN BİLGİSAYAR ARAYÜZ (BBA) SİSTEMLERİ İÇİN YENİ BİR YAKLAŞIM

Aydın, Sefa

Doktora Tezi, Mekatronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Levent GÖKREM

İkinci Danışman: Doç. Dr. Mesut MELEK

Haziran 2025, xv + 90 sayfa

Bu tez çalışması kapsamında önerilen hibrit BBA sistemi, iki farklı EEG cihazı kullanılarak test edilmiş ve hem teknik performans hem de kullanıcı deneyimi açısından kapsamlı bir değerlendirme yapılmıştır. Emotiv Epoc X cihazıyla gerçekleştirilen sistemde, geleneksel Durgun Durum Görsel Uyarın Potansiyel (DDGUP) tabanlı yaklaşımlardaki görsel uyarın bağımlılığı azaltılarak, DDGUP ve EOG sinyallerinin birlikte değerlendirildiği yenilikçi bir yapı sunulmuştur. Kullanıcının doğrudan odaklanmasını gerektiren görsel uyarınların olumsuz etkilerini azaltmak amacıyla, ekranın üst kısmına düşük frekanslı (7Hz) tek bir LED yerleştirilmiş ve bu LED, istemli aktivasyonu doğrulayan bir kontrol katmanı olarak işlev görmüştür. EOG sinyallerinden elde edilen artefaktlarla kullanıcı yönü başarıyla belirlenmiştir. Yapılan iki aşamalı sınıflandırmada, Rastgele Orman (RO) algoritması birinci aşamada %99.57, ikinci aşamada ise %97.83 Doğruluk Oranı (DO) ve 36.75 (bit/dk) Bilgi Aktarım Hızı (BAH) sağlamıştır. Genel değerlendirmede %97.42 doğruluk oranı ve 35.75 (bit/dk) BAH ile sistemin teknik başarımı doğrulanmıştır. Öte yandan, Emotiv Flex EEG cihazı ile geliştirilen diğer sistemde de benzer bir iki aşamalı hibrit yapı uygulanmış; DDGUP ve EOG sinyalleri sıralı olarak değerlendirilmiştir. İlk aşamada, 7Hz frekansındaki LED yardımıyla güvenli aktivasyon sağlanmış, ikinci aşamada ise EOG sinyalleriyle dört yönlü nesne takibi gerçekleştirilmiştir. Bu sistem, yalnızca teknik doğruluk değil, aynı zamanda oturumlar arası kararlılık hedeflenerek tasarlanmıştır. İki farklı oturumda elde edilen veriler Korelasyon Hizalama (KH) tabanlı domain adaptasyon yöntemi ile işlenmiş ve yeniden kalibrasyon ihtiyacı olmaksızın sistemin güvenilir çalıştığı gösterilmiştir. Torbalama Algoritması (TA) birinci aşamada %99.12, ikinci aşamada ise %94.29 DO,

38.35 (bit/dk) BAH, %94.55 hassasiyet ve %94.42 F1-skoru ile en yüksek performansı sağlamıştır. Her iki sistemde de kullanıcı konforu üzerine yoğunlaşmış; düşük frekanslı LED tercihleri, hareket temelli yönlendirme yapısı ve sınırlı sayıda EEG kanalı ile hem görsel yorgunluk hem de sistem karmaşıklığı minimize edilmiştir. Özellikle Emotiv Epoc X sisteminde EOG'ye dayalı istemsiz aktivasyonlar kontrol altına alınırken, Emotiv Flex sisteminde oturumlar arası kararlılık güvence altına alınmıştır. Sonuç olarak, iki cihaz kullanılarak geliştirilen hibrit BBA sistemi, kullanıcı ergonomisini göz ardı etmeden yüksek sınıflandırma başarımı, sistem kararlılığı ve güvenilirlik sunarak laboratuvar ortamlarından günlük yaşama geçiş için güçlü bir aday olduğunu ortaya koymuştur.

Anahtar Kelimeler: Elektroensefalografi, Elektrokülografi, Beyin Bilgisayar Arayüz, Makine Öğrenme, Sınıflandırma, Emotiv Epoc, Emotiv Flex

ABSTRACT

A NEW APPROACH FOR BRAIN-COMPUTER INTERFACE (BCI) SYSTEMS

Aydın, Sefa

Doctoral Thesis, Department of Mechatronic Engineering

Advisor: Assoc. Prof. Dr. Levent GÖKREM

Second Advisor: Assoc. Prof. Dr. Mesut MELEK

June 2025, xv + 90 pages

Within the scope of this thesis, the proposed hybrid BCI system was tested using two different EEG devices and a comprehensive evaluation was made in terms of both technical performance and user experience. In the system implemented with the Emotiv Epoc X device, an innovative structure was presented in which Steady State Visually Evoked Potential (SSVEP) and EOG signals are evaluated together, reducing the visual stimulus dependency in traditional visual stimuli-based approaches. In order to reduce the negative effects of visual stimuli that require the user to focus directly, a single low-frequency (7Hz) LED was placed on top of the screen and this LED served as a control layer that verified voluntary activation. The user orientation was successfully determined by EOG artefacts obtained from EEG signals. In the two-stage classification, the Random Forest (RF) algorithm provided 99.57% accuracy in the first stage and 97.83% accuracy and 36.75 (bit/min) Information Transfer Rate (ITR) in the second stage. In the overall evaluation, the technical performance of the system was verified with 97.42% accuracy and 35.75 (bit/min) ITR. On the other hand, a similar two-stage hybrid structure was applied in the other system developed with the Emotiv Flex EEG device; SSVEP and EOG signals were evaluated sequentially. In the first stage, safe activation was achieved with the help of LED at 7Hz frequency, and in the second stage, four-way object tracking was performed with EOG signals. This system was designed with the aim of not only technical accuracy but also inter-session stability. The data obtained in two different sessions were processed with the Correlation Alignment (CORAL) based domain adaptation method and it was shown that the system works reliably without the need for

recalibration. Bagging Algorithm provided the highest performance with 99.12% accuracy in the first stage and 94.29% accuracy, 38.35 (bit/min) ITR, 94.55% precision and 94.42% F1-score in the second stage. In both systems, user comfort is prioritized; low-frequency LED preferences, motion-based guidance structure and limited number of EEG channels minimize both visual fatigue and system complexity. In particular, in the Emotiv Epoc X system, involuntary activations based on EOG are controlled, while in the Emotiv Flex system, inter-session stability is ensured. As a result, the hybrid BCI system developed using two devices has proven to be a strong candidate for the transition from laboratory environments to daily life by offering high classification performance, system stability and reliability without neglecting user ergonomics.

Keywords: Electroencephalography, Electrooculography, Brain Computer Interface, Machine Learning, Classification, Emotiv Epoc, Emotiv Flex

İÇİNDEKİLER

ETİK SÖZLEŞME	i
JÜRİ KABUL VE ONAY	ii
ÖNSÖZ	iv
ÖZET	v
ABSTRACT	vii
İÇİNDEKİLER	ix
ŞEKİL LİSTESİ	xi
TABLO LİSTESİ	xiii
SİMGELER ve KISALTMALAR	xiv
1. GİRİŞ	1
1.1. Birinci Veriseti (Emotiv Epoc X)	10
1.2. İkinci Veriseti (Emotiv Flex)	12
2. LİTERATÜR ÖZETLERİ	13
3. MATERYAL VE METOT	23
3.1. EEG cihazları	23
3.1.1. Emotiv Epoc X	23
3.1.2. Emotiv FLEX	25
3.2. Güç Spektral Yoğunluğu (GSY)	26
3.3. Korelasyon Hizalaması (KH)	27
3.4. Sayısal İntegrasyon (Trapez)	27
3.5. Normalizasyon	28
3.6. Varyans Analizi (VA)	29
3.7. Polinom Eğrisi Uydurma Yöntemi	29
3.8. Doğruluk Oranı (DO)	30
3.9. Bilgi Aktarım Hızı (BAH)	31
3.10. Sinyal Gücü ve Enerjisi	32
3.11. Hassasiyet, Özseçicilik ve F1-skor Parametreleri	32
3.12. k-En Yakın Komşular (k-EYK)	34
3.13. Destek Vektör Makinesi (DVM)	35
3.14. Rastgele Orman (RO)	36

3.15. Lineer Diskriminant Analiz (LDA)	36
3.16. Torbalama Algoritması	37
3.17. Katılımcılar	37
3.18. Sinyal Kayıt Aşaması.....	38
3.18.1. Birinci Oturum	46
3.18.2. İkinci Oturum	47
4. BULGULAR.....	48
4.1. Birinci Verisetine Ait Bulgular	48
4.1.1. Kanal Seçimi	49
4.1.2. Göz Hareketlerine Dayalı BBA.....	50
4.1.3. Öznitelik Seçimi	58
4.2. İkinci Verisetine ait Bulgular	62
5. TARTIŞMA	72
6. SONUÇLAR.....	79
7. KAYNAKLAR	81
8. ÖZGEÇMİŞ	90

ŞEKİL LİSTESİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 1.1. BBA sistemlerinin temel şeması.	2
Şekil 1.2. Tasarlanan BBA sisteminin genel şeması.	11
Şekil 3.1. Emotiv Epoc X EEG cihazı (a) ve kafa üzerindeki elektrot konumları (b). ...	24
Şekil 3.2. Emotiv Flex EEG Cihazı.....	25
Şekil 3.3. Deneğin X (a) ve Y (b) eksenleri boyunca oluşan maksimum göz açıları. ...	39
Şekil 3.4. Yaklaşımın uygulanma sırası.	42
Şekil 3.5. LED'in aktif (a) ve pasif (b) olduğu durumlarda EEG sinyal kaydına ilişkin deneysel düzenek.....	43
Şekil 3.6. Yukarı-aşağı (a) ve sol-çapraz (b) göz hareketlerine karşılık gelen, AF3, F7, F8 ve AF4 kanallarında kaydedilen ham EEG sinyallerinde göz hareketlerinden kaynaklanan EOG artefaktlarının oluşturduğu örüntüler.	44
Şekil 3.7. Sağ-sol (a) ve sağ-çapraz (b) yönlerinde gerçekleşen göz hareketlerine karşılık olarak, AF3, F7, F8 ve AF4 kanallarında kaydedilen ham EEG verilerinde göz hareketlerinden kaynaklanan EOG artefaktlarının oluşturduğu desenler.....	44
Şekil 3.8. Çalışmada kullanılan kanalların konumları(a) ve kullanılan kanallara ait veri akış ekranı (b).....	45
Şekil 3.9. Yaklaşımın uygulanma aşamaları.....	46
Şekil 3.10. Sinyal kayıt aşaması.....	47
Şekil 4.1. AF3 kanalından elde edilen sinyalin filtreleme öncesi (a) ve Butterworth bant geçiren filtre uygulanmış hâli (b).	49
Şekil 4.2. RO sınıflandırıcı kullanılarak, tüm EEG kanalları üzerinden elde edilen aydınlatılmış ve aydınlatılmamış veri kümelerinin ortalama sınıflandırma doğruluk oranları.	50
Şekil 4.3. LED'in kapalı (a) ve açık (b) durumlarında ortaya çıkan sabit DDGUP potansiyeller.	52
Şekil 4.4. Tasarlanan BBA sisteminin algoritması.	53
Şekil 4.5. Seçilen aktif kanallar olan AF3, F8 ve AF4 üzerinden elde edilen veriler kullanılarak oluşturulan üç boyutlu öznitelik dağılım grafiği.....	54
Şekil 4.6. AF3 kanalına ait aydınlatılmış EEG verilerinden elde edilen entropi, çarpıklık ve ortalama özniteliklerine dayalı olarak oluşturulan üç boyutlu öznitelik	

saçınım grafiği.....	56
Şekil 4.7. VA puanlarına göre sıralanan 160 öznitelik arasından, her bir katılımcı için en yüksek puana sahip ilk 20 öznitelik arasında en sık yer alan özniteliklerin dağılımı.	58
Şekil 4.8. Aydınlatılmış verilerle gerçekleştirilen hareket sınıflandırma aşamasında, VA uygulanmadan önceki ve sonraki doğruluk oranları ile BAH değerlerinin karşılaştırmalı analiz sonuçları.....	61
Şekil 4.9. Tasarlanan ikinci hibrit BBA sistemine ait genel şema.	63
Şekil 4.10. Birinci oturuma ait sol-çapraz(a), sağ-çapraz(b), sağ-sol (c) ve aşağı-yukarı (d) hareket yörüngelerine ait verilerin ortalama genlik grafikleri.	63
Şekil 4.11. İkinci oturuma ait sol-çapraz(a), sağ-çapraz(b), sağ-sol (c) ve aşağı-yukarı (d) hareket yörüngelerine ait verilerin ortalama genlik grafikleri.	64
Şekil 4.12. Fp1 Kanalından alınan ham ve filtrelenmiş EEG sinyali: (a) filtrelenmemiş sinyal, (b) 1–15Hz 5. dereceden Butterworth bant geçiren filtre ile filtrelenmiş sinyal.....	64
Şekil 4.13. LED açık konumundayken meydana gelen DDGUP etkisi.	65
Şekil 4.14. Fp1 kanalına ait sinyal için 20. dereceden polinom kullanılarak uydurulan eğri.	68
Şekil 4.15. FT9 kanalına ait güç, enerji ve polinom uydurma eğrisi özniteliklerine ait 3 boyutlu saçınım grafiği.	68
Şekil 4.16. İkinci sınıflandırma aşamasına ait ortalama doğruluk oranları.	69

TABLO LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 1.1. EEG dalga bantlarının özellikleri.	1
Tablo 3.1. Uzaklığa bağlı olarak X-Y eksenlerinde oluşan maksimum göz açıları.	39
Tablo 3.2. Göz eksenlerindeki hareket yörüngelerinin neden olduğu açı değişiklikleri.	40
Tablo 4.1. Rastgele seçilen bir katılımcı (Denek-2) için Hold-out yöntemiyle gerçekleştirilen eğitim ve test süreci sonucunda elde edilen sınıflandırma doğruluk oranları.	54
Tablo 4.2. AF3, F7, F8 ve AF4 kanalları için tüm öznitelikler kullanılarak aydınlatılmış ve aydınlatılmamış verilerin sınıflandırma doğruluk oranları.	55
Tablo 4.3. AF3, F7, F8 ve AF4 kanallarından elde edilen aydınlatılmış verilerin sınıflandırılmasına ilişkin doğruluk oranları.	57
Tablo 4.4. AF3, F7, F8 ve AF4 kanallarından elde edilen ve VA yöntemiyle seçilmiş özniteliklerin kullanıldığı aydınlatılmış veriye ait sınıflandırma DO ve BAH değerleri.	60
Tablo 4.5. Tasarlanan BBA sisteminin birinci ve ikinci sınıflandırma aşamalarını kapsayan genel doğruluk ve BAH performans sonuçları.	61
Tablo 4.6. Birinci sınıflandırma aşamasına ait doğruluk oranları.	67
Tablo 4.7. İkinci sınıflandırma aşamasına ait DO, BAH, hassasiyet, özseçicilik ve F1-skoru değerleri.	71

SİMGELER ve KISALTMALAR

Simgeler

Açıklama

α

Alfa

β

Beta

dk

Dakika

δ

Delta

γ

Gama

Hz

Hertz

lx

Lüks

m

Metre

cm

Santimetre

s

Saniye

θ

Teta

V

Volt

%

Yüzde

Kısaltma

Açıklama

VA

Varyans Analizi

BA

Bayes Ağları

BBA

Beyin Bilgisayar Arayüz

BAH

Bilgi Aktarım Hızı

ÇDSİ

Çok Değişkenli Senkronizasyon İndeksi

DVM

Destek Vektör Makinesi

DDGUP

Durgun Durum Görsel Uyarın Potansiyel

Dnk

Denek

EEG

Elektroensefalografi

EMG

Elektromiyografi

EOG

Elektrookülografi

GUP	Görsel Uyarılmış Potansiyel
GSY	Güç Spektral Yoğunluğu
HBP	Hataya Bağlı Potansiyel
LED	Işık Yayan Diyot
k-EYK	k-En Yakın Komşu
KKA	Kakonik Korelasyon Analizi
KSA	Konvolüsyonel Sinir Ağı
KP	Korneoretinal Potansiyel
LDA	Lineer Diskriminant Analiz
Mİ	Motor İmgeleme
RBF	Radyal Baz Fonksiyonu
RO	Rastgele Orman
SGO	Sinyal Gürültü Oranı
Ort	Ortalama
GOF	Gönüllü Onam Formu
MEG	Manyetoensefalografi
FMG	Fonksiyonel Manyetik Görüntüleme
TAUA	Topluluk Alt Uzay Ayırıcı
SB	Saf Bayes
DR	Doğrusal Regresyon
SR	Sensörimotor Ritim

1. GİRİŞ

Günümüzde, hareket kabiliyetinin kaybedilmesiyle sonuçlanan ve bireyin yatağa bağımlı hâle gelmesine neden olan felç gibi rahatsızlıklar insanların yaşam kalitesini olumsuz etkilemektedir. Felçli bireyler, bilişsel yetilerini korumalarına rağmen, sinirsel iletimdeki bozukluklar nedeniyle motor kontrol sağlayamamakta ve günlük yaşam aktivitelerinde ciddi kısıtlamalar yaşamaktadırlar. Bu bireylerin temel ihtiyaçlarını karşılayabilmelerine destek olmak amacıyla Beyin Bilgisayar Arayüz (BBA) sistemleri geliştirilmiştir. BBA sistemleri beynin elektriksel aktivitelerini ölçerek bu verileri anlamlı komutlara dönüştürmektedir. Beyin yüzeyindeki nöronlar sürekli olarak etkileşim hâlinde çalışmaktadır. Bu etkileşimler belirli frekans aralıklarında ortaya çıkan ritmik dalgalar şeklinde izlenebilmektedir. Bu dalgalar frekanslarına göre alfa, beta, teta, delta ve gama gibi farklı gruplara ayrılmaktadır. Tablo 1.1’de dalgalara ait frekans ve genlik değerleri özetlenmektedir.


Tablo 1.1. EEG dalga bantlarının özellikleri.

Dalga	Frekans Aralığı (Hz)	Genlik Aralığı (μ V)
Delta (δ)	0.5–4	1–120
Teta (θ)	4–7	20–100
Alfa (α)	7–12	30–50
Beta (β)	12–30	5–30
Gamma (γ)	30+	Değişken

Delta dalgaları, 0.5–4Hz frekans aralığında olup en yavaş ancak en yüksek genlikli beyin dalgalarıdır. Bu dalga tipi, özellikle bir yaş altı bebeklerde ve yetişkinlerde derin uyku evresinde gözlemlenmektedir (Hammond, 2006). 4–7Hz aralığındaki teta dalgaları, hafif uyku ve zihinsel gevşeme durumlarında ortaya çıkmaktadır. Alfa dalgaları ise 7–12Hz aralığında izlenmekte ve genellikle gözler kapalıyken ya da rahatlama hâlindeyken görülmektedir. 12–30Hz arasındaki beta dalgaları uyanıklık, dikkat ve zihinsel çaba gibi durumlarda aktiftir ve özellikle problem çözme gibi bilişsel faaliyetlerde artış göstermektedir. Frekansı 30Hz’in üzerinde olan gama dalgaları, düşük genlikli olmalarına

rağmen algı, tanıma ve yüksek düzeyde bilişsel işlevlerle ilişkilidir ve bazı nörolojik hastalıkların belirlenmesinde önemli rol oynamaktadır (Zhang ve ark., 2009). Frekanslarına göre sınıflandırılan bu beyin dalgaları, BBA sistemlerinin temelini oluşturmaktadır.

BBA sistemlerinde genellikle invaziv olmayan ve cerrahi işlem gerektirmeyen bir yöntem olan Elektroensefalografi (EEG) sıklıkla tercih edilmektedir. EEG ile elde edilen beyin sinyalleri, sinyal işleme teknikleriyle analiz edilerek anlamlı çıktılara dönüştürülmekte ve bu çıktılar belirli komutlarla ilişkilendirilmektedir. Bu sayede, örneğin elektrikli bir tekerlekli sandalye, yatak veya lamba gibi cihazlar kullanıcı zihniyle kontrol edilebilir hâle gelmektedir (Regan, 1989). Bu yapı, özellikle hareket kabiliyeti kısıtlı bireylerin çevreleriyle etkileşim kurabilmelerine ve günlük ihtiyaçlarını daha bağımsız şekilde karşılamalarına imkân tanımaktadır. BBA sistemlerinin temel çalışma prensibi Şekil 1.1’de görsel olarak sunulmaktadır.



Şekil 1.1. BBA sistemlerinin temel şeması.

Şekil 1.1’de görüldüğü gibi, bir BBA sisteminin temel olarak sinyal toplama, ön işleme, öznelik çıkarımı ve sınıflandırma olmak üzere dört ana bileşenden oluşmaktadır. İlk aşamada EEG cihazları aracılığıyla beyin sinyalleri kaydedilmektedir. Ardından, ön işleme adımıyla bu sinyallere kırpma, filtreleme gibi işlemler uygulanarak parazitlerden arındırılmaktadır. İşlenen sinyallerden ayırt edici öznelikler çıkarılmakta ve bu

öznitelikler sınıflandırma aşamasına aktarılmaktadır. Son olarak, farklı makine öğrenme algoritmaları yardımıyla veriler sınıflandırılmakta ve sınıflandırma sonuçlarına bağlı olarak kontrol komutları üretilmektedir.

EEG tabanlı BBA sistemlerinde, sinyal edinimi için genellikle Görsel Uyarılmış Potansiyel (GUP), Motor İmgeleme (Mİ) ve P300 olmak üzere üç temel paradigmadan yararlanılmaktadır. P300 yöntemi, kullanıcı belirli bir uyarı (ışık, ses ya da simgesel görsel) algıladığında, yaklaşık 300–600 ms aralığında EEG sinyalinde pozitif bir sapma oluşmasına dayanmaktadır (Duvina ve ark., 2013). Mİ paradigmasında birey, fiziksel bir hareketi zihninde canlandırarak motor kortekste belirli sinyal örüntülerinin oluşmasını sağlamaktadır (Fakhruzzaman ve ark., 2015). GUP yönteminde ise kullanıcıya belirli frekanslarda yanıp sönen görseller sunulurken, görsel kortekste meydana gelen senkronize voltaj değişimleri kaydedilmektedir (Fernandez-Fraga ve ark., 2019). Uyarım frekansı 6Hz'i geçtiğinde bu durum, Durgun Durum Görsel Uyarılmış Potansiyel (DDGUP) olarak adlandırılmaktadır. Kaydedilen bu EEG sinyalleri sinyal işleme teknikleriyle analiz edilerek sınıflandırılarak kullanıcı niyetine uygun çıktı üretilmektedir.

DDGUP tabanlı BBA sistemleri veri toplama, sinyal işleme ve çıktı üretimi olmak üzere üç temel bileşenden oluşmaktadır. Bu sistemlerde farklı frekanslarda yanıp sönen görsel uyarılar kullanılarak kullanıcıda DDGUP yanıtı oluşturulmaktadır (Hamou ve ark., 2024). Ortaya çıkan bu potansiyel değişimleri EEG cihazları aracılığıyla kaydedilmekte ve elde edilen veriler bilgisayar ortamında işlenerek kontrol komutlarına dönüştürülmektedir. Üretilen bu komutlar, çeşitli çevresel aygıtların kontrolü için kullanılmaktadır. DDGUP yöntemi; invaziv olmayan yapısı, yüksek Bilgi Aktarım Hızı (BAH) ve Sinyal-Gürültü Oranı (SGO), kısa eğitim süresi ve düşük zihinsel yük gerektirmesi gibi avantajlarıyla öne çıkmaktadır (Albahri ve ark., 2023). 1–100Hz aralığında gözlemlenebilen bu yanıtlar, özellikle 15Hz altındaki frekanslarda daha güçlü şekilde elde edilmektedir (Herrmann, 2001). Sistem performansı değerlendirilirken öncelikle DDGUP sinyali frekans alanına dönüştürülerek tepkiler SGO üzerinden görselleştirilmektedir. Ardından sınıflandırma doğruluğu, sistem yanıt süresi ve tanınan

hedef sayısı analiz edilmektedir. Doğruluk büyük ölçüde DDGUP yanıtının gücü ve SGO değerine bağlıken, hız ise hedefe ulaşmak için gereken sinyal süresiyle ilişkilendirilmektedir. Sunulan hedef sayısı ise sistemin hem hızını hem de doğruluğunu doğrudan etkileyebilmektedir (Zhu ve ark., 2010).

P300 ve Mİ gibi diğer BBA paradigmalarıyla kıyaslandığında DDGUP tabanlı sistemler; daha kısa eğitim süresi, yüksek doğruluk oranı ve daha yüksek BAH değeri ile dikkat çekmektedir. Mİ sistemlerinde kullanıcının belirli uzuv hareketlerini zihinsel olarak hayal etmesi ve uzun eğitim süreleri gerekirken, DDGUP doğrudan görsel uyarana verilen doğal beyin tepkilerine dayandığı için kullanım açısından daha pratiktir. Ayrıca, DDGUP birden fazla frekansta eşzamanlı görsel uyaran sunulmasına olanak tanıyarak P300 sistemlerinde yaygın olan ardışık tarama ihtiyacını ortadan kaldırmaktadır. Oksipital kortekste doğrudan ortaya çıkan yanıtlar sayesinde DDGUP sinyalleri yüksek SGO ile kaydedilmekte ve bu da sinyal güvenilirliğini arttırmaktadır. Tüm bu avantajlar, DDGUP tabanlı BBA sistemlerini özellikle felçli veya motor yeti kaybı olan bireyler için etkili bir iletişim ve kontrol aracı hâline getirmektedir (Li ve ark., 2024; Yu ve ark., 2017). Ayrıca literatürdeki birçok çalışma (Kubacki, 2021; Mai ve ark., 2024; Zhang ve ark., 2023; Sadeghi & Maleki, 2022; Saravanakumar & Ramasubba, 2020) bu sistemlerin Elektromiyografi (EMG) ve Elektrookülografi (EOG) gibi biyolojik sinyallerle hibrit biçimde başarıyla entegre edilebildiğini göstermektedir.

Motor yetilerini kaybetmiş bireylerin çevreleriyle etkileşim kurmalarını kolaylaştırmayı amaçlayan EEG tabanlı BBA sistemleri, önemli avantajlar sunsa da çeşitli sınırlılıklar barındırmaktadır. Özellikle, DDGUP tabanlı BBA sistemlerinin içerdiği görsel uyarıların kullanıcı üzerindeki olumsuz etkileri nedeniyle uzun süreli kullanımlar açısından sürdürülebilirliği düşüktür. Öte yandan, bu sistemlerin büyük bölümü yalnızca laboratuvar ortamında test edilmekte olup, gerçek yaşam koşullarında uygulanabilirlikleri sınırlıdır. Ayrıca kullanıcı konforunun yetersizliği, sistemlerin yavaş çalışması ve yüksek maliyetleri de yaygın kullanımı kısıtlayan temel unsurlardır (Maleki ve ark., 2020). EEG cihazları, Manyetoensefalografi (MEG) ve Fonksiyonel Manyetik Rezonans

Görüntüleme (FMG) gibi ileri görüntüleme yöntemlerine kıyasla daha ekonomik olsa da günlük kullanımda engelli bireyler için hâlâ pahalı sistemlerdir (Duvina ve ark., 2013). Tıbbi sınıf EEG sistemlerine alternatif olarak geliştirilen düşük maliyetli cihazlar ise, performans açısından ciddi sınırlamalara sahiptir. Örneğin, Emotiv Epoc X cihazı, G.Tec gibi tıbbi sınıf sistemlere kıyasla daha düşük çözünürlükte sinyaller üretmekte ve daha yavaş çalışmaktadır (Campbell ve ark., 2010; Duncan ve ark., 2009). Yapılan karşılaştırmalı bir çalışmada, Emotiv Epoc'ta 162.69 ms, G.Tec sisteminde ise yalnızca 51.22 ms gecikme olduğu bildirilmiştir (Wang ve ark., 2019). Bir diğer önemli sınırlama ise, görsel uyaranlara dayalı BBA sistemlerinde gözlenen görsel ve zihinsel yorgunluktur. Bu sistemlerde kullanıcıların sürekli olarak yanıp sönen uyaranlara odaklanmaları gerekmektedir. Ancak uzun süreli maruz kalma, kullanıcıların göz sağlığını olumsuz etkileyebilmekte ve kullanım motivasyonunu düşürmektedir (Allison, 2009; Dong & Tian, 2023). BBA sistemlerinin senkronizasyon ihtiyacı da literatürde önemli bir zorluk olarak belirtilmektedir (Bashashati ve ark., 2015). Ayrıca bu tür sistemlerin görsel uyarana dayalı yapısı, mevcut göz hastalıkları olan bireyler için uygun değildir. Bu nedenlerle, BBA sistemlerinin hem teknik hem de ergonomik açıdan daha erişilebilir ve sürdürülebilir hâle getirilmesi, geniş çaplı benimsenmeleri açısından kritik önem taşımaktadır.

