

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ELEKTROENSEFALOGRAFİ VE YAKIN KIZILÖTESİ SPEKTROSKOPİ TABANLI HİBRİT
MODEL KULLANARAK BEYİN BİLGİSAYAR ARAYÜZÜ SİSTEMİNİN PERFORMANSININ
ARTTIRILMASI**

DOKTORA TEZİ

Ebru ERGÜN

**MART 2023
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ELEKTROENSEFALOGRAFI VE YAKIN KIZILÖTESİ SPEKTROSKOPİ TABANLI
HİBRİT MODEL KULLANARAK BEYİN BİLGİSAYAR ARAYÜZÜ SİSTEMİNİN
PERFORMANSININ ARTTIRILMASI**

Ebru ERGÜN

ORCID : - - -

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (ELEKTRONİK MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 07 / 03 / 2023

Tezin Savunma Tarihi : 31 / 03 / 2023

Tez Danışmanı : Doç. Dr. Önder AYDEMİR
ORCID : - - -

Trabzon 2023

ÖNSÖZ

Son yıllarda hızlı gelişme gösteren ve uygulama sistemleri ile oldukça geniş bir araştırma alanı oluşturan beyin bilgisayar arayüzü (BBA) sistemleri için farklı beyin görüntüleme teknikleri giriş işareti olarak kullanılmaktadır. Bu görüntüleme teknikleri arasında elektroensefalografi (EEG)'nin diğer yöntemlere göre daha fazla avantaj sahip olması BBA çalışmalarında yaygın kullanılmasını sağlamaktadır. Ancak hem deney paradigması açısından hem de sadece EEG kullanılarak yapılan çalışmaların BBA sistemlerinin performansını tatmin edici seviyelere çıkarmadığı görülmektedir. Bu da araştırmacıları işlevselliği yüksek deney paradigması içeren hibrit giriş işareti olan BBA sistemlerine yönlendirmektedir. Bu tez çalışmasında da yeni bir deney paradigması içeren EEG+yakın kızılötesi spektroskopi tabanlı hibrit veri kümesinden çıkarılan öznitelikler sınıflandırılarak yüksek başarılı BBA sisteminin oluşturulması amaçlanmıştır.

Bu çalışmanın amacına ulaşması için engin bilgi ve yenilikçi düşünceleriyle bana yol gösteren ve doktora öğrenimim boyunca gerek bilimsel çalışmalarında gerekse diğer konularda beni destekleyerek yardımcı olan tez danışmanım Doç. Dr. Önder AYDEMİR'e ilgi, destek ve tecrübelerini esirgemediğinden dolayı teşekkürlerimi saygı ve minnetle sunarım. Tez izleme komitesinde yer alarak doktora süresi boyunca fikirlerini bizden esirgemeyen Prof. Dr. Ali GANGAL ve Prof. Dr. Cemal KÖSE hocalarımıza çok teşekkür ederim.

Tez çalışmam süresince BİDEB 2211-C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında maddi olarak beni destekleyen Türkiye bilimsel ve Teknolojik Araştırma Kurumu (TUBİTAK)'a teşekkür ederim.

Deneylerin gerçekleştirilmesinde her türlü destek ve yardımlarını esirgemeyen arkadaşım Arş. Gör. Dr. Onur Erdem KORKMAZ'a çok teşekkür ederim. Çalışmalarım süresince sabır, destek ve sevgileriyle yanımda olup hayatım boyunca bana güç veren eşim Gökhan Galip ERGÜN ve oğlum Kerem ERGÜN'e, anlayış ve desteklerinden dolayı değerli aileme, hoşgörülerinden dolayı tüm mesai arkadaşlarıma ve Ayşe Nur ALTUNKAYA'ya çok teşekkür ederim.

Ebru ERGÜN

Trabzon 2023

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Elektroensefalografi ve Yakın Kızılötesi Spektroskopi Tabanlı Hibrit Model Kullanarak Beyin Bilgisayar Arayüzü Sisteminin Performansının Arttırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Önder AYDEMİR’in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 31/03/2023

Ebru ERGÜN

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER DİZİNİ	XII
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Beynin Temel Yapısı	3
1.2.1. Beynin Bölümleri ve Görevleri	3
1.2.2. İnsan Beyninin Çalışma Prensipleri.....	5
1.2.3. Nöronlarda Elektrokimyasal İletim	6
1.2.4. Beyin ve Hemoglobin Konsantrasyonları	7
1.3. Beynin Nöral Aktivitesini Görüntüleme Teknikleri.....	7
1.3.1. Elektroensefalografi Özellikleri	9
1.3.2. Yakın Kızılötesi Spektroskopi Özellikleri.....	11
1.4. Beyin Bilgisayar Arayüzü	14
1.4.1. BBA'nın Giriş İşaretinin Elde Edilme Yöntemi	16
1.4.1.1. BBA için Düşünsel Görev	17
1.4.1.1.1. Motor Hayaline Dayalı Beyin Bilgisayar Arayüzleri	17
1.4.1.1.2. P300 Sinyallerine Dayalı Beyin Bilgisayar Arayüzleri	18
1.4.1.1.3. DDGUP'e Dayalı Beyin Bilgisayar Arayüzleri	20
1.4.2. BBA İçin Ön İşleme	20
1.4.4. Karar Verme Aşamasında Kullanılacak Sınıflandırma Yöntemi	21
1.4.5. Kontrol Çıktısı	22
1.5. Literatür Araştırması.....	22
2. YAPILAN ÇALIŞMALAR.....	32
2.1. Veri Kümesi Tanıtımı.....	32

2.2.	Yöntem	39
2.2.1.	Ön İşleme.....	40
2.2.2.	Öznitelik Çıkarma Yöntemleri	40
2.2.2.1.	Hilbert Dönüşümü Öznitelikleri	41
2.2.2.2.	Bant Gücü Öznitelikleri.....	42
2.2.2.3.	Hızlı Walsh-Hadamard Dönüşümü Öznitelikleri	42
2.2.2.4.	İstatistiksel Öznitelikler	43
2.2.3.	Sınıflandırma Yöntemleri	45
2.2.3.1.	k-En Yakın Komşuluk	46
2.2.3.2.	Destek Vektör Makineleri	48
2.2.3.3.	Karar Ağaç Yapısı	50
2.2.3.4.	Rasgele Orman Algoritması	51
2.1.6.1.	DeneySEL Sonuçların Görselleştirilmesi	52
3.	BULGULAR	54
3.1.	2.4 Saniye Zaman Bölütü ile Elde Edilen Bulgular.....	54
3.2.	4.8 Saniye Zaman Bölütü ile Elde Edilen Bulgular.....	66
3.3.	12 Saniye Zaman Bölütü ile Elde Edilen Bulgular.....	74
3.4.	24 Saniye Zaman Bölütü ile Elde Edilen Bulgular.....	82
4.	SONUÇLAR.....	93
5.	ÖNERİLER	99
6.	KAYNAKLAR.....	101
7.	EKLER	117
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

ELEKTROENSEFALOGRAFİ VE YAKIN KIZILÖTESİ SPEKTROSKOPİ TABANLI
HİBRİT MODEL KULLANARAK BEYİN BİLGİSAYAR ARAYÜZÜ SİSTEMİNİN
PERFORMANSININ ARTTIRILMASI

Ebru ERGÜN

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik- Elektronik Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Önder AYDEMİR
2023, 116 Sayfa, 5 Ek Sayfa

Beyin Bilgisayar Arayüzü (BBA)'lar çeşitli beyin aktivitesini ölçen cihazlardan alınan sinyalleri giriş olarak kullanabilir. Bunlar arasında elektroensefalografi (EEG) diğer yöntemlere göre bazı avantajlara sahip olmasından dolayı BBA çalışmalarında yaygın kullanılmaktadır. Ancak, bu çalışmalar ile BBA sistemlerinin performansının etkin olmaması, benzer deney içeriklerine sahip çalışmaların yaygınlığı ve yeni deney içerikli çalışmaların ise bazı dezavantajlara sahip olması araştırmacıları deney paradigması tabanlı çalışmalara yönlendirmektedir. Buna ek olarak nöral aktiviteyi kaydetmeye yarayan beyin görüntüleme yöntemlerinin kendilerine özgü avantaj ve dezavantajları vardır. Bu bakış açısına dayanarak, birbirlerinin dezavantajlarını telafi eden çoklu sinyal kayıt yöntemlerinin birleştirilmesinin BBA sisteminin performansını artıracakı söylenebilir. EEG'nin aksine, diğer yöntemler arasında yakın kızılötesi spektroskopisi (YKS), vücut hareketlerine ve elektrikli ürünlere karşı göreceli sağlamlık avantajına sahiptir. Bu tez çalışmasında özgün deney paradigmasına sahip 4 sınıflı hibrit EEG+YKS veri kümesi kaydedilmiştir. Sağa, sola, yukarıya ve aşağıya kayan yazı okumaya dayalı bu özgün veri kümesinin hibrit modalite kullanımı ile yüksek başarılı bir BBA sistemi önerilmiştir. EEG+YKS veri kümesi, FHD-2020-9166 nolu Karadeniz Teknik Üniversitesi BAP projesi kapsamında destek alınarak hizmet alımı ile Atatürk Üniversitesinde kaydedilmiştir. Daha hızlı ve doğru BBA sisteminin oluşturulmasının amaçlandığı bu tez çalışmasında, veri kümesinden Hilbert Dönüşümü kullanarak öznitelikler çıkarılmış ardından öznitelikler k -en yakın komşu algoritması ile sınıflandırarak hibrit model ile 96.28 ± 1.30 sınıflandırma doğruluğu hesaplanarak yüksek performanslı bir hibrit BBA sistemi önerilmiştir.

Anahtar Kelimeler: Hibrit model, Elektroensefalografi, Yakın Kızılötesi Spektroskopisi, Beyin Bilgisayar Arayüzü, Deney Paradigması, Sınıflandırma Öznitelik Çıkarma

PhD. Thesis

SUMMARY

IMPROVING THE PERFORMANCE OF BRAIN COMPUTER INTERFACE
SYSTEM USING ELECTROENCEPHALOGRAPHY AND NEAR INFRARED
SPECTROSCOPY-BASED HYBRID MODEL

Ebru ERGUN

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program
Supervisor: Doç. Dr. Önder AYDEMİR
2023, 116 Pages, 5 Appendix Pages

Brain Computer Interface (BCI)'s can use signals from various brain activity measuring devices as inputs. Among these, electroencephalography (EEG) is widely used in BCI studies because it has some advantages over other methods. However, the ineffectiveness of the performance of BCI systems with these studies, the prevalence of studies with similar experimental content, and the fact that studies with new experimental content have some disadvantages lead researchers to experimental paradigm-based studies. In addition, neuroimaging methods for recording neural activity have their own advantages and disadvantages. Based on this point of view, it can be said that combining multiple signal recording methods that compensate for each other's disadvantages will improve the performance of the BCI system. Unlike EEG, among other methods, near infrared spectroscopy (NIRS) has the advantage of relative robustness against body movements and electrical products. In this thesis, a 4-class hybrid EEG+ NIRS dataset with a unique experimental paradigm was recorded. A high performance BCI system is proposed by using hybrid modality of this original dataset based on right, left, up and down scrolling text reading. The EEG+ NIRS dataset was recorded at Atatürk University with the support of the Karadeniz Technical University BAP project numbered FHD-2020-9166 and service procurement. In this thesis study, which aims to create a faster and more accurate BCI system, features are extracted from the dataset using Hilbert Transform, then the features are classified with the k-nearest neighbor algorithm and a high-performance hybrid BCI system is proposed by calculating $96.28\% \pm 1.30$ classification accuracy with the hybrid model.

Key Words: Hybrid model, Electroencephalography, Near Infrared Spectroscopy, Brain Computer Interface, Experiment Paradigm, Classification Feature Extraction

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. 1. Beynin bölümleri.....	4
Şekil 1.2. Sinir hücresi.....	5
Şekil 1.3. Aksiyon potansiyeli evreleri.....	7
Şekil 1.4. Kafa derisi üzerine 10-20 sistemine göre yerleştirilmiş EEG elektrotları	10
Şekil 1.5. EEG verileri için altı ana beyin ritmi	11
Şekil 1.6. Optik penceredeki emilme spektrumu.....	13
Şekil 1.7. Hemogloblin konsantrasyonlarının elde edilmesi	13
Şekil 1.8. Beyin bilgisayar arayüzü temel bileşenleri	16
Şekil 1.9. EEG işaretlerinde ortaya çıkan örnek bir görsel uyarılmış potansiyel.....	18
Şekil 1.10. 4. Satır parlamada iken satır-sütun paradigması	19
Şekil 1.11. DDGUP'e dayalı bir karakter seti örneği	20
Şekil 2.1. Deney katılan bireylerin deney esnasından fotoğrafları.....	33
Şekil 2.2. Deney düzeneği	34
Şekil 2.3. EEG+YKS veri kümesi kayıt prosedürü	34
Şekil 2.4. YYS emitör ve dedektörleri ile EEG elektrot pozisyonları.....	35
Şekil 2.5. Kayan yazı okumaya dayalı görsel ekran.....	36
Şekil 2.6. EEG+YKS veri kümesinden rasgele seçilmiş EEG, Deoxy ve Oxy denemeleri.....	38
Şekil 2.7. Önerilen yöntemin genel akış şeması.....	39
Şekil 2.8. X ve Y etiketlerinden oluşan örnek veri kümesi	48
Şekil 2.9. k-EYK yöntemi için veri sınıflandırması	48
Şekil 2.10. DVM için iki sınıflı problem örneği	49
Şekil 2.11. Karar ağaç yapısı.....	50
Şekil 2.12. Rasgele Orman Algoritması genel yapısı.....	51
Şekil 2.13. Sonuçların gösterildiği örnek radar grafiği	52
Şekil 2.14. Sonuçların gösterildiği örnek kişiye özgü bar grafiği	53
Şekil 3.1. 2.4 sn zaman bölütlerinden çıkarılan HD tabanlı öznelilikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	57
Şekil 3.2. 2.4 sn zaman bölütlerinden çıkarılan BG tabanlı öznelilikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	58

Şekil 3.3. 2.4 sn zaman bölütlerinden çıkarılan HWHD tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	59
Şekil 3.4. 2.4 sn zaman bölütlerinden çıkarılan İÖ ile 50 koşum sonucu ortalama eğitim ve test SD'si.....	60
Şekil 3.5. 2.4 sn zaman bölütlerinden çıkarılan özniteliklerinin sınıflandırılması ile 8 kişi için hesaplanan ortalama eğitim ve test SD'si radar grafikleri.....	65
Şekil 3.6. 4.8 sn zaman bölütlerinden çıkarılan HD tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	68
Şekil 3.7. 4.8 sn zaman bölütlerinden çıkarılan BG tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	69
Şekil 3.8. 4.8 sn zaman bölütlerinden çıkarılan HWHD tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	70
Şekil 3.9. 4.8 sn zaman bölütlerinden çıkarılan İÖ ile 50 koşum sonucu ortalama eğitim ve test SD'si.....	71
Şekil 3.10. 4.8 sn zaman bölütlerinden çıkarılan özniteliklerinin sınıflandırılması ile 8 kişi için hesaplanan ortalama eğitim ve test SD'si radar grafikleri.....	73
Şekil 3.11. 12 sn zaman bölütlerinden çıkarılan HD tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	76
Şekil 3.12. 12 sn zaman bölütlerinden çıkarılan BG tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	77
Şekil 3.13. 12 sn zaman bölütlerinden çıkarılan HWHD tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	78
Şekil 3.14. 12 sn zaman bölütlerinden çıkarılan İÖ ile 50 koşum sonucu ortalama eğitim ve test SD'si	79
Şekil 3.15. 12 sn zaman bölütlerinden çıkarılan özniteliklerinin sınıflandırılması ile 8 kişi için hesaplanan ortalama eğitim ve test SD'si radar grafikleri.....	81
Şekil 3.16. 24 sn zaman bölütlerinden çıkarılan HD tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	83
Şekil 3.17. 24 sn zaman bölütlerinden çıkarılan BG tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	84
Şekil 3.18. 24 sn zaman bölütlerinden çıkarılan HWHD tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si	85
Şekil 3.19. 24 sn zaman bölütlerinden çıkarılan İÖ ile 50 koşum sonucu ortalama eğitim ve test SD'si	86
Şekil 3.20. 24 sn zaman bölütlerinden çıkarılan özniteliklerinin sınıflandırılması ile 8 kişi için hesaplanan ortalama eğitim ve test SD'si radar grafikleri.....	87

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. Literatürde yer alan hibrit EEG+YKS çalışmaları	28
Tablo 2.1. Veri seti hakkında özet bilgi.....	35
Tablo 2.2. İkili sınıflandırma problemi hata matrisi.....	45
Tablo 2.3. Çok sınıflı sınıflandırma problemi hata matrisi	45
Tablo 3.1. 2.4 sn zaman bölütlerinden çıkarılan HD tabanlı özneliklerin sınıflandırılması ile elde edilen 8 kişinin ortalama test SD'si	63
Tablo 3.2. 2.4 sn zaman bölütlerinden çıkarılan BG, HWHD ve İÖ tabanlı özneliklerin k-EYK ile sınıflandırılması sonucu hesaplanan 8 kişinin ortalama test SD'si	64
Tablo 3.3. 2.4 sn'lik zaman bölütlerinin tek denemesi için öznelik çıkartma süresi	64
Tablo 3.4. 4.8 sn zaman bölütlerinden çıkarılan HD tabanlı özneliklerin sınıflandırılması ile elde edilen 8 kişinin ortalama test SD'si	72
Tablo 3.5. 4.8 sn zaman bölütlerinden çıkarılan BG, HWHD ve İÖ tabanlı özneliklerin DVM ile sınıflandırılması sonucu hesaplanan 8 kişinin ortalama test SD'si	72
Tablo 3.6. 12 sn zaman bölütlerinden çıkarılan BG tabanlı özneliklerin sınıflandırılması ile elde edilen 8 kişinin ortalama test SD'si	80
Tablo 3.7. 12 sn zaman bölütlerinden çıkarılan HD, HWHD ve İÖ tabanlı özneliklerden hesaplanan DVM sınıflandırıcı ile hesaplanan 8 kişinin ortalama test SD'si	80
Tablo 3.8. 24 sn zaman bölütlerinden çıkarılan BG tabanlı özneliklerin sınıflandırılması ile elde edilen 8 kişinin ortalama test SD'si	82
Tablo 3.9. K1 için hata matrisi	88
Tablo 3.10. K2 için hata matrisi	89
Tablo 3.11. K3 için hata matrisi	89
Tablo 3.12. K4 için hata matrisi	90
Tablo 3.13. K5 için hata matrisi	90
Tablo 3.14. K6 için hata matrisi	91
Tablo 3.15. K7 için hata matrisi	91
Tablo 3.16. K8 için hata matrisi	92
Tablo 4.1. Literatürde yer alan çalışmaların önerilen metot ile kıyaslanması.....	97

SEMBOLLER DİZİNİ

ALS	Amyotrofik lateral skleroz
AZFD	Ayrık zamanlı Fourier dönüşümü
BBA	Beyin bilgisayar arayüzü
BG	Bant Gücü
BT	Bilgisayarlı tomografi
Cl^-	Klorür iyonu
Cm	Santimetre
DAA	Doğrusal ayırım analizi
DD	Dalgacık dönüşümü
DDGUP	Durağan durum görsel uyarılmış potansiyel
Deoxy/HbR	Karbondioksit taşıyan hemoglobin (deoksi-hemoglobin)
DVM	Destek vektör makinaları
ECoG	Elektrokortikografi
EEG	Elektroensefalografi
ERP	Olay ilişkili potansiyeller
FMRI	Fonksiyonel manyetik rezonans görüntüleme
FN	Yanlış negatifler
FP	Yanlış pozitifler
HD	Hilbert Dönüşümü
HFBS	Higuchi fraktal boyut spektrumu
HMM	Hidden markov modeli
HWHD	Hızlı Walsh-Hadamard Dönüşümü
HWHDK	Hızlı Walsh-Hadamard Dönüşümü Katsayıları
Hz	Hertz
İÖ	İstatiksel Öznitelikler
K^+	Potasyum iyonu
K1	Kişi 1
K2	Kişi 2
K3	Kişi 3
K4	Kişi 4

K5	Kiři 5
K6	Kiři 6
K7	Kiři 7
K8	Kiři 8
KAY	Karar aęacı yapısı
k-EYK	k-en yakın komřuluk algoritması
MA	Mental aritmetik
MEG	Magnetoensefalografi
MBL	Modifiye edilmiř Beer-Lambert yasası
MHH	Motor hareketi hayali
MRG	Manyetik rezonans grntleme
mm	Milimetre
msn	Milisaniye
MU	Motor uygulama
mV	Milivolt
Na ⁺	Sodyum iyonu
nm	Nanometre
OU	Ortak uzamsal rnt
Oxy/HbO	Oksijen tařıyan hemoglobin (oksi-hemoglobin)
Z	zbaęlanım
PET	Pozitron emisyon tomografi
ROA	Rastgele orman algoritması
SD	Sınıflandırma doęruluęu
sn	Saniye
SNR	Sinyal/grlt oranı
SPECT	Tek foton emisyon bilgisayarlı tomografi
TMS	Transkranial manyetik uyarım
TN	Gerek negatifler
TP	Gerek pozitifler
μV	Mikro volt
WHD	Walsh-Hadamard Dnřm
YKS	Yakın kızıltesi spektroskopisi

1. GENEL BİLGİLER

1.1. Giriş

İnsan toplumunun temel özelliği iletişim veya sosyal temastır. Bu özellik, insanların birbirleriyle duygu, arzu ve yenilikçi fikir alışverişinde bulunarak iletişim kurmalarını sağlar (Värbu vd., 2022) (Arpaia vd., 2022). Bu iletişim ses, jest veya yazı ile oluşturulduğunda, insan iletişimi daha basit ve daha az kısıtlı hale gelir. Motor nöronlarında sıkıntı olmayıp hiçbir kasını hareket ettiremeyen örneğin ALS (Amyotrofik Lateral Skleroz) hastası kişiler ise yukarıda bahsedilen iletişim ve sosyal temas fırsatlarına sahip olmayabilir. Bu kişilerin başkalarıyla iletişim kurması neredeyse imkânsız olduğundan, beyin bilgisayar arayüzü (BBA) sistemleri bu tür kişilerin çevre ile iletişim kurmasına olanak sağlar. BBA, genel ifadesi ile beyin ile dış bir cihaz arasındaki doğrudan iletişim yoludur. BBA uygulamaları başlangıçta motor nöronlarında sıkıntı olmayıp hiçbir kasını hareket ettiremeyen kişilerin iletişim kurabilmelerine, bilgisayarları kontrol edebilmelerine ve tekerlekli sandalye veya robotik kollar gibi yardımcı ekipmanları kullanabilmelerine yardımcı olmak için geliştirilmiştir (Abiri vd., 2019) (Torres vd., 2020) (Tibrewal vd., 2022). Daha sonrasında ise bilimsel çalışmaların gelişmesi ile BBA uygulamaları eğlence, sanat ve diğer bazı alanlarda da gerçekleştirilerek tıp dışı alanlardan farklı alanlarda da yer almaya başlamıştır.

BBA'lar elektroensefalografi (EEG), yakın kızılötesi spektroskopisi (YKS), elektrokortikografi (ECoG), magnetoensefalografi (MEG), fonksiyonel manyetik görüntüleme ve pozitron emisyon tomografisi gibi çeşitli beyin aktivitesini ölçen cihazlardan alınan sinyalleri giriş olarak kullanabilir (Paul vd., 2021). Nöral aktiviteyi kaydetmeye yarayan bu yöntemlerin kendilerine özgü avantaj ve dezavantajları vardır. Örneğin, ECoG çok iyi derecede sinyal-gürültü oranına sahiptir ve uzun dönem kullanımlar için uygun iken, bu yöntem acı verici ve mikro elektrotların yerleştirilme işlemlerinden dolayı bazı ciddi riskler içermektedir. Diğer taraftan EEG acı vermeyen, yüksek uzamsal çözünürlüğe sahip ve düşük kurulum maliyetine sahip iken, bu işaretler şebeke gürültüsü ve vücut hareketleri gibi harici ve dahili birçok gürültü kaynaklarından kolayca etkilenebilmektedir (Akila vd., 2020). Ancak, EEG'nin aksine, YYS, vücut hareketlerine ve elektrikli ürünlere karşı göreceli sağlamlık avantajına sahiptir. Bununla birlikte, YYS'nin en büyük dezavantajlarından birisinin de düşük nüfus etme (penetrasyon) derinliği olduğu söylenebilir. Bu bakış açısına

dayanarak, birbirlerinin dezavantajlarını telafi eden çoklu sinyal kayıt yöntemlerinin birleştirilmesinin BBA sisteminin performansını artıracığı söylenebilir. EEG'nin diğer yöntemlere göre daha fazla avantaja sahip olmasından ötürü BBA çalışmaları yaygın olarak EEG tabanlıdır (Das vd., 2019). Ancak, sadece EEG kullanılarak BBA sistemlerinin performansının tatmin edici seviyelerde olmadığı literatürdeki araştırmalardan da anlaşılmaktadır. Bu da araştırmacıları beyin ile BBA'nın çıkış cihazı arasındaki iletişim sisteminin performansını artırmak için tüm bileşenlerinin hızını ve doğruluğunu arttırmaya motive etmektedir. Literatüre bakıldığında ise yapılan çalışmalarda ağırlıklı olarak kaydedilen veri kümesinin deney paradigmasına veya veri kümesine uygulanan matematiksel modele odaklanılmıştır (Hong vd., 2017). Bu tez çalışmasında ise literatürde yaygın kullanılan matematiksel modellere bağlı kalınarak deney paradigmasındaki özgünlük ile hibrit EEG+YKS tabanlı BBA sisteminin performansının artırılması amaçlanmıştır.

BBA türleri göz önüne alındığında literatürde son yıllarda motor hareketi hayali (MHH), P300 ve durağan durum görsel uyarılmış potansiyel (DDGUP) tabanlı sistemlere olan ilgi artmıştır (Abootalebi vd., 2009) (Xing vd., 2018). Bu sistemler, giriş işareti olarak yalnız EEG kullanması açısından avantajlı olsa da MHH tabanlı sistemlere bakıldığında BBA için iyi performansa ulaşılmamıştır. P300 ve DDGUP tabanlı sistemler de yine giriş işareti olarak yalnız EEG kullanması açısından ve minimum eğitime ihtiyaç olması bakımından avantajlıdır (Ditthapron vd., 2019). Bu sistemler ile yapılan çalışmalar ile literatürde kısmen etkin düzeylere ulaşılsa da zaman geçtikçe kullanıcı seyrek uyarıya alıştığı ve sistemi ezberlediği için uyaranlara karşı kullanıcının beyin tepkisi azalabilmektedir ve sonuç olarak sistemin performansı giderek düşebilmektedir (D. Vos vd., 2014). Tüm bunlar göz önüne alındığında hem deney içeriği hem de sinyal çeşidi türü açısından literatürde bir eksiklik vardır. Bu eksikliğin giderilmesi açısından bu tez çalışmasında yeni bir deney paradigmasını önerilmiştir. Bu yeni deney paradigması hibrit EEG+YKS veri kümesine uygulanmıştır. FHD-2020-9166 nolu Karadeniz Teknik Üniversitesi BAP projesi kapsamında destek alınarak hizmet alımı ile Atatürk Üniversitesi'nde dört sınıflı kayan yazı okumaya dayalı EEG+YKS veri kümesi kaydedilmiştir. Bu tez çalışmasında özgün deney paradigması içeren EEG+YKS tabanlı hibrit veri kümesinden çıkarılan öznitelikler sınıflandırılarak yüksek başarılı BBA sistemi oluşturulmuştur.

Veri kümesinden Hilbert Dönüşümü (HD) tabanlı öznitelikler çıkarılmış ardından öznitelikler k -en yakın komşu (k -EYK) algoritması ile sınıflandırılarak yüksek performanslı bir hibrit BBA sistemi önerilmiştir. Ayrıca, önerilen yöntem EEG+deoksijenli hemoglobin


(Deoxy), EEG+oksijenlenli hemoglobin (Oxy), EEG, Deoxy ve Oxy modalitelerinin hepsine ayrı ayrı uygulanarak sonuçların kıyaslaması yapılmıştır. Ayrıca, bu çalışmada önerilen yöntemler MATLAB 2020’de programlanmıştır. Elde edilen sonuçlar literatürdeki çalışmalarla ve literatürde yaygın farklı öznelik ve sınıflandırıcılar ile karşılaştırılarak tezde kullanılan yöntemlerin başarımı değerlendirilmiştir. Ulaşılan sonuçlar, bu tez çalışmasında önerilen kayan yazı okumaya dayalı deney paradigmasının mevcut yöntemler odağında EEG+YKS tabanlı BBA performansına yüksek oranda katkı sağlandığını göstermektedir.

1.2. Beynin Temel Yapısı

Beyin, sinir sistemimizin faaliyetlerini yöneten, kafatası içinde yer alan bir organdır. Karmaşık bir yapıya sahip olan bu organ merkezi sinir sisteminin önemli bir parçasıdır. Kafatası boşluğunun ön ve üst bölgesinde bulunur. Beyin hem fiziksel hem de immünolojik olarak koruyucu beyin omurilik sıvısı adı verilen berrak bir sıvı içinde yüzer. Beyin yaklaşık olarak 1300–1400 gram ağırlığındadır ve hareket, düşünce, konuşma gibi tüm fonksiyonların merkezi konumundadır. Beyin, darbe sırasında kafatasını koruyan meninks adı verilen zarlarla kaplıdır ve başlıca glial hücreler ile nöronlardan oluşan 100 milyar sinir hücresine sahip olduğu tahmin edilmektedir (McFarland vd., 2017) (Genon vd., 2018).

1.2.1. Beynin Bölümleri ve Görevleri

Beyin anatomisi dikkate alındığında sol-sağ ve üst-orta beyin yapıları en genel çerçevede ele alınabilir. Beyin anatomik olarak katmanlıdır. Orta beyin bölgesi limbik sistemdir ve burası hipotalamus, talamus ve hipokampusu içerir (Wise vd., 1999) (Andrew vd., 1996). Beynimiz sağ ve sol olarak adlandırılan iki yarım küreden oluşur. Sol beyin temel olarak bilişsel görevleri, algıyı, düşüncelerin ifadesini, kavramayı, mantıksal yeteneği ve konuşmayı gerçekleştirir. Sağ beyin ise, ifade kapasitesi ve sözel olmayan yüzleri tanıma kapasitesi üzerinde etkiye sahiptir. Bu iki yarı küre arasındaki iletişimi corpus callosum lifleri sağlamaktadır. Yoğun nöral yapıya sahip corpus callosum, beyin sağ ve sol lobları arasında bilgi alışverişinde bulunan bir güç köprüsü görevi görmektedir (Blasi vd., 2006). Frontal, temporal, parietal ve oksipital olmak üzere dört bölümden oluşan beyin görüntüsü Şekil 1.1’de verilmiştir.



Şekil 1. 1. Beynin bölümleri

1) Frontal Lob: Beynin ön kısmında Şekil 1.1’de 1 numaralı alanda yer alan bu lob, serebral korteksin tüm yüzeyinin üçte biri kadardır. Bu lob, duygusal düzenleme, kişilik ve sosyal etkileşim gibi çeşitli işlevlerde yer alır. İnsan davranışı için gerekli olan zor kararlar ve etkileşimler için gereklidir. Ayrıca, ön lob ahlaki yargıların merkezidir. Bu lob, prefrontal bölge, motor korteks ve broca alanından oluşur (Rypma vd., 1999).


2) Temporal Lob: Kortekste lateral fissür adı verilen yarığın altında, kulağa yakın bölgede Şekil 1.1’de 2 numaralı alanda bulunan lobdur. İşitme, dili anlama, görsel hafıza, duygusal ilişkilendirme ve diğer birçok işlevden sorumlu bir bölgedir. Bu lobun lezyonları vücudun tüm fonksiyonlarını etkileyebilir ve bozabilir (Fonseca vd., 2009).

3) Parietal Lob: Başın orta kısmında tepede, frontal lobun hemen arkasında ve oksipital ile temporal lobların yukarısında Şekil 1.1’de 3 numaralı alanda yer alan lobdur. Görme, koku alma, dokunma ve duyma gibi algı ve duyularda önemli bir rol oynar (Sack, 2009). Bu lob, vücut duyusal sinyallerinin yorumlandığı birincil duyusal alandır.

4) Oksipital Lob: Görsel uyaranların işlenmesinde önemli rol alan bu lob serebral korteksin hemen arkasında Şekil 1.1’de 4 numaralı alanda yer alır. Dış dünyadan gelen ışık gözün arkasında yer alan retina tarafından algılanır ve daha sonra ışık enerjisi sinir iletim sinyallerine dönüştürülür (Weinberger vd., 1982). Daha sonra, bu sinyaller oksipital loba iletilir ve burada görsel ve yorumlama sağlanır.

1.2.2. İnsan Beyninin Çalışma Prensibi

Nöronlar, nörotransmitterler adı verilen kimyasal haberciler aracılığıyla birbirleriyle arasında iletişim kurabilen milyarlarca sayıdaki beyin hücreleridir. Nöronlar, kendi aralarında sinaptik iletim adı verilen bir mekanizma aracılığıyla konuşurlar ve beyin çalışması sağlanır. Bir mesaj, bir nörondan diğerine milisaniyeler (msn) içinde iletilir. Bir nöron, diğer nöronlarla veya bir kas hücresiyle sinapsta iletişim kurar. Nöronun temel yapısı Şekil 1.2’de verilmiştir. Şekil 1.2’de 1 numara nöronun merkez parçası olan çekirdeği ifade eder ve bu kısım hücrelerin enerji üretmekten sorumlu kısmıdır. Hücre gövdesinde yer alan dendrit olarak bilinen 2 numaralı kısım ise küçük dallardan oluşmaktadır. 3 numara içinde çekirdekleri bulunduran hücre gövdesini ifade etmektedir. Burası moleküllerin üretildiği, nöronun en önemli hayati aktivitelerinin yapıldığı kısımdır. Nöronun gelişimine ve büyümesine yardımcı olan 4 numaralı kısım schwann hücresini göstermektedir. Periferal sinir sisteminde bulunan bu hücreler dallar veya aksonları kaplar ve bir yalıtkan zar gibi davranırlar. 5 numaralı kısım schwann hücrelerinden oluşan miyelini ifade etmektedir. Bu kısım protein ve lipidlerden oluşan bir maddedir. 6. kısım akson ucunu ifade etmektedir. Akson ucu, nöronda bulunur ve işlevi diğer nöronları birbirine bağlamaktır. 7 numaralı kısım ranvier düğümü olarak ifade edilir. Bu kısım akson uzantılarının her bir miyelin kılıfının arasındaki aralık ya da boşluktur. Akson, nöronun bir başka ana parçasıdır ve bu kısım 8 numara ile gösterilmiştir. Bu kısım elektrik sinyallerinin beyin hücreleri arasında iletilmesinden sorumlu olan ince bir sinir lifidir (Nicholls vd., 2001) (Sidiropoulou vd., 2006) (Kverková vd., 2022).



