

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**MOTOR HAREKET HAYALİ EEG VERİLERİNİ DENEKLERDEN BAĞIMSIZ
ORTAK ELEKTROTLAR KULLANARAK SINIFLAMA**



DOKTORA TEZİ

Ali ÖZKAHRAMAN

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Elektronik Mühendisliği Programı

MART 2025

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**MOTOR HAREKET HAYALİ EEG VERİLERİNİ DENEKLERDEN BAĞIMSIZ
ORTAK ELEKTROTLAR KULLANARAK SINIFLAMA**



DOKTORA TEZİ

**Ali ÖZKAHRAMAN
(504172229)**

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Elektronik Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Tamer ÖLMEZ

MART 2025

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**CLASSIFICATION OF MOTOR IMAGERY EEG DATA USING SUBJECT-
INDEPENDENT COMMON ELECTRODES**



Ph.D. THESIS

**Ali ÖZKAHRAMAN
(504172229)**

Department of Electronics and Communication Engineering

Electronics Engineering Programme

Thesis Advisor: Prof. Dr. Tamer ÖLMEZ

MARCH 2025

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 504172229 numaralı Doktora Öğrencisi Ali ÖZKAHRAMAN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "MOTOR HAREKET HAYALİ EEG VERİLERİNİ DENEKLERDEN BAĞIMSIZ ORTAK ELEKTROTLAR KULLANARAK SINIFLAMA" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Tamer ÖLMEZ**

İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Ender Mete EKŞİOĞLU**

İstanbul Teknik Üniversitesi

Prof. Dr. Gökhan BİLGİN

Yıldız Teknik Üniversitesi

Prof. Dr. Mustafa BAĞRIYANIK

İstanbul Teknik Üniversitesi

Prof. Dr. Süreyya AKYÜZ

Bahçeşehir Üniversitesi

Teslim Tarihi : 21 Ocak 2025

Savunma Tarihi : 14 Mart 2025



Sevgili ođlum ve aileme,



ÖNSÖZ

Doktora çalışmam boyunca bana yol gösteren, nitelikli bir tez hazırlamam için her adımda destek olan ve umutsuzluğa kapıldığım anlarda beni motive eden danışman hocam Prof. Dr. Tamer ÖLMEZ ve kıymetli hocam Prof. Dr. Zümray DOKUR'a en içten teşekkürlerimi sunarım.

Tez izleme jürimde yer alarak değerli yönlendirme ve önerileriyle tezime katkı sunan ve destek olan Prof. Dr. Ender Mete EKŞİOĞLU, Prof. Dr. Gökhan BİLGİN ve Prof. Dr. Nizamettin AYDIN'a teşekkür ederim.

Tüm hayatım boyunca olduğu gibi, bu tezin hazırlanma sürecinde de her zaman yanımda olduklarını hissettiğim annem, babam, ablam ve kardeşime; ayrıca varlığıyla bana ilham kaynağı olan ve en büyük motivasyonumu sağlayan oğlum Hüseyin Aras'a sevgi ve minnetle teşekkür ederim.

Bu tez, beyin ve makineler arasındaki iletişimi geliştirmeye yönelik araştırmalarımın bir ürünüdür. Deneysel düzenekler ve sonuçlar açık bir şekilde sunulmuştur. Bu çalışmanın, Beyin-Bilgisayar Arayüzleri, Nöro Teknoloji, Yapay Zeka ve Motor Hareket Hayali sinyalleri üzerine çalışan araştırmacılara faydalı olmasını dilerim.

Mart 2025

Ali ÖZKAHRAMAN
(Araştırma Görevlisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ	ix
İÇİNDEKİLER.....	xi
KISALTMALAR.....	xiii
SEMBOLLER.....	xv
ÇİZELGE LİSTESİ.....	xvii
ŞEKİL LİSTESİ.....	xix
ÖZET	xxi
SUMMARY.....	xxv
1. GİRİŞ	1
1.1 Tezin Amacı.....	2
1.2 Literatür Araştırması.....	2
1.3 Tez Organizasyonu.....	7
2. ELEKTROENSEFALOGRAFİ (EEG) TABANLI BEYİN-BİLGİSAYAR	
ARAYÜZÜ (BBA).....	9
2.1 Kararlı Hal Görsel Uyarılmış Potansiyel (KHGUP) Tabanlı BBA.....	11
2.2 P300 Tabanlı BBA.....	12
2.3 Motor Hareket Hayali Tabanlı BBA.....	13
2.3.1 ERD / ERS.....	15
3. EEG VERİLERİ İÇİN ÖN İŞLEM METOTLARI.....	17
3.1 Ortak Ortalama Referanslama (OOR).....	17
3.2 Elektrokulografi (EOG) Regresyonu	18
3.3 Kısa Süreli Fourier Dönüşümü (KSFD).....	19
3.4 Sürekli Dalgacık Dönüşümü (SDD)	20
3.5 Dalgacık Temelli Gürültü Temizleme (DTGT)	21
3.6 Ortak Uzamsal Örüntü (OUÖ).....	21
3.6.1 Ortak Uzamsal Örüntü'nün matematiksel olarak ifadesi	23
3.6.2 Filtreli Ortak Uzamsal Örüntü (fOUÖ)	25
3.7 Bağımsız Bileşen Analizi.....	26
4. ELEKTROT SEÇİM METOTLARI.....	27
4.1 Rayleigh Katsayı Haritası	27
4.2 Diverjans Tabanlı Elektrot Seçim Algoritması	28
4.3 Ortak Uzamsal Örüntüler Kullanarak Kanal Seçimi.....	29
4.4 Karşılıklı Bilgi.....	29
4.5 Kanal Dikkat Mekanizması (KDM).....	30
4.6 Permütasyon Önem Skoru	32
4.7 Rastgele Arama Algoritması	32
5. DERİN ÖĞRENME METOTLARI.....	33
5.1 Yapay Sinir Ağları (YSA)	33
5.2 Evrimsel Sinir Ağı (ESA).....	35

5.3 Diverjans Temelli Öznitelik Çıkarımı (Divergence-based Feature Extractor - DivFE)	36
5.4 EEGNet Mimarisine Dayalı Derin Öğrenme Sistemi	39
5.4.1 Derinlemesine evrişim	40
5.4.2 Ayrılabilir evrişim	41
6. BİLGİSAYAR BENZETİMİ	43
6.1 Veri Kümeleri	44
6.1.1 BCI III-3a Veri Kümesi	44
6.1.2 BCI IV-2a Veri Kümesi	45
6.1.3 BCI III-3a Veri Kümesi'ni kullanarak yapay veri oluşturma... ..	46
6.1.4 Weibo Veri Kümesi	47
6.2 Motor Hareket Hayali Sinyallerinin Gürültüden Temizlenmesi	48
6.3 EEG Kanalları Arasından Deneklerden Bağımsız Elektrot Seçimi ve DivFE Mimarisi ile Sınıflama İşlemi	51
6.3.1 Rayleigh Katsayı Haritası kullanarak elektrot yerlerinin belirlenmesi	52
6.3.2 Diverjans değeri kullanarak elektrot yerlerinin belirlenmesi	55
6.3.3 DivFE Mimarisi kullanarak sınıflama işlemi	56
6.4 EOG Kanallarının Önemine İlişkin Deneklerden Bağımsız Elektrot Seçimi ve EEGNet Benzeri Mimari ile Sınıflama İşlemi	61
6.4.1 Karşılıklı Bilgi kullanarak EEG ve EOG arasındaki benzerlik	63
6.4.2 OUÖ kullanarak elektrot seçimi	66
6.4.3 Kanal Dikkat Mekanizması kullanarak elektrot seçimi	68
6.4.4 Permütasyon Önem Skoru kullanarak elektrot seçimi	69
6.4.5 Rastgele Arama Algoritması kullanarak elektrot seçimi	70
6.4.6 Her bir yöntem için elektrotların önemi	70
6.4.7 EEGNet Benzeri Mimari kullanarak sınıflama işlemi	71
6.5 Sınıflama Doğruluklarının Literatürle Karşılaştırılması	73
6.5.1 DivFE Mimarisi ile karşılaştırma	73
6.5.2 EEGNet Benzeri Mimari ile karşılaştırma	76
7. SONUÇ VE TARTIŞMA	79
KAYNAKLAR	83
ÖZGEÇMİŞ	93

KISALTMALAR

BBA	: Beyin-Bilgisayar Arayüzü
EEG	: Elektroensefalografi
EOG	: Elektrokülografi
ERD / ERS	: Olay İlişkin Desenkronizasyon / Senkrenizasyon
ESA	: Evrişimsel Sinir Ağı
FD	: Fourier Dönüşümü
fOUÖ	: Filtrelenmiş Ortak Uzamsal Örüntü
GSY	: Güç Spektral Yoğunluğu
KDM	: Kanal Dikkat Mekanizması
KHGUP	: Kararlı Hal Görsel Uyarılmış Potansiyel
KSFD	: Kısa Süreli Fourier Dönüşümü
MHH	: Motor Hareket Hayali
MMA	: Minimum Mesafe Ağı
OOR	: Ortak Ortalama Referanslama
OUÖ	: Ortak Uzamsal Örüntü
SDD	: Sürekli Dalgacık Dönüşümü
SNR	: Sinyal-Gürültü Oranı
YSA	: Yapay Sinir Ağları



SEMBOLLER

S_i'	: i-inci EEG elektrotunun yeniden referanslanmış sinyali
\bar{S}	: Tüm EEG elektrotları üzerinden hesaplanan ortalama sinyal
EEG	: Orijinal EEG sinyali
EEG _i	: i-inci elektrottaki orijinal EEG sinyali
EEG _i '	: i-inci EEG elektrottaki gürültüden temizlenmiş EEG sinyali
β_0	: EOG Regresyon modelindeki sabit terim
$\beta_1, \beta_2, \dots, \beta_k$: EOG Regresyon modelinden gelen her bir EOG elektrotuna ait katsayılar
EOG _{1i} , ..EOG _{ki}	: Farklı elektrotlardaki EOG sinyalleri
KSFD	: Kısa Süreli Fourier Dönüşüm
wp	: Pencereleme fonksiyonu
SDD	: Sürekli Dalgacık Dönüşümü
Ψ	: Dalgacık Dönüşümü
a	: Ölçek parametresi
b	: Konum parametresi
X_R	: Referans sinyal
X_s	: Referans sinyale göre farklılığı belirginleştirilecek sinyal
W	: OUÖ sonucu oluşan özvektörlere ait matris
w	: OUÖ sonucu oluşan her bir özdeğere ait özvektör
λ	: w ile filtrelenmiş sinyalin, w ile filtrelenmiş referans sinyaline oranının büyüklüğüdür
S	: X_s sinyaline ait kovaryans matris
R	: X_R sinyaline ait kovaryans matris
Λ	: OUÖ sonucu oluşan özdeğerler
I(X;Y)	: İki rastgele değişken X ve Y arasındaki karşılıklı bilgi
H(X)	: X'in entropisi
H(X,Y)	: X ve Y'nin ortak entropisi
P(x)	: X'in olasılık dağılımı
P(x, y)	: X ve Y'nin ortak olasılık dağılımı
C	: Her bir elektrota ait puanlama

w_acc	: Her bir alt kümenin doğruluğu
k	: Elektrotun oluşum sayısı
σ	: Aktivasyon fonksiyonu
sapma_degeri	: Yapay Sinir Ağındaki bir nöronun sapma değeri
w_giris_i	: Nöron girişlerine ait ağırlıklar
n	: Nörona ait giriş sayısı
S_kov_k	: k sınıfına ait kovaryans matrisi
S_kov	: Tüm sınıflara ait kovaryans matrislerinin toplamı
B	: Sınıflar arası dağılım matrisi
WV	: Walsh vektörleri matrisi
EEG_T	: Dil MHH epokları
EEG_F	: Ayak MHH epokları
EEG_{LH}	: Sol el MHH epokları
EEG_{RH}	: Sağ el MHH epokları
EEG_{F-T}	: Ayak-dil MHH epokları
EEG_{LH-F}	: Sol el-ayak MHH epokları
EEG_{RH-F}	: Sağ el-ayak MHH epokları
EEG_{LH-T}	: Sol el-dil MHH epokları
EEG_{RH-T}	: Sağ el-dil MHH epokları
EEG_{RH-LH}	: Sağ el-sol el MHH epokları

ÇİZELGE LİSTESİ

Sayfa

Çizelge 6.1 : Bazı gürültü temizleme metotlarının denek bağımlı sınıflama performansları.....	49
Çizelge 6.2 : Bazı gürültü temizleme metotlarının denek bağımsız sınıflama performansları.....	50
Çizelge 6.3 : BCI III-3a Veri Kümesi'nde 11b, k3b, k6b ve tüm denekler için diverjans değerleri ve elektrot setleri.....	55
Çizelge 6.4 : BCI IV-2a Veri Kümesi'nde D1, D3, D7, D8, D9 ve tüm denekler için diverjans değerleri ve elektrot setleri.....	56
Çizelge 6.5 : BCI III-3a Veri Kümesi'nde dört sınıf için beş elektrot kullanılarak elde edilen sınıflandırma doğruluk oranları (%).	57
Çizelge 6.6 : BCI IV-2a Veri Kümesi'nde dört sınıf için beş elektrot kullanılarak elde edilen sınıflandırma doğruluk oranları (%).	57
Çizelge 6.7 : Yapay oluşturulmuş on sınıf için beş elektrot kullanılarak elde edilen sınıflandırma doğruluk oranları (%).	58
Çizelge 6.8 : Filtreleme, Bağımsız Bileşen Analizi ve fOUÖ için DivFE yapısı (filtre boyutu / katman sayısı).	60
Çizelge 6.9 : SDD ve KSFD için DivFE yapısı (filtre boyutuxfiltre boyutu / katman sayısı).	60
Çizelge 6.10 : Veri Kümesi 2 ve Veri Kümesi 4'e uygulanan dört farklı yöntem için en etkili kanallar.	71
Çizelge 6.11 : Veri Kümesi 2 için yalnızca EEG, yalnızca EOG, hem EEG hem de EOG birlikte ve az sayıda EEG ve EOG elektrotları kullanılarak elde edilen doğruluk sonuçları.	72
Çizelge 6.12 : Veri Kümesi 4 için yalnızca EEG, yalnızca EOG, hem EEG hem de EOG birlikte ve az sayıda EEG ve EOG elektrotları kullanılarak elde edilen doğruluk sonuçları.	73
Çizelge 6.13 : Elektrot azaltma işlemlerinin uygulandığı çalışmaların DivFE Mimarisi kullanılarak elde edilen sonuçlarla karşılaştırılması.	75
Çizelge 6.14 : Elektrot azaltma işlemlerinin uygulandığı çalışmaların EEGNet Benzeri Mimari kullanılarak elde edilen sonuçlarla karşılaştırılması. ..	76



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Farklı canlı türlerine özgü EEG sinyallerindeki tutarlılık.....	10
Şekil 2.2 : 10 Hz frekansında titreşen bir hedefe bakarken KHGUP sinyali. a1) Zaman, a2) Frekans, a3) Zaman-frekans eksenini.....	12
Şekil 2.3 : El, ayak ve dil MHH'nin beyindeki konumları.....	13
Şekil 2.4 : Motor görevi sırasında ERD ve ERS.....	16
Şekil 3.1 : KSFD ve SDD için zaman pencere boyutlarının karşılaştırılması.....	20
Şekil 3.2 : a) OUÖ uygulanmadan öncesi. b) OUÖ uygulandıktan sonrası.....	22
Şekil 3.3 : OUÖ'nün çalışma prensibi.....	23
Şekil 3.4 : fOUÖ'nün çalışma prensibi.....	25
Şekil 3.5 : Bağımsız Bileşen Analizi'nin blok diyagramı.....	26
Şekil 4.1 : Önerilen Kanal Dikkat Mekanizması.....	31
Şekil 5.1 : Örnek bir derin öğrenme mimarisi.....	33
Şekil 5.2 : İki farklı katmanlı YSA için eğitim ve test hatalarının değişimi.....	34
Şekil 5.3 : 2D konvolüsyon işlemi için örnek.....	35
Şekil 5.4 : DivFE Mimarisi (Model 1).....	37
Şekil 5.5 : DivFE eğitim aşaması.....	38
Şekil 5.6 : EEGNet'den esinlenilerek geliştirilen derin öğrenme mimarisi(Model 2).....	40
Şekil 5.7 : Derinlemesine evrişim (konvolüsyon).....	41
Şekil 5.8 : Ayrılabilir evrişim.....	41
Şekil 6.1 : Veri Kümesi 1 için EEG elektrotlarının yerleşimi.....	44
Şekil 6.2 : Denekler için zaman diyagramı (Veri Kümesi 1).....	45
Şekil 6.3 : Denekler için zaman diyagramı (Veri Kümesi 2).....	46
Şekil 6.4 : Veri Kümesi 2 için elektrotların yerleşimi.....	46
Şekil 6.5 : BCI III-3a için Rayleigh Katsayı Haritaları: sol el(L), sağ el(R), ayak(F) ve dil(T).....	53
Şekil 6.6 : BCI IV-2a için Rayleigh Katsayı Haritaları: sol el(L), sağ el(R), ayak(F) ve dil(T).....	54
Şekil 6.7 : Veri Kümesi 2'de D1, D9 ve tüm denekler için ortalama Güç Spektral Yoğunluğu (GSY). a) 22 EEG elektrot. b) 3 EOG elektrot.....	62
Şekil 6.8 : Veri Kümesi 4'de D1, D9 ve tüm denekler için ortalama Güç Spektral Yoğunluğu (GSY). a) 60 EEG elektrot. b) 2 EOG elektrot.....	63
Şekil 6.9 : a) Veri Kümesi 2 için EEG ve EOG kanalları arasındaki Karşılıklı Bilgi. b) Veri Kümesi 2 için elektrot konumları.....	64
Şekil 6.10 : a) Veri Kümesi 4 için EEG ve EOG kanalları arasındaki Karşılıklı Bilgi. b) Veri Kümesi 4 için elektrot konumları.....	65
Şekil 6.11 : Veri Kümesi 2'de tüm elektrotlar boyunca ilk beş uzamsal örüntünün aktivasyonu.....	67
Şekil 6.12 : Veri Kümesi 4'de tüm elektrotlar boyunca ilk beş uzamsal örüntünün aktivasyonu.....	67
Şekil 6.13 : Veri Kümesi 2'de tüm elektrotlar için kanal dikkat ağırlıkları.....	68

Şekil 6.14 : Veri Kümesi 4'de tüm elektrotlar için kanal dikkat ağırlıkları.....	68
Şekil 6.15 : Veri Kümesi 2'de tüm elektrotlar için PÖS.....	69
Şekil 6.16 : Veri Kümesi 4'de tüm elektrotlar için PÖS.....	69
Şekil 6.17 : Veri Kümesi 2'de Rastgele Arama Algoritması kullanarak kanal önemleri.....	70



MOTOR HAREKET HAYALİ EEG VERİLERİNİ DENEKLERDEN BAĞIMSIZ ORTAK ELEKTROTLAR KULLANARAK SINIFLAMA

ÖZET

Beyin-Bilgisayar Arayüzü (BBA) sistemleri, kullanıcıların doğrudan beyin sinyalleriyle harici cihazları kontrol etmelerine olanak tanıyan bir teknoloji olup giderek daha yaygınlaşmaktadır. Son yıllarda BBA alanında yapılan araştırmaların çoğalması, bu teknolojinin potansiyelini artırarak tıbbi rehabilitasyon, nörolojik bozuklukların tedavisi, iletişim araçları ve eğlence uygulamaları gibi birçok farklı alanda kullanımını artırmıştır. Motor Hareket Hayali (MHH) sinyalleri, BBA sistemlerinde kullanılan bir yöntemdir ve bireylerin zihinsel hareket (bir uzvunu) hayali yaparak cihazları kontrol etmelerine olanak tanır. Bu sinyaller, genellikle motor korteksten kaydedilen elektroensefalografi (EEG) verileri ile analiz edilerek işlenir.

BBA sistemlerinde, özellikle son yıllarda derin öğrenme yöntemlerinin uygulanmasıyla etkili performanslar elde edilmektedir. Literatürdeki çalışmalar incelendiğinde, derin öğrenme yöntemlerinin BBA sistemlerinde başarılı sonuçlar sağladığı görülmektedir. Derin öğrenme sistemlerinin güçlü öznelik çıkarma yetenekleri ve bunları BBA sistemlerine etkili bir şekilde entegre edebilmesi, bu performans iyileştirmesine olanak tanımaktadır. BBA sistemlerindeki bu olumlu gelişmelere rağmen, bu sistemler halen esneklikten yoksundur. Bunun en önemli nedeni, BBA sistemlerinde kullanılan mevcut elektrot sayısının fazla olmasıdır. Bu durum hem kullanıcı deneyimini olumsuz etkileyerek sistemlerin esnekliğini sınırlamakta hem de gerçek zamanlı işlemleri zorlaştırmaktadır. Elektrot sayısını azaltmak, hem kullanıcı konforunu artırmak hem de sistemlerin taşınabilirliğini ve kullanım kolaylığını iyileştirmek için kritik önem taşımaktadır. Bu nedenle, sınırlı sayıda elektrot kullanarak yüksek performans elde edebilen BBA sistemleri geliştirilmesi, BBA sistemlerinde mevcut sorunların iyileştirilmesine olanak sağlayacaktır.

Bu tez çalışmasında üç farklı deney uygulanmıştır. İlk deneyde, MHH EEG sinyallerindeki gürültüleri temizlemek amacıyla mevcut bazı gürültü temizleme algoritmaları kullanılmış ve test edilmiştir. Bu aşamada, elektrookülogram (EOG) elektrotlarının da gürültü temizleme sürecinde derin öğrenme sistemleri tarafından kullanılması değerlendirilmiştir. EOG elektrotları göz hareketlerini yakalayarak bunların EEG sinyallerine dahil edebileceği gürültüleri temizlemek için faydalıdır. Bu ilk deney sırasında, Ortak Ortalama Referanslama (OOR), EOG Regresyonu, Dalgacık Temelli Gürültü Temizleme ve Ortak Uzamsal Örüntü (OUÖ) yöntemleri kullanılmıştır. OUÖ dışındaki tüm yöntemler, gürültü temizleme yöntemidir. OUÖ ise bir dönüşüm yöntemidir, iki sınıfı birbirinden ayırt edebilecek bir dönüşüm yaratır. Dolayısıyla, bu dönüşüm aşamasında sinyalleri gürültüden arındırma potansiyeline sahip olduğu için burada kullanılmış ve diğer yöntemlerle performansı karşılaştırılmıştır. Tüm bu yöntemler için veri kümesinde mevcut tüm EEG

elektrotları kullanılmıştır, yani bu aşamada elektrot azaltılması uygulanmamış sadece gürültü temizleme algoritmaları test edilmiştir. Ayrıca, mevcut EEG elektrotlarına EOG elektrotları da dahil edilerek kullandığımız derin öğrenme sisteminin göz hareketi kaynaklı gürültüleri yakalaması beklenmiş ve elde edilen sonuçlar diğer yöntemlerle kıyaslanmıştır.

İkinci ve üçüncü deneylerde, elektrot sayısını azaltarak yüksek performans elde edilmeye çalışılmıştır. Bu deneylerde MHH BBA sistemlerinde her bir veri kümesinde bulunan tüm denekler için ortak olacak şekilde elektrotlar seçilmiştir. Literatürdeki çalışmaların çoğunda elektrot seçimi bireysel olarak, denek bazlı yapılmaktadır. Denek bazlı elektrot seçimi her bir denek için iyi performans sağlasa da, BBA sistemlerinin esnekliğini artırma açısından yetersiz kalmaktadır. Bu nedenle tüm denekler için ortak elektrotlar belirlemek sistemlerin genelleştirilebilirliğini ve kullanım kolaylığını artırma açısından önem taşımaktadır. Ayrıca literatürde elektrot azaltma süreci için çoğunlukla iki sınıflı veri kümesi kullanılmıştır. İki sınıflı sınıflandırma problemi için elektrot azaltma süreci daha kolaydır, çünkü bu genellikle iki sınıfın beyindeki merkezlerinin birbirine uzak olduğu durumlarla ilişkilidir. Çok sınıflı sınıflama problemlerinde bu süreç daha zordur, ancak BBA sistemlerinin genelleştirilmesi açısından bu adım oldukça gereklidir. Dolayısıyla kullanmış olduğumuz veri kümeleri en az 4 sınıftan oluşmaktadır.

İkinci deneyde filtreleme yöntemleri olan diverjans analizi ve rayleigh katsayı haritası kullanarak en uygun EEG elektrotları bulunmuştur. Bu adımda mevcut elektrotlardan beş elektrot seçerek sınıflandırma performansları elde edilmiştir. Ayrıca bazı ön işlem ve veri çoğaltma (artırma) işlemleri de bu ikinci deney aşamasında az sayıda elektrodun performansını artırmak için kullanılmıştır. Üçüncü deneyde ise ilk deneyde kullanmış olduğumuz EOG elektrotlarının önemine ilişkin çalışmalar hem filtreleme hem de sarmalama tabanlı yöntemlerle elde edilmiştir. EOG'nin önemi anlaşıldıktan sonra, az sayıda EEG elektroduyla mevcut EOG elektrotları birleştirilerek performans sonuçları gözlemlenmiştir. Bu üçüncü deneyde Karşılıklı Bilgi, Ortak Uzamsal Örüntü (OUÖ), Kanal Dikkat Mekanizması (KDM), Permütasyon Önem Skoru ve Rastgele Arama Algoritması elektrot seçim (önem) aşamasında kullanılmıştır.

Bu tezin ilk bölümünde MHH BBA sistemlerine giriş yapılmış ve ilgili literatür incelenmiştir. İkinci bölümünde EEG tabanlı BBA sistemleri tanıtılmıştır. Bu bölümde Kararlı Hal Görsel Uyarılmış Potansiyel tabanlı BBA, P300 tabanlı BBA ve Motor Hareket Hayali tabanlı BBA sistemleri anlatılmıştır.

Üçüncü bölümde, EEG verileri için ön işleme adımları tanıtılmıştır. Burada bahsedilen metotlar, hem ön işleme adımlarını hem de dönüşüm yöntemlerini temsil etmektedir. Bu metotlar, sinyalleri derin öğrenme mimarisine vermeden önce, gerçek bilgiyi yalın bir şekilde ortaya koyabilmesi için büyük önem taşımaktadır.

Dördüncü bölümde, tezde kullanılan elektrot seçim algoritmaları kapsamlı bir şekilde anlatılmıştır. Burada hem filtreleme tabanlı yöntemler hem de sarmalama tabanlı yöntemler ele alınmıştır. Bu yöntemler etkili bir elektrot seçimi yapılabilmesi için oldukça önemlidir çünkü doğru elektrotlar, beyin sinyallerinin daha doğru bir şekilde alınmasını ve analiz edilmesini sağlar. Elektrot seçim süreci, BBA sistemlerinin verimliliğini doğrudan etkileyen bir adımdır ve sistemin genel başarısına katkı sağlar. Ayrıca, elektrotların doğru seçimi, gereksiz veri noktalarının elimine edilmesine ve böylece sistemin daha hızlı ve verimli çalışmasına olanak tanır.

Beşinci bölümde derin öğrenme metotlarına giriş yapılmıştır. Burada kısaca Yapay Sinir Ağları (YSA) ve Evrimsel Sinir Ağı (ESA)'dan bahsedilmiştir. Daha sonra tezde önermiş olduğumuz iki farklı model tanıtılmıştır.

Altıncı bölümde, gerçekleştirilen deneyler ve elde edilen sonuçlar paylaşılmıştır. Yapmış olduğumuz üç farklı deneyin sonuçları bu bölümde anlatılmıştır.

Son olarak yedinci bölümde, elde edilen sonuçların önemi ve gelecekte yapılacak çalışmalar anlatılmıştır.

Bu tezde elde edilen sonuçlar, BBA sistemlerinde az sayıda elektrot ile iyi sonuçlar alınabileceğini göstermektedir. Bu açıdan bakıldığında önermiş ve sunmuş olduğumuz bu çalışma BBA sistemlerinde karşılaşılan sorunlara bir çözüm olmaktadır. Elde edilen bu sonuçlar, özellikle pratik uygulamalarda BBA sistemlerinin daha yaygın kullanılmasını teşvik edebilir ve gelecekteki araştırmalar için yeni yönelimlere ışık tutabilir.





CLASSIFICATION OF MOTOR IMAGERY EEG DATA USING SUBJECT-INDEPENDENT COMMON ELECTRODES

SUMMARY

Brain-Computer Interface (BCI) systems have become increasingly significant as an advanced technology that enables users to control external devices directly through brain signals. The growing research in the field of BCI in recent years has expanded the potential of this technology, leading to its widespread application in various areas such as medical rehabilitation, treatment of neurological disorders, communication tools, and entertainment applications. Motor Imagery (MI) signals are a method used in BCI systems, allowing individuals to control devices by performing mental motor imagery. These signals are usually processed by analyzing EEG data via modification from the motor cortex.

In BCI systems, especially in recent years, effective performances have been achieved by applying deep learning methods. When the studies in the literature are examined, it is seen that deep learning methods provide successful results in BCI systems. The powerful feature extraction capabilities of deep learning systems and the ability to effectively integrate them into BCI systems make this performance improvement possible. Despite these positive developments in BCI systems, these systems are still not flexible and easy to use. The most important reason for this is the high number of electrodes used in BCI systems. This situation both negatively affects the user experience and limits the flexibility of the systems and makes real-time operations difficult. Reducing the number of electrodes is critical for both increasing user comfort and improving the portability and ease of use of the systems. Therefore, developing BCI systems that can achieve high performance using a limited number of electrodes will make it possible to improve the existing problems in BCI systems.

In this thesis study, three different experiments were conducted. In the first experiment, various noise reduction algorithms were employed and tested to clean noise from MI EEG signals. At this stage, the use of electrooculogram (EOG) electrodes in the noise reduction process by deep learning systems was also evaluated. During this experiment, common average referencing (CAR), EOG regression, wavelet-based noise reduction, and common spatial pattern (CSP) methods were utilized. All methods, except CSP, are noise reduction methods. CSP, on the other hand, is a transformation method that creates a transformation capable of distinguishing between two classes. Therefore, as this transformation step has the potential to denoise signals, it was included in the experiment, and its performance was compared with other methods. For all these methods, all available EEG electrodes in the dataset were used; no electrode selection was applied at this stage, and only noise reduction algorithms were tested. Additionally, by incorporating the existing EEG electrodes with EOG electrodes, it was anticipated that the deep

learning system used would capture noise caused by eye movements. The results obtained were compared with those of other methods.

In the second and third experiments, efforts were made to achieve high performance by reducing the number of electrodes. In these experiments, electrodes were selected in a way that would be common to all subjects in each dataset used in MHH BCI systems. In most studies in the literature, electrode selection is typically performed individually, on a subject-specific basis. While subject-specific electrode selection provides good performance for each individual, it falls short in enhancing the flexibility of BCI systems. Therefore, identifying common electrodes for all subjects is crucial for improving the generalizability and ease of use of these systems. Additionally, in the literature, the electrode reduction process has predominantly been applied to binary datasets. For binary classification problems, the electrode reduction process is relatively easier, as it is often associated with cases where the centers of the two classes in the brain are spatially distant. However, in multi-class classification problems, this process becomes more challenging, yet it is highly essential for the generalization of BCI systems. For this reason, the datasets we used consist of at least four classes.

In the second experiment, filtering methods such as divergence analysis and Rayleigh coefficient mapping were used to identify the most suitable EEG electrodes. At this stage, five electrodes were selected from the available set, and classification performances were evaluated. Additionally, certain preprocessing and data augmentation techniques were employed during this second experiment to enhance the performance of a reduced number of electrodes. In the third experiment, studies on the importance of the EOG electrodes used in the first experiment were conducted using both filtering and wrapper-based methods. After understanding the significance of EOG, performance results were observed by combining a small number of EEG electrodes with the existing EOG electrodes. In this third experiment, mutual information, common spatial pattern, channel attention mechanism (CAM), permutation importance score, and random search algorithm were utilized in the electrode selection (importance) stage

The first chapter of this thesis provides an introduction to MI-BCI systems and reviews the relevant literature. The second chapter introduces EEG-based BCI systems. In this chapter, Steady-State Visual Evoked Potential (SSVEP)-based BCI, P300-based BCI, and Motor Imagery (MI)-based BCI systems are discussed.

The third chapter introduces preprocessing steps for EEG data. The methods discussed here represent both preprocessing steps and transformation techniques. These methods are of great importance in presenting the raw signals in their purest form before feeding them into the deep learning architecture.

The fourth chapter provides a comprehensive discussion of the electrode selection algorithms used in this thesis. Both filtering-based and wrapper-based methods are examined. These methods are crucial for effective electrode selection, as accurately chosen electrodes enable more precise acquisition and analysis of brain signals. The electrode selection process directly impacts the efficiency of BCI systems and contributes to their overall success. Additionally, accurate electrode selection eliminates unnecessary data points, allowing the system to operate faster and more efficiently.

In the fifth chapter, deep learning methods are introduced. Here, Artificial Neural Networks (ANN) and Convolutional Neural Networks (CNN) are briefly mentioned. Then, two different models that we proposed in the thesis are introduced.

In the sixth chapter, the experiments conducted and the results obtained are presented. Three different experiments were carried out in this thesis, and the results of each and future work are explained in this chapter.

The results obtained in this thesis demonstrate that BCI systems can achieve good results with a limited number of electrodes. From this perspective, the study we have proposed and presented offers a solution to the challenges encountered in BCI systems. These results could particularly encourage the wider use of BCI systems in practical applications and shed light on new directions for future research.





1. GİRİŞ

Beyinden elde edilen sinyallerin işlenmesi günümüzde önem arz etmektedir. Bilim insanları tarafından bu konuda ciddi arařtırmalar yapılmakta ve yeni metotlar aranmaktadır. Motor Hareket Hayali (MHH) sinyalleri, Beyin-Bilgisayar Arayüzü (BBA) tasarımında kullanılan en elverişli yöntemlerden bir tanesidir. MHH sinyalleri, bireyin belirli bir uzvunu (örneğin el, kol veya ayak) hareket ettirmeyi hayal etmesi sırasında ölçülen beyin aktivitelerini temsil etmektedir. Elde edilen bu sinyaller her bir düşünceye, harekete karşılık gözlemlenip incelenir ve her bir amaca özgü MHH sinyalindeki deęişim anlamlandırılmaya çalışılır. Bu sinyaller genellikle elektroensefalografi (EEG) ile anlık olarak ölçülür ve kaydedilir. Ancak BBA sistemleri yalnızca EEG ile sınırlı değildir ve dięer beyin aktivitesi ölçüm yöntemlerini de içerebilir. Bu yöntemler arasında Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI), Fonksiyonel Yakın Kızılötesi Spektroskopisi (fNIRS), Magnetoensefalografi (MEG) ve Elektrokortikografi (ECoG) gibi teknikler bulunmaktadır. EEG dışındaki bu ölçüm yöntemlerinin çoęu genellikle sadece arařtırma ortamlarıyla sınırlı kalmaktadır. Bunun nedenleri arasında ise yüksek maliyet, taşınabilirlikten uzak olmaları ve hareket kısıtlamaları yer almaktadır. Örneęin, fMRI gibi yöntemlerin düşük zamansal çözünürlüęü, anlık beyin aktivitesini tespit etmek için yetersiz olabilir ve bu da gerçek zamanlı bir arayüz oluşturmayı zorlaştırır. Dahası, bu cihazlar genellikle büyük, sabit ve hassas bir kurulum gerektirir ve bu da onları klinik veya günlük yaşam ortamları için uygunsuz hale getirir.