BBA sistemlerinde kullanılan paradigmlar, kullanıcıya bilişsel yük oluşturmaktadır. Ayrıca EEG sinyallerinin değişken doğası ve parazitlere karşı hassasiyeti gibi nedenlerden dolayı kontrol kopmaları yaşanabilmektedir (Jiang ve ark., 2014). Bu sınırlamaları aşmak için geliştirilen hibrit BBA sistemleri, birden fazla sinyal kaynağını birleştirerek performans, güvenilirlik ve kullanılabilirliği artırmayı hedeflemektedir (Wolpaw & Wolpaw, 2012). EEG, zihinsel niyeti algılama açısından güçlü iken, EOG yüksek SGO ile hızlı ve hassas kontrol imkânı sunmaktadır. Bu iki sinyalin birleşimi hem istemli hem de doğal bir etkileşim sağlamaktadır. Literatürde, hibrit sistemlerin tekil BBA yapılarına göre daha yüksek doğruluk ve esneklik sunduğu bildirilmiştir (Kinney-Lang ve ark., 2020; Orlandi ve ark., 2021). Özellikle EOG'nin sisteme entegre edilmesi, sinyal kopmalarına karşı dayanıklılığı artırmakta ve minimal eğitimle sezgisel kullanım imkânı sağlamaktadır (Huang ve ark., 2019). Genel olarak, BBA sistemlerine minimal eğitim

gerektiren EOG'nin entegrasyonu, EEG sinyal kopmalarına karşı sistemi daha dayanıklı hale getirmekte ve daha sezgisel bir kontrol olanağı sunmaktadır. Böylece EEG–EOG tabanlı hibrit BBA sistemleri, daha hızlı, doğru ve kullanıcı dostu çözümler sunarak gerçek dünya uygulamaları için umut vaad etmektedir (Mussi & Adams, 2022).

Yanıp sönen ışıklar veya desenler kullanan BBA sistemleri, kullanıcı konforu ve göz sağlığıyla ilgili kullanılabilirlik açısından önemli sınırlamalara sahiptir. DDGUP ve P300 tabanlı sistemler, titreşimli LED'lere uzun süre odaklanmayı gerektirdiğinden göz yorgunluğu, görsel tükenme ve baş ağrısı gibi şikâyetlere yol açabilmektedir (Brennan ve ark., 2015; Zhu ve ark., 2010). Özellikle 8–20Hz aralığındaki yüksek kontrastlı uyaranlar, fotosensitif bireylerde epileptik nöbet riskini artırmakta ve bu durum sistemin bazı kullanıcı grupları için güvenliğini sorgulatmaktadır (Fisher ve ark., 2005). Ayrıca, tekrarlayan ışık uyarımlarının göz kuruluğu ve dikkat kaybına neden olduğu da rapor edilmiştir (Chu ve ark., 2021). Geleneksel tasarımlarda sistem performansı ve BAH değerine önem verilirken, kullanıcı deneyimi geri planda kalmaktadır. Sonuç olarak, titreşimli uyaranlara dayanan görsel BBA sistemleri ilkesel olarak etkili olsa da uzun süreli kullanımlarda kullanıcılar açısından rahatsız edici ya da sağlıksız olabilmektedir (Punsawad & Wongsawat, 2012). Bu durum, daha konforlu uyaran yaklaşımlarına duyulan ihtiyacı açıkça ortaya koymaktadır.

BBA sistemlerinin karşılaştığı önemli zorluklardan bir diğeri ise sistem performanslarının oturumlar arası değişkenlik göstermesidir. EEG sinyallerinin kararsız doğası, elektrotların yeniden yerleştirilmesi, empedans değişimi, kullanıcı yorgunluğu veya dikkat dağınıklığı gibi etkenler oturumlar arasındaki sinyal örüntülerinde değişimlere neden olmaktadır. Bu nedenle, bir oturumda elde edilen verilere göre eğitilmiş bir sınıflandırıcı, sonraki oturumlarda daha düşük performans sergileyebilmektedir. Bu durum BBA sisteminin kullanılabilirliğini ve güvenilirliğini azaltmakta ve pratik açıdan kullanıcıların her kullanım öncesinde yeniden kalibrasyon yapması gerektiği anlamına gelmektedir. Her oturumda kalibrasyon yapmak hem zahmetli bir iştir hem de sürekli kullanımı zorlaştırmaktadır. Kullanıcı perspektifinden bakıldığında, BBA davranışının

bir oturumdan diğerine öngörülemez olması sisteme duyulan güveni ve sistemin kullanılabilirliği olumsuz etkilemektedir. Günün erken saatlerinde çok iyi çalışan bir sistemin ilerleyen saatlerde tekrar kullanıldığında kötü çalışması, bağımsız kullanım açısından kabul edilebilir değildir (Sung ve ark., 2024). Oturumlar ve hatta bireyler arasındaki değişkenliğin ele alınması, tasarlanan herhangi bir BBA sisteminin laboratuvar ortamlarından günlük yaşama taşınması için kritik öneme sahiptir.

Bu çalışmanın BBA sistemleri üzerinde odaklandığı problemler aşağıda maddeler halinde özetlenmektedir.

- Titreşen uyaranlar: DDGUP ve P300 gibi görsel uyaran temelli BBA sistemleri, titreşen görsel uyaranlar nedeniyle kullanıcıda göz yorgunluğu, baş ağrısı ve epilepsi riski gibi rahatsızlıklara yol açabilmektedir (Zhu ve ark., 2010). Bu durum, sistemin uzun süreli kullanımını sınırlamakta, konfor seviyesini düşürmekte ve bazı kullanıcıların güvenlik gerekçesiyle dışlanmasına neden olmaktadır.
- Oturumlar arası kararsızlık: BBA sistemlerinde oturumlar arası değişkenlik, EEG sinyallerinin kararsız yapısı nedeniyle sistem performansını olumsuz etkilemektedir. Her oturumda yeniden kalibrasyon gereksinimi, sistemin sürekli kullanımını zorlaştırmakta ve kullanıcının sisteme güvenini azaltmaktadır (Sung ve ark., 2024). Bu durum BBA sistemlerinin gerçek hayatta kullanımını önemli ölçüde sınırlamaktadır.
- Güvenilirlik ve doğruluk: Tekil BBA sistemleri, oturumlar arası sık değişkenlik gösteren EEG sinyallerine bağımlı olması nedeniyle sistem güvenliği açısından sorun teşkil etmektedir. EEG sinyalleri tek başına kullanıldığında, sinyalin değişken doğası ve parazitlere karşı hassasiyeti nedeniyle kontrol kopmaları yaşanabilmektedir (Jiang ve ark., 2014). Bu durum BBA sistemlerinin günlük hayatta kullanılabilirliğini kısıtlamakta ve çok kaynaklı hibrit BBA sistemlerinin varlığına ihtiyaç olduğunu göstermektedir.

➤ Sistem kontrolü ve güvenlik: BBA sistemlerinde aktivasyon, istemsiz komutları önlemek ve kullanıcı kontrolünü güvenli biçimde başlatmak için kritik bir öneme sahiptir. Özellikle gerçek dünyada uygulanacak BBA sistemlerinde, her sinyalin komut olarak algılanması kullanıcı deneyimi açısından önemlidir (Mussi & Adams, 2022). Tasarlanan sistemlerin kullanıcıya istemli kontrol başlatma imkânı sunması, çevresel dikkat dağınıklıklarının veya rastgele göz/kas hareketlerinin sistem tarafından yanlış komut olarak algılanmasının önüne geçmek için gereklilik arz etmektedir.

Bu çalışmada, görsel uyaran temelli BBA sistemlerinde tespit edilen problemlere alternatif sağlamak amacıyla, 7Hz LED kullanılarak DDGUP yöntemi ile EEG sinyallerindeki EOG artefaktlarının birlikte değerlendirildiği yeni bir hibrit sistem geliştirilmiştir. Tasarlanan sistemde, DDGUP potansiyellerinin EEG üzerinde kolayca tespit edilebilmesi ve önceden eğitim gerektirmemesi gibi avantajlar (Bashashati ve ark., 2007) göz önünde bulundurularak, güvenli aktivasyon mekanizmasının kontrolü için DDGUP yöntemi tercih edilmiştir. EEG sinyallerinde özellikle frontal bölgedeki kanallarda, göz hareketlerine bağlı olarak EOG artefaktları ortaya çıkmaktadır. Normalde istenmeyen bir sinyal türü olarak kabul edilen bu artefaktlar, nörolojik analizleri bozabileceği gibi yanlış komutlara da yol açabilmektedir (Fatourehchi ve ark., 2007). Ancak bazı çalışmalarda EOG sinyalleri, özellikle göz hareketlerinin tespiti amacıyla faydalı bir kaynak olarak kullanılmaktadır (Zhu ve ark., 2020). Göz kırpma, yönlü bakışlar (yukarı, aşağı, sağ, sol) ve göz kapama gibi hareketler, EEG üzerinden tanımlanabilmekte, izole edilebilmekte ve sınıflandırılabilir. Bu sinyaller daha sonra BBA sistemlerinde farklı komutlara atanarak işlevsel çıktılar üretilebilmektedir (Liu ve ark., 2024).

Tasarlanan hibrit BBA sisteminin sağlamayı hedeflediği katkılar aşağıda maddeler halinde özetlenmektedir.

➤ Görsel konfor: Sistemde kullanılan tek titreşimli uyaran 7Hz LED'dir ve bu frekans değeri, kullanıcılar tarafından düşük rahatsızlık seviyeleriyle algılanabilmektedir. Sistemdeki diğer tüm uyarıcılar hareket temellidir ve ek bir titreşim gerektirmemektedir.

Bu da görsel uyaran temelli sistemlerin kullanıcılarda sebep olduğu görsel yorgunluk problemini büyük ölçüde ortadan kaldırmaktadır. Bu durum beynin hareket işleme yollarını çok daha az görsel zorlanmayla kullanmasını sağlamaktadır.

➤ Oturumlar arası kararlılık: Tasarlanan sistemde veriseti, iki farklı oturumda kaydedilmiştir. Kaydedilen verilere Z-skor normalizasyon ve KH yöntemi uygulanarak, oturumlar arasındaki farklılıklar minimize edilmiş ve sistemin oturumlar arası kararlı bir yapıya sahip olması amaçlanmıştır. Böylece BBA sistemlerinin, farklı oturumlar arasında performans düşüklüğü yaşamasının önüne geçilmesi hedeflenmiştir.

➤ Güvenilirlik ve doğruluk: Tasarlanan BBA sistemi EEG sinyallerinin kararsız yapısına karşılık EOG sinyallerinin yüksek sinyal netliğinden faydalanmaktadır. Sistem tarafından göz hareketleri yüksek hassasiyetle işlenerek karmaşık yörüngeler doğru şekilde sınıflandırılabilir. Genel etki hem kullanıcı dostu hem de güvenilir bir hibrit BBA sistemidir. Kullanıcı minimum düzeyde görsel rahatsızlık yaşayarak, ne zaman komut vereceği konusunda tam kontrole sahiptir bu da gerçek dünya uygulamaları açısından çok önemlidir.

➤ Sistem güvenliği ve aktivasyon: Tasarlanan hibrit sistemde, 7Hz LED aracılığıyla DDGUP ve EOG'nin birlikte onay gerektirmesi, doğal bir güvenlik kontrolü sağlamaktadır. Sistem sadece birinci aşamadaki güvenli aktivasyon gerçekleşikten sonra kontrol durumuna geçtiğinden, kullanıcı LED aktif değilken serbestçe bakabilmekte veya göz kırpabilmektedir; istem dışı bir seçim yapma riski yoktur.


Bu çalışmada, görsel uyaran temelli BBA sistemlerinde kullanıcıların karşılaştığı göz sağlığı sorunlarına alternatif oluşturmak, sistemin konfor, güvenlik, kullanılabilirlik, sistem kararlılığını ve kullanım süresini artırmak amacıyla, DDGUP yöntemi ile EEG sinyallerindeki EOG artefaktlarının birlikte değerlendirildiği yeni bir hibrit sistem geliştirilmiştir. Geliştirilen sistem Emotiv firmasına ait 14 kanallı Emotiv Epoc X başlık

(birinci veriseti) ve 32 kanallı Emotiv FLEX başlık (ikinci veriseti) kullanılarak iki farklı veriseti üzerinde test edilmiştir.

1.1. Birinci Veriseti (Emotiv Epoc X)

Emotiv Epoc X başlık kullanılan sistemde, geleneksel yanıp sönen görsel uyarılar yerine, farklı yörüngelerde hareket eden nesnelerin (beyaz toplar) sunulduğu yenilikçi bir yaklaşım önerilmiştir. Kullanıcıya hareketli nesneler ekran aracılığıyla gösterilmiş ve odaklandığı hareket yörüngesine karşılık gelen komuta (örneğin yatak, tekerlekli sandalye) ait kontrol sinyali elde edilmiştir. Ancak, bu yöntemin potansiyel bir zayıf yönü; kullanıcının istemsiz olarak ekrana bakmaksızın göz hareketi gerçekleştirmesi durumunda sistemin yanlışlıkla aktif hâle gelebilmesidir. Bu sorunu önlemek amacıyla sistemin aktive olabilmesi için ekranın üst merkezine yerleştirilen 7Hz frekansında yanıp sönen bir LED ışığı güvenlik mekanizması olarak tasarlanmıştır. Sistem, DDGUP yöntemi ile bu LED'in tespit edilip edilmediğini kontrol etmekte ve yalnızca kullanıcı bilinçli şekilde LED'e odaklandığında aktif hâle gelmektedir. Böylece LED, sistemin istemsiz komutlardan korunmasını sağlayan bir “emniyet valfi” işlevi görmektedir. Önerilen sistemin genel şeması Şekil 1.2’de sunulmaktadır.

Şekil 1.2’de genel yapısı verilen sistemde, yalnızca bir adet LED kullanıldığı için ışık yoğunluğu oldukça düşüktür. Ayrıca sistemde, kullanıcının doğrudan odaklanmasına gerek yoktur, yalnızca LED'in bulunduğu yöne bakılması yeterli olmaktadır. Oysa geleneksel DDGUP tabanlı BBA sistemlerinde kullanıcıların birden fazla yanıp sönen ışığa uzun süre odaklanmaları gerekmektedir (Kamińska ve ark., 2021). Benzer şekilde, P300 tabanlı sistemlerde de bir komutun algılanabilmesi için görsel uyarana birden fazla kez bakılması zorunludur (Akram ve ark., 2015). Bu çalışmada önerilen sistem, yalnızca tek bir düşük frekanslı LED ile, parlama hissi ve göz yorgunluğu gibi olumsuz etkileri en aza indirgeyerek güvenli bir kullanım sunmaktadır.



Şekil 1.2. Tasarlanan BBA sisteminin genel şeması.

Sistemde veriler Emotiv Epoc X EEG cihazı kullanılarak 256Hz örnekleme frekansı ile toplanmış, kayıtlar hem LED açıkken hem de LED kapalıyken gerçekleştirilmiştir. Kaydedilen EEG verilerine kesme ve filtreleme gibi ön işleme adımları uygulanmış, ardından öznitelik çıkartımı yapılmış ve aktif kanal seçimi gerçekleştirilmiştir. Bu aktif kanallardan elde edilen öznitelikler iki aşamalı sınıflandırma sürecinde değerlendirilmiştir. İlk aşamada, LED açık ve kapalı durumdaki veriler DDGUP yöntemiyle analiz edilerek, Sayısal integrasyon (trapez) yöntemi kullanılarak ayrıştırılmıştır. İkinci aşamada ise, birinci sınıflandırmada LED'in aktif olduğu tespit edilen örnekler üzerinden elde edilen EOG artefaktları kullanılarak, yukarı aşağı, sağ sol, sağ çapraz ve sol çapraz yönlerde hareket eden nesneler sınıflandırılmıştır. Bu çalışmada, görsel uyaranlara uzun süre maruz kalmaktan kaynaklanan göz yorgunluğu ve rahatsızlık gibi sorunlara çözüm sunulması hedeflenmiştir. Önerilen sistem hem kullanıcı konforunu artırmakta hem de uzun süreli kullanım için daha uygun bir yapı sunmaktadır. Önerilen sistem hem DDGUP tabanlı LED tespiti hem de EOG temelli hareket sınıflandırması bir arada kullanarak hibrit bir yapıda tasarlanmıştır. Yapılan deneysel analizler, kullanıcıların LED'e doğrudan odaklanmadan algılanabilir bir tepki oluşturabileceğini ve EOG

artefaktları üzerinden hareketli nesne takibinin başarılı şekilde sınıflandırılabilceğini göstermiştir. Sonuç olarak, tasarlanan sistem kullanılan EEG cihazı ve görsel uyaran etkisinin en aza indirilmesi açısından daha konforlu, geliştirilen kontrol mekanizması dolayısıyla daha güvenli ve uzun süreli kullanıma uygun bir alternatif BBA çözümü sunmuştur.

1.2. İkinci Veriseti (Emotiv Flex)

Emotiv Flex EEG başlığın kullanıldığı çalışmada, DDGUP ve EOG artefaktları birlikte kullanılmıştır. Birinci verisetinin aksine kullanıcıya tek bir ekran üzerinde 7Hz frekanslı LED ve dört farklı yönde hareket eden nesneler sunulmuştur. Sistem, bilinçli aktivasyonu güvence altına almak üzere iki aşamalı olarak yapılandırılmıştır. İlk aşamada, kullanıcının ekrana bakarak LED aracılığıyla DDGUP yanıtı üretip üretmediği analiz edilmiştir. Bu aşamada LED beyin kontrollü güvenlik anahtarı işlevi görmüştür. LED tespit edildiğinde sistemin ikinci aşaması aktif hale gelmesi ve böylece yanlış komut riskinin büyük oranda azaltılması hedeflenmiştir. 7Hz frekansı, fotosensitif bireylerde tetiklenme riskini azaltmak ve yeterli DDGUP üretimi sağlamak amacıyla stratejik olarak seçilmiştir. Sistemin ikinci aşamasında, frontal lobda belirgin olan EOG artefaktları kullanılarak kullanıcının baktığı hareketli nesne yörüngesi belirlenmiştir. Böylece sistem, EEG üzerinden aktivasyon niyetini, EOG üzerinden ise yön kontrolünü analiz etmektedir. İlk aşamada EEG sinyalleri 1–15Hz aralığında filtrelenmiş, ardından GSY analizi ve trapez yöntemiyle öznitelikler çıkarılmıştır. Öznitelik verileri Torbalama Algoritması (TA), Destek Vektör Makinesi (DVM) ve Rastgele Orman (RO) algoritmaları ile sınıflandırılmış ve sırasıyla %99.12, %98.63 ve %98.67 doğruluk oranları elde edilmiştir. İkinci sınıflandırmada, sadece doğru LED aktivasyonu belirlenen örnekler değerlendirilmiş; bu sinyallerden zaman alanına dayalı güç, enerji ve 20. derece polinom öznitelikleri çıkartılmıştır. Öznitelik verilerine oturumlar arası dağılım farklarını azaltmak amacıyla KH yöntemi uygulanmıştır. KH, kovaryans matrislerini hizalayarak kaynak ve hedef veriler arasında istatistiksel uyum sağlamaktadır (Sun & Saenko, 2016). Elde edilen öznitelik verileri ile yapılan sınıflandırmada %94.29 doğruluk oranı ve 38.35 (bit/dk) BAH ile en yüksek başarı TA algoritmasıyla elde edilmiştir.

2. LİTERATÜR ÖZETLERİ

BBA, insan beyni ile dış ortamdaki cihazlar arasında doğrudan iletişim, etkileşim ve kontrol sağlamayı amaçlayan sistemlerdir (Gao ve ark., 2021). Görsel uyaran temelli paradigmlar olan DDGUP ve P300, BBA alanında sıklıkla kullanılmaktadır. Özellikle DDGUP, yüksek SGO, eğitim süresi gerektirmemesi ve uygulama kolaylığı gibi avantajları sayesinde yoğun olarak araştırılan klasik bir BBA paradigmasıdır (Chen ve ark., 2015; Friganovic ve ark., 2016; Ge ve ark., 2019; Nakanishi ve ark., 2018). Zihinsel çaba gerektirmemesi ve EEG sinyallerinde kolayca tespit edilebilir olması, yöntemin kullanıcı konforunu artıran diğer avantajları arasında yer almaktadır (Bashashati ve ark., 2007). Ancak, yanıp sönen görsel uyaranların uzun süreli kullanımı, göz yorgunluğu ve rahatsızlık hissi yaratabilmekte; bu da sistemin kullanım süresini ve konforunu sınırlamaktadır (Li ve ark., 2021). Ayrıca, sistem donanımının maliyeti de yaygın kullanımın önünde bir engel oluşturmaktadır (Melek ve ark., 2020).

Bu bölümde, literatürde DDGUP ve EOG sinyallerinin birlikte kullanıldığı hibrit BBA sistemleri ve Emotiv EEG cihazlarıyla geliştirilen DDGUP tabanlı sistemler üzerine yapılan çalışmalar incelenmiştir.

DDGUP ile EOG sinyallerini birleştirerek geçiş sürelerini optimize eden bir çalışmada (Mai ve ark., 2024) hibrit BBA yapısı önerilmiştir. EOG sinyalleri ile hedefin olasılık dağılımı iyileştirilerek daha hızlı hedef tahmini sağlanmıştır. Başka bir çalışmada (Zhu ve ark., 2020), EOG tabanlı üçlü göz kırpmaya yöntemiyle kontrol edilen, altı serbestlik derecesine sahip bir robotik kol sistemi geliştirilmiş ve %92.09 doğruluk ile 35.98 (bit/dk) BAH değeri elde edilmiştir. Bir diğer çalışmada (Kubacki, 2021), farklı frekanslarda 12 karakterle oluşturulan hibrit, asenkron bir sistem önerilmiş ve sistemin iletişim performansı yüksek bulunmuştur. Benzer şekilde (Zhang ve ark., 2023), 20 düğmeli bir arayüzde DDGUP ve EOG sinyalleri ile doğrultu tespiti yapılmış; 10 katılımcıyla yürütülen deneyde %94.75 doğruluk oranı elde edilmiştir. Farklı bir çalışmada (Saravanakumar & Reddy, 2020), 36 hedef içeren bir sanal yazıcı arayüzü geliştirilmiştir.

EOG ile grup seçimi, DDGUP ile hedef seçimi yapılmıştır. Deneyler sonucunda %94.16 doğruluk değeri rapor edilmiştir. Karşılaştırmalı veri kümesi sunan bir çalışmada ise (Sadeghi & Maleki, 2022) elde edilen veriler 5.5–11.1Hz aralığında yanıp sönen 9 uyararla test edilmiştir.

Bir çalışmada (Asanza ve ark., 2021), araştırmacılar tarafından 7Hz, 9Hz, 11Hz ve 13Hz frekanslarında yanıp sönen görsel uyarıcılardan oluşan bir ekran tasarlanmış ve katılımcıların EEG sinyalleri yaklaşık 10 dakikalık oturumlar boyunca kaydedilmiştir. Eğitim verisinin çeşitliliğini artırmak için beyaz gürültü (0,5 ve 5 genlikli) eklenerek veri seti üç kat büyütülmüştür. Sınıflandırma işlemi DVM ve k-EYK algoritmaları ile gerçekleştirilmiş, ham veriyle elde edilen doğruluk oranları %51.0 ve %54.0 olurken, artırılmış veri ile bu oranlar %55.0 ve %58.0'e yükselmiştir. Başka bir çalışmada (Chiuzbaian ve ark., 2019), EEG tabanlı kontrol mekanizmasına sahip bir dron geliştirilmiş ve 10 sağlıklı birey ile test edilmiştir. Bu sistemde 5.3Hz, 7Hz, 9.4Hz ve 13.5Hz frekanslarındaki görsel uyarılar kullanılmış ve ortalama %92.5 doğruluk ile 10.0 (bit/dk) bir BAH elde edilmiştir. Farklı bir deneyde (Brennan ve ark., 2015) ise, 13–16Hz aralığındaki LED'lerle oluşturulan uyarılar kullanılmış ve sistem, çeşitli frekanslarda görsel titreşim görevlerini tamamlayan 5 denekle test edilmiştir. Ek olarak, 23 katılımcıdan farklı ortamlarda görevleri tamamlamaları istenmiş; ancak 12 kişi ya görevi bitirememiş ya da istenen performansa ulaşamamıştır. Tüm görevleri tamamlayan katılımcılar için ortalama %79.2 DO ve 15.23 (bit/dk) BAH değerine ulaşılmıştır. Bu araştırmalar, farklı frekanslardaki çoklu görsel uyarıcıların kullanıcıyı uzun süre boyunca odaklanmaya zorladığını ve bunun da göz sağlığı üzerinde olumsuz etkiler doğurabileceğini göstermiştir. Bu sistemlerin önemli bir bölümü kullanıcı açısından rahatsız edici bulunmakta ve uzun süreli kullanıma uygun olmadığı belirtilmektedir. Ayrıca bu tür sistemlerde sinyal kayıt sürelerinin genellikle uzun olması ve BAH düzeylerinin düşük kalması da önemli sınırlılıklar arasında yer almaktadır.

Literatürde, görsel uyarı temelli BBA sistemlerinin kullanıcılar üzerinde oluşturduğu olumsuz etkileri en aza indirmek amacıyla çeşitli alternatif yaklaşımlar geliştirilmiştir.

Örneğin bir çalışmada (Kondo & Tanaka, 2023), düşük frekanslı uyaranların neden olduğu görsel titreşim hissini azaltmak için 56–70Hz aralığında çalışan bir sistem önerilmiş, sistemin performansı ise 26-40Hz bandındaki uyaranlarla test edilmiştir. Elde edilen sonuçlara göre düşük frekanslı uyaranlarda %98.0, yüksek frekanslı uyaranlarda ise %87.19 doğruluk oranına ulaşılmış ve sistemin BAH değeri 29.64 (bit/dk) olarak hesaplanmıştır. Ancak elde edilen veriler, yüksek frekanslı uyaranlarda doğruluğun düştüğünü ve bu tür sistemlerin kullanıcı rahatsızlığını azaltma konusunda yeterince etkili olmadığını ortaya koymuştur. Benzer şekilde başka bir çalışmada (Melek ve ark., 2020), dört farklı hızda ve yönde dönen kanatlara sahip bir görsel arayüz önerilmiş ve 27–32 yaş arası beş birey üzerinde test edilmiştir. Siyah zemin üzerine yerleştirilen "A" harfli dört bölümden oluşan bu arayüzde, kübik DVM algoritması kullanılarak her sınıf için 125 saniyelik kayıtlar yapılmış ve en yüksek %93.72 doğruluk oranı elde edilmiştir. Ancak bu sistemin de uzun kayıt süresi, kullanıcı dikkatinin sürdürülebilirliği ve istenmeyen göz hareketlerine karşı kırılğan yapısı nedeniyle kalıcı bir çözüm değildir. Son dönemde, bu tür sorunların önüne geçebilmek amacıyla bazı araştırmalar, görsel uyarıcılara alternatif olarak doğrudan göz hareketlerine odaklanan BBA sistemleri geliştirmiştir. Örneğin bir çalışmada (Saichoo ve ark., 2022), kullanıcıların göz hareketleri aracılığıyla tekerlekli sandalye kontrolü sağlanmış; katılımcılardan göz kapatma, yukarıya ve yanlara bakma gibi hayal edilen görevler istenmiştir. Bu deneyde EEG verileri 12 gönüllüden toplanmış ve Mİ paradigmalarına dayalı olarak ortalama %83.7 doğruluk elde edilmiştir.

Göz kırpma hareketleri ile beyin sinyalleri arasındaki ilişkinin incelendiği bir çalışmada (Ngo ve ark., 2021) sol göz için AF3 ve F7, sağ göz için ise AF4 ve F8 kanalları kullanılmıştır. Göz hareketlerinin etkisine odaklanan bir başka çalışmada (Dimitrov ve ark., 2020), 16 sağlıklı katılımcıdan EEG sinyalleri alınmış ve sağ/sol yönleri gösteren oklar ile beta dalgaları kaydedilmiştir. DVM algoritması ile yapılan sınıflamada standart testlerde %70.0, yönlü görsel uyaranlarla yapılan testlerde ise %76.0 doğruluk değerine ulaşılmıştır. Bu tür göz hareketi temelli sistemler, odaklanma ihtiyacını azaltma potansiyeline sahip olsa da kullanıcıların istemsiz göz hareketlerine karşı sistemin aşırı duyarlı olması ciddi bir sorun oluşturmaktadır. Özellikle sıralı kodlamaya dayalı yaklaşımlar kullanıcı adaptasyonunu zorlaştırmakta, bu da sistemin hata oranlarını

artırmaktadır. Ayrıca, çoğu çalışmada uzun kayıt süreleri ve sınırlı doğruluk oranları da dikkat çekmektedir. Bu nedenle hem kullanıcı deneyimini hem de sistem doğruluğunu geliştirmeye yönelik yeni ve daha dengeli yaklaşımlara ihtiyaç duyulmaktadır.