Şekil 1.2. Sinir hücresi


1.2.3. Nöronlarda Elektrokimyasal İletim

Günlük hayatımızda var olan ve kullanılan elektrik tellerinden farklı olarak nöronlar kimyasal elektrik iletimini gerçekleştirirler. Yalıtkan tel içerisinde elektronlar, oluşan voltaj farkından dolayı bir yönden diğerine akmaya zorlanırken nöronlarda durum farklıdır. Nöronlarda sadece bazı bölgelerde oluşan voltaj farkı ile akım farklı yönlerde akar. Bu akma sırasında akımın hemen önündeki alanda hızla bir voltaj farkı yani aksiyon potansiyeli oluşur ve akımın ilerlemesine olanak tanır. Aksiyon potansiyeli iletildikten sonra hücrede voltaj farkı orijinal seviyesine geri döner (Freeman, 2003) (Orihara, 1952). Potansiyel bu şekilde hücreden hücreye aktarılır.

Normal şartlar altında, bir nöron uyarılmadığı takdirde hücre zarının belirli bir potansiyel farkı vardır. Bu hücre içi ile yani zarın bir tarafıyla hücre dışı yani diğer tarafı arasında bir potansiyel farkı olduğu anlamına gelmektedir. Bu farkın nedeni, hücre içindeki iyon olarak bilinen elektrik yüklü parçacıklar ve hücre dışındaki iyonların sayısındaki farktan kaynaklanmaktadır. Nöronların dış ortamında esas olarak yüksek miktarda sodyum iyonları (Na^+) ve az miktarda negatif klorür iyonları (Cl^-) vardır. Bunun aksine hücrenin içinde proteinler, fosfatlar, potasyum iyonları (K^+) ve negatif yükler bulunur. Ancak iyonların genel dengesine incelendiğinde hücrenin içinin dinlenme halindeyken yani elektrik uyarısı olmadığında daha negatif yüklü, hücre dışının ise daha aktif olduğu yani enerjik olduğu görülmektedir. Yani hücre içinde negatif voltaj ve hücre dışında pozitif voltaj oluşturacak iyonların durumu belirtilmiştir. Bu durum, hücrenin içi ve dışı arasında potansiyel bir fark yaratır. Dış etkenlerden dolayı bu iyonların sayısı değişirse bu potansiyelin değeri de değişir. Normal şartlar altında bu potansiyel sabit kalır ve hücrenin kimyasal yapısı voltaja bağlı iyon kanalları adı verilen hücre zarında yer alan proteinler tarafından korunur. Yani, bu kanallar sadece voltaj değişikliklerinin etkisi altında açılır. Hücre zarı uyarıldığında burada bir potansiyel farkı oluşur. Bu durumda, hücre zarındaki kimyasal aktivite nedeniyle elektrik sinyalleri üretilir (Nunez, 1974) (Vishwakarma vd., 2020). Bu elektrik sinyalinin oluşumuna aksiyon potansiyeli denir. Aksiyon potansiyeli evreleri genel olarak Şekil 1.3'te gösterilmiştir.

Şekil 1.3'te görüldüğü gibi tek bir sinir dinlenme halindeyken hücre içi, hücre dışına göre 70 milivolt (mV) daha negatiftir. Bu yüzden hücre içi -70mV olarak gösterilir. Dinlenme süresince bu potansiyel hep korunur. Dinlenme potansiyelinde olan hücreye gelen bir uyarı ile Na^+ kapıları açılır. Ardından, depolarizasyon olarak ifade edilen bu kısımda

voltaja bağılı açılan Na^+ kapılarından hücre içine büyük miktarda Na^+ girer. Sonrasında Na^+ kapıları kapanır ve daha sonra voltaja bağılı K^+ kapıları açılır. Repolarizasyon başlangıcı olarak adlandırılan bu kısımda K^+ kapılarından hücre dışına K^+ çıkışı olur. Voltajın düşmesi ile K^+ kapıları kapanır.



Şekil 1.3. Aksiyon potansiyeli evreleri

1.2.4. Beyin ve Hemoglobin Konsantrasyonları

Bilim adamları, beyin aktif bölgelerinin fazla enerjiye ihtiyaç duymasından ötürü yüksek oranda oksijen ve glikoza ihtiyaç duyduğunu ifade etmektedir (Tran, 2020). Enerji alışverişi sırasında oksijen gereksinimi olduğundan hücreye enerji girdisi artar. Enerjiyi sağlayan kaynak ise kan dolaşımıdır. Aktif nöronların ihtiyaçlarını karşılamak için bu bölgelere daha fazla kan ulaştırılır. Beyin aktive olurken, aktif beyin hücrelerine kan hücum eder. Beyin çalışmasında esnasında beyindeki 'kanlanma' oranını takip eden ilk çalışma Angelo Mosso tarafından 1881 yılında yapılmıştır (Raichle ve Shepherd, 2014) (Zhong vd., 2021). Kan; dolaşım sisteminde dolaşarak organizmadaki tüm organlara ulaşır ve bu organlara metabolizma için gerekli besin ve oksijeni götürmektedir.

1.3. Beynin Nöral Aktivitesini Görüntüleme Teknikleri

Bilişsel işlev esnasında insan sinir sisteminin yapısının veya işlevinin doğrudan veya dolaylı yollarla incelenebilmesine beyin görüntüleme veya nörogörüntüleme denir (Bernal

vd., 2019) (Zhang vd., 2011). Beyin görüntüleme, yapısal ve işlevsel görüntüleme olmak üzere genel olarak iki kategoriye ayrılır. Yapısal görüntüleme teknikleri genellikle kafatası içerisinde yer alan büyük boyutlardaki hastalık veya sakatlıkların tespiti için kullanılır. İşlevsel görüntüleme teknikleri ise daha küçük boyutlardaki metabolik hastalıkların veya lezyonların tespit edilmesinde, bilişsel psikoloji araştırmalarında ve BBA geliştirmede kullanılır. Bilimsel çalışmalarda günümüzde sıklıkla kullanılan görüntüleme teknikleri ise fonksiyonel manyetik rezonans görüntüleme (fMRI), tek foton emisyon bilgisayarlı tomografi (SPECT), bilgisayarlı tomografi (BT), olay ilişkili potansiyeller (ERP), YKS, transkranyal manyetik uyarım (TMS), pozitron emisyon tomografi (PET), MEG, ECoG ve EEG'dir. Nöral aktiviteyi kaydetmeye yarayan bu yöntemlerin kendilerine özgü avantaj ve dezavantajları vardır. Bunlar arasında fMRI, kandaki oksijen bağlı hemoglobin ile oksijensiz hemoglobinin manyetik özelliklerindeki farklılığa bağlı beyin görüntülemesi gerçekleştirmektedir. Bu görüntüleme tekniğinin en büyük dezavantajı vücudunda protez, implant gibi metalik objeler bulunan kişilerde uygulanma durumudur. Bu objelerden yayılan manyetik rezonans, tıbbi cihazların bozulmasına ve vücuda başka metallerin gelmesine neden olabilmektedir. BT, vücudun farklı açılarından alınmış çok sayıdaki radyografilerini bilgisayara aktararak görüntüleme sağlayan bir tekniktir. Bu tekniğin en büyük dezavantajı ise kişileri yüksek miktarda radyasyona mazur bırakmaktadır (Loos vd., 2022) (Yasmin vd., 2012). Beyinde metabolizmaya katılan moleküllere yabancı bir madde eklenir ve ardından moleküllerden yayılan pozitronlar PET görüntülerinin oluşmasını sağlar. Bu teknik zamansal çözünürlüğü bakımından ve çoğu tıbbi ortamda kolayca bulunamadığından diğer görüntüleme tekniklerine göre dezavantajlıdır. SPECT de ise beyin kan akımının bölgesel olarak inceleyerek görüntüleme gerçekleştirmektedir. Kafaya yerleştirilen bir çubuk ile manyetik yükün beyinde belli bir alana doğru yönlenmesi sayesinde beyinde gerçekleşen elektriksel faaliyetlerdeki değişim ise TMS tekniği ile ölçülür. Yine bu teknik için manyetik enerji kullandığından başlarında ve boynunda metal bulunan kişiler için uygun olmayan bir tekniktir. Beynin işlevsel görüntüsünü elde etmeyi sağlayan MEG ise hem pahalı oluşu hem de kişilerin radyasyona maruz bırakılması açısından dezavantajlıdır. ECoG ise çok iyi derecede sinyal-gürültü oranına sahiptir ve uzun dönem kullanımlar için uygun iken, bu yöntem acı verici ve miktoelektrotların yerleştirilme işlemlerinden dolayı bazı ciddi riskler içermektedir. Diğer taraftan EEG acı vermeyen, yüksek uzamsal çözünürlüğe sahip ve düşük kurulum maliyetine sahip iken, bu işaretler şebeke gürültüsü ve vücut hareketleri gibi harici ve dahili birçok gürültü kaynaklarından kolayca etkilenebilmektedir. Ancak, EEG'nin


aksine, YKS, vücut hareketlerine ve elektrikli ürünlere karşı göreceli sağlamlık avantajına sahiptir. Bununla birlikte, YKS'nin en büyük dezavantajlarından birisinin de düşük nüfus etme (penetrasyon) derinliği olduğu söylenebilir (Tasci ve Tasci, 2022) (Vankdothu vd., 2022).

1.3.1. Elektroensefalografi Özellikleri

EEG, kafa derisine yerleştirilen elektrotlar kullanılarak beyin tarafından üretilen elektriksel değişimlerin kaydedilmesi ve yorumlanmasına dayalı beyin görüntüleme tekniğidir (Azilinson vd., 2023). EEG, kafa derisine göre aynı radyal oryantasyona sahip binlerce nöron tarafından üretilen post-sinaptik potansiyellerin toplamını ölçer. İlk ölçümler Hans Berger tarafından bir insan denek üzerinde yapılmıştır (Zang vd., 2023). Yapılan deneyler için sonuçlar ise ilk olarak 1929'da yayınlanmıştır. Günümüzde, beyin aktivitesini bozan hastalığın, tümörlerin, beyin lezyonlarının ve epileptik durumların tanısında EEG yöntemi kullanılmaktadır. Bu yöntemde dışardan herhangi bir elektriksel uyarım yapılmadığı için kişi acı hissetmez. Buna ek olarak bu tekniğin zamansal çözünürlüğü oldukça yüksektir. EEG sinyallerinin genliği 0-400 mikro volt (μV) ve frekansı ise yaklaşık olarak 1-50 Hertz (Hz) arasındadır. Çok zayıf bir genliğe sahip olduğu için bu sinyalleri sayısallaştırmadan ve işlemeyen önce güçlü bir şekilde yükseltmek gerekir. Tipik olarak, EEG sinyal ölçümleri, 1 ila yaklaşık 256 arasında değişen sayıda elektrot kullanılarak gerçekleştirilir, bu elektrotlar genellikle elastik bir kapak kullanılarak takılır. Elektrotlar ve cilt arasındaki temas genellikle iletken bir jel veya macun kullanılarak artırılır. Bu durum, elektrot montaj prosedürünü genellikle sıkıcı ve uzun bir operasyon haline getirir. BBA araştırmacıları son yıllarda BBA için kuru elektrotlar, yani kullanım için iletken jeller veya macunlar gerektirmeyen elektrotlar önermektedir (Rajinikanth vd., 2022).

Elektrotlar genellikle standart bir modele, yani 10-20 uluslararası sistemine göre yerleştirilir ve adlandırılır (Roy vd., 2022). Bu sistem başlangıçta 19 elektrot için tasarlanmıştır, ancak daha fazla sayıda elektrotla başa çıkmak için genişletilmiş versiyonlar önerilmiştir. Amerikan Elektroensefalografi Derneği tarafından standardize edilen bu elektrot yerleşimi elektrot konumunu tanımlamak için kafada iki adet referans noktası kullanır. Şekil 1.4'te genel görüldüğü gibi burnun üst kısmında gözler ile aynı seviyede olan nasion bu referans noktalarından birincisidir. Kafatasının tabanında kemikli yumruda bulunan diğer referans noktası ise inyon olarak adlandırılır. Boyuna ve enine düzlemlerin

kafatasını bu noktalardan ayırmasıyla %10 ve %20 aralıklarla belirlenen düzlem aralıklarına elektrotlar yerleştirilir. Şekil 1.4'te yer alan P, F ve O sırasıyla Parietal, frontal ve oksipital bölgelerinin baş isimlerini ifade ederken A kulak memesini, C ise merkezi bölgeyi göstermektedir. EEG sinyalleri ritim adı verilen farklı salınımlardan oluşur. Bu ritimler, spektral lokalizasyon açısından farklı özelliklere sahiptir. EEG dalgaları frekans aralığına göre 6 klasik beyin ritmine sahiptir. Bunlar, Şekil 1.5'te görüldüğü gibi Delta, Teta, Alfa, Mu, Beta ve Gamma ritimlerdir.



Şekil 1.4. Kafa derisi üzerine 10-20 sistemine göre yerleştirilmiş EEG elektrotları (Roy vd., 2022)

Delta ritmi: 4 Hz ve altında frekansa sahip olan dalgaların EEG genlikleri 20 ile 400 μ V arasında değişmektedir. Derin olan rüyasız uyku ile ilgili olan bu dalgalar çocuklarda çok yaygındır. Yaşlandıkça, ürettiğimiz bu beyin dalgalarının daha azını elde ederiz (Siddharth vd., 2019).


Teta ritmi: 4 ile 7 Hz frekansı arasında yer alan dalgalardır. EEG genliği 5 ile 100 μ V arasında değişen bu dalgalar çoğunlukla hayal gücü, düşünme ve uyku ile ilgilidir (Ismail vd., 2019).

Alfa ritmi: 8 ile 12 Hz arasında frekansa, 2 ile 10 μ V arasında EEG genliğine sahip ritmik dalgalardır. Sağlıklı, uyanık bir yetişkinde kafatasının parietal ile oksipital lobundan kaydedilirler (Wang vd., 2019).

Mu ritmi: Motor ve sensorimotor kortekste yer alan 8-13 Hz frekans bandındaki salınımlardır. Bu ritmin genliği, özne hareketler yaptığında değişir. Bu ritim aynı zamanda sensorimotor olarak da bilinir (Han vd., 2018).

Beta ritmi: 13-30 Hz arasında frekansa sahip olan dalgalardır. Alfa bandındaki dalga genliklerine göre daha küçük genliğe sahip olan bu dalgaların EEG genlikleri 1 ile 5 μ V arasındadır. Sağlıklı, uyanık bir yetişkinde kafatasından kaydedilirler. Tam dikkatimizi verirken veya çok uyanıkken kaydedilen EEG dalgalarıdır (Hassib vd., 2012).

Gamma ritmi: Bu ritim esas olarak 30 Hz'nin üzerindeki frekanslarla ilgilidir. Bu ritim bazen 80 Hz veya 100 Hz civarında bir maksimum frekansa sahiptir. Çeşitli bilişsel ve motor işlevlerle ilişkilidir (Aydemir, 2017).



Şekil 1.5. EEG verileri için altı ana beyin ritmi

1.3.2. Yakın Kızılötesi Spektroskopi Özellikleri

Kızılötesi ışık, 1 mili metre (mm) ile 700 nano metre (nm) dalga boyu arasında yer alır ve elektromanyetik spektrumun görünür ışık ile mikrodalga bölgeleri arasında bulunur.

İnsan gözü ile görünemeyen bu ışığın dalga boyu görünür ışıktan daha uzundur. Işığın bir kısmı dokular tarafından tutulurken, bir kısmı dokular tarafından geçirilir. Bu durum, dokunun ve ışığın özelliklerine bağlıdır. Kızılötesine yakın ışık, görünür ışığa göre dokuya daha iyi nüfuz eder (Okamoto vd., 2004).


YKS, nörogörüntüleme amacıyla yakın kızılötesi spektroskopisi kullanan optik bir beyin izleme tekniğidir (Sharma vd., 2018) (Tai ve Chau, 2009). Bu teknik ile beyin aktivitesi, nöral aktiviteye yanıt olarak meydana gelen kortikal hemodinamik aktivite, yakın kızılötesi ışık kullanılarak ölçülür. Beyinde bir işlem esnasında dokuda oluşan etkinliği topografik olarak ölçen bu yöntem, doğrudan dokuyu ölçmez. Dokuda bir işlem meydana geldiğinde buradaki enerji gereksinimi artacağından dokuya oksijen ve glikoz takviyesi yapılacaktır. Bu takviye sağlanırken dokudaki kan hacminin büyümesi ile burada oksijen taşıyan hemoglobin (oksi-hemoglobin) miktarında artış olacaktır. Aksine, karbondioksit taşıyan hemoglobin (deoksi-hemoglobin) miktarında ise bir azalma olacaktır. Bu yüzden beyin çalışması esnasında hemoglobin konsantrasyonundaki bu değişiklikler beyinde meydana gelen çalışma durumunu ifade etmektedir.

YKS, hemoglobin konsantrasyonunu yakın kızılötesi ışığın emilimindeki değişikliklerden tahmin eder. Işık kafadan hareket ettikçe veya yayıldıkça, dönüşümlü olarak dağılır veya içinden geçtiği doku tarafından emilir. Hemoglobin, yakın kızılötesi ışığın önemli bir emicisi olduğundan, emilen ışıktaki değişiklikler, hemoglobin konsantrasyonundaki değişiklikleri güvenilir bir şekilde ölçmek için kullanılabilir. Farklı YKS teknikleri, kan hacmini ve oksijenlenmeyi tahmin etmek için ışığın yayılma şeklini de kullanabilir. Teknik güvenli, invaziv değildir ve diğer görüntüleme yöntemleriyle birlikte kullanılabilir (Power vd., 2012) (Chen vd., 2022).


Tipik olarak, ışık yayıcı ve dedektör, deneğin kafatasına ipsilateral olarak (her bir yayıcı / dedektör çifti aynı tarafta) yerleştirilir. YKS cihazı, dokuya lazer ışık yayıcıdan kızılötesine yakın 700-900 nm arası zayıf ışık gönderir (Ghosh vd., 2022). Bu ışık, kafatası, cilt ve beyin zarlarını da içine alan pratik olarak beyin korteksi olarak bilinen kafa derisinin 3 cm kadar derinliğe iner. Daha sonra ışınlar doku içinde yaya benzeyen eliptik yolları izleyerek geri saçılım yapar. Yani ışığın bir kısmı geri yansır. Geri yansıyan bu ışık dedektörler vasıtası ile toplanır. Gönderilen ve yansıyan ışığın emilme miktarları ışık yayıcı ve dedektörlerde incelenir. İncelemeler sonucunda deoksi-hemoglobin ve oksihemoglobin ile toplam kan hacmi değişiklikleri emilme miktarı ölçülerek YKS sinyalleri kaydedilir. 700 nm ile 900 nm arasındaki yakın kızılötesi dalga boyları için oksijenli hemoglobin

(Oxy/HbO) ve deoksijenli hemoglobin (Deoxy/HbR) absorpsiyon spektrumları Şekil 1.6'da gösterilmiştir.

Şekil 1.7'de hemoglobin konsantrasyonlarının emilme ve saçılma yöntemiyle elde edilmesi gösterilmiştir. Burada ışık yayıcıdan gelen kızılötesi ışık dokuyla temas ederek dedektör yardımıyla kanallara veri sağlamaktadır, Burada görüldüğü gibi dedektör ile ışık yayıcı arasında veri alımı sırasında yay şeklinde bir görüntü oluşmaktadır.



Şekil 1.6. Optik penceredeki emilme spektrumu (Merve vd., 2012)



Şekil 1.7. Hemoglobin konsantrasyonlarının elde edilmesi

YKS'nin nasıl çalıştığına baktığımızda, hemoglobin konsantrasyonundaki değişiklikleri ölçmek için, doku boyunca yayılan bir ışık örüntüsü gerekir. Tüm fotonların yer değiştirmesi teorisi olarak bilinen modifiye edilmiş Beer-Lambert (MBL) yasası, ışığın soğurulmasını içinden geçtiği malzemenin özelliklerine bağlar. 730 nm ve 850 nm dalga boylarındaki emilme ve saçılma ölçümleri, kromofor bağımlı konsantrasyonların değişimi sonucu hesaplanır. Emici türlerin sönme katsayısı ve saçılan ışığın yol uzunluk ölçüsü temelinde elde edilen denklem ile YKS hemoglobin konsantrasyonları değişimi bu yasaya uygun olarak ölçülür. Bu yasanın genel ifadesi Denklem 1.1'de verilmiştir. Bu yasa ile HbO, Hb için hemoglobin değişimi elde edilmektedir. Burada $i = 1, 2$, için $\Delta B(t, \lambda_i)$, λ_i dalga boyundaki bir emitörün optik yoğunluk varyasyonudur. $\beta_{HbO}(\lambda_i)$, Oxy ve Deoxy'nin sönüm katsayısıdır. du , emitör ve dedektör arasındaki diferansiyel yol uzunluğu faktörü, y ise bunlar arasındaki mesafedir.


$$\begin{bmatrix} \Delta c_{HbO}(t) \\ \Delta c_{HbR}(t) \end{bmatrix} = \frac{1}{y \times du} \begin{bmatrix} \beta_{HbO}(\lambda_1) & \beta_{HbR}(\lambda_1) \\ \beta_{HbO}(\lambda_2) & \beta_{HbR}(\lambda_2) \end{bmatrix}^{-1} \begin{bmatrix} \Delta B(t, \lambda_1) \\ \Delta B(t, \lambda_2) \end{bmatrix} \quad (1.1)$$

Bu yöntemin diğer nörogörüntüleme yöntemlerine göre çeşitli avantajları vardır. Kişiye çok az kısıtlama getirmesinin yanında kullanılan ışık radyoaktif değildir ve yöntem zararsızdır. Herhangi bir hareket esnasında iken, otururken veya konuşurken kişilerden YKS kaydı yapılabilir. Bu nedenle ölçümler, kayıt sırasında sabit olunması gereken EEG ve fMRI yöntemlerine göre daha doğal koşullarda alınmaktadır. Ölçüm alınan kişilerde kalp pili veya protez olmasında sakınca yoktur ve ölçüm sırasında her türlü görsel veya işitsel uyaran yer alabilir. Diğer yöntemlerle (EEG, fMRI ve MEG gibi) eş zamanlı ölçüm imkânı sunar. Bu yöntemin ana dezavantajı ise derin beyin dokusunu görüntüleyememesi, yalnızca kortikal görüntülemeye imkân vermesidir. Yaklaşık 20 yıldır kullanılan bu yöntem son teknolojik gelişmeler sayesinde giderek daha kullanışlı hale gelmiştir (Petrantonakis vd., 2018).

1.4. Beyin Bilgisayar Arayüzü

Beyin bilgisayar Arayüzü, beyin aktivitesi aracılığıyla kullanıcıların bilgisayarlar ile etkileşime girmesine izin veren sistemlerdir. BBA sisteminde, kaydedilen beyin sinyalleri istenen görevleri tamamlamak için bir bilgisayar sistemine gönderilir (Ergün ve Aydemir, 2020a). Gönderilen sinyaller, bu sistemlerde nesnelerin kontrollü veya düşüncelerin ifadesi

için kullanılır. 1970’li yıllarda BBA alanındaki ilk araştırma Kaliforniya Üniversitesi’nde Ulusal Bilim Vakfı ve DARPA programından sağlanan fonlarla başlamıştır (Zhang vd., 2019). Bu çalışmaların ardından yayınlanan makalelerle BBA terimi ilk defa bilimsel literatüre girmiştir. İnsan beyniyle dış dünya arasında iletişim köprüsü görevi olan BBA’ların literatürde kullanımı sonraki yıllarda birçok alan için devam etmiştir. BBA’lar kullanım amacına göre iki temel kategoriye ayrılabilir. Bunlardan ilki tıbbi alan uygulama kategorisidir. Bu sistemler, engelli kullanıcıları, ALS, serebral felç, felç veya omurilik yaralanması gibi nöromüsküler bozukluklara sahip hastaları günlük ve profesyonel hayatta desteklemek için kullanılmaktadır (Aydemir ve Ergün, 2019) (İsa vd., 2019). BBA temelli protezler ayrıca, hastaların normal fonksiyonlarını geri kazanmalarına olanak sağlayabilmektedir. Dahası beyindeki yapısal anormallikleri, sara gibi nöbetleri, zihinsel durum izleme işlevi, uyku bozukluklarının bulunması ve teşhis edilmesi ve diğer hastalıkları tespit etmeye yardımcı olabilmektedir. İkinci kategori ise tıbbi olmayan alandadır. BBA’lar yukarıda bahsedildiği gibi öncelikle engelli insanlara yönelik olmakla birlikte, sağlıklı insanlara da yardım sağlayabilir. Akıllı evler veya işyerleri gibi alanlarda da insanların günlük yaşamlarına daha fazla güvenlik, lüks ve fizyolojik kontrol sağlamak için bu sistemlerden faydalanılır. Ayrıca video oyunları veya multimedya alanlarında yer alan uygulamaları ile kişilere etkileşim aracı olma olanağı sunmaktadır. Tüm bunlara ek olarak, konuşmaya gerek kalmadan herhangi biriyle telepatik tipte iletişim kurmaya olanak sağlayabilir (Tiwari vd., 2021) (Hramov vd., 2021). Örnek bir BBA sisteminin genel yapısı Şekil 1.8’de verilmiştir. Şekil 1.8’de görüldüğü gibi beyin sinyalleri alınır ve sonrasında bu sinyaller analiz edilir. Son olarak, analiz edilen sinyaller istenen eylemleri gerçekleştiren çıktı aygıtlarına iletilerek komutlara çevrilir. Özellikle, bilişsel işlevlerinde sıkıntı olmayan sadece motor nöronları bozuk olan hastaların hayatlarını kolaylaştıran bu sistemler 1- BBA’nın giriş işaretinin elde edilme yöntemi, 2- ön işleme, 3-öznitelik çıkarma yöntemi, 4- karar verme aşamasında kullanılacak sınıflandırma yöntemi ve 5- kontrol çıktısı aşamalarından oluşmaktadır.



Şekil 1.8. Beyin bilgisayar arayüzü temel bileşenleri

1.4.1. BBA'nın Giriş İşaretinin Elde Edilme Yöntemi

Bu bileşen beyin aktivitesinin hangi yolla elde edileceğini açıklamaktadır. Beyin aktivitelerini ölçmek için kullanılan teknoloji, invaziv ve invaziv olmayan olmak üzere iki ana kategoriye ayrılabilir. İnvaziv BBA, beyin cerrahisi ile doğrudan beyne veya beyin yüzeyine entegre edilir. İnvaziv BBA'ların bir örneği elektrokortikografi'dir. Buna karşılık, invaziv olmayan BBA, bir kullanıcının kafa derisinden beyin aktivitesini tarar. Günümüzde invaziv olmayan BBA uygulamaları için EEG, tek hücre kayıtlamaları, fMRI, bölgesel alan potansiyelleri, YKS, elektrokortigografi, magnetoensefalografi gibi teknikler kullanılmaktadır (Ergün ve Aydemir, 2018b). EEG bu teknikler içerisinde ucuz, uzamsal çözünürlüğü yüksek ve hızlı erişilebilir olması bakımından günümüze kadar sıklıkla tercih edilmiştir (Ochoa vd., 2022). EEG'nin önemli bir dezavantajı genlikleri μV 'lar mertebesinde olduğundan çevresel ve kişisel hareketlerden (istemli ve istemsiz kas hareketleri) kolaylıkla etkilenebilirler. EEG'den farklı olarak YKS, vücut hareketlerinden ve ortam gürültüsünden minimum seviyede etkilenmesi açısından avantajlıdır. Ancak, de düşük nüfus etme derinliği açısından ise YKS dezavantajlıdır. Bunun gibi birbirlerinin dezavantajlarını telafi eden çoklu sinyal kayıt yöntemlerinin birleştirilmesinin BBA sisteminin performansını artıracığı söylenebilir (Ergün ve Aydemir, 2018a).

1.4.1.1. BBA İçin Düşünsel Görev


Bu bileşende düşünsel görev yaklaşımı iki şekilde olabilmektedir. Bunlardan birincisi direkt olarak geliştirilen uygulamaya yönelik düşünsel görevdir. Örneğin bilgisayar imlecinin yukarı/aşağı kontrolüne dayalı bir BBA uygulaması ise kişiden bilgisayar imlecini yukarı ya da aşağı hareket ettirdiğini hayal etmesi istenir (Kottaimalai vd., 2013). Bu tür yaklaşımlarda görev tanımları beynin aynı bölgesini aktive ettiği için işaretlerden öznitelik çıkarma işlemleri karmaşık, zaman alıcı ve daha zor olabilmektedir. Bundan dolayı araştırmacılar ikinci yaklaşım olan beynin farklı bölgelerini aktive edebilecek görev tanımları ile işaretleri kaydetmektedir. Örneğin; bir bilgisayar imlecinin yukarı/aşağı hareket ettirilmesine dayalı BBA uygulaması yapılacak ise kişiden sağ ayağını veya dilini hareket ettirdiğini düşünmesi istenmektedir (Sadiq vd., 2019). Bu düşüncelerden biri imlecini bir yön komutuna (örneğin yukarı hareketi) diğeri de diğer yön komutuna atanmak suretiyle BBA uygulaması gerçekleştirilebilmektedir. Bu ikinci yaklaşımda öznitelikler birinci yaklaşıma göre daha basit matematiksel yaklaşımlar ile elde edilebilmektedir. Bu da direkt olarak BBA uygulamasının hem hız hem de doğruluk açısından performansını arttırabilmektedir. BBA’larda düşünsel görevin kaydedilmesi beynin nöral aktivitesi açısından çoğunlukla 3 farklı paradigmaya ayrılmaktadır. Bu paradigmlar avantaj ve dezavantajları ile aşağıda detaylı olarak açıklanmaktadır.

1.4.1.1.1. Motor Hayaline Dayalı Beyin Bilgisayar Arayüzleri

Fiziksel hareket olmaksızın bir kolun veya bacağın hareket etmesinin hayal edilmesine motor hayali denir. Yapılan çalışmalar, bir kişi aynı MHH gerçekleştirdiğinde, beynin aynı nöral bağlantıları kullandığını göstermektedir. Bu açıdan bakıldığında, aynı motor hayaline dayalı nöral aktiviteler %100 benzer olmasa da temelde benzer kalıplar içerdiğini ve bu kalıpların dijital sinyal işleme ve yapay zeka algoritmaları tarafından tanınabileceğini söylenebilir. MHH dayalı BBA olarak tanımlanan bu sistemler protez bacaklar, robotik kollar ve harekete dayalı bilgisayar oyunu uygulamalarında yaygın olarak kullanılmaktadır. Sinirsel aktivite kalıplarının kişiden kişiye değişmesi bakımından dezavantaja sahip olsa da tamamen düşünce temelli olması bakımında ve ek bir cihaz gerektirmemesi bakımından avantajlıdır (Kumar vd., 2016) (Aggarwal ve Chugh, 2019).

1.4.1.1.2. P300 Sinyallerine Dayalı Beyin Bilgisayar Arayüzleri

P300 sinyali uyarandan yaklaşık 300 ms sonra meydana gelen ve uyarana yanıt olarak beyin tarafından üretilen fizyolojik bir sinyaldir (Aydemir vd., 2022). Bu sinyal oluştuğunda, EEG'de birkaç μV 'luk bir potansiyel değişim meydana gelmektedir. Literatürde bu duruma uyarılmış potansiyel veya P300 sinyali denilmektedir. Daha spesifik olarak, uyarın ne ise o duyu ile isimlendirme yapılmaktadır (Korkmaz ve Aydemir, 2022). Örneğin; Uyarın görme yoluyla geliyorsa görsel uyarılmış potansiyeller, işitme yoluyla geliyorsa işitsel uyarılmış potansiyeller olarak tanımlanır. Şekil 1.9'da EEG işareti için görsel uyarılmış potansiyel grafiği örnek olarak verilmiştir.



Şekil 1.9. EEG işaretlerinde ortaya çıkan örnek bir görsel uyarılmış potansiyel

Şekil 1.9'da kırmızı çizgi EEG işaretini ifade ederken, sarı düşey çizgi ise görsel uyarının geldiği anı ifade etmektedir. Şekilde görüldüğü gibi görsel uyarının gelmesinden yaklaşık 300 ms sonra işarete pozitif artış meydana gelmektedir. BBA sistemlerinde girdi işareti olarak kullanılan P300 sinyallerinin, bu sistemlerde pratik, hızlı olması, hecelelemeye dayalı sistemler için sık tercih edilmesini sağlamaktadır. Diğer bir önemli avantajı ise görsel uyarılmış potansiyeller için sadece oksipital bölgedeki nöral aktivitenin uygulama için yeterli olacağının bilinmesidir. P300 heceleyci, çok basit, güvenilir olduğu ve tatmin edici performans sağlayabildiği için insanların uzuvlarını hareket ettirmeden beyin aktiviteleri yoluyla bilgisayarları veya makineleri kontrol edebilmelerine olanak sağlayan en yaygın

kullanılan BBA uygulamalarından biridir (Korkmaz vd., 2022) (Bayliss vd., 2004). P300 heceleyicisine ait genel görsel Şekil 1.10'da verilmiştir. Burada görüldüğü gibi harfler ve karakterler bir matriste 2 boyutlu satır-sütun olacak şekilde yer alır (Guan vd., 2004). Heceleme sisteminde kullanıcıya sunulan ekrana paradigma denir.




Şekil 1.10. 4. Satır parlamada iken satır-sütun paradigması
(Guan vd., 2004)

Heceleme satır-sütun paradigmasında, kullanıcının odaklanmak istediği tüm harfler tek ekranda görüntülenir. Sonrasında her satır ve her sütun, dönüşümlü olarak her döngüde bir kez olacak şekilde rastgele yanıp söner. Buradaki amaç kullanıcıya sunulan alfabeden kullanıcının odaklandığı harfleri tespit etmektir. Kullanıcı istediği harf veya karakterin yanıp sönmesine her odaklandığında beyinde pozitif anlamda bir elektriksel yanıt oluşmaktadır. Bu yanıt ise yanıp sönme (uyaran) başladıktan yaklaşık 300 msn sonra P300 bileşeni olarak ortaya çıkar (Cecotti vd., 2010). Tek bir P300 denemesinden hedef karakteri tespit etmek zordur. Bu nedenle, her satır ve sütun genellikle birkaç kez yanıp söner. Bu da BBA sistemlerinde önemli bir faktör olan bilgi aktarım hızını azaltır (Fazel-Rezai, 2007) (Oralhan, 2019). Buna ek olarak, kullanıcının zamanla uyarını ve deney paradigmasını ezberlemesinden ötürü beynin tespit edilebilecek düzeyde bir P300 sinyali üretememesi de BBA sisteminin performansının düşmesine neden olmaktadır. Sonuç olarak, diğer BBA'lar gibi, P300 tabanlı BBA'lar da pratik kullanımı açısından hâlâ iyileştirmelere açıktır.