Başarılı bir BBA sistemi geliştirilmesi, farklı alanlarda insanlıęa katkı sağlayacaktır. İlk olarak iyi bir BBA sistemi geliştirilmesi, konuşma ve fiziksel olarak zorluk çeken engelli bireylerin etrafındaki kişilerle iletişime geçebilmesi ve kendi hayatlarını idame ettirebilmesi açısından önemlidir. Bazı engelli bireylerde beyin, el ve bacak gibi kaslar için komutlar üretmekte ancak beyindeki hasar yüzünden bu komutlar ilgili kaslara ulaşamamaktadır. Böylece, geliştirilen BBA sistemleri ile engelli bireyler hayatlarında karşılařtıkları zorlukları bu sistemler aracılıęıyla çözmeye

imkanına sahip olacaktır. İkincisi, geliştirilen iyi bir BBA sistemi ile robot ve drone gibi cihazlar, EEG işaretleriyle hızlı ve doğru bir şekilde kontrol edilebilir. Son olarak ise iyi bir BBA sistemi geliştirilmesi ile özellikle son yıllarda geliştirilmeye çalışılan EEG işaretlerinin oyun konsolunda kullanılmasını daha verimli hale getirecektir.

1.1 Tezin Amacı

Başarılı derin öğrenme sistemleri, Motor Hareket Hayali (MHH) EEG sinyallerini sınıflandırmada etkili olabilse de, BBA sistemleri halen bazı önemli zorluklara sahiptir. Bu sistemlerin en önemli zorluklarından biri, kullanılan elektrot sayısının yüksek olmasıdır. Dolayısıyla, bu sistemleri daha esnek, taşınabilir ve verimli kılabilmek için kullanılan elektrot (kanal) sayısının azaltılması gerekmektedir. BBA sistemlerinde kullanılan sınıf sayısı arttıkça sınıflar arasındaki ayırım yapma karmaşıklığı daha fazla elektrot kullanımını gerektirdiğinden, bu zorluk çok sınıflı sınıflandırma senaryolarında daha belirgin hale gelmektedir. Ayrıca, BBA sistemleri için geliştirilen metotlar genellikle kişiye özeldir. Bir denek üzerinde iyi sonuç veren sistem bir başka denek üzerinde etkili olmayabilmektedir ve bu da geliştirilen birçok sistemin genelleme özelliğinin olmadığını göstermektedir.

Bu tezin amacı, çok sınıflı MHH BBA sistemlerinde tüm kullanıcılar için az sayıda ortak en iyi kanalları belirlemek ve kanal sayısının azaltımı sonrasında sınıflandırma performansını artırmaya çalışmaktır.

1.2 Literatür Araştırması

MHH EEG sinyalleri için literatürde çok sayıda çalışma bulunmaktadır. Bu çalışmaların bir kısmı, EEG sinyallerine uygulanan ön işlem veya dönüşüm metotlarının etkisini araştırmakta (bu gruptaki çalışmalar aynı zamanda EEG gürültüsünü temizlemeye yönelik yöntemleri de kapsamaktadır.), bir kısmı etkili derin öğrenme sistemi tasarımına yönelik geliştirilen yöntemlere odaklanmakta, bir kısmı yapay olarak komut (sınıf) sayısını artırmaya yönelik yapılan çalışmalara, bir kısmı ise elektrot sayısını azaltmaya yönelik çalışmalara odaklanmaktadır.

Özellikle uzamsal sinyal ön işleme olarak Ortak Uzamsal Örüntü (OUÖ) metodu MHH EEG’de vermiş olduğu etkili performanstan dolayı çoğu araştırmacı tarafından

tercih edilmektedir [1][2]. OUÖ ile bazı sinyal ön işleme ve öznitelik çıkarma tekniklerine ait performans kıyaslaması yapılan çalışmalarda OUÖ'nün daha başarılı sonuçlar verdiği görülmektedir. Kaynak [3]'te OUÖ ile Bağımsız Bileşen Analizi metodu kıyaslanmış ve çoğu durumda OUÖ'nün daha iyi performans gösterdiği gözlemlenmiştir. OUÖ çok kanallı MHH EEG sinyallerine ait uzamsal özellikleri çıkarmak için kullanılmaktadır fakat OUÖ EEG sinyallerinin frekans bandına önemli ölçüde bağımlıdır. Kaynak [4] ve [5]'te sırasıyla FBCSP (Filter-Bank OUÖ) ve FBRCSP (Filter-Bank Regularized OUÖ) metotları OUÖ'nün genişletilmiş versiyonları olarak kullanılarak bu soruna çözüm önerilmiştir. Bilindiği gibi OUÖ, ikili sınıflandırmalarda etkili sonuç vermektedir çünkü OUÖ'de amaç, iki farklı sınıf arasındaki farklılığı artırarak sınıflandırmayı kolaylaştırmaktır. Literatürde OUÖ'yü ikiden fazla sınıfa uygulayabilmek için bazı algoritmalar önerilmiştir. Kaynak [6] ve [7]'deki çalışmalarda OUÖ, bire-bir ('one-vs-one') veya bire-tümü ('one-vs-all') algoritmalarıyla ikiden fazla sınıf için kullanılması önerilmiştir. OUÖ'nün ikiden fazla sınıf için verimli bir şekilde kullanılabilmesi için Kaynak [8]'deki yazarlar tarafından yeni bir yöntem önerilmiştir. Önerilen metotta beynin her iki yarım küresindeki ERD (Olay İlişkili Desenkronizasyon) / ERS (Olay İlişkili Senkronizasyon) farklılıklarına bakılarak iki farklı sınıflandırıcı oluşturulur ve son karar bu iki sınıflandırıcıdan elde edilen sonuca göre yapılmaktadır. Dolayısıyla, dört sınıflı sınıflandırma problemi, iki tane ikili ('binary') sınıflandırma problemine dönüştürülmüştür. Bunun yanı sıra önerilen metotla çok daha az sayıda sınıflandırıcı kullanıldığı gösterilmiştir. Önerilen metot k sayıda sınıf için sadece $\log_2 k$ sayıda sınıflandırıcı kullanırken, bire-bir $k(k-1)/2$ ve bire-tüm k sayıda sınıflandırıcı kullanmaktadır.

Zamansal sinyal ön işleme metodu olarak ise Dalgacık Dönüşümü literatürde en sık tercih edilen metotlardan biridir. Dalgacık Dönüşümü, zaman ve frekans çözünürlüğünü aynı anda bulundurma özelliğine sahip olduğu için aynı zamanda etkili bir öznitelik çıkarım metodu olabilmektedir ve bu özellik EEG gibi durağan olmayan sinyallerde kullanılmasını cazip kılmaktadır. Dalgacık özellikleri olarak ise enerji [9][10], entropi [11], ortalama [10][12], standart sapma [12], varyans ve dalgacık katsayıları [13] kullanılan çalışmalar mevcuttur. Dalgacık özelliklerinin performans kıyaslaması üzerine yapılan bir çalışmada [14] ise en etkili sonucu Shannon Entropisi'nin verdiği görülmektedir. EEG sinyalini Dalgacık Dönüşümü ile zaman-frekans görüntülerine çevirmek ve bu şekilde sınıflandırma yapmak yukarıda

bahsedilen EEG sinyali üzerinden Dalgacık Dönüşümüne ait istatistiksel özellikleri kullanmaya göre daha iyi sonuç verdiği ve dolayısıyla son yıllarda daha fazla tercih edildiği görülmektedir [15][16].

MHH EEG sistemlerinde göz hareketi kaynaklı gürültüleri azaltmaya odaklanan bazı çalışmalar bulunmaktadır. Kaynak [17]'de, MHH'nin gerçekleştiği uzvun karşı tarafında (kontralateral) bulunan bir elektrookülogram (EOG) kanalı kullanılarak, EOG kanalları arasında gereksiz etkilerden kaçınılmış ve MHH ile ilişkili sinirsel potansiyelleri koruyan yeni bir normalizasyon modeli geliştirilmiştir. Beynin motor kontrolünün genellikle kontralateral (karşıt) vücut tarafını etkilediği göz önüne alındığında, bu kanal seçimi MHH ile ilişkili sinyallerin daha doğru bir şekilde yakalanmasını hedefler. Hjorth özellikleri uygulanarak, normalizasyon modeli için alt-optimal ağırlıklar öğrenilmiş ve test verilerinde MHH sınıflandırma doğruluğu artırılmıştır. Kaynak [18]'de, EOG artefaktlarını kaldırmak için hesaplama açısından bir doğrusal regresyon modeli kullanılarak, gürültü etkili bir şekilde azaltılmış ve MHH sınıflandırmasını iyileştirmek için gerekli sinirsel sinyaller korunmuştur. Kaynak [19]'da, regresyon analizi ile Bağımsız Bileşen Analizi beraber kullanılarak, orijinal sinyalleri geri kazanmak için otomatik bir gürültü azaltma yöntemi geliştirilmiş ve EOG artefaktları etkili bir şekilde giderilerek, doğru MHH sınıflandırması için kritik olan sinirsel bilgi korunmuştur. Bir çalışmada [20], Bağımsız Bileşen Analizi doğrudan EOG sinyallerine uygulanarak, artefakt bileşenleri tanımlanmış ve bu bileşenler EEG verilerinden etkili bir şekilde çıkarılmıştır. Başka bir çalışmada [21], EEG ve EOG tabanlı yeni bir hibrit BBA sistemi tasarlanmış ve çevrimiçi hedef seçim deneyinde uygulanmıştır. Bu hibrit sistemde, EOG sinyallerinden elde edilen göz hareketi yönü ve EEG sinyallerinden MHH ile tetiklenen olayla ilişkili (de)senkronizasyon (ERD/ERS) aktiviteleri aynı anda tespit edilmiştir. Hedef seçme mekanizması, göz hareketi yönü ile ERD/ERS aktivitelerinin birleştirilerek değerlendirilmesine dayanmaktadır. Bu kapsamlı analizde [22], filtrelenmemiş ve on iki farklı alçak geçiren filtre ile filtrelenmiş EOG sinyalleri, beş algoritma ile test edilmiştir: basit regresyon, en küçük kareler, yinelemeli en küçük kareler, REGICA ve AIR. İstatistiksel sonuçlar, EOG sinyalleri için 6-8 Hz arasındaki alçak geçiren filtre frekansının, bidireksiyonel kirlenmeyi en aza indirerek ve artefakt kaldırma algoritmalarının performansını artırarak en optimal filtrelemeyi sunduğunu göstermektedir. EOG kanalları, MHH ile ilişkili sinirsel

aktiviteleri de kaydedebilir; bu da kaydedilen EOG sinyalinin hem MHH ile ilişkili sinirsel potansiyelleri hem de göz hareketi sinyallerini içerdiği anlamına gelir [23].

Mevcut literatürde, MHH EEG sinyallerinde kanal (elektrot) sayısının azaltılmasına yönelik çalışmalar bulunmaktadır. Ancak, bu çalışmaların çoğu yalnızca iki sınıflı sınıflandırma problemlerine odaklanmaktadır [24-41]. Bu nedenle, yalnızca iki sınıf içeren bir MHH sınıflandırma problemiyle karşılaşıldığında, sınıflandırma görevi genellikle basitleşmektedir. Bunun sebebi, bu iki sınıfın beyindeki aktivasyon merkezlerinin genellikle birbirinden oldukça uzak olmasıdır.

MHH EEG sinyallerinde kanal seçimi amacıyla filtreleme tabanlı tekniklere [24, 26, 28-30, 34, 39-42] ve sarmalama tabanlı tekniklere [25, 27, 31-33, 43-45] odaklanan mevcut çalışmalar bulunmaktadır. Kanal azaltımı bağlamında filtreleme tabanlı teknikler, belirli kriterler veya istatistiksel ölçütler kullanılarak en alakalı kanalları sıralamayı veya seçmeyi içerir. Sarmalama tabanlı teknikler ise, sınıflandırma performansını optimize eden kanal alt kümesini belirlemek için çeşitli kanal kombinasyonlarını keşfeden yinelemeli yaklaşımlardır. Bu yöntemler, farklı kanal kombinasyonlarını sistematik bir şekilde değerlendirir ve bunların sınıflandırma doğruluğu veya diğer performans ölçütleri üzerindeki etkisini inceler. Sarmalama yöntemleri, kanallar arasındaki etkileşimlerin sınıflandırmada önemli bir rol oynadığı durumlarda önemlidir. Ancak bu yöntemler, kullanılan spesifik sınıflandırıcıya bağımlıdır ve bu nedenle, seçilen kanalların optimalliği farklı bir sınıflandırıcı (veya bir derin öğrenme modeli) kullanıldığında devam etmeyebilir. Sınıflandırıcı performansını bir özellik (kanal) seçimi kriteri olarak kullanmak, eğitim veri kümesinde yüksek doğruluğa sahip bir özellik alt kümesine yol açabilir; ancak, bu özellikler bazı durumlarda farklı veri kümelerine iyi bir şekilde genellenemeyebilir [46].

Öte yandan, çalışmaların çoğu, kişiye (deneğe) bağlı ('subject-dependent') kanal seçimine odaklanmaktadır [37, 39-45, 47, 48]. Kişiye bağlı kanal seçimi, bireysel kullanıcılar için yüksek performans sağlayabilirken, farklı kullanıcılar arasında genellenebilirlikten yoksundur. BBA sistemlerini iyileştirmek için, yalnızca bireyler için etkili olan sistemler değil, aynı zamanda daha genel bir çerçeveye sunan yaklaşımların geliştirilmesi kritik önem taşımaktadır. Bu, farklı kullanıcılar ve senaryolar arasında iyi performans gösterebilen, daha sağlam ve uyarlanabilir BBA sistemlerinin oluşturulmasına olanak tanıyacaktır.

Derin öğrenme sistemleri, MHH EEG sinyallerinin sınıflandırılması için etkili araçlar olarak kullanılmaktadır. Başarılı derin öğrenme sistemlerinin seçilmesi veya tasarlanması, MHH sinyallerinin sınıflandırılmasında önemli bir rol oynar. Bu sistemler yalnızca gelişmiş sınıflandırıcılar olarak hizmet etmekle kalmaz, aynı zamanda öznetelik çıkarmada da başarılı bir şekilde çalışır. Derin öğrenme modelleri, MHH verilerindeki karmaşık desenleri otomatik olarak öğrenir ve temsil eder, böylece zaman alıcı bir süreç olabilen manuel özellik çıkarma mühendisliğine olan ihtiyacı ortadan kaldırır. Kaynak [49]'da, araştırmacılar Tam Bağlantılı Sinir Ağı ('Fully Connected Neural Network') yerine Minimum Mesafe Ağı'nı (MMA) kullanmayı seçtiler. Düğüm ve parametre sayısını etkili bir şekilde azaltmak için Walsh vektörlerini çıkış katmanında kullanmışlardır. DivFE ('Divergence-based Feature Extractor') adlı bu yenilikçi yöntem, geleneksel derin öğrenme sistemlerinin sınırlamalarını ele almak için özel olarak tasarlanmış farklı bir derin öğrenme modeli sunmaktadır. Algoritmalarının MHH EEG sinyallerini sınıflandırmadaki etkinliği de gösterilmiştir [49, 50]. EEGNet [51], EEG veri analizi için özel olarak tasarlanmış derin öğrenme mimarisidir. EEG sinyallerindeki hem zamansal hem de uzamsal örüntüleri verimli bir şekilde yakalamak için zamansal evrişimsel (konvolüsyon) katmanlar, derinlikte ayrılabilir evrişimlerle ('depthwise separable convolution') birlikte kullanılır. Bu tasarım, özellikle EEG verilerinin kendisine ait özelliklerini ele almada etkilidir ve bu da onu MHH sınıflandırması gibi görevler için güçlü bir araç haline getirmektedir. Kapsül Ağları [52], özellikle verilerdeki hiyerarşik ilişkileri ve uzamsal hiyerarşileri ele almada geleneksel Evrişimsel Sinir Ağları'nın (ESA) bazı sınırlamalarını aşmak için tasarlanmış sinir ağı mimarisidir. Kapsül Ağları, karmaşık verilerdeki uzamsal hiyerarşileri anlamada diğer mimarilere kıyasla etkilidir. Araştırmacılar, bu sinir ağı modelinin MHH EEG sinyallerinin sınıflandırılmasında da etkili olduğunu göstermişlerdir [53].

MHH-BBA sistemlerinde birden fazla uzva ait MHH beraber kullanılarak komut artırımı yapılabilmesiyle ilgili literatürde bazı çalışmalar mevcuttur. Literatürde genelde iki veya dört komutlu MHH-BBA sistemleri geliştirilmiştir. Komut sayısı arttıkça performansın düştüğü bilinmektedir. Özellikle birleştirilmiş MHH'lar kullanılarak komut artırımı yapmak, aynı sinyalin birden fazla sınıfta bulunması nedeniyle sınıflandırmanın başarısız olacağı düşünülmektedir (örnek: sol el MHH ve her iki el MHH). Kaynak [54]'de, aynı zamanda BBA komut sayısını artırmak için

her iki el MHH'ından yararlanılmıştır; bu da sanılanın aksine iki farklı MHH komutunu birleştirerek BBA komut artırımı yapılabileceğine olanak sağlamaktadır. Bu çalışmada [55] yazarlar [54]'de yapılan çalışmayı bir adım ileriye götürerek sekiz komutlu bir MHH-BBA tasarlamışlardır. Burada beynin üç farklı bölgesine ait (sol taraf, sağ taraf ve merkez) aktivite durumuna göre komutlar belirlenmiştir. Beynin sağ bölgesinde sol el hareketi sırasında, beynin merkezinde ayakların hareketi sırasında ve beynin sol bölgesinde ise sağ el hareketi sırasında değişimler gözlemlenir. Dinlenme MHH ile beraber bu üç farklı MHH ve bunların kombinasyonlarıyla oluşturulan MHH'lar sayesinde toplamda sekiz farklı komut oluşturulabileceği gösterilmiştir. Bu çalışmada [50] ise, araştırmacılar 4 sınıflı bir veri kümesi kullanarak birleştirilmiş MHH'lar oluşturmuş ve bunlardan 10 farklı sınıf elde ederek başarılı bir şekilde sınıflandırmışlardır.

Şimdiye kadar yapılan çalışmaların çoğunda, MHH sinyallerinin sınıflandırılmasında her iki ayak MHH tek komut olarak kullanılmıştır. Bunun nedeni sağ ayak MHH ve sol ayak MHH'nin motor korteks bölgelerinin anatomik olarak birbirine çok yakın olmasıdır. Dolayısıyla, bunları (sol ayak MHH ve sağ ayak MHH) sınıflandırmak uzamsal filtrelemedeki ayrımın net olarak yapılamamasından dolayı zordur. FMRI ile yapılan bu çalışmada [56], sol ve sağ ayak MHH'ları arasındaki uzamsal dağılımların kan oksijen düzeyine bağlı (BOLD) aktivitelerinin benzer olduğu gösterilmiştir. Bir başka çalışmada [57] ise, Cz (merkez) kanalından elde edilen sağ ve sol ayak MHH alfa bandına ilişkin güç değerleri arasında bir fark olmadığı gözlemlenmiştir. Her iki ayak MHH'ların farklılıkları üzerine yapılan bu çalışmada [58] ise sağ ve sol ayak adım MHH'larında alfa bandına ilişkin ERD değerleri arasında farklılık olduğu gösterilmiştir.

1.3 Tez Organizasyonu

Bu tez çalışması, altı farklı bölümden oluşmaktadır. Bu bölümler aşağıda açıklanmaktadır:

- Bölüm 2'de EEG tabanlı BBA sistemlerine giriş yapılmış ve MHH BBA sistemleriyle ilgili ayrıntılı bilgi verilmiştir.
- Bölüm 3'te EEG verileri için ön işlem metotlarından bahsedilmiştir.
- Bölüm 4'te tezde kullanılan elektrot seçim metotlarına değinilmiştir.

- Bölüm 5'te ise tezde kullanılan derin öğrenme mimarilerinden bahsedilmiştir.
- Bölüm 6'da deneylerden elde edilen sonuçlar yer almaktadır.
- Son olarak, Bölüm 7'de tezde elde edilen sonuçlar ve gelecekte yapılacak çalışmalar tartışılmıştır.



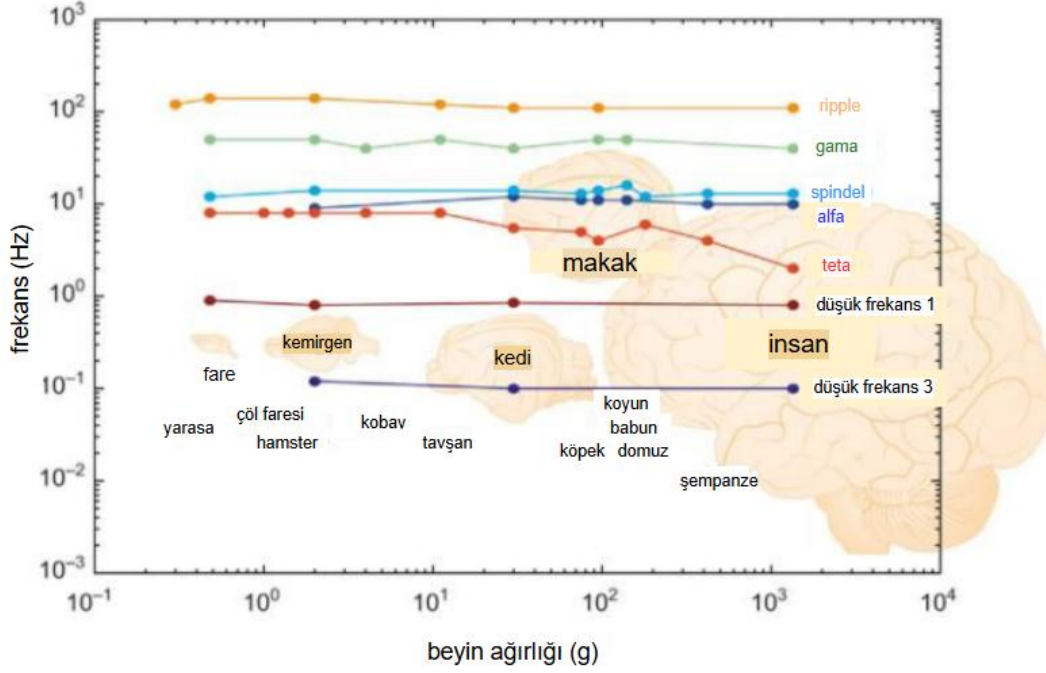
2. ELEKTROENSEFALOGRAFİ (EEG) TABANLI BEYİN-BİLGİSAYAR ARAYÜZÜ (BBA)

Nöronlar elektrokimyasal sinyaller yardımıyla bilgiyi işler ve diğer nöronlara gönderir. Yüklü iyonlar sürekli olarak bu nöronların içine ve dışına akar. Pozitif yüklü iyonlar nörona doğru akarken, nöronlar arasındaki hücre dışı akışkanlık negatif olarak yüklenir. Aynı anda, pozitif yüklü iyonlar nöronun dışına doğru akarken bu akışkanlık pozitif olarak yüklenir. Bundan dolayı nöron, iletken bir tel gibi davranır ve nöron etrafında elektrik alanı oluşturur. Dolayısıyla, bir nörona yakın elektrotlar yardımıyla bu nörona ait voltaj değişimi ölçülebilir. EEG gibi yöntemler, genellikle bir grup nöronun senkronize aktivitelerinden kaynaklanan potansiyel farklarını kaydeder. Beyinden elde edilen sinyaller, alt frekans bantlarına ayrıştırılarak çok sayıda analiz yapılmasına olanak sağlar. Bu alt bantlar delta (< 4 Hz), teta (4 – 7 Hz), alfa (8-12 Hz) ve beta (13-35 Hz)'dir. Her bir alt bant belirli durumlarda baskınlık gösterir. Örneğin, alfa dalgası dinlenme durumunda aktifken, beta dalgası bilincin çevreden gelen uyarılara açık olduğu durumlarda aktiftir.

EEG verisinin işlenmesinin avantajları ve dezavantajlarına bakacak olursak:

Avantajları:

- Aktivasyonları hızlı işleyebilme imkanı vardır çünkü bir boyutlu sinyalleri işlemek nispeten daha kolaydır [59].
- EEG, diğer ölçüm metotlarına kıyasla daha iyi zaman çözünürlüğüne sahiptir.
- Beyin aktivitesi herhangi bir cerrahi müdahaleye ihtiyaç duymadan (invaziv olmayan) kafatasının dışına bağlanan elektrotlar yardımıyla ölçülür.
- EEG sinyalleri insan beynine ait çok sayıda bilgiyi barındırdığı için bu sinyalleri kullanarak birçok analiz yapabilmemizi mümkün kılar.
- Bütün canlı türleri arasındaki EEG sinyalleri incelendiğinde her canlı türüne özgü EEG sinyalleri arasında tutarlılık görülmektedir. Bu durum Şekil 2.1'de gösterilmiştir.



Şekil 2.1: Farklı canlı türlerine özgü EEG sinyallerindeki tutarlılık [60].

Dezavantajları:

- EEG'de uzamsal çözünürlük kötüdür. Beynin aktivasyonlarının yerinin belirlenmesi için sık elektrot kullanılması gereklidir fakat bu hesaplama yükünü artırır.
- Tek bir nörona ait elektrik alanı çok küçük olduğu için EEG ile tek bir nörona ait aktiviteyi ölçmek mümkün değildir. Çünkü beyinde gerçekleşen hesaplamaların hepsi büyük ölçekte olmamakta, az sayıda nöron kullanılarak da bazı hesaplamalar yapılmaktadır. Dolayısıyla EEG, bu az sayıda nöron kullanılarak yapılan hesaplamaları ölçmemektedir [59].
- EEG ile ölçüm yaparken bir nörondaki elektrik alanı bir başka nörondaki elektrik alanının ters voltaj potansiyeline sahip olabilir. Böylelikle bu iki nöronun toplam potansiyel farkı sıfırlanabilir ve EEG sinyali bunu gözlemleyemez [59].
- EEG sinyallerinin elde edilmesi kolay olmasına rağmen karmaşık ve gürültülü olduğu için işlenmesi zordur.

EEG'nin BBA sistemlerinde yaygın kullanımı, yüksek zaman çözünürlüğü sayesinde beyindeki hızlı sinirsel aktiviteleri anında ölçebilmesinden kaynaklanmaktadır. Bunun yanında taşınabilir ve nispeten düşük maliyetli bir yöntem olması sayesinde daha fazla sayıda kullanıcı tarafından tercih edilmek istenmektedir. Ek olarak, EEG

sinyallerinin farklı bilişsel ve motor süreçleri temsil eden frekans bantlarıyla ayrıntılı analize izin vermesi de tercih edilmesinin bir diğer nedenidir.

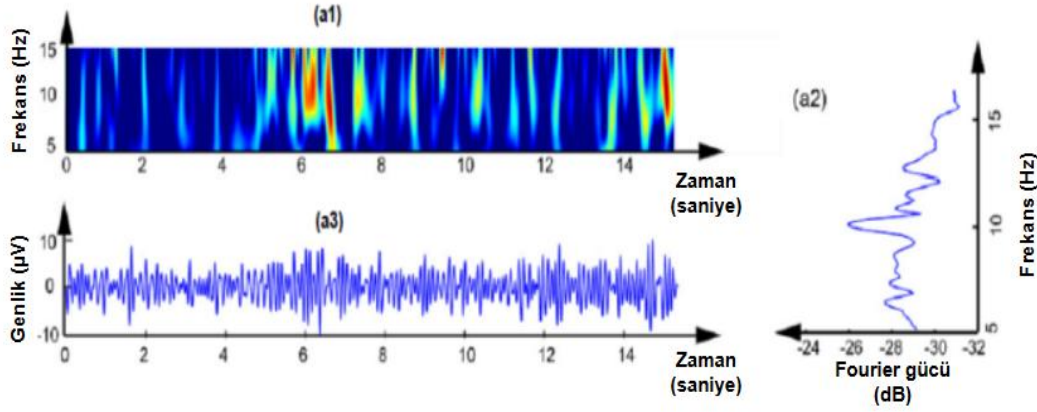
EEG sinyalleri başlangıçta nöbet aktivitesini izlemek gibi gözlemsel amaçlar için kullanılmış olsa da [61], iletişim amaçlı kullanılabilme potansiyeli büyük bir ilgi görmüştür [62]. Ayrıca, cihazları kontrol etmek gibi aktif görevlerdeki önemi ve kullanılabilirliği 1990'larda fark edilmiştir [63].

BBA sistemleri, farklı EEG tabanlı alt dallara ayrılmaktadır. Bunlar arasında Kararlı Hal Görsel Uyarılmış Potansiyel (KHGUP), korteksin belirli frekanslarla senkronize olma yeteneğine dayalı bir yöntem; P300, görsel uyarılara verilen yanıtla beyin aktivitesinin ölçülmesi; ve Motor Hareket Hayali (MHH), motor hareketlerin hayal edilmesiyle ilişkilendirilen beyin sinyallerinin kullanılması gibi farklı paradigmlar bulunmaktadır.

2.1 Kararlı Hal Görsel Uyarılmış Potansiyel (KHGUP) Tabanlı BBA

KHGUP, belirli bir frekansta tekrarlanan görsel uyarılara serebral korteksin tepkilerini ölçen EEG tabanlı bir tekniktir. Bu teknikte beyin aktiviteleri görsel uyarıların frekansı ile senkronize edilir ve bu da sinyalin analiz edilmesine olanak tanır. Görsel uyarılarla çalışan bir BBA sisteminde, kullanıcıya farklı frekansta yanıp sönen ışıklar (örneğin LED'ler) sunulur [64, 65, 66]. Kullanıcı bu ışıklardan birine odaklandığında, ilgili EEG frekans bileşeni, diğerlerinden daha belirgin olur ve bu, kullanıcının hangi uyarıcıya odaklandığını kolayca belirlemeyi sağlar. Şekil 2.2'de, KHGUP BBA sisteminde 10 Hz frekansında titreşen bir uyarıcıya bakılırken zaman, frekans ve zaman/frekans alanlarındaki örnek EEG sinyali gösterilmektedir.

Görsel stimülasyonun yanı sıra, işitsel (SSAEP) [67, 68] ve somatik (SSSEP) [69, 70] uyarımlar ile çalışan BBA sistemleri de geliştirilmiştir. KHGUP tabanlı sistemlerde, genellikle 20 Hz'den düşük frekanslar kullanılır ve en yüksek sinyal-gürültü oranı (SNR) 10 Hz civarındadır, bu da alfa dalgalarının frekans bandına (8-12 Hz) denk gelir. 10 Hz'nin üzerindeki frekanslarda, frekanslar arasındaki ayrılabilirlik azalır [71].



Şekil 2.2: 10 Hz frekansında titreşen bir hedefe bakarken KHGUP sinyali. a1) Zaman, a2) Frekans, a3) Zaman-frekans eksenini [71].

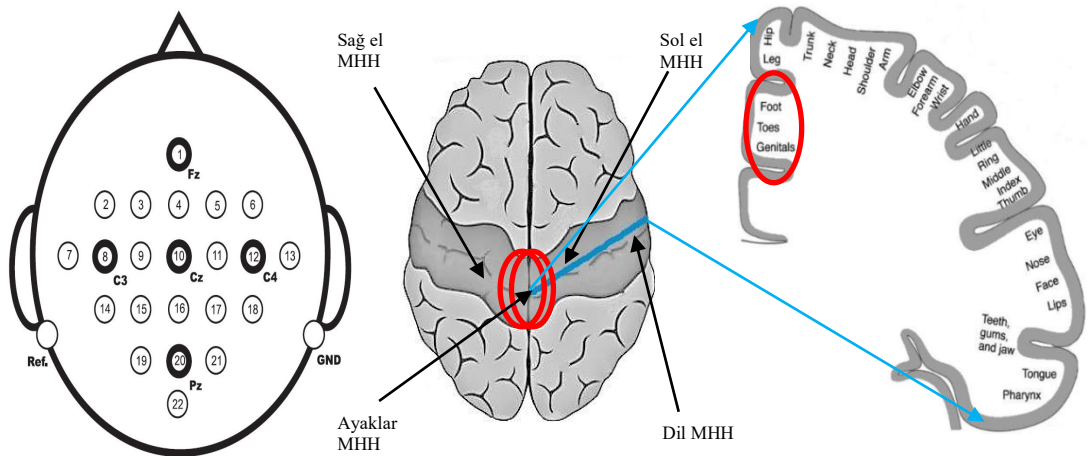
2.2 P300 Tabanlı BBA

P300 tabanlı BBA, beynin parietal bölgesinde yaklaşık 300 ms gecikmeyle ayırt edilebilir bir sinyal değişikliği üreten uyarılarla tetiklenen bir tepkiyle ortaya çıkmaktadır. Bu yöntemin etkili bir şekilde çalışması için, bireyin dikkatini belirli bir görsel veya işitsel uyarıya odaklaması gerekir; böylece beklenen sinyal değişikliği parietal bölgede gerçekleşir. İlk P300 tabanlı BBA sistemi hakkında ayrıntılı bilgi Kaynak [72]'te verilmiştir. P300 tabanlı BBA sistemleri, özellikle iletişim kısıtlılığı yaşayan bireyler için etkili bir araç olarak öne çıkmaktadır. Bu paradigma, kullanıcının dikkatini belirli bir uyarı üzerinde yoğunlaştırmasını gerektirdiği için, kullanıcı niyetinin hızlı ve doğru bir şekilde algılanmasına olanak tanır. Ayrıca, P300 yanıtının güvenilirliği ve çoğu bireyde doğal olarak meydana gelmesi, bu yöntemin uygulama alanlarını genişletmekte ve nörolojik hastalıklar için bir değerlendirme aracı olarak da kullanılmasını sağlamaktadır. P300, beynin iç bilişsel süreçlerine dayanan bir sinyaldir ve bu sinyal, bireyin dikkatini bir uyarıya odaklaması sonucu oluşur. Bu, uyarıcının doğrudan etkisinden ziyade, beynin işleme süreçlerine bağlıdır. Öte yandan, KHGUP doğrudan görsel uyarıların etkisiyle oluşur ve uyarıcının frekansına senkronize olan bir beyin yanıtıdır. Yani, P300'ün oluşumu beynin işlevsel iç süreçlerine dayanırken, KHGUP dışsal uyarıların beynin görsel korteksine etkisiyle şekillenir.