P300 temelli yöntemler, BBA uygulamalarında sıklıkla tercih edilen yaklaşımlar arasındadır. Yapılan bir çalışmada (Selvi ve ark., 2018), 20 ila 37 yaş aralığında altı sağlıklı bireyden elde edilen P300 sinyalleri derin öğrenme teknikleriyle sınıflandırılmıştır. Katılımcılara, iki farklı senaryoyu takip etmelerini gerektiren özel bir arayüz sunulmuştur. Sınıflandırma işlemi için beş katmanlı bir sinir ağı kullanılmış ve eğitim verileriyle %100.0 sınıflandırma başarısı rapor edilmiştir. Test verileri üzerinden yapılan değerlendirmede ise uyaranlar arası 125 ms gecikme ile %80.0 ve 250 ms gecikmeyle ise %40.0 doğruluk elde edilmiştir. Farklı bir çalışmada (Mouli & Palaniappan, 2020), hem sabit DDGUP hem de P300 bileşenini kapsayan hibrit bir donanım platformu geliştirilmiştir. Bu sistem, 7-007810Hz arasında dört farklı frekansta yanıp sönen yeşil LED uyaranlar ve dört yüksek güçlü kırmızı LED ile rastgele aralıklarla P300 tepkilerini uyandıracak şekilde tasarlanmıştır. Beş sağlıklı denek ile yapılan deneyler sonucunda, EEG verilerinde dört farklı olay işaretleyicisine karşılık gelen P300 tepkileri başarıyla tespit edilmiştir. Başka bir araştırmada (Yayık & Kutlu, 2017), görsel uyaranlarla tetiklenen P300 bileşenlerinin desen tanıma amacıyla kullanımına odaklanılmıştır. Çalışmaya katılan 19 gönüllüye, bir ekran üzerinde belirli görsel uyaranları izleyerek bunların yanıp sönme sayılarını saymaları istenmiş ve EEG kayıtları alınmıştır. Bu veriler Bayes Ağları (BA) kullanılarak analiz edilmiş ve %99.86 gibi yüksek bir sınıflandırma doğruluğu elde edilmiştir. Bu çalışmalar, P300 yönteminin görsel uyaranlara dayalı olarak başarılı sınıflama sonuçları verdiğini göstermektedir; ancak sürekli odaklanma gereksinimi kullanıcı konforu açısından bir sınırlılık oluşturmaktadır.

Mİ tabanlı BBA sistemlerine yönelik yapılan bir çalışmada (Mwata ve ark., 2021), hayal edilen el hareketleri ile bir örümcek robotun kontrolü test edilmiştir. Katılımcılardan elde edilen EEG verileri, elin açılmasıyla ileri hareket ve kapanmasıyla geri hareket arasında

ilişkilendirilmiş ve KSA kullanılarak yapılan sınıflandırmada %87.6 doğruluk oranına ulaşılmıştır. Mİ sinyalleri üzerine uzun dönemli bir analiz yapılan başka bir çalışmada (Kaya & Saritas, 2024), bir katılımcıdan 20 günlük süre boyunca sağ, sol, yukarı ve aşağı yönlü imgelem hareketleri kaydedilmiştir. Elde edilen veriler, Topluluk Alt Uzay Ayrıcı (TAUA) sınıflayıcı yöntemiyle analiz edilmiştir. Günlük ortalama dört sınıf için %61.44 doğruluk oranı elde edilirken; beş farklı bireyin verileriyle yapılan genel değerlendirmede dört sınıflı sistem için ortalama %50.42 ve ikili sınıflama (sağ-sol) için %71.84 doğruluk rapor edilmiştir. Bir çalışmada (Trigui ve ark., 2016), bir tekerlekli sandalyenin yön kontrolünü sağlamak amacıyla sabit durum DDGUP temelli bir sistem tasarlanmıştır. Bu sistemde, ekranın sağ, sol ve üst köşelerine sırasıyla 8Hz, 9Hz ve 10Hz frekanslarında yanıp sönen beyaz LED'ler yerleştirilmiştir. 29 ile 58 yaşları arasındaki beş katılımcıyla yürütülen deneylerde, kullanıcının sola, sağa ve ileri yönlerde komut verebilmesi hedeflenmiştir. Sinyallerin analizinde, hem Kakonik Korelasyon Analizi (KKA) hem de Çok Değişkenli Senkronizasyon İndeksi (ÇDSİ) yöntemleri kullanılmış ve her iki yöntemle de %96.0 doğruluk oranı elde edilmiştir.

Yapılan bir çalışmada (Ancau ve ark., 2022), 14 katılımcı ile yürütülen görsel geri bildirim görevlerinde hem çevrim içi hem de çevrim dışı koşullarda Hataya Bağlı Potansiyel (HBP) yanıtları analiz edilmiştir. Katılımcılara sırasıyla 500 ms, 700 ms ve 3000 ms süreli kırmızı, mavi ve yeşil renkteki görsel uyarıcılar gösterilmiştir. Derin öğrenme algoritmaları yardımıyla yapılan sınıflandırmalarda %81.0 doğruluk oranı rapor edilmiştir. Başka bir çalışmada (Faruk ve ark., 2021), kullanıcıların duygusal durumlarını (örneğin heyecan, stres, odaklanma, rahatlama ve ilgi) analiz edebilecek bir sistem geliştirilmiştir. Katılımcılara dikkat ve heyecan uyandırmak amacıyla 15 dakikalık bir matematik yarışması videosu izletilmiş ve elde edilen EEG verileri sınıflandırma amacıyla Saf Bayes (SB) ve Doğrusal Regresyon (DR) algoritmaları ile değerlendirilmiştir. Bu analiz sonucunda, SB sınıflandırıcısı %69.0, DR ise %62.0 oranında doğruluk sağlamıştır. LED parlaklık seviyelerinin beyin yanıtları üzerindeki etkisini inceleyen bir başka çalışmada (Mouli & Palaniappan, 2017), farklı parlaklık düzeylerinin DDGUP tepkileri üzerindeki etkisi araştırılmıştır. 7Hz ile 10Hz arasında değişen frekanslardaki LED'ler %25, %50, %75 ve %100 parlaklık seviyelerinde test

edilmiştir. 5 katılımcı üzerinde yürütülen deneyde, en güçlü DDGUP tepkileri ortalama olarak %75.0 parlaklık düzeyinde gözlemlenmiştir. Ancak bu parlaklık düzeyinin kullanıcılar tarafından rahatsız edici bulunduğu belirtilmiştir. Ayrıca, sistemde kullanılan yüksek sayıda görsel uyarının kullanıcı konforunu düşürdüğü ifade edilmiş ve bu sebeple önerilen yöntemin uygulama açısından sınırlayıcı olduğu sonucuna varılmıştır.

Hibrit BBA sistemleri, birden fazla biyolojik sinyali bir araya getirerek tekil BBA sistemlerinden daha fazla komut kapasitesi, performans ve güvenilirlik sunmayı hedeflemektedir. Bu sistemlerde genellikle EEG ve EOG sinyalleri birlikte kullanılmakta ve doğal göz hareketleri ve göz kırpması gibi istemli EOG artefaktları, EEG tabanlı sistemlere ek kontrol sinyali sağlayabilmektedir. Örneğin, yapılan bir çalışmada araştırmacılar (Ramli ve ark., 2015) EEG–EOG hibrit sistemini tekerlekli sandalye kontrolünde kullanarak göz kırpmaları ile durum değiştirme komutları eklemiştir. Bir diğer çalışmada (Zhu ve ark., 2020) ise altı serbestlik dereceli robotik kol kontrolü için DDGUP ve EOG sinyallerini birleştiren asenkron bir hibrit BBA geliştirmiştir. Bu sistemde temel yönlendirme komutları 15 farklı frekansta yanıp sönen görsel uyarılarla EEG’den elde edilirken, kullanıcının art arda üç kez göz kırpmasıyla DDGUP arayüzü açılıp kapatılmış, böylece ihtiyaç duyulmadığında görsel uyarıların durdurulması ile hem yanlış tetiklemeler önlenmiş hem de görsel yorgunluk azaltılmıştır. On beş katılımcı ile yapılan deneylerde hibrit sistem ortalama 92.1% DO ve 35.98 (bit/dk) BAH değeri sağlamıştır.

Yapılan bir çalışmada araştırmacılar (Huang ve ark., 2019), entegre tekerlekli sandalye ve robot kol sistemini kontrol etmek için EEG ve EOG sinyallerini kullanan bir hibrit BBA önermiştir. Bu sistemde kullanıcı, sol/sağ el motor imgelemesiyle sandalyeyi sola/sağa sürerken; göz kırpması ve kaş kaldırma hareketleriyle diğer komutları gerçekleştirebilmiştir. Yirmi iki gönüllüyle yapılan deneyler, Mİ+EOG hibrit yaklaşımının birden fazla cihazı entegre şekilde kontrol etmek için yeterli doğruluğu sağlayabildiğini göstermiştir. Farklı bir çalışmada araştırmacılar (Kubacki, 2021) DDGUP, EOG, göz izleme ve kuvvet geribildirimini bir arada kullanarak bir sanal

endüstriyel robot kolunun kontrolünü sağlamıştır. Bu sayede EEG ile mümkün olandan daha hassas konumlama ve nesne sıralama başarımı elde etmiştir. Bir diğer çalışmada ise (Zhang ve ark., 2023) hibrit yöntemleri yazı yazma arayüzüne uyarlayarak, DDGUP ile harf seçimi ve sonrasında göz hareketiyle onaylama paradigmasını birleştiren bir BBA geliştirmiştir. Bu çalışmada 20 hedef karakter eşzamanlı yanıp sönerek DDGUP oluşturmaktadır; kullanıcı hedefe odaklandıktan sonra ekrandaki bölgesel butonlar hareket etmekte ve kullanıcının yalnızca hedefi gözleriyle takip etmesi istenmektedir. On sağlıklı denekte ortalama %94.8 doğruluk oranı ve 108.6 (bit/dk) BAH elde eden bu hibrit yazıcı sistemi, salt DDGUP tabanlı bir arayüze kıyasla geçiş süresini kısaltmış ve seçim güvenilirliğini yükseltmiştir.

EEG ile kaydedilen göz hareketi sinyalleri genellikle artefakt olarak görülse de istemli üretilen EOG sinyalleri güçlü ve tekrarlanabilir yapıları sayesinde doğrudan bir kontrol aracı haline getirilebilmektedir. Göz küresi hareketleri ve göz kapağı kasları, beyinden bağımsız olarak yüksek genlikli elektriksel potansiyeller üretmektedir. Bu potansiyeller, alın ve göz çevresine yerleştirilen birkaç elektrotla kolayca ölçülebilmektedir. Yapılan bir çalışmada araştırmacılar (Karas ve ark., 2023), istemli göz artefaktlarını kullanarak yardımcı bir robot kolun kontrolünü sağlamıştır. Bu çalışmada EEG içinde gürültü olarak beliren göz kırpması ve göz kaydırma sinyalleri, özel algoritmalarla tespit edilip komuta dönüştürülmüştür. Beş katılımcıyla test edilen bu yöntemle, kullanıcılar sadece göz hareketlerini kullanarak bir robotu arayüz üzerinden başarılı şekilde kontrol edebilmişlerdir. Bir diğer çalışmada (Kumar & Sharma, 2016), sanal gerçeklik ortamında bir oyun kontrolünü göz hareketleriyle sağlamak için 6 EOG elektrotlu bir giyilebilir arayüz geliştirmiştir. Bu sistemde kullanıcı yedi farklı göz hareketi komutunu gerçekleştirebilmiştir. EOG sinyallerinin yüksek ayırt edicilikle sınıflandırılabilmesi, göz hareketlerinin gürültü değil bilgi taşıyıcı sinyaller olduğunu ortaya koymuştur. Mİ kullanılarak elde edilen EEG sinyallerini sınıflandırırken EOG kanallarının yardımcı öznitelik olarak dâhil edildiği bir çalışmada (Özkahraman ve ark., 2024) ilginç bir şekilde sadece EEG'ye kıyasla anlamlı performans artışı sağlamıştır. 3 EEG ve 3 EOG kanalıyla %83.0 doğruluk elde edilerek, 22 kanallı klasik EEG sınıflandırması neredeyse yakalanmıştır. Bu sonuç, geleneksel olarak artefakt kabul edilen göz sinyallerinin uygun

şekilde değerlendirilmesi halinde faydalı işaretler olduğunu göstermiştir.

DDGUP tabanlı BBA sistemleri, özellikle yüksek BAH ve kısa kalibrasyon süresi gereksinimi avantajlarından dolayı yaygın olarak araştırılmaktadır. DDGUP, belirli frekansta tekrarlayan görsel uyarıların oksipital kortekste oluşturduğu sürekli ritmik EEG tepkisidir. Kullanıcı farklı frekanslarda yanıp sönen birçok hedef arasından birine odaklanarak seçim yapabilir; böylece aynı anda birden fazla komut adayı sunulabilir. Yapılan bir çalışmada (Zhang ve ark., 2023) tasarlanan hibrit sisteminde 20 farklı DDGUP hedefiyle yüksek hızlı bir sanal klavye gerçekleştirmiştir. Bir diğer çalışmada ise (Chen ve ark., 2015) önerilen yaklaşım, DDGUP yanıtının temel frekans bileşenlerini ayrı alt bantlarda korelasyon analizine tabi tutarak tanıma başarımını arttırmıştır. Bu yöntem, özellikle gürültülü ortamlarda veya yüksek frekanslı zayıf DDGUP sinyallerinde daha doğru tespit imkânı sunarak DDGUP tabanlı sistemlerin güvenilirliğini yükseltmiştir.

DDGUP gibi yanıp sönme tabanlı BBA sistemleri, performans açısından başarılı olmakla birlikte, uzun süreli kullanımda kullanıcı konforu önemli bir mesele haline gelmektedir. Yüksek kontrastlı ve düşük frekanslı yanıp sönen görsel uyarılar, bir süre sonra kullanıcılarda göz yorgunluğu, tahriş, baş ağrısı hatta epilepsiye neden olabilmektedir. Bu soruna çözüm olarak; yüksek frekanslı uyarıların insan gözünde sürekli bir ışık gibi algılanması üzerine çalışmalar yapılmıştır. Ancak yapılan bir çalışmada (Ladouce ve ark., 2022) yüksek frekans kullanımının DDGUP sinyal genliğini düşürerek sınıflandırma başarımını olumsuz etkilediğini raporlanmıştır. Bu çalışmada 60Hz gibi yüksek frekanslar konforu artırsa da BBA doğruluğu yeterince yüksek bulunamamıştır. Bir diğer strateji, görsel uyarana ara verilmesi veya kişiye göre uyarlanmasıdır. Örneğin bir çalışmada (Zhu ve ark., 2020) kullanıcı istemediğinde ekran uyarılarını tamamen kapatabilmektedir. Bu sayede kullanıcı, sadece komut vermek istediğinde yanıp sönen uyarılara maruz kalmakta, arada dinlenme imkânı bulmaktadır. Sonuçlar, bu isteğe bağlı uyarım özelliğinin görsel yorgunluğu belirgin şekilde azalttığını ve yanlışlıkla komut oluşmasını engellediğini göstermiştir. Ayrıca, her denemenin ardından göz kırpması gibi doğal hareketlere izin verilmesi de konforu arttıran küçük ama önemli bir uygulamadır.

Ek olarak, arka plan kontrastını düşürme, uyaran boyutunu optimize etme gibi yöntemlerle de gözdeki stresin azaltılması denenmiştir. Örneğin bir çalışmaya ait bulgular (Ladouce ve ark., 2022) düşük kontrastlı görsel uyaran kullanımının umut vaat ettiğini gösterirken, bazıları ise (Chai ve ark., 2019) görsel uyaranların tamamen yerine geçebilecek hareket temelli yaklaşımlarla benzer başarıya ulaşmayı amaçlamışlardır.

Görsel uyaranlara alternatif olarak, hareketli uyaranlar kullanılarak beynin sürekli görsel takip mekanizmalarını hedefleyen BBA paradigmaları geliştirilmiştir. Uyarının frekansının, beynin görsel alanlarında tıpkı DDGUP'ta olduğu gibi sürekli bir potansiyel ortaya çıkardığı ifade edilmiştir. Yapılan bir çalışmada (Chai ve ark., 2019), radyal büyüme ve küçülme hareketi yapan görsel hedefler kullanarak 8 hedefli bir sistem tasarlanmıştır. Büyüyüp-küçülen hareketli uyaranlarla, klasik görsel uyaranlar karşılaştırılmıştır. Sonuçlar, radyal hareket yaklaşımının ortalama 93.4% DO ve 42.5 (bit/dk) BAH değeri ile oldukça yüksek bir performansa ulaştığını göstermiştir. Katılımcılar, sürekli büyüyen küçülen daireleri gözleriyle takip etmenin yanıp sönen ışıklara göre çok daha az yorucu olduğunu bildirmişlerdir. Farklı bir çalışmada (Stawicki & Volosyak, 2020), çeşitli hareketli uyaran tipleri karşılaştırılmış ve bunlar arasında konfor veya performans açısından belirgin farklar olmadığı gözlemlenmiştir. Bazı araştırmalarda görsel uyaran ve hareket yörüngesi karşılaştırması yapıldığında bazı araştırmacılar görsel uyaranların daha yüksek DDGUP genliği sağladığını ancak konforunun düşük olduğunu savunurken, bazı araştırmacılar da uygun hareket yörüngesi tasarımıyla performans kaybı olmadan konfor kazanılabileceği rapor edilmiştir. Örneğin bir çalışmada (Peguero ve ark., 2023) klasik aç-kapa görsel uyaranların, hareketli uyaranlara kıyasla daha güçlü DDGUP yanıtı ürettiği ancak görsel konforun daha düşük olduğu raporlanmıştır. Bir diğer çalışmada (Vidal ve ark., 2011) ortaya atılan yöntemde ise, ekrandaki nesneler belirli yörüngelerde hareket etmiş ve kullanıcı hedef nesneyi gözleriyle takip etmiştir. Bir kamera ile kaydedilen göz hareketleri, önceden bilinen hedef yörüngelerle eşleştirilerek kullanıcının seçimi tespit edilmiştir. Araştırmacılar tarafından yapılan farklı bir çalışmada (Esteves ve ark., 2015) hareket yörüngeler yaklaşımı akıllı saat arayüzünde kullanıcılara gösterilerek kalibrasyon gerektirmeyen, eller serbest bir etkileşim sağlanmıştır. Bu arayüzlerin en büyük avantajı, kullanıcının sadece bilinçli

olarak bir hedefi takip ettiğinde sistemin komut oluřturması ve rastgele bakıřlarda sistemin tepki g stermemesidir. Ayrıca d ř k biliřsel y k ile doęal bir g z hareketi yeterli olduęundan bir ok kullanıcı i in konforludur. Bazı hibrit BBA'lerde ise g rsel uyarılar ile tetiklenen DDGUP kombine edilip sonrasında g z hareketi ile onaylama kullanılmıřtır. B ylece hem beyin hem g z sinyallerini kullanan  ok ařamalı bir se im yapılmıřtır.

Bir BBA sisteminin ger ek hayata uyarlanabilirlięi doęrudan birden fazla oturumda tutarlı performans g stermesine baęlıdır. EEG sinyalleri, elektrot konumu deęiřimleri, cilt-diren  farklılıkları, kullanıcının zihinsel/duygusal durumu gibi pek  ok nedenle oturumlar arası deęiřkenlik sergilemektedir. Bu durum, her yeni kullanım  ncesinde tekrar kalibrasyon yapma ihtiya ını doęurarak BBA'nin kullanımını zahmetli hale getirmektedir. Yapılan bir  alıřmada (Saha & Baumert, 2020), Sens rimotor Ritim (SR) tabanlı M  BBA sistemlerinde performansı d ř ren bu deęiřkenliklerin giderilmesi i in bir derleme sunarak, makine  ęrenimi temelli transfer  ęrenme y ntemlerini ve n rofizyolojik deęiřkenlik  ng r c leri tartıřılmıřtır. İncelemelerde, kalibrasyon gereksinimini azaltmak i in verisetleri arasında ortak  znitelik  ıkartan yaklařımların bařarı vaat ettięini belirtilmiřtir. Nitekim yapılan bir dięer  alıřmada (Giles ve ark., 2022), uzun d nemli BBA kullanıcıları i in her oturum bařındaki eęitim s resini kısaltmayı ama layan bir transfer  ęrenme algoritması geliřtirilmiřtir. 11 fel li hastanın 18 seanslık verisiyle yapılan deęerlendirmede, sadece her sınıf i in 2  rnek kullanılarak dahi,  nceki oturumların transferiyle modeli eęitmenin saf yeni oturum eęitimine g re %4' n  zerinde doęruluk artıřı saęladıęı g sterilmiřtir.

3. MATERYAL VE METOT


Bu bölümde, tez çalışması süresince sinyal kayıt aşamasında kullanılan materyaller ve sinyal işleme aşamasında kullanılan metotlar açıklanmıştır.

3.1. EEG Cihazları

3.1.1. Emotiv Epoc X

BBA sistemlerinin tasarım sürecinde, kullanıcı konforu, ekonomik erişilebilirlik, performans ve taşınabilirlik açısından tercih edilen EEG cihazları büyük önem taşımaktadır. Bu doğrultuda, giyilebilir formda olan, kablosuz bağlantı özelliğine sahip, düşük maliyetli ve ergonomik yapılı EEG cihazları öncelikli tercihler arasında yer almaktadır. Ayrıca cihaz seçiminde; kanal sayısı, donanım maliyeti, kurulum süresinin kısa olması, kullanım kolaylığı ve sistemin entegre edileceği BBA türü gibi kriterler belirleyici unsurlar olarak öne çıkmaktadır (Jiang ve ark., 2014).

Çalışmada tercih edilen Emotiv Epoc X EEG cihazı, 14 kanal üzerinden EEG sinyali kaydı yapabilme kapasitesine sahiptir. Lityum pille çalışan cihaz, yaklaşık 12 saate kadar kesintisiz mobil kullanım imkânı sunmakta ve kablosuz bağlantı özelliği sayesinde kullanıcıya hareket özgürlüğü sağlamaktadır. Kafa yapısına göre ayarlanabilen tasarımı bireysel uyumu arttırmakta; ekonomik fiyatı ve yaklaşık 15 dakikada tamamlanabilen hızlı kurulum süresi ile BBA uygulamaları açısından pratik ve ulaşılabilir bir seçenek hâline gelmektedir. Emotiv Epoc X cihazı (a) ve cihazın elektrot yerleşimi (b) Şekil 3.1’de sunulmaktadır.



Şekil 3.1. Emotiv Epoc X EEG cihazı (a) ve kafa üzerinde elektrotların konumları (b).

Şekil 3.1(a)'da verilen Emotiv Epoc X EEG cihazı, elektrotlar ile kafa derisi arasındaki empedansı azaltmak amacıyla özel olarak formüle edilmiş tuzlu su bazlı bir solüsyon kullanmaktadır. Bu solüsyonun tercih edilmesi, deney sonrasında katılımcının saçını yıkama zorunluluğunu ortadan kaldırarak hem hijyen hem de kullanıcı konforu açısından önemli avantajlar sunmaktadır. Cihaz, 128 SPS veya 256 SPS örnekleme hızlarında çalışabilmekte ve 16 bit çözünürlükle yüksek kaliteli EEG verisi sağlamaktadır. Veri kaydı ve yönetimi için cihazla entegre şekilde çalışan EmotivPRO yazılımı (v3.5.3), Emotiv şirketi (San Francisco, ABD) tarafından geliştirilmiştir. Şekil 3.1(b)'de gösterildiği üzere, cihaz üzerindeki elektrotlar uluslararası kabul görmüş 10–20 sistemine göre konumlandırılmıştır. Bu dizilime göre, F3, F4, AF3, AF4, F7 ve F8 bölgelerindeki elektrotlar frontal korteks aktivitelerini takip etmek için kullanılmaktadır. T7, T8, FC5 ve FC6 elektrotları işitsel ve görsel bilişsel işlevlerin yanı sıra dil süreçleriyle ilişkilendirilirken; P7 ve P8 elektrotları algı ve sayısal işlemeye yönelik sinirsel aktiviteleri izlemek üzere konumlandırılmıştır. O1 ve O2 bölgelerine yerleştirilen elektrotlar ise özellikle görsel algı, kısa süreli hafıza ve tepki süreleriyle ilişkilidir. Cihaz ayrıca iki referans elektrot ile sistemin elektriksel dengesini sağlamak üzere yapılandırılmıştır (Williams ve ark., 2020).

3.1.2. Emotiv Flex EEG cihazı

Emotiv cihazlarının yapılan çalışmalarda sık tercih edilme sebepleri arasında, diğer EEG cihazlarına göre daha düşük maliyetli olması, yeterli sayıda kanal sunması ve kullanım kolaylığı sağlaması yer almaktadır (Värbu ve ark., 2022). Emotiv Flex EEG cihazı, 32 kanal kapasitesine sahiptir ve üzerinde iki referans elektrot bulunmaktadır. Bu elektrotlardan biri aktif elektrot olan Common Mode Sense (CMS), diğeri ise pasif elektrot olarak adlandırılan Driven Right Leg (DRL) elektrotudur. Cihazın tüm elektrot konumları, uluslararası 10/20 sistemine uygun olarak yerleştirilmiştir. Şekil 3.2’de Emotiv Flex EEG başlığı gösterilmektedir.



Şekil 3.2. Emotiv Flex EEG cihazı.

Şekil 3.2’de gösterilen kablosuz bağlantı özelliğine sahip olan Emotiv Flex EEG cihazı, lityum pilleri sayesinde yaklaşık 9 saat boyunca kesintisiz kullanım imkânı sunmaktadır. Cihaz, kullanıcıya 128-256Hz örnekleme hızı ve 16-32 bit çözünürlük değerleri sağlamaktadır (Värbu ve ark., 2022).

3.2. Güç Spektral Yoğunluğu (GSY)

Kafa derisine yerleştirilen yüzey elektrotları aracılığıyla elde edilen EEG sinyalleri, bilgisayar ortamında voltaj-zaman serileri şeklinde kaydedilmektedir. Ancak bu sinyallerin zaman ve genlik düzeyinde doğrudan analiz edilmesi oldukça karmaşık ve sınırlayıcıdır. Bu nedenle, sinyalin frekans bileşenlerini daha anlaşılır ve ayrıştırılabilir hale getirmek için zaman alanında frekans alanına dönüşüm yapılması gerekmektedir. Bu tez çalışmasında, EEG verilerinin frekans özniteliklerini çıkartmak ve belirli bantlardaki enerji dağılımını değerlendirmek amacıyla Welch Güç Spektral Yoğunluğu (GSY) tahmin yönteminden faydalanılmıştır.

Welch yöntemi, zaman serisini örtüşen ve eşit uzunluktaki K adet segmente ayırarak her segment için ayrı ayrı periodogram hesaplamaktadır. Her bir segmentin uzunluğu L ile ifade edilmektedir. Ardından, bu periodogramların ortalaması alınarak nihai güç spektrum tahmini elde edilmektedir. Bu işlem sayesinde daha düşük varyanslı ve daha güvenilir bir spektral yoğunluk grafiği elde edilmektedir. Welch yönteminin matematiksel ifadesi Denklem 1'de sunulmuştur.

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

$$U = \frac{1}{L} \sum_{n=0}^{L-1} \omega^2(n) \quad (2)$$

Denklem 1'de, K örtüşen segmentlerin sayısını, L uzunluklarını, N sinyalin uzunluğunu ve f frekansı temsil etmektedir. Ek olarak, $x_i(n)$ giriş sinyalidir ve $\omega(n)$ pencereleme fonksiyonudur. Denklem 2'de, U ile gösterilen değer Denklem 1'de kullanılan pencere fonksiyonunun kuvvetini temsil etmektedir (Tiwari ve ark., 2022).