1.4.1.1.3. DDGUP'e Dayalı Beyin Bilgisayar Arayüzleri

DDGUP sinyalleri, görsel uyarım nedeniyle oksipital lobda gözlemlenebilen salınımlardır. Salınımların frekansları, stimülasyonun frekansları ile aynıdır ve pratikte daha çok 1-10 Hz arasında uyarın serisi kullanılır (Ortner vd., 2010) (Kwon vd., 2022). Kullanıcılar bir uyarana odaklandığında, karşılık gelen frekans bantlarındaki genlik artar. Bu gerçeği kullanarak, kullanıcının f , $2f$ veya $3f$ vb. frekanslı ekran bölümüne bakıp bakmadığını tespit etmek mümkündür. Bu amaç için literatürde çeşitli grafiksel arayüzler önerilmiştir. Şekil 1.11, basit bir DDGUP heceleyici biçimini göstermektedir. Bu örnekte r sembolü üç aşamada seçilmiştir. Her aşama, ekranda farklı titreşim frekanslarına sahip dört kutudan oluşur. Her aşamada denek r sembolünü içeren kutuya odaklanır. DDGUP'nin dezavantajı, devam eden diğer beyin aktivitelerine ve ayrıca gürültüye gömülü olduğundan, kayıt aralığı uzun olmalıdır. Başka bir sınırlaması ise, yalnızca belirli bir frekans aralığındaki titreşen frekansların makul bir DDGUP yanıtı uyandırmasıdır. Ticari kullanımlar için DDGUP tabanlı heceleyicilerin ileriye dönük çalışmalara ihtiyacı vardır (Shao vd., 2020) (Kelly vd., 2005) (Wang vd., 2016).



Şekil 1.11. DDGUP'e dayalı bir karakter seti örneği

1.4.2. BBA İçin Ön İşleme

Ön işleme adımının amacı, sinyalde istenen modellerin kalitesini iyileştirmek ve sinyal gürültü oranını (SNR) geliştirmektir. Ön işleme aynı zamanda istenmeyen sinyal gürültülerinin çıkarılmasını, 50 Hz güç hattı girişimi gibi elektriksel gürültüyü veya diğer istenmeyen sinyal özelliklerini gidermek için uygulanır (Ilyas vd., 2015) (Nakra ve Duhan., 2022). Örneğin BBA'lar için bilgilendirici EEG sinyalleri 30 Hz'nin altındaki frekanslarda bulunur. Bu nedenle, daha yüksek frekanslara sahip diğer tüm içerik, bir düşük geçiş filtresi kullanılarak kaldırılabilir. Buna ek olarak, sinyallerin uygulanacağı alana bağlı olarak, bant

geçiren filtreler kullanılarak belirli frekans bantları da seçilebilir. EEG sinyali, beyin sinyallerini bozan istenmeyen potansiyeller içerebilir. Bu sinyallere artefakt denir ve işleme adımından önce temizlenmelidir. Artefaktlar insan vücudunun dışından (fizyolojik olmayan) veya insan vücudunun içinden (fizyolojik) kaynaklanabilir. Birinci tip artefaktlar, kayıt ekipmanından kaynaklanabilir. İnsan vücudunda artefakta neden olabilecek bazı faaliyetler de vardır. Göz kırpması ve gözbebeği hareketinden kaynaklanan oküler ve vücut bölümlerinin hareketinden kaynaklanan kas, fizyolojik eserlerin iki ana grubudur. Artefaktlar bazı stratejilerle aza indirgenebilir. Deney esnasında gönüllü bireylerden hareket etmekten ve göz kırpmaktan kaçınmaları istenerek artefaktlardan kaçınılabilir. Artefaktlar ayrıca çevrimdışı uygulamalarda bir uzman tarafından belirlenebilir ve elemine edilebilir (Rithwik vd., 2022) (Aznan vd., 2013). Buna ek olarak sinyal işleme adımı sırasında artefaktların otomatik olarak belirlenebilir ve sinyalden temizlenebilir. BBA'nın çevrimiçi uygulaması nedeniyle, bu yaklaşım BBA çalışmaları için tercih edilen yöntemdir.

1.4.3. BBA İçin Öznitelik Çıkarma

Öznitelik çıkarma, farklı düşünce durumunda kaydedilen BBA işaretlerinin önemli özelliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir (Sun vd., 2014) (Chakladar vd., 2019) (Nisar vd., 2022). Örneğin BBA tekniğini kullanan bir tekerlekli sandalye kullanıcısı aracını geriye doğru hareket ettirmek istediğinde EEG sinyalinin nasıl bir örüntü oluşturduğu sorusuna cevabı bir öznitelik çıkarımıdır. Bu aşama, BBA sisteminde önemli ve kritik bir aşamadır. Çünkü çıkarılan özniteliklerin kalitesi, doğrudan sınıflandırıcı performansını ve dolayısıyla BBA'nın performansını etkiler. Bu aşamada araştırmacılar düşük boyutlu, basitçe hesaplanabilir ve yüksek sınıflandırma doğruluğu (SD) sağlayan öznitelik çıkarma yöntemleri arayışındadır.

1.4.4. Karar Verme Aşamasında Kullanılacak Sınıflandırma Yöntemi

Sınıflandırma, BBA işaretlerinden çıkarılan öznitelik vektörlerini dikkate alarak önceden belirlenmiş sınıflara atama işlemidir. Bu aşamanın sonunda kişinin ne düşündüğüne karar verilir. Etiket bilinmeyen işaretin hangi sınıfa ait olduğunu belirlemek hem hızlı hem de doğru olmalıdır. Literatürde sınıflandırma için birçok farklı algoritma kullanılmaktadır.

Bunlardan en sık kullanılanları destek vektör makineleri (DVM), *k*-EYK, doğrusal ayrım analizi (DAA) ve yapay sinir ağları gibi algoritmalarıdır (Jadhav vd., 2022) (Haltaş vd., 2019).

1.4.5. Kontrol Çıktısı

Sınıflandırma sonucuna göre gelen komutlar analiz edilir ve bu komutların çıktısına göre aygıt çalıştırılır. Komut sayısı BBA’de sınıf sayısını ifade eder. BBA’larda 2 sınıflı veya çok sınıflı kontrol çıktısına dayalı çalışmalar mevcuttur (Li vd., 2019). Bu çalışmalarda kontrol çıktısı olarak seçim çözme, tekerlekli sandalye kontrolü, robot kolu kullanımı, imlecin kontrolü veya harf seçimi gibi işlevleri gerçekleştirmek için uygun komutlar sağlanır (Chamola vd., 2020).

1.5. Literatür Araştırması

BBA’ların performansını arttırmak BBA bileşenlerinin en iyi şekilde oluşturulmasına bağlıdır. Bu amaçla literatürde farklı düşünsel görev tanımlı (mental aritmetik (MA) (Sammer vd., 2007) veya MHH’ye (Kayıkçıoğlu ve Aydemir, 2010) dayalı gibi), 2 sınıflı (Yavuz ve Aydemir, 2017) (Aydemir ve Kayıkçıoğlu, 2011), 3 sınıflı (Scherer vd., 2004) veya 4 sınıflı (Schlögl vd., 2005) EEG tabanlı BBA işaretlerini sınıflandırıcı çalışmalar mevcuttur. Araştırmacılar birbiri ile ilişkisiz düşünsel görevlerle daha ayırt edici sinyaller kaydetme ve işleme yoluna gitmektedir. MHH dayalı 4 sınıflı çalışmalar arasında Naeem ve arkadaşları sağ el, sol el, dil ve ayak hareketi hayaline dayalı verileri sınıflandırarak 8 kişi için ortalama %63.60 SD hesaplamışlardır (Naeem vd., 2006). Townsend ve arkadaşları yine sağ el, sol el, dil ve ayak hareketi hayaline dayalı veriler ile 4 kişi için ortalama %65.00 SD’ye ulaşmışlardır (Townsend vd., 2006). Aynı MHH dayalı bir başka EEG veri kümesi ile ise Lei ve arkadaşları 3 kişi için ortalama %63.00 SD hesaplamışlardır (Lei vd., 2009). Farklı zihinsel aritmetik tabanlı EEG işaretleri için sınıflandırma doğruluğunu artırıcı çalışmalar arasında ise Wang ve Sourina 10 kişiden kaydedilmiş 14 kanallı EEG veri kümesi ile çalışmışlardır. Burada veri kümesinden güç spektrum yoğunluğu, istatistiksel, ÖZ ve Higuchi fraktal boyut spektrumu (HFBS) tabanlı öznitelikler çıkartmışlardır. DVM kullanarak en iyi sonucu HFBS tabanlı özniteliklerle her bir kanal için %69.42 ile %84.15

arasında SD hesaplamışlardır (Wang ve Sourina, 2013). Li ve Zhang zihinsel aritmetik tabanlı EEG işaretlerinden ortak uzamsal örüntü (OUÖ) ve tensör ayırt edici analizi tabanlı öznitelikler çıkartmışlardır. Çıkarılan öznitelikleri DVM ile sınıflandırarak en iyi sonuçları tensör ayırt edici analizi ile 2 kişi için sırasıyla %85.00 ve %75.10 olarak hesaplamışlardır (Li ve Zhang, 2016). Zihinsel aritmetik tabanlı EEG işaretleri ile yapılan başka bir çalışmada ise, Anderson ve Sijercic 5 farklı zihinsel aritmetik için kaydedilen EEG işaretleri ile çalışmışlardır. Bu çalışmalarında işaretten ÖZ tabanlı öznitelikler çıkartarak bu öznitelikleri yapay sinir ağları ile sınıflandırmışlardır. 4 kişi için ortalama %38.00 ile %78.00 arasında SD'ye ulaşmışlardır (Anderson ve Sijercic, 1996).

EEG tabanlı bu çalışmalara ek olarak BBA sistemini kişilerin kavramasını artırmak için literatürde EEG kontrol sinyalleri olarak anılan nörofizyolojik sinyaller ile de çalışmalar yapılmıştır (Leoni vd., 2022). Bunlar arasında P300 ve DDGUP en yaygın kullanılanlardır. P300 sinyallerinin sınıflandırılması için yapılan çalışmalar arasından Chaurasiya ve arkadaşları kendi kaydettikleri heceleyici veri kümesinde DVM ile %94.20 SD hesaplamışlardır (Chaurasiya vd., 2016). Bir başka P300 tabanlı çalışmada Arican ve Polat BCI Yarışması III 2004 Veri Kümesi II ile yaptıkları çalışmada DVM en küçük kareler topluluğu ile %94.16 SD hesaplamışlardır (Arican ve Polat, 2019). Cortez ve arkadaşları heceleyici P300 tabanlı kaydettikleri başka bir çalışmada ise derin inanç ağları ile %91.60 SD'ye ulaşmışlardır (Cortez vd., 2020). DDGUP tabanlı çalışmalarda ise Cecotti ve arkadaşları yapay sinir ağlarını kullanarak %95.61 SD hesaplamışlardır (Cecotti vd., 2011). Bir başka çalışmada ise Nguyen ve arkadaşları ise DDGUP tabanlı heceleyici sistemi için DVM sınıflandırıcısını kullanarak %93.80 SD elde etmişlerdir (Nguyen vd., 2018). Başka bir DDGUP tabanlı heceleyici sisteminde ise Podmore ve arkadaşları derin yapay sinir ağları ile %86.00 SD'ye ulaşmışlardır (Podmore vd., 2019). DDGUP tabanlı BBA'lar, sinyal kararlılığı ve sinyal işleme karmaşıklığı açısından P300'e göre daha iyi olsa da bu iki BBA modelinin bazı dezavantajları vardır. Deney içeriği açısından katılımcının dış uyaranlara sürekli dikkat etmesi gerekir ve bazı kullanıcılarda yorgunluğa neden olabilir. Bu da BBA sisteminin performansını giderek azaltmaktadır.

Her ne kadar EEG tabanlı BBA'larda kısmen başarılı sonuçlar elde edilmiş olsa da özellikle pratik uygulamalarda EEG işaretlerinin elektromanyetik gürültüden, kişinin istemli (yutkunma, başını çevirmesi, dişlerini sıkması gibi) veya istemsiz (göz kırpması, kalp atışı gibi) yaptığı kas hareketlerinden kolayca etkilenebilmesinden ötürü BBA'ların performansı ciddi şekilde düşmektedir. Bu da araştırmacıları BBA'nın giriş işaretini farklı yollarla elde

edilmesi arayışına itmektedir. Literatürde bu arayışın bir sonucu olarak kişiye çok az kısıtlama getirmesi, kişinin yaptığı kas hareketlerinden EEG kadar etkilenmemesi ve yine acı vermeyen bir yöntem olması bakımından YKS yönteminin EEG ile kullanıldığı görülmektedir (Einalou vd., 2016) (Villringer vd., 1993).

YKS ile dokudaki oksî-hemoglobin ve deoksi-hemoglobin miktarı ile bunların konsantrasyonlarındaki değişim ölçülerek beynin elektriksel aktivitesi hakkında veri elde edilebilmektedir (Villringer vd., 1993). Literatürde şimdiye kadar farklı düşünsel görev tanımlı (mental aritmetik (Ang vd., 2010) (Tanida vd., 2004), motor hayali (Power vd., 2010) vb.) YKS tabanlı BBA çalışmaları mevcuttur. Bunlar arasında motor hayali tabanlı yapılanlardan biri Zhanga ve arkadaşlarının çalışmalarıdır. Bu çalışmalarında 10 kişiden 20 kanallı kaydedilmiş 2 sınıflı YKS veri kümesi ile çalışmışlardır. Sağ/sol el MHH dayalı YKS veri kümesine OUÖ tabanlı filtreleme uyguladıktan sonra öznelikleri DAA ile sınıflandırarak HbO için %75.30, HbR için %72.30 SD hesaplamışlardır (Zhang vd., 2017). Başka bir çalışmada Haihong ve Cuntai 2 sınıflı sağ/sol el MHH dayalı YKS veri kümesine Kernel temelli sinyal yerelleştirme yöntemini uygulamışlardır. Daha sonra sınıflandırıcı olarak DVM kullanarak %74.10 SD hesaplamışlardır (Haihong vd., 2006). Sitaram ve arkadaşları ise 5 kişiden kaydedilen 2 sınıflı sağ/sol el MHH dayalı elde ettikleri YKS işaretlerini DVM ve hidden markov modeli (HMM) ile sınıflandırmışlardır. DVM ile 5 kişi için ortalama %73.00 SD hesaplarırken, HMM ile ortalama %89.00 SD hesaplamışlardır (Sitaram vd., 2007). Naseer ve arkadaşları ise (Naseer vd., 2015)'daki çalışmalarında 4 sınıflı YKS verilerini sınıflandırmışlardır. Burada 4 sınıf, sağ/sol MHH, mental aritmetik ve mental hesaplama tabanlı YKS verileri olarak 10 kişiden kaydedilmiştir. DDA ile sınıflandırdıkları verilerinden 10 kişi için ortalama %73.30 SD hesaplamışlardır. Mental aritmetik tabanlı çalışmalarda ise, Naseer ve arkadaşları 14 sağlıklı denekten kaydedilen veri seti ile çalışmıştır. Hemoglobin konsantrasyonundaki değişikliklerin ortalaması tabanlı öznelik çıkartarak bu öznelikleri DDA ve DVM ile sınıflandırdılar. Sonuç olarak, DDA'yı kullanarak ortalama %74.28 SD ve DVM'yi kullanarak % 82.14 SD hesaplamışlardır (Naseer vd., 2014). Bauernfeind ve arkadaşları ise 8 denekten alınan mental aritmetik tabanlı YKS sinyallerini kullanmışlardır. Daha sonra, HbO sinyallerinden işaretin ayırt edici gücü temelli öznelikler çıkartarak bu öznelikleri DDA ile sınıflandırmışlardır. Sonuç olarak 8 denekten ortalama %79.70 SD hesaplamışlardır (Bauernfeind vd., 2011).

YKS tabanlı BBA çalışmalarında elde edilen sonuçlar EEG'ye göre kısmen düşük sonuçlar olsa da bu yöntemin BBA'lar için de kullanılabileceği gösterilmiştir. EEG'ye

göre avantaj ve dezavantajlar barındıran bu ölçme yöntemi yaklaşık son 5 yıldır araştırmacılar tarafından hibrit BBA oluşturulmak için kullanılmaya başlanmıştır. Bu hibrit kullanımındaki temel amaç BBA'ların sınıflandırma doğruluğunu arttırmaktır. Araştırmacılar çalışmalarında bu hibrit kullanımın etkinliğini göstermek için EEG tabanlı yöntemlerin sonuçları ile EEG+YKS hibrit tabanlı yöntemlerin sonuçlarını karşılaştırmaktadırlar (Tomita vd., 2014) (Wallois vd., 2012).

BBA performansını ve evrenselliğini iyileştirmek için çeşitli optimizasyon teknikleri ve paradigmlar (Lee vd., 2014) önerilmiştir. BBA sistemlerinin gelişmesi için gereken çözümlerden birisi, beyin görüntüleme tekniklerinin çoklu kullanılması, yani, bir hibrit BBA oluşturan ölçüm cihazlarının kullanılmasında yatmaktadır (Khan vd., 2014). Hibrit BBA modelleri arasında son yıllarda EEG+YKS tabanlı sistemler önem kazanmaktadır. Literatürde 2 veya çok sınıflı mental aritmetik (Khan vd., 2014), motor hayali (Kanoh vd., 2009) vb. tabanlı düşünsel EEG+YKS işaretleri ile çalışılmıştır.

Literatürde yapılan EEG+YKS çalışmaları ayrıntılı olarak birçok açıdan incelemeyi artırmak amaçlı Tablo 1.1'de verilmiştir. Yapılan çalışmalar arasında Fazli ve arkadaşları 2 sınıflı MHH dayalı ve motor uygulama (MU)'ya dayalı EEG+YKS işaretleri ile çevrimdışı olarak çalışmışlardır. YYS işaretlerinin ortalaması ve EEG işaretlerinin bant gücü tabanlı öznitelikler çıkartarak bu öznitelikleri DAA ile sınıflandırmışlardır. MHH dayalı EEG+YKS veri kümesi ile %83.20 SD hesaplarırken MU dayalı EEG+YKS veri kümesi ile ise %93.20 SD hesaplamışlardır (Fazli vd., 2012). Buccino ve arkadaşları ise yine 2 sınıflı MHH dayalı EEG+YKS işaretleri ile çevrimdışı olarak çalışmışlardır. YYS işaretlerinin ortalamasını alırken EEG işaretlerinden OUÖ tabanlı öznitelikler çıkartmışlardır. DAA ile sınıflandırdıkları özniteliklerden %94.20 SD'ye ulaşmışlardır (Buccino vd., 2016). MU dayalı başka bir çalışmada ise Li ve arkadaşları 2 sınıflı EEG+YKS işaretleri ile çevrimiçi olarak çalışmışlardır. YYS işaretlerinden ortalama tabanlı öznitelikler çıkartırken EEG işaretlerinden Dalgacık Dönüşümü (DD) tabanlı öznitelikler çıkarmışlardır. Daha sonra, çıkarılan öznitelikleri DVM ile sınıflandırarak %91.02 üzerinde SD hesaplamışlardır (Li vd., 2017). Bir başka çalışmada, Al-Quraishi ve arkadaşları 20 kişiden kaydedilen 2 sınıflı MU dayalı veri kümesi ile çalışmışlardır. Bu çalışmalarında YYS verilerinden varyans, basıklık ve çarpıklık tabanlı öznitelikler çıkartırken, EEG verilerinden ortalama mutlak değer, karekök ortalaması, dalga biçimi uzunluğu ve dördüncü dereceden özbağlanım katsayıları tabanlı öznitelikler çıkartmışlardır. Daha sonra, DVM ile %93.01 SD hesaplamışlardır (Al-Quraishi vd., 2021). Zihinsel görev tabanlı kaydedilen çalışmalarda ise Al-Shargie ve

arkadaşları 22 sağlıklı kişiden kaydettikleri EEG+YKS veri kümesi ile çalışmışlardır. 2 sınıflı olan veri kümesinden HbO için ortalama konsantrasyon, EEG için ise ortalama güç tabanlı öznelilikler çıkartmışlardır. DVM ile sınıflandırılan özneliliklerden %95.10 SD hesaplamışlardır (Al-Shargie vd., 2016). Cicalese ve arkadaşları ise MA tabanlı 4 sınıflı EEG+YKS veri kümesinin YKS verilerinden ortalama, EEG verilerinden ise Bant gücü tabanlı öznelilikler çıkartmışlardır. Çıkarılan öznelilikleri DDA ile sınıflandırarak %79.31 SD elde etmişlerdir (Cicalese vd., 2020). Shin ve arkadaşları ise bilişsel görev tanımlı 2 sınıflı EEG+YKS veri kümesi ile çalışmışlardır. Bu çalışmalarında EEG ve YKS verilerinden OUÖ'nün logaritmik varyansı tabanlı öznelilikler çıkartmışlardır. 26 kişiden oluşan veri kümesi için öznelilikleri DAA ile sınıflandırarak %86.80 SD'ye ulaşmışlardır (Shin vd., 2018).

Tablo 1.1'e bakıldığında deney içeriği açısından literatürde yapılan çalışmalar motor görevi ağırlıklıdır. Motor ağırlıklı görevlerin birçoğu sağa ve sola imleç, ok veya el hareketi hayali tabanlı iken MU dayalı görevlerde bunların uygulanması ile alakalıdır. Bunlar arasından 2 sınıflı EEG+YKS işaretlerinin sınıflandırılmasıyla %61.30-%99.85 SD hesaplanırken 3 sınıflı EEG+YKS işaretleri için %82.20 SD'ye ulaşılmıştır. Motor görevi tabanlı çalışmaları ise zihinsel görev tabanlı çalışmalar takip etmiştir. Bu çalışmaların deney içeriği ise genel olarak zihinsel yorgunluk seviyesi tahmini, zihinsel iş yükü veya zihinsel stres tespiti olduğu görülmektedir. Tablo 1.1'de görüldüğü gibi zihinsel görev tabanlı 2 sınıflı çalışmalarda ise SD %75.60-95.10 arasındadır. Bunlara ek olarak bilişsel görev, ses ve video algısı gibi deney içeriklerine sahip çalışmalar da Tablo 1.1'de verilmiştir. 2 sınıflı yapılan bu deney içeriklerinde ise SD sırasıyla %86.60 ve %97.80'dir. Tablo 1.1'e baktığımızda elektrotların pozisyonları genellikle frontal ve motor korteks ağırlıklı olsa da bazı çalışmalarda neredeyse tüm kafatasını kapsayacak şekilde yayılmıştır. Elektrot sayısı ise yaygın olarak 6-128 arasında YKS elektrot sayısının ise 6-170 arasında olduğu Tablo 1.1'de görülmektedir. Tablo 1.1 deneye katılan kişi sayı açısından değerlendirildiğinde ise bu sayı 6 ila 29 kişi arasında değişmektedir.

BBA alanında yapılan bu çalışmalar değerlendirildiğinde elde edilen sınıflandırma doğruluklarının göreceli olarak başarılı olduğu görülse de halen daha geliştirilmesi gereken bir alan olduğu dikkati çekmektedir. Sınıflandırma doğruluğu ise direkt olarak çıkarılan etkin özneliliklere bağlıdır. Etkin öznelilikler ise beynin farklı düşünsel görevler esnasında ürettiği işaretlerden elde edilebilir. İnsan beyninin sağ lobunun görsel ve işitsel görevlerde, sol lobunun ise matematiksel işlemlerde daha aktif olduğu esas dikkate

alındığında bu bölgelere hitap edecek düşünsel görevlere ait sinyallerin daha ayırt edici olacağı beklenebilir. Bu temel bilgi esas alınarak ve EEG+YKS sinyallerinin doğası düşünülerek bu çalışmada özgün deney paradigması önerilmiştir. Bu paradigmada beynin farklı bölgelerinin daha etkin olmasını sağlayacak sağa, sola, yukarıya ve aşağıya kayan yazı okumaya dayalı görevler belirlenmiştir. Önerilen bu yeni paradigma yöntemi bu alandaki SD'yi %96.28'e çıkarmıştır.



Tablo 1.1. Literatürde yer alan hibrit EEG+YKS çalışmaları

Referanslar	Kişilerin Durumu	Analiz Türü	Kişi sayısı	Beyin Bölgesi	Deney İçeriği	YKS Öznitelikleri	EEG Öznitelikleri	Sınıflandırıcı	Frekans	Elektrot sayısı	Olası Uygulama	Kontrol Sayısı	SD
(Fazli vd., 2012)	Sağlıklı	Çevrimdışı	14	Frontal, motor ve parietal korteks	1. MHH: Sağa veya sola hareket eden ok hayali 2. MU: El açma kapama hareketi	HbO, HbR ve HbT'nin ortalaması	Bant Gücü	DAA	EEG:100 NIRS:6.25	EEG:37 NIRS:24	Seçim çözme	2	1. %83.20 (MHH) 2. %93.20 (MU)
(Tomita vd., 2014)	Sağlıklı	Çevrimdışı	13	Görsel korteks	DDGUP tabanlı görev	HbO ve HbR'nin 1. ve 2. dereceden türevi	Bant Gücü	Ortak Sınıflandırıcı	EEG:500 NIRS:1.81	EEG:6 NIRS:16	Çoktan seçmeli seçim ve tekerlekli sandalye kontrolü	2	%85.00
(Khan vd., 2014b)	Sağlıklı	Çevrimiçi	20	Frontal ve motor korteks	MHH: Sağa veya sola hareket eden yön hayali	HbO ve HbR'nin ortalaması	Bant Gücü	DAA	EEG:256 NIRS:1.81	EEG:8 NIRS:12	Tekerlekli sandalye kontrolü	2	%94.70
(Blokland vd., 2014)	Tetrapleji hastaları	Çevrimdışı	12	Motor korteks	1. MHH: Parmakları ve başparmağı sürekli hareket ettirme hayali 2. MU: Parmakları ve başparmağı sürekli hareket ettirme	HbO ve HbR'nin Ortalaması (3-18 sn Aralığında)	Bant Gücü	Doğrusal lojistik regresyon sınıflandırıcı	EEG:256 NIRS:250	EEG:8 NIRS:6	Seçim çözme	2	1. %79.00 (MHH) 2. %87.00 (MU)
(Putze vd., 2014)	Sağlıklı	Çevrimdışı	12	İşitsel ve görsel korteks	Ses ve video algısı	HbO ve HbR'nin Ortalamasının Farkı	Bant Gücü	DVM	EEG:256 NIRS:19.5	EEG:12 NIRS:170	Seçim çözme	2	%97.80
(Koo vd., 2015)	Sağlıklı	Çevrimiçi	6	Motor korteks	MHH: Sağa veya sola hareket eden ok hayali	HbO için Eşik Değeri	OUÖ	EEG için DVM ve YYS için eşik	EEG:256 NIRS:6.25	EEG:6 NIRS:8	Seçim çözme	2	%88.00

Referanslar	Kişilerin Durumu	Analiz Türü	Kişi sayısı	Beyin Bölgesi	Deney İçeriği	YKS Öznitelikleri	EEG Öznitelikleri	Sınıflandırıcı	Frekans	Elektrot sayısı	Olası Uygulama	Kontrol Sayısı	SD
(Lee vd., 2015)	Sağlıklı	Çevrimiçi	14	Frontal, motor ve parietal korteks	MHH: Sağ ve sol el hareketi hayali	HbO ve HbR'nin Ortalama Genliği	OUÖ ve Logaritmik Güç	DAA	EEG:100 NIRS:6.25	EEG:37 NIRS:24	Seçim çözme	2	%61.30
(Yin vd., 2015)	Sağlıklı	Çevrimiçi	6	Motor korteks	MHH: Farklı hızlarda sağ el sıkma hareketi hayali	HbO ve HbR'nin Farkı	Zaman Frekansı Fazı	Aşırı Öğrenme Makinesi	EEG:250 NIRS:1	EEG:21 NIRS:24	Seçim çözme	2	%89.00
(Buccino vd., 2016)	Sağlıklı	Çevrimdışı	15	Motor korteks	MHH: Sağ ve sol el hareketi hayali	HbO Sinyal Ortalaması ve Sinyal Eğimi	OUÖ	DAA	EEG:250 NIRS:10.42	EEG:21 NIRS:34	Tekerlekli sandalye kontrolüne uygulanabilir	2	%94.20
(Ahn vd., 2016)	Sağlıklı	Çevrimiçi	11	Tüm kafatası	Zihinsel yorgunluk seviyesi tahmin	HbO ve HbR'nin Genliği	Bant Gücü	DAA	EEG:512 NIRS:10	EEG:64 NIRS:8	Uyku görevi	2	%68.30
(Al-Shargie vd., 2016)	Sağlıklı	Çevrimdışı	22	Frontal korteks	Zihinsel stres ölçümü: Stresli ve stresli olmayan durumlarda seçim yapma	Ortalama HbO konsantrasyonu	Ortalama gücü	DVM	EEG:256 NIRS:10	EEG: 7 NIRS:23	Stresli koşullar altında zihinsel aritmetik görev	2	%95.10
(Aghajani vd., 2017)	Sağlıklı	Çevrimiçi	17	Frontal ve parietal korteks	Çalışan Bellek: Zihinsel iş yükü n-geri görev	HbO ve HbR'nin Tepe, Eğim, Standart Sapma, Çarpıklık ve Basıklık Değeri	Bant Gücü ve Faz Kilitleme Değeri	DVM	EEG:250 NIRS:8.93	EEG:19 NIRS:19	Zihinsel yorgunluk tahmini	2	%90.90
(Ge vd., 2017)	Sağlıklı	Çevrimdışı	12	Motor korteks	MHH: Sağ ve sol el hareketi hayali	Hurst Üssü	OUÖ	DVM	EEG:1000 NIRS:28	EEG:64 NIRS: 52	Seçim çözme	2	%81.20

Referanslar	Kişilerin Durumu	Analiz Türü	Kişi sayısı	Beyin Bölgesi	Deney İçeriği	YKS Öznitelikleri	EEG Öznitelikleri	Sınıflandırıcı	Frekans	Elektrot sayısı	Olası Uygulama	Kontrol Sayısı	SD
(Li vd., 2017)	Sağlıklı	Çevrimiçi	11	Motor korteks	MU: Sağ ve sol el hareketi	HbO ve Hbr'nin Ortalaması (2 sn'lik zaman diliminde)	Dalgacık Dönüşümü Katsayısı	DVM	EEG:500 NIRS:7.81	EEG:18 NIRS:34	2 sn'lik zaman diliminde seçim kodu çözme	2	%91.02
(Shin vd., 2017)	Sağlıklı	Çevrimdışı	29	Frontal, motor ve görsel korteks	1. MHH: Sağ ve sol el hareketi hayali 2. MA: Dinlenme durumuna karşı zihinsel aritmetik	OUÖ'nün logaritmik varyansı	OUÖ'nün logaritmik varyansı	DAA	EEG:200 NIRS:12.5	EEG: 30 NIRS:36	Seçim çözme	2	1. %74.20 (MHH) 2. %88.10 (MU)
(Shin vd., 2018a)	Sağlıklı	Çevrimdışı	26	Parietal ve oksipital korteks	Ayrımcılık/seçim yanıt görevi	OUÖ'nün logaritmik varyansı	OUÖ'nün logaritmik varyansı	DAA	EEG:1 NIRS:10.4	EEG: 30 NIRS:36	Seçim çözme	2	%86.80
(Shin vd., 2018b)	Sağlıklı	Çevrimdışı	8	Frontal korteks	MI: Parmak hareketi hayali MA: Zihinsel işlem Dinlenme durumu	Eğim ve varyans	OUÖ'nün logaritmik varyansı	DAA	EEG:2.05 NIRS:13.3	EEG: 21 NIRS:16	Seçim çözme	3	%82.20
(Cicalese vd., 2020)	Sağlıklı olmayan	Çevrimdışı	29	Frontal ve parietal korteks	MA: Dört, beş ve altı basamaklı sayıların ezberlenmesi ve görev kısmında söylenmesi	Ortalama	Bant gücü	DAA	EEG:500 NIRS:3.91	EEG: 33 NIRS:46	Seçim çözme	4	%79.31
(Al-Quraishi vd., 2021)	Sağlıklı	Çevrimdışı	20	Motor korteks	MU: Sağ ve sol ayak bileği eklem hareketleri	Varyans, basıklık ve çarpıklık	Ortalama mutlak değer, dalga uzunluğu, OUÖ	DVM	EEG:256 NIRS:10	EEG:20 NIRS:32	Seçim çözme (sağ ve sol ayak bileği eklem hareketleri)	2	%93.01

Referanslar	Kişilerin Durumu	Analiz Türü	Kişi sayısı	Beyin Bölgesi	Deney İçeriği	YKS Öznitelikleri	EEG Öznitelikleri	Sınıflandırıcı	Frekans	Elektrot sayısı	Olası Uygulama	Kontrol Sayısı	SD
(Zhang vd., 2022)	Sağlıklı	Çevrimdışı	20	Frontal, parietal, temporal ve oksipital korteks	Dinlenmek-oturma durumu	HbO statik ve dinamik fonksiyonel bağlantısı	Küresel alan gücüne dayalı mikro durum	k-ortalama kümeleme	EEG:1000 NIRS:17.54	EEG: 32 NIRS: 40	Dinlenme-Oturma (gözler kapalı, gözler açık)	2	--
(Ergün ve Aydemir, 2020)	Sağlıklı	Çevrimdışı	29	Frontal, motor ve görsel korteks	MHH: Sağ ve sol el açma kapama hareketi hayali	FWHD	FWHD	k-EYK	EEG:200 NIRS:12.5	EEG: 30 NIRS:36	Seçim çözme	2	%78.21
(He vd., 2022)	Sağlıklı	Çevrimdışı	29	Frontal, motor ve görsel korteks	MHH: Sağ ve sol el açma kapama hareketi hayali	Uzay-zaman korelasyonları	Uzay-zaman korelasyonları	Yapay sinir ağları	EEG:200 NIRS:12.5	EEG: 30 NIRS:36	Seçim çözme	2	%82.11
(Nour vd., 2022)	Sağlıklı	Çevrimdışı	29	Frontal, motor ve görsel korteks	MHH: Sağ ve sol el açma kapama hareketi hayali	Çoklu bant genişliği analizi	Çoklu bant genişliği analizi	Evrişimsel sinir ağları	EEG:200 NIRS:12.5	EEG: 30 NIRS:36	Seçim çözme	2	%99.85

2. YAPILAN ÇALIŞMALAR

2.1. Veri Kümesi Tanıtımı

Bu tez çalışmasında, Karadeniz Teknik Üniversitesi FHD-2020-9166 nolu BAP projesi kapsamında alınan hizmet alımı ile Atatürk Üniversitesi/ Spor Bilimleri fakültesinde veri kümesi kaydı gerçekleştirilmiştir. Yaşları 19-38 arasında değişen sekiz sağlıklı katılımcı (bay/bayan) deneylere katılmıştır. Deneyin başında, her katılımcının haklarını ve çıkarlarını korumak için gönüllü olduklarına dair yazılı rızası alınmıştır. Bu tez çalışmasında, katılımcılar Kişi-1, Kişi-2, Kişi-3, Kişi-4, Kişi-5, Kişi-6, Kişi-7 ve Kişi-8 takma adlarıyla tanımlanmıştır. Çalışma, Karadeniz Teknik Üniversitesi Etik Kurulu tarafından proje için onaylanmıştır ve Helsinki bildirgesi (Mellin-Olsen vd., 2010) altında gerçekleştirilmiştir.