2.3 Motor Hareket Hayali Tabanlı BBA

Motor Hareket Hayali (MHH) tabanlı BBA, kişinin motor bir hareketi hayal etmesi sırasında alınan beyin sinyallerinin işlenmesi ile o hareket hayalinin tahmin edilmesine dayanan yüksek teknolojik bir yaklaşımdır. Bu yöntem, özellikle felç, omurilik yaralanmaları veya diğer nörolojik hastalıklar nedeniyle hareket kısıtlaması yaşayan bireyler için önemli bir potansiyel taşıdır. MHH tabanlı BBA, kullanıcıların fiziksel hareketlerini doğrudan gerçekleştirmeleri yerine, motor hareketleri sadece zihinsel olarak hayal etmeleriyle sistemle etkileşime girmelerini sağlar. Bu sayede, hareket kontrolü ve çevresel etkileşimler artırılabilir, rehabilitasyon süreçlerine katkı sağlanabilir. MHH herhangi bir fiziksel çıktı olmaksızın bir hareketin zihinsel ön izlemesi olarak düşünülebilir. Motor bir hareketin hayali ve bu hareketin yürütülmesi sırasında benzer beyin bölgelerinin aktif olduğu yaygın olarak kabul edilmektedir. Bu nedenle, bu bölgeler hem işlevsel olarak hayal edilen veya temsil edilen hareketle aynı şekilde bağlantılıdır hem de bu hareketi üretmede aynı nedensel role sahiptir [73].

Motor hareketi veya Motor Hareket Hayali genellikle Şekil 2.3'deki koyu bantlı alanda gözlemlenir. Bazı denekler için bu aktivasyonlar koyu banttan öteye uzanabilir. Beyin birçok aktiviteyi aynı anda yönettiğinden, MHH sinyalleri diğer aktivitelerin sinyalleri arasında neredeyse kaybolabilir. Ayrıca, EEG sinyalleri düşük sinyal-gürültü oranına sahiptir. Bu nedenle, elektrotları MHH merkezlerine daha yakın yerleştirmek değerli bilgileri çıkarmak için bir avantaj sağlayabilir. Sol el, sağ el, ayak ve dil MHH'nin beyindeki merkezleri Şekil 2.3'de görülmektedir.



Şekil 2.3: El, ayak ve dil MHH'nin beyindeki konumları [50].

MHH tabanlı BBA sistemlerini kullanmak belli zorlukları da beraberinde getirebilmektedir. Bunlardan başlıcaları düşük uzamsal çözünürlük, denekler ve oturumlar arasındaki farklılıklar, sınırlı sınıf sayısı, durağan olmayan EEG ve deneyimsiz deneklerdir.

Uzamsal çözünürlük kafa tasının üzerine yerleştirilen elektrot sayısı ile ilişkilidir ve bu sayının artması daha yüksek bir uzamsal çözünürlük sağlar. Fakat bu, hesaplama yükünü artırır ve BBA sistemlerinde gecikmiş bir tepkimeye sebep olabilir. Ayrıca daha fazla elektrot kullanmak BBA'yı pratik olmayan ve rahatsız edici bir tasarım haline getirir.

Denekler ve oturumlar arasındaki farklılıklar, aynı hareketin hayal edilmesinde bile büyük ölçüde kendini gösterir. Bu farklılık, yalnızca kişiler arasında değil, aynı kişi için farklı zamanlarda gerçekleştirilen oturumlar arasında da gözlemlenebilir. ERD ve ERS sinyal özelliklerindeki uzamsal, spektral ve zamansal değişkenlik, sınıflandırıcının genelleme yeteneğini zayıflatarak performansını olumsuz etkiler. Aynı sınıflandırıcı, bir denek için yüksek performans sağlarken, başka bir denek için düşük performans gösterebilir.

Bir deneğin hayal ettirebileceği sınırlı sayıda uzvu bulunduğu için dolayı elde edilecek sınıf sayısı da sınırlıdır. Bu da yüksek sınıflı BBA sistemleri geliştirilmesi durumunu kısıtlamaktadır. Bir alternatif, aynı uzuv için farklı hareket türlerinin hayal edilmesiyle sınıf sayısının artırılmasıdır; örneğin bileğin birkaç farklı hareketi. Ancak bu durumda, aktivasyon merkezleri aynı uzamsal konumda üretileceği için düşük hata ile sınıflandırma yapmak daha zor olacaktır.

EEG sinyalleri, durağan olmayan bir yapıya sahiptir. Bu sinyallerin karakteristik özellikleri zaman içerisinde değişir, çünkü beyin aktiviteleri çeşitli faktörlere bağlı olarak farklılaşır. Örneğin, ruh hali, dışsal uyaranlar, yorgunluk ve bilişsel durumlar, EEG sinyallerinin özelliklerini etkileyebilir. Bu nedenle, adaptif algoritmalar ve etkili derin öğrenme teknikleri sıklıkla geliştirilmeye çalışılır, çünkü bu yöntemler zaman içindeki değişimleri dikkate alarak daha doğru sonuçlar elde edilmesine olanak sağlayabilir.

Deneklerin eğitimi BBA sistemlerinin temelini oluşturmaktadır. Deneklerden veriler toplanmadan önce bu konuda gerekli eğitimden geçirilmesi gerekmektedir. Bu da BBA sistemleri için zaman alıcı bir süreç haline gelmektedir. Eğitim süreci,

deneklerin MHH becerilerini geliřtirmelerini ve dođru beyin sinyalleri üretmelerini sađlamak için kritik öneme sahiptir. Ayrıca, yeterli eđitim verilmeden toplanan veriler, sistemin dođruluđunu ve güvenilirliđini olumsuz etkileyebilir.

Dolayısıyla, MHH tabanlı BBA sistemleri tasarlanırken bu sorunlar göz önünde bulundurulmalıdır.

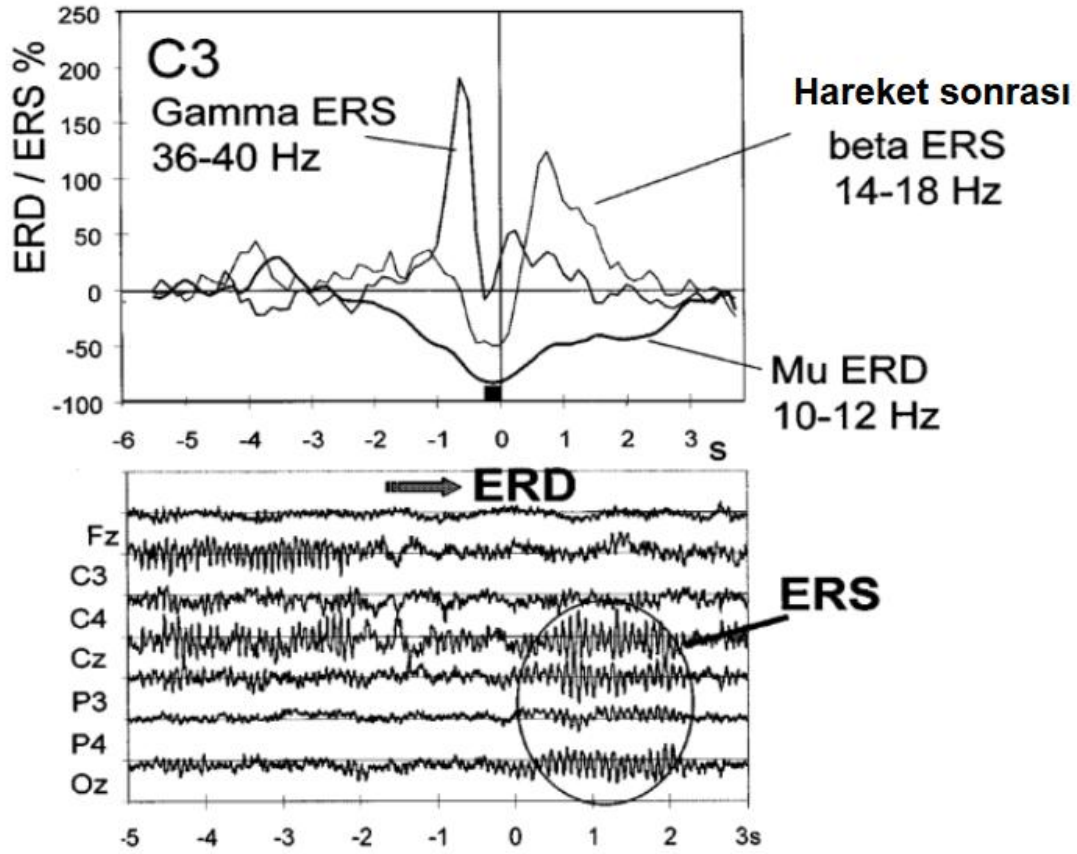
2.3.1 ERD / ERS

ERD/ERS (Olaya İliřkin Desenkronizasyon/Senkronizasyon), motor hareketi veya MHH sırasında EEG sinyallerinde belirli frekans bantlarında gözlenen güç deđişimlerini ifade eder. ERD, belirli bir beyin bölgesindeki nöronların senkron aktivitesindeki azalmayla iliřkili frekans bandındaki güçteki azalmadır. Buna karřılık, ERS, artan nöronal senkronizasyonun bir sonucu olarak frekans bandındaki güçteki artışı tanımlar. Bu fenomenler genellikle motor hareketleriyle iliřkili mu (8-12 Hz) ve beta (13-30 Hz) frekans bantlarında gözlenir. Örneđin, bir el hareketi sırasında veya sadece bu hareketin zihinsel hayali sırasında, motor kortekste ERD/ERS dinamikleri meydana gelir. Bu süreç, hem gerçek hem de hayali motor hareketlerinin beyindeki nöronal aktiviteyi nasıl düzenlediđini anlamak için önemli bir göstergedir ve motor kontrolünün nörofizyolojik mekanizmalarını incelemede kritik bir rol oynar.

Genel olarak, ERD veya ERS salınımları motor veya zihinsel aktiviteler veya uyarımlarla gözlemlenir. Bu salınımlar, nörokimyasal beyin sistemlerinin modüle edici etkileri, sinaptik etkileşimlerin gücündeki deđişiklikler veya yerel nöronların iç zar özelliklerindeki deđişiklikler nedeniyle olabilir. Duyusal ve bilişsel işleme ve motor davranıřla iliřkili beyin salınımlarının dinamikleri karmařık uzamsal-zamansal desenler oluşturabilir. Örneđin, belirli bir elektrot konumunda, düşük frekanslı bileşenlerin desenkronizasyonu içine gömülü yüksek frekanslı bileşenlerin senkronizasyonu aynı anda görülebilir. Farklı kafa derisi bölgelerinde, aynı anda 10 Hz bileşenlerin desenkronizasyonu ve senkronizasyonu da mümkündür [74].

Şekil 2.4'te ERD ve ERS desenlerini gösteren bir örnek verilmiştir. Bu figürde, üst panel, sađ iřaret parmađı kaldırma hareketi sırasında C3 elektrodundan elde edilen üç farklı frekans bandındaki (10-12 Hz, 14-18 Hz, 36-40 Hz) bant gücünü göstermektedir. Dikey çizgi, hareketin başlangıcını ($t=0s$) iřaret etmektedir. ERD'nin hareketten 2,5 saniye önce başladığı, hareket başlangıcından hemen önce gama bandındaki ERS'nin zirve yaptığı ve beta bandındaki ERS'nin hareketten sonraki bir

saniye içinde ortaya çıktığı görülmektedir. Alt panel ise üst panelle ilişkili olarak farklı elektrotlar için ERD ve ERS sinyallerini gösteren EEG zaman çerçevesini sunmaktadır. Buradan, hareket başlangıcından önce merkezi elektrot bölgelerinde EEG desenkronizasyonu (ERD) olduğu ve hareket sırasında alfa bandı aktivitesinde bir artış (ERS) gözlemlendiği belirtilmiştir.



Şekil 2.4: Motor görevi sırasında ERD ve ERS [74].

3. EEG VERİLERİ İÇİN ÖN İŞLEM METOTLARI

EEG sinyalleri genellikle göz hareketlerinden kaynaklanan artefaktlar, kas aktivitesi ve çevredeki elektronik cihazlardan gelen elektriksel parazit gibi çeşitli kaynaklardan gürültü içerir ve bu da gerçek beyin aktivitesinin doğru bir şekilde analiz edilmesini zorlaştırabilir. Etkili bir ön işlem adımı, sinyal kalitesini artırarak, derin öğrenme modellerinin yalnızca ilgili ve anlamlı özelliklere odaklanmasını sağlar. Aynı zamanda, bazı dönüşüm metotları, sinyallerin zaman-frekans özelliklerini veya uzamsal desenlerini daha belirgin hale getirerek sınıflandırmayı kolaylaştırabilir. Bu yöntemler, özellikle karmaşık sinyallerde belirli bir sınıfa özgü olan ayırt edici özelliklerin öne çıkarılmasına yardımcı olur ve modelin performansını artırabilir. Burada ön işlem adımı olarak bahsettiğimiz hem ön işlem adımlarını (gürültü temizleme algoritmaları dahil şekilde) hem de dönüşüm metotlarını kapsamaktadır.

3.1 Ortak Ortalama Referanslama (OOR)

Ortak Ortalama Referanslama (OOR), Motor Hareket Hayali (MHH) EEG sinyallerinin kalitesini artırmak için tercih edilen etkili bir ön işlem metodudur. Bu yöntem, her bir elektrodun kaydettiği sinyalden, tüm elektrotların aynı anda ölçtüğü sinyallerin ortalamasını çıkararak çalışır. OOR'un temel amacı, elektrotlar arasında ortak olan gürültü kaynaklarını azaltmaktır. Bu ortak gürültüler genellikle ortam kaynaklı elektriksel parazitler veya kafa derisi boyunca yayılmış biyolojik artefaktlar (örneğin, geniş kas hareketleri) gibi faktörlerden kaynaklanır. Bu yöntem özellikle tüm elektrotları aynı anda etkileyen gürültüleri başarılı bir şekilde azaltarak sinyal-gürültü oranını artırır. Ancak, OOR yerel artefaktlar üzerinde sınırlı bir etkiye sahiptir; örneğin, göz hareketi veya bölgesel kas aktivitelerinin neden olduğu gürültü bu yöntemle tam olarak ortadan kaldırılamaz. Dolayısıyla, OOR genellikle başka ön işlem yöntemleriyle birlikte kullanılır. OOR'un matematiksel ifadesi Denklem 3.1'de [75] verilmiştir.

$$S_i' = EEG_i - \bar{S} \quad (3.1)$$

Burada, S_i' i-inci elektrodun yeniden referanslanmış sinyalini, EEG_i , i-inci elektrodun kaydedilen orijinal sinyalini ve \bar{S} ise Denklem 3.2'de [75] gösterildiği gibi N elektrodun tamamı üzerinden hesaplanan ortalama sinyali gösterir ve boyutu veride mevcut olan zaman noktasına eşittir.

$$\bar{S} = \frac{1}{N} \sum_{j=1}^N EEG_j \quad (3.2)$$

3.2 Elektrookulografi (EOG) Regresyonu

Bu teknik, göz kırpması ve göz hareketi sırasında EEG sinyallerinde meydana gelen gürültüleri gidermek için kullanılır. Bu yöntem, EEG sinyalleriyle eşzamanlı olarak EOG sinyallerinin kaydedilmesini ve ardından EEG'nin gözle ilgili aktivitelere atfedilebilecek kısmını tahmin etmek ve çıkarmak için regresyon analizinin kullanılmasını içerir. Özellikle, EEG sinyallerinin bağımlı değişkenler, EOG sinyallerinin ise bağımsız değişkenler olarak yer aldığı bir doğrusal regresyon modeli oluşturulur. Regresyon parametreleri, gözlemlenen EEG sinyalleri ile EOG ölçümlerinden tahmin edilen sinyaller arasındaki kare farklarının toplamını en aza indiren en küçük kareler tahmini yöntemi kullanılarak belirlenir. Bu yöntem, kaynak [76]'da açıklandığı şekilde gerçekleştirilir. Regresyon parametreleri elde edildikten sonra gürültüden arındırılmış EEG sinyalleri Denklem 3.3'de [75] gösterildiği gibi elde edilir.

$$EEG_i' = EEG_i - (\beta_0 + \beta_1 * EOG_{1i} + \beta_2 * EOG_{2i} + \dots + \beta_k * EOG_{ki}) \quad (3.3)$$

Burada, EEG_i' i-inci elektrottaki gürültüden temizlenmiş EEG sinyalini, EEG_i i-inci elektrottaki orijinal EEG sinyalini, β_0 regresyon modelindeki sabit terimi, $\beta_1, \beta_2, \dots, \beta_k$ parametreleri regresyon modelinden gelen her bir EOG kanalına ait katsayıları ve $EOG_{1i}, EOG_{2i}, \dots, EOG_{ki}$ farklı kanallardaki EOG sinyallerini temsil etmektedir.

3.3 Kısa Süreli Fourier Dönüşümü (KSFD)

Fourier Dönüşümü (FD), frekans bölgesi analizi yapan bir tekniktir. FD, zaman bölgesindeki sinyali frekans bölgesine aktarır ve böylece sinyalin frekans özelliklerinin elde edilmesi sağlanır [77]. Ancak, FD gibi statik spektral analiz yöntemleri, yalnızca zamanla özellikleri değişmeyen sabit sinyaller için iyi çalışır. Zamanla değişen sinyallerde, FD'nin sınırlamaları belirginleşir çünkü bu yöntem, sinyalin zamansal dinamiklerini yakalamakta zorlanır. Bu durum, özellikle MHH gibi durağan olmayan EEG sinyallerinde problem yaratabilir. FD, sinyalin tamamı üzerinden frekanslara özgü bilgileri elde eder, bu nedenle zaman bölgesindeki bilgilerin zamansal hassasiyeti kaybolur. Zaman bölgesindeki bilgilerin zamansal hassasiyetini, frekanslara özgü bilgilerle birleştirmek daha iyi bir yaklaşımdır. Zaman-frekans analizi, EEG sinyallerini hem zaman hem de frekans bölgesinde temsil ederek, durağan olmayan sinyallerin dezavantajını azaltır. Zaman-frekans analizi yöntemlerinden biri, KSFD'dir (Kısa Süreli Fourier Dönüşümü). EEG sinyalleri durağan olmadığından, KSFD, ön işlem veya öznitelik çıkarma yöntemi olarak tercih edilir. KSFD'de, sinyalin tamamı yerine kısa zaman pencereleri üzerinden Fourier dönüşümü alınır. Böylece hem zaman hem de frekans çözünürlükleri aynı anda elde edilmektedir. KSFD formülü Denklem 3.4'te [78] görülmektedir:


$$\text{KSFD}(x(t)) = \mathbf{X}(\tau, \omega) = \int_{-\infty}^{\infty} EEG(t)wp(t - \tau)e^{-j\omega t} dt \quad (3.4)$$

Burada $EEG(t)$ ve $wp(t)$ sırasıyla zaman bölgesindeki sinyali ve pencereleme fonksiyonunu temsil etmektedir.

EEG epokları genellikle belirli bir zaman diliminde kaydedilen beyin aktivitesini temsil eder ve bu veriler MHH gibi görevlerde kullanılır. KSFD, her bir epok için ayrı ayrı hesaplanır ve her bir epoktaki sinyalin zaman-frekans çözünürlüğü sağlanarak MHH gibi değişken beyin aktivitesinin daha doğru bir şekilde analiz edilmesine olanak tanır. Bu yaklaşım, sinyallerdeki anlık değişiklikleri yakalayıp sınıflandırma doğruluğunu artırabilir.

3.4 Sürekli Dalgacık Dönüşümü (SDD)

KSFD'nin eksikliği, zaman penceresi boyutunun tüm frekanslar için sabit olmasıdır. Bu eksiklik, dalgacık dönüşümü analiziyle çözümler; bu yöntem, değişken boyutlu bölümlerle pencereleme tekniği sunar, böylece düşük frekans bilgileri için daha hassas büyük zaman aralıkları ve yüksek frekans bilgileri için daha kısa bölgeler kullanılabilir. Bu durum Şekil 3.1'de gösterilmiştir.



Şekil 3.1: KSFD ve SDD için zaman pencere boyutlarının karşılaştırılması [78].

EEG sinyalleri, yüksek frekanslarda yüksek zaman çözünürlüğü gerektiren kısa süreli ani yükselişler içerir ve ayrıca düşük frekanslarda daha uzun EEG salınımları için nispeten yüksek frekans çözünürlüğüne ihtiyaç duyulmaktadır. Sürekli Dalgacık Dönüşümü (SDD), EEG sinyallerinin zaman-frekans analizinde en etkili yöntemlerden biridir [79]. Durağan olmayan sinyallerin değişken özelliklerini anlamak için, nispeten yüksek zaman ve frekans çözünürlükleri sağlar. SDD formülü Denklem 3.5'te [78] görülmektedir.

$$\mathbf{SDD}(a, b) = \langle EEG, \psi_{a,b} \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} EEG(t) \cdot \psi \left(\frac{t-b}{a} \right) dt \quad (3.5)$$

Burada, EEG orijinal sinyali ve Ψ ise dalgacık dönüşümünü temsil eder ve Denklem 3.6'daki [78] gibi tanımlanır.

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi \left(\frac{t-b}{a} \right), \quad a, b \in \Re \quad (3.6)$$

Burada a ölçek parametresini, b ise konum parametresini temsil eder. Ölçek parametresi, dalgacığı esnetmek veya sıkıştırmakla sorumludur, konum parametresi ise dalgacık fonksiyonunu zaman eksenini boyunca kaydırmakla sorumludur. SDD, a ve b parametrelerinin fonksiyonları olan birçok dalgacık katsayısı çıktısı üretir.

3.5 Dalgacık Temelli Gürültü Temizleme (DTGT)

Dalgacık Temelli Gürültü Temizleme (DTGT), sinyallerden gürültüyü ortadan kaldırarak temel özelliklerin korunmasını sağlar. Bu yaklaşım, gürültü ve sinyal özelliklerinin zamanla değiştiği durağan olmayan sinyaller için özellikle faydalıdır ve genellikle ses, görüntü ve EEG gibi biyolojik sinyallerin işlenmesinde kullanılır. DTGT, sinyalin Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform - DWT) kullanılarak dalgacık katsayılarına ayrılmasıyla başlar. Bu teknik, sinyali farklı frekans bileşenlerine ve çeşitli ölçeklere ayırarak ayrıntılı bir çoklu çözünürlük analizi sunar. Bu ayrıştırma sonucunda iki ana tür katsayı elde edilir: Yaklaşım katsayıları, sinyalin genel eğilimini veya düşük frekans bileşenlerini yansıtır. Detay katsayıları, genellikle gürültünün yoğunlaştığı yüksek frekans bileşenlerini temsil eder [75].

DTGT sürecinde katsayıların eşiklenmesi kritik bir adımdır. Bu adımda bir eşik değeri belirlenir ve bu eşik değerinin altında kalan katsayılar, çoğunlukla gürültüyü temsil ettikleri varsayılarak azaltılır veya sıfıra ayarlanır. Eşikleme için iki ana yaklaşım vardır:

Yumuşak Eşikleme (Soft Thresholding): Belirlenen eşik değeri kadar tüm katsayıların büyüklüğünü azaltır. Bu, küçük katsayıları tamamen sıfırlarken, büyük katsayıları hafifçe küçültür.

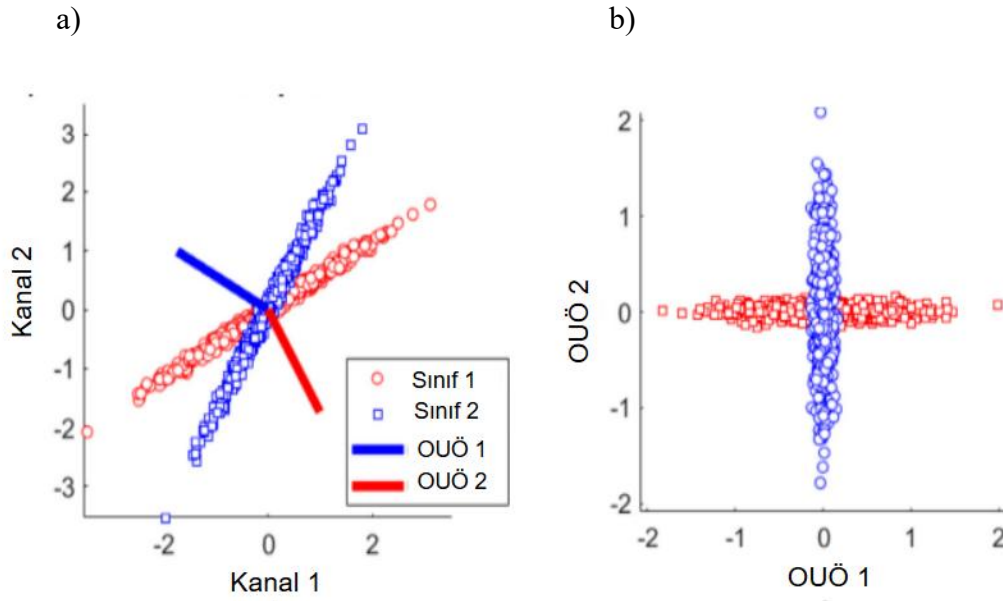
Kesin Eşikleme (Hard Thresholding): Eşik değerinin altında kalan katsayıları doğrudan sıfırlar ancak diğerlerini değiştirmez.

Eşikleme işleminin ardından temizlenen dalgacık katsayıları, Ters Ayırık Dalgacık Dönüşümü (Inverse Discrete Wavelet Transform - IDWT) kullanılarak yeniden bir sinyale dönüştürülür. Bu, orijinal girdinin temel özelliklerini koruyarak gürültü seviyelerini azaltılmış bir sinyal elde edilmesini sağlar [75].

3.6 Ortak Uzamsal Örüntü (OUÖ)

Ortak Uzamsal Örüntü (OUÖ), hızlı ve etkili bir uzamsal filtreleme yöntemidir ve birçok farklı alanda kullanılmaktadır. Beyinden elde edilen sinyallerin uzamsal olarak filtrelenmesinde en yaygın kullanılan metotlardan biridir. OUÖ, sinyallerin gürültüden arındırılması, boyut azaltma ve kaynak ayrıştırma için kullanılmaktadır. OUÖ kullanarak sınıfların birbirinden daha kolay ayrıştırılabilir olduğu Şekil 3.2'den görülmektedir. Burada, OUÖ uygulanmadan önce verilerin daha iç içe olduğu, ancak

OUÖ uygulandıktan sonra farklı iki sınıfa ait verilerin arasındaki farkın maksimuma ulaştığı gözlemlenmektedir. Şekil 3.2’de mavi ve kırmızı noktalarla temsil edilen iki veri kümesi bulunmaktadır. Şekil 3.2a’da bu iki veri kümesinin birbirine daha yakın olduğu görülmektedir. OUÖ uygulandıktan sonra, bu veriler Şekil 3.2b’de olduğu gibi daha belirgin şekilde ayrılmaktadır. Şekil 3.2b’de iki sınıf arasındaki farkın arttığı ve dolayısıyla sınıflandırmanın daha kolay hale geldiği açıkça gözlemlenmektedir.



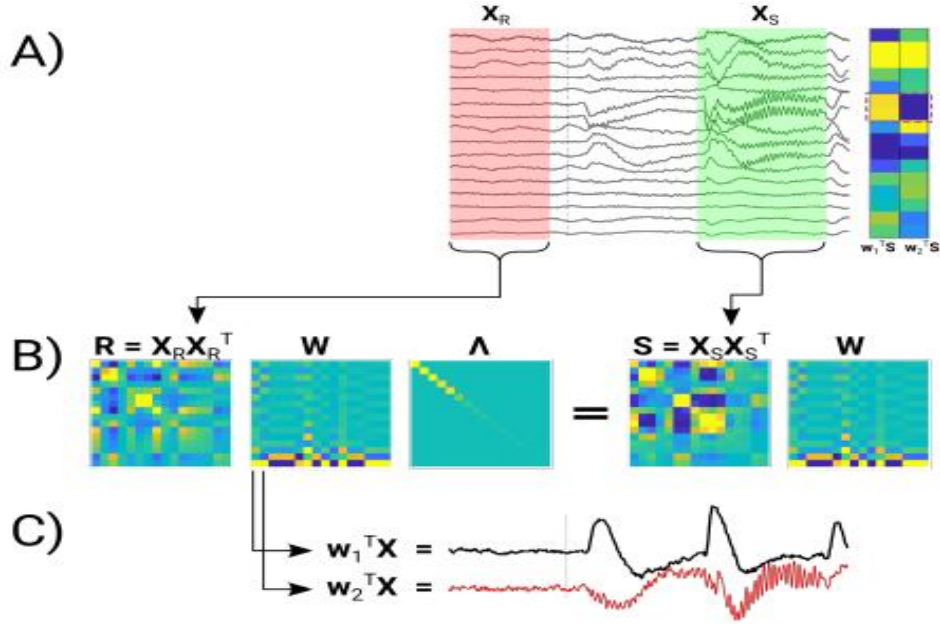
Şekil 3.2: a) OUÖ uygulanmadan önce. b) OUÖ uygulandıktan sonrası [80].

“OUÖ, veri içindeki birbiriyle ilişkili kısımlarla ilişkisi bulunmayan kısımları ayırarak farklılığı belirginleştirir.” “OUÖ tarafından gerçekleştirilen uzamsal filtreler, aynı veriye ait iki özellik arasındaki farklılığı maksimuma getirmek için tasarlanır – bir özellik farklılığı artırmak için, bir özellik ise referans olarak kullanılır” [80]. Bu özellikler bir deney koşulu ve bir kontrol koşulu veya birinci deney koşulu (örneğin, sol el MHH) ve ikinci deney koşulu (örneğin, sağ el MHH) olabilir. Dolayısıyla, OUÖ bir denetimli uzamsal filtreleme yöntemi olarak bilinir.

Belirlenen bu iki özelliği X_S (sinyal) ve X_R (referans) olarak adlandırdığımızda, OUÖ Şekil 3.3’te görüldüğü gibi çalışmaktadır.

Şekil-3.3-A’daki grafik, bir fareye görsel bir uyarı verildikten sonra elde edilen beyin sinyallerini göstermektedir. Şekilden de görüleceği üzere, X_S (sinyal) penceresi görsel uyarı başlatıldıktan kısa bir süre sonra belirli bir zaman dilimi boyunca

seçilirken, X_R (referans) penceresi ise görsel uyarı başlamadan hemen önceki zaman diliminde seçilmiştir. OUÖ ile amacımız görsel uyarı başladıktan sonraki sinyalin görsel uyarı başlamadan önceki sinyalle ayrıştırılmasını sağlayacak bileşenleri elde ederek sinyal-gürültü oranını veya sinyal-referans oranını artırmaktır.



Şekil 3.3: OUÖ'nün çalışma prensibi [80].

OUÖ, bu seçilen sinyaller üzerinden Şekil 3.3- B ve C'de gösterildiği şekilde çalışır. İlk olarak, seçilen iki zaman dilimine ait kovaryans matrisler elde edilir ve bu matrisler üzerinden genelleştirilmiş özdeğer ayrıştırması (generalized eigenvalue decomposition) gerçekleştirilerek özdeğerler ve özvektörler bulunur. Elde edilen özvektörler (W matrisi) uzamsal filtreleri ve Λ ise özdeğerleri (diyagonal matris) temsil etmektedir. Özvektörlerle ilişkili özdeğerler, S (X_S 'e ait kovaryans matris) ve R (X_R 'e ait kovaryans matris) oranını bu özvektörler boyunca temsil eder, yani özdeğer değeri yüksek olan özvektör, S ve R oranını (farklılığı) yüksek yapan bir özellik olur. Daha sonra elde edilen bu özvektörler bizim orijinal verimizle çarpılarak uzamsal filtrelenmiş (farklılığı belirginleştirilmiş) veri elde edilir.

3.6.1 Ortak Uzamsal Örüntü'nün matematiksel olarak ifadesi

OUÖ'yü matematiksel olarak elde etmek ve anlamak için Denklem 3.7'den [80] yararlanabiliriz. Burada X_S farklılığı belirginleştirilecek (referansa göre) sinyal ve X_R ise referans sinyal olarak adlandırılır ve her ikisi de belirtilen sinyal için kanal(elektrot)-zaman matrisi olarak temsil edilir.

$$\lambda = \frac{\|w^T X_S\|^2}{\|w^T X_R\|^2} \quad (3.7)$$

Denklem 3.7’de λ vektörün büyüklüğünü göstermektedir. λ ise w ile filtrelenmiş sinyalin, w ile filtrelenmiş referans sinayline oranının büyüklüğüdür. Denklem 3.7’yi düzenlersek:

$$\lambda = \frac{(w^T X_S)(w^T X_S)^T}{(w^T X_R)(w^T X_R)^T} = \frac{w^T (X_S X_S^T) w}{w^T (X_R X_R^T) w} \quad (3.8)$$

elde edilir.

Denklem 3.8’de [80], XX^T ilgili sinyal için kovaryans matrisidir. Kovaryans matris veriye ait kanallar arasındaki doğrusal ilişkiyi (correlation) gösteren ortalama-merkezli (mean-centered) bir kare matristir.

$S = X_S X_S^T$ ve $R = X_R X_R^T$ olmak üzere Denklem 3.8’i düzenlersek:

$$\lambda = \frac{w^T S w}{w^T R w}, \quad (3.9)$$

elde edilir.

Denklem 3.9’da [80], $w^T X w$ ilgili sinyal için ikinci dereceden form (quadratic form) olarak da bilinir.

OUÖ ile amacımız, sinyal-referans oranını maksimum yapan filtre değerlerini bulmaktır. Denklem 3.9’dan yola çıkarak burada λ parametresini maksimum yapacak w değerleri bizim filtre değerlerimiz olacaktır. Dolayısıyla, iki farklı veride ortak olarak bulunan verileri ihmal ederek farklılıklar belirginleştirilmeye çalışılacaktır.

Bu durum Denklem 3.10’da [80] gösterilmiştir.

$$\operatorname{argmax}_w \frac{w^T S w}{w^T R w}, \quad (3.10)$$

Denklem 3.10 sadece tek bir uzamsal filtre değeri ortaya çıkarır fakat toplam kanal sayısı boyunca uzamsal filtre değerini bazı kısıtlamalar dâhilinde elde edebiliriz.

Uzamsal filtreleri tek bir vektör değil de birden fazla vektör boyunca hesaplamak için Denklem 3.9 kullanılarak, Denklem 3.11 [80] elde edilir.

$$\Lambda = (W^T R W)^{-1} W^T S W \quad (3.11)$$

Denklem 3.11’de W içindeki her bir sütun bir uzamsal filtreyi ve Λ ise ilgili sütun doğrultusundaki oranı temsil eder.