3.3. Korelasyon Hizalaması (KH)

Farklı oturumlarda kaydedilen biyolojik sinyaller arasında ortaya çıkan dağılım farklılıkları, makine öğrenme tabanlı sınıflandırıcıların genelleme başarısını olumsuz etkileyebilmektedir. Bu nedenle, bu çalışmada oturumlar arası dağılım farklarını azaltmak amacıyla Korelasyon Hizalaması (KH) yöntemi kullanılmıştır. KH, etiket bilgisine ihtiyaç duymadan, kaynak ve hedef veri kümelerinin kovaryans yapılarını hizalayarak dağılımsal uyum sağlamaktadır. Bu yöntem, kaynak veri kümesinin kovaryans matrisi beyazlatıldıktan sonra hedef veri kümesinin kovaryans yapısına göre yeniden renklendirilmesi prensibine dayanmaktadır. Böylece eğitim verisinin istatistiksel yapısı test verisine daha yakın hâle getirilerek, oturumlar arası transfer başarımı artırılmaktadır (Sun & Saenko, 2016). KH dönüştürülmüş kaynak verisi Denklem 3 ile ifade edilmektedir.

$$X_C = C_S^{-1/2} \times C_T^{1/2} \quad (3)$$

Burada X_C kaynak veri matrisi, $C_S^{-1/2}$ Kaynak kovaryans matrisinin ters karekökü ve $C_T^{1/2}$ hedef kovaryans matrisinin karekökünü ifade etmektedir.

3.4. Sayısal İntegrasyon (Trapez)

Bu çalışmada, 7Hz frekansında yanıp sönen LED aktif ve pasif durumda kaydedilen EEG sinyalleri arasında meydana gelen DDGUP farkı belirlemek amacıyla trapez sayısal entegrasyon yöntemi kullanılmıştır. Trapez yöntemi, bilimsel ve mühendislik tabanlı birçok alanda, bir fonksiyonun altında kalan alanı yaklaşık olarak hesaplamak için sıklıkla tercih edilen etkili bir yöntemdir. Bu teknikte, analiz edilmek istenen sinyal birbirine bitişik çok sayıda küçük trapez ile temsil edilmekte ve bu bölgelerin alanlarının toplamı alınarak yaklaşık integral değeri hesaplanmaktadır. Özellikle frekans spektrumunda

belirli bantlar altında kalan enerjiyi belirlemek için sayısal ve pratik bir çözüm sağlamaktadır. Bu yöntemin Denklem 4 ile ifade edilmektedir.

$$\int_a^b f(x)dx = \frac{h}{2} [f(x_0) + 2 \sum_{i=1}^{n-1} f(x_i) + f(x_n)] \quad (4)$$

Burada a ve b fonksiyonun integral aralığını, h her bir alt yamuğun genişliğini ve $(x_0, x_1, \dots, x_n)$ aralık içindeki eşit aralıklı noktaları temsil etmektedir.

3.5. Normalizasyon

Normalizasyon, makine öğrenmesi uygulamalarında verilerin ortak bir ölçeğe getirilmesini sağlayarak modelin öğrenme sürecini iyileştiren önemli bir ön işleme tekniğidir. Bu işlem, farklı aralık ve dağılıma sahip özniteliklerin karşılaştırılabilir hâle gelmesini sağlamaktadır. Normalizasyon için literatürde min-max ölçekleme, L2 normu ve Z-skor normalizasyonu gibi çeşitli yöntemler yaygın olarak kullanılmaktadır. Bu çalışmada ise, veriler üzerindeki varyans ve genlik farklarını ortadan kaldırmak amacıyla Z-skor temelli normalizasyon yöntemi kullanılmıştır. Bu yaklaşım, her bir gözlemin ait olduğu veri kümesinin ortalamasından ne kadar uzaklaştığını standart sapma cinsinden ifade etmektedir. Böylece tüm öznitelikler 0 ortalamaya ve 1 birimlik standart sapmaya indirgenmektedir. Z-skor temelli normalizasyon matematiksel olarak Denklem 5 ile ifade edilmektedir.

$$x' = \frac{x - \mu}{\sigma} \quad (5)$$

Burada x normalleştirilecek veriyi, μ veri ortalamasını ve σ veri standart sapmasını ifade etmektedir.

3.6. Varyans Analizi (VA)

Sinyal işleme uygulamalarında, farklı sınıfları birbirinden ayırt edebilmek amacıyla veri kümelerinden anlamlı özniteliklerin çıkartılması kritik bir adımdır. Ancak her çıkartılan öznitelik sınıflar arasında yüksek ayırt edicilik sağlamayabilmektedir. Bu gibi durumlarda, sınıflandırma performansını artırmak için öznitelik seçim ya da eleme süreci uygulanabilmektedir. Varyans Analizi (VA) bu amaçla kullanılan yaygın istatistiksel yöntemlerden biridir. VA testi, farklı gruplar arasında anlamlı varyans farklarının olup olmadığını değerlendirerek hangi özniteliklerin daha ayırt edici olduğunu belirlemeye yardımcı olmaktadır. Çoğu istatistiksel analiz yazılımı, VA'yı doğrudan ham veri üzerinde uygulama imkânı sunmaktadır (Sthle & Wold, 1990). VA'nın temel matematiksel yapısı ve hesaplaması Denklem 6 ile ifade edilmektedir.

$$VA = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \hat{Y})^2 \quad (6)$$

Burada Y_{ij} , i . gruba ait j . gözlem değerini temsil ederken; $\hat{Y}$, tüm gruplardaki gözlemlerin genel ortalamasını ifade etmektedir. k , toplam grup sayısını, n_i ise her bir i . gruptaki gözlem sayısını göstermektedir.

3.7. Polinom Eğrisi Uydurma Yöntemi

Çalışmanın ikinci sınıflandırma safhasını oluşturan EOG artefaktlarının zaman alanında sınıflandırılması için Polinom Eğrisi Uydurma Yöntemi kullanılmıştır. Bu yöntem veri seti üzerinde en küçük kareler yöntemine dayalı olarak bir polinom modeli oluşturma işlemidir. Yöntemde başlangıç ve bitiş veri noktaları ile model arasındaki toplam hata minimize edilerek en uygun polinom katsayıları elde edilmektedir. Polinom modeli Denklem 7 ile ifade edilmektedir.

$$p(x) = a_0x^n + a_1x^{n-1} + \dots + a_{n-1}x + a_n \quad (7)$$

Burada n polinomun derecesini, a_i ise polinom katsayılarını temsil etmektedir. Çalışmada, polinom eğrisi uydurmak amacıyla polyfit fonksiyonu kullanılmıştır. Polyfit, x değerlerine bağlı olarak bir Vandermonde matrisi oluşturmakta ve bu matris üzerinden Denklem 8’de verilen en küçük kareler çözümü ile polinom katsayıları hesaplanmaktadır.

$$a = (V^T V)^{-1} V^T y \quad (8)$$

Burada, V Vandermonde matrisi, a polinom katsayı vektörü ve y ise gözlenen veri değerleri vektörüdür. Çalışmada, veri yapısına ve eğri uydurma doğruluğuna bağlı olarak polinom derecesi belirlenmiş ve uygun modelin seçilmesi sağlanmıştır.

3.8. Doğruluk Oranı (DO)

DO, BBA sistemlerinde en yaygın olarak benimsenen performans ölçütleri arasındadır. Doğru tahmin edilen örneklerin yapılan toplam tahmin sayısına oranını hesaplayarak bir modelin sınıflandırma performansının basit bir ölçüsünü sağlamaktadır. Özellikle doğru tahminlerin, doğru ve yanlış tahminlerin toplamına oranı olarak tanımlanmaktadır. DO, Denklem 9 ile hesaplanmaktadır.

$$DO = \frac{\text{doğru sınıflandırılmış tahminler}}{\text{toplam örnek sayısı}} \quad (9)$$

Literatürde, sınıflandırma doğruluğu genellikle Hold-out geçerleme yöntemleri

aracılığıyla değerlendirilmektedir. Bu yöntem, veri kümesini iki ayrı gruba ayırarak işlemi gerçekleştirilmektedir. Gruplardan biri modelin öğrenmesi için kullanılan eğitim kümesi, diğeri ise modelin başarımını değerlendirmek amacıyla kullanılan test kümesidir. Eğitim aşamasında sistem, örüntüleri öğrenerek bir sınıflandırma modeli oluşturmakta ve ardından bu model, daha önce görmediği test verileri üzerinde denenerek performansı ölçülmektedir. Bu sürecin daha güvenilir ve gerçeğe yakın sonuçlar vermesi için veri kümesi sıklıkla rastgele karşılaştırılmakta ve işlem birkaç kez tekrarlanarak elde edilen doğruluk değerlerinin ortalaması alınmaktadır. Bu yaklaşım, sistemin kararlılığını ve tutarlılığını sağlamak açısından önemli bir avantaj sunmaktadır (Melek ve ark., 2020).

3.9. Bilgi Aktarım Hızı (BAH)

BAH, bir sistemin gerçek zamanlı kullanım potansiyelini değerlendirmede kullanılan temel performans parametrelerinden biridir. Bu parametre sistemin yalnızca doğruluğunu değil, aynı zamanda karar süresini ve sınıf sayısını da dikkate alarak daha bütüncül bir değerlendirme sunmaktadır. Bu yönüyle, klasik doğruluk ölçütlerinden daha kapsamlı bir başarı değerlendirmesi sağlamaktadır. Shannon bilgi teorisine dayalı olarak geliştirilen bu metrik, birim zamanda sistem aracılığıyla bilgi aktarım hızı (bit/dk) cinsinden ifade etmektedir. BAH'nin matematiksel hesaplaması Denklem 10 ile tanımlanmakta olup; doğruluk oranı, sınıf sayısı ve karar süresi parametreleri dikkate alınarak hesaplanmaktadır (Wolpaw ve ark., 1998).

$$B_t = \log_2 K + p \log_2 p + (1 - p) \log_2 \left(\frac{1-p}{K-1} \right) \quad (10)$$

Bu formülde, K değişkeni sistem kullanıcılarına sunulan toplam sınıf veya komut sayısını, p ise sistemin elde ettiği sınıflandırma doğruluğunu temsil etmektedir. Hesaplanan BAH değeri, birim zamanda aktarılan bilgi miktarını gösteren B_t ile ilişkilendirilerek Denklem 11 yardımıyla ifade edilmektedir.

$$BAH = 60 * \frac{Bt}{T} \quad (11)$$

Burada T , sınıflandırma süreci boyunca sistemin tek bir karar üretmesi için geçen zamanı, yani her bir tahmin için ayrılan süreyi ifade etmektedir. BAH parametresi, BBA sistemlerinin gerçek hayat uygulamalarına adapte edilebilmesi için vazgeçilmezdir.

3.10. Sinyal Gücü ve Enerjisi

Enerji, özellikle EOG gibi sinyallerde göz hareketinin gücünü, genliğini veya süresini temsil eden, sağ-sol ya da yukarı-aşağı gibi farklı yönlerde bakışlarda ortaya çıkan sinyallerin ayırt edilmesinde güçlü bir özneliktir. Bu parametre, bir sinyalin toplam içerdiği karelenmiş genliklerinin toplamı olarak tanımlanmaktadır. Güç ise veri kümesindeki tek bir örnek başına düşen ortalama enerjiyi ifade etmektedir. Enerji özneliği Denklem 12 ile Güç ise Denklem 13 ile ifade edilmektedir.

$$E = \sum_{n=1}^N x(n)^2 \quad (12)$$

$$P = \frac{1}{N} \sum_{n=1}^N x(n)^2 \quad (13)$$

Denklemlerde (12-13), $x(n)$ sinyale ait n 'inci örneği, N ise toplam örnek sayısını temsil etmektedir.

3.11. Hassasiyet, Özseçicilik ve F1-skor Parametreleri

Hassasiyet, modelin yaptığı pozitif tahminlerin ne kadarının gerçekten doğru olduğunu

gösteren bir ölçüttür. Ölçüt Denklem 14 ile ifade edilmektedir (Powers, 2011).

$$hassasiyet = \frac{DP}{DP+YP} \quad (14)$$

Özseçicilik ise bir modelin gerçek pozitif verileri ne kadar iyi tahmin edebildiğini gösteren kritik bir ölçüttür. Düşük özseçicilik oranı sistemin önemli verileri gözden kaçırdığını gösterir. Özseçicilik ölçütü Denklem 15 ile hesaplanmaktadır (Powers, 2011).

$$\text{Özseçicilik} = \frac{DP}{DP+YN} \quad (15)$$

F1-skor, hassasiyet ve özseçicilik arasındaki dengeyi sağlayarak, sınıflandırma modelinin genel başarımını dengeli şekilde değerlendirmek için kullanılmaktadır. DO'nın yanıltıcı sonuçlar verebileceği dengesiz sınıf dağılıma sahip verisetinde F1-skoru daha adil bir ölçüt olarak önem kazanmaktadır. F1-skor Denklem 16 ile hesaplanmaktadır (Powers, 2011).

$$F1 - skor = 2 \times \frac{hassasiyet \times \text{özseçicilik}}{hassasiyet + \text{özseçicilik}} \quad (16)$$

F1-skor ölçütü 0-1 aralığında değer almaktadır. Ölçüt 1'e yaklaştıkça model tarafından yapılan tahminlerin mükemmel olduğu 0'a yaklaştıkça ise modelin doğru tahmin yapamadığı kararına varılmaktadır.

3.12. k-En Yakın Komşular (k-EYK)

k-En Yakın Komşu (k-EYK) algoritması, BBA sistemlerinde yaygın olarak tercih edilen denetimli bir makine öğrenme yöntemidir. Bu algoritma, sınıflandırılması gereken bir örneğin, özellik uzayında kendisine en yakın olan k adet komşusunun sınıf etiketlerine bakılarak karar verilmesini esas almaktadır. Buradaki k , dikkate alınacak komşu sayısını belirleyen ve önceden tanımlanan bir hiperparametredir. Bu nedenle, sınıflandırma performansı doğrudan seçilen k değeri ile ilişkilidir. Uygulamada, genellikle k değeri, toplam örnek sayısının karekökünden küçük olacak şekilde seçilmektedir. k-EYK algoritmasında komşuluk ilişkisi, örnekler arasındaki mesafeye dayalı olarak belirlenmektedir. Bu mesafe genellikle Öklid (Denklem 17), Manhattan (Denklem 18) veya Minkowski (Denklem 19) uzaklık ölçütleri kullanılarak hesaplanmaktadır (Mulak & Talhar, 2013).

$$d_{xy} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (17)$$

$$d_{xy} = \sum_{i=1}^k |x_i - y_i| \quad (18)$$

$$d_{xy} = (\sum_{i=1}^k (|x_i - y_i|)^q)^{1/q} \quad (19)$$

Denklemlerde (17–19), k veri noktalarının sayısı, i verilerin indeksini ve d mesafeyi göstermektedir.

3.13. Destek Vektör Makinesi (DVM)

Destek Vektör Makinesi (DVM), özellikle sınıflandırma problemlerinde yaygın olarak kullanılan denetimli bir makine öğrenme algoritmasıdır. Bu yaklaşım, verileri farklı sınıflara en iyi şekilde ayıran optimum karar sınırlarını belirlemeyi amaçlamaktadır. Bazı veri doğrusal olarak ayrılabilirken, birçok gerçek dünya verisi doğrusal olarak ayrılamamaktadır. Bu gibi durumlarda, veri noktalarının daha yüksek boyutlu bir özellik uzayına taşınması için çekirdek (kernel) fonksiyonları kullanılmaktadır. Bu dönüşüm sayesinde, doğrusal olmayan ayrımlar bile doğrusal sınırlayıcı yüzeylerle temsil edilebilir hâle gelmektedir (Cortes ve ark., 1995). Bu çalışmada, çekirdek yöntemi olarak Gauss tabanlı Radyal Baz Fonksiyonu (RBF) tercih edilmiştir. RBF çekirdeği, iki örnek arasındaki uzaklığa bağlı olarak Denklem 20 ile ifade edilmektedir.

$$K(x_i, x_j) = \varphi(x_i) \times \varphi(x_j) \quad (20)$$

İki örnek veri noktasına RBF çekirdek fonksiyonu uygulandığında, bu fonksiyon tarafından oluşturulan karar yüzeyine ait vektörel ağırlık değeri, Denklem 21 yardımıyla hesaplanmaktadır. Bu ifade, karar sınırının şekillenmesinde temel rol oynayan benzerlik ölçümünü yansıtmaktadır.

$$W = \sum_i a_i y_i \varphi(x_i) \quad (21)$$

DVM sınıflandırıcısı, model karmaşıklığı ile genelleme kabiliyeti arasındaki dengeyi sağlamak amacıyla Denklem 22’de ifade edilen optimizasyon fonksiyonunu minimize etmektedir (Cortes ve ark., 1995). Bu yaklaşım hem yüksek doğruluk hem de aşırı öğrenmeden kaçınma hedefiyle boyutluluk ve esneklik arasında optimal bir denge kurulmasına olanak tanımaktadır.

$$\left[\frac{1}{n} \sum_{i=1}^n \max \left(0, 1 - y_i (x^k x_i - b) \right) \right] + \lambda |w|^2 \quad (22)$$

3.14. Rastgele Orman (RO)

Rastgele Orman (RO), topluluk öğrenme yöntemlerinden biri olan torbalama yaklaşımının bir uzantısı olarak geliştirilmiştir ve özellikle sınıflandırma problemlerinde sıkça tercih edilmektedir (Breiman, 1996). Bu yöntem, eğitim süresinin kısalığı, yüksek boyutlu verilerle etkili çalışabilmesi ve sınırlı sayıda hiperparametre gerektirmesi gibi avantajları sayesinde, birçok geleneksel sınıflandırma algoritmasına kıyasla öne çıkmaktadır. RO algoritması, her biri rastgele seçilen öznitelik altkümelerine dayalı olarak oluşturulan çok sayıda karar ağacından meydana gelmektedir. Her bir ağaç, eğitim verisinin farklı örneklerinden oluşturulmuş alt kümelerle eğitilmektedir. Bu çerçevede, $f(x)$ boyutunda gerçek değerli rastgele bir vektör ile rastgele seçilen bir hedef değişkenin bilinmeyen ortak dağılımı dikkate alınmaktadır. RO'nin temel amacı, hedef değişkeni tahmin etmek üzere bir kayıp fonksiyonunu minimize eden bir karar fonksiyonu elde etmektir (Zhang & Ma, 2005).

3.15. Lineer Diskriminant Analiz (LDA)

Lineer Diskriminant Analiz (LDA), sınıflar arasındaki ayrımı maksimize etmeyi ve aynı sınıf içerisindeki varyasyonu minimize etmeyi hedefleyen denetimli bir makine öğrenme yöntemidir (Bishop, 1995). Bu algoritma, yalnızca sınıflandırma amacıyla değil, aynı zamanda boyut indirgeme aracı olarak da sıkça tercih edilmektedir. LDA, veriyi daha az boyutlu fakat daha ayırt edici bir uzaya yansıtarak, sınıflar arasındaki ayrımı kolaylaştırmaktadır. Bu bağlamda, algoritma; sınıf içi ve sınıflar arası dağılımları tanımlayan matrisleri temel almaktadır. Bu matrisler Denklem 23 ile ifade edilmektedir.

$$S_{\omega} = \frac{\sum_k \sum_{i \in c_k} (x^i - m_k)(x^i - m_k)^T}{N}, S_b = \frac{\sum_k n_k (m_k - m)(m_k - m)^T}{N} \quad (23)$$

Burada $\frac{1}{n_k} \sum_{i \in c_k} x^i$ ifadesi, k sınıfına ait örneklerin ortalama vektörünü tanımlamaktadır. Benzer şekilde, $m = \frac{1}{N} \sum_i x^i$ ifadesi ise tüm veri kümesinin genel ortalamasını temsil etmektedir. LDA algoritması, sınıflar arası ayrımı optimize ederken, bu ortalamalar ve dağılımlar üzerinden çalışmaktadır. Algoritma, genellikle eğitilmiş veri üzerinden bir Gaussian karışım modeli kurularak sınıflar arasında farklılık yaratmayı mümkün kılmaktadır. Ancak, bu model yalnızca eğitim sürecinde temsil edilen sınıflarla sınırlıdır; yani daha önce karşılaşılmamış yeni sınıf örneklerini sınıflandırmakta yetersiz kalabilmektedir (Ioffe, 2006).

3.16. Torbalama Algoritması

Torbalama Algoritması (TA), istatistiksel yeniden örnekleme ve topluluk öğrenmesini birleştiren güçlü bir yöntemdir. Yöntem özellikle yüksek varyansa sahip sınıflandırıcıların genelleme yeteneğini artırmak amacıyla geliştirilmiştir ve eğitim verisinden rastgele ve tekrarlı olarak seçilen alt kümeler üzerinde birden fazla zayıf öğrenici (genellikle karar ağaçları) eğitilmesini ve bu bireysel tahminlerin çoğunluk oyu ile birleştirilmesini temel almaktadır (Breiman, 1996). Böylece, her bir model eğitim setinin farklı bir örnekleme üzerinde çalıştığı için model varyansı azaltılmakta ve öğrenme sürecinde oluşabilecek aşırı uyum riski önemli ölçüde azaltılmaktadır (Dietterich, 2000).

3.17. Katılımcılar


Bu çalışmada Emotiv Epoc X EEG cihazı ile oluşturulan veriseti, yaşları 18 ile 45 arasında değişen (ort. 30.7), herhangi bir sağlık sorunu veya bağımlılığı bulunmayan

(sigara kullanımı hariç) gönüllü bireyler dahil edilmiştir. Denekler, deneysel süreçler hakkında detaylı şekilde bilgilendirilerek, Gönüllü Onam Formu (GOF) doldurmak suretiyle çalışmaya katılmıştır. Deneysel uygulamalar toplam 10 katılımcı (4 kadın ve 6 erkek) ile gerçekleştirilmiştir.

Emotiv FLEX EEG başlık ile oluşturulan veriseti ise herhangi bir bağımlılığı veya kronik hastalığı olmayan, yaşları 20-30 aralığında (ort. 22.5) 15 sağlıklı bireyin (6 kadın, 9 erkek) katılımıyla gerçekleştirilmiştir. Katılımcılar çalışma hakkında detaylı olarak bilgilendirilmiş ve GOF doldurtularak çalışmaya dahil edilmişlerdir. Araştırma süreci, Trabzon Kanuni Eğitim ve Araştırma Hastanesi Tıp Fakültesi Etik Kurulu tarafından 23618724 protokol numarası ile onaylanarak etik uygunluk çerçevesinde yürütülmüştür.

3.18. Sinyal Kayıt Aşaması

Emotiv Epoc X EEG cihazı ile yapılan veri kaydı için deneysel düzenek: 144Hz yenileme hızına, 1 ms tepki süresine ve 27 inç (yaklaşık 68 cm) ekran boyutuna sahip bir LCD monitörün, boş ve sessiz bir odada düz bir masa üzerine yerleştirilmesiyle oluşturulmuştur. Görsel uyaran olarak kullanılan 7Hz frekanslı LED, ekranın üst orta noktasına yerleştirilmiştir. Katılımcının ekranla olan görsel hizasını sağlamak amacıyla, ekrana tam karşıdan bakabilecek şekilde ve 120 cm mesafede bir sandalye konumlandırılmıştır. Deneğin ekrana olan bu uzaklığı temel alınarak, yatay (a) ve dikey (b) göz açıları Şekil 3.3’de sunulmaktadır.



Şekil 3.3. Deneğin X (a) ve Y (b) eksenleri boyunca oluşan maksimum göz açıları.

İnsan gözü, yatay düzlemde yaklaşık 178° ve dikey düzlemde ise 135° 'lik bir görsel algı alanına sahip, kavisli bir anatomik yapıya sahiptir. Bununla birlikte, zamansal yönde görüş alanını sınırlayan maksimum açı genellikle 105° olarak tanımlanmaktadır (Simpson, 2017). Göz hareketlerinin izlenmesine dayalı sistemlerde, gözün hareket açısı büyük önem taşımaktadır; çünkü daha belirgin göz hareketleri, daha anlamlı ve güçlü sinyallerin elde edilmesini sağlamaktadır. Ancak, aşırı geniş açılar kullanıcının görsel hedefe çok yakın olduğunu gösterdiğinden rahatsızlık hissine neden olabilmektedir. Yapılan bir çalışmada, deneysel uygulamalarda kullanılan göz hareketi açıları genellikle 20° ile 30° arasında sınırlandırılmıştır (Roescher ve ark., 2023). Şekil 3.3'te sunulan deney düzeneğinde yer alan mesafe değerleri temel alınarak, yatay (X) ve dikey (Y) eksenler için oluşabilecek maksimum göz hareketi açıları Tablo 3.1'de sunulmaktadır.

Tablo 3.1. Uzaklığa bağlı olarak X-Y eksenlerinde oluşan maksimum göz açıları.

Eksen	X	Y	Z
Mesafe (cm)	60	35	120
Bakış Açısı ($^\circ$)	29.5	16.5	-

İnsan gözünde, kornea ile retina arasında Korneoretinal Potansiyel (KP) olarak adlandırılan doğal bir elektriksel potansiyel farkı bulunmaktadır. Bu yapıda kornea pozitif, retina ise negatif bir elektrik yükü taşımaktadır. KP potansiyeli, göz çevresine

yerleştirilen elektrotlar aracılığıyla EOG sinyali olarak kaydedilebilmektedir. Elde edilen bu EOG sinyalleri, göz küresinin pozisyonu hakkında bilgi verdiğinden, göz hareketlerinin tespiti amacıyla yaygın biçimde kullanılmaktadır (Fang & Shinozaki, 2018).


Çalışmada kullanılan dört farklı hareketli yörünge arasındaki açılar, göz eksenlerinde meydana gelen açısal değişimler göz önünde bulundurularak tanımlanmıştır. Sağ–sol yönlü hareketler sırasında yalnızca yatay eksenindeki göz açıları dikkate alınırken; yukarı–aşağı yönlü hareketler için dikey eksenindeki açısal değişimler temel alınmıştır. Çapraz yörüngeler ise her iki eksenin eşzamanlı değişimini içermektedir. Sağ çapraz hareket yörüngesinde X ve Y eksenindeki açılar pozitif yönde değerlendirilirken, sol çapraz hareket yörüngesinde bu açılar gözün yapısına bağlı olarak ters yönde meydana gelmektedir. Bu çalışmanın geliştirilme sürecinde çeşitli göz hareketi yörüngeleri test edilmiştir. Özellikle dairesel ve üçgen biçimli yörüngeler için EEG verileri toplanmış ve bu sinyaller mevcut sinyal işleme algoritmaları ile analiz edilmiştir. Ancak, gerçekleştirilen analizler sonucunda, bu iki yörüngenin benzer eksen açılarına sahip olması nedeniyle sistem tarafından ayırt edilmesinin güç olduğu görülmüştür. Çalışma için hazırlanan veri kayıt düzeneğinde (Şekil 3.3) kullanıcının ekrana olan uzaklığına (120cm) bağlı olarak meydana gelen Göz eksenlerindeki hareket yörüngelerinin neden olduğu açı değişiklikleri Tablo 3.2’de verilmektedir.

Tablo 3.2. Göz eksenlerindeki hareket yörüngelerinin neden olduğu açı değişiklikleri.

Yörünge	X Eksen		Y Eksen	
	Sağ	Sol	Sağ	Sol
Sağ-sol	+14.0	-14.0	0	0
Yukarı-aşağı	Yukarı	Aşağı	Yukarı	Aşağı
	0	0	+8.0	-8.0
Sağ çapraz	Sağ üst	Sol alt	Sağ üst	Sol alt
	+14.0	-14.0	+8.0	-8.0
Sol çapraz	Sol üst	Sağ alt	Sol üst	Sağ alt
	-14.0	+14.0	+8.0	-8.0


Elde edilen bulgular, BBA sistemlerinin yüksek doğruluk oranlarına ulaşabilmesi için yörüngeler arasında belirgin eksen açısı farkı bulunmasının kritik öneme sahip olduğunu ortaya koymuştur. Bu doğrultuda, yapılan deneysel testler sonucunda en yüksek sınıflandırma başarımını sağlayan dört yörünge belirlenmiş ve nihai sistemde bu yörüngeler kullanılmıştır.