Deneyden önce, her bir gönüllüye deneysel yöntem ve adımlar anlatılmıştır ve tüm gönüllüler tüm süreci tam olarak anlamıştır. Deneyi yapan kişi, güvenilirliği sağlamak için deneysel sürecin denetlenmesinden sorumlu olarak deneyi gerçekleştirmiştir. Deney, geniş ve kapalı bir laboratuvar da yapılmıştır. Gönüllü bireyler, Şekil 2.1’de gösterildiği gibi, 1920x1080 çözünürlüklü LCD monitörden bir metre kadar uzakta rahat bir koltuğa oturmuşlardır. Ayrıca, gönüllü bireylerin fiziksel ve zihinsel durumunu ve yüksek sinyal kalitesini korumak için kişilerin yeterli mola vermesi sağlanmıştır. Şekil 2.2’de gösterilen deney düzeneği ile veri kümesi kaydedilmesi gerçekleştirilmiştir. Burada görüldüğü gibi gönüllü katılımcı uyaran ekranına baktığı esnada kafatasına takılı olan EEG ve YKS elektrotları ile senkron olarak beyin sinyalleri alınmaktadır. EEG elektrotlarından alınan bilgi EEG portu ile YKS elektrotlarından alınan bilgi ise YKS portu ile ayrı ayrı bilgisayar ekranına aktarılmaktadır.

Uygun deney ortam sağlandıktan sonra gönüllü bireylerden sağa (sınıf 1), sola (sınıf 2), yukarıya (sınıf 3) ve aşağıya (sınıf 4) kayan yazı okumaya dayalı EEG+YKS işaretleri kaydedilmiştir. Deney kaydının tek seansı için oluşturulmuş deney prosedürü Şekil 2.3’teki gibi gerçekleştirilmiştir. Deney toplamda 6 seanstan oluşmaktadır ve her bir seansta katılımcılardan toplamda 20 denemelik kayıtlar alınmıştır. Her bir seans 60 saniye (sn)’lik ön dinlenme ile başlayıp, 2 sn’lik görev tanıtımı ile devam etmektedir. Bu kısımda, bir bilgisayar ekranının tam ortasında katılımcılara bir görsel uyarı ile hangi görev tanımını yapmaları gerektiği verilmiştir. Bu görev tanımları rasgele ve eşit sayıda olacak şekilde


ekranda belirmiştir. Daha sonra kısa bir bip sesi ile görevin gerçekleşeceği 24 sn'lik kısma geçilmiştir. Bu kısım kısa bir bip sesi ile sonlandırılıp 10 sn deneme sonu dinlenmesi gerçekleştirilerek tekrar görev tanıtımına dönülmüştür. 20 denemelik kaydın alınması ile 1. seans 60 sn'lik, 2. seans 120 sn'lik, 3. seans 180 sn'lik, 4. seans 240 sn'lik, 5. seans 300 sn'lik, 6. seans 360 sn'lik seans sonu dinlenmesi gerçekleştirilerek her bir seans için veri kaydı sonlandırılmıştır. Böylece 1 kişiden toplamda 120 denemelik veri (Her bir sınıftan 30 deneme) kaydedilmiştir. EEG için 250 Hz, YKS için 10.1725 Hz örnekleme frekansı ile veriler kaydedilmiştir.




Şekil 2.1. Deney katılan bireylerin deney esnasından fotoğrafları

Bu tez çalışmasında EEG sinyalleri, Brain Product tarafından geliştirilen ActiChamp cihazı kullanılarak toplanırken, YKS sinyalleri simültane olarak, NIRX Optical Neuroimaging cihazı kullanılarak kaydedilmiştir. EEG elektrotları ve YKS elektrotları tek bir şapka ile gönüllü kişilerin kafatasına yerleştirilmiştir. Deneyler sırasında elektrotlar uluslararası 10/20 sistemine göre yerleştirilerek unipolar EEG kaydı yapılmış ve veri


toplama sırasında tüm elektrot empedans değerleri 5 k Ω 'un altında tutulmuştur. EEG veriler 31 elektrot ile Uluslararası 10-20 Sistemi'ne göre olmak üzere frontal, sentral, temporal ve oksipital bölgelere yerleştirilmiştir. YKS verileri de 18 elektrot ile alınmıştır. YKS emitör ve dedektörleri ise görme duyusunun aktif olduğu sentral ve oksipital bölgelere yayılmıştır. Elektrotların, detektör ve emitörlerin genel görüntüsü Şekil 2.4'teki gibidir. Burada yeşil ile işaretli kısımlar EEG elektrotlarını, mavi kısımlar detektörleri, kırmızı kısımlar ise emitörleri ifade etmektedir. Veri seti hakkında detaylı bilgi Tablo 2.1'de özet olarak verilmiştir.



Şekil 2.2. Deney düzeneği



Şekil 2.3. EEG+YKS veri kümesi kayıt prosedürü



Şekil 2.5. Kayan yazı okumaya dayalı görsel ekran


Deney esnasında katılımcılar ekrandan bilimsel içerikli cümleler okumuştur. Bu cümleler TUBİTAK Bilim Teknik dergisinden rasgele olarak farklı konularda seçilmiştir (URL-1, 2022). Örnek cümleler şu şekilde sıralanabilir:

- Kokunun kaynağı olan uçucu kimyasallar nemle daha uzaklara taşınmakla kalmaz, aynı zamanda havada bulunma süreleri de uzar.
- Lityum iyon bataryalarda, tıpkı standart pillerde olduğu gibi iki tür elektrot vardır. Biri pozitif yüklü katot, diğeri negatif yüklü anot.
- Göz kırpma sırasında göz kapaklarımızın kapalı kalma süresi sohbet ettiğimiz kişinin bilinçaltında farklı çıkarımlarla sonuçlanabiliyor.
- Bazal gözyaşı, gözlerimizin üzerinde ince bir tabaka oluşturarak daha iyi görmemize ve enfeksiyonlardan korunmamıza yardımcı olur.
- Gözyaşı bezleri gözyaşı salgılama miktarını artırır, meibomian bezler gözyaşının buharlaşmasını geciktiren yağlı bir tabaka oluşturulmasına katkıda bulunur.
- Bilim insanları, proteinler sayesinde dizginlenerek mikroskopik boyutta tutulan kristallerin etkisiz hâle getirilmesi için dalağa gönderildiğini düşünüyor.
- Gözümüzün ön bölümünde yer alan ve ışığı odaklamakla gözü dış etkilerden koruma görevlerini üstlenen kornea, işlevini gözyaşı sayesinde yerine getirir.
- Korneada kan damarları bulunmaz; korneanın ihtiyaç duyduğu oksijen, göz kırpma eylemiyle yenilenen gözyaşı tabakasına karışan havadan sağlanır.

- Güncel araştırmalara göre, gözlerden beyne iletilen yüklü veri akışının göz kırpmayla kesintiye uğraması, beyinde kısa dinlenmelere yol açıyor.
- Gözyaşı; mukus, su ve yağ bileşenlerinden oluşur. Sıkça gözlerimizi kırpmamızın en temel işlevi, gözümüzün nemli ortamının devamlılığını sağlamaktır.
- Mevsimsel değişimler sıcaklığa ek olarak diğer duyularımız için de farklılıkları beraberinde getirir. Koku alma duyumuz da bunlardan biri.
- 2019'da dünya genelinde antibiyotiğe dirençli bakterilerin neden olduğu enfeksiyonlar yüzünden bir milyondan fazla kişi hayatını kaybetti.
- Şarj sırasında lityum iyonlar katottan anota doğru hareket eder. Telefonu kullanmaya başladığınız sırada ise iyonlar bu kez ters yöne, anottan katota doğru gider.
- Antibiyotiklerin aşırı ve gereksiz kullanımı, direncin daha yaygınlaşmasına yol açarak sepsis ve zatürree gibi yaygın enfeksiyonların tedavisinin zorlaşmasına yol açabilir.
- Ekolojide besinlerdeki toksik birikimi ve çevreye zararlı kimyasalları ifade eden ağır metaller, metalürjide bir yoğunluk kategorisi olarak değerlendirilebiliyor.
- Elektrikli araçlarda motorlar dairesel hareket oluşturur. Bu sayede elektrikli motorun oluşturduğu hareket doğrudan tekerleklerle aktarılabilir.
- Elektrikli araçlarda elektrik enerjisini hareket enerjisine dönüştüren elektrikli motorlar, petrol yakıtlı araçlarda içten yanmalı motorlar kullanılır.
- Son yıllarda tüketimi fazla olan gıdaların üretimi sırasında harcanan doğal kaynaklar ve salınan sera gazı miktarı hesaplanarak yayınlanmaya başlandı.
- Hafıza kaybı ve bilişsel yetilerin azalması gibi belirtiler ortaya çıkmadan yıllar önce bile Alzheimer hastalığı beyne zarar vermeye başlayabiliyor.
- Araştırmacılar katılımcıların neşeli olduğunu düşündükleri müzikleri dinledikleri zaman daha yaratıcı olduğunu, sessiz ortamda çalışan insanlardan daha eşsiz fikirler ortaya koyduklarını gözlemledi.

Ham EEG verileri, EEGLab (URL-2, 2023) araç kutusu ham YKS verileri ise, NIRSLab (URL-3, 2023) araç kutusu kullanılarak ön işleme işlemlerinden sonra MATLAB'a (URL-4, 2017) aktarılmıştır. Matlab programında çizdirilen örnek EEG, Deoxy ve Oxy verileri Şekil 2.6'da gösterilmiştir. Şekil 2.6'da her bir grafik EEG, Deoxy ve Oxy


için rasgele olarak seçilmiştir ve tek bir denemeyi ifade etmektedir. Burada her bir grafikte x eksenini zaman eksenini y eksenini ise işaretin genliğini ifade etmektedir.



Şekil 2.6. EEG+YKS veri kümesinden rasgele seçilmiş EEG, Deoxy ve Oxy denemeleri

2.2. Yöntem

Önerilen yöntem verilerin kaydedilmesi, verilerin zaman dilimlerine bölünmesi, öznetelik çıkartma ve sınıflandırma aşamalarından oluşmaktadır. Bu aşamaların birbiri ile ilişkilerini gösterir genel akış şeması Şekil 2.7’de gösterilmiştir. Buna göre kişiden EEG+YKS işaretleri kendisine söylenen düşünsel görevler yapıldığı sırada 4 sınıflı olarak kaydedilmiştir. Daha sonra bu işaretlerden şebeke gürültüsü ön işleme ile temizlenmiştir. Ön işlemeden geçirilen bu işaretler zaman dilimlerine bölütlenerek veri artırımı amaçlanmıştır. EEG+YKS veri kümesi, görev kısmı 24 sn olduğu için bunun tam sayı katları olacak şekilde sırasıyla 2.4, 4.8, 12 ve 24 sn’lik zaman dilimleri şeklinde bölütlenmiştir. Bölütlenen EEG+YKS veri kümesi rastgele olarak sırasıyla yüzde 65, 9 ve 26’lik eğitim, doğrulama ve test kümesi olarak ayrılmıştır. Eğitim ve test veri kümesi her sınıftan eşit sayıda denemeler içermektedir. Daha sonra belirlenen matematiksel yöntemler ile bölütlenen işaretlerden öznetelikler çıkartılmıştır. Son olarak da bu öznetelikler makine öğrenmesi algoritmaları ile sınıflandırılarak bilinmeyen test denemeleri etiketlenmiştir.



Şekil 2.7. Önerilen yöntemin genel akış şeması

250 Hz örnekleme frekansı kullanılarak 30 kanaldan kaydedilen EEG verileri 24 sn'lik zaman dilimi uzunluğundayken EEG veri seti için toplam deneme sayısı 120'dir. Veri formatını *deneme x örnek sayısı x kanal sayısı* olarak ifade edilirse 24 sn'lik veri boyutu $120 \times 6000 \times 30$ olmaktadır. EEG verileri 12 sn'lik zaman dilimlerine bölütlendiğinde toplam deneme sayısı 240 olmaktadır ve veri boyutu $240 \times 3000 \times 30$ olmaktadır. 4.8 sn'lik zaman dilimlerine bölütlendiğinde ise $600 \times 1200 \times 30$ olan veri boyutu, 2.4 sn'lik zaman dilimlerine bölütlendiğinde $1200 \times 600 \times 30$ olmaktadır. Diğer taraftan 24 sn'lik zaman dilimi uzunluğundayken toplam 250 örneği olan YKS veri kümesinin veri boyutu $120 \times 250 \times 18$ iken, 12 sn'lik zaman dilimlerine bölütlendiğinde ise veri boyutu $240 \times 125 \times 18$ olmaktadır. 4.8 sn'lik zaman dilimlerine bölütlendiğinde ise $600 \times 50 \times 18$ olan veri boyutu, 2.4 sn'lik zaman dilimlerine bölütlendiğinde $1200 \times 25 \times 18$ olmaktadır. Bu çalışmada işareten HD, Bant Gücü (BG), Hızlı Walsh-Hadamard Dönüşümü (HWHD) ve istatistiksel öznitelikler (İÖ) yöntemleri tabanlı öznitelikler çıkartılmış olup çıkarılan öznitelikler *k*-EYK, DVM, DT ve RF yöntemleriyle daha güvenilir test sonuçları elde etmek için 50 koşum sonucu hesaplanarak sınıflandırılmıştır. İlgili tüm SD sonuçları, karşılık gelen 50 test sınıflandırmasının ortalaması alınarak elde edilmiştir. Tüm sınıflandırma işlemleri; 16 GB, 2.92 GHz Intel Core i7 işlemcili bilgisayar üzerinde MATLAB R2020b programı kullanılarak gerçekleştirilmiştir.

2.2.1. Ön İşleme

Ön işleme aşamasında 50 Hz güç hattı girişimi gibi elektriksel gürültüyü veya diğer istenmeyen sinyal özellikleri veri kümesinden 2. dereceden bant durduran filtre (He ve Liu, 2009) ile giderilmiştir.

2.2.2. Öznitelik Çıkarma Yöntemleri

Veri kümesindeki sınıfların birbirinden ayırt edilmesini sağlayacak ayırt edici özelliklerin istatistiksel veya matematiksel analiz yöntemleriyle elde edilmesi işlemi öznitelik çıkartımı olarak tanımlanır (Fu vd., 2008). Bu tez çalışmasında alt başlıklarda açıklanan HD, BG, HWHD ve İÖ yöntemleri öznitelik aşamasında kullanılmıştır.

2.2.2.1. Hilbert Dönüşümü Öznitelikleri

HD, Hilbert'in Riemann-Hilbert problemi olarak bilinen analitik fonksiyonlarla ilgili olarak ortaya attığı bir problem üzerine yaptığı 1905 çalışmasında ortaya çıktı. (Chen ve Hao, 2017). HD, bir spektral analizden minimum faz yanıtını elde etmek için kullanılan bir tekniktir. EEG veya YKS gibi beyin dinamiklerini oluşturan sinyal türleri durağan değildir. HD ise doğrusal bir operatör değildir. Ancak, frekansı fazdaki bir değişim oranı olarak temsil ederek frekansı zamanla değişebilir kıldığı için durağan olmayan sinyallerin belirlenmesi ve araştırılması için etkili bir yöntemdir (Gupta vd., 2020). Genel olarak, ham kayıtlar zamanla değişen çok sayıda frekans içermektedir (Jayasree vd., 2010). HD'nin frekans alanında özellikle basit bir gösterimi vardır: Bir fonksiyonun her frekans bileşenine, frekansın işaretine bağlı olarak $\pm 90^\circ$ 'lik bir faz kayması verir. Denklem 2.1'de gösterildiği gibi $p(t)$ işaretinin HD'si ($\widehat{pn}(t)$), işaretin $h(t) = 1/\pi t$ ile konvolüsyonla elde edilmektedir. Bu çalışmada $p(t)$ EEG veya YKS sinyalini temsil etmektedir. İşaretin dürtü tepkisi ise Denklem 2.2'de gösterilmiştir.

$$H\{p(t)\} = \widehat{pn}(t) = p(t) * \frac{1}{\pi t} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{p(\tau)}{t - \tau} d\tau \quad (2.1)$$

$$H(\omega) = F[h(t)] = -i \operatorname{sign}(\omega) \quad (2.2)$$

Denklem 2.2'de görüldüğü gibi işaretin dürtü tepkisi $\omega < 0$ için $+i$ 'ye ve $\omega > 0$ için $-i$ 'ye eşittir. Bu nedenle HD, $p(t)$ 'nin negatif frekans bileşenlerini $+90$ derece ve pozitif frekans bileşenlerini -90 derece kaydırma etkisine sahiptir. Nedensellik nedeniyle, bir $p(t)$ işaretinin HD'si gerçekte ve sanal kısımları ile Denklem 2.3'teki gibi ilişkilendirilir. $\widehat{pn}(t)$ 'nin gerçekte ve sanal kısımlarının karelerinin toplamının karekökünün ortalaması (HD_{abs}) Denklem 2.4'de verilmiştir.

$$\widehat{pn}(t) = r(\widehat{pn}(t)) + i(\widehat{pn}(t)) \quad (2.3)$$

$$HD_{abs} = \frac{\sum_{i=1}^m \sqrt{r(\widehat{pn}_i(t))^2 + i(\widehat{pn}_i(t))^2}}{m} \quad (2.4)$$

Burada m , $\widehat{p\mathbf{n}}(t)$ 'nin uzunluğunu ifade etmektedir. Bu tez çalışmasında HD_{abs} değerleri, EEG, Deoxy ve Oxy denemelerini temsil eden öznitelikler olarak kullanılmıştır.

2.2.2.2. Bant Gücü Öznitelikleri

Bir bant gücü özelliğinin hesaplanması, belirli bir frekans bandındaki bir sinyalin bant geçişli olarak filtrelenmesinden, ardından filtrelenmiş sinyalin karesinin alınmasından ve son olarak belirli bir zaman penceresinde elde edilen değerlerin ortalamasının alınmasından oluşur (Naser ve Aydemir, 2022) (Brodu vd., 2011). Normal dağılıma yakın bir dağılıma sahip özniteliklere sahip olmak için bu değeri log-dönüştürmek de mümkündür. Bant gücü özellikleri genellikle, tanınacak zihinsel durumlara göre önceden belirlenmiş birkaç frekans bandı için hesaplanır. Bu tür öznitelikler literatürde motor görevi, görüntü sınıflandırma ve bilişsel işlem görevlerinin için başarıyla kullanılmıştır. Ayırık zamanlı Fourier dönüşümü (AZFD), ayırık zamanlı sinyal işleme algoritmalarının ve sistemlerinin analizinde, tasarımında ve uygulanmasında olduğu kadar doğrusal filtreleme, korelasyon analizi ve spektral analiz gibi sinyal işleme uygulamalarında da kullanılmaktadır (Zhao vd., 2011). AZFD, ayırık zamanlı periyodik bir işaretin periyodunun sonsuz olduğu düşüncesine dayanarak Ayırık Fourier serisinin alınması mantığına dayanır. AZFD, m uzunluğunda sınırlı uzunluklu bir $p[n]$ sinyali için aşağıda verilen Denklem 2.5 ile ifade edilir. AZFD'si alınmış $p[n]$ sinyali için bant gücü ise Denklem 2.6'daki gibidir. Şunu belirtmek gerekir ki bu tez çalışmasında alt kesim frekansı 1 Hz, üst kesim frekansı ise 4 Hz olarak seçilmiştir.

$$R(e^{j2\pi k/m}) = P[k] = \sum_{n=0}^{m-1} p[n]e^{-j2\pi nk/m} \quad (2.5)$$

$$BG = \frac{1}{T} \sum_{n=-\infty}^{\infty} |P[k]|^2 \quad (2.6)$$

2.2.2.3. Hızlı Walsh-Hadamard Dönüşümü Öznitelikleri

HWHD, zaman alanlı zaman serilerini frekans alanlı verilere dönüştüren sayısal sinyal işleme, görüntü işleme ve biyomedikal işaretleme alanlarında yaygın olarak kullanılan etkili

yöntemlerden biridir (Ergün ve Aydemir, 2020b) (Saka ve Aydemir, 2016). Walsh-Hadamard Dönüşümü (WHD), bir zaman serisini sinüzoidal olmayan bir diziye böler. Ortogonal fonksiyonlar, yani Walsh fonksiyonları, +1 veya -1 değerlerine sahip kare dalgalar. WHD, genelleştirilmiş bir frekans kategorisi olan sıra değerleri verir. Birim zaman aralıklarında ortalama sıfır geçiş sayısının %50'si ile belirlenir. Her Walsh işlevine benzersiz bir dizi değeri ayrılmıştır. Döndürülen dizi değerleri, orijinal verilerdeki sinyal frekanslarına yaklaşmak için kullanılabilir (Lopez-Ramirez vd., 2022) (Srivastva ve Singh, 2018). HWHK, sinyal örneklerini 2^n uzunluğunda ayırır ve 2^n katsayısına böler. Hadamard matrisi (H_n), Denklem 2.7'deki gibi hesaplanan $2^n \times 2^n$ boyutlu matristir.

$$H_n = \frac{1}{\sqrt{2^n}} \begin{bmatrix} H_{n-1} & \cdots & H_{n-1} \\ \vdots & \ddots & \vdots \\ H_{n-1} & \cdots & -H_{n-1} \end{bmatrix} \quad (2.7)$$

Bu tez çalışmasında EEG denemelerinde $N = 6000/(1,2,5,10)$ örnek bulunmasından dolayı $n = 13,12,11,10$ ($N \leq 2^n$), YKS denemelerinde $M = 250/(1,2,5,10)$ örnek bulunmasından dolayı $m = 8,7,6,5$ ($M \leq 2^n$) olarak alınmıştır. Bir giriş sinyali olan $p(t)$ 'nin Hızlı Walsh-Hadamard Dönüşümü katsayı (HWHK)'ları Denklem 2.8'deki gibidir. Bu tez çalışmasında EEG ve YKS sinyallerinden HWHK'nın ortalaması tabanlı öznitelikler çıkarılmıştır. Çıkarılan öznitelikler Denklem 2.9'da gösterildiği gibidir.

$$HWHK = H_n \cdot p(t) \quad (2.8)$$

$$HWHK_{ort} = \frac{\sum_{i=1}^m HWHK_i}{m} \quad (2.9)$$

2.2.2.4. İstatistiksel Öznitelikler

Çarpıklık genellikle bir dağılımın şekil özelliklerini tanımlamak için kullanılır. Olasılık kuramı ve istatistik bilim dallarında bir dağılımın ortalama etrafındaki simetriden ne kadar saptığını göstermektedir (Radhi vd., 2022) (Wang vd., 2022). Denklem 2.10'da bir

$p(n)$ işareti için çarpıklık ifadesi verilmiştir. Burada $\bar{p}$, 1'den m 'e kadarki p değerlerinin aritmetik ortalamasıdır.

$$\text{Çarpıklık} = \frac{\frac{1}{m} \sum_{n=1}^m (p(n) - \bar{p})^3}{\left(\frac{1}{m} \sum_{n=1}^m (p(n) - \bar{p})^2\right)^{3/2}} \quad (2.10)$$

Gerçek değerli bir rasgele değişkenin olasılık dağılımının "tepe noktasının" bir ölçüsüdür. Pozitif basıklık katsayısı sivri dağılıma, negatif basıklık katsayısı ise basık bir dağılıma işaret eder (Sharif vd., 2022) (Zhang vd., 2022). Denklem 2.11'de basıklık ifadesi verilmiştir. Burada $\bar{p}$, 1'den m 'e kadarki p değerlerinin aritmetik ortalamasıdır.

$$\text{Basıklık} = \frac{\frac{1}{m} \sum_{n=1}^m (p(n) - \bar{p})^4}{\left(\frac{1}{m} \sum_{n=1}^m (p(n) - \bar{p})^2\right)^2} \quad (2.11)$$

Varyans kavramı, bir dağılımın her bir değerinin, dağılımın ortalamasından ne kadar uzakta olduğu ile ilgilidir (Cheng vd., 2022) (Li vd., 2008). Varyans, bu sapmaların ortalamasını ölçer. 1'den m 'e kadarki bir $p(n)$ işareti için varyans ifadesi Denklem 2.12'de verilmiştir.

$$\text{Varyans} = \frac{1}{m} \sum_{n=1}^m (p(n) - \bar{p})^2 \quad (2.12)$$

Standart sapma, bir popülasyon, örnek, olasılık dağılımı veya rastgele değişken için veri değerlerinin dağılımını özetlemek için olasılık teorisinde ve istatistikte kullanılan bir ölçüdür (Phinyomark vd., 2010) (Sharma vd., 2016). Standart sapma ile verilerin ortalamaya ne kadar yakın olduğunu bulunur. Standart sapma küçükse, veriler ortalamanın etrafına dağılır. Standart sapma büyük olduğunda ise, veriler ortalamadan uzağa dağılır. 1'den m 'e kadarki bir $p(n)$ işareti için standart sapma ifadesi Denklem 2.13'te verilmiştir.

$$\text{StandartSapma} = \sqrt{\frac{1}{m} \sum_{n=1}^m (p(n) - \bar{p})^2} \quad (2.13)$$

2.2.3. Sınıflandırma Yöntemleri

Sınıflandırma, basitçe verilerin veri kümesinde tanımlanan çeşitli kategorilere ayrılmasıdır. Sınıflandırma algoritmaları, bu dağılım modelini belirli bir eğitim setinden öğrenir ve ardından sınıfı bilinmeyen bir test verisi geldiğinde doğru şekilde sınıflandırmaya çalışır. Veri seti üzerinde bu kategorileri gösteren değerlere etiket adı verilir ve eğitim ve test sırasında verinin kategorisini belirlemek için kullanılır (Wang vd., 2021) (Aldayel vd., 2021). Makine öğrenimi alanında ve özellikle istatistiksel sınıflandırma probleminde, hata matrisi bir algoritmayı değerlendirmek veya farklı algoritmaların performansını karşılaştırmak için bir sınıflandırma probleminin performansının görselleştirilmesine izin veren özel bir tablo düzenidir (Subasi vd., 2007) (Sita vd., 2013).

İkili ve çok sınıflı bir sınıflandırma problemi için karışıklık matrisi Tablo 2.2 ve Tablo 2.3'te sunulmuştur. Matrisin her satırı, gerçek bir sınıftaki deneme sayısını temsil ederken, her sütun, tahmin edilen bir sınıftaki deneme sayılarını temsil eder veya tam tersi de literatürde yer almaktadır. Hata matrisinin i. satırındaki ve j. sütunundaki bir ögesi, tahmin edilen sınıfın j. ve gerçek sınıfın i. olduğu denemelerin sayısını göstermektedir.

Tablo 2.2. İkili sınıflandırma problemi hata matrisi

Hata Matrisi		Tahmini Sınıf	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	TP	FN
	Negatif	FP	TN

Tablo 2.3. Çok sınıflı sınıflandırma problemi hata matrisi

Hata Matrisi		Tahmini Sınıf			
		R_1	R_2	...	R_N
Gerçek Sınıf	R_1	$R_{1,1}$	FP	...	$R_{1,N}$
	R_2	FN	TP	...	FN
	...	...	...	...	...
	R_N	$R_{N,1}$	FP	...	$R_{N,N}$

İkili bir sınıflandırma probleminde, karışıklık matrisi 2×2 boyutundadır ve etiketlerden biri “Pozitif”, diğeri “Negatif” kabul edilir. Matris elemanları, tahmin edilen etikete (pozitif,

negatif) ve tahmin edilenin gerçek sınıf etiketiyle (doğru, yanlış) karşılaştırmasının sonucuna göre sınıflandırılır: gerçek pozitifler (TP), gerçek negatifler (TN), yanlış pozitifler (FP) ve yanlış negatifler (FN). Hata matrisinden faydalananarak hesaplanan iki sınıflı problem için sınıflandırma doğruluğunun eşitliği Denklem 2.14'te verilmiştir.

$$SD2 = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (2.14)$$

Çok sınıflı sınıflandırma durumunda, ikili sınıflandırma için tanımlanan metrikler tam anlamıyla geçerli değildir. Çok sınıflı hata matrisi, $N \times N$ boyutuna sahiptir; burada N , $R_1, R_2, \dots, R_N$ farklı sınıf etiketlerinin sayısıdır. Bu nedenle, TP, TN, FP, FN örneklerinin karakterizasyonu bu durumda uygulanamaz. Bunun yerine, Tablo 2.3'teki örnekte sağlanan karakterizasyona dayalı olarak belirli bir sınıfa odaklanan bir analiz yapmak mümkündür. Bu yaklaşıma dayalı olarak her sınıf için bir dizi metrik tanımlanabilir (Heydarian vd., 2022) (Nurkholis vd., 2022). Daha sonra, bu ölçümlerin uygun kombinasyonuna dayalı olarak, tüm hata matrisi için hesaplama yapmak mümkündür. Tablo 2.3'teki hata matrisinden faydalananarak hesaplanan çok sınıflı problem için sınıflandırma doğruluğunun eşitliği Denklem 2.15'te verilmiştir.

$$SDÇ = \frac{\sum_{i=1}^N TP(R_i)}{\sum_{i=1}^N \sum_{j=1}^N R_{i,j}} \times 100 \quad (2.15)$$

Bu tez çalışmasında dört sınıflı veri kümesi ile çalışılmıştır. Veri kümesi k -EYK, DVM, karar ağaç yapısı (KAY) ve rasgele orman algoritması (ROA) yöntemleriyle sınıflandırılmıştır. Bu yöntemler aşağıda açıklanmıştır.

2.2.3.1. k -En Yakın Komşuluk


k -EYK yöntemi 1951'de Fix ve Hodges tarafından önerilmiş ve daha sonra 1967'de Cover ve Hart tarafından geliştirilmiş bir algoritmadır (Kayıkcıoğlu ve Aydemir, 2010) (Wang vd., 2022). Sınıflandırma ve regresyon için basit, sağlam ve çok yönlü olan bu algoritma, örüntü tanıma, modellerin sıralanması, metin kategorizasyonu ve nesne tanıma gibi farklı problem türlerinin yanı sıra biyoinformatik ve tıp dahil olmak üzere birçok farklı

alanda kullanılmaktadır. Parametrik olmayan ve tembel öğrenen bir sınıflandırıcıdır. Parametrik olmaması, k -EYK yöntemini temel veri özelliklerine ilişkin varsayımlardan muaf tutar, bu nedenle veriler hakkında önceden bilgiye sahip olmaya gerek yoktur. k -EYK yöntemi, etiketi bilinmeyen test denemesini eğitim setindeki en yakın komşunun (elemanın), k değerine (benzerliğe) göre belirleyerek sınıflandırma işlemi gerçekleştiren denetimli/gözetimli makine öğrenme algoritmasıdır. k -EYK yöntemi, eğitim ve test verileri arasındaki uzaklığı/benzerliği bulmaktır. Uzaklık/benzerlik ölçütleri olarak k -EYK’de Minkowski, Manhattan, Chebychev, Öklid, Kosinüs, Şehir bloğu, Korelasyon benzerliği gibi birçok yöntem literatürde kullanılmıştır (Al-azzawi vd., 2022) (Sha’Abani vd., 2020). Bu tez çalışmasında bu uzaklık ölçütlerinden Öklid, Kosinüs, Şehir bloğu ve Korelasyon kullanılmıştır. Bunlar arasından en iyi sonuçlara Öklid uzaklık ölçütü ile ulaşılmıştır. İki nesne arasındaki Öklid mesafesi Denklem 2.16 kullanılarak hesaplanmıştır. Burada m tane r ve t noktaları arasındaki Öklid uzaklığı $\text{Öklid}M$ ile ifade edilmektedir.


$$\text{Öklid}M(r, t) = \sqrt{\sum_{i=1}^m (p_{ri} - p_{ti})^2} \quad (2.16)$$

k -EYK yöntemi için örnek bir gösterim Şekil 2.8’de verilmemiştir. Burada etiketi bilinmeyen mavi yuvarlak test verisinin sınıfı öğrenilmek istenmektedir. Test verisi Şekil 2.8’de gösterildiği gibi X veya Y sınıflarından birine aittir. Burada " k ", k -EYK yöntemi için en yakın komşu değeridir. Eğer $k = 3$ alınırsa Şekil 2.8’de test verisinin eğitim verilerine olan uzaklıkları ölçülür ve en yakın 3 tanesi belirlenir. Şekil 2.9’de görüldüğü gibi en yakın verilerden 2’si X sınıfında ve 1’i Y sınıfına aittir. Bu durumda algoritma bu test verisinin X sınıfına ait olması gerektiğini göstermektedir. Burada x ve y ekseni her bir sınıf için uzaklık birimini ifade etmektedir.

k -EYK yönteminde k parametresinin belirlenmesi önemli hususlardan biridir. Bu tez çalışması için rastgele alt örnekleme yöntemi kullanılarak en ideal k parametresi her bir her bir modalite ve kişi için her koşulda hesaplanarak test sınıflandırılması gerçekleştirilmiştir.



Şekil 2.8. X ve Y etiketlerinden oluşan örnek veri kümesi



Şekil 2.9. k-EYK yöntemi için veri sınıflandırması

2.2.3.2. Destek Vektör Makineleri


DVM, ilk olarak Cortes ve Vapnik (1995) tarafından önerilen, denetimli sınıflandırmada yaygın olarak kullanılan bir sınıflandırma algoritmasıdır (Bhuvaneswari vd., 2013) (Ghosh vd., 2019). DVM kavramı sinir ağlarından alınmıştır veya sinir ağının matematiksel uzantısı olduğunu söylenebilir. DVM hem doğrusal hem de doğrusal olmayan verileri sınıflandırabilir. DVM, orijinal eğitim verilerini çok boyutlu uzaya dönüştürerek ve daha yüksek boyutta hiper-düzlem oluşturarak sınıflandırma işlemi yapmaktadır. DVM için optimal bir hiper düzlem tabanlı matematik öğrenme Şekil 2.10'da gösterilmiştir. Şekil

2.10’da gösterildiği gibi bir düzlem üzerine yerleştirilmiş verileri ayırmak için bir doğru çizilir. Çizilecek bu doğru, iki sınıfın noktaları için de maksimum uzaklıkta olması gerekmektedir. Şekil 2.10’da kare bloklar ve yuvarlak bloklar olmak üzere iki farklı sınıf yer almaktadır. Burada iki çizginin orta sınır çizgisi sınır çizgisini, her iki sınıfa yakın olan kesikli çizgiler ise sınır düzlemlerini ifade etmektedir. Ayrıca, sınır düzlemleri üzerinde bulunan sınıflar destek vektörlerini göstermektedir (Li vd., 2013) (Abisoye vd., 2019).

Sınıflandırmadaki amaç etiketi bilinmeyen test verisini sınıflandırmak olduğu için bu iki sınıfı ayıracak bir doğru çizilir. Çizilen bu doğrunun ± 1 ’i arasında kalan kısma margin adı verilir. Margin ne kadar geniş ise iki veya daha fazla sınıf o kadar iyi ayrıştırılır. Hiper düzlem, her iki sınıf için de Denklem 2.17’deki eşitsizlik işlevini yerine getirecek şekilde oluşturulmuştur.

$$\hat{z} = \begin{cases} 0, & \omega^T \cdot x + b < 0 \\ 1, & \omega^T \cdot x + b \geq 0 \end{cases} \quad (2.17)$$


Denklem 2.17’de w ağırlık vektörü, x girdi vektörü, b ise sapmayı ifade etmektedir. Yeni bir test verisi için çıkan sonuç 0’den küçükse test denemesi yuvarlak bloklu sınıflara, 0’den büyük ise kare bloklu sınıflara daha yakın olacaktır. Bu tez çalışmasında DVM yöntemi için sigma parametresi rastgele alt örnekleme yöntemi ile her bir veri kümesi için ideal olarak seçilmiştir.