Denlem 3.11'i düzenlersek;

$$\Lambda = (W^T R W)^{-1} W^T S W = W^{-1} R^{-1} S W \quad (3.12)$$

ve

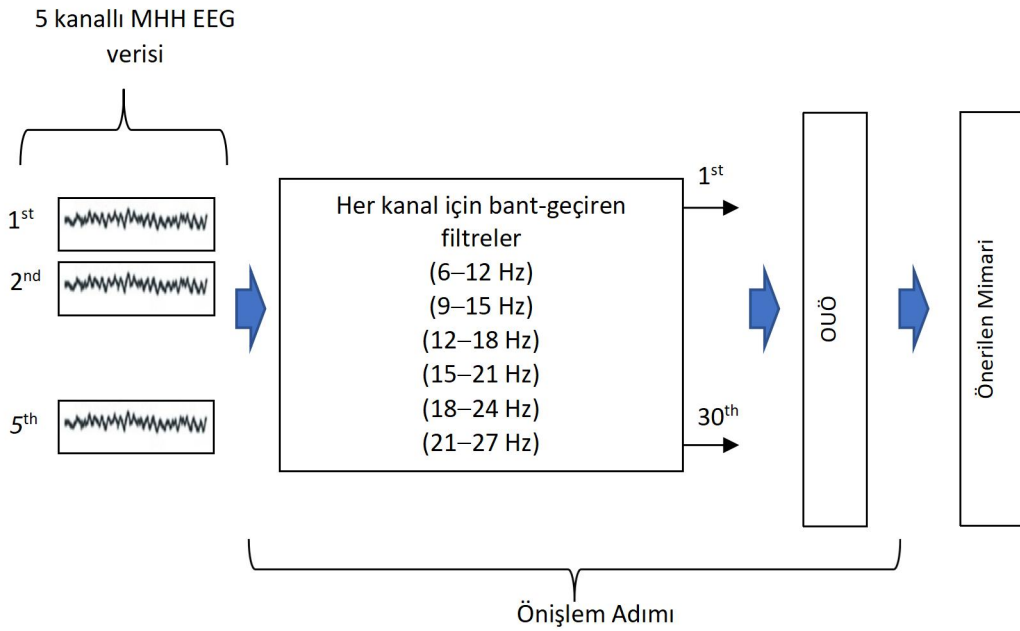
$$R W \Lambda = S W \quad (3.13)$$

elde edilir.

Burada, Denklem 3.13 [80], genelleştirilmiş özdeğer ayrıştırması metodu ile çözülür; yani, farklılığı belirginleştirecek ağırlık değerleri (uzamsal filtreler, W) özvektörler ve bunların ağırlıkları (Λ) ise özdeğerlerdir. Elde edilen bu özvektörler (W), özdeğer ağırlıklarının büyüklüğüne göre sıralanır ve orijinal verimizle çarpılarak uzamsal filtrelenmiş veri elde edilmiş olunur.

3.6.2 Filtreli Ortak Uzamsal Örüntü (fOUÖ)

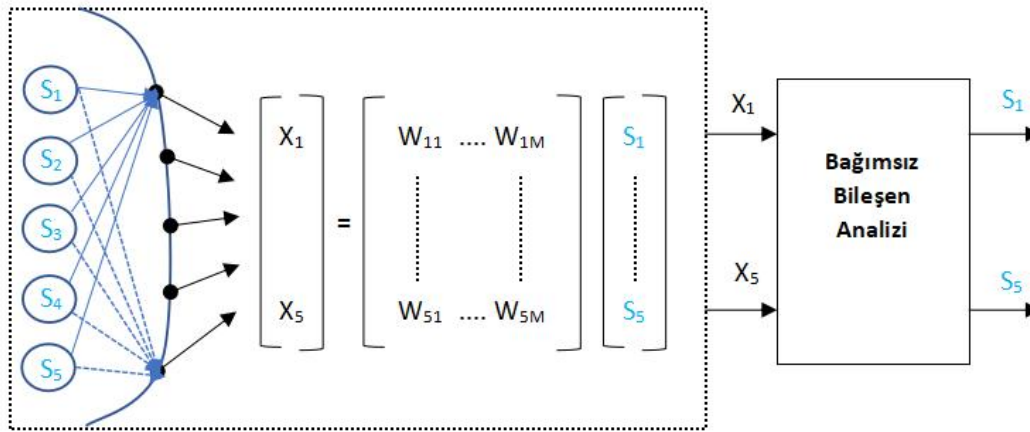
Motor Hareket Hayali (MHH) EEG'leri, farklı frekans aralıklarında önemli özellikler taşır. Filtrelenmiş Ortak Uzamsal Örüntü (fOUÖ) yönteminde, bu özellikleri çıkarmak için üst üste binen frekans aralıklarında bant geçiren filtreler uygulanır. Daha sonra, her bir bant geçiren filtrenin çıktısına OUÖ uygulanır; böylece her bir bireyin frekans özelliklerinin bireye özgü olarak çıkarılması hedeflenir. Şekil 3.4, beş kanallı MHH sinyalleri için fOUÖ yönteminin çalışma prensibini göstermektedir.



Şekil 3.4: fOUÖ'nün çalışma prensibi [78].

3.7 Bağımsız Bileşen Analizi

Bağımsız Bileşen Analizi, doğrusal bir uzamsal filtreleme yöntemidir. Sinyal işleme alanının birçok dalında, özellikle de gürültü giderme amacıyla yaygın olarak kullanılır [81]. Bağımsız Bileşen Analizi, sinyalin içsel yapısını analiz ederek, özellikle beynin elektriksel aktivitelerindeki özgün bileşenleri daha iyi ayırt etme imkanı sunar. Bu özellik, EEG sinyallerinin daha hassas bir şekilde işlenmesini sağlar, böylece daha güvenilir analizler elde edilir. Bağımsız Bileşen Analizi'nin amacı, birçok kaynaktan gelen sinyalleri istatistiksel olarak bağımsız sinyallere ayırmaktır. Bağımsız Bileşen Analizi, uzamsal filtreleme için bazı varsayımlar uygular. Gaussian dağılımlarının tamamını gürültü, Gaussian olmayan dağılımları ise anlamlı sinyaller olarak değerlendirir. Ayrıca, iç içe geçmiş sinyallerin Gaussian bir dağılıma sahip olduğunu varsayar. Bu varsayımlara dayanarak, Bağımsız Bileşen Analizi, kanalların ağırlıklı kombinasyonlarını kullanarak yeni bileşenlerin bağımsız ve Gaussian olmayan zaman serisi sinyalleri oluşturmasını sağlar. Bağımsız Bileşen Analizi, bağımsız kaynakları bulmak için yüksek dereceli istatistiklerden faydalanır ve verilerden yararlı bilgileri çıkarır. Şekil 3.5, Bağımsız Bileşen Analizi'nin blok diyagramını göstermektedir.



Şekil 3.5: Bağımsız Bileşen Analizi'nin blok diyagramı [78].

4. ELEKTROT SEÇİM METOTLARI

Kanal (elektrot) sayısının azaltılmasında filtreleme ve sarmalama tabanlı teknikler kullanılmaktadır. Filtreleme teknikleri, bir algoritma tarafından sağlanan bir alt kümenin belirlenmesi için bağımlılık, uzaklık veya bilgi ölçümleri gibi bir kriter uygular. Filtreleme, sınıflandırıcı bağımsızlığı sağlayan hızlı bir yöntemdir, ancak genellikle düşük doğruluk eğilimi gösterir [82]. Buna karşılık, sarmalama (wrapping) tekniği, alt kümeyi belirlemek için bir tahminleyicinin (makine öğrenme modeli) çıktısını bir hedef fonksiyon olarak kullanır. Sarmalama yöntemleri, veri kümesi ile sınıflandırıcı arasındaki özel etkileşimlere bağlı olduğundan, genellikle filtreleme yöntemlerinden daha iyi sınıflandırma oranlarına ulaşır. Bu nedenle, sarmalama yöntemlerinin en büyük avantajı, yüksek sınıflandırma performansı sağlamasıdır. Sarmalama teknikleri, çapraz doğrulama doğruluk ölçümlerini kullanarak aşırı öğrenmeyi (overfitting) önlemek için bir mekanizma içerir. Ancak, bu tekniğin dezavantajları, genellikle yoksun olması ve yavaş çalışmasıdır. Sarmalama tekniği, çalışmada seçilen sınıflandırıcıya bağlı olduğu için genellikle yoksundur [82]. Bu çalışmada kanal seçimi için, filtreleme yöntemlerinden olan Rayleigh Katsayı Haritası, Diverjans Tabanlı Kanal Seçim Algoritması, Karşılıklı Bilgi (Mutual Information), Ortak Uzamsal Örüntüleri ve sarmalama tabanlı yöntemlerden olan Kanal Dikkat Mekanizması, Permütasyon Önem Skoru ve Rastgele Arama algoritmaları kullanılmıştır.

4.1 Rayleigh Katsayı Haritası

Rayleigh katsayıları, OUÖ (Ortak Uzamsal Örüntü) algoritmasının matematiksel temelini oluşturan bir ölçüm yöntemidir. Bu katsayılar, iki sınıfın varyans oranını karşılaştırarak, hangi uzamsal filtrelerin en fazla ayırım gücüne sahip olduğunu belirler. OUÖ algoritmasında, uzamsal filtreler her iki sınıfın varyanslarını ayırtmak için optimize edilir ve bu süreç Rayleigh katsayısını maksimize etmeyi

hedefler (denklem 3.9). Rayleigh katsayısı, sınıflar arasındaki varyans farkını en iyi yansıtan filtreleri seçmek için bir kriter görevi görür.

OUÖ algoritmasının sonucunda elde edilen Rayleigh katsayıları, uzamsal filtrelerin sınıflar arasındaki ayırım gücünü sayısal olarak ifade eder. Bu katsayılar, sınıflar arasındaki varyansın ne kadar başarılı bir şekilde ayrıştırıldığını anlamak için kullanılabilir. Örneğin, yüksek Rayleigh katsayıları, belirli bir uzamsal filtrenin iki sınıf arasındaki sinyalleri ayırt etmede etkili olduğunu gösterir. Böylece, OUÖ algoritmasının matematiksel mekanizması ile Rayleigh katsayıları, ayırık sınıf özelliklerini temsil eden filtrelerin seçilmesinde doğrudan ilişkilidir.

4.2 Diverjans Tabanlı Elektrot Seçim Algoritması

Bu çalışmada, belirli bir zaman aralığında tüm elektrotlar arasından en iyi elektrot setini belirlemek için dinamik programlama yöntemi kullanılmıştır. Dinamik programlama sürecinde ilk olarak, en yüksek diverjans değerini üreten en iyi tek kanal belirlenir. Bu aşamada, 1D özellik vektörlerinin boyutu, tek kanal için 1×1 olarak ifade edilir, burada a , kullanılan zaman penceresindeki özellik sayısını temsil eder. Daha sonra, bir önceki aşamada bulunan tek kanal ile birlikte, en yüksek diverjans değerini sağlamak üzere en iyi çifti oluşturan ikinci kanal belirlenir. Bu aşamada, iki kanal için 1D özellik vektörlerinin boyutu $2a$ ($a \times 2$) olur. Bu şekilde, her aşamada daha önce belirlenen en iyi kanal kombinasyonuna yeni kanallar eklenerek set genişletilir. Bu iterasyon, en yüksek diverjans değerine sahip, önceden belirlenmiş sayıda kanalı bulmaya yönelik adım adım ilerletilir.

Diverjans, özellikle sinyal işleme ve istatistiksel analizde, bir veri kümesindeki dağılımın ne kadar farklı olduğunu veya ne kadar değişkenlik gösterdiğini ölçen bir kavramdır. EEG verilerinde diverjans, farklı elektrotlardan elde edilen sinyallerin içerdiği bilgi çeşitliliğini belirler. Yüksek bir diverjans değeri, elektrotlar arasındaki sinyallerin daha farklı özellikler taşıdığı ve daha fazla bilgi içerdiği anlamına gelir. Bu da, beyin aktivitelerinin daha ayrıntılı bir şekilde analiz edilebilmesine olanak tanır. Diverjansın maksimize edilmesi, EEG sinyallerinin daha zengin ve anlamlı bir şekilde temsil edilmesine yardımcı olur, çünkü daha fazla çeşitlilik ve farklılık taşıyan sinyaller seçilmiş olur. Diverjans analiziyle ilgili daha fazla bilgi, derin öğrenme modelimiz olan DivFE'nin tanıtıldığı 5.3. Bölümde sunulmuştur.

4.3 Ortak Uzamsal Örüntüler Kullanarak Kanal Seçimi

OUÖ filtreleri, Bölüm 3.6.1'de tanımlanan OUÖ sürecinin sonunda elde edilir. Bu filtrelerin, Rayleigh Katsayı Haritası kullanılarak kanal seçimi için nasıl kullanıldığı ise Bölüm 4.1'de açıklanmıştır. Bu filtreler, orijinal EEG sinyallerini değiştirerek, sınıf ayrımlarıyla bağlantılı bilgilerin güçlendirildiği ve daha kolay sınıflandırma yapılabilen bir dönüştürülmüş alan oluşturmada önemli bir rol oynar. Diğer yandan, OUÖ örüntüleri, OUÖ filtreleriyle uyumlu olan uzamsal düzenlemeleri ifade eder. Bu örüntüler, farklı EEG kanalları boyunca sinirsel aktivitenin nasıl dağıldığını gösterir ve MHH görevleriyle en alakalı olan beyin bölgeleri hakkında fikir verirler. Bu nedenle örüntüler, uygun kanal seçimi prosedürü hakkında daha fazla bilgi sağlayabilirler. Örüntüler ayrıca EEG verilerinin, filtreler tarafından çıkarılan belirgin sinirsel kaynaklar aracılığıyla nasıl üretildiğine dair bir anlayış sunar. Bu durum, [83] numaralı çalışmada da vurgulanmıştır. OUÖ'nün genel tanımı Denklem 4.1'den [84] görülebilir.

$$OUÖ_DönüştürülmüşVeri = \mathbf{w}^T \times OrijinalVeri \quad (4.1)$$

Denklem 4.1'de w uzamsal filtrelerden oluşan ve boyutları $R^{C \times C}$ olan bir matrisdir; C kanal sayısını temsil eder. $OUÖ_DönüştürülmüşVeri$, OUÖ uygulanması sonucu oluşan yeni veriyi ve $OrijinalVeri$ ise ham EEG verilerini temsil eder ve boyutları kanal \times zaman şeklinde temsil edilir.

Denklem 4.1, Denklem 4.2'deki [84] gibi düzenlenebilir.

$$OrijinalVeri = (\mathbf{w}^{-1})^T \times OUÖ_DönüştürülmüşVeri \quad (4.2)$$

Burada $(\mathbf{w}^{-1})^T$, Denklem 4.2'deki uzamsal örüntülerin matrisidir. Bu örüntüler elde edilmeden önce, MHH aktivasyonunun genellikle bu frekans aralığında gerçekleşmesi nedeniyle veri kümesine 7 ile 35 Hz arasında bir band geçiren filtre uygulanmıştır [84].

4.4 Karşılıklı Bilgi

Karşılıklı Bilgi, iki değişken arasında paylaşılan bilgi miktarını ölçmek için kullanılan bir yöntemdir. EOG ve EEG elektrotlarının analiz edilmesi bağlamında, bir tür sinyal hakkında diğerinden ne kadar bilgi çıkarılabileceğini değerlendirmeye

yardımcı olur. EOG ve EEG elektrotları arasındaki ortak bilgiyi değerlendirerek, sağladıkları bilgilerde ne kadar örtüşme olduğunu belirlemek mümkündür. Bu, EOG elektrotlarının beyin aktivitesi hakkında ek değerli bilgi sağlayıp sağlamadığını veya sadece tekrarlayıcı bilgiye sahip olup olmadığını anlamak için özellikle faydalıdır. Bu elektrotlar arasındaki yüksek bilgi, EEG ve EOG elektrotlarının örtüşen bilgileri yakalayabileceğini ve bunun EEG tabanlı analizlerin genel etkinliğine katkıda bulunabileceğini gösterir. Tersine, düşük bilgi, EOG elektrotlarının EEG sinyalleri tarafından yakalananların ötesinde anlamlı bir örtüşen bilgi sağlamadığını veya EEG kanallarından elde edilen faydalı bilgilerin dışında farklı ve faydalı bilgiler içerebileceğini gösterebilir.

İki rastgele değişken X ve Y arasındaki Karşılıklı Bilgi $I(X;Y)$ şu şekilde tanımlanır:

$$I(X;Y) = H(X) + H(Y) - H(X,Y) \quad (4.3)$$

Denklem 4.3'de [84], $H(X)$ X'in entropisi, $H(Y)$ Y'nin entropisi ve $H(X,Y)$ ise X ve Y'nin ortak entropisidir. Entropi, sinyaldaki belirsizliği temsil eder ve Denklem 4.4'deki [84] gibi hesaplanabilir;

$$H(X) = - \sum_{x \in X} P(x) \log P(x) \quad (4.4)$$

Denklem 4.4'de [84], $P(x)$ değişkeni X'in olasılık dağılımını ve x, X'in alabileceği tüm olası değerleri temsil eder. Diğer taraftan, ortak entropi, iki rastgele değişkenin birleşik belirsizliğini ölçer. X ve Y arasındaki ortak entropi şu şekilde hesaplanır:

$$H(X,Y) = - \sum_{x \in X, y \in Y} P(x,y) \log P(x,y) \quad (4.5)$$

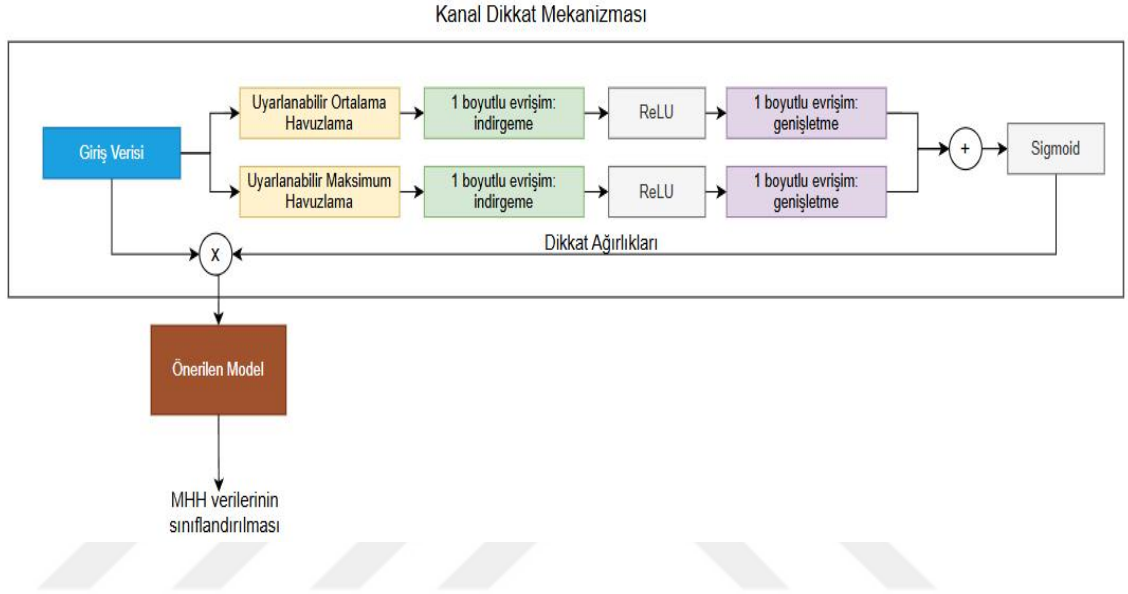
Denklem 4.5'de [84], $P(x,y)$ X ve Y'nin ortak olasılık dağılımıdır.

4.5 Kanal Dikkat Mekanizması (KDM)

Kanal Dikkat Mekanizması (KDM), MHH sinyallerinin sınıflandırılmasına en çok katkıda bulunan kanalları tespit etmek için kullanılır. Filtreleme yöntemleri olarak kabul edilen metotların aksine, KDM en etkili kanalları belirlemek için sınıflandırıcı performansını kullanan bir sarmalayıcı tabanlı yöntemdir. KDM, sınıflandırma katkısına bağlı olarak her kanala farklı ağırlıklar atayarak çalışır. Eğitim sırasında, model en önemli bilgileri taşıyan kanallara daha fazla odaklanmayı öğrenir ve bu da modelin farklı MHH görevleri arasında ayırım yapma yeteneğini etkili bir şekilde

iyileştirir. Bu dinamik ağırlıklandırma, KDM'nın en iyi kanalları uyarlanabilir bir şekilde seçmesini ve sınıflandırma sürecini optimize etmesini sağlar.

Önerilen KDM Şekil 4.1'de gösterilmiştir. Önerilen KDM'de, giriş verileri girdiğinde, önce iki tür havuzlama işlemine tabi tutulur: Uyarlanabilir Ortalama Havuzlama ve Uyarlanabilir Maksimum Havuzlama. Bu işlemler, her kanal için zaman boyutu boyunca bilgileri özetler ve hem ortalamayı hem de maksimum özellikleri yakalar.



Şekil 4.1: Önerilen Kanal Dikkat Mekanizması [84].

Birleştirilmiş çıktılar daha sonra iki 1D evrişimsel katmandan geçirilir, burada ilk katman kanal sayısını azaltır ve ikincisi bunları orijinal boyutlarına geri getirir. Bu yaklaşım, modelin kanal bilgilerini sıkıştırarak ve sonra geri yükleyerek en önemli özelliklere odaklanmasını sağlar ve dikkat mekanizmasının etkinliğini artırır. Doğrusal olmayanlığı tanıtmak için bu katmanlar arasına bir ReLU aktivasyon fonksiyonu uygulanır. Ortalama ve Maksimum Havuzlama yollarından gelen çıktılar birleştirilir ve çıktı değerlerini 0 ile 1 arasında bir aralığa ölçekleyen bir Sigmoid aktivasyon fonksiyonundan geçirilir. Bu ölçekleme, her bir kanalın önemini belirleyen bir geçit mekanizması görevi görür. Ölçeklenen değerler (dikkat ağırlıkları) daha sonra orijinal giriş verileriyle çarpılır, en bilgilendirici kanalları etkili bir şekilde yükseltir ve daha az alakalı olanları zayıflatır. Bu işlenmiş veriler daha sonra önerilen derin öğrenme modeline beslenir, bu da modelimizin en önemli kanallara odaklanmasını ve gürültüyü ve alakasız bilgileri filtreleyerek MHH görevlerini sınıflandırma yeteneğini geliştirmesini sağlar. Bu yapı, model mimarisine dahil

edilmiş ve Şekil 4.1'de gösterildiği gibi, giriş ile önerilen derin öğrenme modeli arasına yerleştirilmiştir [84].

4.6 Permütasyon Önem Skoru

Permütasyon Önem Skoru (PÖS), bir makine öğrenimi modelinde elektrotların (veya özneliliklerin) önemini değerlendirmek için kullanılan başka bir sarmalayıcı tabanlı yöntemdir. Bir elektrodun değerleri rastgele karıştırıldığında, model performansındaki değişikliği ölçerek her bir kanalın modelin tahminlerine ne kadar katkıda bulunduğunu belirler. Bu yöntem, kanal ile hedef değişken arasındaki ilişkiyi parçalara ayırarak modelin tahminlerinin o belirli kanala ne kadar bağımlı olduğunu ortaya çıkarır. Performansta önemli bir düşüş, kanalın çok önemli bir rol oynadığını gösterirken, daha küçük bir etki, kanalın daha az önemli olduğunu gösterir. Bu yaklaşım, hangi kanalların en etkili olduğu hakkında değerli bilgiler sağlar, kanal seçimine yardımcı olur ve model yorumlanabilirliğini artırır.

4.7 Rastgele Arama Algoritması

Kanal seçimi sürecine rastgelelik dahil edilmesi, önceden tanımlanmış hiyerarşilerin ötesinde daha geniş bir keşfe olanak tanıyarak performansı iyileştirebilir ve potansiyel olarak daha iyi sonuçlar elde edilmesini sağlayabilir [85]. Bu yöntemde, k kanal eşit olasılıkla rastgele seçilir ve model, yalnızca bu rastgele seçilen kanallar kullanılarak eğitilir ve elde edilen performans, bu belirli alt kümedeki kanalların sahip olduğu performans olarak atanır. Bu işlem birçok kez tekrarlanır ve ardından her kanalın ortalama performans değeri hesaplanır. Sonuç olarak, daha yüksek puanlara sahip kanallar daha bilgilendirici olarak kabul edilir ve bu puanlara göre kanal seçimi yapılır. Her kanal için performans puanlarının hesaplanması Denklem 4.6'da [84] gösterilmiştir;

$$c_i = \frac{\sum_{j=1}^k w_{accj}}{k} \quad (4.6)$$


Burada, C her bir kanalın puanlarını, w_acc her bir alt kümenin (ya da ait olduğu kanalın) doğruluğunu ve k o belirli kanalın oluşum sayısını temsil eder. Denklem 4.6'dan da görüleceği üzere, her bir kanalın sahip olduğu performansların toplamı, o kanalın seçilme sayısına (k) bölünerek, bu C kanal puanları elde edilir.

5. DERİN ÖĞRENME METOTLARI

Literatürde, özellikle son on yıla kadar öznelik çıkarımı yapılarak bir sınıflandırıcı ile sonuçlar elde edilmiştir. Ancak, son yıllarda derin öğrenme yöntemlerindeki gelişmeler sayesinde hem daha iyi performanslar elde edilmiş hem de manuel öznelik çıkarımına olan ihtiyaç (bazı durumlar haricinde) ortadan kalkmıştır.

5.1 Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları (YSA), insan beyninin bilgi işleme mekanizmalarını taklit ederek geliştirilmiş bir hesaplama yöntemidir. İnsan beynindeki nöronlar, sinapslar aracılığıyla sürekli etkileşim halindedir ve öğrenme süreçleri, bu bağlantıların kimyasal ve elektriksel değişimleriyle gerçekleştirilir. YSA'lar, benzer bir şekilde çok sayıda işlem biriminin (yapay nöron) birbirine, her biri kendine özgü bir ağırlık katsayısına sahip bağlantılarla bağlanmasıyla oluşturulan matematiksel sistemlerdir. Sinir ağları, giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç temel katmandan oluşur. Gizli katmanların sayısı birden fazla ise, bu ağ derin öğrenme mimarisi olarak adlandırılır. Şekil 5.1'de giriş katmanında üç nöron, iki gizli katman (her birinde dört nöron) ve çıkış katmanında bir nöron bulunan bir derin öğrenme mimarisi görülmektedir.




Şekil 5.1: Örnek bir derin öğrenme mimarisi.

YSA'da her bir nöron belirli matematiksel hesaplardan sorumludur. Bu durum Denklem 5.1'de görülmektedir.

$$y = \sigma(\text{sapma_degeri} + \sum_{i=1}^n (w_giris_i * x_i)) \quad (5.1)$$

Burada, σ aktivasyon fonksiyonunu, *sapma_degeri* nörona ait sapmayı, *w_giris* ise nöron girişlerine ait ağırlıkları ve *n* ise o nörona olan giriş sayısını belirtmektedir. YSA'larda aktivasyon fonksiyonu, modelin giriş verileriyle çıktı arasındaki doğrusal olmayan ilişkileri öğrenmesini sağlayan bir matematiksel dönüşümdür. Aktivasyon fonksiyonu, modelin doğrusal olmayan karmaşık ilişkileri öğrenebilmesi için önemlidir. Bunun yanı sıra, her nöronda bir sapma (bias) değeri bulunur ve girdinin ağırlıklı toplamına eklenerek modelin öğrenme yeteneğini artırır.

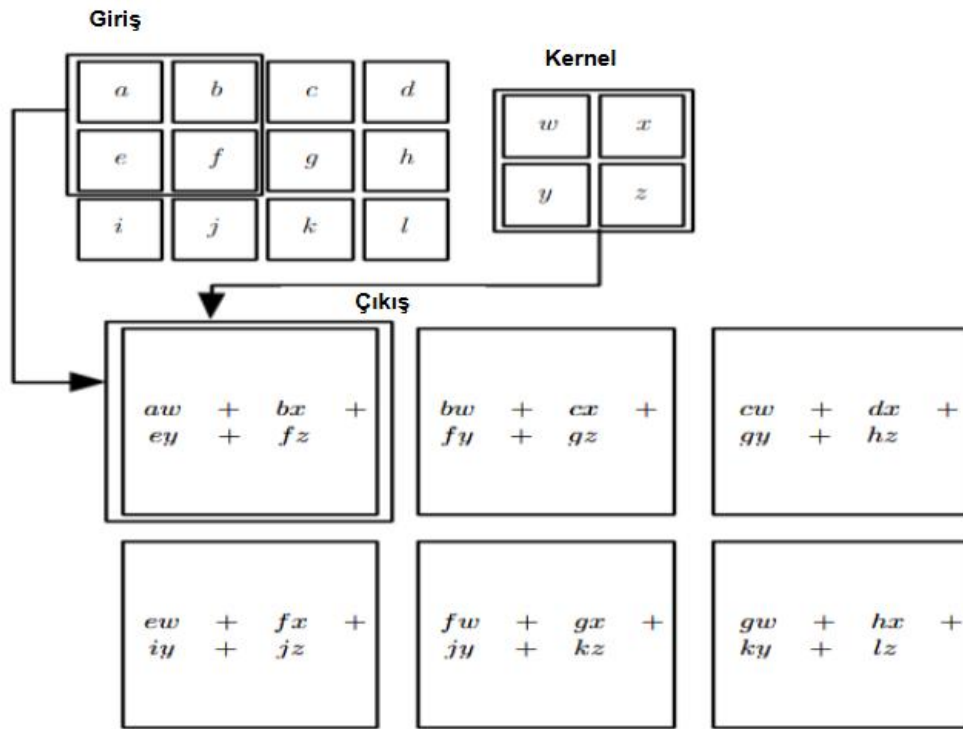
Eğitim (öğrenme) sürecinde sinir ağırları Geri Yayılım (Backpropagation) yöntemiyle, elde edilmiş çıkış ile esas çıkışı kıyaslayarak ağırlıklarını günceller ve hatayı (hata fonksiyonunu) minimize edene kadar bu yöntem uygulanmaya devam eder. Bu yöntemde, çıkıştan başlanarak her bir katmanda türev alınarak hesaplamalar yapılır. Bu işlem zincir kuralı ile giriş katmanına kadar tekrarlanır ve her katmandaki ağırlıklar güncellenir. Yeni sinir ağı modelleri tasarlanırken çok derin sinir ağı oluşturulması gerekebilir. Ancak bilindiği gibi, çok derin sinir ağı eğitmek gradyan kaybolması (vanishing gradient) veya aşırı öğrenme (overfitting) gibi çeşitli sorunlar yaratmasından dolayı zordur ve bu sorunlar, performansı kötü etkileyebilmektedir. Şekil 5.2'de bir sinir ağı'nın 20 ve 56 katmanlı durumları için eğitim ve test hataları görülmektedir. Buradan görüleceği gibi, sinir ağı derinleştikçe eğitim ve test hataları artmaktadır.



Şekil 5.2: İki farklı katmanlı YSA için eğitim ve test hatalarının değişimi [86]

5.2 Evrişimsel Sinir Ağı (ESA)

Evrişimsel Sinir Ağı (ESA), YSA'ların özelleşmiş bir biçimidir. Sinir ağlarına kıyasla genellikle görüntü sınıflandırmada daha çok tercih edilmektedir ve bunun başlıca nedenlerinden biri, ESA ile iki ve daha yüksek boyutlu bilgiyi koruyabilirken, YSA'lar ile bunun mümkün olmamasıdır. Ayrıca, ESA, sinir ağlarına kıyasla çok daha az parametreye sahip olduğundan, yüksek hesaplama gerektiren işlemleri daha kısa sürede gerçekleştirebilmektedir. ESA'yı oluşturan katmanlar konvolüsyon (evrişim), ortaklama (pooling) ve tam bağlantılı (fully connected) sinir ağıdır. Konvolüsyon, veriye bir filtre (kernel) uygulanmasıdır, yani elimizdeki veri ile filtrenin konvolüsyon işleminin gerçekleştirilmesi sonucunda konvolüsyon katmanı elde edilir. Konvolüsyona bir örnek, Şekil 5.3'te gösterilmiştir.




Şekil 5.3: 2D konvolüsyon işlemi için örnek [87].

Konvolüsyon işlemi, EEG tabanlı Beyin-Bilgisayar Arayüzü (BBA) sinyalleri için kritik bir öneme sahiptir. Bunun nedeni, bir epok içindeki öteleme değişmezliği, MHH tabanlı BBA uygulamalarının temel varsayımdır. Yani, bir birey bir motor hareketini belirli bir süre boyunca hayal ettiğinde, ayırt edici desenlerin zaman eksenindeki konumu herhangi bir önem taşımaz.

Ortaklama (pooling) katmanı, konvolüsyon sonucu elde edilen yüksek miktardaki parametrelerin boyutunu azaltarak modelin hesaplama yükünü düşürür ve aşırı öğrenmeyi engellemeye yardımcı olur. Bu katman, giriş verisinin önceden belirlenmiş yerel bölgelerine belirli bir işlev uygulanarak çalışır. Genellikle bu işlev, o bölgedeki maksimum değerin alınması ya da ortalama değerin hesaplanmasıdır. Son olarak, elde edilen değerler, sınıflandırma işlemi için sinir ağının son katmanına aktarılır ve bu katman üzerinden sınıflandırma gerçekleştirilir.

5.3 Diverjans Temelli Öznitelik Çıkarımı (Divergence-based Feature Extractor - DivFE)

Derin öğrenme sistemleri, tüm avantajlarının yanında bazı dezavantajları da beraberinde getirmektedir. Bu dezavantajlardan bazıları, yüksek hafıza gerekliliği, yüksek hesaplama gücü gereksinimi ve çok sayıda parametrenin ortaya çıkmasıdır. ESA mimarilerinde, son katmanda kullanılan tam bağlantılı sinir ağları çok sayıda ek parametreyi de beraberinde getirdiği için bahsedilen bu sorunlara sebep olmakta ve ağı eğitmek zorlaşmaktadır. Çünkü parametre sayısı arttıkça yerel minimum sayısı da artmakta ve bu yüzden algoritmanın bir yerel minimumda sıkışıp kalma olasılığı artmaktadır. DivFE [88, 89] (model 1) metodunda da öznitelikler başarılı bir şekilde elde edildikten sonra, tam bağlantılı sinir ağları yerine Minimum Mesafe Ağı (MMA) kullanılmıştır. MMA'da sınıf etiketleri, Walsh vektörlerine göre ayarlanarak ESA eğitim aşaması güçlendirilmiştir. Verinin hangi sınıfa ait olduğu özniteliklerin çıkışı ile önceden belirlenmiş Walsh vektörleri arasındaki mesafe ile belirlenir. Dolayısıyla, öznitelik çıkışına en yakın olan MMA düğümü sınıfı belirlemektedir. Her düğüm bir sınıf etiketine sahiptir. MMA, ağdaki her bir düğümün ağırlıkları belirli bir Walsh vektörünün elemanlarına eşit olarak ayarlandığından ve bu ağırlıklar değişmediğinden, eğitim sırasında kullanılmaz. Ancak, tam bağlantılı sinir ağının ağırlıkları eğitim süreci boyunca sürekli olarak değişir. DivFE ağının genel yapısı Şekil 5.4'te gösterilmiştir. DivFE'de amaç, öznitelikler için diverjansı maksimuma getirecek bir ağ inşa ederek eğitimi güçlendirmektir. Dolayısıyla, DivFE ismini buradan (Divergence-based Feature Extractor) almaktadır. Maksimum diverjans, sınıf içi ve sınıflar arası ayrımı yapacak özniteliklerin elde edilmesini sağlar.