Deneysel uygulamalara geçilmeden önce, çalışma ortamı dikkat dağıtıcı çevresel etkilerden (ışık, ses, hareket vb.) izole edilerek uygun koşullar sağlanmıştır. Veri toplama sürecine geçilmeden önce kayıt cihazı dezenfekte edilmiş ve her katılımcı bireysel olarak deney odasına alınmıştır. Katılımcılara, deney sürecinde kullanılan cihazların ve prosedürlerin insan sağlığı açısından herhangi bir risk oluşturmadığı açıkça ifade edilmiştir. Bilgilendirme sonrasında, etik ilkeler doğrultusunda yazılı GOF formları alınmıştır. İlk olarak katılımcılara Emotiv Epoc X EEG cihazı giydirilmiştir. Cihazın elektrotlarının iletkenliğini artırmak amacıyla, uygulama sırasında tuzlu su çözeltisi kullanılmıştır. EEG başlığı takıldıktan sonra, sinyal kalitesi Emotiv tarafından geliştirilen EmotivBCI yazılımı aracılığıyla bilgisayar üzerinden kontrol edilmiş ve sinyal düzeyleri %98'in üzerine ulaştığında sistem hazır hale gelmiştir. Deney öncesinde katılımcılara takip etmeleri gereken hareketli nesneler ve yörüngeler hakkında gerekli yönlendirmeler yapılmıştır. Uygulanan yöntemde dört temel yörünge tipi vardır: sağ–sol yönlü yatay hareket, yukarı–aşağı yönlü dikey hareket, sağ çapraz hareket ve sol çapraz hareket. Bu hareket yolları üzerinden oluşturulan deney düzeneği Şekil 3.4'te gösterilmektedir.



Şekil 3.4. Yaklaşımın uygulanma sırası.


İlk aşamada, 7Hz frekansında yanıp sönen LED aktif hâle getirilmiştir (Şekil 3.5(a)). Deneysel protokol, sağ-sol yönlü göz hareketlerine yönelik olarak, başlangıçta üç saniyelik bir uyarı sesi ile başlatılmıştır. Bu uyarının ardından, saniyede bir tam devir gerçekleştiren beyaz renkli hareketli nesne katılımcıya 10 saniye boyunca gösterilmiştir. Sürenin sonunda tekrar üç saniyelik uyarı sesi ile kayıt tamamlanmıştır. Bu süreç hem sağa sol hareket yörüngesi için toplamda 10 kez tekrar edilmiştir. Her kayıt oturumu arasında katılımcılara bir dakikalık dinlenme süresi verilmiştir. Aynı prosedür, yukarı-aşağı, sağ-çapraz ve sol-çapraz yörüngelerindeki hareketli nesne uyarıları için de uygulanmış ve her bir yörünge tipi için 10 tekrar yapılmıştır. Deneysel sürecin LED'in açık ve kapalı olduğu senaryolara ait görsel temsilleri Şekil 3.5'de sunulmaktadır.



Şekil 3.5. LED'in aktif (a) ve pasif (b) olduğu durumlarda EEG sinyal kaydına ilişkin deneysel düzenek.


Veri toplama sürecinin ikinci aşamasında, 7Hz frekansına sahip LED kapatılmıştır (Şekil 3.5.(b)). Bu aşamada deneklere ilk olarak, sağ-sol hareket yörüngesi 10 saniye boyunca gösterilmiş, kayıt başlangıcında 3 saniyelik bir uyarı sesi verilmiştir. Kayıt, yine 3 saniyelik bir uyarı sesiyle sonlandırılmıştır. Sağ-sol yönlü hareketlere ilişkin bu süreç, her katılımcı için on kez tekrarlanmıştır. Aynı yöntemle yukarı-aşağı, sağ çapraz ve sol çapraz hareket yörüngeleri için de 10'ar tekrarlı kayıtlar alınarak deney tamamlanmıştır.

Literatürde göz hareketlerine dayalı BBA sistemlerine yönelik yapılan çalışmalarda (Bobrov ve ark., 2011; Ngo ve ark., 2021; Saichoo ve ark., 2021), özellikle frontal bölgede konumlanan AF3, F7, F8 ve AF4 elektrotlarının sıklıkla aktif kanallar olarak belirlendiği görülmüştür. Bu doğrultuda, mevcut çalışmada da söz konusu kanalların yüksek ayırt edici güce sahip olacağı varsayılmıştır. AF3, F7, F8 ve AF4 elektrotlarından elde edilen, EOG artefaktları içeren ham EEG sinyalleri; yukarı-aşağı göz hareketi için Şekil 3.6(a)'da, sol-çapraz hareket için Şekil 3.6(b)'de, sağ-sol hareket için Şekil 3.7(a)'da ve sağ-çapraz hareket için Şekil 3.7(b)'de görsel olarak sunulmaktadır. Ayrıca deney sırasında LED'in aktif olduğu durumlarda elde edilen kayıtlar “aydınlatılmış veriler”, LED'in kapalı olduğu durumlarda elde edilen kayıtlar ise “aydınlatılmamış veriler” olarak tanımlanmıştır.




Şekil 3.6. Yukarı-aşağı (a) ve sol-çapraz (b) göz hareketlerine karşılık gelen, AF3, F7, F8 ve AF4 kanallarında kaydedilen ham EEG sinyallerinde göz hareketlerinden kaynaklanan EOG artefaktlarının oluşturduğu örüntüler.

Deney süresince toplam 800 EEG kaydı elde edilmiştir. Bu kayıtlar, 256Hz örnekleme frekansı ile toplanmış ve Emotiv firması tarafından sağlanan EmotivPRO yazılımı kullanılarak “.csv” formatına dönüştürülmüştür. Elde edilen veriler, sinyal işleme ve analiz aşamaları için Matlab (R2023b) ortamına aktarılmıştır.



Şekil 3.7. Sağ-sol (a) ve sağ-çapraz (b) yönlerinde gerçekleşen göz hareketlerine karşılık olarak, AF3, F7, F8 ve AF4 kanallarında kaydedilen ham EEG verilerinde göz hareketlerinden kaynaklanan EOG artefaktlarının oluşturduğu sinyal desenleri.

Emotiv FLEX EEG cihazı kullanılarak yapılan veri kaydı için ise: Intel Core i7-12650 işlemcili ve NVIDIA RTX 4060 grafik kartına sahip bir dizüstü bilgisayar ve 260Hz yenileme hızına sahip 31.5 inçlik LCD ekran kullanılmıştır. Görsel uyarım için, ekranın üst orta noktasına 7Hz frekansında yanıp sönen bir LED yerleştirilmiş, denek ise ekrandan yaklaşık 90 cm uzaklıktaki bir sandalye üzerine konumlandırılmıştır. Veri toplama işlemi, çevresel etkenlerin (örneğin, ses, ışık, hareket) deney üzerinde bozucu etkisini minimize etmek amacıyla akustik ve görsel olarak izole edilmiş bir laboratuvar ortamında gerçekleştirilmiştir. Her bir deneğe deney öncesinde prosedür detaylı şekilde açıklanmış ve GOF doldurtularak onayları alınmıştır. EEG başlığı, üretici firmanın tavsiyeleri doğrultusunda salinli su kullanılarak konumlandırılmış, temas kalitesi ise EmotivBCI yazılımı ile en az %98 sinyal doğruluğu hedeflenerek doğrulanmıştır. Elektrot yerleşimi uluslararası 10-20 sistemine uygun olarak konumlandırılmış ve her oturum öncesinde yeniden salin solüsyonu ile temas kalitesi optimize edilmiştir. Bu çalışmada, yalnızca frontal lob bölgesindeki dört EEG kanalı (Fp1, F7, F8, Fp2) aktif olarak kullanılmıştır. Bu kanal seçimi hem sistem karmaşıklığını azaltmak hem de göz hareketleriyle ilişkilendirilen artefaktların en yüksek düzeyde elde edilebileceği bölgeleri hedeflemek amacıyla yapılmıştır (Liu ve ark., 2022). Şekil 3.8’de kullanılan kanalların konumları (a) ve kullanılan kanallara ait veri akış ekranı (b) gösterilmiştir.




Şekil 3.8. Çalışmada kullanılan kanalların konumları(a) ve kullanılan kanallara ait veri akış ekranı (b).

Şekil 3.8’de gösterilen elektrotlar kullanılarak, veriler sabah saatlerinde (08:00-10:00) ve akşam saatlerinde (16:00-18:00) olmak üzere iki oturumda gerçekleştirilmiştir.

3.18.1. Birinci oturum


Birinci oturum, kullanıcıların sabah saatlerinde (08:00–10:00) gösterdiği bilişsel performans farklılıklarını ölçmek amacıyla gerçekleştirilmiştir. Oturum, 7Hz LED’in aktif hâle getirilmesiyle başlamıştır. Her bir deney, 3 saniyelik sesli bir başlangıç işaretiyle başlatılmış ve ekranın sol üst köşesinde hareket eden “sol çapraz” yönlü bir beyaz top animasyonu ile desteklenmiştir. Denekler bu hedefi gözleriyle izlerken toplam 16 saniyelik veri kaydı yapılmıştır (3 sn başlangıç, 10 sn veri kaydı, 3 sn bitiş). Aynı protokol, farklı rotalardaki (sağ çapraz, sağ-sol, yukarı-aşağı) hareketli nesnelerle tekrarlanmış ve her bir yön için 10 tekrar gerçekleştirilmiştir. LED kapatıldıktan sonra, rastgele göz hareketlerini temsil eden pasif izleme sınıfına yönelik kayıtlar alınmıştır. Deneklerden herhangi bir hedefe odaklanmadan, rastgele bakışlar sergilemeleri istenmiştir. Bu kayıtlar da benzer şekilde 16 saniyelik periyotlarla yapılmıştır. Her denek için toplamda 5 farklı sınıf için 10’ar tekrarla 50 kayıt elde edilmiştir. Deney sırasında takip edilen hareketli yörünge görev sırası Şekil 3.9’da gösterilmiştir.



Şekil 3.9. Yaklaşımın uygulanma aşamaları

3.18.2. İkinci oturum

İkinci oturum, bireylerin gün içerisindeki bilişsel ve nörofizyolojik değişimlere karşı sistemin kararlılığını değerlendirmek amacıyla akşam saatlerinde (16:00–18:00) gerçekleştirilmiştir. EEG başlığı, ilk oturumda kullanılan kanal yerleşimleri ve empedans seviyeleri korunarak yeniden yerleştirilmiş ve elektrotlar yeniden salinli (tuzlu) su ile ıslatılmıştır. Oturumlar arasındaki sinyal farklılıklarının önüne geçmek için, EEG elektrotlarının birebir aynı konumlarda ve ıslaklıkta olmasına özellikle dikkat edilmiştir. Veri toplama prosedürü, birinci oturumla tamamen aynı olacak şekilde tekrarlanmıştır. Veri kayıt aşamasına ait görsel Şekil 3.10’da gösterilmektedir.



Şekil 3.10. Sinyal kayıt aşaması


Oturumlarda elde edilen sinyaller 256Hz örnekleme frekansı ile kaydedilmiş ve ham veriler “.csv” formatında depolanmıştır. Tüm deneklerden toplamda 1500 adet örnek elde edilmiş ve veriler sinyal işleme aşaması için Matlab (R2023b) ortamına aktarılmıştır.

4. BULGULAR

Bu çalışmada Emotiv Epoc X EEG başlık kullanılarak oluşturulan verisetine ait bulgular “Birinci Verisetine Ait Bulgular” başlığı altında ve Emotiv Flex EEG başlık kullanılarak oluşturulan verisetine ait bulgular ise “İkinci Verisetine Ait Bulgular” başlığı altında sunulmuştur.

4.1. Birinci Verisetine Ait Bulgular

Emotiv Epoc X EEG cihazı kullanılarak oluşturulan birinci verisetinde her katılımcı için LED açık konumundayken 40, kapalı konumdayken ise yine 40 olmak üzere toplam 80 EEG kaydı gerçekleştirilmiştir. Her bir denek için dört farklı nesne yörüngesi ve her yörünge için 10 tekrar içeren oturumlar sonucunda, her biri 16 saniye süresinde toplam 80 adet EEG sinyali elde edilmiştir. Elde edilen tüm veri sinyal işleme aşaması için Matlab (R2023b) ortamına aktarılmıştır. İlk adımda, verilerin başında ve sonunda bulunan 3 saniyelik uyarı sesleri kesilerek veri setinden çıkartılmış ve böylece her kayıttan 10 saniyelik, (2560×14) boyutunda ham EEG sinyali elde edilmiştir. Bu 10 saniyelik veriler, her biri 3 saniye uzunluğunda ve 1 saniyelik örtüşme içeren parçalara (768×14) bölünmüştür. Bu yöntemle, her kayıttan beş adet 3 saniyelik parça elde edilmiş ve böylece her katılımcı için toplamda 200 adet aydınlatılmış, 200 adet de aydınlatılmamış EEG verisi elde edilmiştir. Parçalara ayrılan verilere, 1–45Hz bant geçiren beşinci derece Butterworth filtre uygulanmıştır. Bu işlem Matlab ortamında *filter* fonksiyonu aracılığıyla uygulanmıştır. Örnek bir kanal (AF3) üzerinden filtreleme öncesi ve sonrası sinyal görünümü Şekil 4.1'de sunulmaktadır.




Şekil 4.1. AF3 kanalından elde edilen sinyalin filtreleme öncesi (a) ve Butterworth bant geçiren filtre uygulanmış hâli (b).

Filtreleme işleminin ardından hem aydınlatılmış hem de aydınlatılmamış verilere Welch GSY yoğunluğu yöntemi uygulanmıştır. Sinyal analizi sırasında Hamming penceresi kullanılmış, pencere uzunluğu 637 ve örtüşme miktarı 636 olarak deneysel olarak belirlenmiştir. Spektral analizden elde edilen frekans çözünürlüğü aracılığıyla EEG sinyalleri delta (0–4 Hz), teta (4–8 Hz), alfa (8–13 Hz), beta (13–30 Hz) ve gama (30–45 Hz) bantlarına ayrılmıştır. Bu frekans bantlarından her biri için ortalama, varyans, çarpıklık, basıklık, entropi, trapez, hareketlilik ve karmaşıklık öznitelikler çıkartılarak toplamda 40 öznitelik elde edilmiştir.

4.1.1. Kanal seçimi

Aydınlatılmış ve aydınlatılmamış veri kümeleri, etkin kanal seçiminde kullanılmak üzere tüm kanallar için ayrı ayrı analiz edilmiştir. Bu kapsamda RO, LDA, DVM ve k-EYK gibi yaygın olarak kullanılan sınıflandırma algoritmaları kullanılmıştır. Her sınıflandırıcı için süreç 10 tekrar ile gerçekleştirilmiş ve ortalama doğruluk oranları hesaplanmıştır. Sınıflandırma sonuçları Şekil 4.2'de görsel olarak sunulmaktadır.



Şekil 4.2. RO sınıflandırıcı kullanılarak, tüm EEG kanalları üzerinden elde edilen aydınlatılmış ve aydınlatılmamış veri kümelerinin ortalama sınıflandırma doğruluk oranları.

Şekil 4.2'de bakıldığında hem aydınlatılmış hem de aydınlatılmamış veri setlerinde en yüksek sınıflandırma doğruluk oranlarının AF3, F7, F8 ve AF4 kanallarında elde edildiği görülmektedir. Bu kanalların, EEG cihazı üzerinde göz çevresine yakın konumlandırılmış olması nedeniyle özellikle bu çalışmada etkili olduğu değerlendirilmiştir. Dolayısıyla, söz konusu kanallar analiz sürecinde aktif kanal olarak tercih edilmiştir.


4.1.2. Göz hareketlerine dayalı BBA

Geliştirilen BBA sistemi, birbirini takip eden iki sınıflandırma aşamasından oluşmaktadır. İlk aşamada, sistem öncelikle aydınlatılmış ve aydınlatılmamış veriler arasında ayrım yaparak arka plandaki görsel uyarının varlığını tespit etmeyi hedeflemektedir. Bu aşamada doğru şekilde aydınlatılmış olarak tanımlanan veriler, ikinci aşama için test veri setini oluşturmuştur. İkinci aşamada ise, bu örnekler içerisindeki hareket yönleri (sağ-sol, yukarı-aşağı, sağ-çapraz ve sol-çapraz) belirlenmiştir.

Aydınlatılmış ve aydınlatılmamış EEG verilerinin ayrıştırıldığı birinci sınıflandırma aşamasında, sinyaller 1–15Hz bant aralığında beşinci dereceden Butterworth bant geçiren filtre ile filtrelenmiştir. Filtreleme sonrasında, veriler üzerinde 637 örnek uzunluğu ve 636 örnek örtüşmeye sahip Hamming penceresi uygulanarak GSY analizi gerçekleştirilmiştir. Frekans çözünürlüğü Welch yöntemiyle hesaplanmış ve ardından 1–10Hz ve 6–8Hz aralıkları seçilmiştir. Bu iki aralıktaki alanların hesaplanması için Matlab ortamında *trapz* komutu ile trapez sayısal integrasyon uygulanmıştır. Son olarak, elde edilen iki frekans bandına ait trapez öznitelik değerlerinin oranı alınarak normalize edilmiş tek bir öznitelik elde edilmiştir (Denklem 16).


$$z' = \frac{\text{trapz}(\theta)}{\text{trapz}(\rho)} \quad (16)$$

Denklemden, θ sembolü 6–8Hz bandındaki trapez alanı, ρ ise 1–10Hz bandı için hesaplanan trapez değerini ifade etmektedir. Bu iki değerin birbirine oranlanmasıyla, tek ve normalize edilmiş bir trapez öznitelik elde edilmiştir. Geliştirilen BBA sisteminde, LED'in açık olduğu durumlarda, 6–8Hz frekans bandında belirgin bir potansiyel örüntüsü gözlemlenmektedir. Bu örüntünün varlığı, ışıklı verilerde hesaplanan normalize edilmiş trapez öznitelik değerlerinin genellikle 0 değerine yakın olmasına neden olmaktadır. Öte yandan, LED'in kapalı olduğu durumlarda aynı frekans aralığında anlamlı bir potansiyel oluşmadığından, DDGUP içermeyen veriler için bu öznitelik değeri 1'e yakın çıkmaktadır. Her iki durumda da elde edilen trapez öznitelikler, makine öğrenmesi algoritmaları aracılığıyla sınıflandırılmıştır. DDGUP potansiyel oluşumu ise Şekil 4.3'te gösterilmiştir.




Şekil 4.3. LED'in kapalı (a) ve açık (b) durumlarında ortaya çıkan sabit DDGUP potansiyeller.

Şekil 4.3(a) incelendiğinde, LED kapalı durumda iken 6–8Hz frekans bandında belirgin bir potansiyel değişiminin oluşmadığı gözlenmektedir. Buna karşılık, Şekil 4.3(b)'de LED açık konumdayken aynı frekans bandında belirgin bir potansiyel artışı dikkat çekmektedir. Bu potansiyellerin belirginlik düzeyi, L1 ve L2 ile ifade edilen frekans bantlarının alan oranlarına dayalı olarak hesaplanan trapez öznitelik ile değerlendirilmiştir. Elde edilen öznitelik değeri sayesinde verinin aydınlatılmış olup olmadığı belirlenebilmekte, böylece sistem kullanıcısının odaklandığı bölgede görsel uyarının (LED ışığının) mevcut olup olmadığı anlaşılabilmektedir. Işığın tespit edilemediği durumlarda sistem devre dışı kalarak kullanıcının istemsiz aktivasyonlara karşı güvenli bir BBA deneyimi yaşamasına olanak tanımaktadır. Tasarlanan BBA sisteminin genel akış diyagramı Şekil 4.4'te ve seçilen aktif kanallar olan AF3, F8 ve AF4 üzerinden elde edilen üç boyutlu öznitelik dağılım grafiği Şekil 4.5'te sunulmaktadır.



Şekil 4.4. Tasarlanan BBA sisteminin algoritması.



Şekil 4.5. Seçilen aktif kanallar olan AF3, F8 ve AF4 üzerinden elde edilen veriler kullanılarak oluşturulan üç boyutlu öznitelik dağılım grafiği.

Birinci sınıflandırma aşamasında yalnızca tek bir öznitelik kullanılmış olsa da seçilen etkili kanallar (AF3, F7, F8 ve AF4) üzerinden elde edilen veriler birleştirilerek toplamda dört öznitelik türetilmiştir. Bu öznitelikler, aydınlatılmış ve aydınlatılmamış veri örneklerini ayırt etmek amacıyla 75% eğitim ve 25% test oranıyla Hold-out yöntemi ile ayrılmıştır. Sistemin kararlılığını değerlendirmek amacıyla, rastgele seçilen bir katılımcıya (Denek-2) ait eğitim ve test verileri kullanılarak sınıflandırma gerçekleştirilmiştir. Elde edilen doğruluk değerleri Tablo 4.1’de verilmektedir. Yapılan her bir deneme Tablo (4.1)’de “Dnm” olarak temsil edilmiştir.

Tablo 4.1. Rastgele seçilen bir katılımcı (Denek-2) için Hold-out yöntemiyle gerçekleştirilen eğitim ve test süreci sonucunda elde edilen sınıflandırma doğruluk oranları.

Algoritma	Veri	Dnm-1	Dnm-2	Dnm-3	Dnm-4	Dnm-5	Dnm-6	Dnm-7	Dnm-8	Dnm-9	Dnm-10	Ort. (%)
DVM	eğitim	100.0	99.34	100.0	100.0	100.0	100.0	99.34	100.0	100.0	99.34	99.80
	test	100.0	100.0	97.92	97.92	97.92	100.0	97.92	97.92	100.0	97.92	98.75
k-EYK	eğitim	100.0	98.02	95.83	98.02	98.02	98.02	100.0	100.0	100.0	99.34	98.72
	test	95.83	89.58	91.67	93.75	93.75	93.75	93.75	95.83	95.83	97.92	94.16
LDA	eğitim	98.68	99.34	99.34	100.0	99.34	99.34	98.68	99.34	100.0	99.34	99.34
	test	97.92	100.0	100.0	100.0	100.0	97.92	97.92	97.92	97.92	97.92	98.75
RO	eğitim	99.34	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	99.93
	test	100.0	100.0	95.83	100.0	95.83	97.92	97.92	97.92	100.0	100.0	98.54

Tablo 4.1 incelendiğinde elde edilen değerlerin kabul edilebilir aralıklarda olduğu, aşırı veya yetersiz uyum olmadığı ve deneme sayısının yöntemin sağlamlığını göstermeye yettiği görülmektedir. Sistemin sağlamlığı test edildikten sonra RO, LDA, k-EYK ve DVM sınıflandırıcıları kullanılarak veriler sınıflandırılmıştır. Sınıflandırma işlemleri 10 kez tekrarlanmış ve ortalama sonuçlar hesaplanarak her bir denek için doğruluk oranı hesaplanmıştır. Sınıflandırma aşamasına ait doğruluk oranları Tablo 4.2’de verilmektedir. Tabloda (4.2) aydınlatılmış veriler Sınıf-1, aydınlatılmamış veriler ise Sınıf-2 olarak temsil edilmiştir.


Tablo 4.2. AF3, F7, F8 ve AF4 kanalları için tüm öznitelikler kullanılarak aydınlatılmış ve aydınlatılmamış verilerin sınıflandırma doğruluk oranları.

Algoritma	Sınıf	Dnk-1	Dnk-2	Dnk-3	Dnk-4	Dnk-5	Dnk-6	Dnk-7	Dnk-8	Dnk-9	Dnk-10	Ort. (%)
DVM	Sınıf-1	100.0	100.0	99.37	100.0	99.68	97.50	100.0	100.0	100.0	99.37	99.59
	Sınıf-2	97.08	100.0	100.0	100.0	100.0	100.0	95.20	95.41	98.75	100.0	98.64
	DO	98.54	100.0	99.68	100.0	99.37	98.75	97.60	97.70	99.37	99.68	99.11
k-EYK	Sınıf-1	100.0	100.0	98.95	100.0	98.95	100.0	100.0	98.95	100.0	98.95	99.58
	Sınıf-2	96.45	98.95	100.0	99.79	100.0	96.45	98.95	100.0	99.79	100.0	99.03
	DO	98.22	99.47	99.79	99.89	99.47	98.22	99.47	99.79	99.89	99.47	99.30
LDA	Sınıf-1	96.12	97.50	99.11	100.0	100.0	99.37	100.0	98.95	98.95	100.0	99.00
	Sınıf-2	92.00	91.66	94.37	96.04	89.58	92.29	91.45	89.37	95.20	92.91	92.48
	DO	94.06	94.58	96.74	98.02	94.79	95.83	95.72	94.16	97.07	96.45	95.74
RO	Sınıf-1	100.0	99.37	100.0	99.79	100.0	99.68	99.79	98.95	100.0	98.95	99.65
	Sınıf-2	100.0	100.0	98.54	100.0	99.37	98.75	100.0	100.0	98.33	100.0	99.49
	DO	100.0	99.68	99.27	99.89	99.68	99.21	99.89	99.47	99.16	99.47	99.57

Tablo 4.2’ye bakıldığında, sırasıyla RO, DVM, LDA ve k-EYK algoritmaları için %99.57, %99.11, %95.74 ve %98.22 doğruluk oranlarının elde edildiği, RO ve DVM algoritmalarının diğer sınıflandırıcılara kıyasla daha yüksek doğruluk oranı sağladığı görülmektedir. Bu sonuçlar, önerilen yöntemin temelini oluşturan güvenlik odaklı görsel uyarının (LED) sistem tarafından yüksek başarıyla tespit edildiğini ortaya koymuştur.

İlk sınıflandırma aşamasında doğru biçimde tespit edilen aydınlatılmış veriler, sistemin ikinci aşamasında hareket yörüngelerini belirlemek üzere test verisi olarak değerlendirilmiştir. İkinci sınıflandırma aşamasında, birinci aşamada doğru

sınıflandırılan tüm aydınlatılmış ham veriler kullanılmıştır. Veriler, 1–45Hz aralığında beşinci dereceden Butterworth filtresiyle işlenmiş ve filtreleme Matlab komutu olan *filtfilt* fonksiyonu ile gerçekleştirilmiştir. Ardından, 637 örnek uzunluğuna ve 636 örnek örtüşme değerine sahip Hamming penceresi ile Welch GSY analizi gerçekleştirilmiştir. Bu analiz sonucunda delta (0–4 Hz), teta (4–8 Hz), alfa (8–13 Hz), beta (13–30 Hz) ve gama (30–45 Hz) olmak üzere beş farklı frekans bandı tanımlanmıştır. Her bant için entropi, ortalama, çarpıklık, trapz, varyans, hareketlilik, karmaşıklık ve çarpıklık gibi çeşitli öznitelikler çıkartılmıştır. Örnek olarak, rastgele seçilen AF3 kanalına ait entropi, ortalama ve çarpıklık özniteliklerinden oluşturulan üç boyutlu öznitelik saçılım grafiği Şekil 4.6’da sunulmaktadır.



Şekil 4.6. AF3 kanalına ait aydınlatılmış EEG verilerinden elde edilen entropi, çarpıklık ve ortalama özniteliklerine dayalı olarak oluşturulan üç boyutlu öznitelik saçılım grafiği.

Şekil 4.6’da bakıldığında çıkartılan öznitelik verilerinin göz ile net şekilde ayrılabilir durumda olduğu görülmektedir. Her bir frekans bandından sekiz öznitelik elde edilmesiyle, toplamda beş frekans bandı üzerinden 40 öznitelik çıkarılmıştır. Seçilen aktif EEG kanallarının birleşimiyle bu sayı 160’a ulaşmıştır. Elde edilen öznitelikler, Hold-out yöntemi ile %75’i eğitim, %25’i test seti olarak ayrılmıştır. İlk sınıflandırma aşamasında doğru şekilde tespit edilen veriler test verisetine dahil edilirken, yanlış sınıflandırılan örnekler elenmiştir. Veriler, RO, LDA, k-EYK ve DVM sınıflandırma algoritmaları ile

sınıflandırılmıştır. Her makine öğrenme algoritması için sınıflandırma işlemi 10 defa tekrarlanmış ve ortalama DO ve BAH değerleri hesaplanmıştır. Elde edilen sonuçlar Tablo 4.3'te verilmektedir. Tabloda (4.3) yukarı-aşağı hareket yörüngesi Sınıf-1, sağ-sol hareket yörüngesi Sınıf-2, sol-çapraz hareket yörüngesi Sınıf-3 ve sağ-çapraz hareket yörüngesi Sınıf-4 olarak temsil edilmiştir.

Tablo 4.3. AF3, F7, F8 ve AF4 kanallarından elde edilen aydınlatılmış verilerin sınıflandırılmasına ilişkin doğruluk oranları.