Şekil 2.10. DVM için iki sınıflı problem örneği

2.2.3.3. Karar Ağaç Yapısı

KAY, sınıflandırma ve tahmin için güçlü, tümevarımsal çıkarım için en yaygın kullanılan pratik yöntemlerden biridir (Guan vd., 2019) (Polat vd., 2007). Gürültülü verilere dayanıklı ve ayrık ifadeleri öğrenebilen ayrık değerli fonksiyonlara yaklaşmak için iyi bir yöntemdir. Bu yöntem tıbbi vakaları teşhis etmeyi öğrenmekten, kredi başvurusunda bulunanların kredi riskini değerlendirmeye kadar çok çeşitli alanlara başarıyla uygulanmaktadır. Karar ağacı öğrenimi, tüm olası karar ağaçlarının uzayında buluşsal, tek adımlı ileriye dönük geri izlemesiz bir aramadır. Karar ağaçları fazla hesaplama gerektirmeden sınıflandırma yapar. Ancak, karar ağaçları, çok sınıflı ve nispeten az sayıda eğitim denemesi içeren sınıflandırma problemlerinde çok etkin değildir. Karar ağacı, akış şeması ağaç benzeri yapısıdır; burada her iç karar düğümleri ile giriş verilerinin özellikleri test edilirken, her dal ile bu testin sonucu temsil edilir (Albaqami vd., 2021) (Duan vd., 2015) Yapraklar ise her bir sınıf etiketini ifade etmektedir. Örnek bir KAY Şekil 2.11’de gösterilmiştir. Şekil 2.11’de kare blok karar düğümünü, yuvarlak bloklar iç karar düğümlerini, →’lar dalları gösterirken, yıldızlar ise uç yaprakları yani her bir sınıfı ifade etmektedir.



Şekil 2.11. Karar ağaç yapısı

Karar ağacı öğreniminin işleyişi şu şekildedir:


- Bir özellik seçilir ve iç karar düğümleri yardımıyla giriş verileri test edilir.
- Hangi yöne yöneleceğine dair sorular sorulur.
- Testin her sonucuna göre dallara ayrılır.

- Bu sonucu tatmin eden örneklerin alt kümesine karşılık gelen alt düğüme taşıyın.
- Her alt düğümde yinelemeli olarak çalıştırın.
- Her sınıf için yaprak düğümüne geldiğinde karar ağaç yapısını sonlandır.

2.2.3.4. Rasgele Orman Algoritması

ROA, Leo Breiman ve Adele Cutler'in ticari markasını taşıyan, birden fazla karar ağacının çıktısını tek bir sonuca ulaşmak için birleştiren, yaygın olarak kullanılan bir makine öğrenme algoritmasıdır (Kayhan vd., 2022) (Şenel vd., 2020) (Wang vd., 2015). Kullanım kolaylığı ve esnekliği hem sınıflandırma hem de regresyon problemlerini ele aldığı için sıklıkla tercih edilmektedir. Rastgele orman algoritması, ilişkisiz bir karar ağaçları ormanı oluşturmak için hem torbalamayı hem de özellik rastgeleliğini kullandığından, torbalama yönteminin bir uzantısıdır.

Özellik havuzu oluşturma veya "rastgele alt uzay yöntemi" olarak da bilinen özellik rastgeleştirme, karar ağaçları arasında düşük korelasyon sağlayan özelliklerin rastgele bir alt kümesini oluşturur. Karar ağacı yapısı algoritması ile rastgele ormanlar arasındaki temel fark budur. Karar ağaçları tüm olası özellik atamalarını dikkate alırken, rastgele ormanlar bu özelliklerden yalnızca bazılarını seçer (Wang vd., 2019) (Wei vd., 2020). ROA için genel gösterim Şekil 2.12'de gösterilmiştir. Şekilde görüldüğü gibi öncelikle her bir deneme için karar ağacı oluşturur ve her bir karar ağacının tahmini değer sonucu hesaplanır. Tahmin sonucu oluşan her değer için gerçekleşen sonuca göre oylama yapılır. Bu oylamada tahmin için en çok olan sınıf için etiket atanır.




Şekil 2.12. Rasgele Orman Algoritması genel yapısı

ROA'sında ağaç sayısı ayarlanması gereken önemli bir parametredir. Bu tez çalışmasında ağaç sayısı parametresi rastgele alt örnekleme yöntemi ile her bir veri kümesi için ideal olarak seçilmiştir.


2.1.6.1. Deneysel Sonuçların Görselleştirilmesi

Bu çalışmada sonuçların sunumu için kullanılan grafiklerden biri Şekil 2.13'te bir örneği gösterilen radar grafiğidir. Her bir radar grafiği iç içe geçmiş beşgenlerden oluşmaktadır. Burada beşgenlerin her bir uç noktası sırasıyla EEG+Deoxy, EEG+Oxy, EEG, Deoxy ve Oxy modalitelerini ifade etmektedir. Radar grafiğinin içinde yer alan mavi, turuncu, gri ve sarı iç içe geçmiş değer skalaları ise sırasıyla *k*-EYK, DVM, KAY ve ROA sınıflandırıcıları için 8 kişinin ortalama SD'sini göstermektedir. Radar grafiği üzerinde yer alan örnek SD_1 ve SD_2 sınıflandırma doğruluğunu temsil etmektedir. Bu örnekteki radar grafiğinden, EEG+Oxy modalitesi için *k*-EYK metodu ile %95.26 ortalama SD elde edildiğini ve benzer şekilde Oxy modalitesi için ROA metodu ile ortalama %56.26 SD elde edildiğini görülmektedir. Ayrıca deneylerin 5 farklı modalite için 4 farklı sınıflandırma algoritması kullanılarak hesaplanması göz önüne alındığında, sonuçları daha iyi görsel olarak sunmak için tüm deneysel sonuçları bu kombinasyonlar için 8 kişinin ortalama eğitim ve test SD sonucu olarak bu radar grafikleri kullanılarak sunulmuştur.



Şekil 2.13. Sonuçların gösterildiği örnek radar grafiği

Bu çalışmada sonuçların sunumu için kullanılan diğer bir grafik örneği Şekil 2.14'te gösterilen kişiye özgü bar grafikleridir. Her bir grafikte EEG+Deoxy, EEG+Oxy, EEG, Deoxy ve Oxy modalitelerinin her biri için 8 kişinin 50 koşum sonucu ortalama SD'si ayrı ayrı yer almaktadır. Bar grafiğinin içinde yer alan her bir sütun her bir kişi için SD'yi ifade ederken $K_1, K_2, K_3, K_4, K_5, K_6, K_7, K_8$ sırasıyla Kişi 1, Kişi 2, Kişi 3, Kişi 4, Kişi 5, Kişi 6, Kişi 7 ve Kişi 8'i ifade etmektedir. Bar sütunları arasında yer alan skala çizgileri ise sırasıyla 20, 40, 60, 80 ve 100 değerinde sınır çizgileridir ve SD'yi ifade etmektedir. Bu örnek grafiğinden görüldüğü üzere EEG+Oxy modalitesinde K_5 için %88.82 ortalama SD elde edilirken, benzer şekilde Deoxy modalitesinde K_7 için %75.35 SD hesaplanmıştır. Ayrıca deneylerin 8 farklı katılımcı ile yapıldığı göz önüne alındığında, sonuçları daha iyi görsel olarak sunmak için tüm deneysel sonuçları EEG+Deoxy, EEG+Oxy, EEG, Deoxy ve Oxy modalitelerinin her biri için kişi bazlı eğitim ve test SD sonuçları bu grafikler kullanılarak sunulmuştur.



Şekil 2.14. Sonuçların gösterildiği örnek kişiye özgü bar grafiği

3. BULGULAR

Bu çalışma ile sağa, sola, yukarıya ve aşağıya kayan yazı okumaya dayalı 4 sınıflı EEG+YKS veri kümesi kaydedilmiştir. Bu veri kümesinin kaydı Karadeniz Teknik Üniversitesi bünyesinde FHD-2020-9166 nolu BAP projesi destekli yürütülmüştür. Deney ortamı ve veri kümesi kaydı ise Atatürk Üniversitesi/Spor Bilimleri fakültesinde gerçekleştirilmiştir. Bu düşsel görev esnasında kaydedilen EEG+YKS verilerine Şekil 2.7'deki deney prosedürü başarı bir şekilde uygulanarak etkin sonuçlar elde edilmiştir. Bu veri kümesi sırasıyla 2.4, 4.8, 12 ve 24 sn'lik zaman dilimleri şeklinde bölütlenmiştir. Ardından bölütlenen EEG+YKS veri kümesi rastgele olarak sırasıyla yüzde 65, 9 ve 26'lık eğitim, doğrulama ve test kümesi olarak ayrılmıştır. Daha sonra bölütlenen veri kümesinden HD, BG, HWHD ve İÖ tabanlı öznitelikler çıkartılmıştır. Son olarak da bu öznitelikler *k*-EYK, DVM, KA, ROA tabanlı algoritmalar ile sınıflandırılarak bilinmeyen test denemeleri etiketlenmiştir. 4 sınıflı olan ve 8 kişiden oluşan veri kümesi için önerilen algoritma 2.4, 4.8, 12 ve 24 sn'lik zaman bölütleri için tüm kişilere ve tüm modalitelere ayrı ayrı uygulanmıştır. Tüm sınıflandırma işlemlerinde EEG ve YKS'nin tüm kanalları kullanılmıştır. Sınıflandırma sonuçları EEG+Deoxy, EEG+Oxy, Deoxy ve Oxy modaliteleri için ayrı ayrı hesaplanmıştır.

3.1. 2.4 Saniye Zaman Bölütü ile Elde Edilen Bulgular


2.4 sn zaman bölütlerinden çıkarılan HD tabanlı özniteliklerin her bir kişi için sırasıyla *k*-EYK, DVM, KAY ve ROA ile sınıflandırılması ile 50 koşum sonucu ortalama eğitim ve test SD sonuçları her bir modalite için Şekil 3.1'de kişi bazlı bar grafiğinde verilmiştir. Şekil 3.1'de görüldüğü gibi *k*-EYK sınıflandırıcısı ile EEG+Deoxy, EEG+Oxy modalitesi için en iyi test SD'si sırasıyla K3 için 98.45 ± 0.94 , K3 için 98.47 ± 1.33 en kötü test SD ise K4 için 92.74 ± 1.70 , K6 için 92.95 ± 1.49 olarak hesaplanmıştır. Diğer yandan EEG, Deoxy ve Oxy modalitesi için ise sırasıyla K3 için 94.26 ± 2.14 , K7 için 90.30 ± 2.17 , K1 için 87.58 ± 1.90 en kötü test SD'si K6 için 86.55 ± 1.49 , K8 için 51.32 ± 3.46 , K3 için 39.33 ± 2.37 olarak hesaplanmıştır. DVM sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için en iyi-en kötü test SD'si K1-K4 için 98.46 ± 0.93 - 91.73 ± 1.78 , K1-K4 için 98.44 ± 0.90 - 91.54 ± 1.61 arasında değişmektedir. EEG, Deoxy ve Oxy modalitesi için ise sırasıyla en iyi-en kötü test SD'si

K1-K4 için $\%95.08 \pm 1.52$ - $\%86.64 \pm 1.61$, K7-K8 için $\%93.34 \pm 1.51$ - $\%59.60 \pm 2.67$, K1-K3 için $\%81.45 \pm 2.36$ - $\%44.03 \pm 2.45$ arasında değişmektedir. KAY ile EEG+Deoxy, EEG+Oxy modalitesi için en iyi test SD'si sırasıyla K1 için $\%68.75 \pm 2.87$, K3 için $\%78.25 \pm 9.52$ en kötü test SD ise K8 için $\%43.06 \pm 8.16$, K4 için $\%46.86 \pm 2.71$ olarak hesaplanırken EEG, Deoxy ve Oxy modalitesi için ise sırasıyla K3 için $\%75.06 \pm 3.34$, K1 için $\%69.15 \pm 3.38$, K1 için $\%72.03 \pm 3.32$ en kötü test SD'si K2 için $\%66.62 \pm 2.81$, K8 için $\%42.20 \pm 2.77$, K3 için $\%32.73 \pm 2.97$ olarak hesaplanmıştır. ROA sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için en iyi-en kötü test SD'si K1-K3 için $\%83.73 \pm 2.87$ - $\%62.11 \pm 4.70$, K1-K4 için $\%83.88 \pm 2.46$ - $\%65.91 \pm 5.13$ arasında değişmektedir. EEG, Deoxy ve Oxy modalitesi için ise sırasıyla en iyi-en kötü test SD'si K5-K2 için $\%92.20 \pm 2.36$ - $\%82.98 \pm 4.56$, K1-K8 için $\%88.94 \pm 2.08$ - $\%53.34 \pm 3.46$, K1-K3 için $\%87.87 \pm 2.06$ - $\%38.47 \pm 2.80$ arasında değişmektedir.


2.4 saniye zaman bölütlerinden çıkarılan BG tabanlı özniteliklerin her bir kişi için sırasıyla *k*-EYK, DVM, KAY ve ROA ile sınıflandırılması ile 50 koşum sonucu ortalama eğitim ve test SD sonuçları her bir modalite için Şekil 3.2'de kişi bazlı bar grafiğinde verilmiştir. Şekil 3.2'de görüldüğü gibi *k*-EYK sınıflandırıcısı ile EEG+Deoxy, EEG+Oxy modalitesi için en iyi test SD'si sırasıyla K8 için $\%97.62 \pm 1.50$, $\%97.44 \pm 1.21$ en kötü test SD ise K4 için $\%91.15 \pm 1.61$, $\%90.95 \pm 1.91$ olarak hesaplanmıştır. Diğer yandan EEG, Deoxy ve Oxy modalitesi için ise sırasıyla K3 için $\%93.54 \pm 1.82$, K7 için $\%81.53 \pm 2.40$, K1 için $\%66.28 \pm 2.65$ en kötü test SD'si K5 için $\%84.31 \pm 1.91$, K5 için $\%31.25 \pm 2.27$, K5 için $\%34.03 \pm 2.38$ olarak hesaplanmıştır. DVM sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için en iyi-en kötü test SD'si K1-K4 için $\%97.29 \pm 1.27$ - $\%85.68 \pm 2.10$, K1-K4 için $\%96.96 \pm 1.50$ - $\%85.04 \pm 2.01$ arasında değişmektedir. EEG, Deoxy ve Oxy modalitesi için ise sırasıyla en iyi-en kötü test SD'si K1-K4 için $\%92.72 \pm 2.45$ - $\%81.66 \pm 2.01$, K7-K5 için $\%82.65 \pm 2.27$ - $\%33.13 \pm 2.18$, K4-K5 için $\%63.75 \pm 3.21$ - $\%35.03 \pm 2.28$ arasında değişmektedir. KAY ile EEG+Deoxy, EEG+Oxy modalitesi için en iyi test SD'si sırasıyla K8 için $\%63.77 \pm 5.31$, K3 için $\%74.61 \pm 5.30$ en kötü test SD ise K5 için $\%42.86 \pm 3.89$, K4 için $\%46.37 \pm 3.83$ olarak hesaplanırken EEG, Deoxy ve Oxy modalitesi için ise sırasıyla K5 için $\%74.22 \pm 2.61$, K7 için $\%60.41 \pm 3.04$, K1 için $\%63.96 \pm 3.39$ en kötü test SD'si K6 için $\%68.37 \pm 6.27$, K8 için $\%37.47 \pm 2.08$, K8 için $\%29.06 \pm 2.06$ olarak hesaplanmıştır. ROA sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için en iyi-en kötü test SD'si K6-K5 için $\%78.75 \pm 4.12$ - $\%59.96 \pm 5.50$, K8-K2 için $\%81.45 \pm 5.32$ - $\%67.03 \pm 4.09$ arasında

değişmektedir. EEG, Deoxy ve Oxy modalitesi için ise sırasıyla en iyi-en kötü test SD'si K3-K6 için $\%91.08 \pm 3.31$ - $\%83.56 \pm 4.09$, K7-K8 için $\%84.22 \pm 2.87$ - $\%46.90 \pm 2.91$, K1-K8 için $\%80.60 \pm 3.44$ - $\%32.13 \pm 2.52$ arasında değişmektedir. Tüm bunlara ek olarak, 2.4 sn zaman bölütlerinden çıkarılan HWHD ve İÖ tabanlı özneliliklerin her bir kişi için sırasıyla k-EYK, DVM, KAY ve ROA ile sınıflandırılması ile 50 koşum sonucu ortalama eğitim ve test SD sonuçları her bir modalite için Şekil 3.3 ve 3.4'te kişi bazlı bar grafiğinde verilmiştir.







Şekil 3.1. 2.4 sn zaman bölütlerinden çıkarılan HD tabanlı özneliteler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.2. 2.4 sn zaman bölütlerinden çıkarılan BG tabanlı öz nitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.3. 2.4 sn zaman bölütlerinden çıkarılan HWHD tabanlı öznelilikler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.4. 2.4 sn zaman bölütlerinden çıkarılan İÖ ile 50 koşum sonucu ortalama eğitim ve test SD'si

Her bir sınıflandırıcı ve modalite için 2.4 sn zaman bölütlerinden çıkarılan HD, BG, HWHd ve İÖ öznitelikleri kullanılarak hesaplanan 8 kişinin ortalama eğitim ve test SD'si Şekil 3.5'teki radar grafiklerinde gösterilmiştir. Burada HD tabanlı özniteliklerin *k*-EYK ile sınıflandırılmasıyla EEG+Deoxy modalitesi için 96.01 ± 2.26 eğitim 96.23 ± 1.30 test SD'si, EEG+Oxy modalitesi için 95.89 ± 2.13 eğitim 96.28 ± 1.30 test SD'si, EEG modalitesi için 91.63 ± 6.16 eğitim 91.25 ± 2.64 test SD'si, Deoxy modalitesi için 77.18 ± 4.44 eğitim 77.31 ± 2.53 test SD'si, Oxy modalitesi için 58.66 ± 4.39 eğitim 57.67 ± 2.75 test SD'si hesaplanmıştır. DVM sınıflandırıcısı ile EEG+Deoxy modalitesi için 94.23 ± 2.83 eğitim 95.40 ± 1.52 test SD'si, EEG+Oxy modalitesi için 94.57 ± 2.76 eğitim 95.51 ± 1.47 test SD'si, EEG modalitesi için 90.53 ± 6.63 eğitim 91.46 ± 1.93 test SD'si, Deoxy modalitesi için 78.23 ± 4.61 eğitim 79.14 ± 2.30 test SD'si, Oxy modalitesi için 78.23 ± 4.61 eğitim 79.14 ± 2.30 test SD'si hesaplanmıştır. KAY sınıflandırıcısı ile EEG+Deoxy modalitesi için 55.43 ± 6.52 eğitim 656.75 ± 4.77 test SD'si, EEG+Oxy modalitesi için 62.50 ± 6.99 eğitim 65.04 ± 6.43 test SD'si, EEG modalitesi için 70.10 ± 5.44 eğitim 71.52 ± 2.90 test SD'si, Deoxy modalitesi için 56.68 ± 5.75 eğitim 57.93 ± 3.20 test SD'si, Oxy modalitesi için 42.70 ± 5.03 eğitim 43.76 ± 3.01 test SD'si hesaplanmıştır. ROA sınıflandırıcısı ile EEG+Deoxy modalitesi için 80.13 ± 3.72 eğitim 74.98 ± 3.90 test SD'si, EEG+Oxy modalitesi için 80.99 ± 4.15 eğitim 75.81 ± 5.12 test SD'si, EEG modalitesi için 95.94 ± 4.20 eğitim 87.71 ± 3.15 test SD'si, Deoxy modalitesi için 80.62 ± 3.58 eğitim 75.94 ± 2.92 test SD'si, Oxy modalitesi için 59.64 ± 3.92 eğitim 53.30 ± 2.84 test SD'si hesaplanmıştır.

BG tabanlı özniteliklerin *k*-EYK ile sınıflandırılmasıyla EEG+Deoxy modalitesi için 95.35 ± 1.40 eğitim 95.72 ± 2.25 test SD'si, EEG+Oxy modalitesi için 95.26 ± 1.29 eğitim 95.59 ± 2.28 test SD'si, EEG modalitesi için 90.38 ± 2.54 eğitim 90.49 ± 6.70 test SD'si, Deoxy modalitesi için 55.26 ± 2.74 eğitim 52.95 ± 5.00 test SD'si, Oxy modalitesi için 49.10 ± 3.05 eğitim 47.29 ± 4.52 test SD'si hesaplanmıştır. DVM sınıflandırıcısı ile EEG+Deoxy modalitesi için 91.49 ± 3.13 eğitim 92.63 ± 1.78 test SD'si, EEG+Oxy modalitesi için 91.28 ± 3.47 eğitim 92.43 ± 1.82 test SD'si, EEG modalitesi için 87.69 ± 7.22 eğitim 88.40 ± 2.11 test SD'si, Deoxy modalitesi için 52.24 ± 5.19 eğitim 52.80 ± 2.41 test SD'si, Oxy modalitesi için 46.96 ± 5.41 eğitim 48.03 ± 2.49 test SD'si hesaplanmıştır. KAY sınıflandırıcısı ile EEG+Deoxy modalitesi için 52.74 ± 7.46 eğitim 54.93 ± 6.31 test SD'si, EEG+Oxy modalitesi için 59.73 ± 9.43 eğitim 62.88 ± 7.55 test SD'si, EEG modalitesi için 70.16 ± 10.52 eğitim 71.34 ± 2.74 test SD'si, Deoxy

modalitesi için 51.26 ± 5.56 eğitim 52.24 ± 3.18 test SD'si, Oxy modalitesi için 39.95 ± 5.47 eğitim 40.43 ± 2.85 test SD'si hesaplanmıştır. ROA sınıflandırıcısı ile EEG+Deoxy modalitesi için 77.78 ± 3.94 eğitim 71.44 ± 4.53 test SD'si, EEG+Oxy modalitesi için 80.90 ± 4.34 eğitim 75.03 ± 5.43 test SD'si, EEG modalitesi için 96.31 ± 4.08 eğitim 87.44 ± 3.64 test SD'si, Deoxy modalitesi için 73.78 ± 3.84 eğitim 68.38 ± 2.91 test SD'si, Oxy modalitesi için 56.26 ± 3.69 eğitim 49.16 ± 3.17 test SD'si hesaplanmıştır.

HWHD tabanlı özneliklerin *k*-EYK ile sınıflandırılmasıyla EEG+Deoxy modalitesi için 56.88 ± 4.37 eğitim 54.30 ± 2.20 test SD'si, EEG+Oxy modalitesi için 56.60 ± 4.66 eğitim 54.19 ± 2.26 test SD'si, EEG modalitesi için 58.68 ± 4.89 eğitim 52.20 ± 2.51 test SD'si, Deoxy modalitesi için 33.03 ± 4.42 eğitim 29.16 ± 2.23 test SD'si, Oxy modalitesi için 30.56 ± 4.05 eğitim 26.32 ± 2.09 test SD'si hesaplanmıştır. DVM sınıflandırıcısı ile EEG+Deoxy modalitesi için 54.64 ± 4.96 eğitim 54.99 ± 2.20 test SD'si, EEG+Oxy modalitesi için 54.15 ± 4.92 eğitim 54.77 ± 2.31 test SD'si, EEG modalitesi için 53.80 ± 5.10 eğitim 53.79 ± 1.68 test SD'si, Deoxy modalitesi için 27.37 ± 4.81 eğitim 27.50 ± 2.14 test SD'si, Oxy modalitesi için 26.08 ± 4.61 eğitim 25.97 ± 2.09 test SD'si hesaplanmıştır. KAY sınıflandırıcısı ile EEG+Deoxy modalitesi için 40.50 ± 6.81 eğitim 41.95 ± 4.72 test SD'si, EEG+Oxy modalitesi için 45.52 ± 7.50 eğitim 47.97 ± 5.38 test SD'si, EEG modalitesi için 51.36 ± 5.25 eğitim 51.38 ± 2.11 test SD'si, Deoxy modalitesi için 28.16 ± 4.69 eğitim 28.59 ± 2.29 test SD'si, Oxy modalitesi için 26.73 ± 4.73 eğitim 26.32 ± 2.18 test SD'si hesaplanmıştır. ROA sınıflandırıcısı ile EEG+Deoxy modalitesi için 51.00 ± 5.18 eğitim 43.74 ± 3.96 test SD'si, EEG+Oxy modalitesi için 53.52 ± 4.66 eğitim 46.30 ± 5.03 test SD'si, EEG modalitesi için 60.70 ± 4.59 eğitim 52.11 ± 1.82 test SD'si, Deoxy modalitesi için 32.07 ± 4.27 eğitim 27.72 ± 2.33 test SD'si, Oxy modalitesi için 30.81 ± 4.10 eğitim 26.27 ± 2.22 test SD'si hesaplanmıştır.

İÖ'nin *k*-EYK ile sınıflandırılmasıyla EEG+Deoxy modalitesi için 53.49 ± 4.80 eğitim 51.26 ± 2.55 test SD'si, EEG+Oxy modalitesi için 53.00 ± 4.95 eğitim 51.22 ± 2.68 test SD'si, EEG modalitesi için 54.51 ± 4.49 eğitim 47.29 ± 2.74 test SD'si, Deoxy modalitesi için 29.18 ± 4.14 eğitim 24.94 ± 2.21 test SD'si, Oxy modalitesi için 29.85 ± 4.15 eğitim 25.62 ± 2.05 test SD'si hesaplanmıştır. DVM sınıflandırıcısı ile EEG+Deoxy modalitesi için 50.75 ± 4.82 eğitim 51.61 ± 2.41 test SD'si, EEG+Oxy modalitesi için 50.56 ± 5.24 eğitim 51.34 ± 2.41 test SD'si, EEG modalitesi için 49.50 ± 4.79 eğitim 48.85 ± 1.92 test SD'si, Deoxy modalitesi için 25.01 ± 4.52 eğitim

%24.91±2.14 test SD'si, Oxy modalitesi için %25.36±4.52 eğitim %25.54±2.02 test SD'si hesaplanmıştır. KAY sınıflandırıcısı ile EEG+Deoxy modalitesi için %28.23±5.12 eğitim %28.63±2.96 test SD'si, EEG+Oxy modalitesi için %28.26±5.36 eğitim %28.26±5.36 test SD'si, EEG modalitesi için %28.61±4.58 eğitim %29.12±2.48 test SD'si, Deoxy modalitesi için %25.56±4.74 eğitim %25.37±2.39 test SD'si, Oxy modalitesi için %25.03 ± 4.88 eğitim %25.64±2.31 test SD'si hesaplanmıştır. ROA sınıflandırıcısı ile EEG+Deoxy modalitesi için %38.88±3.22 eğitim %29.03±2.77 test SD'si, EEG+Oxy modalitesi için %39.09±3.17 eğitim %29.35±2.72 test SD'si, EEG modalitesi için %50.24±2.92 eğitim %30.18±2.35 test SD'si, Deoxy modalitesi için %35.46±2.77 eğitim %25.70±2.43 test SD'si, Oxy modalitesi için %35.46±2.87 eğitim %25.81±2.32 test SD'si hesaplanmıştır. Bu sonuçlar incelendiğinde en iyi sonuçların HD tabanlı öznitelikleri kullanarak ulaşıldığı görülmektedir. Bundan dolayı, her bir modalite için 2.4 sn'lik zaman bölütlerinden çıkarılan HD tabanlı özniteliklerin her bir sınıflandırıcı ile elde edilen 8 kişinin ortalama test SD'si Tablo 3.1'de ayrıntılı olarak gösterilmiştir.

Her bir modalite için 2.4 sn'lik zaman bölütlerinden çıkarılan HD'nin yanı sıra BG, HWHD ve İÖ tabanlı özniteliklerinin *k*-EYK ile sınıflandırılması sonucu hesaplanan 8 kişinin ortalama test SD'si Tablo 3.2'de gösterilmiştir.

Her bir modalite ve öznitelik için 2.4 sn'lik zaman bölütlerinin tek denemesi için öznitelik çıkartma süresi ise Tablo 3.3'te gösterilmiştir. Tablo 3.3'te görüldüğü gibi hibrit modalite için en kısa öznitelik çıkartım süresi 0.81 msn ile HD tabanlı özniteliklerden hesaplanmıştır. BG tabanlı özniteliklerin öznitelik çıkartım süresi ise hibrit modalite için ortalama 1.33 msn olarak hesaplanmıştır. Tüm bunlara ek olarak, HWHD ve İÖ ile bu süre hibrit modalite için sırasıyla ortalama 3.99 ve 5.54 olarak hesaplanmıştır.

Tablo 3.1. 2.4 sn zaman bölütlerinden çıkarılan HD tabanlı özniteliklerin sınıflandırılması ile elde edilen 8 kişinin ortalama test SD'si

Modalite	<i>k</i> -EYK	DVM	KA	ROA
EEG+Deoxy	96.23±1.30	95.40±1.52	56.75±4.77	74.98±3.90
EEG+Oxy	96.28±1.30	95.51±1.47	65.04±6.43	75.81±5.12
EEG	91.25±2.64	91.46±1.93	71.52±2.90	87.71±3.15
Oxy	55.21±2.70	58.27±2.46	43.76±3.01	53.30±2.84
Deoxy	77.31±2.53	79.14±2.30	57.93±3.20	75.94±2.92

Tablo 3.2. 2.4 sn zaman bölütlerinden çıkarılan BG, HWHD ve İÖ tabanlı özneliklerin *k*-EYK ile sınıflandırılması sonucu hesaplanan 8 kişinin ortalama test SD'si

Modalite	BG	HWHD	İÖ
EEG+Deoxy	95.72±1.40	54.30±2.20	51.26±2.55
EEG+Oxy	95.59±1.29	54.19±2.26	51.22±2.68
EEG	90.49±2.54	52.20±2.51	47.29±2.74
Oxy	47.29±3.05	26.32±2.09	25.62±2.05
Deoxy	52.95±2.74	29.16±2.23	24.94±2.21

Tablo 3.3. 2.4 sn'lik zaman bölütlerinin tek denemesi için öznelik çıkartma süresi

Süre (msn)	HD	BG	HWHD	İÖ
EEG+Deoxy	0.81	1.33	3.98	5.83
EEG+Oxy	0.81	1.33	3.99	5.25
EEG	0.78	1.23	2.95	3.58
Oxy	0.02	0.18	0.48	0.61
Deoxy	0.02	0.17	0.47	0.61




Şekil 3.5. 2.4 sn zaman bölütlerinden çıkarılan öz niteliklerinin sınıflandırılması ile 8 kişi için hesaplanan ortalama eğitim ve test SD'si radar grafikleri

3.2. 4.8 Saniye Zaman Bölütü ile Elde Edilen Bulgular


4.8 sn zaman bölütlerinden çıkarılan HD tabanlı özneliklerin her bir kişi için sırasıyla *k-EYK*, *DVM*, *KAY* ve *ROA* ile sınıflandırılması ile 50 koşum sonucu ortalama eğitim ve test SD sonuçları her bir modalite için Şekil 3.6'de kişi bazlı bar grafiğinde verilmiştir. Şekil 3.6'de görüldüğü gibi *k-EYK* sınıflandırıcısı ile EEG+Deoxy, EEG+Oxy modalitesi için en iyi test SD'si sırasıyla K7 için 88.41 ± 3.56 , K3 için 88.83 ± 3.88 en kötü test SD ise K6 için 80.01 ± 4.07 , K6 için 79.61 ± 3.87 olarak hesaplanmıştır. Diğer yandan EEG, Deoxy ve Oxy modalitesi için ise sırasıyla K3 için 78.47 ± 3.94 , K2 için 76.46 ± 3.91 , K1 için 74.06 ± 3.77 en kötü test SD'si K6 için 68.62 ± 3.87 , K8 için 35.63 ± 4.48 , K8 için 32.16 ± 4.27 olarak hesaplanmıştır. *DVM* sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için en iyi-en kötü test SD'si K1-K4 için 92.40 ± 2.82 -% 79.60 ± 4.85 , K1-K4 için 91.03 ± 2.96 -% 79.86 ± 4.03 arasında değişmektedir. EEG, Deoxy ve Oxy modalitesi için ise sırasıyla en iyi-en kötü test SD'si K5-K4 için 86.79 ± 3.37 -% 75.94 ± 4.03 , K7-K8 için 83.31 ± 3.88 -% 41.65 ± 4.55 , K1-K8 için 72.11 ± 3.69 -% 36.33 ± 4.19 arasında değişmektedir. *KAY* ile EEG+Deoxy, EEG+Oxy modalitesi için en iyi test SD'si sırasıyla K1 için 54.51 ± 5.68 , 54.71 ± 5.78 en kötü test SD ise K8 için 32.96 ± 4.91 , K7 için 36.71 ± 5.40 olarak hesaplanırken EEG, Deoxy ve Oxy modalitesi için ise sırasıyla K3 için 59.43 ± 3.88 , K1 için 57.73 ± 5.40 , K1 için 60.35 ± 4.75 en kötü test SD'si K6 için 54.22 ± 6.84 , K8 için 33.88 ± 4.80 , K8 için 29.01 ± 3.90 olarak hesaplanmıştır. *ROA* sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için en iyi-en kötü test SD'si K1-K3 için 64.51 ± 5.55 -% 42.65 ± 4.53 , K1-K5 için 65.08 ± 5.10 -% 42.26 ± 4.12 arasında değişmektedir. EEG, Deoxy ve Oxy modalitesi için ise sırasıyla en iyi-en kötü test SD'si K3-K6 için 84.69 ± 4.66 -% 70.92 ± 4.97 , K1-K8 için 77.31 ± 4.37 -% 37.81 ± 4.11 , K1-K8 için 76.61 ± 5.34 -% 30.51 ± 4.13 arasında değişmektedir.