Şekil 5.4: DivFE Mimarisi (Model 1) [88].

Herhangi iki sınıf arasındaki mesafe aynıyken, sınıf merkezlerinin birbirinden olabildiğince uzak tutulması her sınıf merkezini bir Walsh vektörüyle temsil ederek yapılır. Öznelikler, bu Walsh vektörünün satırlarına göre çıkış verecek şekilde eğitilir. Bu şekilde özneliklerin çıkışını Walsh vektörlerinin satırları olarak ayarlamak sınıf merkezleri arasındaki mesafeyi ve dolayısıyla da diverjans değerini artırır. Diverjans değeri, Denklem 5.2'deki [88] formül ile hesaplanmaktadır.

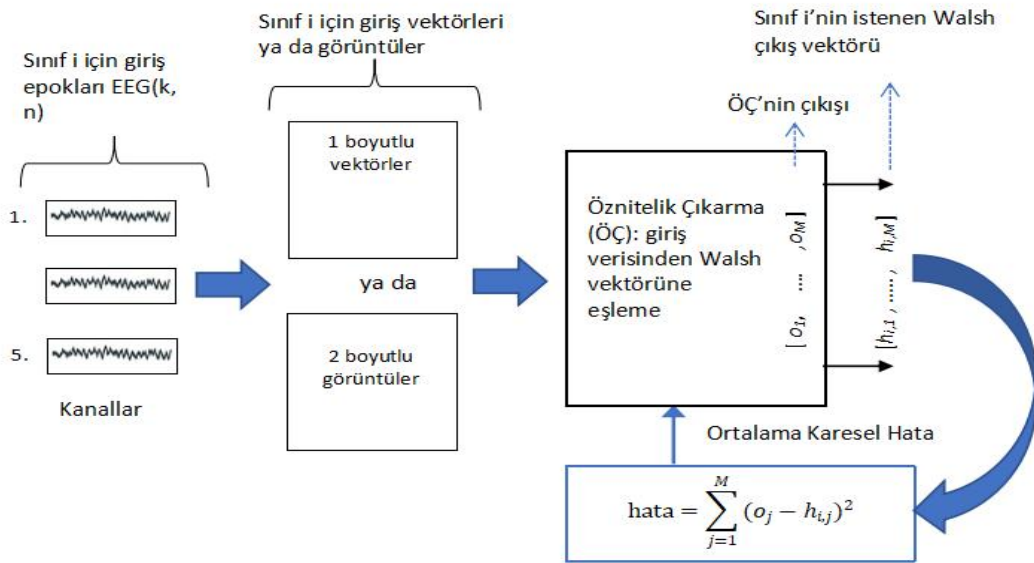
$$\text{diverjans değeri} = \text{tr}(S_{\text{kov}}^{-1}.B)$$

$$S_{\text{kov}} = S_{\text{kov}_1} + S_{\text{kov}_2} + \dots + S_{\text{kov}_k} + \dots + S_{\text{kov}_C} \quad (5.2)$$

Burada S_{kov_k} , k sınıfına ait kovaryans matrisi, S_{kov} ise bütün sınıflara ait kovaryans matrislerinin toplamını göstermektedir. S_{kov} burada aynı zamanda sınıf içi dağılım matrisi olarak da bilinir. S_{kov} matrisi, özneliklerin çıkışı kullanılarak elde edilir. B ise sınıflar arası dağılım matrisidir ve sınıflara ait ortalama (mean) vektörlerin kovaryansı ile elde edilir. Denklemden görüleceği üzere, sınıflar arası dağılımı arttırarak ve sınıf içi dağılımı azaltarak daha yüksek diverjans değeri elde edilir. Yüksek diverjans değeri de bize özneliklerin uygun dağılımının elde edildiğini gösterir. B matrisi Walsh vektörleri kullanılarak oluşturulmuştur. Denklem 5.3'te [88] iki, dört ve sekiz boyutlu Walsh matrisleri görülmektedir.

$$WV = \begin{bmatrix} +V & +V \\ +V & -V \end{bmatrix} WV = \begin{bmatrix} +V & +V & +V & +V \\ +V & -V & +V & -V \\ +V & +V & -V & -V \\ +V & -V & -V & +V \end{bmatrix} WV = \begin{bmatrix} 11111111 \\ 10101010 \\ 11001100 \\ 10011001 \\ 11110000 \\ 10100101 \\ 11000011 \\ 10010110 \end{bmatrix} \quad (5.3)$$

Walsh vektörleri, yukarıdaki matrislerin (Denklem 5.3) sütunları veya satırlarıdır. Herhangi iki Walsh vektörü arasındaki mesafe aynıdır ve bu mesafe, Walsh matrisinin derecesinin yarısına eşittir. Klasik yöntemlerde, hedef (istenen) çıktı vektörü yalnızca bir '1' değeri içerir ve kalan vektör elemanları '0' olarak ayarlanır. Bu durumda, ağız çıkış düğümü, giriş vektörü için sınıf etiketini temsil eder. Bu yöntemde, iki farklı sınıfı temsil eden herhangi iki vektör arasındaki mesafe (çekiç mesafesi) sabittir ve her zaman 2'ye eşittir. Ancak, sınıflar Walsh vektörleriyle temsil edildiğinde, herhangi iki Walsh vektörü arasındaki mesafe her zaman Walsh matrisinin derecesinin yarısına eşit olur. Örneğin, 16 boyutlu bir Walsh matrisi için mesafe 8 olacaktır. Bu nedenle, Walsh vektörü tabanlı düğüm etiketleme yönteminde, iki sınıf vektörü klasik yöntemle kıyasla birbirinden dört kat daha uzakta yer alır. Bu şekilde eğitim stratejisi, sınıflar arasındaki mesafeyi dört kat artırmayı sağlar. Daha yüksek boyutlu Walsh matrisleri için bu faktörün büyüdüğü ve sınıflandırma doğruluğuna katkı sağladığı açıktır. DivFE eğitim aşaması Şekil 5.5'te görülmektedir. Bu derin öğrenme mimarisi tezde model 1 olarak ifade edilmiştir.



Şekil 5.5: DiVFE eğitim aşaması [88].

5.4 EEGNET Mimarisine Dayalı Derin Öğrenme Sistemi

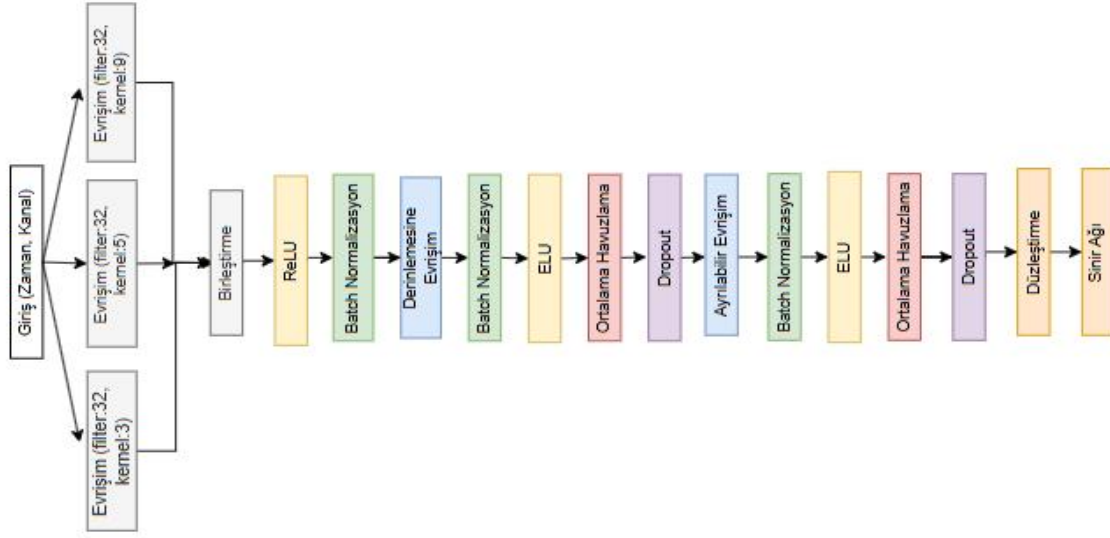
Literatürde EEG sinyallerinin sınıflandırmasında kullanılan etkili derin öğrenme metotlarından biri EEGNet'tir [51]. Bu çalışmada önerdiğimiz bir diğer model (model 2), Şekil 5.6'da gösterilen zamansal evrişim bloğunu takiben, EEGNet'ten [51] esinlenen bir yaklaşımla derinlemesine ve ayrılabilir evrişimler kullanır. Ancak, 2D evrişimler yerine, daha az sayıda kanalın bulunduğu durumlara uyum sağlamak ve sınırlı uzamsal bilgiyle bile etkinliği garanti etmek için 1D evrişimler tercih edilmiştir.

EEGNet'ten farklı olarak, zamansal evrişim bloğunda birden fazla kernel boyutu kullanılmıştır. Kernel boyutu, öznitelik çıkarımı için giriş dizisi üzerinde hareket eden evrişim filtresinin veya penceresinin boyutlarını temsil eder. Daha küçük bir kernel boyutu, ağın yerel özellikleri algılamasına olanak tanırken, daha büyük bir kernel boyutu daha geniş ve genel özellikleri yakalar. Bu sayede, giriş verilerinin daha iyi zamansal özellikleri elde edilir.

Zamansal evrişimlerin birleştirilmesinin ardından, sırasıyla ReLU ve batch normalizasyon kullanılmıştır. Derinlemesine ve ayrılabilir evrişimden sonra ise, sırasıyla batch normalizasyon, ELU, ortalama havuzlama ve dropout katmanları kullanılmıştır, bu Şekil 5.6'da gösterilmiştir.

Batch normalizasyon, bir katmanın çıktısını normalize etmek için kullanılır. Bu teknik, eğitim sürecini hızlandırır ve modelin genelleme yeteneğini artırır. ReLU ve ELU, aktivasyon fonksiyonları olarak kullanılır; bu da önerilen modelin doğrusal olmayan öznitelikleri yakalamasına ve daha karmaşık özelliklerin sınıflandırılmasına yardımcı olur.

Ortalama havuzlama, giriş verilerinin uzamsal boyutlarını, belirli bir pencere içinde ortalama değerini alarak azaltmak için kullanılır. Bu, ağıdaki parametre sayısını azaltırken, en önemli özniteliklerin elde edilmesine yardımcı olur. Dropout katmanı ise aşırı uyum (overfitting) sorunlarını engellemek için tercih edilmiştir. Eğitim süreci sırasında, dropout her güncellemede rastgele bazı giriş birimlerini devre dışı bırakır ve bu birimler ile tüm bağlantıları dışlar. Son olarak, düzleştirme (flatten) katmanı, çok boyutlu veriyi bir boyutlu diziye dönüştürmek için kullanılır ve düzleştirme katmanını takiben sınıflandırma işlemi için tam bağlantılı sinir ağı (dense) katmanı kullanılır.




Şekil 5.6: EEGNet'den esinlenilerek geliştirilen derin öğrenme mimarisi (Model 2) [84].

Tüm bu etkili tekniklerin birleştirilmesi, modelin giriş verisinin hem uzamsal hem de zamansal özelliklerini anlamasını sağlar ve bu sayede verimizdeki karmaşık desenlerin tanınmasına olanak tanır. Bu derin öğrenme mimarisi, tezde Model 2 olarak ifade edilmiştir.

5.4.1 Derinlemesine evrişim

Derinlemesine evrişimler, derin öğrenme modellerinde kullanılan parametre sayısını azaltır. Geleneksel 1D evrişimlerde, tüm girdi üzerinde tek bir filtre uygulanarak tek bir öznitelik haritası oluşturulur. Derinlemesine 1D evrişimlerde, giriş kanalları kadar (veya giriş kanallarının katları kadar) filtre bulunur. Bu filtrelerin her biri, karşılık gelen giriş kanalıyla bağımsız olarak evrişim işlemi yapar ve birden fazla öznitelik haritası oluşturur. Bu durum Şekil 5.7'de gösterilmektedir. Veri kümesi birden fazla kanaldan oluştuğundan, her kanalın kendi filtre setine sahip olması faydalıdır. Bu sayede, filtre ağırlıkları diğer kanallarla paylaşılması yerine, derinlemesine evrişimle her kanal üzerinde ayrı ayrı filtreler uygulanır. Bu yöntem, giriş verisinin kanal bazında uzamsal filtrelemesini gerçekleştirmeyi mümkün kılar. Bu işlem sonrasında, her bir kanaldan elde edilen öznitelik haritaları birleştirilerek derinlemesine evrişim katmanının çıktısı oluşturulur.




Şekil 5.7: Derinlemesine evrişim (konvolüsyon).

Derinlemesine evrişimler, geleneksel evrişimlere kıyasla önemli bir hesaplama verimliliği sağlar. Her bir giriş kanalı için yalnızca bir filtre kullanıldığı için parametre sayısı ve hesaplama maliyeti belirgin şekilde azalır. Bu özellik, büyük veri kümelerinde ve sınırlı kaynaklarla çalışan modellerde büyük bir avantaj sunar. Ayrıca, parametre sayısının azalması, modelin daha az parametreye sahip olmasına ve daha hızlı çalışmasına imkan sağlar. Derinlemesine evrişimler, her kanalın özgün özelliklerini yakalamak için özel filtreler kullandığından, modelin genel performansını artırabilir. Bu, özellikle çok kanallı verilerde (örneğin, EEG, video veya çok kanallı ses) önemli bir avantaj oluşturur çünkü her kanalın kendine has bilgilerini en iyi şekilde öğrenmek mümkündür.

5.4.2 Ayrılabilir evrişim

Ayrılabilir evrişim, Şekil 5.8’de gösterildiği gibi derinlemesine evrişim katmanının sonuna 1x1 evrişim eklenmesiyle elde edilir. Ayrılabilir evrişim, derinlemesine evrişimin daha fazla optimize edilmesiyle ortaya çıkar.



Şekil 5.8: Ayrılabilir evrişim.

1x1 evrişim, evrişimli sinir ağlarında kullanılan bir filtreleme işlemidir ve genellikle "nokta bazlı evrişim" olarak adlandırılır. Bu evrişim türü, 1x1 filtresi kullanılarak her

çıktı pikseli için yalnızca tek bir pikselin (veya veri noktasının) evrişimini ifade eder. Ancak bu işlem tüm kanallarda gerçekleştirilir. Başka bir deyişle, her pikselin çıktısı için tüm kanalların ağırlıklı bir kombinasyonu hesaplanır. 1x1 evrişim, özellikle çok kanallı verilerde kanallar arasındaki ilişkileri öğrenmek için kullanılır. Bu evrişim türü, çıkış kanallarının sayısını değiştirmek için oldukça etkilidir. Ayrıca, büyük filtreler yerine yalnızca bir piksel işlendiği için hesaplama verimliliği sağlar, böylece işlem süresi azaltılır ve parametre sayısı kontrol altında tutulur. Ayrıca, 1x1 evrişimler boyut azaltma için de yararlıdır; çok sayıda kanalın birleştirilmesi veya çıktı kanalı sayısının değiştirilmesi gerektiğinde kullanılırlar. Bu özellikler sayesinde, modelin daha karmaşık ve doğrusal olmayan ilişkileri öğrenmesine olanak tanır. 1x1 evrişimler, derin evrişimlerden sonra kanallar arasındaki korelasyonları öğrenmek için de kullanılabilir, böylece parametre sayısını azaltırken önemli özellikler öğrenilebilir. Özetle, 1x1 evrişim, çok kanallı verilerde kanallara özgü özelliklerin öğrenilmesini sağlayarak ağırlık verimliliğini artıran önemli bir araçtır.

6. BİLGİSAYAR BENZETİMİ

Bu tez çalışmasında üç farklı deneyin sonuçları sunulmuştur. İlk deneyde tüm algoritmalar, NVIDIA GeForce RTX 3050 dizüstü grafik kartıyla donatılmış bir bilgisayarda Python kullanılarak gerçekleştirilmiştir. Bu ilk deneyde, MHH sinyalleri için ön işlem (gürültü temizleme) ya da dönüşüm metotları test edilmiştir. Ön işlem ve dönüşüm metotları olarak Ortak Ortalama Referanslama (OOR), EOG Regresyonu, Dalgacık Temelli Gürültü Temizleme (DTGT) ve Ortak Uzamsal Örüntü (OUÖ) kullanılmıştır. Ayrıca, EEG kanallarıyla beraber EOG kanalları da derin öğrenme sistemine verilmiş ve elde edilen performans ön işlem adımında uygulanan metotlarla kıyaslanmıştır. Bu ilk deney aşamasında, önerdiğimiz mimari olarak Model 2 kullanılmıştır.

İkinci deneyde, tüm algoritmalar 32 çekirdekli ve GTX 2080 Ti grafik kartıyla donatılmış bir bilgisayarda Python kullanılarak kodlanmıştır. Bu ikinci deney aşamasında, tüm deneklerde ortak olan en başarılı EEG elektrotları, Rayleigh Katsayı Haritası ve Diverjans Tabanlı Elektrot Seçimi kullanılarak araştırılmıştır. Ortak elektrotlar belirlendikten sonra, ön işlem adımları olarak filtreleme, Bağımsız Bileşen Analizi, Sürekli Dalgacık Dönüşümü (SDD), Kısa Süreli Fourier Dönüşümü (KSFD) ve Filtrelenmiş Ortak Uzamsal Örüntü (fOUÖ) uygulanmıştır. Derin öğrenme mimarisi olarak DivFE mimarisinden (Model 1) yararlanılmıştır.

Üçüncü deneyde, ilk deneyde olduğu gibi tüm algoritmalar NVIDIA GeForce RTX 3050 dizüstü grafik kartıyla donatılmış bir bilgisayarda Python kullanılarak gerçekleştirilmiştir. Bu aşamada, EOG elektrotlarının MHH sinyallerinin sınıflandırılmasındaki önemi, çeşitli kanal (öznitelik) seçim algoritmalarıyla araştırılmıştır. Kanal (elektrot) seçimi için, Karşılıklı Bilgi, Ortak Uzamsal Örüntü (OUÖ), Kanal Dikkat Mekanizması (KDM), Permütasyon Önem Skoru ve Rastgele Arama yöntemlerinden yararlanılmıştır. Derin öğrenme mimarisi olarak EEGNet benzeri mimariden (Model 2) yararlanılmıştır.

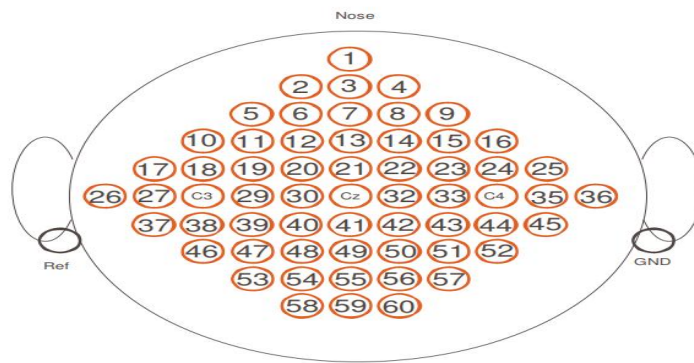
Bu çalışmada değerlendirme kısmı için doğruluk (accuracy) metriki kullanılmıştır. Doğruluk, toplam örnekler arasında doğru sınıflandırılanların oranını ifade eder ve sınıflandırıcının genel performansını ölçen temel bir ölçüttür. Doğruluk, doğru pozitif ve doğru negatif tahminlerin toplamının, yapılan toplam tahmin sayısına bölünmesiyle hesaplanır. Ayrıca, birinci ve üçüncü deneyde denek bazında performanslar elde edildikten sonra tüm deneklerin performanslarının ortalaması (mean), medyanı (median) ve standart sapması hesaplanmıştır. Bu hesaplamalar, genel performansın merkezi eğilim ve dağılım özelliklerini anlamak için yapılmıştır.

EEG sinyallerinin sınıflandırılması için eğitim ve test süreçlerinde 2005 BCI III-3a [91, 92], 2008 BCI IV-2a [93, 94], yapay oluşturulmuş bir EEG Veri Kümesi ve Weibo Veri Kümesi [95] kullanılmıştır. Ayrıca, birinci ve üçüncü deney aşamalarında MHH verilerinin yüklenmesi için MOABB kütüphanesi [96] kullanılmış, veri üzerinde çeşitli ön işlem teknikleri ise MNE-Python kütüphanesi [97,98] ile uygulanmıştır.

6.1 Veri Kümeleri


6.1.1 BCI III-3a Veri Kümesi

BCI III-3a Veri Kümesi (Veri Kümesi 1), üç farklı denekten elde edilen EEG verilerini içermektedir. Her bir denek, dört farklı MHH gerçekleştirmiştir: sol el, sağ el, dil ve her iki ayak. Her bir epok, 60 kanaldan kaydedilen MHH EEG sinyallerinden oluşmaktadır. Şekil 6.1, elektrotların kafa derisi üzerindeki yerleşimini göstermektedir. EEG sinyalleri, 250 Hz örnekleme hızıyla kaydedilmiştir.



Şekil 6.1: Veri Kümesi 1 için EEG elektrotlarının yerleşimi [92].


Şekil 6.2’de, bu veri kümesi için denekler tarafından gerçekleştirilen zaman diyagramı verilmiştir. Şekil 6.2’den görüleceği üzere, ilk iki saniye deneklere sessiz bir ortamda boş bir ekran gösterildikten sonra, ikinci saniyede bir uyarı sesi ile beraber ‘+’ işareti ekranda gösterilmiştir. Bir saniye sonra, üçüncü saniyede ise rastgele bir şekilde gerçekleştirilecek dört MHH’yi temsilen bir ok işareti (sola, sağa, yukarı ve aşağı doğru) 1 saniye boyunca deneklere gösterilmekte ve deneklerin üçüncü saniyeden yedinci saniyeye kadar toplamda dört saniye ilgili MHH’yi gerçekleştirmeleri beklenmektedir. Mevcut verilerin %80’i eğitim için kullanılmış, geri kalan veri ise test için ayrılmıştır.



Şekil 6.2: Denekler için zaman diyagramı (Veri Kümesi 1) [92].

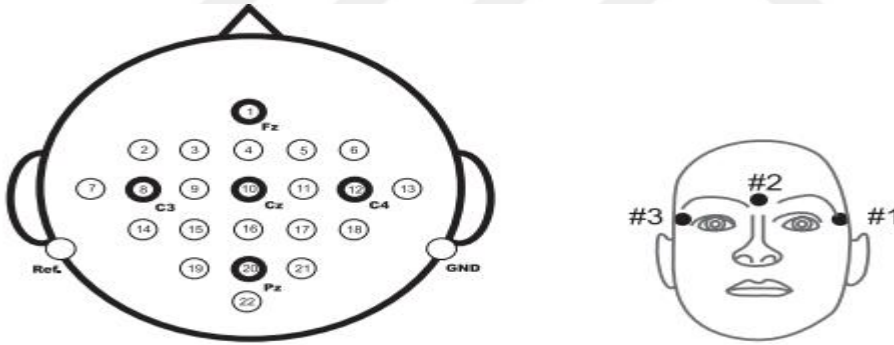
6.1.2 BCI IV-2a Veri Kümesi

BCI IV-2a Veri Kümesi’nde (Veri Kümesi 2) toplamda 9 denek, dört farklı (sol el, sağ el, her iki ayak ve dil MHH) MHH’yi gerçekleştirmiştir. Her bir denekten, farklı günlerde iki oturumda veri elde edilmiştir. Her bir oturum 6 kısımdan ve her bir kısımda 48 testten oluşmaktadır. İki oturum sonunda, her bir denek için toplamda $2 \times 6 \times 48 = 576$ test oluşmaktadır. Denekler için zaman akışı, Şekil 6.3’te gösterilmektedir. Denekler, deneye başlamadan önce bir bilgisayar ekranının karşısına oturtulmaktadır. Başlangıç anında ($t=0s$), uyarı sesi ile beraber sabit bir ‘×’ işareti siyah ekranda gösterilmektedir. 2 saniye sonra, deneğin gerçekleştireceği MHH’ye ait bir ipucu ekranda görünmektedir. İpucu, sola, sağa, aşağıya ve yukarıya doğru bir ok işareti olup her biri dört sınıftan birini temsil etmektedir. Bu ipucu, 1.25 saniye boyunca ekranda görünmektedir. İpucu ekranda görüldükten sonra, deneklerin ‘×’ işareti kaybolana kadar ($t=6s$) ilgili hareketi hayal etmeleri istenmektedir. Bu adımlar tamamlandıktan sonra kısa bir süre beklenip ara verilir ve gereken işlemler tekrarlanır.



Şekil 6.3: Denekler için zaman diyagramı (Veri Kümesi 2) [94].

Veriler kaydedilirken 250 Hz örnekleme frekansı kullanılmış ve verilere 0.5 Hz ile 100 Hz arasında bir bant-geçiren süzgeç uygulanmıştır. Ayrıca yük hattından gelen 50 Hz'lik gürültüyü bastırmak için bir bant durduran filtre kullanılmıştır. EEG sinyalinin elde etmek için toplam 22 elektrot ve bu 22 EEG elektroduna ek olarak 3 EOG (Electrookülogram) elektrodundan yararlanılmıştır. Elektrotların yerleşimi, Şekil 6.4'te gösterilmektedir. Mevcut verilerin %80'i eğitim için kullanılmış, geri kalan veri ise test için ayrılmıştır.



Şekil 6.4: Veri Kümesi 2 için elektrotların yerleşimi [94].

6.1.3 BCI III-3a Veri Kümesi'ni kullanarak yapay veri oluşturma

Yapay oluşturulan veri kümesi (Veri Kümesi 3), üç katılımcıdan toplanan epoklardan oluşmakta ve on farklı MHH görevini içermektedir. Kombine MHH EEG'ler (sağ el-sol el; sol el-ayaklar; sağ el-dil; ayaklar-dil; sağ el-ayaklar; sol el-dil), BCI III-3a Veri Kümesi'ndeki dört basit MHH sinyali (sol el, sağ el, ayaklar ve dil) kullanılarak yapay olarak oluşturulmuştur. Kombine bir MHH EEG sinyali oluşturmak için bir MHH EEG sınıfı, başka bir MHH EEG'ye eklenmiştir:

$$\mathbf{EEG}_{F-T}\{i\}(k, n) = [\mathbf{EEG}_F\{i\}(k, n) + \mathbf{EEG}_T\{i\}(k, n)]/2 \quad (6.1)$$

$$\mathbf{EEG}_{LH-F}\{i\}(k, n) = [\mathbf{EEG}_{LH}\{i\}(k, n) + \mathbf{EEG}_F\{i\}(k, n)]/2$$

$$\mathbf{EEG}_{RH-F}\{i\}(k, n) = [\mathbf{EEG}_{RH}\{i\}(k, n) + \mathbf{EEG}_F\{i\}(k, n)]/2$$

$$\mathbf{EEG}_{LH-T}\{i\}(k, n) = [\mathbf{EEG}_{LH}\{i\}(k, n) + \mathbf{EEG}_T\{i\}(k, n)]/2$$

$$\mathbf{EEG}_{RH-T}\{i\}(k, n) = [\mathbf{EEG}_{RH}\{i\}(k, n) + \mathbf{EEG}_T\{i\}(k, n)]/2$$

$$\mathbf{EEG}_{RH-LH}\{i\}(k, n) = [\mathbf{EEG}_{RH}\{i\}(k, n) + \mathbf{EEG}_{LH}\{i\}(k, n)]/2$$

Burada n örnekleri, k ise kanalları temsil etmektedir. $\mathbf{EEG}_{F-T}\{i\}(k, n)$, $\mathbf{EEG}_{LH-F}\{i\}(k, n)$, $\mathbf{EEG}_{RH-F}\{i\}(k, n)$, $\mathbf{EEG}_{LH-T}\{i\}(k, n)$, $\mathbf{EEG}_{RH-T}\{i\}(k, n)$ ve $\mathbf{EEG}_{RH-LH}\{i\}(k, n)$ sırasıyla i -inci ayak-dil, sol el-ayak, sağ el-ayak, sol el-dil, sağ el-dil ve sağ el-sol el kombine MHH EEG epokunu ifade eder; $\mathbf{EEG}_T(k, n)$ ve $\mathbf{EEG}_F(k, n)$ ise sırasıyla dil ve ayak MHH EEG epoklarını temsil eder. $\mathbf{EEG}_{LH}(k, n)$ ve $\mathbf{EEG}_{RH}(k, n)$ ise sırasıyla sol el ve sağ el MHH sinyallerini temsil etmektedir. Aynı yöntemle, her katılımcı için tüm kombine MHH EEG sinyalleri yapay olarak oluşturulmuştur. Kombine MHH EEG sinyalindeki örnek sayısı, her bir basit MHH sinyalinin örnek sayısına eşittir [50]. Her bir epok, BCI III-3a Veri Kümesi'nde olduğu gibi 60 kanallı MHH EEG'lerden oluşmaktadır. Mevcut verilerin %80'i eğitim için kullanılmış, geri kalan veri ise test için ayrılmıştır [78].

6.1.4 Weibo Veri Kümesi

Weibo Veri Kümesi [95] (Veri Kümesi 4), basit uzuv MHH ile birleşik uzuv motor hareket hayali görevleri arasındaki EEG örüntülerindeki farklılıkları incelemek için tercih edilmiştir. Bu veri kümesinde, on katılımcı yedi motor hareket hayali görevini gerçekleştirmiştir: sol el, sağ el, ayaklar, eller, dinlenme, sol el ve sağ ayak, sağ el ve sol ayak. Veriler, 60 EEG kanalı ve 2 EOG kanalı kullanılarak 200 Hz frekansta örneklendirilmiştir. Her katılımcı için veri toplama, her yedi sınıf için 80 deneme içeren tek bir oturumda gerçekleştirilmiş ve toplamda 560 (80*7) deneme yapılmıştır. Her deneme 8 saniye uzunluğunda ve deneyler ekranın ortasında beyaz bir dairenin belirmesiyle başlamıştır. 2 saniye sonra, kırmızı bir daire (hazırlık işareti) 1 saniye boyunca belirmiş ve katılımcıların (deneklerin) yaklaşan görev için hazırlanmaları beklenmiştir. Ardından, MHH görevini gösteren karakter ('sol el,' 'sol el & sağ

ayak' vb.) 4 saniye boyunca görüntülenmekte ve bu süre zarfında katılımcılardan herhangi bir kas hareketinden kaçınarak ilgili MHH'yi gerçekleştirmeleri istenmiştir. 7. saniyede, bir sonraki deneme başlamadan önce 1 saniye boyunca 'Rest' (dinlenme) kelimesi deneklere gösterilmiş ve deneklerin herhangi bir MHH gerçekleştirmemeleri istenmiştir. Mevcut verilerin %80'i eğitim için, geri kalan %20'si ise tüm denemelerde test için ayrılmıştır.

6.2 Motor Hareket Hayali Sinyallerinin Gürültüden Temizlenmesi

Ön işlem veya dönüşüm metotları olarak Ortak Ortalama Referanslama (OOR), EOG Regresyon, Dalgacık Temelli Gürültü Temizleme (DTGT) ve Ortak Uzamsal Örüntü (OUÖ) kullanılmıştır. Ayrıca, EEG kanallarıyla birlikte EOG kanalları da derin öğrenme sistemine verilmiş ve elde edilen performans ön işlem (ya da dönüşüm) adımında uygulanan metotlarla kıyaslanmıştır. Bu adımda genellikle gürültü temizleme metotları, EEG sinyallerinde mevcut olabilecek gürültüleri temizlemek için kullanılmış ve en etkili yöntem tespit edilmeye çalışılmıştır. Bu aşamada sadece Veri Kümesi 2'den yararlanılmıştır ve derin öğrenme mimarisi olarak Model 2 kullanılmıştır.

Ön işlemde geçmiş ve ham EEG verileri için performans sonuçları, denek bağımlı sınıflandırma için Çizelge 6.1'de, denek bağımsız sınıflandırma için ise Çizelge 6.2'de gösterilmiştir. Ayrıca, genel performansı daha iyi değerlendirebilmek için dokuz deneğin tüm sonuçlarına ait ortalama, medyan ve standart sapma değerleri Çizelge 6.1'de sunulmuştur. Ancak, karşılaştırma ve tartışmayı kolaylaştırmak amacıyla bu sonuçların ortalaması tezde vurgulanmıştır.

Çizelge 6.1'de, denek bağımlı sınıflandırmada en iyi sonuçlar, OOR, OUÖ ve EEG ile birlikte EOG kanallarının bir arada kullanılmasıyla elde edilmiştir. Çizelge 6.2'de ise, denek bağımsız sınıflandırmada en iyi sonuç, yalnızca EEG ve EOG kanallarının beraber kullanılmasıyla elde edilmiştir.

Denek bağımlı sınıflandırmada, OOR özellikle avantajlıdır çünkü tek bir bireyin verilerindeki gürültü profili genellikle tutarlı olduğundan, OOR ortak gürültü unsurlarına odaklanarak EEG sinyallerini etkili bir şekilde temizleyebilir. Ancak, denek bağımsız sınıflandırmada, modelin farklı bireylerden gelen veriler arasında genelleme yapması gerektiğinden, bireyler arası gürültü türleri ve seviyelerindeki

değişkenlik, OOR'ın etkinliğini azaltmaktadır. Bu değişkenlik, çıkarılan ortalama sinyalin her bireyin EEG verilerindeki spesifik gürültü bileşenlerini tam olarak temsil etmemesi anlamına gelir ve OOR'ın bu farklı gürültüleri ele alma etkinliğini düşürür.

Çizelge 6.1: Bazı gürültü temizleme metodlarının denek bağımlı sınıflama performansları [75].