Algoritma	Sınıflar	Dnk-1	Dnk-2	Dnk-3	Dnk-4	Dnk-5	Dnk-6	Dnk-7	Dnk-8	Dnk-9	Dnk-10	Ort. (%)
DVM	Sınıf-1	93.33	100.0	97.50	95.83	97.50	94.16	99.16	100.0	97.50	97.50	97.24
	Sınıf-2	100.0	100.0	92.50	99.16	95.00	91.66	100.0	98.33	100.0	90.00	96.66
	Sınıf-3	100.0	100.0	100.0	100.0	99.16	100.0	100.0	100.0	100.0	100.0	99.91
	Sınıf-4	91.66	98.33	95.00	93.33	95.00	99.16	95.00	97.50	100.0	91.66	95.66
	DO	96.25	99.58	96.25	97.08	96.66	96.25	98.54	98.95	99.37	94.79	97.37
	BAH	34.44	39.28	34.46	35.52	35.04	34.58	37.66	38.20	38.92	32.58	36.06
k-EYK	Sınıf-1	89.58	98.33	83.33	100.0	91.67	91.67	91.67	70.83	78.33	98.33	89.37
	Sınıf-2	93.64	90.83	91.67	91.67	83.33	75.00	83.33	100.0	91.25	75.83	87.65
	Sınıf-3	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
	Sınıf-4	95.83	87.50	83.33	75.00	75.00	91.67	91.67	83.33	77.08	85.00	84.54
	DO	94.76	94.16	89.58	91.67	87.50	89.58	91.67	88.54	86.66	89.79	90.39
	BAH	32.54	32.04	27.05	29.08	25.46	27.05	29.08	26.10	24.43	27.25	28.01
LDA	Sınıf-1	83.33	100.0	100.0	95.00	100.0	89.16	90.0	96.66	100.0	94.16	94.83
	Sınıf-2	93.33	100.0	91.66	92.50	96.66	83.33	95.83	97.50	98.33	70.00	91.91
	Sınıf-3	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
	Sınıf-4	90.00	95.00	100.0	95.00	81.66	95.83	95.83	97.50	91.66	95.00	93.74
	DO	91.66	98.75	97.91	95.62	94.58	92.08	95.41	97.91	97.50	89.79	95.12
	BAH	29.32	37.93	36.58	33.98	32.29	29.97	33.44	36.78	36.18	27.59	33.40
RO	Sınıf-1	95.83	100.0	100.0	98.33	97.50	95.00	98.33	97.50	100.0	96.66	97.91
	Sınıf-2	100.0	100.0	97.50	98.33	98.33	93.33	98.33	96.66	98.33	95.00	97.58
	Sınıf-3	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
	Sınıf-4	93.33	95.83	98.33	96.66	96.66	91.66	95.00	99.16	99.16	95.00	96.07
	DO	97.29	98.96	98.95	98.33	98.12	95.00	97.91	98.33	99.37	96.66	97.89
	BAH	35.88	38.20	38.20	37.30	37.06	32.91	36.78	37.42	39.00	34.80	36.75

Tablo 4.3'e bakıldığında, RO, DVM, LDA ve k-EYK algoritmaları ile sırasıyla %97.89, %97.37, %95.12 ve %90.39 doğruluk oranlarına ulaşılmış ve BAH değerleri sırasıyla 36.75, 36.06, 33.42 ve 28.01 (bit/dk) olarak hesaplanmıştır. En yüksek başarıyı RO algoritması gösterirken, DVM algoritması yakın doğruluk ve BAH değerleri sağlamıştır. LDA ve k-EYK algoritmaları ise bu iki yönteme kıyasla daha düşük performans

sergilemiştir. Özellikle RO sınıflandırıcısı, ikinci sınıflandırma aşamasında aydınlatılmış verileri ayırt etmede %97.89 doğruluk ve 36.75 (bit/dk) BAH ile en yüksek sonuçları sunmuştur.

4.1.3. Öznitelik seçimi

Aydınlatılmış verilerin sınıflandırılması aşamasında, toplam 160 öznitelik arasından VA tabanlı seçim yöntemi kullanılarak en ayırt edici öznitelikler tespit edilmiştir. Her katılımcı için öznitelikler seçilmiş ve ardından artan sıralamayla RO algoritması ile sınıflandırılmıştır. Öznitelik sayısına bağlı olarak elde edilen doğruluk oranları analiz edilmiştir. En yüksek katkı sağlayan ilk 20 özneliğin dağılımı Şekil 4.7’de gösterilmektedir.



Şekil 4.7. VA puanlarına göre sıralanan 160 öznelik arasından, her bir katılımcı için en yüksek puana sahip ilk 20 öznelik arasında en sık yer alan özneliklerin dağılımı.

Şekil 4.7 incelendiğinde, F8 kanalından elde edilen 82 ve 83 numaralı özneliklerin delta frekans bandına ait ortalama ve çarpıklık değerlerinin: tüm katılımcılar açısından en yüksek sınıflandırma performansı sağlayan öznelikler arasında yer aldığı gözlenmiştir.

Aynı kanaldan elde edilen 92 ve 93 numaralı öznitelikler, yani teta bandına karşılık gelen trapez alan ve entropi değerleri de dokuz katılımcıda ilk 20 öznitelik arasında yer alarak dikkate değer bir seçicilik göstermiştir. Benzer bir durum F7 kanalı için de geçerli olup, bu kanaldan türetilen 42, 43, 52 ve 53 numaralı öznitelikler (delta ortalama ve çarpıklık ile teta trapez ve entropi) dokuz katılımcı için yüksek ayırt ediciliğe sahip olarak öne çıkmıştır. Bu veriler, delta frekans bandının sınıflandırma performansına güçlü katkı sunduğunu, özellikle ortalama ve çarpıklık gibi istatistiksel özniteliklerin bu bantta belirleyici olduğunu ortaya koymaktadır. Teta bandı ise trapez alan ve entropi öznitelikleriyle bu başarıyı destekleyici niteliktedir.


Bu doğrultuda, VA tabanlı öznitelik seçimi yaklaşımıyla belirlenen en etkili parametreler kullanılarak, her kanal için dört öznitelikten oluşan ve toplamda 16 öznitelik içeren yeni bir öznitelik veri kümesi oluşturulmuştur. Elde edilen öznitelik kümesi, ikinci sınıflandırma aşamasında DVM, k-EYK, LDA ve RO makine öğrenme algoritmaları kullanılarak sınıflandırılmıştır. Elde edilen sınıflandırma DO ve BAH değerleri Tablo 4.4’de sunulmaktadır. Ayrıca elde edilen doğruluk oranı ve BAH değerleri VA değerine bağlı olarak Şekil 4.8’de karşılaştırılmıştır. Tabloda (4.4) sınıflar yukarı-aşağı hareket yörüngesi (Sınıf-1), sağ-sol hareket yörüngesi (Sınıf-2), sol-çapraz hareket yörüngesi (Sınıf-3) ve sağ-çapraz hareket yörüngesi (Sınıf-4) olarak temsil edilmiştir.

Tablo 4.4 ve Şekil 4.8’in değerlendirilmesi sonucunda, k-EYK sınıflandırıcısı açısından önemli bir performans artışı gözlemlenmiştir. Doğruluk oranı %90.39’dan %93.33’e yükselirken, BAH değeri 28.01 (bit/dk)’dan 32.04 (bit/dk)’ya çıkmıştır. RO ve LDA sınıflandırıcılarında ise, VA öncesi ve sonrası sonuçlar birbirine oldukça yakın çıkmış, kayda değer bir farklılık gözlenmemiştir. DVM sınıflandırıcısı açısından ise doğruluk oranı %96.53 değerine, BAH değeri ise 36.06 (bit/dk)’ya gerilemiştir. Bu sonuçlar, toplam öznitelik sayısının 160’tan 16’ya düşürülmesine rağmen sınıflandırma performansının büyük ölçüde korunabildiğini ve VA tabanlı öznitelik seçiminin bu çalışma kapsamında etkili olduğunu ortaya koymuştur. RO ve LDA sınıflandırıcılarında VA öncesi ve sonrası sonuçların birbirine oldukça yakın olduğu, kayda değer bir farklılık

olmadığı gözlenmemiştir. DVM sınıflandırıcısı açısından ise DO %96.53 değerine, BAH değeri ise 36.06 (bit/dk)’ya gerilemiştir.

Tablo 4.4. AF3, F7, F8 ve AF4 kanallarından elde edilen ve VA yöntemiyle seçilmiş öz niteliklerin kullanıldığı aydınlatılmış verilere ait sınıflandırma DO ve BAH değerleri.

Algoritma	Sınıflar	Dnk-1	Dnk-2	Dnk-3	Dnk-4	Dnk-5	Dnk-6	Dnk-7	Dnk-8	Dnk-9	Dnk-10	Ort. (%)
DVM	Sınıf-1	93.33	98.33	93.33	90.00	94.16	95.0	99.16	96.66	100.0	99.16	95.91
	Sınıf-2	100.0	100.0	85.83	96.66	96.66	91.66	96.66	94.16	99.16	90.00	95.07
	Sınıf-3	100.0	100.0	100.0	100.0	99.16	100.0	100.0	100.0	100.0	100.0	99.91
	Sınıf-4	95.00	96.66	93.33	93.33	98.33	95.00	97.50	96.66	99.16	87.50	95.24
	DO	97.08	98.75	93.12	95.00	97.08	95.41	98.33	96.87	99.58	94.16	96.53
	BAH	35.44	37.93	30.79	32.91	35.79	33.43	37.21	35.25	39.28	31.81	34.98
k-EYK	Sınıf-1	97.50	100.0	96.66	97.50	91.66	92.50	90.00	93.33	92.50	99.16	95.08
	Sınıf-2	79.16	99.16	91.66	99.16	91.66	80.00	87.50	90.0	95.83	85.83	89.99
	Sınıf-3	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
	Sınıf-4	90.00	95.83	95.83	95.83	73.33	91.66	90.00	90.83	96.66	86.66	90.66
	DO	91.66	98.75	96.04	98.12	89.16	91.04	91.87	93.54	96.25	92.91	93.93
	BAH	29.35	37.93	34.10	37.20	26.84	28.73	29.85	31.33	34.43	30.69	32.04
LDA	Sınıf-1	86.66	97.50	98.33	92.50	95.83	90.00	93.33	90.00	99.16	91.66	93.49
	Sınıf-2	95.83	98.33	85.0	95.0	99.16	86.66	97.50	92.50	96.66	83.33	92.99
	Sınıf-3	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
	Sınıf-4	88.33	99.16	85.83	92.50	86.66	90.00	95.83	98.33	100.0	100.0	93.66
	DO	92.70	98.75	92.29	95.0	95.41	91.66	96.66	95.20	98.95	93.75	95.03
	BAH	30.39	37.93	30.11	32.84	33.50	29.18	35.04	33.07	38.29	31.27	33.15
RO	Sınıf-1	93.33	98.33	98.33	94.16	98.33	94.16	99.16	95.83	100.0	95.00	96.66
	Sınıf-2	100.0	100.0	95.83	100.0	97.50	96.66	95.83	99.16	100.0	98.33	98.33
	Sınıf-3	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
	Sınıf-4	93.33	97.50	96.66	95.83	94.16	96.66	97.50	96.66	100.0	95.00	96.33
	DO	96.66	98.95	97.70	97.50	97.50	96.87	98.12	97.91	100.0	97.08	97.83
	BAH	35.01	38.20	36.22	36.04	36.15	35.28	36.94	36.58	40.00	35.35	36.57



Şekil 4.8. Aydınlatılmış verilerle gerçekleştirilen hareket sınıflandırma aşamasında, VA uygulanmadan önceki ve sonraki doğruluk oranları ile BAH değerlerinin karşılaştırmalı analiz sonuçları.

Bu sonuçlar, toplam öznitelik sayısının 160'tan 16'ya düşürülmesine rağmen sınıflandırma performansının büyük ölçüde korunabildiğini ve VA tabanlı öznitelik seçiminin bu çalışma kapsamında etkili olduğunu ortaya koymuştur. Sistem performansı hem birinci hem de ikinci sınıflandırma aşamalarını kapsayacak şekilde değerlendirilmiş ve sonuçlar Tablo 4.5'te özetlenmektedir.


Tablo 4.5. Tasarlanan BBA sisteminin birinci ve ikinci sınıflandırma aşamalarını kapsayan genel doğruluk ve BAH performans sonuçları.

Algoritma	Ölçüt	Dnk-1	Dnk-2	Dnk-3	Dnk-4	Dnk-5	Dnk-6	Dnk-7	Dnk-8	Dnk-9	Dnk-10	Ort. (%)
DVM	DO	95.63	98.75	92.80	95.0	96.46	94.20	95.94	94.64	98.95	93.85	95.62
	BAH	33.43	37.66	30.25	32.68	34.46	31.77	33.81	32.27	37.98	31.38	33.56
k-EYK	DO	90.00	98.22	95.83	98.01	88.68	89.41	91.38	93.34	96.14	92.41	93.34
	BAH	27.45	36.85	33.67	36.55	26.22	26.89	28.79	30.82	34.05	29.84	31.11
LDA	DO	87.19	93.39	89.28	93.11	90.43	78.95	87.68	85.37	91.62	88.07	88.49
	BAH	24.89	30.88	26.77	30.57	27.86	18.47	25.32	23.32	29.03	25.67	26.27
RO	DO	96.66	98.63	96.98	97.39	97.18	96.10	98.01	97.39	99.16	96.56	97.42
	BAH	34.71	37.47	35.13	35.68	35.40	34.01	36.55	35.68	38.33	34.58	35.75

Önerilen BBA sisteminin birinci ve ikinci sınıflandırma aşamalarını kapsayan genel DO ve BAH performanslarını özetleyen Tablo (4.5) incelendiğinde, en yüksek ortalama doğruluk oranının %97.42 ile RO sınıflandırıcısına ait olduğu görülmüştür. Bu sınıflandırıcı aynı zamanda 35.75 (bit/dk) ortalama ile de sistemin en yüksek BAH değerini sağlamıştır. Diğer sınıflandırıcılarla kıyaslandığında, RO algoritmasının hem doğruluk hem de hız açısından en verimli sonuçları verdiği gözlemlenmiştir. DVM sınıflandırıcısı da %95.62 DO ve 33.56 (bit/dk) BAH ile dikkate değer performans sergilemiştir. Buna karşılık, en düşük ortalama DO ve BAH değerleri sırasıyla %88.49 ve 26.27 (bit/dk) ile LDA algoritmasında görülmüştür. Bu sonuçlar, özellikle RO sınıflandırıcısının önerilen sistemde hem DO hem de BAH açısından diğer yöntemlere kıyasla daha kararlı ve yüksek performans sunduğunu ortaya koymuştur.


4.2. İkinci Verisetine ait Bulgular

Emotiv FLEX EEG başlık kullanılarak oluşturulan ikinci veri seti beş sınıftan oluşmaktadır. Bu sınıflardan dördü, 7Hz frekansında titreşen LED aktifken, kullanıcıların görsel olarak yönlendirilmiş hareketli nesne yörüngelerini takip ettiği sırada kaydedilmiş; beşinci sınıf ise, LED kapalıyken ve kullanıcı rastgele göz hareketleri gerçekleştirirken elde edilmiştir. Bu yapı, sistemin iki aşamalı bir sınıflandırma yapısında kurgulanmasını sağlamıştır. Birinci aşamada, LED açık (DDGUP mevcut) ve LED kapalı (DDGUP yok) durumları birbirinden ayırt edilmiştir. İkinci aşamada ise, yalnızca LED açık durumunda kaydedilen dört farklı hareketli yörüngeye ait veriler sınıflandırılmıştır. Sabah oturumunda toplanan verilerin tamamı eğitim verisi, akşam oturumundaki verilerin tamamı ise test verisi olarak kullanılarak sistemin oturumlar arası kararlılığı test edilmiştir. Tasarlanan hibrit BBA sistemine ait şema Şekil 4.9'da gösterilmektedir. Her oturumda, başlangıçta ve sonda yer alan üç saniyelik sesli uyarılarla birlikte toplam 16 saniyelik veriler (4096 örnek x 4 kanal) kaydedilmiştir. Sistemin başlangıç ve bitiş uyarı seslerinden etkilenmemesi için bu bölümler sinyalden kesilmiş ve yalnızca 10 saniyelik (2560 örnek x 4 kanal) sinyaller değerlendirilmiştir.




Şekil 4.9. Tasarlanan ikinci hibrit BBA sistemine ait genel şema.

Elde edilen ham sinyaller 1 saniyelik örtüşme ile 3 saniyelik alt pencerelere ayrılmış ve her bir denemeden 5 adet 3 saniyelik (768 örnek x 4 kanal) sinyal elde edilmiştir. Denek 2'ye ait Sol çapraz(a), sağ çapraz(b), sağ sol (c) ve aşağı yukarı (d) hareket birinci oturum verilerinin ortalama genlik grafikleri Şekil 4.10'da ve ikinci oturuma ait verilerin ortalama genlik değeri grafikleri ise Şekil 4.11'de verilmektedir.




Şekil 4.10. Birinci oturuma ait sol-çapraz(a), sağ-çapraz(b), sağ-sol (c) ve aşağı-yukarı (d) hareket yörüngelerine ait verilerin ortalama genlik grafikleri.




Şekil 4.11. İkinci oturuma ait sol-çapraz(a), sağ-çapraz(b), sağ-sol (c) ve aşağı-yukarı (d) hareket yörüngelerine ait verilerin ortalama genlik grafikleri.

Sinyaller Matlab komutu olan filtfilt aracılığıyla 1–15Hz aralığında beşinci dereceden Butterworth bant geçiren filtreden geçirilmiştir. Butterworth filtreleri, geçiş bandında düz frekans cevabı sağlamaları ve sinyalin genlik bileşenlerini korumaları sebebiyle EEG işleme uygulamalarında sıklıkla tercih edilmektedir (Sörnmo & Pablo, 2005). Örnek olarak, Fp1 kanalına ait bir sinyalin filtrelenmeden önceki (a) ve sonraki (b) hali Şekil 4.12’de gösterilmektedir.



Şekil 4.12. Fp1 Kanalından alınan ham ve filtrelenmiş EEG sinyali: (a) filtrelenmemiş sinyal, (b) 1–15Hz 5. dereceden Butterworth bant geçiren filtre ile filtrelenmiş sinyal.

Farklı derecelerde filtre tasarımları test edilmiş ve geçiş bandı keskinliği ile sinyal bozulması arasındaki denge göz önünde bulundurularak en uygun performans beşinci dereceden filtrede elde edilmiştir. Filtrelenen sinyaller, Welch metodu kullanılarak GSY ile zaman alanından frekans alanına dönüştürülmüştür. Hamming penceresi ile 640 örnek uzunluğunda ve 639 örnek örtüşmeli pencereleme yapılmıştır. GSY analizinde kullanılan Hamming 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 & Bokil, 2007; Welch, 1967). GSY'dan elde edilen spektrum üzerinde 4–10Hz ve 6–8Hz frekans aralıkları seçilmiştir. Bu iki frekans bandına ait alanlar, bant gücünü hesaplamak için literatürde sık kullanılan trapez entegrasyon yöntemi (Avots ve ark., 2022) ile hesaplanarak, iki frekans bandı için hesaplanan değerler birbirine oranlanmıştır. Elde edilen oranlanmış trapez öznitelikler ile 7Hz frekansında LED uyarımıyla oluşan DDGUP aktivitesinin tespiti hedeflenmiştir. LED açık durumda iken oluşturulan temsili DDGUP potansiyel Şekil 4.13'te gösterilmektedir.



Şekil 4.13. LED açık konumundayken meydana gelen DDGUP etkisi.

Elde edilen öznitelik verilerine bireyler arası ve oturumlar arası genlik değişimlerini dengelemek amacıyla Z-skor normalizasyon uygulanarak ortalaması 0 ve standart sapması 1 hâline getirilmiştir (Lehmann ve ark., 2007). Yine farklı oturumlarda kaydedilen veriler arasında istatistiksel dağılım farklılıkları gözlemlenebileceğinden, bu tür problemlerin azaltılması amacıyla normalize edilmiş eğitim verilerine KH yöntemi


uygulanmıştır. KH, kaynak ve hedef veri kümelerinin kovaryans matrislerini birbirine yaklaştırmak suretiyle alan uyumu sağlayarak, kaynak veriyi hedef verinin dağılımına istatistiksel olarak hizalamaktadır (Sun & Saenko, 2016). Bu bağlamda, normalize edilmiş eğitim verisinin kovaryans matrisi beyazlatılmış, ardından test verisinin kovaryans yapısına göre yeniden renklendirilerek dönüştürülmüştür. Birinci sınıflandırma aşamasında DDGUP tespiti için, DVM, RO ve TA makine öğrenme algoritmaları kullanılmıştır. DVM algoritması, çok sınıflı sınıflandırma için Matlab ortamında *fitcecoc* fonksiyonu ile gerçekleştirilmiştir. Algoritmanın güçlü sınırlayıcı yüzey oluşturma kabiliyeti ve doğrusal olmayan ayırımlar için kernel dönüşümü özelliğinden dolayı (Cortes ve ark., 1995; Lotte ve ark., 2007) RBF çekirdek fonksiyonu tercih edilmiş, hiperparametre ayarlamaları ise otomatik optimizasyon yöntemiyle yapılmıştır. TA ise *fitcensemble* komutu ile uygulanmış ve her biri maksimum 10 bölünme sınırına sahip 100 adet karar ağacından oluşan topluluk modeli kurulmuştur. Böylece veri alt kümeleri üzerinden birden fazla zayıf öğrenici eğiterek sınıflandırma performansının artırılması hedeflenmiştir. Yüksek boyutlu verilerde öznitelik seçimi yapmaksızın etkin sınıflandırma sağlayabildiğinden dolayı EEG sinyallerinde sıkça tercih edilen RO algoritması (Haresh & Begum, 2025) ise *TreeBagger* fonksiyonu kullanılarak uygulanmıştır. RO modeli, her biri rastgele öznitelik altkümeleri kullanılarak eğitilmiş 30 karar ağacından oluşturulmuştur. Model sınıflandırıcı olarak yapılandırılmış ve model çıktıları hücresel formattan sayısal forma dönüştürülmüştür. Tüm sınıflandırma algoritmaları, oturum-1 verileri ile eğitilmiş ve oturum-2 verileri ile test edilmiştir. Elde edilen sınıflandırma doğruluk oranları Tablo 4.6’da sunulmaktadır. Tabloda (4.6), Sınıf-1 LED aktif konumda kaydedilen hareketli yörünge verilerini ve Sınıf-2 ise LED kapalı konumda kaydedilen rastgele bakış verilerini temsil etmektedir.

Tablo 4.6 incelendiğinde TA öğrenme algoritmasının 99.12% doğruluk oranı ile birinci sınıflandırma aşaması için en iyi performansı sergilediği görülmektedir. İkinci sınıflandırma aşaması, birinci aşamada algoritmalar tarafından doğru olarak sınıflandırılan verilerin ham halleri kullanılarak oluşturulan veri kümesi üzerinde gerçekleştirilmiştir.

Tablo 4.6. Birinci sınıflandırma aşamasına ait doğruluk oranları.


Algoritma	RO			DVM			TA		
Sınıflar	Sınıf-1	Sınıf-2	DO	Sınıf-1	Sınıf-2	DO	Sınıf-1	Sınıf-2	DO
Dnk-1	99.00	92.00	97.60	99.05	92.00	97.64	99.80	96.60	99.16
Dnk-2	99.55	97.60	99.16	99.15	92.00	97.72	99.90	97.80	99.48
Dnk-3	99.20	92.00	97.76	99.65	96.80	99.08	99.70	97.80	99.32
Dnk-4	99.85	97.40	99.36	99.60	97.80	99.24	99.75	97.20	99.24
Dnk-5	99.70	97.80	99.32	99.50	97.60	99.12	99.85	97.40	99.36
Dnk-6	99.85	96.60	99.20	99.15	92.00	97.72	99.85	96.80	99.24
Dnk-7	99.10	92.00	97.68	99.70	97.00	99.16	99.50	95.20	98.64
Dnk-8	99.05	92.00	97.64	99.00	92.00	97.60	100.0	95.80	99.16
Dnk-9	99.00	92.00	97.60	99.35	98.00	99.08	99.90	97.60	99.44
Dnk-10	99.75	98.00	99.40	99.15	92.00	99.72	99.50	97.80	99.16
Dnk-11	99.80	97.80	99.40	99.70	97.40	99.24	100.0	95.60	99.12
Dnk-12	99.80	96.60	99.16	99.00	92.00	97.60	99.05	92.00	97.64
Dnk-13	99.30	97.40	98.92	99.95	98.80	99.72	100.0	95.60	99.12
Dnk-14	99.50	95.20	98.64	99.15	92.00	97.72	99.70	97.00	99.70
Dnk-15	99.70	97.80	99.32	99.70	97.00	99.16	99.80	96.60	99.16
Ort. (%)	99.47	95.48	98.67	99.38	94.96	98.63	99.75	96.45	99.12

Filtreleme aşamasında sinyallere, geçiş bandındaki düz frekans yanıtı sayesinde sinyalin genlik bileşenlerini bozmadan filtreleme yapma özelliğine sahip olan (Sörnmo & Pablo, 2005) dördüncü dereceden Butterworth filtre 0.5–32Hz aralığında uygulanmıştır. Filtreleme işlemi sonrası, zaman ve frekans alanlarına dayalı sinyal gücü, sinyal enerjisi ve polinom uydurma öznitelik çıkartma yöntemleri kullanılmıştır. Polinom uydurma yöntemi 20. dereceye kadar genişletilmiş ve elde edilen tüm polinom katsayıları öznitelik vektörüne dahil edilmiştir. Yüksek dereceli polinomlar, sinyalin yapısal eğilimlerini daha ayrıntılı biçimde temsil ederek sınıflandırma performansını artırmada etkili olmaktadır (Mahmood ve ark., 2024). Şekil 4.14'te Fp1 kanalına ait sağ çapraz hareket sinyal için 20. derece polinom kullanılarak uydurulan örnek eğri gösterilmektedir.




Şekil 4.14. Fp1 kanalına ait sinyal için 20. dereceden polinom kullanılarak uydurulan eğri.

Elde edilen özniteliklerin dağılımlarını görmek amacıyla Şekil 4.15'te rastgele seçilen Fp2 kanalına ait saçınım grafiği verilmektedir. Şekilde Sınıf-1 sol-çapraz hareket yörüngesini, Sınıf-2 sağ-çapraz hareket yörüngesini, Sınıf-3 sağ-sol hareket yörüngesini ve Sınıf-4 ise yukarı-aşağı hareket yörüngesini temsil etmektedir.



Şekil 4.15. FT9 kanalına ait güç, enerji ve polinom uydurma eğrisi özniteliklerine ait 3 boyutlu saçınım grafiği.

Şekil 4.15 incelendiğinde, çalışma için çıkartılan özniteliklerin (güç, enerji ve eğri uydurma), hareket yörüngelerine ait sınıflar için göz ile dahi büyük ölçüde ayırt edilebilir olduğu görülmektedir. Elde edilen öznitelik verileri DVM, Matlab ortamında *fitcecoc* fonksiyonu kullanılarak yapılandırılmıştır. DVM modelinin hiperparametre optimizasyonu ise otomatik ayarlama yöntemi ile gerçekleştirilmiştir. *fitcensemble* fonksiyonu aracılığıyla uygulanan TA, her biri maksimum 15 bölünme derinliğine sahip 100 adet karar ağacından oluşan bir topluluk modeli olarak yapılandırılmıştır. Bu yöntem ile, veri altkümeleri üzerinde birden fazla zayıf öğrenici eğitilerek sınıflandırma başarımının artırılması amaçlanmıştır. RO algoritması Matlab fonksiyonu *TreeBagger* kullanılarak uygulanmıştır. RO modeli, rastgele seçilen öznitelik altkümeleri üzerinden eğitilen 50 karar ağacından oluşmakta olup, sınıflandırıcı olarak yapılandırılmıştır. Model çıktıları, değerlendirme sürecinde hücrel formattan sayısal formata dönüştürülerek analiz edilmiştir. 10 bağımsız tekrar üzerinden yürütülen sınıflandırmalara ait ortalama doğruluk oranları Şekil 4.16’da verilmiştir.



Şekil 4.16. İkinci sınıflandırma aşamasına ait ortalama doğruluk oranları.

Şekil 4.16’da ikinci sınıflandırma aşamasına ait ortalama doğruluk oranları verilmiştir. RO, TA ve DVM algoritmaları için sırasıyla 79.87%, 81.54% ve 76.31% ortalama doğruluk oranları elde edilmiştir. TA algoritmasının diğer algoritmalarından daha iyi performans sağladığı görülmüştür.