4.8 sn zaman bölütlerinden çıkarılan BG tabanlı özneliklerin her bir kişi için sırasıyla *k-EYK*, *DVM*, *KAY* ve *ROA* ile sınıflandırılması ile 50 koşum sonucu ortalama eğitim ve test SD sonuçları her bir modalite için Şekil 3.7'de kişi bazlı bar grafiğinde verilmiştir. Şekil 3.7'de görüldüğü gibi *k-EYK* sınıflandırıcısı ile EEG+Deoxy, EEG+Oxy modalitesi için en iyi test SD'si sırasıyla K8 için 88.31 ± 4.73 , 88.70 ± 4.41 en kötü test SD ise K4 için 78.61 ± 4.53 , 77.28 ± 5.35 olarak hesaplanmıştır. Diğer yandan EEG, Deoxy ve Oxy modalitesi için ise sırasıyla K1 için 75.86 ± 3.95 , K7 için 63.35 ± 4.97 , K4 için


%50.78±4.77 en kötü test SD'si K4 için %67.18±5.35, K5 için %29.80±3.77, K5 için %29.91±3.63 olarak hesaplanmıştır. DVM sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için en iyi-en kötü test SD'si K1-K4 için %87.86±3.55-%76.83±3.77, K1-K4 için %87.70±3.89-%77.00±3.79 arasında değişmektedir. EEG, Deoxy ve Oxy modalitesi için ise sırasıyla en iyi-en kötü test SD'si K1-K4 için %83.62±3.31-%74.00±3.79, K7-K5 için %69.78±4.35-%31.75±4.44, K1-K5 için %51.71±3.44-%31.15±2.70 arasında değişmektedir. KAY ile EEG+Deoxy, EEG+Oxy modalitesi için en iyi test SD'si sırasıyla K7 için %43.73±4.42, K8 için %51.10±4.46 en kötü test SD ise K5 için %33.95±5.74, K5 için %33.81±5.93 olarak hesaplanırken EEG, Deoxy ve Oxy modalitesi için ise sırasıyla K1 için %59.91± 4.60, K7 için %46.43±5.68, K1 için %49.80±5.00 en kötü test SD'si K6 için %54.78±5.13, K5 için %34.75±4.77, K5 için %27.88±3.93 olarak hesaplanmıştır. ROA sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için en iyi-en kötü test SD'si K6-K5 için %57.35±6.12-%39.01±5.75, K1-K5 için %57.21±5.98-%43.26±6.43 arasında değişmektedir. EEG, Deoxy ve Oxy modalitesi için ise sırasıyla en iyi-en kötü test SD'si K5-K4 için %82.95±4.81-%74.27±5.66, K7-K5 için %66.80±5.76-%38.31±4.86, K1-K5 için %67.45±4.79-%31.20±4.28 arasında değişmektedir. Tüm bunlara ek olarak, 4.8 sn zaman bölütlerinden çıkarılan HWHD ve İÖ tabanlı özneliliklerin her bir kişi için sırasıyla k-EYK, DVM, KAY ve ROA ile sınıflandırılması ile 50 koşum sonucu ortalama eğitim ve test SD sonuçları her bir modalite için Şekil 3.8 ve 3.9'te kişi bazlı bar grafiğinde verilmiştir.




Şekil 3.6. 4.8 sn zaman bölütlerinden çıkarılan HD tabanlı öznitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.7. 4.8 sn zaman bölütlerinden çıkarılan BG tabanlı öz nitelikler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.8. 4.8 sn zaman bölütlerinden çıkarılan HWHD tabanlı öznelilikler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.9. 4.8 sn zaman bölütlerinden çıkarılan İÖ ile 50 koşum sonucu ortalama eğitim ve test SD'si

Her bir sınıflandırıcı ve modalite için 4.8 sn zaman bölütlerinden çıkarılan HD, BG, HWHD ve İÖ öznitelikleri kullanılarak hesaplanan 8 kişinin ortalama eğitim ve test SD'si Şekil 3.10'daki radar grafiklerinde gösterilmiştir. Burada HD öznitelikleri için en iyi test SD'si EEG+Deoxy modalitesi ile 85.00 ± 4.01 olarak, BG öznitelikleri için EEG+Oxy modalitesi ile 85.40 ± 4.19 , HWHD öznitelikleri için EEG+Oxy modalitesi ile 48.60 ± 3.80 , İÖ için EEG+Deoxy modalitesi ile 42.10 ± 3.99 olarak hesaplanmıştır. Bu sonuçlar incelendiğinde en iyi sonuçların HD tabanlı öznitelikleri kullanarak ulaşıldığı görülmektedir. Bundan dolayı, her bir modalite için 4.8 sn zaman bölütlerinden çıkarılan HD tabanlı özniteliklerine uygulanan her bir sınıflandırıcı sonucu 8 kişinin ortalama test SD'si Tablo 3.4'te ayrıntılı olarak gösterilmiştir. Tablo 3.4'te görüldüğü gibi her bir modaliteyi SD açısından karşılaştırdığımızda en iyi sonuçlar EEG+Oxy modalitesi ile 87.00 ± 3.67 olarak elde edilmiştir. Her bir modalite için 4.8 sn zaman bölütlerinden çıkarılan HD'nin yanı sıra BG, HWHD ve İÖ tabanlı özniteliklerinin DVM ile sınıflandırılması sonucu hesaplanan 8 kişinin ortalama test SD'si Tablo 3.5'te gösterilmiştir.

Tablo 3.4. 4.8 sn zaman bölütlerinden çıkarılan HD tabanlı özniteliklerin sınıflandırılması ile elde edilen 8 kişinin ortalama test SD'si

Modalite	k-EYK	DVM	KA	ROA
EEG+Deoxy	85.00 ± 4.01	86.92 ± 3.52	43.67 ± 4.97	53.86 ± 5.55
EEG+Oxy	85.40 ± 4.19	87.00 ± 3.67	40.71 ± 6.43	49.09 ± 6.16
EEG	74.27 ± 4.48	82.52 ± 3.62	57.49 ± 3.98	78.28 ± 4.79
Oxy	44.90 ± 4.26	49.11 ± 4.09	37.07 ± 4.24	44.09 ± 4.97
Deoxy	63.27 ± 4.45	67.51 ± 4.09	47.11 ± 4.97	61.32 ± 4.81

Tablo 3.5. 4.8 sn zaman bölütlerinden çıkarılan BG, HWHD ve İÖ tabanlı özniteliklerin DVM ile sınıflandırılması sonucu hesaplanan 8 kişinin ortalama test SD'si

Modalite	BG	HWHD	İÖ
EEG+Deoxy	83.48 ± 3.59	48.35 ± 3.85	42.10 ± 3.99
EEG+Oxy	83.84 ± 3.62	48.60 ± 3.80	41.96 ± 4.10
EEG	79.66 ± 3.44	47.18 ± 2.96	40.78 ± 2.93
Oxy	41.03 ± 3.77	25.35 ± 3.22	24.84 ± 3.51
Deoxy	42.88 ± 4.19	25.71 ± 3.43	24.81 ± 3.70




Şekil 3.10. 4.8 sn zaman bölütlerinden çıkarılan öz niteliklerinin sınıflandırılması ile 8 kişi için hesaplanan ortalama eğitim ve test SD'si radar grafikleri

3.3. 12 Saniye Zaman Bölütü ile Elde Edilen Bulgular


12 sn zaman bölütlerinden çıkarılan HD tabanlı özniteliklerin her bir kişi için sırasıyla *k*-EYK, DVM, KAY ve ROA ile sınıflandırılması ile 50 koşum sonucu ortalama eğitim ve test SD sonuçları her bir modalite için Şekil 3.11’de kişi bazlı bar grafiğinde verilmiştir. Şekil 3.11’de görüldüğü gibi *k*-EYK sınıflandırıcısı ile EEG+Deoxy, EEG+Oxy modalitesi için test SD’si sırasıyla 16.85 ± 3.70 - 13.02 ± 3.06 ve 15.90 ± 3.69 - 12.80 ± 2.82 arasında değişirken EEG, Deoxy ve Oxy modalitesi için ise sırasıyla 16.85 ± 4.37 - 13.00 ± 2.82 , 32.20 ± 4.60 - 25.55 ± 4.24 ve 30.02 ± 4.54 - 25.40 ± 4.63 arasında değişmektedir. DVM sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için test SD’si 46.10 ± 5.95 - 40.60 ± 5.09 , 44.72 ± 5.71 - 37.50 ± 4.93 arasında değişmektedir. EEG, Deoxy ve Oxy modalitesi için ise sırasıyla test SD’si 44.40 ± 5.03 - 38.85 ± 4.93 , 47.50 ± 5.96 - 27.30 ± 4.12 ve 40.85 ± 4.59 - 27.10 ± 4.70 arasında değişmektedir. KAY ile EEG+Deoxy, EEG+Oxy modalitesi için en iyi test SD’si sırasıyla 30.55 ± 5.38 - 25.85 ± 4.77 ve 30.42 ± 4.38 - 23.32 ± 3.97 arasında değişirken EEG, Deoxy ve Oxy modalitesi için ise sırasıyla 31.75 ± 4.25 - 27.92 ± 4.32 , 33.25 ± 5.76 - 27.62 ± 5.10 ve 33.15 ± 5.38 - 24.80 ± 3.65 arasında değişmektedir. ROA sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için test SD’si sırasıyla 30.57 ± 2.00 - 24.60 ± 4.85 ve 28.35 ± 4.82 - 23.62 ± 4.89 arasında değişirken EEG, Deoxy ve Oxy modalitesi için ise sırasıyla 45.22 ± 5.84 - 36.10 ± 4.39 , 39.92 ± 5.55 - 29.60 ± 4.67 ve 41.32 ± 6.51 - 26.45 ± 4.70 arasında değişmektedir. 12 sn zaman bölütlerinden çıkarılan BG tabanlı özniteliklerin her bir kişi için sırasıyla *k*-EYK, DVM, KAY ve ROA ile sınıflandırılması ile 50 koşum sonucu ortalama eğitim ve test SD sonuçları her bir modalite için Şekil 3.12’de kişi bazlı bar grafiğinde verilmiştir. Şekil 3.12’de görüldüğü gibi *k*-EYK sınıflandırıcısı ile EEG+Deoxy, EEG+Oxy modalitesi için test SD’si sırasıyla 15.97 ± 4.13 - 12.92 ± 3.62 ve 16.30 ± 4.06 - 13.17 ± 3.81 arasında değişirken EEG, Deoxy ve Oxy modalitesi için ise sırasıyla 16.92 ± 3.81 - 12.70 ± 3.81 , 28.82 ± 5.21 - 23.55 ± 4.81 ve 31.37 ± 4.40 - 23.90 ± 3.86 arasında değişmektedir. DVM sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için test SD’si 45.12 ± 6.62 - 41.35 ± 6.67 , 45.90 ± 5.98 - 41.45 ± 4.60 arasında değişmektedir. EEG, Deoxy ve Oxy modalitesi için ise sırasıyla test SD’si 46.12 ± 6.54 - 42.10 ± 4.60 , 35.10 ± 5.11 - 23.42 ± 4.81 ve 30.92 ± 5.19 - 24.82 ± 3.49 arasında değişmektedir. KAY ile EEG+Deoxy, EEG+Oxy modalitesi için en iyi test SD’si sırasıyla 27.67 ± 4.30 - 24.45 ± 4.65 ve

%28.97±4.99-23.07±4.34 arasında değişirken EEG, Deoxy ve Oxy modalitesi için ise sırasıyla %31.92±5.26-27.80±4.29, %29.95±4.69-24.95±5.18 ve %30.40±4.85-23.20±4.07 arasında değişmektedir. ROA sınıflandırıcısı ile hesaplanan kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy modalitesi için test SD'si %26.90±5.41-24.15±4.58 ve %28.95±5.11-23.20±4.32, EEG, Deoxy ve Oxy modalitesi için ise sırasıyla test SD'si %46.42±6.30-40.40±4.53, %31.72±5.17-26.60±4.71 ve %32.42±5.13-23.75±4.06 arasında değişmektedir. Tüm bunlara ek olarak, 12 sn zaman bölütlerinden çıkarılan HWHD ve İÖ tabanlı özniteliklerin her bir kişi için sırasıyla *k*-EYK, DVM, KAY ve ROA ile sınıflandırılması ile 50 koşum sonucu ortalama eğitim ve test SD sonuçları her bir modalite için Şekil 3.13 ve 3.14'te kişi bazlı bar grafiğinde verilmiştir.







Şekil 3.11. 12 sn zaman bölütlerinden çıkarılan HD tabanlı öznelilikler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.12. 12 sn zaman bölütlerinden çıkarılan BG tabanlı öznelilikler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.13. 12 sn zaman bölütlerinden çıkarılan HWHD tabanlı öznelilikler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.14. 12 sn zaman bölütlerinden çıkarılan İÖ ile 50 koşum sonucu ortalama eğitim ve test SD'si


Her bir sınıflandırıcı ve modalite için 4.8 sn zaman bölütlerinden çıkarılan HD, BG, HWHD ve İÖ öznitelikleri kullanılarak hesaplanan 8 kişinin ortalama eğitim ve test SD'si Şekil 3.15'teki radar grafiklerinde gösterilmiştir. Burada HD öznitelikleri için en iyi test SD'si EEG+Deoxy modalitesi ile 43.73 ± 5.74 olarak, BG öznitelikleri için EEG+Oxy modalitesi ile 44.18 ± 5.68 , HWHD öznitelikleri için EEG+Deoxy modalitesi ile 31.28 ± 4.75 , İÖ için EEG+Deoxy modalitesi ile 25.17 ± 4.33 olarak hesaplanmıştır. Bu sonuçlar incelendiğinde en iyi sonuçların BG tabanlı öznitelikleri kullanarak ulaşıldığı görülmektedir. Bundan dolayı, her bir modalite için 12 sn zaman bölütlerinden çıkarılan BG tabanlı özniteliklere her bir sınıflandırıcı uygulanması ile hesaplanan 8 kişinin ortalama test SD'si Tablo 3.6'da ayrıntılı olarak gösterilmiştir. Tablo 3.6'da görüldüğü gibi her bir modaliteyi SD açısından karşılaştırdığımızda en iyi sonuçlar EEG+Oxy modalitesi ile 44.18 ± 5.68 olarak elde edilmiştir. Her bir modalite için 12 sn zaman bölütlerinden çıkarılan HD, HWHD ve İÖ tabanlı özniteliklerinin DVM ile sınıflandırılması sonucu hesaplanan 8 kişinin ortalama test SD'si Tablo 3.7'de gösterilmiştir.

Tablo 3.6. 12 sn zaman bölütlerinden çıkarılan BG tabanlı özniteliklerin sınıflandırılması ile elde edilen 8 kişinin ortalama test SD'si

Modalite	k-EYK	DVM	KA	ROA
EEG+Deoxy	14.18 ± 3.38	43.34 ± 5.92	26.24 ± 4.54	25.82 ± 4.75
EEG+Oxy	14.62 ± 3.96	44.18 ± 5.68	26.18 ± 4.69	25.33 ± 4.83
EEG	14.46 ± 3.58	44.17 ± 5.89	30.42 ± 4.97	42.40 ± 6.05
Oxy	26.48 ± 4.63	28.45 ± 4.53	27.58 ± 4.68	28.49 ± 4.82
Deoxy	26.20 ± 4.48	29.49 ± 4.56	27.83 ± 5.06	29.70 ± 5.00

Tablo 3.7. 12 sn zaman bölütlerinden çıkarılan HD, HWHD ve İÖ tabanlı özniteliklerden hesaplanan DVM sınıflandırıcı ile hesaplanan 8 kişinin ortalama test SD'si

Modalite	HD	HWHD	İÖ
EEG+Deoxy	43.73 ± 5.74	31.28 ± 4.75	25.17 ± 4.33
EEG+Oxy	42.90 ± 5.93	31.10 ± 4.54	24.88 ± 4.51
EEG	42.78 ± 5.84	31.24 ± 4.51	25.42 ± 4.42
Oxy	32.27 ± 4.52	26.29 ± 3.83	26.21 ± 3.91
Deoxy	38.50 ± 4.99	24.93 ± 4.02	24.15 ± 3.92



Şekil 3.15. 12 sn zaman bölütlerinden çıkarılan özneliklerinin sınıflandırılması ile 8 kişi için hesaplanan ortalama eğitim ve test SD'si radar grafikleri


3.4. 24 Saniye Zaman Bölütü ile Elde Edilen Bulgular

24 sn zaman bölütlerinden çıkarılan HD tabanlı özniteliklerin her bir kişi için sırasıyla *k*-EYK, DVM, KAY ve ROA ile sınıflandırılması ile 50 koşum sonucu ortalama eğitim ve test SD sonuçları her bir modalite için Şekil 3.16’da BG tabanlı öznitelikler için Şekil 3.17’de, HWHD tabanlı öznitelikler için Şekil 3.18’de, İÖ tabanlı sonuçlar için ise Şekil 3.19’da gösterilmiştir.


Her bir sınıflandırıcı ve modalite için 12 sn zaman bölütlerinden çıkarılan HD, BG, HWHD ve İÖ özniteliklerinin kullanılması ile hesaplanan 8 kişinin ortalama eğitim ve test SD’si Şekil 3.20’deki radar grafiklerinde gösterilmiştir. Burada BG öznitelikleri için en iyi test SD’si EEG+Deoxy modalitesi ile 24.27 ± 6.15 olarak hesaplanmıştır. Sonuçlar her bir modalite için 24 sn zaman bölütlerinden çıkarılan BG tabanlı özniteliklerin her bir sınıflandırıcıya uygulanması ile elde edilen 8 kişinin ortalama test SD’si Tablo 3.8’de ayrıntılı olarak gösterilmiştir. Burada görüldüğü gibi diğer zaman bölütlerine kıyasla test SD’si düşük seviyelerde kalmaktadır.

Tablo 3.8. 24 sn zaman bölütlerinden çıkarılan BG tabanlı özniteliklerin sınıflandırılması ile elde edilen 8 kişinin ortalama test SD’si


Modalite	<i>k</i> -EYK	DVM	KA	ROA
EEG+Deoxy	19.02±5.66	16.61±4.72	24.27±6.15	23.26±6.59
EEG+Oxy	18.90±5.53	16.11±4.60	24.13±6.61	23.74±6.55
EEG	19.03±5.71	16.57±4.99	24.29±6.36	22.98±6.49
Oxy	25.29±6.03	25.99±5.47	25.29±6.37	25.43±6.56
Deoxy	24.26±5.86	23.99±5.76	24.50±6.35	24.71±6.66




Şekil 3.16. 24 sn zaman bölütlerinden çıkarılan HD tabanlı öznelilikler ile 50 koşum sonucu ortalama eğitim ve test SD'si




Şekil 3.17. 24 sn zaman bölütlerinden çıkarılan BG tabanlı öznelilikler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.18. 24 sn zaman bölütlerinden çıkarılan HWHD tabanlı öznelilikler ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.19. 24 sn zaman bölütlerinden çıkarılan İÖ ile 50 koşum sonucu ortalama eğitim ve test SD'si



Şekil 3.20. 24 sn zaman bölütlerinden çıkarılan öznelitliklerinin sınıflandırılması ile 8 kişi için hesaplanan ortalama eğitim ve test SD'si radar grafikleri

Hesaplanan sonuçlar incelendiğinde performansı en iyi metotların öznetelik açısından HD sınıflandırıcı açısından ise *k*-EYK olduğu, sinyal uzunluğu açısından ise 2.4 sn zaman bölümlü sinyaller için etkin olduğu görülmektedir. Performansın en iyi olduğu EEG+Oxy modalitesi için kişi bazlı test hata matrisi sonuçları K1, K2, K3, K4, K5, K6, K7 ve K8 için sırasıyla Tablo 3.9, 3.10, 3.11, 3.12, 3.13, 3.14, 3.15 ve 3.16’da gösterilmiştir. Bu tablolardaki hata matrisleri SD açısından yorumlandığında K1 için ortalama 98.11 ± 1.04 , K2 için 95.28 ± 1.33 , K3 için 98.48 ± 1.33 , K4 için 93.16 ± 1.60 , K5 için 97.38 ± 1.27 , K6 için 92.95 ± 1.50 , K7 için 97.34 ± 1.29 ve K8 için 97.55 ± 1.07 olarak hesaplanmıştır. Hata matrisleri her bir sınıf için 80 test denemesinin 50 koşum sonucu ortalama sınıflandırma sayısını göstermektedir. Tablo 3.9’te ortalama 78.74 tane S1 etiketli denemeler doğru etiketlenmişken S1 etiketli ortalama 0.30 deneme S2, 1.04 deneme S3, 0.78 deneme S4 olarak yanlış etiketlenmiştir. Buna ek olarak ortalama 79.54 tane S2 etiketli denemeler doğru etiketlenmişken S2 etiketli ortalama 0.64 deneme S1, 0.20 deneme S3, 0.56 deneme S4 olarak yanlış etiketlenmiştir. Ayrıca, ortalama 78.72 tane S3 etiketli denemeler doğru etiketlenmişken S3 etiketli ortalama 0.02 deneme S1, 0.16 deneme S2, 1.70 deneme S4 olarak yanlış etiketlenmiştir. Son olarak, ortalama 76.96 tane S4 etiketli denemeler doğru etiketlenmişken S4 etiketli ortalama 0.60 deneme S1, 0.00 deneme S2, 0.04 deneme S3 olarak yanlış etiketlenmiştir.

Tablo 3.9. K1 için hata matrisi

Hata Matrisi (K1)		Tahmini Sınıf			
		S1	S2	S3	S4
Gerçek Sınıf	S1	78.74	0.64	0.02	0.60
	S2	0.30	79.54	0.16	0.00
	S3	1.04	0.20	78.72	0.04
	S4	0.78	0.56	1.70	76.96

Tablo 3.10’da ortalama 77.94 tane S1 etiketli denemeler doğru etiketlenmişken S1 etiketli ortalama 2.26 deneme S2, 1.74 deneme S3, 1.56 deneme S4 olarak yanlış etiketlenmiştir. Buna ek olarak ortalama 75.74 tane S2 etiketli denemeler doğru etiketlenmişken S2 etiketli ortalama 0.58 deneme S1, 2.42 deneme S3, 1.10 deneme S4 olarak yanlış etiketlenmiştir. Ayrıca, ortalama 75.60 tane S3 etiketli denemeler doğru etiketlenmişken S3 etiketli ortalama 0.54 deneme S1, 1.72 deneme S2, 1.72 deneme S4 olarak yanlış etiketlenmiştir. Son olarak, ortalama 75.62 tane S4 etiketli denemeler doğru

etiketlenmişken S4 etiketli ortalama 0.94 deneme S1, 0.28 deneme S2, 0.24 deneme S3 olarak yanlış etiketlenmiştir.

Tablo 3.10. K2 için hata matrisi

Hata Matrisi (K2)		Tahmini Sınıf			
		S1	S2	S3	S4
Gerçek Sınıf	S1	77.94	0.58	0.54	0.94
	S2	2.26	75.74	1.72	0.28
	S3	1.74	2.42	75.60	0.24
	S4	1.56	1.10	1.72	75.62

Tablo 3.11’de ortalama 79.56 tane S1 etiketli denemeler doğru etiketlenmişken S1 etiketli ortalama 0.32 deneme S2, 0.52 deneme S3, 0.44 deneme S4 olarak yanlış etiketlenmiştir. Buna ek olarak ortalama 79.22 tane S2 etiketli denemeler doğru etiketlenmişken S2 etiketli ortalama 0.04 deneme S1, 0.58 deneme S3, 0.88 deneme S4 olarak yanlış etiketlenmiştir. Ayrıca, ortalama 78.84 tane S3 etiketli denemeler doğru etiketlenmişken S3 etiketli ortalama 0.00 deneme S1, 0.20 deneme S2, 1.18 deneme S4 olarak yanlış etiketlenmiştir. Son olarak, ortalama 77.50 tane S4 etiketli denemeler doğru etiketlenmişken S4 etiketli ortalama 0.40 deneme S1, 0.26 deneme S2, 0.06 deneme S3 olarak yanlış etiketlenmiştir.

Tablo 3.11. K3 için hata matrisi

Hata Matrisi (K3)		Tahmini Sınıf			
		S1	S2	S3	S4
Gerçek Sınıf	S1	79.56	0.04	0.00	0.40
	S2	0.32	79.22	0.20	0.26
	S3	0.52	0.58	78.84	0.06
	S4	0.44	0.88	1.18	77.50

Tablo 3.12’de ortalama 77.08 tane S1 etiketli denemeler doğru etiketlenmişken S1 etiketli ortalama 1.44 deneme S2, 0.56 deneme S3, 4.68 deneme S4 olarak yanlış etiketlenmiştir. Buna ek olarak ortalama 76.36 tane S2 etiketli denemeler doğru etiketlenmişken S2 etiketli ortalama 0.50 deneme S1, 2.24 deneme S3, 2.94 deneme S4 olarak yanlış etiketlenmiştir. Ayrıca, ortalama 75.84 tane S3 etiketli denemeler doğru etiketlenmişken S3 etiketli ortalama 0.70 deneme S1, 0.98 deneme S2, 3.54 deneme S4 olarak yanlış etiketlenmiştir. Son olarak, ortalama 68.84 tane S4 etiketli denemeler doğru

etiketlenmişken S4 etiketli ortalama 1.72 deneme S1, 1.22 deneme S2, 1.36 deneme S3 olarak yanlış etiketlenmiştir.

Tablo 3.12. K4 için hata matrisi

Hata Matrisi (K4)		Tahmini Sınıf			
		S1	S2	S3	S4
Gerçek Sınıf	S1	77.08	0.50	0.70	1.72
	S2	1.44	76.36	0.98	1.22
	S3	0.56	2.24	75.84	1.36
	S4	4.68	2.94	3.54	68.84

Tablo 3.13'te ortalama 79.16 tane S1 etiketli denemeler doğru etiketlenmişken S1 etiketli ortalama 1.64 deneme S2, 1.28 deneme S3, 1.28 deneme S4 olarak yanlış etiketlenmiştir. Buna ek olarak ortalama 77.52 tane S2 etiketli denemeler doğru etiketlenmişken S2 etiketli ortalama 0.54 deneme S1, 0.98 deneme S3, 1.32 deneme S4 olarak yanlış etiketlenmiştir. Ayrıca, ortalama 77.50 tane S3 etiketli denemeler doğru etiketlenmişken S3 etiketli ortalama 0.20 deneme S1, 0.22 deneme S2, 0.66 deneme S4 olarak yanlış etiketlenmiştir. Son olarak, ortalama 77.42 tane S4 etiketli denemeler doğru etiketlenmişken S4 etiketli ortalama 0.10 deneme S1, 0.62 deneme S2, 0.24 deneme S3 olarak yanlış etiketlenmiştir.

Tablo 3.13. K5 için hata matrisi

Hata Matrisi (K5)		Tahmini Sınıf			
		S1	S2	S3	S4
Gerçek Sınıf	S1	79.16	0.54	0.20	0.10
	S2	1.64	77.52	0.22	0.62
	S3	1.28	0.98	77.50	0.24
	S4	0.60	1.32	0.66	77.42

Tablo 3.14'te ortalama 76.50 tane S1 etiketli denemeler doğru etiketlenmişken S1 etiketli ortalama 4.28 deneme S2, 0.90 deneme S3, 3.62 deneme S4 olarak yanlış etiketlenmiştir. Buna ek olarak ortalama 74.46 tane S2 etiketli denemeler doğru etiketlenmişken S2 etiketli ortalama 1.04 deneme S1, 2.02 deneme S3, 2.66 deneme S4 olarak yanlış etiketlenmiştir. Ayrıca, ortalama 76.32 tane S3 etiketli denemeler doğru etiketlenmişken S3 etiketli ortalama 0.56 deneme S1, 0.48 deneme S2, 3.56 deneme S4 olarak yanlış etiketlenmiştir. Son olarak, ortalama 70.16 tane S4 etiketli denemeler doğru

etiketlenmişken S4 etiketli ortalama 1.90 deneme S1, 0.78 deneme S2, 0.76 deneme S3 olarak yanlış etiketlenmiştir.

Tablo 3.14. K6 için hata matrisi

Hata Matrisi (K6)		Tahmini Sınıf			
		S1	S2	S3	S4
Gerçek Sınıf	S1	76.50	1.04	0.56	1.90
	S2	4.28	74.46	0.48	0.78
	S3	0.90	2.02	76.32	0.76
	S4	3.62	2.66	3.56	70.16

Tablo 3.15’te ortalama 78.38 tane S1 etiketli denemeler doğru etiketlenmişken S1 etiketli ortalama 1.18 deneme S2, 0.38 deneme S3, 1.04 deneme S4 olarak yanlış etiketlenmiştir. Buna ek olarak ortalama 78.42 tane S2 etiketli denemeler doğru etiketlenmişken S2 etiketli ortalama 1.10 deneme S1, 0.76 deneme S3, 1.74 deneme S4 olarak yanlış etiketlenmiştir. Ayrıca, ortalama 78.40 tane S3 etiketli denemeler doğru etiketlenmişken S3 etiketli ortalama 0.04 deneme S1, 0.20 deneme S2, 0.92 deneme S4 olarak yanlış etiketlenmiştir. Son olarak, ortalama 76.30 tane S4 etiketli denemeler doğru etiketlenmişken S4 etiketli ortalama 0.48 deneme S1, 0.20 deneme S2, 0.46 deneme S3 olarak yanlış etiketlenmiştir.

Tablo 3.15. K7 için hata matrisi

Hata Matrisi (K7)		Tahmini Sınıf			
		S1	S2	S3	S4
Gerçek Sınıf	S1	78.38	1.10	0.04	0.48
	S2	1.18	78.42	0.20	0.20
	S3	0.38	0.76	78.40	0.46
	S4	1.04	1.74	0.92	76.30

Tablo 3.16’da ortalama 78.66 tane S1 etiketli denemeler doğru etiketlenmişken S1 etiketli ortalama 0.88 deneme S2, 0.16 deneme S3, 1.76 deneme S4 olarak yanlış etiketlenmiştir. Buna ek olarak ortalama 78.48 tane S2 etiketli denemeler doğru etiketlenmişken S2 etiketli ortalama 0.74 deneme S1, 1.00 deneme S3, 0.46 deneme S4 olarak yanlış etiketlenmiştir. Ayrıca, ortalama 78.74 tane S3 etiketli denemeler doğru etiketlenmişken S3 etiketli ortalama 0.24 deneme S1, 0.50 deneme S2, 1.50 deneme S4 olarak yanlış etiketlenmiştir. Son olarak, ortalama 76.28 tane S4 etiketli denemeler doğru

etiketlenmişken S4 etiketli ortalama 0.36 deneme S1, 0.14 deneme S2, 0.10 deneme S3 olarak yanlış etiketlenmiştir.

Tablo 3.16. K8 için hata matrisi

Hata Matrisi (K8)		Tahmini Sınıf			
		S1	S2	S3	S4
Gerçek Sınıf	S1	78.66	0.74	0.24	0.36
	S2	0.88	78.48	0.50	0.14
	S3	0.16	1.00	78.74	0.10
	S4	1.76	0.46	1.50	76.28

4. SONUÇLAR

BBA sistemleri arařtırmaları, engelli insanlara yardım ve rehabilitasyon için ilerleme kaydetmektedir. Bu sistemlerin giriř iřaretini oluřturan beyin verilerinin kaydedilme prosedürü, toplanması ve verileri yorumlamanın saęlam yollarını bulmak, bu arařtırmanın ayrılmaz bir parçası olmuřtur. EEG ve YKS tařınabilirlięi, invaziv olmaması ve dięer beyin görüntüleme tekniklerine kıyasla nispeten düşük maliyeti nedeniyle beyin aktivitelerini izlemek için en çok kullanılan teknolojiler arasındadır. EEG ve YKS'yi birleřtirmek, sınıflandırma doęruluęu, kontrol komutlarının sayısı ve yanıt süresi aęısından BBA performansını geliřtirdięi kanıtlanmış, iyi bilinen ve yerleřik bir metodolojidir. Farklı prosedürde hem EEG'yi hem de YKS'yi ięeren hibrit BBA arařtıran önemli arařtırmalar literatürde olmasına raęmen deney paradigması aęısından hala yeterince arařtırma yapılmamıřtır. Bu tez ęalıřmasında, yaygın olarak kullanılan sinyal iřleme ve makine öęrenimi algoritmalarına özel bir odaklanmanın yanı sıra kayan yazı okumaya dayalı deney paradigması yöntemi ile deney prosedürünün hibrit BBA sistemine olan potansiyel etkisi arařtırılmıřtır. Elde edilen sonuçlar ile kayan yazı okumaya dayalı deney paradigması ile hibrit bir EEG+YKS tabanlı BBA sistemi geliřtirme ęalıřmalarına ıřık tutulacaęı düşünölmektedir.

Verinin ęeřitli tekniklerle deęiřtirilerek yeniden sentetik veri oluřturma iřlemi veri artırımı olarak isimlendirilir. Deneme sayısı fazla veri kümesi ile ęalıřmak BBA performansını önemli ölçüde deęiřtirmektedir. Bu yüzden önerilen metottun iyi bir řekilde analiz edilmesinde veri artırma yöntemlerine bařvurulmuřtur. Tüm bunlara ek olarak kullanılan veri uzunluęu aęısından sistemin mümkün olduęunca ideal olması BBA sisteminin uygulanabilirlięini artırtmıřtır. Sonuç olarak zaman bölötleme ile veri artırımı yapmak hem eęitim ařamasında veri analizinin daha saęlıklı olmasını hem de BBA sistemi için daha hızlı komut ęıktısı saęlamıřtır.

Bu tez ęalıřmasında Karadeniz Teknik Üniversitesi FHD-2020-9166 nolu BAP projesi kapsamında alınan hizmet alımı ile Atatürk Üniversitesi/ Spor Bilimleri Fakölte 'sinde kaydedilen EEG+YKS veri kümesi ile ęalıřılmıřtır. Sınıflandırma doęruluęunu arttırmak için řekil 2.7'de yer alan metot, farklı boyutta zaman bölötleme ile veri artırımı yapılarak veri kümesine uygulanmıřtır. Farklı öznitelik ęıkarımı ve sınıflandırıcı algoritmalarının veri kümelerine uygulanması ile de sonuçlar karřılařtırılmıřtır. Bu yaklařımlar arasından bu tez

çalışması için önerilen yöntem, kayan yazı esnasında kaydedilen multimodal sinyallerin 2.4 sn zaman bölütlerinden çıkarılan HD tabanlı özniteliklerin *k*-EYK ile sınıflandırılmasıdır. Bu tez çalışmasında önerilen yöntem ile EEG+Oxy modalitesi ile en iyi sonuç 8 kişinin ortalaması için 96.28 ± 1.30 olarak hesap edilmiştir. 2.4 sn zaman bölütlü sonuçların verildiği Tablo 3.1'e bakıldığında tüm sınıflandırıcılar için en iyi sonucun *k*-EYK ve DVM için hibrit modalitede olduğu görülmektedir. Ancak, KAY ve ROA'sında EEG ile ulaşılan sonuçlar bu sınıflandırıcıların hibrit modalite sonuçlarına göre daha fazladır. Her sınıflandırıcının veri analizi esnasındaki veri etiketleme tepkisi kendi algoritmik mekanizmasına göre farklıdır. Bu açıdan bakıldığında her bir modalite için hesaplanan sonuçların tüm sınıflandırıcılar için aynı tepkide olması beklenmez. 2.4 sn zaman bölütlü sinyallere uygulanan farklı öznitelik çıkartma yöntemlerinin sonuçları ise Tablo 3.2'de verilmiştir. Tabloya bakıldığında her ne kadar HD tabanlı öznitelikler bu tez çalışması için önerilmiş olsa da BG tabanlı öznitelikler ile de etkin sonuçların elde edildiği görülmektedir. Bu tez çalışmasında önerilen 4 sınıflı deney paradigmasının hem HD hem de BG tabanlı öznitelik metotları ile yüksek sonuçlar vermesi önerilen paradigmanın ne denli ayırt edici nitelikte olduğunu göstermektedir.