	Ham veri (22 EEG elektrot)	OOR (22 EEG elektrot)	EOG Regresyon (22 EEG + 3 EOG elektrot)	Dalgacık temelli gürültü temizleme (22 EEG elektrot)	OUÖ (22 EEG elektrot)	22 EEG + 3 EOG =25 elektrot
D1	81.8	88.7	90.5	82.7	88.7	85.3
D2	65.5	81.8	84.4	67.2	80.1	75.8
D3	91.3	92.2	93.1	91.3	93.1	89.6
D4	81	87.0	84.4	81	84.4	86.2
D5	83.6	82.7	78.4	81.8	79.3	95.6
D6	77.5	82.7	79.3	76.7	81.8	80.1
D7	92.2	93.9	91.3	91.3	97.4	91.3
D8	90.5	90.5	90.5	90.5	90.5	91.3
D9	93.1	93.1	93.1	92.2	95.6	96.5
Ortalama	84	88	87.2	83.8	87.8	87.9
Medyan	83.6	88.7	90.5	82.7	88.7	89.6
Standart sapma	8.4	4.5	5.4	7.9	6.4	6.4

EOG Regresyonu'nun, özellikle denek bağımlı sınıflandırmada performansı artırdığı gözlemlenmiştir. Ancak, EEG kanallarıyla birlikte EOG kanallarının dahil edilmesi, hem denek bağımlı hem de denek bağımsız sınıflandırmada performansı daha da artırmaktadır. EOG Regresyonu ile EEG ve EOG kanallarının birlikte kullanımındaki performans farkı, büyük ölçüde EOG Regresyonu'nun basitliğinden kaynaklanmaktadır. EOG Regresyonu genellikle EEG sinyalleri ile göz hareketi kaynaklı artefaktlar arasında doğrusal bir ilişki olduğunu varsayar. Bu doğrusal varsayım, EEG verilerindeki tüm karmaşıklıkları yeterince yansıtamayabilir ve bu durum, artefakt giderme sürecinin daha az etkili olmasına neden olabilir.

Buna karşılık, EOG kanallarının dahil edilmesi, daha zengin ve kapsamlı bir veri bağlamı sunar ve derin öğrenme çerçevesinde daha karmaşık, potansiyel olarak doğrusal olmayan modellerin, ilgili beyin sinyallerini gürültüden daha etkili bir şekilde ayırt etmesine olanak tanır. Bu yöntem, modelin uyum sağlama ve göz hareketi kaynaklı artefaktları doğru bir şekilde tespit etme yeteneğini geliştirerek genel performansı artırır.

Çizelge 6.2: Bazı gürültü temizleme metodlarının denek bağımsız sınıflama performansları [75].

	Ham veri (22 EEG elektrot)	OOR (22 EEG elektrot)	EOG Regresyon (22 EEG + 3 EOG elektrot)	Dalgacık temelli gürültü temizleme (22 EEG elektrot)	OUÖ (22 EEG elektrot)	22 EEG + 3 EOG = 25 elektrot
Tüm denekler	81.8	83.8	82.5	81.4	83.9	87.4

EOG Regresyonu ve EEG ile birlikte EOG kanallarının kullanımı, öncelikli olarak göz hareketi kaynaklı artefaktları azaltmayı hedeflerken, sinyalde diğer türdeki gürültüler devam edebilir. Buna rağmen, sonuçlar, EOG kanallarının dahil edilmesiyle göz kaynaklı gürültünün giderilmesinin, OOR, OUÖ ve Dalgacık Temelli Gürültü Temizleme (DTGT) gibi diğer ön işleme yöntemlerine kıyasla daha yüksek veya benzer performans sağladığını göstermektedir. Ayrıca, EOG kanallarının dahil edilmesi sadece gürültü gidermede değil, MHH ile ilişkili bilgiler taşıyabilme olasılığı da sunduğundan, diğer yöntemlere oranla daha iyi sonuç vermesi normal karşılanabilir. Bu durum, EOG kanallarının sadece bir gürültü kaynağı değil, aynı zamanda anlamlı sinyallerin ayrıştırılmasına katkıda bulunabilecek bir veri kaynağı olarak değerlendirilebileceğini göstermektedir.

OUÖ, özellikle denek bağımlı sınıflandırmada, bireysel görevler veya koşullara özgü beyin sinyal örüntülerini etkili bir şekilde izole ederek performansı önemli ölçüde artırmaktadır (Çizelge 6.1 ve Çizelge 6.2’de gösterildiği gibi). OUÖ uygulanmadan önce, Ortak Ortalama Referanslama (OOR) ve EOG Regresyonu gibi çeşitli ön işlem teknikleri test edilmiştir. Ancak, bu yöntemlerin hiçbiri, Çizelge 6.1 ve Çizelge 6.2’de detaylandırılan en iyi performans gösteren modellerin ötesinde performans iyileştirmesi sağlayamamıştır.

Bu çalışmada, DTGT işlemi için 'sym8' dalgacı ve 3. seviye ayrıştırma kullanılarak sinyal özelliklerinin farklı ölçeklerde etkili bir şekilde yakalanması hedeflenmiştir. Ancak bu ayarlara rağmen, DTGT, denek bağımlı ve denek bağımsız sınıflandırmaların performansını artırmamış, hatta bazı durumlarda performansı düşürmüştür. Çeşitli farklı dalgacık türleri ve ayrıştırma seviyeleri ile yapılan ek deneyler, en iyi sonuçların 3. seviyede 'sym8' ile elde edildiğini göstermiştir; ancak bu durum genel performansı iyileştirememiştir.

Bu ilk deney aşamasında, EOG kanallarının EEG ile birlikte kullanılmasının hem denek bağımlı hem de denekten bağımsız uygulamalarda performansı artırdığı gözlemlenmiştir. EOG kanallarının önemine ilişkin ayrıntılı çalışmalar ise Bölüm 6.4'te sunulmaktadır.

6.3 EEG Kanalları Arasından Deneklerden Bağımsız Elektrot Seçimi ve DivFE Mimarisi ile Sınıflama İşlemi

Bu aşamada, Veri Kümesi 1, 2 ve 3 için sonuçlar elde edilmiş ve derin öğrenme mimarisi olarak DivFE (Model 1) kullanılmıştır. Ayrıca, ön işlem adımlarından bağımsız olarak veri çoğaltma (artırma) metodundan da yararlanılmıştır. Veri çoğaltma işleminin amacı, derin öğrenme modelimizin verilerdeki gereksiz bilgilerden etkilenmeden doğru özellikleri belirlemesine yardımcı olmaktır. Bu bağlamda, MHH EEG sinyallerini çoğaltmak için beş adım gerçekleştirilmiştir. Veri çoğaltma yalnızca eğitim kümesine uygulanmış olup, orijinal EEG sinyalleri de artırılmış veri kümesine dahil edilmiştir.

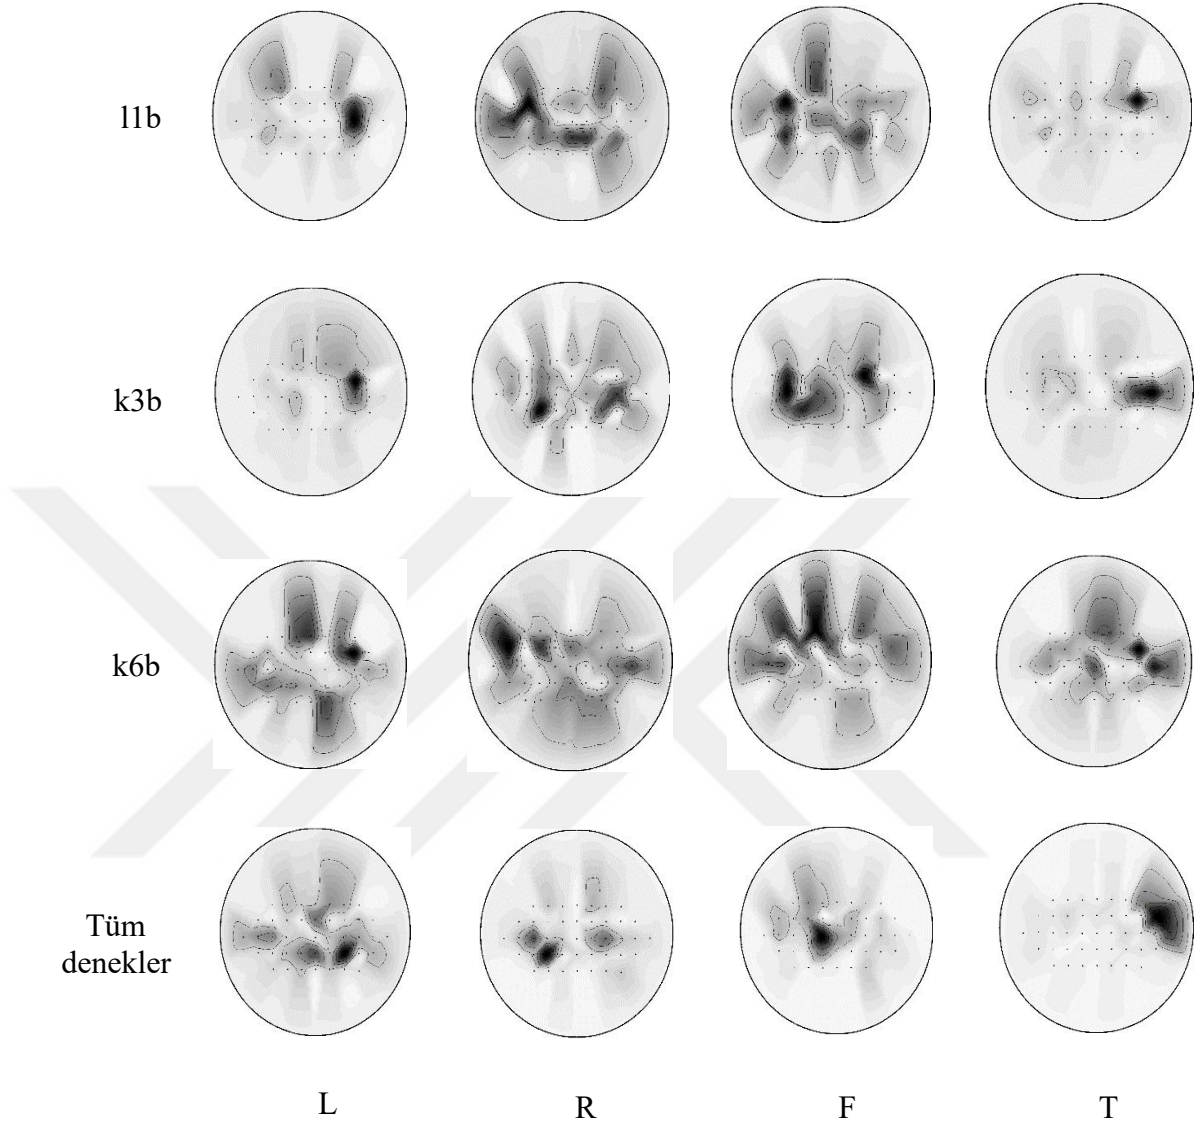
- ◆ **Birinci adımda**, her kanaldaki EEG sinyalinin ortalama değeri sıfıra eşitlenir.
- ◆ **İkinci adımda**, bu ortalama değeri sıfıra eşitlenen EEG sinyalleri 0,2 ile 5,0 arasında rastgele seçilen genliklerle çarpılarak artırılır.
- ◆ **Üçüncü adımda**, ikinci adımın sonunda elde edilen tüm kanallardaki EEG sinyallerinin polaritesi 0,5 olasılıkla ters çevrilir. Başka bir deyişle, EEG sinyalleri 0,5 olasılıkla -1 veya +1 ile çarpılır.
- ◆ **Dördüncü adımda**, üçüncü adımın sonunda elde edilen EEG sinyali, $(-E_{pok_Boyutu}/2)$ ile $(+E_{pok_Boyutu}/2)$ arasında rastgele seçilen tek bir değer etrafında döndürülür.

- ◆ **Beşinci ve son adımda**, dördüncü adımda elde edilen tüm kanallardaki EEG sinyallerine, 0,01 standart sapmaya sahip rastgele gürültü eklenir.


6.3.1 Rayleigh Katsayı Haritası kullanarak elektrot yerlerinin belirlenmesi

Şekil 6.5 ve Şekil 6.6'da, Veri Kümesi 1 ve Veri Kümesi 2 için Rayleigh Katsayı Haritaları gösterilmiştir. Tüm analizler, [3.0 : 3.5], [3.25 : 3.75], ..., [5.5 : 6.0] saniyelik 11 farklı zaman aralığında gerçekleştirilmiştir. Epokların her bir zaman aralığı için Rayleigh Katsayı Haritası bu aralıklarda incelenmiştir. Bu katsayıların görsel haritasının, aynı deneğe ait her bir zaman aralığı için farklı olduğu gözlemlenmiştir. Aslında, her farklı MHH'nin, Şekil 2.3'te ilgili merkezlerinde gözlemleneceği varsayılmaktadır. Epokların zaman aralığı değiştirilerek oluşturulan görsel haritalar detaylı şekilde incelenmiştir. Bu analizler, elektrot seçiminin yalnızca deneğe değil, aynı zamanda belirli bir zaman aralığına da bağlı olup olmadığını belirlemek için bilgi sağlamaktadır. Aynı zamanda, bu çalışma tüm denekler arasında ortak elektrotların belirlenmesine odaklandığından, aynı veri kümesine ait tüm denekler için ortak bir veri kümesi oluşturulmuştur. Şekil 6.5, Veri Kümesi 1'deki ayak (F), dil (T), sol el (L) ve sağ el (R) sınıfları için hesaplanan Rayleigh Katsayı Haritalarını göstermektedir. Bu katsayı haritalarının her biri farklı bir zaman aralığında bulunmuştur. 11b, k3b, k6b ve tüm denekler için zaman aralıkları sırasıyla [3.5 : 4.0], [3.25 : 3.75], [4.25 : 4.75] ve [4.75 : 5.25] saniyedir. 2008 BCI IV-2a Veri Kümesi'nden D1, D3, D7, D8 ve D9 denekleri üzerinde analizler gerçekleştirilmiştir. Bu deneklerin seçilme nedeni, önceki çalışmaların bu denekler için yüksek sınıflandırma performansı elde ettiğini göstermesidir [50, 99]. Şekil 6.6, 2008 BCI IV-2a Veri Kümesi'ndeki ayak (F), dil (T), sol el (L) ve sağ el (R) sınıfları için hesaplanan Rayleigh Katsayı Haritalarını göstermektedir. Bu katsayı haritalarının her biri farklı bir zaman aralığında hesaplanmıştır. D1, D3, D7, D8, D9 ve tüm denekler için zaman aralıkları sırasıyla [3.25 : 3.75], [3.5 : 4.0], [3.75 : 4.25], [3.0 : 3.5], [3.75 : 4.25] ve [3.75 : 4.25] saniyedir. Bu analizler, tüm denekler kullanılarak oluşturulan veri kümesinde MHH EEG aktivasyonlarının, Şekil 2.3'te gösterilen koyu banttaki ilgili merkezlere daha yakın olduğunu göstermektedir. Bu nedenle, bu gözlemler, tüm denekler için belirlenecek ortak elektrotların Şekil 2.3'te gösterilen koyu bant içinde yer alması gerektiğini göstermektedir. Aslında, her denek için farklı bir elektrot seti belirlemek, o denek için sınıflandırma doğruluğunu doğal

olarak artıracaktır. Ancak bu çalışmanın amacı, tüm denekler için ortak bir elektrot seti kullanarak sınıflandırma doğruluğunu artırmaktır [78].



Şekil 6.5: BCI III-3a için Rayleigh Katsayı Haritaları: sol el(L), sağ el(R), ayak(F) ve dil(T) [78].



Şekil 6.6: BCI IV-2a için Rayleigh Katsayı Haritaları: sol el(L), sağ el(R), ayak(F) ve dil(T) [78].

6.3.2 Diverjans değeri kullanarak elektrot yerlerinin belirlenmesi

Bölüm 6.3.1'dekine benzer şekilde analizler belirli bir zaman çerçevesinde yapılmıştır. Tüm analizler, [3.0 : 4.0], [3.25 : 4.25], , [5.0 : 6.0] saniyelik 9 zaman diliminde gerçekleştirilmiştir. Her bir zaman dilimi için MHH EEG sinyallerinin diverjans değerleri incelenmiştir. Bu çalışma, tüm denekler arasında ortak elektrotları belirlemeye odaklandığı için, aynı veri kümesindeki tüm denekler için ortak bir veri kümesi oluşturulmuştur. BCI III-3a Veri Kümesi'nde, 11b, k3b, k6b ve tüm denekler için zaman aralıkları sırasıyla [4.25 : 5.25], [4.0 : 5.0], [3.0 : 4.0] ve [3.75 : 4.75] saniyedir. Analizler, literatürde bu denekler için yüksek performanslar elde edilmiş olan 2008 BCI IV-2a Veri Kümesi'ndeki D1, D3, D7, D8 ve D9 denekleri için yapılmıştır [50, 99]. D1, D3, D7, D8, D9 ve tüm denekler için zaman aralıkları sırasıyla [3.0 : 4.0], [3.0 : 4.0], [3.0 : 4.0], [3.25 : 4.25], [3.0 : 4.0] ve [3.0 : 4.0] saniyedir. Çizelge 6.3 ve Çizelge 6.4'te, her bir denek için farklı zaman aralıklarında elde edilen elektrot setleri ve en yüksek diverjans değerleri gösterilmektedir. Çizelge 6.3, BCI III-3a için elde edilen sonuçları sunmaktadır. Tüm denekler için belirlenen ortak elektrotların {28, 41, 44, 18, 43} Şekil 2.3'deki koyu bandın içinde olduğu gözlemlenebilir. Çizelge 6.4 ise BCI IV-2a için elde edilen sonuçları göstermektedir. Çizelge 6.4'te, tüm denekler için belirlenen ortak elektrotların {14, 16, 18, 13, 17} Şekil 2.3'deki koyu bandın içinde olduğu gözlemlenmektedir.

Çizelge 6.3: BCI III-3a Veri Kümesi'nde 11b, k3b, k6b ve tüm denekler için diverjans değerleri ve elektrot setleri [78].

11b	Elektrot kümesi	{13}	{13,38}	{13,38,37}	{13,38,37,31}	{13,38,37,31,3}
	Diverjans değeri	1.032	2.401	4.122	7.109	12.921
k3b	Elektrot kümesi	{28}	{28,30}	{28,30,40}	{28,30,40,27}	{28,30,40,27,22}
	Diverjans değeri	1.544	3.237	4.702	6.627	8.647
k6b	Elektrot kümesi	{58}	{58,37}	{58,37,60}	{58,37,60,44}	{58,37,60,44,52}
	Diverjans değeri	2.182	4.356	6.765	11.361	18.77
Tüm denekler	Elektrot kümesi	{28}	{28,41}	{28,41,44}	{28,41,44,18}	{28,41,44,18,43}
	Diverjans değeri	0.459	0.957	1.398	1.792	2.144

Çizelge 6.4: BCI IV-2a Veri Kümesi'nde D1, D3, D7, D8, D9 ve tüm denekler için diverjans değerleri ve elektrot setleri [78].

D1	Elektrot kümesi	{14}	{14,15}	{14,15,18}	{14,15,18,3}	{14,15,18,3,2}
	Diverjans değeri	1.153	2.079	2.839	3.519	4.048
D3	Elektrot kümesi	{8}	{8,18}	{8,18,16}	{8,18,16,7}	{8,18,16,7,22}
	Diverjans değeri	1.356	1.882	2.490	2.962	3.461
D7	Elektrot kümesi	{8}	{8,10}	{8,10,22}	{8,10,22,19}	{8,10,22,19,14}
	Diverjans değeri	0.659	1.199	1.626	2.072	2.541
D8	Elektrot kümesi	{20}	{20,18}	{20,18,12}	{20,18,12,21}	{20,18,12,21,13}
	Diverjans değeri	0.612	0.932	1.492	1.984	2.415
D9	Elektrot kümesi	{12}	{12,14}	{12,14,16}	{12,14,16,7}	{12,14,16,7,8}
	Diverjans değeri	1.367	2.084	2.832	3.468	4.181
Tüm denekler	Elektrot kümesi	{14}	{14,16}	{14,16,18}	{14,16,18,13}	{14,16,18,13,17}
	Diverjans değeri	0.264	0.394	0.557	0.712	0.846

6.3.3 DivFE Mimarisi kullanarak sınıflama işlemi

Bu çalışmada, daha az düğümden oluşan bir diverjans tabanlı derin öğrenme mimarisi (DivFE), EEG sinyallerinin sınıflandırılmasında kullanılmıştır. Elektrot setinin, denek ve zaman aralığına bağlı olduğu görülmüştür. Denek sayısı arttıkça, MHH EEG aktivasyonlarının Şekil 2.3'te gösterilen koyu bant içerisinde kalması beklenmektedir. Çizelge 6.3 ve 6.4'te yer alan tüm deneklerin ortak setine ait sonuçlar da bu varsayımı desteklemektedir. Bu nedenle, dört farklı MHH EEG aktivasyonunun beyindeki merkezlerine yakın beş elektrot belirlendi. Bu 5 elektrot, BCI III-3a Veri Kümesi için {28, 31, 32, 33 ve 35} ve BCI IV-2a Veri Kümesi için {8, 10, 11, 12 ve 13} numaralı elektrotlardan oluşmaktadır. Çizelge 6.5, dört sınıfa sahip BCI III-3a'nın 11b, k3b ve k6b denekleri için sınıflandırma performansını göstermektedir. Çizelge 6.6, dört sınıfa sahip BCI IV-2a'nın D1–D9 denekleri için sınıflandırma performansını göstermektedir. Çizelge 6.7 ise, on sınıfa sahip yapay

EEG Veri Kümesi'nin 11b, k3b ve k6b denekleri için sınıflandırma performansını göstermektedir.

Çizelge 6.5: BCI III-3a Veri Kümesi'nde dört sınıf için beş elektrot kullanılarak elde edilen sınıflandırma doğruluk oranları (%) [78].

Denekler	Veri kümesindeki tüm 60 elektrot	5 elektrot kullanarak sınıflandırma doğruluklarının elde edilmesi {28, 31, 32, 33, 35}					
		Veri Artırma	Filtreleme	BBA	SDD	KSFD	fOUÖ
11b	84.8	81.8	97.0	30.3	57.6	63.6	84.8
k3b	77.9	84.7	84.7	38.9	79.6	74.6	81.6
k6b	54.3	74.3	74.3	40	51.4	54.3	54.3
Ortalama doğruluk	72.3	80.3	85.3	36.4	62.8	64.2	73.5

BBA: Bağımsız Bileşen Analizi

Çizelge 6.6: BCI IV-2a Veri Kümesi'nde dört sınıf için beş elektrot kullanılarak elde edilen sınıflandırma doğruluk oranları (%) [78].

Denekler	Veri kümesindeki tüm 22 elektrot	5 elektrot kullanarak sınıflandırma doğruluklarının elde edilmesi {8, 10, 11, 12, 13}					
		Veri Artırma	Filtreleme	BBA	SDD	KSFD	fOUÖ
D1	76.3	77.3	71.8	35.5	68.2	60	73.8
D2	47.2	61	46.7	34.5	44.5	41.8	43.2
D3	82.4	75	71.3	24.1	65.7	59.3	71.6
D4	58.2	62.2	53.1	32.6	54.1	43.9	54.1
D5	35.5	48.6	33.6	26.2	38.3	34.6	43
D6	43	54.7	44.2	36	43	40.7	50.6
D7	70.6	67.9	63.3	34.9	67.9	57.8	55
D8	75.7	67.3	67.3	30.8	60.7	52.3	65.4
D9	78	72	69	34	73	56	68
Ortalama doğruluk	62.9	65.1	57.8	32.1	57.3	49.6	58.3

BBA: Bağımsız Bileşen Analizi

Çizelge 6.7: Yapay oluşturulmuş on sınıf için beş elektrot kullanılarak elde edilen sınıflandırma doğruluk oranları (%) [78].

Denekler	Veri kümesindeki tüm 60 elektrot	5 elektrot kullanarak sınıflandırma doğruluklarının elde edilmesi {28, 31, 32, 33, 35}					
		Veri Artırma	Filtreleme	BBA	SDD	KSFD	fOUÖ
11b	71.9	76.7	55.8	23.1	37.2	25.6	62.2
k3b	89.2	82.4	61.0	13.5	25.6	32.4	57.8
k6b	81.4	72.1	51.2	17.4	24.4	24.4	35.6
Ortalama doğruluk	80.8	77.1	57.3	18	29.1	27.5	51.9

BBA: Bağımsız Bileşen Analizi

Çizelgelerde yedi farklı aşamanın sonuçları görülmektedir. İlk aşamada, tüm sonuçlar herhangi bir elektrot azaltma veya ön işlem uygulamadan, tüm elektrotlar kullanılarak gerçekleştirilmiştir. Dolayısıyla, ön işlem ve kanal azaltma metotlarının performansını bu ham performansla kıyaslama şansı elde edilmektedir. Sonraki aşamalarda, seçilen beş kanal kullanılmış ve ön işlem adımları test edilmiştir. Bu analizlerde, her bir epok beş kanal içermekte ve her kanalın M verisi bulunmaktadır. Tezin ilerleyen bölümlerinde, bu M değeri kullanılarak bazı hesaplamalar yapılacaktır.

İkinci aşamada, kanal azaltma işlemi sonucunda elde edilen beş elektrot için sadece epok çoğaltma (artırma) işlemi yapılmış ve sonuçlar çizelgelere işlenmiştir. Bu adımda herhangi bir ön işlem adımı uygulanmamıştır. Dolayısıyla, sadece veri çoğaltma işleminin, azaltılmış ortak kanallar üzerindeki performansa etkisi test edilmiştir.

Üçüncü aşamada, beş elektrot ve filtreleme yöntemi kullanılarak sınıflandırma doğrulukları elde edilmiştir. Her elektrot için bant geçiren altı farklı filtre kullanılmıştır: (6-12 Hz), (9-15 Hz), (12-18 Hz), (15-21 Hz), (18-24 Hz) ve (21-27 Hz). Böylece, bir epok için 30 kanal elde edilmiştir. Bu aşamada, farklı frekans

bantlarının sınıflandırma performansı üzerindeki etkisi ve elde edilen 30 kanalın MHH verileriyle ilişkili özellikleri ne ölçüde yansıttığı incelenmiştir. Filtreleme işlemi, belirli frekans bantlarında MHH sinyallerini daha belirgin hale getirmeyi amaçlamaktadır.

Dördüncü aşamada, azaltılmış beş elektrot üzerinden Bağımsız Bileşen Analizi ön işlem adımı olarak test edilmiştir. Bağımsız Bileşen Analizi, EEG verilerindeki bağımsız bileşenleri ayırarak göz hareketleri veya kas aktiviteleri gibi istemsiz sinyallerin etkisini en aza indirmeyi amaçlar. Bu yöntem, MHH sinyallerini daha saf bir şekilde elde etmeyi ve sınıflandırma doğruluğunu artırmayı amaçlamaktadır.

Beşinci aşamada, beş elektrot üzerinden Sürekli Dalgacık Dönüşümü (SDD) ön işlem adımı olarak test edilmiştir. Burada bir boyutlu EEG sinyalleri, iki boyutlu hale getirilmiştir. SDD'nin analizi için 20 bileşen kullanılmıştır, dolayısıyla her bir elektrotun boyutu $20 \times M$ 'dir. Filtre olarak Gauss1 filtresi tercih edilmiştir. Elde edilen iki boyutlu görüntüler, sinyalin hem zamansal hem de frekans yapısını koruyarak sınıflandırma performansını geliştirmeyi hedefler.

Altıncı aşamada, beş elektrot ve Kısa Süreli Fourier Dönüşümü (KSFD) kullanılarak sınıflandırma doğrulukları elde edilmiştir. Her bir kanalın bir boyutlu MHH EEG sinyalleri, iki boyutlu görüntülere dönüştürülmüştür. Örnekleme frekansı, hareketli pencere boyutu ve örtüşme sayısı sırasıyla 250, 250 ve 249 olarak belirlenmiştir. Analizler için KSFD'nin 30 bileşeni kullanılmıştır. Bu nedenle, her bir kanalın görüntü boyutu $30 \times M$ 'dir.

Yedinci aşamada, sınıflandırma doğrulukları, beş elektrot ve fOUÖ (filtrelenmiş OUÖ) yöntemi kullanılarak elde edilmiştir. Epoklar, beş kanaldan oluşmaktadır. Her kanal için altı bant geçiren filtre kullanılmıştır: (6-12 Hz), (9-15 Hz), (12-18 Hz), (15-21 Hz), (18-24 Hz) ve (21-27 Hz). OUÖ yöntemi, MHH sinyallerindeki ayırt edici özellikleri daha iyi yakalayarak sınıflandırma başarısını artırmayı amaçlamaktadır. Bant geçiren filtreleme ise, farklı frekans aralıklarındaki sinyallerin özelliklerini ayrı ayrı analiz etme olanağı sağlamaktadır.

Bu çalışmada, DivFE ağları, tüm denekler için aynı veri kümesinde ve aynı yapıya sahip olacak şekilde oluşturulmuştur. MHH EEG epoklarının giriş boyutu, kullanılan ön işlem yöntemine bağlıdır. Bu çalışmada, tüm DivFE ağlarında 16 boyutlu Walsh vektörleri kullanılmıştır, bu nedenle derin öğrenme sisteminin son düzleştirme

katmanında 16 çıkış düğümü bulunmaktadır. DivFE ağının altıncı katmanı, BCI III-3a ve BCI IV-2a Veri Kümeleri için tek bir tam bağlantılı katmandan oluşmaktadır. En büyük zorluklardan biri, derin öğrenme sisteminin genel yapısının belirlenmesidir. Bu çalışmada üç farklı veri kümesi, altı farklı yöntem ve toplam 15 denek yer almaktadır. Bu nedenle, her bir denek için modele ait hiperparametrelerin ince ayarı yapılmamıştır. Çizelge 6.8 ve 6.9'da yalnızca genel yapılar gösterilmiştir. Hiperparametreler, DivFE Mimarisini daha önceden kullanan bazı çalışmalardan [50] elde edilen sonuçlar göz önünde bulundurularak belirlenmiştir.

Çizelge 6.8: Filtreleme, Bağımsız Bileşen Analizi ve fOUÖ için DivFE yapısı (filtre boyutu / katman sayısı) [78].

Veri kümeleri	Katman 1	Katman 2	Katman 3	Katman 4	Katman 5	Katman 6	Katman 7	Katman 8
BCI III-3a	9/40	9/40	9/40	9/40	9/40	20/16	-	-
BCI IV-2a	7/60	7/60	7/60	7/60	7/60	15/16	-	-
Yapay veri kümesi	15/50	13/50	11/50	9/50	7/50	5/50	3/50	5/16

Çizelge 6.9: SDD ve KSFD için DivFE yapısı (fitre boyutu×filtre boyutu / katman sayısı) [78].

Veri kümeleri	Katman 1	Katman 2	Katman 3	Katman 4	Katman 5	Katman 6
BCI III-3a	3×11/40	3×9/40	3×7/40	3×5/40	3×3/40	L×20/16
BCI IV-2a	3×9/40	3×7/40	3×5/40	3×3/40	30×29/16	-
Yapay veri kümesi	3×11/40	3×9/40	3×7/40	3×5/40	3×3/40	L×20/16

L = SDD için 20 ve KSFD için 30

Çizelge 6.5, 6.6 ve 6.7'de gösterildiği gibi, eğitim sırasında ön işlem yöntemlerinin kullanılması sınıflandırma performansını artırmamaktadır. Ancak, DivFE'nin eğitiminde verileri çoğaltmanın olumlu etkisi gözlemlenmiştir. Bununla birlikte, bu gözlemler, her bir ön işlem sürecine özgü ince ayar yapılmadan elde edilmiştir. Ön işlem yöntemleri ayrıca hesaplama yükünü artırmaktadır. Bu nedenle, ön işlem yöntemlerinin kullanılması yerine yalnızca verileri çoğaltma işleminin kullanılması tavsiye edilmektedir.

6.4 EOG Kanallarının Önemine İlişkin Deneklerden Bağımsız Elektrot Seçimi ve EEGNet Benzeri Mimari ile Sınıflama İşlemi

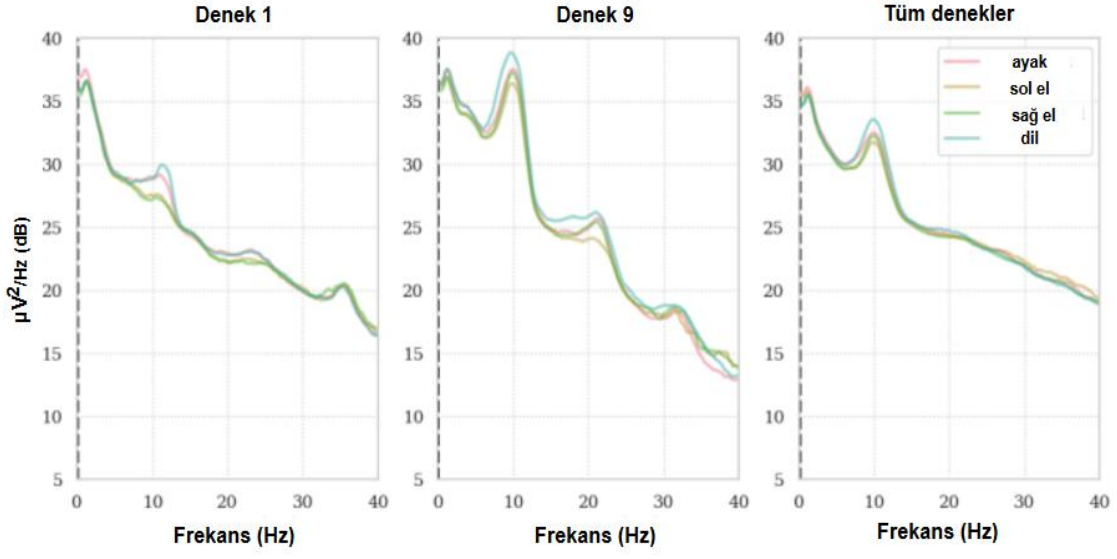
EEG sinyalleri, kendine özgü bazı özellikler taşır. Alfa, beta, teta ve delta dalgaları gibi farklı frekans bantlarında gözlemlenir ve her biri farklı bilişsel durumlar ve aktivitelerle ilişkilidir. Ayrıca, EEG sinyalleri 1/f karakteristiği sergiler; bu durumda güç, frekans arttıkça azalır. Şekil 6.7 ve Şekil 6.8'de, her sınıfa ait Güç Spektral Yoğunluğu (GSY) grafikleri, hem EEG hem de EOG kanalları için, Denek 1 ve Denek 9 gibi bireysel katılımcılar ile tüm katılımcıların birleştirilmiş verileri kullanılarak sırasıyla Veri Kümesi 2 ve Veri Kümesi 4'ten elde edilen sonuçlarla sunulmuştur.

X eksenini, 0.1 ila 40 Hz arasındaki frekansları, Y eksenini ise $\mu\text{V}^2/\text{Hz}$ birimindeki GSY'yi desibel (dB) cinsinden ifade etmektedir. Şekil 6.7 ve Şekil 6.8'in oluşturulması için, 0.1 ile 40 Hz arasındaki frekans aralığına odaklanılarak spektral tahmin için çoklu (multitaper) yöntem uygulanmıştır. Daha düzgün spektral tahminler sağlanmasıyla bilinen bu yöntem, her sınıf, her katılımcı ve tüm katılımcılar birleştirilmiş şekilde, her iki veri kümesi için de GSY'yi doğru bir şekilde yakalamak amacıyla seçilmiştir.