Çalışmada iki oturum arasında meydana gelen istatistiksel dağılım farklılıklarını azaltmak amacıyla, ikinci sınıflandırma aşamasına ait öznitelik verilerine KH yöntemi uygulanmıştır. KH, kaynak (eğitim) ve hedef (test) veri kümelerinin kovaryans matrislerini hizalayarak alanlar arası istatistiksel uyum sağlamaktadır. Bu yöntem kapsamında, normalize edilmiş eğitim verisinin kovaryans matrisi beyazlatılmış, ardından test verisinin kovaryans yapısına göre yeniden renklendirilerek kaynak veriler hedef dağılıma istatistiksel olarak uyumlu hâle getirilmiştir. Böylece modelin, oturumlar arası genelleme kabiliyeti artırılmıştır [20]. Daha sonra öznitelik verileri birinci sınıflandırma aşamasında olduğu gibi RO, DVM ve TA makine öğrenme algoritmaları kullanılarak sınıflandırılmıştır. Birinci oturumda (günün erken saatlerinde) kaydedilen KH uygulanmış verilerin tamamı eğitim verisi olarak ve ikinci gün kaydedilen normalize edilmiş verilerin tamamı test verisi olarak kullanılmıştır. DVM algoritması, Matlab ortamında *fitcecoc* fonksiyonu kullanılarak yapılandırılmıştır. DVM modelinin hiperparametre optimizasyonu ise otomatik ayarlama yöntemi ile gerçekleştirilmiştir. *fitcensemble* fonksiyonu aracılığıyla uygulanan TA, her biri maksimum 15 bölünme derinliğine sahip 100 adet karar ağacından oluşan bir topluluk modeli olarak yapılandırılmıştır. Bu yöntem ile, veri altkümeleri üzerinde birden fazla zayıf öğrenici eğitilerek sınıflandırma başarımının artırılması amaçlanmıştır. RO algoritması Matlab fonksiyonu *TreeBagger* kullanılarak uygulanmıştır. RO modeli, rastgele seçilen öznitelik altkümeleri üzerinden eğitilen 50 karar ağacından oluşmakta olup, sınıflandırıcı olarak yapılandırılmıştır. Model çıktıları, değerlendirme sürecinde hücrel formattan sayısal formata dönüştürülerek analiz edilmiştir. Tüm sınıflandırma işlemleri 10 bağımsız tekrar üzerinden yürütülmüş ve elde edilen ortalama DO, BAH, hassasiyet, özseçicilik ve F1-skor değerleri Tablo 4.7’de verilmektedir.

Tablo 4.7. İkinci sınıflandırma aşamasına ait DO, BAH, hassasiyet, özseçicilik ve F1-skoru değerleri.

Algoritma	Sınıflar	Dnk-1	Dnk -2	Dnk -3	Dnk -4	Dnk -5	Dnk -6	Dnk -7	Dnk -8	Dnk -9	Dnk -10	Dnk -11	Dnk -12	Dnk -13	Dnk -14	Dnk -15	Ort. (%)
RO	Sınıf-1	82.20	97.60	91.60	93.40	86.80	98.20	76.80	85.20	90.80	93.40	80.40	89.80	93.20	92.40	91.80	89.57
	Sınıf-2	93.80	94.80	96.00	95.80	91.60	99.00	95.20	96.80	95.80	99.80	93.40	95.80	95.40	97.20	95.20	95.70
	Sınıf-3	82.80	96.60	94.60	93.00	96.20	100.0	92.00	91.80	96.40	95.60	92.00	90.80	94.40	91.80	92.60	93.37
	Sınıf-4	98.00	98.00	96.60	96.00	96.20	99.60	94.60	98.80	96.00	97.80	94.60	95.80	95.80	95.60	94.60	96.53
	DO	89.20	96.75	94.70	94.55	92.70	99.20	89.65	93.15	94.75	96.65	90.10	93.05	94.70	94.25	93.55	93.80
	BAH	32.33	41.06	38.45	38.20	36.09	45.56	32.68	36.60	38.42	40.76	33.17	36.44	38.42	37.90	37.00	37.54
	Hassasiyet	89.45	96.78	94.97	94.76	93.18	99.23	90.10	93.35	94.87	97.01	90.59	93.37	94.90	94.59	93.90	94.07
	Özseçicilik	89.20	96.75	94.70	94.55	92.70	99.20	89.65	93.15	94.75	96.65	90.10	93.05	94.70	94.25	93.55	93.80
	F1-skoru	89.32	96.76	94.83	94.65	92.94	99.21	89.87	93.25	94.81	96.83	90.34	93.21	94.80	94.42	93.72	93.93
DVM	Sınıf-1	77.20	97.80	86.20	88.20	88.60	98.80	82.60	82.60	88.40	86.20	81.20	87.80	86.80	87.00	88.40	87.18
	Sınıf-2	94.20	92.20	95.20	97.40	86.20	96.40	95.60	98.40	94.60	94.60	93.80	92.00	90.80	96.00	95.00	94.16
	Sınıf-3	81.60	89.40	89.40	84.80	85.20	97.80	81.20	90.40	89.20	91.40	81.00	89.20	90.40	92.40	87.60	88.06
	Sınıf-4	99.40	97.00	100.0	99.80	99.60	98.80	98.40	98.00	98.80	100.0	99.00	99.80	100.0	93.40	98.00	98.66
	DO	88.10	94.10	92.70	92.55	89.90	97.95	89.45	92.35	92.75	93.05	88.75	92.20	92.00	92.20	92.25	92.02
	BAH	31.16	37.53	36.05	35.90	33.10	42.77	32.49	35.78	36.06	36.47	32.01	35.41	35.20	35.42	35.48	35.38
	Hassasiyet	88.30	94.53	93.01	92.75	91.45	98.01	90.21	92.61	93.18	93.42	89.60	92.70	92.90	96.71	92.96	92.82
	Özseçicilik	88.10	94.10	92.70	92.55	89.90	97.95	89.45	92.35	92.75	93.05	88.75	92.20	92.00	92.20	92.25	92.02
	F1-skoru	88.20	94.31	92.85	92.65	90.67	97.98	89.83	92.48	92.96	93.23	89.17	92.45	92.45	94.40	92.60	92.41
TA	Sınıf-1	82.80	98.00	93.40	92.40	84.80	99.80	77.20	83.00	94.20	92.40	78.00	94.00	93.00	93.00	94.00	90.01
	Sınıf-2	96.60	95.20	98.20	98.20	91.00	100.0	95.60	95.20	98.00	97.60	95.40	97.80	98.20	98.20	97.40	96.84
	Sınıf-3	83.60	97.60	96.80	97.00	94.80	100.0	93.20	86.90	97.40	97.20	95.00	96.40	96.00	96.20	97.00	95.00
	Sınıf-4	94.20	98.00	94.00	94.80	95.00	100.0	94.00	99.90	94.20	94.80	94.00	94.60	94.40	94.00	94.20	95.34
	DO	89.30	97.20	95.60	95.60	91.40	99.95	90.00	91.25	95.95	95.50	90.60	95.70	95.40	95.35	95.65	94.29
	BAH	32.46	41.75	39.48	39.52	34.54	49.53	33.06	34.38	39.93	39.35	33.71	39.63	39.23	39.17	39.56	38.35
	Hassasiyet	89.67	97.21	95.89	95.85	91.81	99.95	90.39	91.55	96.20	95.77	90.90	95.96	95.67	95.61	95.89	94.55
	Özseçicilik	89.30	97.20	95.60	95.60	91.40	99.95	90.00	91.25	95.95	95.50	90.60	95.70	95.40	95.35	95.65	94.29
	F1-skoru	89.48	97.20	95.74	95.72	91.60	99.95	90.19	91.40	96.07	95.63	90.75	95.83	95.53	95.48	95.77	94.42

Tablo 4.7 incelendiğinde, RO algoritmasının ortalama 93.80% doğruluk oranı, 37.54 (bit/dk) BAH değeri ve %94.07 hassasiyet ile iyi bir performansı sergilediği görülmektedir. Algoritma özellikle Sınıf 4'te 96.53% doğruluk oranı ile dikkat çekmektedir. DVM algoritması ortalama 92.02% doğruluk oranı, 35.38 (bit/dk) BAH değeri ve 92.82% hassasiyet ile RO algoritmasına yakın bir performans sergilemiştir. Sınıf 4'te 98.66% gibi yüksek bir doğruluk oranı elde edilirken Sınıf 1'de 87.18% doğruluk oranı ile diğer algoritmalarla oranla daha düşük bir performans elde edilmiştir. TA yöntemi ise, ortalama 94.29% doğruluk oranı, 38.35 (bit/dk) BAH ve 94.55% hassasiyet ile en yüksek genel performansı göstermiştir. Algoritma özellikle Sınıf 2 ve Sınıf 3'te sırasıyla 96.84% ve %95.00 doğruluk oranları ile öne çıkmaktadır. Genel olarak, TA algoritması, yüksek doğruluk oranı ve BAH ile en iyi performansı sergilemiştir. RF algoritması TA'ya yakın performans sergilerken, DVM bazı sınıflarda yüksek doğruluk oranları elde etmesine rağmen diğer iki algoritmanın gerisinde kalmıştır. Elde edilen sonuçlar bu çalışma için EEG sinyallerinde bulunan EOG artefakt sinyallerinin sınıflandırılmasında KH yönteminin etkili bir domain adaptasyon yöntemi olduğunu ortaya koymuştur. Ayrıca TA algoritmasının sergilediği performans, mevcut çalışma için topluluk öğrenme yöntemlerinin etkili olduğunu göstermiştir.

5. TARTIŞMA

GUP tabanlı BBA sistemlerine yönelik yapılan çalışmalar incelendiğinde çoğunlukla doğruluk oranı ve performans metriklerine odaklanıldığı görülmektedir (Värbu ve ark., 2022). Ancak bu sistemlerde kullanılan görsel uyaranların, kullanıcıların göz sağlığı üzerinde olumsuz etkiler yarattığı, konfor seviyesini düşürdüğü ve kullanım süresini sınırladığı bilinmektedir (Allison, 2009; Dong & Tian, 2023). Nitekim bazı çalışmalarda, görsel uyaranlara uzun süreli maruz kalan deneklerin deneyleri tamamlayamadığı bildirilmektedir (Brennan ve ark., 2015). GUP temelli sistemler, kullanıcıların uyaran frekanslarını algılayabilmesini gerektirdiğinden, görme bozukluğu olan bireyler için uygun bir seçenek değildir. Öte yandan, yapılan araştırmalar EEG ve EOG sinyallerinin bütünleşik kullanımıyla oluşturulan hibrit BBA sistemlerinin doğruluk ve esneklik açısından önemli avantajlar sunduğunu ortaya koymaktadır (Wolpaw & Wolpaw, 2012). DDGUP tabanlı sistemler, yüksek BAH değerleri ile ön plana çıkmasına karşın; kullanıcı konforu, bireysel farklılıklar ve oturumlar arası değişkenlik gibi sınırlayıcı faktörlerle karşılaşmaktadır (Sung ve ark., 2024; Zhu ve ark., 2010). Bu noktada, uygun şekilde işlenen EOG sinyalleri, düşük maliyetli ve hızlı tepki verebilen bir alternatif kontrol arayüzü olarak dikkat çekmektedir (Huang ve ark., 2019). Özellikle oturumlar arası farklılıkların giderilmesine yönelik çeşitli alan adaptasyon yöntemleri ön plana çıkmaktadır. Bununla birlikte, düşük kanal sayısı ile geliştirilen sistemlerin taşınabilirlik, kullanım kolaylığı ve donanım sadeliği açısından kullanıcıya önemli avantajlar sağladığı bilinmektedir (Özkahraman ve ark., 2024).

Bu çalışmada, GUP tabanlı BBA sistemlerinde kullanıcıların göz sağlığı ve konforu üzerinde oluşturduğu olumsuz etkileri en aza indirmeyi, kullanıcı kontrolünü en üst seviyeye çıkartmayı ve oturumlar arası kararsız sistem yapısına karşı dayanıklı hibrit tabanlı özgün yaklaşıma sahip bir BBA sistemi sunulmuştur. Önerilen hibrit sistem için Emotiv Epoc X ve Emotiv Flex EEG cihazları kullanılarak iki farklı veriseti oluşturulmuştur. Emotiv Epoc X EEG başlık ile oluşturulan birinci verisetinde klasik titreşimli görsel uyaranlar yerine, farklı yönlerde hareket eden dört ayrı nesne kullanılmıştır. Bu hareketli nesnelerle ilişkili komutlar, EEG kayıtlarındaki EOG

bileşenleri aracılığıyla sınıflandırılmıştır. Ancak, kullanıcı istemsiz şekilde hareketli nesne yörüngelerini takip ettiğinde, sistemin istemsiz şekilde aktif olma riski ortaya çıkmaktadır. Benzer durumlara literatürde yer alan göz hareketi temelli sistemlerde de sıkça rastlandığı görülmektedir (Dimitrov ve ark., 2020; Ngo ve ark., 2021; Saichoo ve ark., 2022). Mevcut probleme yönelik çözüm amacıyla daha önce seri göz kırpma ya da belirli yönlere bakma gibi yöntemler önerilmişse de bu yaklaşımlar sistemin kullanımını ve kullanıcıyı bilişsel açıdan zorlayarak hata oranlarını arttırmaktadır. Yapılan çalışmada geliştirilen sistemde, bu sorunun üstesinden gelmek için 7Hz frekansında yanıp sönen bir LED, ekranın orta üst kısmına yerleştirilmiştir. Sistem, kullanıcının LED'e doğrudan odaklanmasına gerek kalmaksızın, EEG üzerinden DDGUP yöntemiyle LED'in varlığını kontrol etmektedir. LED'in tespit edilmesi, kullanıcının sistemi bilinçli olarak devreye soktuğunu gösterirken; LED algılanmadığında sistem pasif kalmakta ve istemsiz komut oluşumu engellenmektedir. LED'in düşük parlaklıkta ve bir adet kullanılması, görsel rahatsızlık riskini azaltmakta; sistemin dikkat dağıtmadan ve kullanıcıyı yormadan güvenli şekilde çalışmasını mümkün kılmaktadır. Böylece, kullanıcı doğrudan flaş etkisine maruz kalmadan, yalnızca hareketli nesneleri takip ederek sistemi etkin biçimde kontrol edebilmektedir.

EEG sinyallerindeki EOG artefaktları kullanılan çalışmada, farklı yönlerde hareket eden nesnelerin kontrolü sağlanmış ve sistemin aktifleşme aşaması, arka planda yerleştirilen 7Hz LED'in oluşturduğu DDGUP potansiyelin algılanmasıyla gerçekleştirilmiştir. Bu yaklaşımla, klasik görsel uyaran tabanlı BBA sistemlerinde karşılaşılan parlama hissi, görsel rahatsızlıklar ve kullanım süresinin kısalması gibi sorunlara çözüm getirilmesi hedeflenmiştir. Görsel uyaranlara alternatif olarak hareketli nesne temelli sınıflandırma önerilmiş; böylece kullanıcı konforu ve sistemin uzun süreli kullanılabilirliği arttırılmaya çalışılmıştır. Ayrıca, sistemin kullanıcı tarafından güvenli bir şekilde başlatılabilmesi için DDGUP yöntemiyle LED'in varlığı kontrol edilerek istemsiz komutların önüne geçilmesi amaçlanmıştır. BBA sistemlerinde aktivasyon aşamasında sistemin doğru karar verebilmesi kritik öneme sahiptir; zira yanlış tetiklemeler felçli bireyler için önemli zorluklar doğurabilmektedir. Bu nedenle, sürekli göz kırpma gibi geleneksel yöntemlere

alternatif olarak, dikkat gerektirmeyen ve daha konforlu bir kontrol mekanizması sunulmuştur.

İkinci verisetinde ise (Emotiv Flex EEG başlık ile oluşturulan), geleneksel EEG tabanlı sistemlerde karşılaşılan oturum değişkenliği, görsel uyaran kaynaklı rahatsızlıklar ve güvenilirlik sorunlarını aşmak amacıyla hibrit bir BBA sistemi önerilmiştir. Kullanıcıların gün içerisindeki fizyolojik ve psikolojik dalgalanmalarına karşı dayanıklı bir sistem tasarımı hedeflenmiş; bu doğrultuda veri kayıtları sabah ve akşam olmak üzere iki farklı oturumda gerçekleştirilmiştir. Tüm hareketli nesneler eş zamanlı olarak kullanıcıya sunulurken sistemin gerçek yaşam koşullarına en iyi uyarlanabilir seviyede olması hedeflenmiştir. Tasarlanan sistem iki aşamalı sınıflandırma yapısına sahiptir. İlk aşamada, ortalama trapez güç spektral öznitelikleri çıkartılarak, 7Hz LED'e karşılık gelen DDGUP aktivasyonu güvenli bir tetikleme mekanizması olarak tespit edilmiştir. İkinci aşamada ise, EEG sinyallerinde bulunan ham EOG artefaktlarından yararlanılarak, dört farklı hareket yörüngesinin sınıflandırılması amacıyla güç, enerji, 20. derece polinom katsayıları zaman alanı öznitelikleri çıkartılmıştır. Sınıflandırma süreçlerinde birinci oturumda kaydedilen verilere normalizasyon ve KH yöntemleri uygulanmış; TA, DVM ve RO algoritmaları kullanılarak modeller eğitilmiştir. İkinci oturum verileri ise modelleri test etmek için kullanılmıştır. Sonuçlar, birinci sınıflandırma aşamasında TA algoritmasının 99.12% doğruluk ile en yüksek başarıyı sağladığını ve düşük frekanslı görsel uyarılmış potansiyellerin tespiti için topluluk öğrenme yaklaşımının güvenilirliğini ortaya koymuştur. İkinci aşamada, veriler ilk olarak herhangi bir adaptasyon yöntemi uygulanmadan sınıflandırılmıştır. Daha sonra KH adaptasyon yöntemi uygulanarak sınıflandırma işlemi tekrarlanmış ve sonuçlar karşılaştırılmıştır. TA, 81.54% ortalama doğruluk oranından 94.29% doğruluk oranına ulaşarak bireysel varyasyonlara rağmen oturumlar arası en iyi başarıyı sağlamıştır.

Elde edilen sonuçlar, tasarlanan sistemin bireysel varyasyonlara rağmen oturumlar arası genelleme yeteneği sunduğunu kanıtlamıştır. Farklı donanımsal özelliklere sahip iki EEG başlık (Emotiv Epoc X ve Emotiv Flex) kullanılarak test edilen hibrit BBA sistemlerinin

performans, konfor ve uygulanabilirlik yönlerinden incelendiği bu çalışmada: her iki cihazla da yürütülen deneylerde yüksek DO ve BAH değerleri elde edilmiş olup, sistemlerin farklı kullanım senaryolarına uygun biçimde optimize edilebileceği gösterilmiştir.

Emotiv Epoc X EEG cihazı ile oluşturulan verisetine ait F7, AF3, AF4 ve F8 kanallar kullanılarak, RO algoritması ile %97.42 DO ve 35.75 (bit/dk) BAH değerleri elde edilmiştir. Katılımcı sayısının literatürdeki benzer çalışmalara göre yeterli düzeyde olması, sistemin doğruluğunu destekleyen önemli bir etkidir. Epoc X cihazı uygun fiyatı, taşınabilirliği, uzun pil ömrü ve kolay kurulum özellikleriyle dikkat çekmektedir. Bununla birlikte, cihazın uzun süreli kullanımda kullanıcının başına uyguladığı basınç, sınırlı baş uyumu ve sensör değiştirilemezliği gibi bazı ergonomik sınırlamaları da beraberinde getirmektedir. Ayrıca elektrotların zamanla kuruması ve oksitlenmesi, temas kalitesini düşürebilmektedir. Bu sınırlamalara rağmen cihazın pratik avantajları ve düşük maliyeti uygulamalar için hâlâ cazip bir seçenek olmasını sağlamaktadır.

Emotiv Flex EEG cihazı ile yapılan çalışmada ise yalnızca dört kanal kullanılarak %94.29 DO ve 38.35 (bit/dk) BAH elde edilmiştir. Flex cihazının daha esnek konfigürasyon imkânı, farklı baş yapısına uyum sağlayabilen sensör yapısı ve daha gelişmiş sinyal kalitesi, deneysel uygulamalarda avantaj sağlamıştır. Bu deneylerde veri toplama işlemi farklı zaman dilimlerinde gerçekleştirilmiş, KH tabanlı adaptasyon tekniği ile oturumlar arası dağılım farkları azaltılarak sistemin kararlılığı sağlanmıştır. Bu yönüyle, literatürde genellikle yalnızca tek oturum verileriyle test edilen çalışmalara kıyasla önemli bir ilerleme kaydedilmiştir. KH yöntemi sayesinde kaynak ve hedef veri arasındaki istatistiksel farklar minimize edilmiş, böylece sistemin yeniden kalibrasyon ihtiyacı ortadan kaldırılmıştır.

Her iki cihazla geliştirilen sistemlerde, görsel uyaran olarak yalnızca 7Hz frekansında tek bir LED kullanılmış; temel sınıflandırma kararı ise EOG kaynaklı artefaktlara dayalı göz

hareketleriyle gerçekleştirilmiştir. Bu sistem ile literatürde sıkça karşılaşılan çoklu frekanslı ışıklı uyaranların neden olduğu görsel yorgunluk, dikkat dağınıklığı ve epilepsi riski gibi sorunlara karşı etkili bir çözüm sunulmuştur. Kullanıcıların doğrudan titreşen uyaranlara sürekli odaklanma gereksinimi ortadan kaldırılmış, daha konforlu bir kullanım deneyimi sağlanmıştır. Ayrıca sistemin güvenilirliği, iki aşamalı bir kontrol mekanizmasıyla güçlendirilmiştir. İlk aşamada, kullanıcının LED'e odaklanarak bilinçli bir şekilde aktivasyonu başlatması sağlanmış; ikinci aşamada ise EOG sinyallerinden elde edilen zaman alanı öznitelikleriyle yön tayini sağlanmıştır. Bu yaklaşım, istemsiz göz kırpma veya çevresel dikkat dağınıklıklarının yanlış komutlara yol açmasını büyük ölçüde önleyerek ve sistemin gerçek dünya uygulamaları için uygunluğunu artırmıştır.

Sonuç olarak, Emotiv Epoc X ve Flex cihazları ile geliştirilen sistemlerin her biri, farklı avantajlara ve sınırlamalara sahip olsa da önerilen sistem her iki cihazla da yüksek DO ve BAH performansı sergilemiştir. Nispeten düşük kanal sayısı ile elde edilen bu başarı, sistemin donanımsal basitlik içinde yüksek verim sunabildiğini ortaya koymuştur. Ayrıca oturumlar arası kararlılığı destekleyen alan adaptasyon yöntemi KH, hibrit BBA sistemlerinin sürdürülebilirliğini ve güvenilirliğini önemli ölçüde artırmıştır. Bu bağlamda çalışma, kullanıcı konforunu, teknik doğruluğu ve uzun vadeli uygulanabilirliği ön planda tutan dengeli bir BBA çözümü sunmuştur.

Geliştirilen sistemin avantajlarına rağmen, çalışmalar sırasında fark edilen bazı dezavantajları da vardır. Örneğin, GUP tabanlı BBA sistemlerinde parlaklık düzeyi (lx), beyin sinyallerinde meydana gelen değişim üzerinde etkili bir parametredir. DDGUP paradigmasında ışık yoğunluğu üzerine yapılan araştırmalarda genellikle 30 lx'in altındaki ışık seviyeleri incelenmiş ve genel eğilim olarak parlaklık arttıkça elde edilen sinyallerin daha belirgin hâle geldiği bildirilmiştir (Duszyk ve ark., 2014; Ladouce ve ark., 2022; López ve ark., 2021; Sakurada ve ark., 2015). Bununla birlikte, bazı çalışmalarda maksimum aydınlatma düzeyinin her zaman en yüksek başarıyı getirmediği, aksine bazı durumlarda kullanıcıda rahatsızlık oluşturabileceği de raporlanmıştır (Ladouce ve ark., 2022; Mouli & Palaniappan, 2020). Bu çalışmada kullanıcıyı görsel

yükten korumak amacıyla yalnızca tek bir görsel uyaran (LED) kullanılmış ve kullanıcıdan bu uyaran üzerine odaklanması istenmemiştir. Bu sayede hem maruz kalınan ışık miktarı azaltılmış hem de daha konforlu bir kullanım hedeflenmiştir. Ancak LED'in parlaklığıyla ilgili özel bir analiz yapılmamış olup, ileride uyarının ışık yoğunluğunun sistem performansına etkisi değerlendirilebilir. Bu hem sistem performansın artırılması hem de kullanıcı konforunun iyileştirilmesi için faydalı olabilir. Bir diğer dikkat çeken sınırlama ise sistemde kullanılan ekranın sürekli kullanıcı karşısında bulunmasının yarattığı görsel rahatsızlıktır. Monitörün ışık yayması uzun süreli kullanımda göz konforunu olumsuz etkileyebilir. Son olarak, bu çalışmada geliştirilen sistem gerçek zamanlı ortamda test edilmemiştir. Bu durum sistemin pratikteki uygulanabilirliği hakkında bilgi vermemektedir. İlerideki çalışmalar, sistemin gerçek zamanlı senaryolarda denenmesini ve burada değinilen sınırlamaların giderilmesini hedeflemelidir.

6. SONUÇLAR

İki farklı EEG cihazı (Emotiv Epoc X ve Emotiv Flex) ile geliştirilen hibrit BBA sistemleri üzerinden yürütülen bu çalışma hem teknik doğruluk hem de kullanıcı deneyimi açısından önemli çıkarımlar sunmaktadır. Her iki BBA sistemi, DDGUP ve EOG sinyallerini farklı yapılandırmalarla birleştirerek, düşük kanal sayısı ile etkili bir kontrol mekanizması sağlamayı hedeflemiş; güvenlik, kararlılık ve konfor gibi uygulama odaklı kriterler önceliklendirilmiştir.

Emotiv Epoc X cihazıyla gerçekleştirilen sistemde, özellikle görsel konforu önceleyen bir yaklaşım ön planda tutulmuştur. Geleneksel DDGUP tabanlı sistemlerde, kullanıcının doğrudan odaklanmasını gerektiren yüksek kontrastlı uyarıcılar, uzun vadede göz yorgunluğu, baş ağrısı ve dikkat dağınıklığı gibi olumsuzluklara yol açabilmektedir. Bu sınırlamayı aşmak amacıyla, çalışmada hareketli nesneler üzerinden elde edilen EOG artefaktları kullanılmış, sistemin yalnızca bilinçli komutlarla aktif hâle gelmesini sağlamak adına 7Hz frekanslı, düşük parlaklığa sahip tek bir LED uyarıcısı eklenmiştir. Bu yapı sayesinde, kullanıcı LED'e odaklanmadığında sistemin ikinci aşaması devre dışı kalarak istemsiz komutlar engellenmiştir. İki aşamalı sınıflandırma sürecinde, ilk aşamada RO algoritması ile %99.57 doğruluk elde edilirken, ikinci aşamada EOG sinyalleri üzerinden yön belirleme %97.83 doğruluk oranı ile gerçekleştirilmiştir. Genel sistem performansı ise %97.42 DO ve 35.75 (bit/dk) BAH olarak kaydedilmiştir. Ayrıca çalışmada EEG kanalları ve frekans bantlarının etkisi analiz edilerek sistemin daha verimli hâle getirilmesi hedeflenmiştir.

Emotiv Flex EEG cihazı ile geliştirilen sistemde ise öncelikli olarak sistemin oturumlar arası kararlılığı ve yeniden kalibrasyon ihtiyacı üzerinde yoğunlaşmıştır. Kullanıcıların her oturum öncesi sistemle yeniden eğitilmesi ihtiyacını ortadan kaldırmak için sisteme KH yöntemi uygulanmış, farklı zaman dilimlerinde kaydedilen verilerdeki dağılım farkları istatistiksel olarak azaltılmıştır. Böylece sistem, iki ayrı oturumda da kararlı şekilde çalışmış, yeniden kalibrasyon gereksinimi ortadan kaldırılmıştır. Birinci

sınıflandırma aşamasında 1–15Hz aralığında filtrelenen EEG sinyalleri üzerinden GSY ve sayısal integrasyon temelli öznitelikler çıkartılmış; TA, RO ve DVM algoritmalarıyla sınıflandırma yapılmıştır. En yüksek başarı %99.12 doğruluk oranı ile TA algoritması kullanılarak elde edilmiştir. İkinci aşamada ise EOG sinyallerinden çıkarılan zaman alanı öznitelikleriyle dört yönlü nesne takibi yapılmıştır. TA algoritması %94.29 doğruluk oranı, (38.35 bit/dk) BAH, %94.55 hassasiyet ve %94.42 F1-skoru değerleri ile yine en yüksek performansı sergilemiştir. RO algoritması, TA'ya yakın bir performans sergilerken, DVM algoritması ise diğerlerine kıyasla daha düşük bir performans göstermiştir.