Önerilen metot ile Şekil 3.1'de kişi bazlı sonuçlar incelendiğinde ise EEG+Deoxy, EEG+Oxy ve EEG modaliteleri için K1, K3, K5, K7 ve K8'in test SD sonuçları diğer kişilere göre daha iyi olduğu görülmektedir. Aynı modalitelerde K6 için test SD sonuçları nispeten daha düşüktür. Bunun sebebi ise kişinin deneye tam olarak odaklanmamasından kaynaklı olabilir.

4.8 sn zaman bölütlü sonuçlar için Bulgular kısmında yer alan Tablo 3.4'e bakıldığında sonuçların 2.4 sn zaman bölütlü sonuçlara göre nispeten daha düşük olduğu görülmektedir. Burada HD tabanlı öznitelikler ile *k*-EYK ile EEG+Oxy modalitesi için 85.40 ± 4.19 SD hesaplandığı görülmektedir. 2.4 sn zaman bölütlü sonuçlara göre bu modalite için sonuç 11.30 kadar düşmüştür. 2.4 sn zaman bölütlü sonuçlarda olduğu gibi yine burada da KAY ve ROA'sında tekli modalite olan EEG için hibrit modaliteye göre daha yüksek sonuçlar elde edilmiştir. 12 sn zaman bölütlü sonuçlar için Bulgular kısmında yer alan Tablo 3.6 incelendiğinde ise BG tabanlı öznitelikler ile DVM sınıflandırıcı kullanılarak ulaşılan en iyi test SD'nin EEG+Oxy modalitesi için 44.18 ± 5.68 olduğu görülmektedir. Önerilen metot ile kıyaslandığında bu zaman bölütüyle elde edilen test SD sonucu 54.11 kadar düşmüştür. Tablo 3.8'de 24 sn zaman bölütüyle hesaplanan sonuçlara göz atıldığında ise İÖ için EEG+Deoxy modalitesi ile en yüksek 24.27 ± 6.15 test SD'si elde edildiği görülmektedir.

Zaman bölütü, sn açısından büyüdükçe test SD'sinin giderek düştüğü hesaplanan sonuçlardan anlaşılmaktadır. Bu durum daha kısa sinyallerin daha etkin bilgiyi içermesi ve daha önemli özniteliklerin çıkarılmasına olanak tanimasından kaynaklanabilmektedir. Ayrıca, daha kısa bölütlü sinyallerin sınıflandırma algoritmasının daha güçlü bir örüntü tanımlama yapabilmesine ve daha doğru sonuçlar vermesine yardımcı olduğu düşünülmektedir. Tüm bunlara ek olarak bu durum daha kısa sinyal işlenmesiyle daha az hesaplama karmaşıklığı ve depolama alanı sağlar. Diğer taraftan BBA için daha hızlı komut üretmesi açısından önemli bir avantaj sağlamaktadır. Tüm bunlar değerlendirildiğinde farklı yönlere kayan yazıların okunmasına dayalı BBA sistemlerinde 2.4 sn'lik sinyal bölütlerinin kullanılmasının daha uygun olduğu anlaşılmaktadır.

Tüm bunlara ek olarak elde edilen tüm sonuçlar için hesaplanan standart sapma değerleri BULGULAR başlığında verilmiştir. Standart sapma, bir dizi değerlerin varyasyon veya dağılımını ifade etmektedir. Standart sapmanın küçük olması ulaşılan sonuçların ortalama etrafında gruplaştıklarını göstermektedir. Bu çalışmada önerilen yöntem ile ulaşılan sonuçların düşük standart sapmaya sahip olması veri analizinin sağlıklı yapıldığını göstermektedir.

Literatürde çeşitli deney paradigması içeren EEG+YKS veri kümeleri ile çalışılmıştır. Bu çalışmaların ayrıntılı bilgileri Tablo 1.1'de gösterilmektedir. Tablo 1.1'de görüldüğü gibi deneye katılan sayısı 6-29 arasında olan bu veri kümeleri deney paradigması açısından MHH, MU, ZA ve zihinsel stres ölçümü tabanlıdır. MHH tabanlı çalışmalarda genellikle sağa ve sola işaret hayali, ok hayali ve el hayali tabanlı çalışmalar yapılmışken MU tabanlı çalışmalarda genellikle bunların uygulaması gerçekleştirilmiştir. ZA tabanlı çalışmalar da ise çeşitli matematiksel işlem yapımı veya altı basamaklı sayıların ezberlenmesi gerçekleştirilirken, diğer bazı çalışmalarda zihinsel iş yükü ölçümü gerçekleştirilmiştir. Bu tez çalışmasında önerilen deney paradigması ise sağa, sola, aşağı ve yukarı kayan yazı okumaya dayalı deney paradigması olması açısından ve literatürde daha önce kullanılmamış olması bakımından özgünlük içermektedir. Tablo 1.1'de yer alan deneyler arasından özellikle seçim çözme amacıyla gerçekleştirilen 2015 ve sonrası çalışmaların sonucu Tablo 4.1'de özet olarak verilmiştir. Burada görüldüğü gibi işaretin ortalaması, varyansı veya standart sapması gibi literatürde yaygın olarak kullanılan metotlar öznitelik çıkartma aşamasında kullanılmıştır. Sınıflandırıcı metodu olarak ise yine literatürde yaygın olan DAA, DVM ve *k*-EYK metotları seçilmiştir. Tüm bunlara ek olarak çalışmaların çoğu 2 sınıflı olarak gerçekleştirilmiştir. Tüm bunlar göz önüne alındığında bu tez çalışmasında

özgün kaydedilen veri kümesi ile çalışarak literatüre katkı sunulmuştur. Ayrıca, öznitelik aşamasında HD'nin ve sınıflandırma aşamasında ise *k*-EYK gibi literatürde yaygın metotlar kullanılarak 4 sınıflı veri analizi gerçekleştirilmiştir ve önerilen metot ile 96.28 ± 1.30 SD hesaplanmıştır. Tablo 1.1'de görüldüğü gibi literatürde yapılan 4 sınıflı en iyi çalışmaya göre 16.97 SD daha fazla hesaplanmıştır. Ulaşılan bu başarılı sonuçlar, tez çalışmasında kaydedilen veri kümesinin etkinliğini ispat etmektedir.

Bu tez çalışmasında önerilen deney paradigmasında kaydedilen sinyallere ait önerilen öznitelik yöntemi ile bu çalışmada kullanılan diğer öznitelik yöntemleri süre açısından Tablo 1.1'de kıyaslanmıştır. Burada görüldüğü gibi tek EEG+YKS denemesi için öznitelik çıkartma süresi, önerilen metot ile 0.81 ms'dir. Bu sonuçlar hedeflenen BBA sisteminin daha hızlı ve etkin olacağını göstermektedir. Ayrıca, bu tez çalışmasında kaydedilen sağa, sola, yukarıya ve aşağıya kayan yazı okumaya dayalı veri kümesi belirli zaman dilimlerine bölütlenerek veri kümesinde artırım yapılarak etkin sonuçlara ulaşılmıştır. Bu sonuçlara göre EEG+YKS tabanlı BBA verilerinin tüm uzunluğu kullanılmadan etkin bilgiyi içeren optimum deneme sayısına sahip veri kümesi ile daha yüksek SD hesaplanmaktadır.

Bu tez çalışmasında öznitelik çıkartma aşamasında önerilen deney paradigmasındaki sinyallerin ayırt edilebilmesi için HD önerilmiştir. Bu algoritma uygulanırken hesaplanan HD'nin mutlak değerlerinin ortalaması hesaplanarak etkin öznitelikler bulunmuştur. Buna ek olarak HD'nin mutlak değerlerinin standart sapması da hesaplanarak önerilen öznitelik çıkartma bazında karşılaştırma yapılmıştır. 2.4, 4.8, 12 ve 24 sn zaman bölütlerinden çıkarılan HD'nin mutlak değerlerinin standart sapması tabanlı özniteliklerin tüm sınıflandırıcılar ile ortalama eğitim ve test SD sonuçları Ek-1'de sırasıyla Şekil Ek 1.1, Şekil Ek 1.2, Şekil Ek 1.3 ve Şekil Ek 1.4'te kişi bazlı bar grafiğinde verilmiştir. Ayrıca, Her bir sınıflandırıcı ve modalite için her bir zaman bölütlerinden çıkarılan HD'nin mutlak değerlerinin standart sapması öznitelikleri ile hesaplanan 8 kişinin ortalama eğitim ve test SD'si Şekil Ek 1.5'teki radar grafiklerinde gösterilmiştir. Burada hesaplanan en iyi sonuç EEG+Oxy modalitesi için 2.4 sn zaman bölütü ile ortalama 44.97 ± 2.76 test SD'si olarak hesaplanmıştır. Hesaplanan sonuç bu özneliğin bu veri kümesi için etkin olmadığını göstermektedir.

Tablo 4.1. Literatürde yer alan çalışmaların önerilen metot ile kıyaslanması

Referanslar	Deney İçeriği	YKS Öznitelikleri	EEG Öznitelikleri	Sınıflandırıcı	Frekans	Elektrot sayısı	Kontrol Sayısı	SD
(Lee vd., 2015)	MHH: Sağ ve sol el hareketi hayali	HbO ve HbR'nin Ortalama Genliği	OUÖ ve Logaritmik Güç	DAA	EEG:100 NIRS:6.25	EEG:37 NIRS:24	2	%61.30
(Buccino vd., 2016)	MHH: Sağ ve sol el hareketi hayali	HbO Sinyal Ortalaması ve Sinyal Eğimi	OUÖ	DAA	EEG:250 NIRS:10.42	EEG:21 NIRS:34	2	%94.20
(Ge vd., 2017)	MHH: Sağ ve sol el hareketi hayali	Hurst Üssü	OUÖ	DVM	EEG:1000 NIRS:28	EEG:64 NIRS: 52	2	%81.20
(Li vd., 2017)	MU: Sağ ve sol el hareketi	HbO ve HbR'nin Ortalaması (2 sn'lik zaman diliminde)	Dalgacık Dönüşümü Katsayısı	DVM	EEG:500 NIRS:7.81	EEG:18 NIRS:34	2	%91.02
(Shin vd., 2018b)	MI: Parmak hareketi hayali MA: Zihinsel işlem Dinlenme durumu	Eğim ve varyans	OUÖ'nün logaritmik varyansı	DAA	EEG:2.05 NIRS:13.3	EEG: 21 NIRS:16	3	%82.20
(Cicalese vd., 2020)	MA: Dört, beş ve altı basamaklı sayıların ezberlenmesi ve görev kısmında söylenmesi	Ortalama	Bant gücü	DAA	EEG:500 NIRS:3.91	EEG: 33 NIRS:46	4	%79.31
(Ergün ve Aydemir, 2022)	MHH: Sağ ve sol el hareketi hayali	FWHD	FWHD	k-EYK	EEG:200 NIRS:12.5	EEG: 30 NIRS:36	2	%78.21
(Nour vd., 2022)	MHH: Sağ ve sol el hareketi hayali	Çoklu bant genişliği analizi	Çoklu bant genişliği analizi	Evrişimsel sinir ağları	EEG:200 NIRS:12.5	EEG: 30 NIRS:36	2	%99.85
Önerilen Metot	Sağa, sola, yukarıya ve aşağıya kayan yazı okuma	Hilbert Dönüşümü	Hilbert Dönüşümü	k-EYK	EEG:250 NIRS:10.17	EEG: 31 NIRS:18	4	%96.28

Derin öğrenme, yapay sinir ağları ile bunun benzeri makine öğrenmesi algoritmalarını içine alan bir veya birden çok gizli katmanlı bir uygulama alanıdır. Yani bilgisayar en az bir yapay sinir ağı kullanarak ve bunu birçok algoritmadan geçerek veriyi işleyebilmektedir. Son yıllarda BBA uygulamaları için derin öğrenme yöntemlerinin kullanıldığı çalışmaların sayısı artmaktadır. BBA çalışmalarında derin öğrenme yöntemlerinin daha fazla araştırılmasının, bu yöntemleri BBA uygulamaları için uygun bir seçim haline getirebilmektedir. Bu yüzden bu çalışmada da LSTM (Uzun-Kısa Vadeli Bellek) temelli veri öğrenme mimarisi kullanılarak veri kümesi analiz edilmiştir. LSTM, uzun kısa süreli bellek derin öğrenme alanı için yapay bir yinelemeli sinir ağı mimarisidir. Standart ileri beslemeli sinir ağlarının aksine, LSTM'lerin geri besleme bağlantıları vardır. Yalnızca anlık verileri

değil, aynı zamanda veri dizilerini de işleyebilir. Veri dizilerine uygunluğu açısından bu çalışmada derin öğrenme mimarilerinden LSTM araştırılmıştır. Model tasarlanırken hiperparametrelerin optimum seçilmesi gerekmektedir. Bu çalışmada mini-batch boyutu 16, öğrenme hızı 10^{-4} , eğitim tur (epoch) sayısı 50, optimizasyon algoritması “adam” ve seyreltme (dropout) değeri 0.2 olarak seçilmiştir. Bu tez çalışmasında önerilen öz nitelik çıkartma metodu kullanılarak 8 kişi için EEG+Oxy modalitesi ile ortalama %26.01 eğitim %23.52 test EEG+Deoxy modalitesi ile ortalama %25.85 eğitim %23.36 test SD’si hesaplanmıştır. Ulaşılan sonuç bu veri kümesi için derin öğrenme mimari kullanımının etkin olmadığını göstermektedir. Derin öğrenme uygulamalarında veri setinin büyüklüğü ve çeşitliliği öğrenme için en önemli faktörlerden biridir. Bu tez çalışmasında kullanılan veri kümesi boyutunun düşük olması derin öğrenme mimarisinde kullanımı için dezavantaj yaratabilmektedir.

Bu tez çalışması, çok yönlü kayan yazı okumaya dayalı EEG+YKS tabanlı hibrit BBA sistemlerinin potansiyelini göstermektedir. Önerilen yöntemin BBA sistemleri üzerindeki performansını araştırmak için, bu tez sırasında çeşitli öz nitelik ve sınıflandırma yöntemleri kullanılarak analizler gerçekleştirilmiştir. Sonuçlar hem farklı metotlar hem de literatürdeki hibrit çalışmalar ile birçok açıdan karşılaştırılmıştır ve yöntemimizin çoğu durumda daha iyi sınıflandırma performansı sağladığı gösterilmiştir.

5. ÖNERİLER

Beyin fonksiyonunun kapsamlı bir resmini sağlamak için iki veya daha fazla beyin sinyali alıp analiz edebilen multimodal sistemler son yıllarda kullanılmaktadır. Özellikle nöronal elektriksel aktivite ve beyin hemodinamik aktivitesi gibi iki farklı fizyolojik süreci temsil eden iki yöntemi birleştirerek daha eksiksiz bir beyin görüntülemesi elde edilebilir. EEG, gönüllü katılımcının kafa derisine yerleştirilen elektrotları kullanarak beyin sinyallerini invaziv olmayan bir şekilde kaydederek beyin elektriksel aktivitesini değerlendirmek için en yaygın kullanılan yöntemlerden biridir. YKS ise düşük maliyetli, taşınabilir ve invaziv olmayan birçok avantaja sahip olması bakımından son yıllarda popüler olmaya başlamıştır. EEG ve YKS'nin avantajları, onları multimodal çalışmalar için en uygun teknikler haline getirmektedir. Multimodal bu veriler BBA için giriş işareti olarak kullanılırlar. BBA, bilgisayarları veya harici cihazları kontrol etmek için tek başına serebral aktiviteye izin veren bir donanım ve yazılım iletişim sistemidir. Bu sistemlerin temel amacı, amiotrofik lateral skleroz, beyin sapı felci veya omurilik yaralanması gibi nörolojik nöromüsküler bozukluklar nedeniyle tamamen felç olmuş veya "kilitlenmiş" ağır engelli kişilere iletişim yetenekleri sağlamaktır. Bu yüzden BBA sistemleri için kullanılan EEG+YKS işaretlerinin deney paradigması, uygulanan önışlem, öznelite ve sınıflandırma yöntemleri önemlidir. Bu tez çalışmasında 4 sınıflı sağa, sola, yukarıya ve aşağıya kayan yazı okumaya dayalı deney paradigmasını içeren veri kaydı başarılı bir şekilde gerçekleştirilmiştir. Elde edilen eğitim ve test SD sonuçlarının performansı ile bu gösterilmiştir. Gelecekte, sonuçların genellenebilmesinin artırımı için deneylerin daha fazla katılımcı üzerinde uygulanması gerekmektedir. Buna ek olarak, her ne kadar bu tez çalışmasında kaydedilen sınıf sayısı literatüre göre fazla olsa da BBA sisteminin uygulanma alanının artırılması açısından kontrol sayısının artırımı önemlidir.

Göz hareketinin neden olduğu eserler, beyin kayıtlı aktivite modellerini büyük ölçekte değiştiren bir sorun kaynağıdır. Bu tezde deneklerden kayıt sırasında gözlerini hareket ettirmemeleri istenmiştir. Ancak yine de bunun önüne geçilememektedir. Göz artefaktı günlük yaşamda BBA sisteminde kaçınılmazdır ve otomatik yöntemlerle üstesinden gelinmelidir. Şu anda, MHH çalışmalarında otomatik göz artefaktlarının çıkarılması için tam olarak başarılı bir yöntem bulunmamaktadır. Kayıt cihazlarındaki iyileştirmelerin, sinyal kalitesini iyileştirmeyi ve artefaktları ortadan kaldırmayı mümkün

kılacağına inanıyoruz. Bu iyileştirmeler, günlük hayatta kullanılabilecek daha başarılı BBA sistemlerine yol açacaktır. Beyin aktiviteleri esnasında kayıt alınan EEG+YKS verilerine ayrıca ortam ve çeşitli biyolojik etkiler olarak adlandırılan gürültüler de eklenebilir. Bu gürültüler verilerin işlenmesini zorlaştırabilir. Gerekli ön işleme yöntemiyle bu gürültülerin temizlenme işlemleri yapılmalıdır.

EEG+YKS veri kümesine uygulanacak öznitelik çıkartma kısmına gelindiğinde ise bunun için literatürde çeşitli matematiksel yöntemler yer almaktadır. Anlamlı öznitelikler sınıflandırma performansını doğrudan artırdığından öznitelik çıkarma, veri sınıflandırmasında en kritik öneme sahip adım haline gelmiştir. Beynin fizyolojik yapısından dolayı farklı kişilerden alınan EEG+YKS verileri aynı olmadığından hesaplanan özniteliklerde farklılık oluşturur. Buna ek olarak, EEG ve YKS modalitelerinin kayıt doğası farklı olduğundan bu modalitelere farklı metotlar uygulanabilir. Bu tez çalışmasında EEG+YKS veri kümesinden çıkarılan öznitelikleri değerlendirmek için birkaç sınıflandırma metodu kullanarak kıyaslama yapılmıştır. Bu sınıflandırıcılara ek olarak literatürde yer alan Genetik Algoritmalar, Yapay Sinir Ağları ve DAA gibi farklı türden sınıflandırıcılar da kullanılarak sonuçlar değerlendirilebilir. Ayrıca, kayıt alınan verinin hangi beyin bölgesinde etkin olduğu belirlenerek analiz için uygun elektrotlar seçilmelidir. Bu durum BBA sisteminin daha hızlı olmasını sağlayacaktır. Ancak, bu çalışmada kayıt esnasında kullanılan tüm elektrotların kullanılması ve seçimin otomatik olmayışı dezavantajlıdır. Bu yüzden elektrot sayısını hızlı ve otomatik bir şekilde belirleyen algoritma oluşturulabilir.

Tüm bunlara ek olarak, beyin hastalıklarını taramak için potansiyel bir araç olarak ağırlık, düşük güç tüketimi ve düşük maliyetli beyin izleme sistemlerinin önemi giderek artmaktadır. Yukarıdaki anlatılan tüm avantajlar ve dezavantajlar göz önünde bulundurarak, bu çalışmada kullanılan cihazı minyatürleştirerek, düşük maliyetli, hafif ve düşük güç tüketen entegre bir EEG+YKS beyin izleme sistemi tasarımı da gerçekleştirilebilir.

6. KAYNAKLAR

- Abiri, R., Borhani, S., Sellers, E. W., Jiang, Y., ve Zhao, X., 2019. A comprehensive review of EEG-based brain-computer interface paradigms, Journal of neural engineering, 16, 1, 1-11.
- Abisoye, O. A., Abisoye, B. O., Ekundayo, A., ve Ogunwede, E., 2019. Prediction of Epileptic Seizure using Support Vector Machine and Genetic Algorithm, 3rd International Engineering Conference Federal University of Technology, Eylül, Minna, Nigeria, Bildiriler Kitabı, 1-5.
- Abootalebi, V., Moradi, M. H., ve Khalilzadeh, M. A., 2009. A new approach for EEG feature extraction in P300-based lie detection, Computer methods and programs in biomedicine, 94, 1, 48-57.
- Aggarwal, S., ve Chugh, N., 2019. Signal processing techniques for motor imagery brain computer interface: A review, Array, 1, 1-3.
- Aghajani, H., Garbey, M., ve Omurtag, A., 2017. Measuring mental workload with EEG plus fNIRS, Frontiers in human neuroscience, 11, 359, 1-20.
- Ahn, S., Nguyen, T., Jang, H., Kim, J. G., ve Jun, S. C., 2016. Exploring neuro-physiological correlates of drivers' mental fatigue caused by sleep deprivation using simultaneous EEG, ECG, and fNIRS data, Frontiers in human neuroscience, 10, 219, 1-14.
- Akila, V., ve Christaline, J. A., 2020. A review of cognitive brain activation using near-infrared spectroscopy (NIRS), AIP Conference Proceedings, 2282, 1, 1-20.
- Al-azzawi, A. H. A. L., Al-Jumaili, S., Ibrahim, A. A., ve Duru, A. D., 2022. Classification of epileptic seizure features from scalp electrical measurements using KNN and SVM based on Fourier Transform, In AIP Conference Proceedings, 2499, 1, 1-3.
- Albaqami, H., Hassan, G. M., Subasi, A., ve Datta, A., 2021. Automatic detection of abnormal EEG signals using wavelet feature extraction and gradient boosting decision tree, Biomedical Signal Processing and Control, 70, 102957, 1-10.
- Aldayel, M., Ykhlef, M., ve Al-Nafjan, A., 2021. Recognition of consumer preference by analysis and classification EEG signals, Frontiers in Human Neuroscience, 14, 604639, 1-8.
- Al-Shargie, F., Kiguchi, M., Badruddin, N., Dass, S. C., Hani, A. F. M., ve Tang, T. B., 2016. Mental stress assessment using simultaneous measurement of EEG and fNIRS, Biomedical optics express, 7, 10, 3882-3898.
- Al-Quraishi, M. S., Elamvazuthi, I., Tang, T. B., Al-Qurishi, M., Adil, S. H., ve Ebrahim, M., 2021. Bimodal data fusion of simultaneous measurements of EEG and fNIRS during lower limb movements, Brain Sciences, 11, 6, 1-713.

- Andrew, C., ve Pfurtscheller, G., 1996. Event-related coherence as a tool for studying dynamic interaction of brain regions, Electroencephalography and clinical neurophysiology, 98, 2, 144-148.
- Anderson, C. W., ve Sijercic, Z., 1996. Classification of EEG signals from four subjects during five mental tasks, In Solving engineering problems with neural networks: proceedings of the conference on engineering applications in neural networks, Haziran, Türkiye, Bildiriler Kitabı, 407-414.
- Ang, K. K., Guan, C., Lee, K., Lee, J. Q., Nioka, S., ve Chance, B., 2010. A brain-computer interface for mental arithmetic task from single-trial near-infrared spectroscopy brain signals, In Pattern Recognition, Ağustos, İstanbul, Türkiye, Bildiriler Kitabı, 3764-3767.
- Arıcan, M., Polat, K., 2019. Pairwise and variance-based signal compression algorithm (PVBSC) in the P300 based speller systems using EEG signals, Computer methods and programs in biomedicine, 176, 149–157.
- Arpaia, P., Esposito, A., Natalizio, A., ve Parvis, M., 2022. How to successfully classify EEG in motor imagery BCI: a metrological analysis of the state of the art, Journal of Neural Engineering, 19, 3, 1-31.
- Aydemir, O., 2017. Olfactory recognition based on EEG gamma-band activity, Neural computation, 29, 6, 1667-1680.
- Aydemir, O., ve Ergün, E., 2019. A robust and subject-specific sequential forward search method for effective channel selection in brain computer interfaces, Journal of neuroscience methods, 313, 60-67.
- Aydemir, O., Saka, K., ve Ozturk, M., 2022. Investigating the effects of stimulus duration and inter-stimulus interval parameters on P300 based BCI application performance, Computer Methods in Biomechanics and Biomedical Engineering, 25, 14, 1545-1553.
- Aydemir, O., ve Kayikcioglu, T., 2011. Wavelet transform based classification of invasive brain computer interface data, Radioengineering, 20, 1, 31-38.
- Aznan, N. K. N., ve Yang, Y. M., 2013. Applying Kalman filter in EEG-based brain computer interface for motor imagery classification, In 2013 international conference on ICT convergence (ICTC), Ekim, Jeju, Korea, Bildiriler Kitabı, 688-690.
- Azilion, M., Makhalova, J., Zaaraoui, W., Medina Villalon, S., Viout, P., Roussel, T., ve Guye, M., 2023. Combining sodium MRI, proton MR spectroscopic imaging, and intracerebral EEG in epilepsy, Human Brain Mapping, 44, 2, 825-840.
- Bauernfeind, G., Scherer, R., Pfurtscheller, G., ve Neuper, C., 2011. Single-trial classification of antagonistic oxyhemoglobin responses during mental arithmetic, Medical & biological engineering & computing, 49, 9, 979.

- Bayliss, J. D., Inverso, S. A., ve Tentler, A., 2004. Changing the P300 brain computer interface, CyberPsychology & Behavior, 7, 6, 694-704.
- Bernal, J., Kushibar, K., Asfaw, D. S., Valverde, S., Oliver, A., Martí, R., ve Lladó, X., 2019. Deep convolutional neural networks for brain image analysis on magnetic resonance imaging: a review, Artificial intelligence in medicine, 95, 64-81.
- Bhuvaneswari, P., ve Kumar, J. S., 2013. Support vector machine technique for EEG signals, International Journal of Computer Applications, 63, 13, 1-11.
- Blasi, G., Goldberg, T. E., Weickert, T., Das, S., Kohn, P., Zolnick, B., ve Mattay, V. S., 2006. Brain regions underlying response inhibition and interference monitoring and suppression, European Journal of Neuroscience, 23, 6, 1658-1664.
- Brodu, N., Lotte, F., ve Lécuyer, A., 2011. Comparative study of band-power extraction techniques for motor imagery classification, 2011 IEEE symposium on computational intelligence, cognitive algorithms, mind, and brain (CCMB), Nisan, Paris, Fransa, Bildiriler Kitabı, 1-6.
- Blokland, Y., Spyrou, L., Thijssen, D., Eijsvogels, T., Colier, W., Floor-Westerdijk, M., vd., 2013. Combined EEG-fNIRS decoding of motor attempt and imagery for brain switch control: an offline study in patients with tetraplegia. IEEE transactions on neural systems and rehabilitation engineering, 22, 2, 222-229.
- Buccino, A. P., Keles, H. O., ve Omurtag, A., 2016. Hybrid EEG-fNIRS asynchronous brain-computer interface for multiple motor tasks, Plos One, 11, 1, 1-8.
- Cecotti, H., ve Graser, A., 2010. Convolutional neural networks for P300 detection with application to brain-computer interfaces, IEEE transactions on pattern analysis and machine intelligence, 33, 3, 433-445.
- Cecotti, H., 2011. A time-frequency convolutional neural network for the offline classification of steady-state visual evoked potential responses, Pattern Recognition Letters, 32, 8, 1145-1153.
- Cicalese, P. A., Li, R., Ahmadi, M. B., Wang, C., Francis, J. T., Selvaraj, S., ve Zhang, Y., 2020. An EEG-fNIRS hybridization technique in the four-class classification of alzheimer's disease, Journal of neuroscience methods, 336, 108-618.
- Chakladar, D. D., ve Chakraborty, S., 2019. Feature extraction and classification in brain-computer interfacing: Future research issues and challenges, Natural computing for unsupervised learning, 101-131.
- Chamola, V., Vineet, A., Nayyar, A., ve Hossain, E., 2020. Brain-computer interface-based humanoid control: A review, Sensors, 20, 13, 3620.
- Chaurasiya, R. K., Londhe, N. D., ve Ghosh S., 2016. Binary DE-based channel selection and weighted ensemble of SVM classification for novel brain-computer interface using Devanagari script-based P300 speller paradigm, International Journal Human Computer Interaction, 32, 11, 861-877.

- Chen, L., ve Hao, Y., 2017. Feature extraction and classification of EHG between pregnancy and labour group using Hilbert-Huang transform and extreme learning machine, Computational and Mathematical Methods in Medicine, 1-9.
- Chen, C., Ma, Z., Liu, Z., Zhou, L., Wang, G., Li, Y., ve Zhao, J., 2022. An energy-efficient wearable functional near-infrared spectroscopy system employing dual-level adaptive sampling technique, IEEE Transactions on Biomedical Circuits and Systems, 16, 1, 119-128.
- Cheng, J., Sun, J., Yao, K., Xu, M., ve Cao, Y., 2022. A variable selection method based on mutual information and variance inflation factor, Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 268, 120-652.
- Cortez, S. A., Flores, C., ve Andreu-Perez, J., 2020. Single-trial p300 classification using deep belief networks for a BCI system, In: 2020 IEEE International conference on electronics, electrical engineering and computing (INTERCON), Eylül, Lima, Peru, Bildiriler Kitabı, 1-4.
- Einalou, Z., Maghooli, K., Setarehdan, S. K., ve Akin, A., 2016. Effective channels in classification and functional connectivity pattern of prefrontal cortex by functional near infrared spectroscopy signals, Optik-International Journal for Light and Electron Optics, 127, 6, 3271-3275
- Ergün, E., ve Aydemir, Ö., 2018. Decoding of binary mental arithmetic based near-infrared spectroscopy signals. In 2018 3rd International Conference on Computer Science and Engineering (UBMK), Eylül, Bosna Hersek, Bildiriler Kitabı, 201-204.
- Ergün, E., ve Aydemir, Ö., 2018. Etkin epoklar ile motor hayaline dayalı EEG işaretlerinin sınıflandırma doğruluğunun artırılması, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 24, 5, 817-823.
- Ergün, E., ve Aydemir, O., 2020. A new evolutionary preprocessing approach for classification of mental arithmetic-based EEG signals, Cognitive Neurodynamics, 14, 609-617.
- Ergün, E., ve Aydemir, Ö., 2020. A hybrid BCI using singular value decomposition values of the fast walsh hadamard transform coefficients, IEEE Transactions on Cognitive and Developmental Systems, 1-10.
- Fazel-Rezai, R., 2007. Human error in P300 speller paradigm for brain-computer interface, 2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Ağustos, Lyon, Fransa, Bildiriler Kitabı, 2516-2519.
- Fazli, S., Mehnert, J., Steinbrink, J., Curio, G., Villringer, A., Müller, K. R., vd., 2012. Enhanced performance by a hybrid NIRS-EEG brain computer interface, Neuroimage, 59, 519-529.

- Fonseca, A. T. D., Guedj, E., Alario, F. X., Laguitton, V., Mundler, O., Chauvel, P., ve Liegeois-Chauvel, C., 2009. Brain regions underlying word finding difficulties in temporal lobe epilepsy, Brain, 132, 10, 2772-2784.
- Fu, Y., Yan, S., ve Huang, T. S., 2008. Classification and feature extraction by simplexization, IEEE Transactions on Information Forensics and Security, 3, 1, 91-100.
- Freeman, W. J., 2003. The wave packet: an action potential for the 21st century, Journal of integrative neuroscience, 2, 1, 3-30.
- Das, S., Tripathy, D., Raheja, J. L., Das, S., Tripathy, D., ve Raheja, J. L., 2019. A Review on Algorithms for EEG-Based BCIs, Applied Sciences and Technology, 25-56.
- De Vos, M., Kroesen, M., Emkes, R., ve Debener, S., 2014. P300 speller BCI with a mobile EEG system: comparison to a traditional amplifier, Journal of neural engineering, 11, 3, 036008.
- Ditthaporn, A., Banluesombatkul, N., Kettrat, S., Chuangsuwanich, E., ve Wilaiprasitporn, T., 2019. Universal joint feature extraction for P300 EEG classification using multi-task autoencoder, IEEE Access, 7, 68415-68428.
- Duan, L., Ge, H., Ma, W., ve Miao, J., 2015. EEG feature selection method based on decision tree, Bio-Medical Materials and Engineering, 26, 1, 1019-1025.
- Ge, S., Yang, Q., Wang, R. M., Lin, P., Gao, J. F., Leng, Y., vd., 2017. A brain computer interface based on a few-channel EEG-fNIRS bimodal system, IEEE Access 5, 208–218.
- Genon, S., Reid, A., Langner, R., Amunts, K., ve Eickhoff, S. B., 2018. How to characterize the function of a brain region, Trends in Cognitive Sciences, 22, 4, 350-364.
- Ghosh, L., Laha, M., Konar, A., Bhattacharya, S., ve Nagar, A. K., 2022. Fuzzy Relational Approach to Determine Functional Brain Connectivity in Learning Tasks for Dyslexia Children Using an f-NIRS Device, In 2022 International Joint Conference on Neural Networks Temmuz, Padua, İtalya, Bildiriler Kitabı, 1-8.
- Ghosh, S., Dasgupta, A., ve Swetapadma, A., 2019. A study on support vector machine based linear and non-linear pattern classification, In 2019 International Conference on Intelligent Sustainable Systems, Şubat, Palladam, Hindistan, Bildiriler Kitabı, 24-28.
- Gupta, V., ve Mittal, M., 2020. Efficient R-peak detection in electrocardiogram signal based on features extracted using Hilbert transform and Burg method, Journal of the Institution of Engineers, 101, 1, 23-34.
- Guan, C., Thulasidas, M., ve Wu, J., 2004. High performance P300 speller for brain-computer interface, In IEEE International Workshop on Biomedical Circuits and Systems, Aralık, Singapore, Bildiriler Kitabı, 3-5.