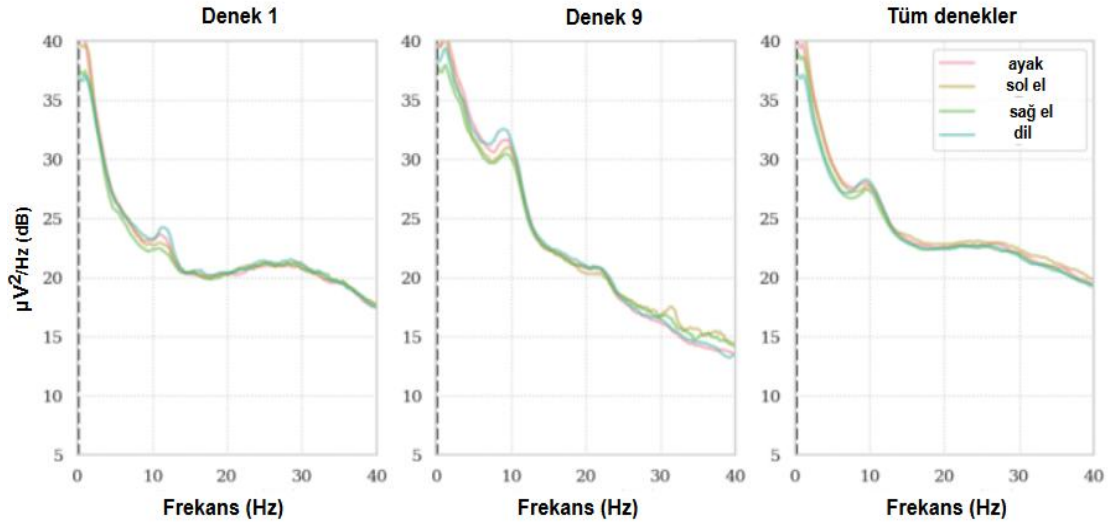
Şekil 6.7 ve Şekil 6.8, hem EEG hem de EOG kanallarının GSY'lerinin her iki veri kümesinde de 1/f özelliklerini koruduğunu göstermektedir. Bu durum, kanallar arasında tutarlı bir frekans dağılımı modeli olduğunu ve EOG kanallarının EEG kanallarına benzer bilgiler taşıyabileceğini düşündürmektedir. Ayrıca, sınıf temelli ilişkilerin özellikle Veri Kümesi 2'de, EOG kanallarında neredeyse EEG kanallarındakiyle aynı olduğu gözlemlenmiştir; bu durum, bu kanalların aktardığı bilgilerde bir örtüşme olabileceğini vurgulamaktadır.

Bu gözlemler, EOG kanallarının görevle ilişkili sinirsel aktiviteleri yansıtabilme potansiyelini desteklemektedir. Ek olarak, sınıf temelli desenlerdeki benzerlik, EOG kanallarının sınıflandırma sürecinde hem sinirsel hem de oküler (göz hareketine dayalı) sinyalleri yansıtan bir karışımı yakalıyor olabileceğini göstermektedir.

(a)

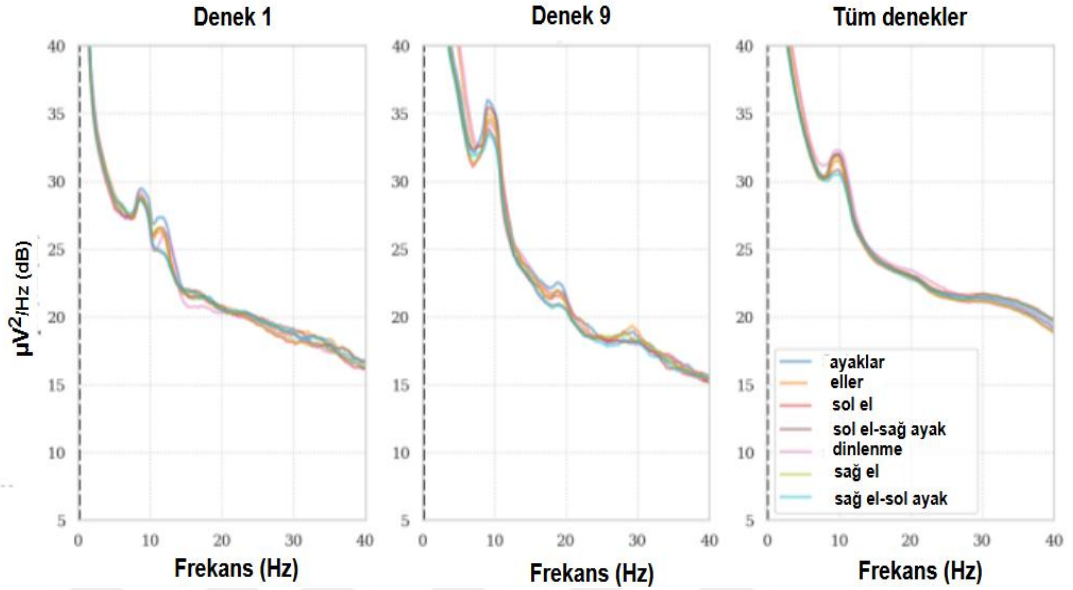


(b)




Şekil 6.7: Veri Kümesi 2’de D1, D9 ve tüm denekler için ortalama Güç Spektral Yoğunluğu (GSY). a) 22 EEG elektrot. b) 3 EOG elektrot [84].

(a)



(b)

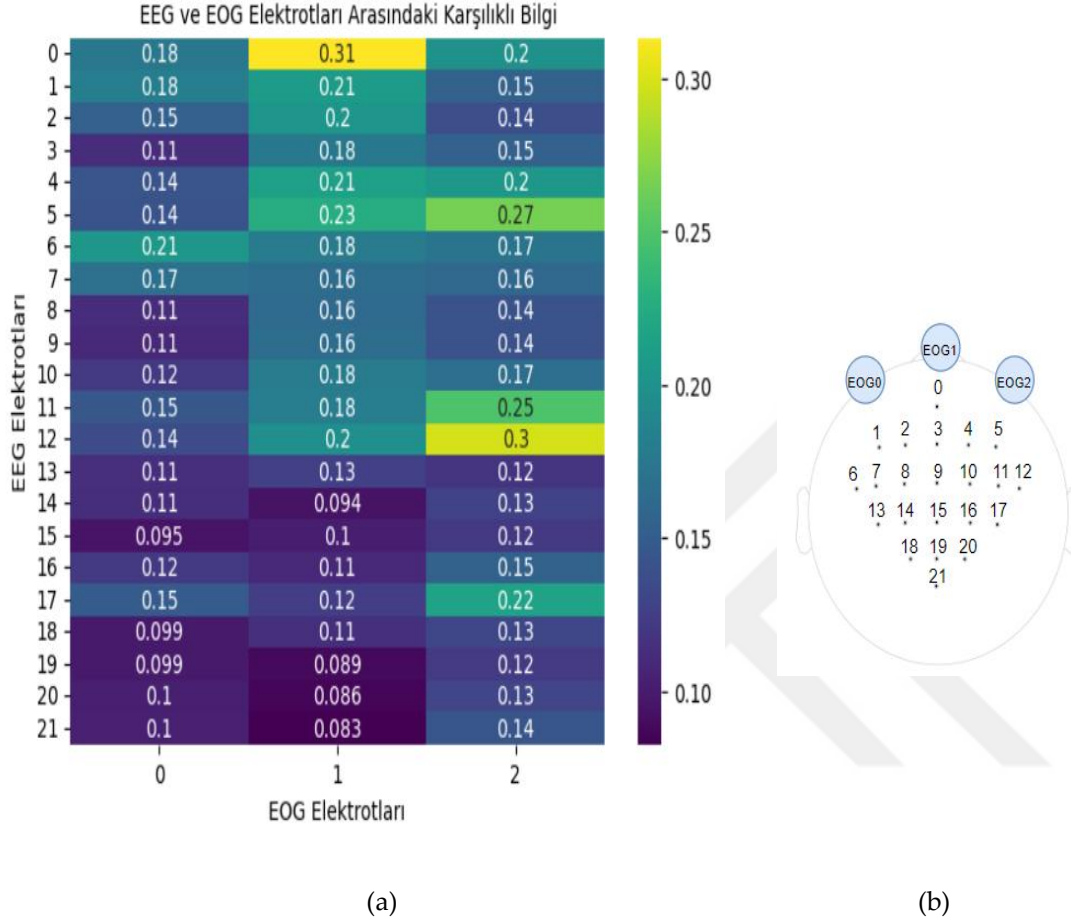


Şekil 6.8: Veri kümesi 4'de D1, D9 ve tüm denekler için ortalama Güç Spektral Yoğunluğu (GSY). a) 60 EEG elektrot. b) 2 EOG elektrot.[84]

6.4.1 Karşılıklı Bilgi kullanarak EEG ve EOG elektrotları arasındaki benzerlik

EEG ve EOG kanalları arasındaki Karşılıklı Bilgi, Veri Kümesi 2 için Şekil 6.9'da ve Veri Kümesi 4 için Şekil 6.10'da gösterilmiştir. Şekil 6.9'da görüldüğü gibi, EOG 0, sırasıyla EEG6, EEG0 ve EEG1 ile en yüksek değeri göstermektedir. EOG 1 için, en yüksek değer sırasıyla EEG0, EEG5, EEG4 ve EEG1 ile elde edilmiştir.

Benzer şekilde, EOG 2, sırasıyla EEG12, EEG5 ve EEG11 ile en yüksek değere sahiptir. EOG ve EEG kanalları arasındaki en yüksek değer, genellikle beynin aynı tarafında bulunan kanallar arasında meydana geldiği gözlemlenmiştir.



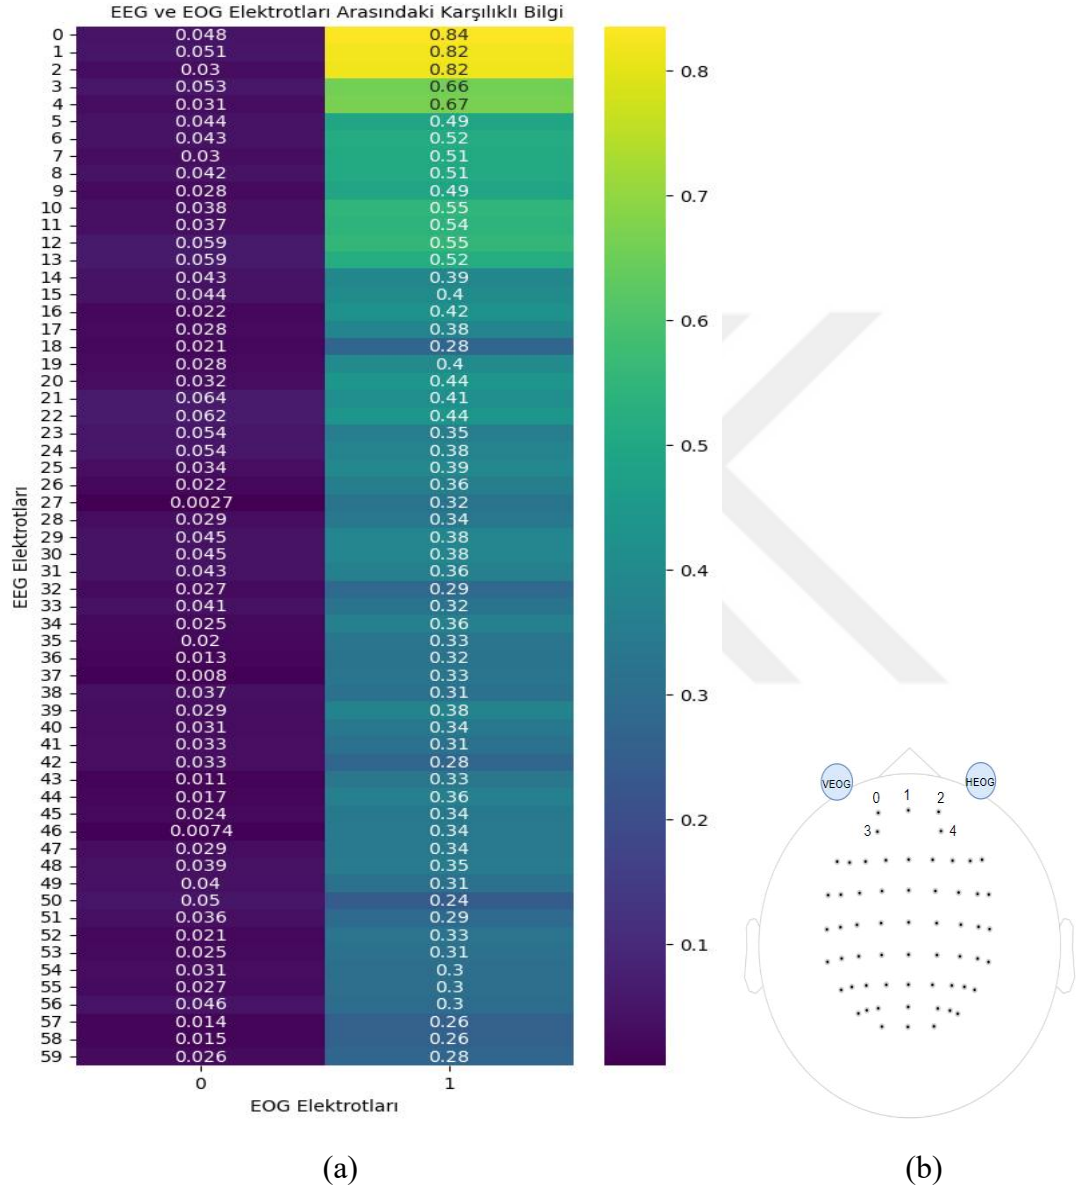
Şekil 6.9: a) Veri Kümesi 2 için EEG ve EOG kanalları arasındaki Karşılıklı Bilgi. b) Veri Kümesi 2 için elektrot konumları [84].

Weibo Veri Kümesi için Şekil 6.10'da, Dikey Elektrokülogram (VEOG) Kanalı (indeks 0) tüm EEG kanallarıyla düşük bilgi değeri sergilerken, Yatay Elektrokülogram (HEOG) Kanalı (indeks 1) özellikle ön (frontal) EEG kanallarıyla yüksek bilgi değeri sergilemektedir.

Bu durum, bu kanalların muhtemelen benzer bilgileri yakaladığını ve EEG ile EOG kanalları arasındaki mesafe azaldıkça bu bilgi değerinin daha yüksek olduğunu (Veri Kümesi 4'deki VEOG hariç) göstermektedir.

Bu yüksek bilgi değeri, her iki senaryonun ayrı ayrı ya da birlikte gerçekleşebileceğini gösterir: Birincisi, EOG kanallarının EEG sinyallerini tamamlayan değerli bilgiler sağlayabileceğini ima eder; ikincisi, gözlere daha yakın

olan bu kanalların hem gözle ilgili artefaktların hem de EEG elektrotlarında mevcut faydalı bilgilerin bulunabileceğini vurgular. Bu da EOG kanallarının EEG kanallarıyla birlikte dikkatlice analiz edilip kullanılmasının önemini ortaya koymaktadır.



Şekil 6.10: a) Veri Kümesi 4 için EEG ve EOG kanalları arasındaki Karşılıklı Bilgi. b) Veri Kümesi 4 için elektrot konumları [84].

Karşılıklı Bilgi analizinin amacı, EEG ve EOG kanallarının benzer bilgileri taşıyabileceğini göstererek EOG kanallarının önemini vurgulamaktır. Bu benzerlik, EOG kanallarının MHH sinyallerinin sınıflandırılmasında faydalı olabileceğini, çünkü bu kanalların tamamlayıcı veya örtüşen öznelikleri yakalayabileceğini


düşündürür. Ayrıca, analiz, genellikle gürültü olarak kabul edilen EOG kanallarının, EEG verileriyle birleştirildiğinde faydalı bilgiler sağlayabileceğini ve böylece sinyal yorumlamasında daha hassas sonuçlar elde edilmesine yardımcı olabileceğini öne sürmektedir.

6.4.2 OUÖ kullanarak elektrot seçimi

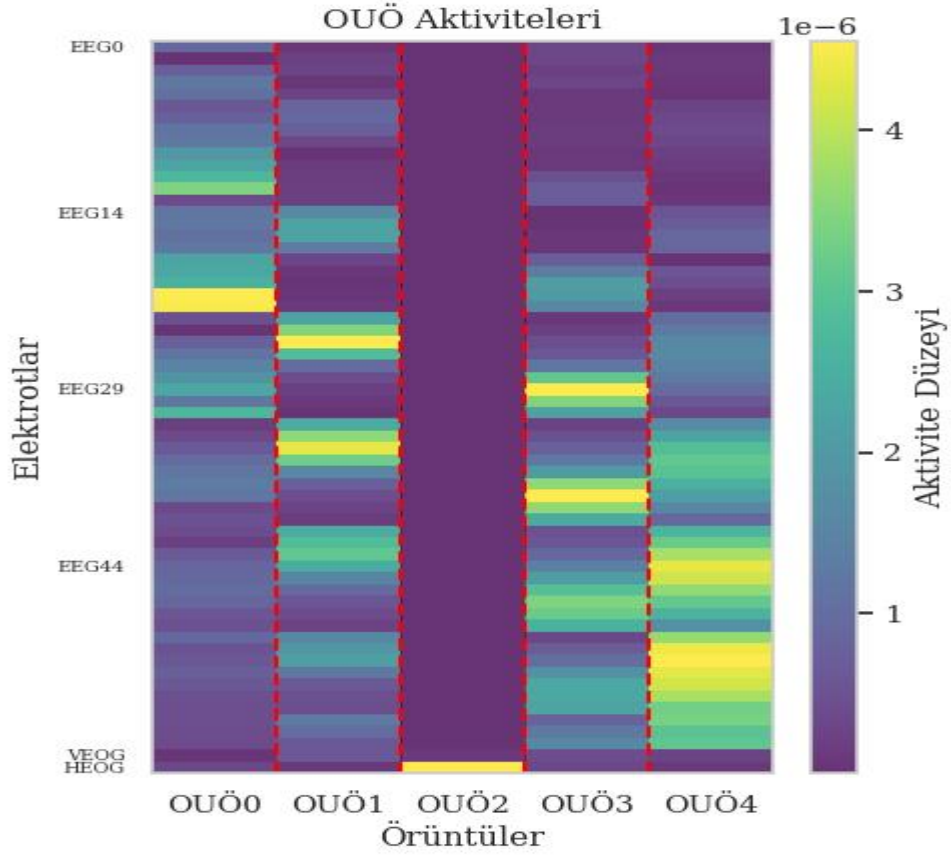
OUÖ'ler, her kanalın katkısını yansıtarak en fazla bilgi miktarını gösterir. Bu örüntüler, özellikle en bilgilendirici kanalları vurguladıkları için önemlidir ve farklı MHH görevleri arasında ayırt edici bir rol oynar.

Bu nedenle, ilk uzamsal örüntüler, EOG kanallarının katkı sağlayan kanallar olarak dahil edilme potansiyelini tespit etmek amacıyla incelenmiştir. Bu ilk örüntülere odaklanarak yapılan analiz, EOG kanallarının ilgili sinirsel aktiviteyi yakalamada önemli bir rol oynayıp oynamadığını belirlemeyi amaçlamaktadır. Her kanal için ilk beş uzamsal örüntüsüne karşılık gelen aktivasyonlar, Veri Kümesi 2 için Şekil 6.11'de ve Veri Kümesi 4 için Şekil 6.12'de gösterilmiştir. Veri Kümesi 2 için, Elektrot 22, 23 ve 24 (son üç kanal: EOG0, EOG1, EOG2) EOG kanallarıdır; Veri Kümesi 4 için ise, Elektrot 60 ve 61 (son iki kanal: VEOG, HEOG) EOG kanallarıdır. Veri Kümesi 2 için, en bilgilendirici ilk uzamsal örüntü olan OUÖ0, tüm kanallar arasında en yüksek aktiviteyi gösteren Elektrot 24 ve 22'yi (EOG 2 ve EOG 0) öne çıkarmaktadır. Ayrıca, OUÖ4 de EOG kanallarını vurgulayarak, sırasıyla Elektrot 24, 23 ve 22'yi (EOG 2, EOG 1 ve EOG 0) öne çıkarmaktadır. Veri Kümesi 4 için ise, üçüncü en önemli örüntü (OUÖ2), Elektrot 61'in (HEOG) en yüksek aktiviteyi sergilediğini göstermektedir. Elektrot 60 (VEOG), Elektrot 61 kadar aktif olmasa da OUÖ2 için aktivite açısından ikinci sıradadır.

Bu ikinci deneyde, OUÖ yalnızca kanal seçimi (veya önem sıralaması) adımıyla uygulanmış olup, genel bir ön işlem adımı olarak uygulanmamıştır. OUÖ ile elde edilen bu örüntüler, EOG kanallarının dahil edilmesinin önemini vurgulamaktadır. Bu durum, EOG kanallarının MHH sınıflandırma görevinde önemli özellikleri yakalamada kritik bir rol oynadığını ve daha iyi bir analiz için EEG verisiyle birlikte entegrasyonlarının gerektiğini göstermektedir. EOG kanallarının dahil edilmesiyle model, yalnızca EEG verisi kullanıldığında gözden kaçabilecek ek özelliklerden faydalanabilir.




Şekil 6.11: Veri Kümesi 2’de tüm elektrotlar boyunca ilk beş uzamsal örüntünün aktivasyonu [84].




Şekil 6.12: Veri Kümesi 4’de tüm elektrotlar boyunca ilk beş uzamsal örüntünün aktivasyonu [84].

6.4.3 Kanal Dikkat Mekanizması kullanarak elektrot seçimi

Şekil 6.13 ve Şekil 6.14, sırasıyla Veri Kümesi 2 ve Veri Kümesi 4 için kanal (elektrot) dikkat ağırlıklarını göstermektedir. Şekil 6.13'te, EOG 2 ve EOG 0 kanalları, tüm 25 kanal arasında en yüksek değere sahipken, EOG 1 de birçok EEG kanalından daha yüksek bir değere sahiptir. Şekil 6.14'te ise, VEOG Kanalı (Kanal 60) en yüksek değere sahipken, HEOG Kanalı (Kanal 61) EEG kanallarıyla karşılaştırılabilir bir değere sahiptir. Bu bulgular, Veri Kümesi 4'deki HEOG hariç, her iki veri kümesi için de EOG kanallarının önemini vurgulamaktadır.



Şekil 6.13: Veri Kümesi 2’de tüm elektrotlar için kanallara ait dikkat ağırlıkları [84].




Şekil 6.14: Veri Kümesi 4’de tüm elektrotlar için kanallara ait dikkat ağırlıkları [84].


6.4.4 Permütasyon Önem Skoru kullanarak elektrot seçimi

Her kanal için Permütasyon Önem Skor'u (PÖS), Veri Kümesi 2 için Şekil 6.15'te ve Veri Kümesi 4 için Şekil 6.16'da gösterilmektedir. Veri Kümesi 2 için yapılan analiz, EOG kanallarının, özellikle sonuncusunun (EOG 2) yüksek değer gösterdiğini ortaya koymaktadır. EOG 0 ve EOG 1, ayrıca birçok EEG kanalına kıyasla daha yüksek değere sahiptir, bu da sınıflandırma sürecindeki önemli rollerini göstermektedir.

Veri Kümesi 4'te ise, VEOG kanalı en yüksek değere sahipken, HEOG kanalı da çoğu EEG kanalından daha yüksek bir değere sahiptir. Bu bulgular, EOG kanallarının sınıflandırma görevi üzerindeki önemli etkisini vurgulayarak, bu kanallardaki varyasyonların modelin performansını önemli ölçüde etkilediğini göstermektedir.



Şekil 6.15: Veri Kümesi 2'de tüm elektrotlar için PÖS [84].




Şekil 6.16: Veri Kümesi 4'de tüm elektrotlar için PÖS [84].

6.4.5 Rastgele Arama Algoritması kullanarak elektrot seçimi

Rastgele Arama Algoritması yalnızca Veri Kümesi 2'ye uygulanmıştır, çünkü Veri Kümesi 4'te çok sayıda EEG kanalı bulunmaktadır. Veri Kümesi 4'e bu yöntemi uygulamak, her kanalın birden çok kez seçildiğinden emin olmak için çok sayıda yinleme gerektirir ve bu da sonuç alma sürecini uzatmaktadır.

Veri Kümesi 2 için, toplam 25 kanaldan altı kanal 500 kez rastgele seçilmiştir. Her yinlemede elde edilen doğruluk, o alt kümedeki kanallara atanan ağırlık olarak işlev görmüş ve her kanal için ortalama doğruluk hesaplanmıştır.

Altı kanalın seçimi Bölüm 6.4.7'de ele alınacaktır. Şekil 6.17, Rastgele Arama Algoritması kullanıldığında Veri Kümesi 2'deki her kanal için ortalama kanal performansını göstermektedir. Şekil 6.17'de gösterildiği gibi, tüm kanallar benzer aktivasyon değerlerine sahip olmakla birlikte, EOG kanalları, özellikle EOG 0 ve EOG 2, tüm EEG kanallarından daha iyi performans göstermektedir.



Şekil 6.17: Veri Kümesi 2’de Rastgele Arama Algoritması kullanarak kanal önemleri [84].

6.4.6 Her bir yöntem için elektrot önemi

Çizelge 6.10, sırasıyla Veri Kümesi 2 ve Veri Kümesi 4'e uygulanan OUÖ, Permütasyon Önem Skoru, Kanal Dikkat Mekanizması ve Rastgele Arama Algoritması olmak üzere dört farklı yöntem için en iyi performans gösteren kanalları sunmaktadır. Bu çizelge, yukarıda açıklanan yöntemlerden elde edilen deneysel sonuçların bir özetini içermektedir. Karşılıklı Bilgi analizi, hem EEG hem de EOG kanallarının sınıflandırma görevi için ortak bilgi taşıyabileceğini göstermeyi

amaçladığından, bu analiz sonuçları Çizelge 6.10'a dahil edilmemiştir. Ayrıca, Rastgele Arama Algoritması Veri Kümesi 4'e uygulanmadığı için, Çizelge 6.10'da ilgili bölüm boş bırakılmıştır.

Çizelge 6.10'da gösterildiği üzere, EOG kanalları tüm yöntemlerde tutarlı bir şekilde etkinliğini göstermiştir. EOG kanallarının çeşitli kanal seçim yöntemleri tarafından tutarlı bir şekilde öne çıkarılması, bu kanalların karmaşık sinyal desenlerini yakalamadaki etkinliğine işaret edebilmektedir.

Çizelge 6.10: Veri Kümesi 2 ve Veri Kümesi 4'e uygulanan dört farklı yöntem için en etkili kanallar [84].

Metotlar	Veri Kümesi 2 için en iyi elektrotlar	Veri Kümesi 4 için en iyi elektrotlar
Ortak Uzamsal Örüntü	OUÖ0: EOG2, EOG0	OUÖ0: EEG elektrotları
	OUÖ1: EEG elektrotları	OUÖ1: EEG elektrotları
	OUÖ2: EEG elektrotları	OUÖ2: HEOG, VEOG
	OUÖ3: EEG elektrotları	OUÖ3: EEG elektrotları
	OUÖ4: EOG2, EOG1, EOG0	OUÖ4: EEG elektrotları
Permütasyon Önem Skoru	EEG7, EEG21, EEG18, EEG17, EOG2,...	VEOG, EEG25, EEG8, EEG29, EEG27, HEOG,...
Kanal Dikkat Mekanizması	EOG2, EOG0, EEG18, EEG7,..	VEOG, EEG27, EEG35,..
Rastgele Arama Algoritması	EOG2, EOG0, EOG1, EEG21,...	

6.4.7 EEGNet Benzeri Mimari kullanarak sınıflama işlemi

MHH aktivitesi ağırlıklı olarak Şekil 2.3'te gösterilen koyu gri alanda gerçekleşmekte olup, bu bölge aynı zamanda dört temel MHH sınıfının (sol el, sağ el, dil ve ayaklar) beyindeki merkezlerini de vurgulamaktadır. Veri Kümesi 2 yalnızca bu dört sınıfı içerirken, Veri Kümesi 4 ek olarak birleşik MHH sınıflarını da içermektedir. Bu birleşik MHH sınıflarının aktivasyon merkezlerinin, orijinal sınıfların aktivasyon merkezlerine yakın olması beklenmektedir.

Her MHH sınıfı için merkezi bölgeleri temsil etmek amacıyla, her iki veri kümesi için de koyu gri bölgenin solundan (elektrot 'C3'), ortasından (elektrot 'Cz') ve sağından (elektrot 'C4') birer EEG kanalı seçilmiştir. Bu doğrultuda, EOG

kanallarının dahil edilmesiyle daha az sayıda kanal kullanarak performans değerlendirmesi yapmak amacıyla, denek bazlı sınıflandırmada Veri Kümesi 2 için 6 kanal (3 EEG + 3 EOG) ve Veri Kümesi 4 için 5 kanal (3 EEG + 2 EOG) belirlenmiştir. Uyumluluğu sağlamak için, Bölüm 6.4.5'te Veri Kümesi 2 için Rastgele Arama Algoritması kullanılarak 6 rastgele kanal seçilmiştir. Çizelge 6.11 ve Çizelge 6.12, sırasıyla Veri Kümesi 2 ve Veri Kümesi 4 için elde edilen sonuçları göstermektedir. Denekler bazındaki tüm sonuçların ortalaması, medyanı ve standart sapması, genel performansın kapsamlı bir değerlendirmesini sağlamak için Çizelge 6.11 ve 6.12'de verilmiştir. Ancak, karşılaştırmalar için yalnızca sonuçların ortalaması dikkate alınmıştır.

Çizelge 6.11: Veri Kümesi 2 için yalnızca EEG, yalnızca EOG, hem EEG hem de EOG birlikte, ve az sayıda EEG ve EOG elektrotları kullanılarak elde edilen doğruluk sonuçları.

Denekler	22 EEG (%)	22 EEG + 3 EOG (%)	3 EOG (%)	3 EEG (%)	3 EEG + 3 EOG (%)
D1	81.8	85.3	62	65.5	79.3
D2	65.5	75.8	63.7	48.2	71.5
D3	91.3	89.6	51.7	82.7	83.6
D4	81	86.2	62.9	59.4	71.5
D5	83.6	95.6	94.8	69.8	95.6
D6	77.5	80.1	62.9	55.1	71.5
D7	92.2	91.3	90.5	85.3	92.2
D8	90.5	91.3	86.2	76.7	91.3
D9	93.1	96.5	75.8	81	90.5
Ortalama	84	87.9	72.2	69.3	83
Medyan	83.6	89.6	63.7	69.8	83.6
Standart sapma	8.46	6.46	14.23	12.41	9.3

Bu çizelgeler yalnızca EEG kanallarını, yalnızca EOG kanallarını, hem EEG hem de EOG kanallarını birlikte ve EOG kanallarıyla beraber az sayıda EEG kanalları kümesini ('C3', 'Cz' ve 'C4') kullanan modelin performansını göstermektedir.

Sonuçlar, EOG kanallarıyla birlikte az sayıda EEG kanalının kullanılmasının, tüm EEG kanallarının kullanılmasına kıyasla benzer veya daha iyi performans sağladığını

göstermektedir. Çizelge 6.11'e göre, Veri Kümesi 2 için, 3 EEG ve 3 EOG kanalından oluşan toplam 6 kanal, %83 doğruluk elde etmiştir; bu oran, 22 EEG kanalının tamamı kullanıldığında elde edilen %84 doğruluğa oldukça yakındır. Çizelge 6.12'de ise, Veri Kümesi 4 için, 3 EEG ve 2 EOG kanalından oluşan toplam 5 kanal, %61 doğruluk sağlamış ve 60 EEG kanalının tamamı kullanıldığında elde edilen %57,4 doğruluğu aşmıştır

Çizelge 6.12: Veri Kümesi 4 için yalnızca EEG, yalnızca EOG, hem EEG hem de EOG birlikte, ve az sayıda EEG ve EOG elektrotları kullanılarak elde edilen doğruluk sonuçları.

Denekler	60 EEG (%)	60 EEG + 2 EOG (%)	2 EOG (%)	3 EEG (%)	3 EEG + 2 EOG (%)
D1	35.7	44.6	51.7	45.5	58
D2	47.3	57.1	49.1	41.9	56.2
D3	40.1	43.7	31.2	41	41
D4	66.9	79.4	62.5	62.5	67.8
D5	64.2	68.7	58.9	73.2	73.2
D6	45	48	50	44	42
D7	64.2	70.5	48.2	52.6	53.5
D8	66.9	64.2	59.8	73.2	73.2
D9	63.3	62.5	58.9	58.9	66
D10	81.2	87.5	81.2	55.3	79.4
Ortalama	57.4	62.6	55.1	54.8	61
Medyan	63.75	63.35	55.3	53.95	62
Standart sapma	13.784	13.89	12.16	11.48	12.47

6.5 Sınıflama Doğruluklarının Literatürle Karşılaştırılması

6.5.1 DivFE Mimarisi ile karşılaştırma

Çizelge 6.13, literatürdeki çalışmaların denek sayılarını, sınıflandırma performanslarını, sınıf sayılarını, azaltılmış elektrot sayılarını, kanal azaltma için kullanılan teknik türlerini ve kullanılan veri kümelerini özetlemektedir. Çoğu

çalışmanın iki sınıflı problemler üzerine yoğunlaştığı gözlemlenmiştir. Beyindeki motor korteks organizasyonu göz önüne alındığında, sol el hareketi beynin sağ yarım küresinde, sağ el hareketi ise beynin sol yarım küresinde aktive edildiğinden, iki sınıflı bir problemi azaltılmış elektrot sayısı ile ayırt etmek görece daha kolaydır. Bu çalışmada, sınıflandırma görevini daha zorlu hale getirmek amacıyla sınıf sayısı 10'a çıkarılmıştır. Çizelge 6.13'te gösterildiği üzere, 10 sınıflı problem için elde edilen sınıflandırma doğruluğu oldukça umut vericidir.

Sınıf sayısının artması, genellikle sınıflandırma performansında belirgin bir düşüşe neden olmaktadır [50]. BCI III-3a Veri Kümesi dört sınıf içermektedir. Çizelge 6.13'te yer alan Jin ve ark. çalışmasında [35], araştırmacılar bu veri kümesindeki dört sınıf arasından yalnızca iki sınıfı seçerek sınıflandırma işlemi gerçekleştirmiştir. Jin ve ark. çalışmasında [35], araştırmacıların neden dört sınıf yerine yalnızca iki sınıfı seçtikleri net değildir. Bununla birlikte, sonuç olarak iki sınıflı sınıflandırmada yüksek doğruluk elde etmişlerdir. Çizelge 6.13'te yer alan Dai ve ark. çalışmasında [101] ise BCI IV-2a Veri Kümesi kullanılmıştır. Bu veri kümesi, dokuz denekten alınan verileri içermekte olup, deneylerde yalnızca D1, D2 ve D3 denekleri dikkate alınmıştır. Elektrot azaltma işlemi sonucunda, D1, D2 ve D3 için sırasıyla 6, 11 ve 8 elektrot belirlenmiştir. Elektrotlar, sınıflandırma performansını artırmak amacıyla deneklere bağlı olarak belirlenmiştir. D1, D2 ve D3 denekleri için, bu çalışmada ortalama %71,1 sınıflandırma doğruluğu elde edilmiştir; Kaynak [101] çalışmasında ise bu oran %76,3 olarak raporlanmıştır. Çalışmamızda ise beş elektrot kullanılmış olup, elektrotlar deneklerden bağımsız olarak belirlenmiştir.