Her iki sistemde de sınırlı sayıda kanal kullanılarak yüksek doğruluk ve verimli kontrol sağlanmış, geleneksel sistemlerde karşılaşılan kullanıcı yorgunluğu, yanlış aktivasyon, oturumlar arası kararsızlık sorunlarına karşı etkili bir BBA sistemi önerilmiştir. Özellikle Emotiv Flex sistemi, alan adaptasyon yöntemleri sayesinde gerçek yaşam uygulamalarına daha uygun hâle gelirken; Emotiv Epoc X sistemi, görsel konforu önceleyen yapısıyla uzun süreli kullanımda kullanıcı dostu bir sistem sunmuştur. Sonuç olarak, her iki cihazla elde edilen bulgular, düşük donanım maliyeti, kolay kurulum, yüksek sınıflandırma başarımları ve güvenli kullanım yapısıyla hibrit BBA sistemlerinin gelecekte günlük yaşamda uygulanabilirliği açısından umut vaat ettiğini ortaya koymuştur.

7. KAYNAKLAR

- Akram, F., Han, S. M., & 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>.
- Albahri, A. S., Al-Qaysi, Z. T., Alzubaidi, L., Alnoor, A., Albahri, O. S., Alamoodi, A. H., & Bakar, A. A. (2023). A Systematic Review of Using Deep Learning Technology in the Steady-State Visually Evoked Potential-Based Brain-Computer Interface Applications: Current Trends and Future Trust Methodology. *International Journal of Telemedicine and Applications*, 2023. <https://doi.org/10.1155/2023/7741735>.
- 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.
- Ancau, D. M., Ancau, M., & Ancau, M. (2022). Deep-learning online EEG decoding brain-computer interface using error-related potentials recorded with a consumer-grade headset. *Biomedical Physics and Engineering Express*, 8(2). <https://doi.org/10.1088/2057-1976/AC4C28>.
- Asanza, V., Avilés-Mendoza, K., Trivino-Gonzalez, H., Rosales-Uribe, F., Torres-Brunes, J., Loayza, F. R., Peláez, E., Cajo, R., & Tinoco-Egas, R. (2021). SSVEP-EEG Signal Classification based on Emotiv EPOC BCI and Raspberry Pi. *IFAC-PapersOnLine*, 54(15), 388-393. <https://doi.org/10.1016/J.IFACOL.2021.10.287>.
- Avots, E., Jermakovs, K., Bachmann, M., Päeske, L., Ozcinar, C., & Anbarjafari, G. (2022). Ensemble Approach for Detection of Depression Using EEG Features. *Entropy*, 24(2), 211. <https://doi.org/10.3390/E24020211>.
- Bashashati, A., Fatourechi, M., Ward, R. K., & Birch, G. E. (2007). A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *Journal of neural engineering*, 4(2). <https://doi.org/10.1088/1741-2560/4/2/R03>.
- Bashashati, H., Ward, R. K., Birch, G. E., & Bashashati, A. (2015). Comparing Different Classifiers in Sensory Motor Brain Computer Interfaces. *PLOS ONE*, 10(6), e0129435. <https://doi.org/10.1371/JOURNAL.PONE.0129435>.
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition* CLARENDON PRESS, OXFORD 1995. Clarendon Press: Oxford.
- Bobrov, P., Frolov, A., Cantor, C., Fedulova, I., Bakhnyan, M., & Zhavoronkov, A. (2011). Brain-Computer Interface Based on Generation of Visual Images. *PLOS ONE*, 6(6), e20674. <https://doi.org/10.1371/JOURNAL.PONE.0020674>.
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24(2), 123-140. <https://doi.org/10.1007/BF00058655>.
- Brennan, C. P., McCullagh, P. J., Galway, L., & Lightbody, G. (2015a). 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>.
- Brennan, C. P., McCullagh, P. J., Galway, L., & Lightbody, G. (2015b). 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>.
- Campbell, A., Choudhury, T., Hu, S., Lu, H., Mukerjee, M. K., Rabbi, M., & Raizada, R. D. S. (2010). NeuroPhone: Brain-mobile phone interface using a wireless EEG headset. Proceedings of the 2nd ACM SIGCOMM Workshop on Networking, Systems, and Applications on Mobile Handhelds, MobiHeld '10, Co-located with SIGCOMM 2010, 3-8. <https://doi.org/10.1145/1851322.1851326>.
- Chailloux Peguero, J. D., Hernández-Rojas, L. G., Mendoza-Montoya, O., Caraza, R., & Antelis, J. M. (2023). SSVEP detection assessment by combining visual stimuli paradigms and no-training detection methods. *Frontiers in Neuroscience*, 17, 1142892-1142892. <https://doi.org/10.3389/FNINS.2023.1142892>.
- Chai, X., Zhang, Z., Guan, K., Liu, G., & Niu, H. (2019). A radial zoom motion-based paradigm for steady state motion visual evoked potentials. *Frontiers in Human Neuroscience*, 13, 451739. <https://doi.org/10.3389/FNHUM.2019.00127>.
- Chen, X., Wang, Y., Gao, S., Jung, T. P., & Gao, X. (2015). Filter bank canonical correlation analysis for implementing a high-speed SSVEP-based brain-computer interface. *Journal of Neural Engineering*, 12(4). <https://doi.org/10.1088/1741-2560/12/4/046008>.
- Chen, X., Wang, Y., Nakanishi, M., Gao, X., Jung, T. P., & Gao, S. (2015). High-speed spelling with a noninvasive brain-computer interface. *Proceedings of the National Academy of Sciences of the United States of America*, 112(44), E6058-E6067. <https://doi.org/10.1073/PNAS.1508080112>.
- Chiuzbaian, A., Jakobsen, J., & Puthusserypady, S. (2019). Mind Controlled Drone: An Innovative Multiclass SSVEP based Brain Computer Interface. 7th International Winter Conference on Brain-Computer Interface, BCI 2019. <https://doi.org/10.1109/IWW-BCI.2019.8737327>.
- Chu, C., Luo, J., Tian, X., Han, X., & Guo, S. (2021). A P300 Brain-Computer Interface Paradigm Based on Electric and Vibration Simple Command Tactile Stimulation. *Frontiers in Human Neuroscience*, 15, 641357. <https://doi.org/10.3389/FNHUM.2021.641357>.
- Cortes, C., Vapnik, V., & Saitta, L. (1995). Support-vector networks. *Machine Learning* 1995 20:3, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>.
- Dietterich, T. G. (2000). Ensemble Methods in Machine Learning. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1857 LNCS, 1-15. https://doi.org/10.1007/3-540-45014-9_1.
- Dimitrov, G., Petrov, P., Dimitrova, I., Panayotova, G., Garvanov, I., Bychkov, O., Kovatcheva, E., & Petrova, P. (2020). Increasing the Classification Accuracy of EEG based Brain-computer Interface Signals. Proceedings - International Conference on Advanced Computer Information Technologies, ACIT, 386-390. <https://doi.org/10.1109/ACIT49673.2020.9208944>.
- Dong, Y., & Tian, S. (2023). A large database towards user-friendly SSVEP-based BCI. *Brain Science Advances*, 9(4), 297-309.

- <https://doi.org/10.26599/BSA.2023.9050020>.
- D., R. (1989). Human brain electrophysiology. Evoked potentials and evoked magnetic fields in science and medicine. <https://cir.nii.ac.jp/crid/1572543025661076864>.
- Duncan, C. C., Barry, R. J., Connolly, J. F., Fischer, C., Michie, P. T., Näätänen, R., Polich, J., Reinvang, I., & Van Petten, C. (2009). Event-related potentials in clinical research: Guidelines for eliciting, recording, and quantifying mismatch negativity, P300, and N400. *Clinical Neurophysiology*, 120(11), 1883-1908. <https://doi.org/10.1016/J.CLINPH.2009.07.045>.
- Duszyk, A., Bierzyńska, M., Radzikowska, Z., Milanowski, P., Kuś, R., Suffczyński, P., Michalska, M., Labęcki, M., Zwoliński, P., & Durka, P. (2014). Towards an Optimization of Stimulus Parameters for Brain-Computer Interfaces Based on Steady State Visual Evoked Potentials. *PLOS ONE*, 9(11), e112099. <https://doi.org/10.1371/JOURNAL.PONE.0112099>.
- Duvinage, M., Castermans, T., Petieau, M., Hoellinger, T., Cheron, G., & Dutoit, T. (2013). Performance of the Emotiv Epoc headset for P300-based applications. *BioMedical Engineering Online*, 12(1). <https://doi.org/10.1186/1475-925X-12-56>.
- Esteves, A., Velloso, E., Bulling, A., & Gellersen, H. (2015). Orbits: Gaze interaction for smart watches using smooth pursuit eye movements. *UIST 2015 - Proceedings of the 28th Annual ACM Symposium on User Interface Software and Technology*, 457-466. <https://doi.org/10.1145/2807442.2807499>.
- Fakhruzzaman, M. N., Riksakomara, E., & Suryotrisongko, H. (2015). EEG Wave Identification in Human Brain with Emotiv EPOC for Motor Imagery. *Procedia Computer Science*, 72, 269-276. <https://doi.org/10.1016/J.PROCS.2015.12.140>.
- Fang, F., & Shinozaki, T. (2018). Electrooculography-based continuous eye-writing recognition system for efficient assistive communication systems. *PLOS ONE*, 13(2), e0192684. <https://doi.org/10.1371/JOURNAL.PONE.0192684>.
- Faruk, M. J. H., Valero, M., & Shahriar, H. (2021). An investigation on non-invasive brain-computer interfaces: Emotiv Epoc+ neuroheadset and its effectiveness. *Proceedings - 2021 IEEE 45th Annual Computers, Software, and Applications Conference, COMPSAC 2021*, 580-589. <https://doi.org/10.1109/COMPSAC51774.2021.00086>.
- Fatourehchi, M., Bashashati, A., Ward, R. K., & 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>.
- Fernandez-Fraga, S. M., Aceves-Fernandez, M. A., & Pedraza-Ortega, J. C. (2019). EEG data collection using visual evoked, steady state visual evoked and motor image task, designed to brain computer interfaces (BCI) development. *Data in Brief*, 25, 103871. <https://doi.org/10.1016/J.DIB.2019.103871>.
- Fisher, R. S., Harding, G., Erba, G., Barkley, G. L., & Wilkins, A. (2005). Photic- and pattern-induced seizures: A review for the epilepsy foundation of america working group. *Epilepsia*, 46(9), 1426-1441. <https://doi.org/10.1111/J.1528-1167.2005.31405.X>.
- Friganovic, K., Medved, M., & Cifrek, M. (2016). Brain-computer interface based on steady-state visual evoked potentials. *2016 39th International Convention on Information and Communication Technology, Electronics and Microelectronics*,

- MIPRO 2016 - Proceedings, 391-395.
<https://doi.org/10.1109/MIPRO.2016.7522174>.
- Ge, S., Jiang, Y., Wang, P., Wang, H., & Zheng, W. (2019). Training -Free Steady-State Visual Evoked Potential Brain-Computer Interface Based on Filter Bank Canonical Correlation Analysis and Spatiotemporal Beamforming Decoding. *IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*, 27(9), 1714-1723. <https://doi.org/10.1109/TNSRE.2019.2934496>.
- Giles, J., Ang, K. K., Phua, K. S., & Arvaneh, M. (2022). A Transfer Learning Algorithm to Reduce Brain-Computer Interface Calibration Time for Long-Term Users. *Frontiers in Neuroergonomics*, 3, 837307. <https://doi.org/10.3389/FNNGO.2022.837307>.
- Hammond, R. T. (2006). Intense ultrashort electromagnetic pulses and the equation of motion. <https://arxiv.org/pdf/physics/0607285>.
- Hamou, S., Moufassih, M., Tarahi, O., Agounad, S., & Azami, H. I. (2024). Hybrid approach: combining eCCA and SSCOR for enhancing SSVEP decoding. *Journal of Supercomputing*, 80(10), 14391-14416. <https://doi.org/10.1007/S11227-024-06027-7>.
- Herrmann, C. S. (2001). Human EEG responses to 1-100 Hz flicker: Resonance phenomena in visual cortex and their potential correlation to cognitive phenomena. *Experimental Brain Research*, 137(3-4), 346-353. <https://doi.org/10.1007/S002210100682>.
- Huang, Q., Zhang, Z., Yu, T., He, S., & Li, Y. (2019). An EEG-/EOG-Based Hybrid Brain-Computer Interface: Application on Controlling an Integrated Wheelchair Robotic Arm System. *Frontiers in Neuroscience*, 13, 459140. <https://doi.org/10.3389/FNINS.2019.01243>.
- Ioffe, S. (2006). Probabilistic Linear Discriminant Analysis. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 3954 LNCS, 531-542. https://doi.org/10.1007/11744085_41.
- Jiang, J., Zhou, Z., Yin, E., Yu, Y., & Hu, D. (2014). Hybrid Brain-Computer Interface (BCI) based on the EEG and EOG signals. *Bio-Medical Materials and Engineering*, 24(6), 2919-2925. <https://doi.org/10.3233/BME-141111>.
- Kamińska, D., Smółka, K., & Zwoliński, G. (2021). Detection of Mental Stress through EEG Signal in Virtual Reality Environment. *Electronics* 2021, Vol. 10, Page 2840, 10(22), 2840. <https://doi.org/10.3390/ELECTRONICS10222840>.
- Karas, K., Pozzi, L., Pedrocchi, A., Braghin, F., & Roveda, L. (2023). Brain-computer interface for robot control with eye artifacts for assistive applications. *Scientific Reports*, 13(1), 1-16. <https://doi.org/10.1038/S41598-023-44645>.
- Kaya, E., & 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>.
- Kinney-Lang, E., Kelly, D., Floreani, E. D., Jadavji, Z., Rowley, D., Zewdie, E. T., Anaraki, J. R., Bahari, H., Beckers, K., Castelane, K., Crawford, L., House, S., Rauh, C. A., Michaud, A., Mussi, M., Silver, J., Tuck, C., Adams, K., Andersen, J., ... Kirton, A. (2020). Advancing Brain-Computer Interface Applications for Severely Disabled Children Through a Multidisciplinary National Network:

- Summary of the Inaugural Pediatric BCI Canada Meeting. *Frontiers in Human Neuroscience*, 14. <https://doi.org/10.3389/FNHUM.2020.593883>.
- Kondo, S., & 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>.
- Kubacki, A. (2021). Use of Force Feedback Device in a Hybrid Brain-Computer Interface Based on SSVEP, EOG and Eye Tracking for Sorting Items. *Sensors* 2021, Vol. 21, Page 7244, 21(21), 7244. <https://doi.org/10.3390/S21217244>.
- Kumar, D., & Sharma, A. (2016). Electrooculogram-based virtual reality game control using blink detection and gaze calibration. 2016 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2016, 2358-2362. <https://doi.org/10.1109/ICACCI.2016.7732407>.
- Ladouce, S., Darmet, L., Torre Tresols, J. J., Velut, S., Ferraro, G., & Dehais, F. (2022). Improving user experience of SSVEP BCI through low amplitude depth and high frequency stimuli design. *Scientific Reports*, 12(1), 1-12. <https://doi.org/10.1038/S41598-022-12733>.
- Lehmann, C., Koenig, T., Jelic, V., Prichep, L., John, R. E., Wahlund, L. O., Dodge, Y., & Dierks, T. (2007). Application and comparison of classification algorithms for recognition of Alzheimer's disease in electrical brain activity (EEG). *Journal of Neuroscience Methods*, 161(2), 342-350. <https://doi.org/10.1016/J.JNEUMETH.2006.10.023>.
- Li, M., He, D., Li, C., & Qi, S. (2021). Brain-Computer Interface Speller Based on Steady-State Visual Evoked Potential: A Review Focusing on the Stimulus Paradigm and Performance. *Brain Sciences* 2021, Vol. 11, Page 450, 11(4), 450. <https://doi.org/10.3390/BRAINSKI11040450>.
- Liu, X., Hu, B., Si, Y., & Wang, Q. (2024). The role of eye movement signals in non-invasive brain-computer interface typing system. *Medical & biological engineering & computing*, 62(7), 1981-1990. <https://doi.org/10.1007/S11517-024-03070-7>.
- Liu S., Zhang D., Liu Z., Review of brain-computer interface based on steady-state visual evoked potential, *Brain Science Advances*, vol. 8, no. 4, pp. 258–275, Dec. 2022, doi: 10.26599/BSA.2022.9050022.
- Li, Z., Zhang, R., Li, W., Li, M., Chen, X., & Cui, H. (2024). Enhancement of hybrid BCI system performance based on motor imagery and SSVEP by transcranial alternating current stimulation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 32. <https://doi.org/10.1109/TNSRE.2024.3451015>.
- Lotte, F., Congedo, M., Lécuyer, A., Lamarche, F., & Arnaldi, B. (2007). A review of classification algorithms for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 4(2), R1. <https://doi.org/10.1088/1741-2560/4/2/R01>.
- Mahmood, H. R., Gharkan, D. K., Jamil, G. I., Jaish, A. A., & Yahya, S. T. (2024). Eye Movement Classification using Feature Engineering and Ensemble Machine Learning. *Engineering, Technology & Applied Science Research*, 14(6), 18509-18517. <https://doi.org/10.48084/ETASR.9115>.
- Mai, X., Ai, J., Ji, M., Zhu, X., & Meng, J. (2024a). 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>.
- Mai, X., Ai, J., Ji, M., Zhu, X., & Meng, J. (2024b). 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>.
- Maleki, M., Manshouri, N., & Kayikcioglu, T. (2020). Brain-computer Interface Systems for Smart Homes - A Review Study. *Recent Advances in Electrical & Electronic Engineering (Formerly Recent Patents on Electrical & Electronic Engineering)*, 14(2), 144-155. <https://doi.org/10.2174/2352096513999200727175948>.
- Melek, M., Manshouri, N., & 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>.
- Mitra, P., & Bokil, H. (2007). Observed Brain Dynamics. *Observed Brain Dynamics*, 1-404. <https://doi.org/10.1093/ACPROF:OSO/9780195178081.001.0001>.
- Mouli, S., & Palaniappan, R. (2017). Eliciting higher SSVEP response from LED visual stimulus with varying luminosity levels. 2016 International Conference for Students on Applied Engineering, ICSAE 2016, 201-206. <https://doi.org/10.1109/ICSAE.2016.7810188>.
- Mouli, S., & 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>.
- Mulak, P., & Talhar, N. (2013). Analysis of Distance Measures Using K-Nearest Neighbor Algorithm on KDD Dataset. *International Journal of Science and Research*, 4, 2319-7064.
- Murillo López, J. L., Cerezo Ramírez, J. C., & Yoo, S. G. (2021). Study of the Influences of Stimuli Characteristics in the Implementation of Steady State Visual Evoked Potentials Based Brain Computer Interface Systems. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12855 LNAI, 302-317. https://doi.org/10.1007/978-3-030-87897-9_28.
- Mussi, M. G., & Adams, K. D. (2022). EEG hybrid brain-computer interfaces: A scoping review applying an existing hybrid-BCI taxonomy and considerations for pediatric applications. *Frontiers in Human Neuroscience*, 16. <https://doi.org/10.3389/FNHUM.2022.1007136>.
- Mwata-Velu, T., Ruiz-Pinales, J., Rostro-Gonzalez, H., Ibarra-Manzano, M. A., Cruz-Duarte, J. M., & Avina-Cervantes, J. G. (2021). Motor imagery classification based on a recurrent-convolutional architecture to control a hexapod robot. *Mathematics*, 9(6). <https://doi.org/10.3390/MATH9060606>.
- Nakanishi, M., Wang, Y., Chen, X., Wang, Y. Te, Gao, X., & Jung, T. P. (2018). Enhancing detection of SSVEPs for a high-speed brain speller using task-related component analysis. *IEEE Transactions on Biomedical Engineering*, 65(1), 104-112. <https://doi.org/10.1109/TBME.2017.2694818>.
- Ngo, B. V., Nguyen, T. H., & Nguyen, T. N. (2021). EEG Signal-Based Eye Blink Classifier Using Convolutional Neural Network for BCI Systems. *Proceedings - 2021 15th International Conference on Advanced Computing and Applications, ACOMP 2021*, 176-180. <https://doi.org/10.1109/ACOMP53746.2021.00031>.
- Orlandi, S., House, S. C., Karlsson, P., Saab, R., & Chau, T. (2021). Brain-Computer Interfaces for Children With Complex Communication Needs and Limited Mobility: A Systematic Review. *Frontiers in Human Neuroscience*, 15. <https://doi.org/10.3389/FNHUM.2021.643294>.

- Özkahraman, A., Ölmez, T., & Dokur, Z. (2024). Performance Improvement with Reduced Number of Channels in Motor Imagery BCI System. *Sensors (Basel, Switzerland)*, 25(1), 120. <https://doi.org/10.3390/S25010120>.
- Powers, D. (2011). Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.
- Punsawad, Y., & Wongsawat, Y. (2012). Motion visual stimulus for SSVEP-based BCI system. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2012*, 3837-3840. <https://doi.org/10.1109/EMBC.2012.6346804>.
- Ramli, R., Arof, H., Ibrahim, F., Mokhtar, N., & Idris, M. Y. I. (2015). Using finite state machine and a hybrid of EEG signal and EOG artifacts for an asynchronous wheelchair navigation. *Expert Systems with Applications*, 42(5), 2451-2463. <https://doi.org/10.1016/J.ESWA.2014.10.052>.
- Roescher, T., Randles, B., & Welcher, J. (2023). Estimation of Seated Driver Eye Height based on Standing Height, Weight, Seatback Angle, and Seat Bottom Angle. *SAE Technical Papers*. <https://doi.org/10.4271/2023-01-0838>.
- Sadeghi, S., & Maleki, A. (2022). A comprehensive benchmark dataset for SSVEP-based hybrid BCI. *Expert Systems with Applications*, 200, 117180. <https://doi.org/10.1016/J.ESWA.2022.117180>.
- Saha, S., & Baumert, M. (2020). Intra- and Inter-subject Variability in EEG-Based Sensorimotor Brain Computer Interface: A Review. *Frontiers in Computational Neuroscience*, 13, 87. <https://doi.org/10.3389/FNCOM.2019.00087>.
- Saichoo, T., Boonbrahm, P., & Punsawad, Y. (2021). Facial-machine interface-based virtual reality wheelchair control using EEG artifacts of emotiv neuroheadset. *ECTI-CON 2021 - 2021 18th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology: Smart Electrical System and Technology, Proceedings*, 781-784. <https://doi.org/10.1109/ECTI-CON51831.2021.9454926>.
- Saichoo, T., Boonbrahm, P., & Punsawad, Y. (2022). Investigating User Proficiency of Motor Imagery for EEG-Based BCI System to Control Simulated Wheelchair. *Sensors* 2022, Vol. 22, Page 9788, 22(24), 9788. <https://doi.org/10.3390/S22249788>.
- Sakurada, T., Kawase, T., Komatsu, T., & Kansaku, K. (2015). Use of high-frequency visual stimuli above the critical flicker frequency in a SSVEP-based BMI. *Clinical Neurophysiology*, 126(10), 1972-1978. <https://doi.org/10.1016/J.CLINPH.2014.12.010>.
- Saravanakumar, D., & Ramasubba Reddy, M. (2020). A virtual speller system using SSVEP and electrooculogram. *Advanced Engineering Informatics*, 44, 101059. <https://doi.org/10.1016/J.AEI.2020.101059>.
- Selvi, A. O., Ferikoglu, A., & Guzel, D. (2018). Comparing the stimulus time of the P300 Based Brain Computer Interface Systems with the Deep Learning Method. *ISMSIT 2018 - 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies, Proceedings*. <https://doi.org/10.1109/ISMSIT.2018.8567064>.
- Simpson, M. J. (2017). Mini-review: Far peripheral vision. *Vision Research*, 140, 96-105. <https://doi.org/10.1016/J.VISRES.2017.08.001>
- Sörnmo, L., & Pablo, L. (2005). *Bioelectrical Signal Processing in Cardiac and*

- Neurological Applications. Elsevier Science & Technology.
- Stawicki, P., & Volosyak, I. (2020). Comparison of Modern Highly Interactive Flicker-Free Steady State Motion Visual Evoked Potentials for Practical Brain–Computer Interfaces. *Brain Sciences* 2020, Vol. 10, Page 686, 10(10), 686. <https://doi.org/10.3390/BRAINSCI10100686>.
- Sthle, L., & Wold, S. (1990). Multivariate analysis of variance (MANOVA). *Chemometrics and Intelligent Laboratory Systems*, 9(2), 127-141. [https://doi.org/10.1016/0169-7439\(90\)80094-M](https://doi.org/10.1016/0169-7439(90)80094-M).
- Sun, B., & Saenko, K. (2016). Deep CORAL: Correlation alignment for deep domain adaptation. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9915 LNCS, 443-450. <https://doi.org/10.1007/978-3-319-49409-8>.
- Sung, D. J., Kim, K. T., Jeong, J. H., Kim, L., Lee, S. J., Kim, H., & Kim, S. J. (2024). Improving inter-session performance via relevant session-transfer for multi-session motor imagery classification. *Heliyon*, 10(17), e37343. <https://doi.org/10.1016/J.HELİYON.2024.E37343>.
- Tiwari, S., Goel, S., & 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>.
- Trigui, O., Zouch, W., & Ben Messaoud, M. (2016). A comparison study of SSVEP detection methods using the Emotiv Epoc headset. *16th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering, STA 2015*, 48-53. <https://doi.org/10.1109/STA.2015.7505108>.
- Värbu, K., Muhammad, N., & Muhammad, Y. (2022). Past, Present, and Future of EEG-Based BCI Applications. *Sensors* 2022, Vol. 22, Page 3331, 22(9), 3331. <https://doi.org/10.3390/S22093331>.
- V., H. M., & Begum, B. S. (2025). Towards imagined speech: Identification of brain states from EEG signals for BCI-based communication systems. *Behavioural Brain Research*, 477, 115295. <https://doi.org/10.1016/J.BBR.2024.115295>.
- Vidal, M., Bulling, A., & Gellersen, H. (2011). Analysing EOG signal features for the discrimination of eye movements with wearable devices. *PETMEI'11 - Proceedings of the 1st International Workshop on Pervasive Eye Tracking and Mobile Eye-Based Interaction*, 15-20. <https://doi.org/10.1145/2029956.2029962>.
- Wang, Y., Markham, C., & Deegan, C. (2019). Assessing the time synchronisation of EEG systems. *30th Irish Signals and Systems Conference, ISSC 2019*. <https://doi.org/10.1109/ISSC.2019.8904947>.
- 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>.
- Williams, N. S., McArthur, G. M., & Badcock, N. A. (2020). 10 years of EPOC: A scoping review of Emotiv's portable EEG device. *bioRxiv*, 2020.07.14.202085. <https://doi.org/10.1101/2020.07.14.202085>.
- Wolpaw, J. R., Ramoser, H., McFarland, D. J., & 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>.
- Wolpaw, J. R., & Wolpaw, E. W. (2012). *Brain–Computer Interfaces: Principles and*

- Practice. *Brain-Computer Interfaces: Principles and Practice*, 1-424. <https://doi.org/10.1093/ACPROF:OSO/9780195388855.001.0001>.
- Yayik, A., & Kutlu, Y. (2017). Beyin Bilgisayar Arayüzü Tabanlı Görsel Tespit Sistemi. 2017 25th Signal Processing and Communications Applications Conference, SIU 2017. <https://doi.org/10.1109/SIU.2017.7960406>.
- Yu, Y., Zhou, Z., Liu, Y., Jiang, J., Yin, E., Zhang, N., Wang, Z., Liu, Y., Wu, X., & Hu, D. (2017). Self-paced operation of a wheelchair based on a hybrid brain-computer interface combining motor imagery and P300 potential. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(12), 2516-2526. <https://doi.org/10.1109/TNSRE.2017.2766365>.
- Zhang, C.; M. (2005). *Ensemble Machine Learning*. Ensemble Machine Learning. <https://doi.org/10.1007/978-1-4419-9326-7>.
- Zhang, J., Gao, S., Zhou, K., Cheng, Y., & Mao, S. (2023a). 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, X., Wu, B., Zhang, Y., Zhang, T., Yang, L., Fang, H. H. P., Ford, T., & Cheng, S. (2009). Class 1 integronase gene and tetracycline resistance genes tetA and tetC in different water environments of Jiangsu Province, China. *Ecotoxicology*, 18(6), 652-660. <https://doi.org/10.1007/S10646-009-0332-3>.
- Zhu, D., Bieger, J., Garcia Molina, G., & Aarts, R. M. (2010). A survey of stimulation methods used in SSVEP-based BCIs. *Computational Intelligence and Neuroscience*, 2010. <https://doi.org/10.1155/2010/702357>.
- Zhu, Y., Li, Y., Lu, J., & Li, P. (2020). A Hybrid BCI Based on SSVEP and EOG for Robotic Arm Control. *Frontiers in Neurorobotics*, 14. <https://doi.org/10.3389/FNBOT.2020.583641>.

8. ÖZGEÇMİŞ