- Guan, S., Zhao, K., ve Yang, S., 2019. Motor imagery EEG classification based on decision tree framework and Riemannian geometry, Computational intelligence and neuroscience, 1-14.
- Haihong, Z., ve Cuntai, G., 2006. A kernel-based signal localization method for nirs brain-computer interfaces, In Pattern Recognition 18th International Conference, Ağustos, Hong Kong, China, Bildiriler Kitabı, 1158-1161.
- Haltaş, K., Ergüzen, A., ve Erdal, E., 2019. Classification methods in EEG based motor imagery BCI systems, In 2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies, Ekim, Ankara, Türkiye, Bildiriler Kitabı, 1-5.
- Han, G., ve Yang, L., 2017. Study on the Changes of EEG Signal and Driving Behavior Based on the Driving Simulator, In Green Intelligent Transportation Systems, Proceedings of the 7th International Conference on Green Intelligent Transportation System and Safety, Temmuz, Singapore, Bildiriler Kitabı, 409-420.
- Hassib, M., Mental task classification using single-electrode brain computer interfaces, Yüksek Lisans Tezi, Stuttgart Üniversitesi, Almanya, 2012.
- He, Q., ve Liu, C., 2009. A novel low-pass filter with an embedded band-stop structure for improved stop-band characteristics, IEEE Microwave and Wireless Components Letters, 19, 10, 629-631.
- He, Q., Feng, L., Jiang, G., ve Xie, P., 2022. Multimodal Multitask Neural Network for Motor Imagery Classification With EEG and fNIRS Signals, IEEE Sensors Journal, 22, 21, 20695-20706.
- Heydarian, M., Doyle, T. E., ve Samavi, R., 2022. MLCM: Multi-label confusion matrix, IEEE Access, 10, 19083-19095.
- Hong, K. S., ve Khan, M. J., 2017. Hybrid brain-computer interface techniques for improved classification accuracy and increased number of commands: a review, Frontiers in neurorobotics, 35, 1-7.
- Hramov, A. E., Maksimenko, V. A., ve Pisarchik, A. N., 2021. Physical principles of brain-computer interfaces and their applications for rehabilitation, robotics and control of human brain states, Physics Reports, 918, 1-133.
- Ismail, M., Hofmann, K., ve Abd El Ghany, M. A., 2019. Early diagnoses of Alzheimer using EEG data and deep neural networks classification, In 2019 IEEE Global Conference on Internet of Things, Aralık, Dubai, Birleşik Arap Emirlikleri, Bildiriler Kitabı, 1-5.
- Isa, N. M., Amir, A., Ilyas, M. Z., ve Razalli, M. S., 2019. Motor imagery classification in Brain computer interface (BCI) based on EEG signal by using machine learning technique, Bulletin of Electrical Engineering and Informatics, 8, 1, 269-275.

- Ilyas, M. Z., Saad, P., ve Ahmad, M. I., 2015. A survey of analysis and classification of EEG signals for brain-computer interfaces, In 2015 2nd International Conference on Biomedical Engineering, Mart, Penang, Malezya, Bildiriler Kitabı, 1-6.
- Jadhav, V., Tiwari, N., ve Chawla, M., 2022. A Review on EEG Data Classification Methods for Brain-Computer Interface, In International Conference on Innovative Computing and Communications: Proceedings, Eylül, Singapore, Bildiriler Kitabı, 747-760.
- Jayasree, T., Devaraj, D., ve Sukanesh, R., 2010. Power quality disturbance classification using Hilbert transform and RBF networks, Neurocomputing, 73, 7-9, 1451-1456.
- Kanoh, S. I., Murayama, Y. M., Miyamoto, K. I., Yoshinobu, T., ve Kawashima, R., 2009. A NIRS-based brain-computer interface system during motor imagery: system development and online feedback training, In Engineering in Medicine and Biology Society, Eylül, Minneapolis, ABD, Bildiriler Kitabı, 594-597.
- Kayhan, H., Otomatik üretim teknolojisine uygun betonların basınç dayanımlarının makine öğrenmesi ve derin öğrenme yöntemleri ile tahmin edilmesi, Yüksek Lisans Tezi, Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilecik, 2022.
- Kayikcioglu, T., ve Aydemir, O., 2010. A polynomial fitting and k-NN based approach for improving classification of motor imagery BCI data, Pattern Recognition Letters, 31, 11, 1207-1215.
- Kelly, S. P., Lalor, E. C., Reilly, R. B., ve Foxe, J. J., 2005. Visual spatial attention tracking using high-density SSVEP data for independent brain-computer communication, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 13, 2, 172-178.
- Khan, M. J., Hong, K. S., Naseer, N., Bhutta, M. R., ve Yoon, S. H., 2014. Hybrid EEG-NIRS BCI for rehabilitation using different brain signals, The Annual Conference of the Society of Instrument and Control Engineers (SICE), Eylül, Sapporo, Japonya, Bildiriler Kitabı, 1768-1773.
- Khan, M. J., Hong, M. J., ve Hong, K. S., 2014. Decoding of four movement directions using hybrid NIRS-EEG brain-computer interface, Frontiers in human neuroscience, 8, 244, 1-6.
- Koo, B., Lee, H. G., Nam, Y., Kang, H., Koh, C. S., Shin, H. C., vd., 2015. A hybrid NIRS-EEG system for self-paced brain computer interface with online motor imagery, Journal of Neuroscience Methods, 244, 26-32.
- Korkmaz, O. E., Aydemir, O., Oral, E. A., ve Özbek, I. Y., 2022. An efficient 3D column-only P300 speller paradigm utilizing few numbers of electrodes and flashings for practical BCI implementation, Plos One, 17, 4, 26-59.
- Korkmaz, O. E., Aydemir, Ö., Oral, E. A., ve Özbek, Y., 2022. Kişiden Bağımsız Çevrimiçi P300-Tabanlı Beyin-Bilgisayar Arayüzü Sınıflandırma Modeli Oluşturulması, Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 27, 1, 73-85.

- Kottaimalai, R., Rajasekaran, M. P., Selvam, V., ve Kannapiran, B., 2013. EEG signal classification using principal component analysis with neural network in brain computer interface applications, In 2013 IEEE international conference on emerging trends in computing, communication and nanotechnology, Mart, Tirunelveli, Hindistan, Bildiriler Kitabı, 227-231
- Kumar, S., Sharma, A., Mamun, K., ve Tsunoda, T., 2016. A deep learning approach for motor imagery EEG signal classification, In 2016 3rd Asia-Pacific World Congress on Computer Science and Engineering, Aralık, Nadi, Fiji, Bildiriler Kitabı, 34-39.
- Kverková, K., Marhounová, L., Polonyiová, A., Kocourek, M., Zhang, Y., Olkowicz, S., ve Němec, P., 2022. The evolution of brain neuron numbers in amniotes, Proceedings of the National Academy of Sciences, 119, 11.
- Kwon, J., ve Im, C. H., 2022. Novel Signal-to-Signal translation method based on StarGAN to generate artificial EEG for SSVEP-based brain-computer interfaces, Expert Systems with Applications, 203, 117574.
- Lee, M. H., Fazli, S., Mehnert, J., ve Lee, S. W., 2014. Hybrid brain-computer interface based on EEG and NIRS modalities, In Brain-Computer Interface (BCI), Şubat, Gangwon, Kore, Bildiriler Kitabı, 1-2.
- Lee, M. H., Fazli, S., Mehnert, J., ve Lee, S. W., 2015. Subject-dependent classification for robust idle state detection using multi-modal neuroimaging and data-fusion techniques in BCI, Pattern Recognition, 48, 2725–2737.
- Lei, X., Yang, P., ve Yao, D., 2009. An empirical Bayesian framework for brain–computer interfaces, IEEE transactions on neural systems and rehabilitation engineering, 17, 6, 521-529.
- Leoni, J., Strada, S. C., Tanelli, M., Brusa, A., ve Proverbio, A. M., 2022. Single-trial stimuli classification from detected P300 for augmented Brain–Computer Interface: A deep learning approach, Machine Learning with Applications, 9, 100393.
- Li, B., Huang, D. S., Wang, C., ve Liu, K. H., 2008. Feature extraction using constrained maximum variance mapping, Pattern Recognition, 41, 11, 3287-3294.
- Li, G., ve Chung, W. Y., 2013. Detection of driver drowsiness using wavelet analysis of heart rate variability and a support vector machine classifier, Sensors, 13, 12, 16494-16511.
- Li, J., ve Zhang, L., 2016. Regularized tensor discriminant analysis for single trial EEG classification in BCI, Pattern Recognition Letters, 31, 7, 619-628.
- Li, R., Potter, T., Huang, W., ve Zhang, Y., 2015. Enhancing performance of a hybrid eeg-fnirs system using channel selection and early temporal features, Frontiers in Human Neuroscience, 11-462.

- Li, Z., Zhang, S., ve Pan, J., 2019. Advances in hybrid brain-computer interfaces: principles, design, and applications, Computational Intelligence and Neuroscience, 3807670, 1-9.
- Loos, W. S., Souza, R., Andersen, L. B., Lebel, R. M., ve Frayne, R., 2022. Extraction of a vascular function for a fully automated dynamic contrast-enhanced magnetic resonance brain image processing pipeline, Magnetic Resonance in Medicine, 87, 3, 1561-1573.
- Lopez-Ramirez, M., Rodriguez-Donate, C., Ledesma-Carrillo, L. M., Villalobos-Pina, F. J., Munoz-Minjares, J. U., ve Cabal-Yepe, E., 2022. Walsh–Hadamard domain-based intelligent online fault diagnosis of broken rotor bars in induction motors, IEEE Transactions on Instrumentation and Measurement, 71, 1-11.
- Mellin-Olsen, J., Staender, S., Whitaker, D. K., ve Smith, A. F., 2010. The Helsinki declaration on patient safety in anaesthesiology, European Journal of Anaesthesiology, 27, 7, 592-597.
- McFarland, D. J., ve Wolpaw, J. R., 2017. EEG-based brain–computer interfaces, Current Opinion In Biomedical Engineering, 4, 194-200.
- Naeem, M., Brunner, C., Leeb, R., Graimann, B., ve Pfurtscheller, G., 2006. Seperability of four-class motor imagery data using independent components analysis, Journal of neural engineering, 3, 3, 208.
- Nakra, A., ve Duhan, M., 2022. Motor imagery EEG signal classification using long short-term memory deep network and neighbourhood component analysis, International Journal of Information Technology, 14, 4, 1771-1779.
- Naseer, N., Hong, M. J., ve Hong, K. S., 2014. Online binary decision decoding using functional near-infrared spectroscopy for the development of brain–computer interface, Experimental brain research, 232, 2, 555-564.
- Naseer, N., ve Hong, K. S., 2015. Decoding answers to four-choice questions using functional near infrared spectroscopy, Journal of Near Infrared Spectroscopy, 23, 1, 23-31.
- Naser, A., ve Aydemir, O., 2022. Classification of pleasant and unpleasant odor imagery EEG signals, Neural Computing and Applications, 1-10.
- Nguyen, T. H., Yang, D. L., Chung, W. Y., 2018. A high-rate BCI speller based on eye-closed EEG signal, IEEE Access, 6, 33995–34003.
- Nicholls, J. G., Martin, A. R., Wallace, B. G., ve Fuchs, P. A., From neuron to brain, Sinauer Yayınları, No. 271, Sunderland, 2001.
- Nisar, H., Boon, K. W., Ho, Y. K., ve Khang, T. S., 2022. Brain-Computer Interface: Feature Extraction and Classification of Motor Imagery-Based Cognitive Tasks, In 2022 IEEE International Conference on Automatic Control and Intelligent Systems, Haziran, Shah Alam, Malezya, Bildiriler Kitabı, 42-47.

- Nurkholis, A., Alita, D., ve Munandar, A., 2022. Comparison of Kernel Support Vector Machine Multi-Class in PPKM Sentiment Analysis on Twitter, Rekayasa Sistem Dan Teknologi Informasi, 6, 2, 227-233.
- Nunez, P. L., 1974. The brain wave equation: a model for the EEG, Mathematical Biosciences, 21, 3-4, 279-297.
- Nour, M., Öztürk, Ş., ve Polat, K., 2021. A novel classification framework using multiple bandwidth method with optimized CNN for brain-computer interfaces with EEG-fNIRS signals, Neural Computing and Applications, 33, 22, 15815-15829.
- Ochoa, J. B., 2002. EEG signal classification for brain computer interface applications, Ecole Polytechnique Federale De Lausanne, 7, 1-72.
- Okamoto, M., Dan, H., Shimizu, K., Takeo, K., Amita, T., Oda, I., ve Dan, I., 2004. Multimodal assessment of cortical activation during apple peeling by NIRS and fMRI, Neuroimage, 21, 4, 1275-1288.
- Oralhan, Z., 2019. A new paradigm for region-based P300 speller in brain computer interface, IEEE Access, 7, 106618-106627.
- Orihara, O., 1952. Comparative observation of the action potential of autonomic nerve with EEG, The Tohoku Journal of Experimental Medicine, 57, 1, 43-55.
- Ortner, R., Guger, C., Prueckl, R., Grünbacher, E., ve Edlinger, G., 2010. SSVEP based brain-computer interface for robot control. In *Computers Helping People with Special Needs*, Temmuz, Vienna, Austria, Bildiriler Kitabı, 85-90.
- Paul, D., Mukherjee, M., ve Bakshi, A., 2021. A review of brain-computer interface., Advances in Medical Physics and Healthcare Engineering, 507-531.
- Petrantonakis, P. C., ve Kompatsiaris, I., 2018. Single-trial NIRS data classification for brain-computer interfaces using graph signal processing, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 26, 9, 1700-1709.
- Phinyomark, A., Hirunviriya, S., Limsakul, C., ve Phukpattaranont, P., 2010. Evaluation of EMG feature extraction for hand movement recognition based on Euclidean distance and standard deviation, The 2010 ECTI International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, Mayıs, Chiang Mai, Tayland, Bildiriler Kitabı, 856-860.
- Podmore, J. J., Breckon, T. P., Aznan, N. K., Connolly, J. D., 2019. On the relative contribution of deep convolutional neural networks for SSVEP-based bio-signal decoding in BCI speller applications, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 27, 4, 611-618.

- Polat, K., ve Güneş, S., 2007. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform, Applied Mathematics and Computation, 187, 2, 1017-1026.
- Power, S. D., Falk, T. H., ve Chau, T., 2010. Classification of prefrontal activity due to mental arithmetic and music imagery using hidden Markov models and frequency domain near-infrared spectroscopy, Journal of neural engineering, 7, 2.
- Power, S. D., Kushki, A., ve Chau, T., 2012. Intersession consistency of single-trial classification of the prefrontal response to mental arithmetic and the no-control state by NIRS, Plos One, 7, 7, 37-791.
- Putze, F., Hesslinger, S., Tse, C. Y., Huang, Y. Y., Herff, C., Guan, C. T., vd., 2014. Hybrid fNIRS-EEG based classification of auditory and visual perception processes, Frontiers in Neuroscience, 8, 373.
- Radhi, A. A., Akkar, H. A., ve Abdullah, H. N., 2022. Skewness and access kurtosis as denoised mixed features-based K-Medoids for cooperative spectrum sensing, Physical Communication, 54, 101-831.
- Raichle, M. E., ve Shepherd, G. M., 2014, Angelo Mosso's circulation of blood in the human brain, Oxford University Yayınları, New York, 191 s.
- Rajinikanth, V., Kadry, S., Taniar, D., Kamalanand, K., Elaziz, M. A., ve Thanaraj, K. P., 2022. Detecting epilepsy in EEG signals using synchro-extracting-transform (SET) supported classification technique, Journal of Ambient Intelligence and Humanized Computing, 1-19.
- Rithwik, P., Benzy, V. K., ve Vinod, A. P., 2022. High accuracy decoding of motor imagery directions from EEG-based brain computer interface using filter bank spatially regularised common spatial pattern method, Biomedical Signal Processing and Control, 72, 103-241.
- Roy, S., Bhattacharjee, S., Mandal, B. K., ve Saha, M., 2022. A Comparative Study on Different Techniques for Classification of Brain Waves From EEG Signals, American Journal of Science & Engineering, 2, 4, 1-7.
- Rypma, B., Prabhakaran, V., Desmond, J. E., Glover, G. H., ve Gabrieli, J. D., 1999. Load-dependent roles of frontal brain regions in the maintenance of working memory, Neuroimage, 9, 2, 216-226.
- Sack, A. T., 2009. Parietal cortex and spatial cognition, Behavioural brain research, 202, 2, 153-161.
- Sadiq, M. T., Yu, X., Yuan, Z., Zeming, F., Rehman, A. U., Ullah, I., ve Xiao, G., 2019. Motor imagery EEG signals decoding by multivariate empirical wavelet transform-based framework for robust brain-computer interfaces, IEEE access, 7, 171431-171451.

- Saka, K., Aydemir, Ö., ve Öztürk, M., 2016. Classification of EEG signals recorded during right/left hand movement imagery using Fast Walsh Hadamard Transform based features, In 2016 39th International Conference on Telecommunications and Signal Processing (TSP), Haziran, Viyana, Avusturya, Bildiriler Kitabı, 413-416.
- Sammer, G., Blecker, C., Gebhardt, H., Bischoff, M., Stark, R., Morgen, K. ve Vaitl, D., 2007. Relationship between regional hemodynamic activity and simultaneously recorded EEG-theta associated with mental arithmetic-induced workload, Human brain mapping, 28, 8, 793-803.
- Scherer, R., Muller, G. R., Neuper, C., Graitmann, B., ve Pfurtscheller, G., 2004. An asynchronously controlled EEG-based virtual keyboard: improvement of the spelling rate, IEEE Transactions on Biomedical Engineering, 51, 6, 979-984.
- Schlögl, A., Lee, F., Bischof, H., ve Pfurtscheller, G., 2005. Characterization of four-class motor imagery EEG data for the BCI-competition 2005, Journal of neural engineering, 2, 4, 1-14.
- Shaabani, M. N. A. H., Fuad, N., Jamal, N., ve Ismail, M. F., 2019. kNN and SVM classification for EEG: a review. In InECCE2019: Proceedings of the 5th International Conference on Electrical, Control ve Computer Engineering, Temmuz, Kuantan, Malezya, Bildiriler Kitabı, 555-565.
- Shao, L., Zhang, L., Belkacem, A. N., Zhang, Y., Chen, X., Li, J., ve Liu, H., 2020. EEG-controlled wall-crawling cleaning robot using SSVEP-based brain-computer interface, Journal of healthcare engineering, 1-10.
- Sharif, M. I., Khan, M. A., Alqahtani, A., Nazir, M., Alsubai, S., Binbusayyis, A., ve Damaševičius, R., 2022. Deep learning and kurtosis-controlled, entropy-based framework for human gait recognition using video sequences, Electronics, 11, 3, 334.
- Sharma, A., Amarnath, M., ve Kankar, P. K., 2016. Feature extraction and fault severity classification in ball bearings, Journal of Vibration and Control, 22, 1, 176-192.
- Sharma, G., ve Roy Chowdhury, S., 2018. Design of NIRS probe based on computational model to find out the optimal location for non-invasive brain stimulation, Journal of medical systems, 42, 12, 244.
- Shin, J., von Lüthmann, A., Blankertz, B., Kim, D. W., Jeong, J., Hwang, H. J., ve Müller, K. R., 2016. Open access dataset for EEG+ NIRS single-trial classification, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 25, 10, 1735-1745.
- Shin, J., Von Lüthmann, A., Kim, D. W., Mehnert, J., Hwang, H. J., ve Müller, K. R., 2018. Simultaneous acquisition of EEG and NIRS during cognitive tasks for an open access dataset, Scientific data, 5, 1, 1-16.
- Shin, J., Kwon, J., ve Im, C. H., 2018. A ternary hybrid EEG-NIRS brain-computer interface for the classification of brain activation patterns during mental arithmetic, motor imagery, and idle state, Frontiers in neuroinformatics, 12, 5, 1-9.

- Sidiropoulou, K., Pissadaki, E. K., ve Poirazi, P., 2006. Inside the brain of a neuron, EMBO reports, 7, 9, 886-892.
- Siddharth, S., Jung, T. P., ve Sejnowski, T. J., 2019. Impact of affective multimedia content on the electroencephalogram and facial expressions, Scientific Reports, 9, 1, 16295.
- Sita, J., ve Nair, G. J., 2013. Feature extraction and classification of EEG signals for mapping motor area of the brain, In 2013 International Conference on Control Communication and Computing, Aralık, Thiruvananthapuram, Hindistan, Bildiriler Kitabı, 463-468.
- Sitaram, R., Zhang, H., Guan, C., Thulasidas, M., Hoshi, Y., Ishikawa, A. ve Birbaumer, N., 2007. Temporal classification of multichannel near-infrared spectroscopy signals of motor imagery for developing a brain-computer interface, NeuroImage, 34, 4, 1416-1427.
- Srivastva, R., ve Singh, Y. N., 2018. ECG biometric analysis using Walsh-Hadamard transform, In Advances in Data and Information Sciences, 1, 201-210.
- Subasi, A., 2007. EEG signal classification using wavelet feature extraction and a mixture of expert model, Expert Systems with Applications, 32, 4, 1084-1093.
- Sun, S., ve Zhou, J., 2014. A review of adaptive feature extraction and classification methods for EEG-based brain-computer interfaces, In 2014 International Joint Conference on Neural Networks, Temmuz, Beijing, China, Bildiriler Kitabı, 1746-1753.
- Şenel, F. A., 2020. Makine Öğrenmesi Algoritmaları Kullanılarak Kayısı İç Çekirdeklerinin Sınıflandırılması, Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9, 2, 807-815.
- Tai, K., ve Chau, T., 2009. Single-trial classification of NIRS signals during emotional induction tasks: towards a corporeal machine interface, Journal of neuroengineering and rehabilitation, 6, 1-14.
- Tanida, M., Sakatani, K., Takano, R., ve Tagai, K., 2004. Relation between asymmetry of prefrontal cortex activities and the autonomic nervous system during a mental arithmetic task: near infrared spectroscopy study, Neuroscience letters, 369, 1, 69-74.
- Tasci, B., ve Tasci, I., 2022. Deep feature extraction based brain image classification model using preprocessed images: PDRNet, Biomedical Signal Processing and Control, 78, 103-948.
- Tetik, M., Beyin İşlevsel Yakın Kızılötesi Ölçümünü Etkileyen Etmenlerin Değerlendirilmesi, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Sağlık Bilimleri Enstitüsü, İzmir, 2012.
- Tibrewal, N., Leeuwis, N., ve Alimardani, M., 2022. Classification of motor imagery EEG using deep learning increases performance in inefficient BCI users, Plos One, 17, 7, 1-12.


- Tiwari, A., ve Chaturvedi, A., 2021. A novel channel selection method for BCI classification using dynamic channel relevance, IEEE Access, 9, 126698-126716.
- Tomita, Y., Vialatte, F. B., Dreyfus, G., Mitsukura, Y., Bakardjian, H., ve Cichocki, A., 2014. Bimodal BCI using simultaneously NIRS and EEG, IEEE Transactions on Biomedical Engineering, 61, 4, 1274-1284.
- Torres, E. P., Torres, E. A., Hernández-Álvarez, M., ve Yoo, S. G., 2020. EEG-based BCI emotion recognition: A survey, Sensors, 20, 18, 5083.
- Townsend G., Graimann B., ve Pfurtscheller G., 2006. A comparison of common spatial patterns with complex band power features in a four-class BCI experiment, IEEE Transactions on Biomedical Engineering, 53, 4, 642-51.
- Tran, Nhu N., vd., 2020. The use of near-infrared spectroscopy (NIRS) to measure cerebral oxygen saturation during body position changes on infants less than one year old, Journal of Pediatric Nursing, 55, 155-164.
- Xing, X., Wang, Y., Pei, W., Guo, X., Liu, Z., Wang, F., ve Chen, H., 2018. A high-speed SSVEP-based BCI using dry EEG electrodes, Scientific reports, 8, 1, 14-708.
- Vankdothu, R., Hameed, M. A., Ameen, A., ve Unnisa, R., 2022. Brain image identification and classification on internet of medical things in healthcare system using support value based deep neural network, Computers and Electrical Engineering, 102, 108196.
- Värbu, K., Muhammad, N., ve Muhammad, Y., 2022. Past, present, and future of EEG-based BCI applications, Sensors, 22, 9, 31-33.
- Villringer, A., Planck, J., Hock, C., Schleinkofer, L., ve Dirnagl, U., 1993. Near infrared spectroscopy (NIRS): a new tool to study hemodynamic changes during activation of brain function in human adults, Neuroscience letters, 154, 1, 101-104.
- Vishwakarma, R., Khwaja, H., Samant, V., Gaude, P., Gambhir, M., ve Aswale, S., 2020. EEG signals analysis and classification for BCI systems: a review, In 2020 International Conference on Emerging Trends in Information Technology and Engineering, Şubat, Vellore, Hindistan, Bildiriler Kitabı, 1-6.
- Wallois, F., Mahmoudzadeh, M., Patil, A., ve Grebe, R., 2012. Usefulness of simultaneous EEG–NIRS recording in language studies, Brain and language, 121, 2, 110-123.
- Wang, D., Li, H., ve Chen, J., 2019. Detecting and measuring construction workers' vigilance through hybrid kinematic-EEG signals, Automation in Construction, 100, 11-23.
- Wang, G., Deng, Z., ve Choi, K. S., 2015. Detection of epileptic seizures in EEG signals with rule-based interpretation by random forest approach, In Advanced Intelligent Computing Theories and Applications: 11th International Conference, Ağustos, Fuzhou, Çin, Bildiriler Kitabı, 738-744.

- Wang, J., ve Wang, M., 2021. Review of the emotional feature extraction and classification using EEG signals, Cognitive robotics, 1, 29-40.
- Wang, Q., ve Sourina, O., 2013. Real-time mental arithmetic task recognition from EEG signals, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 21 2, 225-232.
- Wang, X., Gong, G., Li, N., ve Qiu, S., 2019. Detection analysis of epileptic EEG using a novel random forest model combined with grid search optimization, Frontiers in human neuroscience, 13, 52.
- Wang, X., Ling, Y., Ling, X., Li, X., Li, Z., Hu, K., ve Yang, Q., 2022. A particle swarm algorithm optimization-based SVM–KNN algorithm for epileptic EEG recognition, International Journal of Intelligent Systems, 1-17.
- Wang, Y., Chen, X., Gao, X., ve Gao, S., 2016. A benchmark dataset for SSVEP-based brain–computer interfaces, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 25, 10, 1746-1752.
- Wang, Z., ve Wang, L., 2022. An Attention Approach for Dimensionality Reduction That Can Correct Feature Collection Skewness, IEEE Access, 10, 117273-117280.
- Wei, L., Ventura, S., Lowery, M., Ryan, M. A., Mathieson, S., Boylan, G. B., ve Mooney, C., 2020. Random forest-based algorithm for sleep spindle detection in infant EEG, In 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society, Temmuz, Montreal, Kanada, Bildiriler Kitabı, 58-61.
- Weinberger, D. R., Luchins, D. J., Morihisa, J., ve Wyatt, R. J., 1982. Asymmetrical volumes of the right and left frontal and occipital regions of the human brain, Annals of Neurology: Official Journal of the American Neurological Association and the Child Neurology Society, 11, 1, 97-100.
- Wise, R. J., Greene, J., Büchel, C., ve Scott, S. K., 1999. Brain regions involved in articulation, The Lancet, 353, 9158, 1057-1061.
- Yasmin, M., Sharif, M., Masood, S., Raza, M., ve Mohsin, S., 2012. Brain image enhancement-A survey, World Applied Sciences Journal, 17, 9, 1192-1204.
- Yavuz, E. ve Aydemir, Ö., 2017. Nilüfer Çiçeği ve Kediotu Kokularını Koklama Anında Kaydedilmiş EEG İşaretlerinin Sınıflandırılması, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 21, 2, 430-436.
- Yin, X. X., Xu, B. L., Jiang, C. H., Fu, Y. F., Wang, Z. D., Li, H. Y., vd., 2015. A hybrid BCI based on EEG and fNIRS signals improves the performance of decoding motor imagery of both force and speed of hand clenching, Journal of Neural Engineering, 12, 036004.
- Zang, D., Zhao, X., Qiao, Y., Huo, J., Wu, X., Wang, Z., ve Zhang, L., 2023. Enhanced brain parcellation via abnormality inpainting for neuroimage-based consciousness evaluation of hydrocephalus patients by lumbar drainage, Brain Informatics, 10, 1, 1-3.


- Zhang, R., Li, X., Wang, Y., Liu, B., Shi, L., Chen, M., ve Hu, Y., 2019. Using brain network features to increase the classification accuracy of MI-BCI inefficiency subject, IEE Access, 7, 74490-74499.
- Zhang, S., Zheng, Y., Wang, D., Wang, L., Ma, J., Zhang, J., ve Zhang, D., 2017. Application of a common spatial pattern-based algorithm for an fNIRS-based motor imagery brain-computer interface, Neuroscience letters, 655, 35-40.
- Zhang, Y., Dong, Z., Wu, L., ve Wang, S., 2011. A hybrid method for MRI brain image classification, Expert Systems with Applications, 38, 8, 10049-10053.
- Zhang, Y., ve Zhu, C., 2020. Assessing brain networks by resting-statedynamic functional connectivity: An fNIRS-EEG study, Frontiers in Neuroscience, 13, 1430, 1-9.
- Zhang, Y., Li, Y., Kong, L., Niu, Q., ve Bai, Y., 2022. Improved DBSCAN Spindle Bearing Condition Monitoring Method Based on Kurtosis and Sample Entropy, Machines, 10, 5, 363.
- Zhao, H. B., Liu, C., Yu, C. Y., ve Wang, H., 2011. Channel selection and feature extraction of ECoG-based brain-computer interface using band power, In Applied Mechanics and Materials, Trans Tech Publications, No. 44, 4 s, Çin.
- Zhong, W., Ji, Z., ve Sun, C., 2021. A review of monitoring methods for cerebral blood oxygen saturation, In Healthcare, 9, 9, 1-1104.
- URL-1, <https://bilimtekNIK.tubitak.gov.tr/>. 5 Mayıs 2022.
- URL-2, <https://nirx.net/nirslab-1>. 10 Mart 2022.
- URL-3, <https://nirx.net/nirslab-1>. 9 Mart 2022.
- URL-4, [http:// https://www.mathworks.com/](http://https://www.mathworks.com/), 19 Şubat 2018.

7. EKLER


Ek 1. HD'nin mutlak deęerlerinin standart sapması tabanlı öz niteliklerin sonuçları




Şekil Ek 1.1. 2.4 sn zaman bölütlerinden çıkarılan eğitim ve test SD




Şekil Ek 1.2. 4.8 sn zaman bölütlerinden çıkarılan eğitim ve test SD



Şekil Ek 1.3. 12 sn zaman bölütlerinden çıkarılan eğitim ve test SD



Şekil Ek 1.4. 24 sn zaman bölütlerinden çıkarılan eğitim ve test SD



Şekil Ek 1.5. Tüm zaman bölütlerinden çıkarılan öznelitelerin sınıflandırılması ile 8 kişinin ortalama eğitim ve test SD'si radar grafikleri

ÖZGEÇMİŞ

Ebru ERGÜN, İlköğretim ve ortaöğretimini Trabzon Merkez’de tamamlamış olup, 2009 yılında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünü kazandı. Bu öğrenimini 2014 yılında tamamlayarak aynı sene yüksek lisans eğitimine başladı. Yüksek lisans eğitimini 2017 yılında tamamlayarak aynı sene doktora eğitimine devam etti. Doktora eğitimi süresince BİDEB 2211-C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında maddi olarak Türkiye bilimsel ve Teknolojik Araştırma Kurumu tarafından desteklendi. 2015 yılında Recep Tayyip Erdoğan Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü’nde Araştırma Görevlisi olarak göreve başladı. İyi derecede İngilizce bilen Ergün, biyomedikal alanındaki çalışmalarını sürdürmektedir.

SCI/SCI-E indekslerine giren dergilere gönderilen makaleler

1. Aydemir, O., ve Ergün, E., 2019. A robust and subject-specific sequential forward search method for effective channel selection in brain computer interfaces, Journal of neuroscience methods, 313, 60-67.
2. Ergün, E., ve Aydemir, O., 2020. A new evolutionary preprocessing approach for classification of mental arithmetic based EEG signals, Cognitive Neurodynamics, 14, 609-617.
3. Ergün, E., ve Aydemir, Ö., 2020. A hybrid BCI using singular value decomposition values of the fast walsh hadamard transform coefficients, IEEE Transactions on Cognitive and Developmental Systems, 1-10.

Diğer dergilerde yayınlanacak makaleler

4. Yavuz, E., ve Aydemir, Ö., 2017. Nilüfer Çiçeği ve Kediotu Kokularını Koklama Anında Kaydedilmiş EEG İşaretlerinin Sınıflandırılması, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 21, 2, 430-436.
5. Ergün, E., ve Aydemir, Ö., 2018. Etkin epoklar ile motor hayaline dayalı EEG işaretlerinin sınıflandırma doğruluğunun artırılması, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 24, 5, 817-823.

Hakemli konferans/sempozyumların bildiri kitaplarında yer alan yayınlar

6. Ergün, E., ve Aydemir, O., 2020. Firefly Algorithm Based Feature Selection for EEG Signal Classification, In 2020 Medical Technologies Congress (TIPTEKNO), Kasım, Trabzon, Türkiye, Bildiriler Kitabı, 1-4.
7. Ergün, E., ve Aydemir, Ö., 2020. Classification of Mental Arithmetic Based Hybrid EEG+ NIRS Signals, In 2020 28th Signal Processing and Communications Applications Conference (SIU), Ekim, Gaziantep, Türkiye, Bildiriler Kitabı, 1-4.
8. Ergün, E., ve Aydemir, Ö., 2018. Decoding of binary mental arithmetic based near-infrared spectroscopy signals, In 2018 3rd International Conference on Computer Science and Engineering (UBMK), Eylül, Saraybosna, Bosna Hersek, Bildiriler Kitabı, 201-204.
9. Aydemir, Ö., Altun, H., ve Ergün, E., 2018. Classification of Brain Responses to the Various Spice Odors, In 2018 3rd International Conference on Computer Science and Engineering (UBMK), Eylül, Saraybosna, Bosna Hersek, Bildiriler Kitabı, 205-208.
10. Ergün, E., ve Aydemir, Ö., 2018. Classification of motor imaginary based near-infrared spectroscopy signals, In 2018 26th Signal Processing and Communications Applications Conference (SIU), Mayıs, İzmir, Türkiye, Bildiriler Kitabı, 1-4.
11. Altun, H., Ergün, E., ve Aydemir, Ö., 2018. Classification of electroencephalography signals recorded during olfaction of some spices, In 2018 26th Signal Processing and Communications Applications Conference (SIU), Mayıs, İzmir, Türkiye, Bildiriler Kitabı, 1-4.
12. Yavuz, E., ve Aydemir, Ö., 2017. Classification of EEG Based BCI Signals Imagined Hand Closing and Opening, In Telecommunications and Signal Processing (TSP), Temmuz, Barselona, Bildiriler Kitabı: 1-4.
13. Yavuz, E. ve Aydemir, Ö., 2017. Beyin-Bilgisayar Arayüzü Uygulamalarında Etkin Kanalların Belirlenmesi, 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU), Mayıs, Antalya, Bildiriler Kitabı: 1-4.
14. Yavuz, E. ve Aydemir, Ö., 2017. Feature extraction from mental arithmetic based EEG signals, Medical Technologies National Congress (TIPTEKNO), Ekim, Trabzon, Bildiriler Kitabı: 1-4.
15. Yavuz, E. ve Aydemir, Ö., 2016. Olfaction recognition by EEG analysis using wavelet transform features. In INnovations in Intelligent SysTems and Applications (INISTA), Ağustos, Sinaia, Bildiriler Kitabı: 1-4.

16. Yavuz, E., ve Aydemir, Ö., 2016. EEG Tabanlı Beyin Bilgisayar Arayüzü İşaretlerinin Etkin Zaman Dilimlerinden Çıkarılmış Özniteliklerle Sınıflandırma Doğruluklarının Artırılması. XX. Biyomedikal Mühendisliği Ulusal Toplantısı (BİYOMUT), Kasım, İzmir, Bildiriler Kitabı: 1-5.