Diğer çalışmalar [106, 107] kendi dört sınıflı veri kümelerini kullanmaktadır. Tanaka ve ark. çalışmasında [106], dört sınıf içeren bir veri kümesi (29 kanal) için kanal sayısı 17 olarak belirlenmiş ve elektrotlar deneklere bağlı olarak belirlenmiştir. Dört sınıf (sol el, sağ el, ayak MHH'ları ve dinlenme durumu) için %46,65 sınıflandırma performansı elde etmişlerdir.

Wei ve ark. [107] çalışmasında, araştırmacılar kendi dört sınıflı veri kümelerini (sol el, sağ el, ayak ve dil MHH'ları) kullanmışlardır. Bu veri kümesi, beş denekten alınan verileri içermektedir. D1, D2, D3, D4 ve D5 denekleri için sırasıyla 6, 11, 14, 8 ve 8 elektrot belirlenmiştir ve beş denek için ortalama %75,6 sınıflandırma performansı elde edilmiştir.

Çizelge 6.13: Elektrot azaltma işlemlerinin uygulandığı çalışmaların DivFE Mimarisi kullanılarak elde edilen sonuçlarla karşılaştırılması [78].

Çalışmalar	Denek Sayısı	Sınıflama Doğruluğu (%)	Sınıf Sayısı	Azaltılmış Elektrot Sayısı	Kullanılan Teknik	Veri Kümesi
Çalışma [100]	5	78.7	2	10	Filtreleme	BCI III-4a
	3	87.3	2	10	Filtreleme	BCI III-3a
Çalışma [101]	3	73.4	2	2, 16, 16	Filtreleme	BCI IV-1
	3	76.3	4	6, 8, 11	Filtreleme	BCI IV-2a
Çalışma [24]	7	83.6	2	17	Filtreleme	BCI IV-1
Çalışma [26]	5	74.5	2	~33.6	Filtreleme	BCI III-4a
	3	85.6	2	~39.3	Filtreleme	BCI III-3a
Çalışma [31]	5	75.1-98.5	2	16-47	Sarmalama	BCI III-4a
Çalışma [32]	5	70.0-96.7	2	22-41	Sarmalama	BCI III-4a
	7	70.0-90.0	2	17-28	Sarmalama	BCI IV-1
Çalışma [33]	1	80	2	10	Sarmalama	BCI III-4a
Çalışma [34]	3	77.8	2	11-51	Filtreleme	BCI III-3a
	5	86.9	2	35-114	Filtreleme	BCI III-4a
	4	84.4	2	12-51	Filtreleme	BCI IV-1
Çalışma [35]	3	91.9	2	13-30	Filtreleme	BCI III-3a
	5	87.4	2	14-67	Filtreleme	BCI III-4a
	4	81.6	2	3-46	Filtreleme	BCI IV-1
Çalışma [36]	5	88.6	2	7-12	Filtreleme	BCI III-4a
	4	84.4	2	6-10	Filtreleme	BCI IV-1
Çalışma [102]	3	79.0	2	23-24	Sarmalama	BCI IV-1
Çalışma [103]	9	73.1	2	2	Sarmalama	BCI IV-2a
Çalışma [104]	9	68.9	4	20	Sarmalama	BCI IV-2a
Çalışma [43]	9	69	4	8	Filtreleme	BCI IV-2a
Çalışma [105]	3	79.4	4	33	Hibrit	BCI III-3a
Bizim çalışmamız	3	80.3	4	5	Filtreleme	BCI III-3a
	9	65.1	4	5	Filtreleme	BCI IV-2a
	3	77.1	10	5	Filtreleme	Yapay veri

Bizim çalışmamızda ise, literatürdeki sınıflandırma performanslarına karşılık gelen sonuçların, az sayıda ortak elektrot kullanılarak elde edildiği gözlemlenmiştir. Çalışmanın amacı, sınıflandırma performansında önemli bir azalma olmadan tüm denekler arasında ortak, asgari sayıda elektrot belirlemektir. Bu bağlamda, Çizelge 6.13'ten görülebileceği gibi, elde edilen sınıflandırma performansları, literatürde daha fazla elektrot kullanılarak elde edilen performanslarla karşılaştırılabilir düzeydedir. Çizelge 6.13'te sunulan çalışmalar ise, tüm denekler için asgari sayıda

ortak elektrot belirleme konusunu ele almadan yalnızca sınıflandırma doğruluğunu iyileştirmeye odaklanmıştır.

6.5.2 EEGNet Benzeri Mimari ile karşılaştırma

Daha önce belirtildiği gibi, sınıf sayısı arttıkça performans azalma eğilimindedir ve bu da yüksek sınıflı MHH sinyalleri için elektrot sayısını azaltmayı daha zor hale getirmektedir. Çizelge 6.14, literatürdeki çoğu çalışmanın yalnızca iki sınıfa odaklandığını ve sınıf sayısı arttıkça elektrot azaltmanın zorluğunu vurgulamaktadır.

Çizelge 6.14: Elektrot azaltma işlemlerinin uygulandığı çalışmaların EEGNet Benzeri Mimari kullanılarak elde edilen sonuçlarla karşılaştırılması [78].

Çalışmalar	Denek Sayısı	Sınıflama Doğruluğu (%)	Sınıf Sayısı	Azaltılmış Elektrot Sayısı	Veri Kümesi
Çalışma [24]	7	83.6	2	17	BCI IV-1
Çalışma [26]	5	74.5	2	~33.6	BCI III-4a
	3	85.6	2	~39.3	BCI III-3a
Çalışma [31]	5	75.1-98.5	2	16-47	BCI III-4a
Çalışma [32]	5	70.0-96.7	2	22-41	BCI III-4a
	7	70.0-90.0	2	17-28	BCI IV-1
Çalışma [34]	3	77.8	2	11-51	BCI III-3a
	5	86.9	2	35-114	BCI III-4a
	4	84.4	2	12-51	BCI IV-1
Çalışma [35]	3	91.9	2	13-30	BCI III-3a
	5	87.4	2	14-67	BCI III-4a
	4	81.6	2	3-46	BCI IV-1
Çalışma [36]	5	88.6	2	7-12	BCI III-4a
	4	84.4	2	6-10	BCI IV-1
Çalışma [43]	9	69	4	8	BCI IV-2a
Çalışma [42]	5	88	4	16	BCI III-4a
	9	75	4	17	BCI IV-2a
Çalışma [40]	5	89.3	2	Denek bazlı	BCI III-4a
	3	84.1	2	Denek bazlı	BCI IV-1
Çalışma [41]	5	90.2	2	Denek bazlı	BCI III-4a
	4	82.8	2	Denek bazlı	BCI IV-1
Bizim çalışmamız	9	83	4	6	BCI IV-2a
	10	61	7	5	Weibo

Bu sorunu ele almak için, mevcut çalışmaların çoğunun genellikle dörtten fazla sınıfı içermediğini kabul ederek, çok sınıflı veri kümeleri seçilmiştir. Weibo Veri Kümesi (Veri Kümesi 4), BBA sistemleri için daha kapsamlı bir çözüm sağlamayı amaçlayan yedi sınıf içerdiği için özel olarak bu çalışmada kullanılmıştır.





7. SONUÇ VE TARTIŞMA

Bu tez çalışması üç deneyden oluşmaktadır. İlk deneyde, MHH sinyalleri için gürültü temizleme metotları karşılaştırılmıştır. Bu kapsamda, EOG elektrotları EEG elektrotlarına ek olarak derin öğrenme mimarisine verilmiş ve bu mimarinin, göz hareketi kaynaklı gürültüleri EOG elektrotlarını kullanarak otomatik olarak tespit edip edemeyeceği araştırılmıştır. EOG kanallarının kullanımı, diğer yöntemlere (OOR, EOG Regresyonu, DTGT, OUÖ) kıyasla daha etkili sonuçlar vermiştir. Tüm bu gözlemler sırasında, EOG elektrotlarının sadece göz hareketi kaynaklı gürültüleri sağlamakla kalmayıp, aynı zamanda MHH ile ilgili faydalı bilgiler de taşıyabileceği anlaşılmıştır. Dolayısıyla, EOG kanallarının önemine ilişkin detaylı çalışmalar üçüncü deney aşamasında yapılmış ve etkinliği gösterilmiştir.

Bundan sonraki deneyler (ikinci ve üçüncü deney), tüm denekler için ortak en iyi elektrotları seçmek amacıyla yapılmıştır. İkinci deney aşamasında, elektrot sayısının belirli bir seviyede tutulması hedeflenmiştir. Bu aşamada BCI III-3a, BCI IV-2a ve yapay bir veri kümesi kullanılmıştır. Ancak yapılan analizler, elektrotların bireylere ve seçilen zaman aralığına oldukça bağımlı olduğunu göstermiştir. Bu nedenle, aynı veri kümesindeki tüm bireylerin verileri kullanılarak geniş bir veri kümesi oluşturulmuştur. Ortak veri kümesine dahil edilen birey sayısı arttıkça, ortak elektrotların Şekil 2.3'teki koyu bölgeden seçilmesi gerektiği daha iyi anlaşılmıştır. Ortak elektrotları belirlemek için filtreleme yöntemlerinden Rayleigh Katsayısı Haritası ve Diverjans Analizi kullanılmıştır. Bu kapsamda, Şekil 2.3'teki koyu bölgeden 5 EEG elektrodu seçilerek sonuçlar gözlemlenmiştir. Elektrot sayısının 5'e düşürülmesi, kurulum hazırlığı için gereken zaman ve çabayı önemli ölçüde azaltırken, denekler için daha fazla konfor sağlamaktadır. Bu çalışmada, elektrot sayısının belirli bir seviyeye düşürülmesinin sınıflandırma doğruluğunu önemli ölçüde azaltmadığı gözlemlenmiştir. Ayrıca, bu yaklaşım, hesaplama yükünü de önemli ölçüde azaltmaktadır. İkinci deney aşamasında, DivFE'nin (Model 1) sınıflandırma doğruluğunu artırmak için filtreleme, Sürekli Dalgacık Dönüşümü,

OUÖ, KSFD ve Bağımsız Bileşen Analizi gibi ön işlem yöntemleri uygulanmış ve sonuçlar karşılaştırılmıştır. Çalışmada, bu ön işlem yöntemlerinin DivFE ile birlikte sınıflandırma performansına etkisi incelenmiş ve ön işlemlerin sınıflandırma performansına katkı sağlamadığı gözlemlenmiştir. Veri artırma (data augmentation) işleminin tek başına sınıflandırma performansını artırmak için yeterli olduğu tespit edilmiştir. Derin Sinir Ağları, genellikle iki bileşenden oluşur: öznitellikleri çıkarıcı bir Evrişimsel Sinir Ağı (ESA) ve sınıflandırıcı olarak görev yapan bir tam bağlantılı yapay sinir ağı. Derin Sinir Ağlarında düğüm sayısının artışına en büyük katkıyı tam bağlantılı yapay sinir ağı bileşeni sağlar. Önerilen mimari (Model 1), ESA kısmını bir öznitellik çıkarıcı olarak ve Minimum Mesafe Ağını (MMA) bir sınıflandırıcı olarak kullanmaktadır. Önerilen mimaride, tam bağlantılı yapay sinir ağından herhangi bir ekstra parametre gelmediği için küçük boyutlu bir mimari haline gelmektedir. Az parametreye sahip bir ağ yapısı, BBA (Beyin-Bilgisayar Arayüzü) sistemlerinin gerçek zamanlı uygulamaları için önemli bir özelliktir. Sadece veri artırma yönteminin tercih edilmesi durumunda, DivFE'nin BCI III-3a, BCI IV-2a ve yapay EEG veri kümeleri için parametre sayıları şu şekilde hesaplanmıştır:

$$\# \text{ parametre (BCI III-3a)} = 5 \times 9 \times 40 + 40 \times 9 \times 40 + 40 \times 9 \times 40 + 40 \times 9 \times 40 + 40 \times 9 \times 40 + 40 \times 20 \times 16 = 72200$$

$$\# \text{ parametre (BCI IV-2a)} = 5 \times 7 \times 60 + 60 \times 7 \times 60 + 60 \times 7 \times 60 + 60 \times 7 \times 60 + 60 \times 7 \times 60 + 60 \times 15 \times 16 = 117300$$

$$\# \text{ parametre (yapay veri kümesi)} = 5 \times 15 \times 50 + 50 \times 13 \times 50 + 50 \times 11 \times 50 + 50 \times 9 \times 50 + 50 \times 7 \times 50 + 50 \times 5 \times 50 + 50 \times 3 \times 50 + 50 \times 5 \times 16 = 127750$$

Üçüncü deney aşaması, EOG kanallarının önemine ilişkin yapılan çalışmaları kapsamaktadır. Bu aşamada, BCI IV-2a (4 sınıf MHH) ve Weibo Veri Kümesi (7 sınıf MHH) kullanılmış ve herhangi bir veri artırma tekniği kullanılmamıştır. Tüm kanalların performansı, hem filtreleme hem de sarmalama tabanlı yöntemler kullanılarak analiz edilmiştir. Analizler, Karşılıklı Bilgi, OUÖ, PÖS, KDM ve Rastgele Arama gibi tekniklerle değerlendirildiğinde, EOG kanallarının genellikle çoğu EEG kanallarına göre daha yüksek önem skorları elde ettiğini göstermiştir. Bu sonuçlar, özellikle EEG sinyalleriyle birleştirildiğinde, EOG kanallarının değerli bilgiler sağlayabildiğini vurgulamaktadır. İkinci deney aşamasında vurgulanan Şekil 2.3'teki gri bölgeden üç EEG elektrodu (C3, Cz, C4) her bir veri setinde mevcut EOG elektrotlarıyla birleştirilerek elektrot azaltılması gerçekleştirilmiş ve etkili

sonular alınmıřtır. Bu alıřmada, EOG kanallarının hem sınıflandırma hem de kanal azaltma srelerine dahil edilmesinin potansiyel faydaları gsterilmiřtir. nc deneyde, ikinci deneyden farklı bir mimari (Model 2) geliřtirilmiřtir. Bu yeni mimaride EEGNet'ten esinlenilmiřtir. Elde edilen sonular incelendiėinde, kullanmıř olduėumuz bu mimari ile ok daha iyi sonular elde edildiėi grlmektedir.

Literatrdeki oėu alıřmadan farklı olarak, ikinci ve nc deneylerde elektrot seimi (veya azaltma) hem denekten baėımsız hem de ok sınıflı senaryolarda uygulanmıřtır. Bu yaklařım, bireyler arasındaki deėiřkenlik ve artan sınıf sayısı nedeniyle kanal azaltma ve sınıflandırma srecini daha karmařık hale getirmektedir. Bu zorluklara raėmen, byle senaryolarda elektrot azaltma konusunu ele almak, daha dayanıklı ve uyarlanabilir BBA sistemleri geliřtirmek iin kritik neme sahiptir. Bu tr senaryolar iin etkili zmler, BBA'ların esnekliėini ve performansını artırarak daha eřitli uygulamalar iin daha pratik hale gelmelerini saėlamaktadır.

Gelecekte yapılacak alıřmalarda, EEG ve EOG elektrotlarının birlikte kullanılmasına ynelik daha fazla arařtırma yapılması nerilmektedir. Ayrıca, EOG kanallarının kullanımıyla ilgili daha fazla deneysel arařtırma, gz hareketi ve EEG sinyalleri arasındaki iliřkiyi daha iyi anlamayı saėlayarak, iki kanal tipi arasındaki etkileřimi optimize etmek iin yeni yaklařımlar geliřtirilmesine olanak taniyacaktır. Ek olarak, daha byk veri kmeleri zerinde EEG elektrotlarının seiminin yapılması sistemin gvenilirliėi aısından olduka nemlidir. Yapılacak bu alıřmalar, zellikle ok sınıflı seneryolarda ve deneklerden baėımsız bir řekilde yapıldıėında, daha verimli ve esnek BBA sistemlerinin geliřtirilmesine katkıda bulunacaktır.



KAYNAKLAR

- [1] **Ramoser, H., Müller-Gerking, J., & Pfurtscheller, G.** (2000). Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE Transactions on Rehabilitation Engineering*, 8(4). <https://doi.org/10.1109/86.895946>.
- [2] **Martín-Clemente, R., Olias, J., Thiyam, D. B., Cichocki, A., & Cruces, S.** (2018). Information theoretic approaches for motor-imagery BCI systems: Review and experimental comparison. *In Entropy* (Vol. 20, Issue 1). <https://doi.org/10.3390/e20010007>.
- [3] **Naeem, M., Brunner, C., Leeb, R., Graimann, B., & Pfurtscheller, G.** (2006). Separability of four-class motor imagery data using independent components analysis. *Journal of Neural Engineering*, 3(3). <https://doi.org/10.1088/1741-2560/3/3/003>.
- [4] **Ang, K. K., Chin, Z. Y., Zhang, H., & Guan, C.** (2008). Filter Bank Common Spatial Pattern (FBCSP) in brain-computer interface. *Proceedings of the International Joint Conference on Neural Networks*. <https://doi.org/10.1109/IJCNN.2008.4634130>.
- [5] **Park, S. H., Lee, D., & Lee, S. G.** (2018). Filter Bank Regularized Common Spatial Pattern Ensemble for Small Sample Motor Imagery Classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(2). <https://doi.org/10.1109/TNSRE.2017.2757519>.
- [6] **Fang, Y., Chen, M., Zheng, X., & Harrison, R. F.** (2012). Extending CSP to detect motor imagery in a four-class BCI. *Journal of Information and Computational Science*, 9(1).
- [7] **Fang, Y., Chen, M., & Harrison, R. F.** (2011). A multi-class pattern recognition method for motor imagery EEG data. *Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics*. <https://doi.org/10.1109/ICSMC.2011.6083634>.
- [8] **Lindig-Leon, C., & Bougrain, L.** (2016). A Multi-label Classification Method for Detection of Combined Motor Imageries. *Proceedings - 2015 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2015*. <https://doi.org/10.1109/SMC.2015.543>.
- [9] **Lotte, F., Congedo, M., Lécuyer, A., Lamarche, F., & Arnaldi, B.** (2007). A review of classification algorithms for EEG-based brain-computer interfaces. *In Journal of Neural Engineering* (Vol. 4, Issue 2). <https://doi.org/10.1088/1741-2560/4/2/R01>.

- [10] **Hu, D., Li, W., & Chen, X.** (2011). Feature extraction of motor imagery EEG signals based on wavelet packet decomposition. *2011 IEEE/ICME International Conference on Complex Medical Engineering, CME 2011*. <https://doi.org/10.1109/ICCME.2011.5876829>.
- [11] **Chatterjee, R., Bandyopadhyay, T., Sanyal, D. K., & Guha, D.** (2018). Comparative analysis of feature extraction techniques in motor imagery EEG signal classification. *Smart Innovation, Systems and Technologies*, 79. https://doi.org/10.1007/978-981-10-5828-8_8.
- [12] **Xu, B., & Song, A.** (2008). Pattern Recognition of Motor Imagery EEG using Wavelet Transform. *Journal of Biomedical Science and Engineering*, 01(01). <https://doi.org/10.4236/jbise.2008.11010>.
- [13] **Baig, M. Z., Mehmood, Y., & Ayaz, Y.** (2016). A BCI System Classification Technique Using Median Filtering and Wavelet Transform. *In Lecture Notes in Logistics*. https://doi.org/10.1007/978-3-319-23512-7_34.
- [14] **Kant, P., Hazarika, J., & Laskar, S. H.** (2019). Wavelet transform based approach for EEG feature selection of motor imagery data for braincomputer interfaces. *Proceedings of the 3rd International Conference on Inventive Systems and Control, ICISC 2019*. <https://doi.org/10.1109/ICISC44355.2019.9036445>.
- [15] **Xu, B., Zhang, L., Song, A., Wu, C., Li, W., Zhang, D., Xu, G., Li, H., & Zeng, H.** (2019). Wavelet Transform Time-Frequency Image and Convolutional Network-Based Motor Imagery EEG Classification. *IEEE Access*, 7. <https://doi.org/10.1109/ACCESS.2018.2889093>.
- [16] **Tyagi, A., & Nehra, V.** (2017). Time frequency analysis of non-stationary motor imagery EEG signals. *2017 International Conference on Computing and Communication Technologies for Smart Nation, IC3TSN 2017*, 2017-October. <https://doi.org/10.1109/IC3TSN.2017.8284448>.
- [17] **Sun, L., Feng, Z., Chen, B., & Lu, N.** (2018). A contralateral channel guided model for EEG based motor imagery classification. *Biomedical Signal Processing and Control*, 41. <https://doi.org/10.1016/j.bspc.2017.10.012>.
- [18] **Iqbal, M. A., Rahman, M. M., Muhtasim, S., Uddin Shubha, S. E., & Hasan, M.** (2022). Effect of EOG Artifact Removal on EEG Motor-Imagery Classification. *Proceedings of 2022 25th International Conference on Computer and Information Technology, ICCIT 2022*. <https://doi.org/10.1109/ICCIT57492.2022.10056062>.
- [19] **Wang, D., Miao, D., & Blohm, G.** (2012). Multi-class motor imagery EEG decoding for brain-computer interfaces. *Frontiers in Neuroscience, OCT*. <https://doi.org/10.3389/fnins.2012.00151>.
- [20] **Chaisaen, R., Autthasan, P., Mingchinda, N., Leelaarporn, P., Kunaseth, N., Tammajarung, S., Manoonpong, P., Mukhopadhyay, S. C., & Wilaiprasitporn, T.** (2020). Decoding EEG Rhythms during Action Observation, Motor Imagery, and Execution for Standing and Sitting. *IEEE Sensors Journal*, 20(22). <https://doi.org/10.1109/JSEN.2020.3005968>.

- [21] **Jiang, J., Zhou, Z., Yin, E., Yu, Y., & Hu, D.** (2014). Hybrid Brain-Computer Interface (BCI) based on the EEG and EOG signals. *Bio-Medical Materials and Engineering*, 24(6). <https://doi.org/10.3233/BME-141111>.
- [22] **Naeem Mannan, M. M., Ahmad Kamran, M., Kang, S., & Jeong, M. Y.** (2018). Effect of EOG signal filtering on the removal of ocular artifacts and EEG-based brain-computer interface: A comprehensive study. *Complexity*, 2018. <https://doi.org/10.1155/2018/4853741>.
- [23] **Croft, R. J., & Barry, R. J.** (2000). Removal of ocular artifact from the EEG: A review. In *Neurophysiologie Clinique* (Vol. 30, Issue 1). [https://doi.org/10.1016/S0987-7053\(00\)00055-1](https://doi.org/10.1016/S0987-7053(00)00055-1).
- [24] **Qiu, Z., Jin, J., Zhang, Y., & Wang, X.** (2016). Generic Channels Selection in Motor Imagery-Based BCI. https://doi.org/10.1007/978-981-10-0207-6_57.
- [25] **Kirar, J. S., & Agrawal, R. K.** (2020). A combination of spectral graph theory and quantum genetic algorithm to find relevant set of electrodes for motor imagery classification. *Applied Soft Computing*, 97. <https://doi.org/10.1016/j.asoc.2019.105519>.
- [26] **Gaur, P., McCreddie, K., Pachori, R. B., Wang, H., & Prasad, G.** (2021). An automatic subject specific channel selection method for enhancing motor imagery classification in EEG-BCI using correlation. *Biomedical Signal Processing and Control*, 68. <https://doi.org/10.1016/j.bspc.2021.102574>.
- [27] **Atyabi, A., Luerssen, M., Fitzgibbon, S., & Powers, D. M. W.** (2012). Evolutionary feature selection and electrode reduction for EEG classification. *2012 IEEE Congress on Evolutionary Computation, CEC 2012*. <https://doi.org/10.1109/CEC.2012.6256130>.
- [28] **Feng, J. K., Jin, J., Daly, I., Zhou, J., Niu, Y., Wang, X., & Cichocki, A.** (2019). An Optimized Channel Selection Method Based on Multifrequency CSP-Rank for Motor Imagery-Based BCI System. *Computational Intelligence and Neuroscience*, 2019. <https://doi.org/10.1155/2019/8068357>.
- [29] **Arvaneh, M., Guan, C., Ang, K. K., & Quek, C.** (2011). Optimizing the channel selection and classification accuracy in EEG-based BCI. *IEEE Transactions on Biomedical Engineering*, 58(6). <https://doi.org/10.1109/TBME.2011.2131142>.
- [30] **Shenoy, H. V., & Vinod, A. P.** (2014). An iterative optimization technique for robust channel selection in motor imagery based brain computer interface. *Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics*, 2014-January(January). <https://doi.org/10.1109/smc.2014.6974191>.
- [31] **He, L., Hu, Y., Li, Y., & Li, D.** (2013). Channel selection by Rayleigh coefficient maximization based genetic algorithm for classifying single-trial motor imagery EEG. *Neurocomputing*, 121. <https://doi.org/10.1016/j.neucom.2013.05.005>.

- [32] Shi, B., Wang, Q., Yin, S., Yue, Z., Huai, Y., & Wang, J. (2021). A binary harmony search algorithm as channel selection method for motor imagery-based BCI. *Neurocomputing*, 443. <https://doi.org/10.1016/j.neucom.2021.02.051>.
- [33] Yang, J., Singh, H., Hines, E. L., Schlaghecken, F., Iliescu, D. D., Leeson, M. S., & Stocks, N. G. (2012). Channel selection and classification of electroencephalogram signals: An artificial neural network and genetic algorithm-based approach. *Artificial Intelligence in Medicine*, 55(2). <https://doi.org/10.1016/j.artmed.2012.02.001>.
- [34] Jin, J., Liu, C., Daly, I., Miao, Y., Li, S., Wang, X., & Cichocki, A. (2020). Bispectrum-Based Channel Selection for Motor Imagery Based Brain-Computer Interfacing. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(10). <https://doi.org/10.1109/TNSRE.2020.3020975>.
- [35] Jin, J., Miao, Y., Daly, I., Zuo, C., Hu, D., & Cichocki, A. (2019). Correlation-based channel selection and regularized feature optimization for MI-based BCI. *Neural Networks*, 118. <https://doi.org/10.1016/j.neunet.2019.07.008>.
- [36] Park, Y., & Chung, W. (2020). Optimal Channel Selection Using Correlation Coefficient for CSP Based EEG Classification. *IEEE Access*, 8. <https://doi.org/10.1109/ACCESS.2020.3003056>.
- [37] Zhou, A., Zhang, L., Yuan, X., & Li, C. (2023). A signal prediction-based method for motor imagery EEG classification. *Biomedical Signal Processing and Control*, 86. <https://doi.org/10.1016/j.bspc.2023.105139>.
- [38] Lee, H. C., & Lee, C. H. (2023). Generalized Optimal EEG Channels Selection for Motor Imagery Brain-Computer Interface. *IEEE Sensors Journal*, 23(20). <https://doi.org/10.1109/JSEN.2023.3313236>.
- [39] Pawan, & Dhiman, R. (2023). Electroencephalogram channel selection based on pearson correlation coefficient for motor imagery-brain-computer interface. *Measurement: Sensors*, 25. <https://doi.org/10.1016/j.measen.2022.100616>.
- [40] Meng, M., Dong, Z., Gao, Y., & She, Q. (2023). Optimal channel and frequency band-based feature selection for motor imagery electroencephalogram classification. *International Journal of Imaging Systems and Technology*, 33(2). <https://doi.org/10.1002/ima.22823>.
- [41] Shiam, A. A., Hassan, K. M., Islam, M. R., Almassri, A. M. M., Wagatsuma, H., & Molla, M. K. I. (2024). Motor Imagery Classification Using Effective Channel Selection of Multichannel EEG. *Brain Sciences*, 14(5), 462. <https://doi.org/10.3390/brainsci14050462>.
- [42] Mahamune, R., & Laskar, S. H. (2023). An automatic channel selection method based on the standard deviation of wavelet coefficients for motor imagery based brain-computer interfacing. *International Journal of Imaging Systems and Technology*, 33(2). <https://doi.org/10.1002/ima.22821>.

- [43] **Tong, L., Qian, Y., Peng, L., Wang, C., & Hou, Z. G.** (2023). A learnable EEG channel selection method for MI-BCI using efficient channel attention. *Frontiers in Neuroscience*, 17. <https://doi.org/10.3389/fnins.2023.1276067>.
- [44] **Liang, W., Jin, J., Daly, I., Sun, H., Wang, X., & Cichocki, A.** (2023). Novel channel selection model based on graph convolutional network for motor imagery. *Cognitive Neurodynamics*, 17(5). <https://doi.org/10.1007/s11571-022-09892-1>.
- [45] **Kashefi Amiri, H., Zarei, M., & Daliri, M. R.** (2024). Motor imagery electroencephalography channel selection based on deep learning: A shallow convolutional neural network. *Engineering Applications of Artificial Intelligence*, 136, 108879. <https://doi.org/10.1016/J.ENGAPPAI.2024.108879>.
- [46] **Pudjihartono, N., Fadason, T., Kempa-Liehr, A. W., & O'Sullivan, J. M.** (2022). A Review of Feature Selection Methods for Machine Learning-Based Disease Risk Prediction. In *Frontiers in Bioinformatics* (Vol. 2). <https://doi.org/10.3389/fbinf.2022.927312>.
- [47] **Xia, Y., Dong, J., Li, D., Li, K., Nan, J., & Xu, R.** (2023). An Adaptive Channel Selection and Graph ResNet Based Algorithm for Motor Imagery Classification. *International Journal of Advanced Computer Science and Applications*, 14(5). <https://doi.org/10.14569/IJACSA.2023.0140525>.
- [48] **Tiwari, A.** (2023). A logistic binary Jaya optimization-based channel selection scheme for motor-imagery classification in brain-computer interface. *Expert Systems with Applications*, 223. <https://doi.org/10.1016/j.eswa.2023.119921>.
- [49] **Dokur, Z., & Olmez, T.** (2021). Classification of motor imagery electroencephalogram signals by using a divergence based convolutional neural network. *Applied Soft Computing*, 113. <https://doi.org/10.1016/j.asoc.2021.107881>.
- [50] **Korhan, N., Olmez, T., & Dokur, Z.** (2023). Generating ten BCI commands using four simple motor imageries and classification by divergence-based DNN. *Neural Computing and Applications*, 35(2). <https://doi.org/10.1007/s00521-022-07787-0>.
- [51] **Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. M., Hung, C. P., & Lance, B. J.** (2018). EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 15(5). <https://doi.org/10.1088/1741-2552/aace8c>.
- [52] **Sabour, S., Frosst, N., & Hinton, G. E.** (2017). Dynamic routing between capsules. *Advances in Neural Information Processing Systems*, 2017-December.
- [53] **Ha, K. W., & Jeong, J. W.** (2019). Motor imagery EEG classification using capsule networks. *Sensors* (Switzerland), 19(13). <https://doi.org/10.3390/s19132854>.

- [54] **Lindig-Leon, C., & Bougrain, L.** (2015). Comparison of sensorimotor rhythms in EEG signals during simple and combined motor imageries over the contra and ipsilateral hemispheres. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2015-November. <https://doi.org/10.1109/EMBC.2015.7319259>.
- [55] **Lindig-León, C., Rimbert, S., & Bougrain, L.** (2020). Multiclass Classification Based on Combined Motor Imageries. *Frontiers in Neuroscience*, 14. <https://doi.org/10.3389/fnins.2020.559858>.
- [56] **Leyton, A. S. F., & Sherrington, C. S.** (1917). OBSERVATIONS ON THE EXCITABLE CORTEX OF THE CHIMPANZEE, ORANG-UTAN, AND GORILLA. *Quarterly Journal of Experimental Physiology*, 11(2). <https://doi.org/10.1113/expphysiol.1917.sp000240>.
- [57] **Sun, M., Akiyoshi, H., Igasaki, T., & Murayama, N.** (2013). Asynchronous brain-computer interface with foot motor imagery. *2013 ICME International Conference on Complex Medical Engineering, CME 2013*. <https://doi.org/10.1109/ICCME.2013.6548237>.
- [58] **Liu, Y. H., Lin, L. F., Chou, C. W., Chang, Y., Hsiao, Y. T., & Hsu, W. C.** (2019). Analysis of Electroencephalography Event-Related Desynchronisation and Synchronisation Induced by Lower-Limb Stepping Motor Imagery. *Journal of Medical and Biological Engineering*, 39(1). <https://doi.org/10.1007/s40846-018-0379-9>.
- [59] **Cohen, M. X.** (n.d.). Complete neural signal processing and analysis: Zero to hero [Udemy kursu]. Udemy.<https://www.udemy.com/course/solved-challenges-ants/>.
- [60] **Buzsáki, G., Logothetis, N., & Singer, W.** (2013). Scaling brain size, keeping timing: Evolutionary preservation of brain rhythms. *In Neuron* (Vol. 80, Issue 3). <https://doi.org/10.1016/j.neuron.2013.10.002>.
- [61] **Cybulsky, N.** (1914). Action currents of the cerebral cortex. *Bull Acad Sci Cracov*, pp. 776–781.
- [62] **Vidal, J. J.** (1973). Toward direct brain-computer communication. *In Annual review of biophysics and bioengineering* (Vol. 2). <https://doi.org/10.1146/annurev.bb.02.060173.001105>.
- [63] **Kennedy, P. R., & Bakay, R. A. E.** (1998). Restoration of neural output from a paralyzed patient by a direct brain connection. *NeuroReport*, 9(8). <https://doi.org/10.1097/00001756-199806010-00007>.
- [64] **Müller-Putz, G. R., & Pfurtscheller, G.** (2008). Control of an electrical prosthesis with an SSVEP-based BCI. *IEEE Transactions on Biomedical Engineering*, 55(1). <https://doi.org/10.1109/TBME.2007.897815>.
- [65] **Cheng, M., Gao, X., Gao, S., & Xu, D.** (2002). Design and implementation of a brain-computer interface with high transfer rates. *IEEE Transactions on Biomedical Engineering*, 49(10). <https://doi.org/10.1109/TBME.2002.803536>.

- [66] **Işcan, Z., Özkaya, Ö., & Dokur, Z.** (2011). Classification of EEG in a steady state visual evoked potential based brain computer interface experiment. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 6594 LNCS(PART 2). https://doi.org/10.1007/978-3-642-20267-4_9.
- [67] **Guo, J., Gao, S., & Hong, B.** (2010). An auditory brain-computer interface using active mental response. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 18(3). <https://doi.org/10.1109/TNSRE.2010.2047604>.
- [68] **Matsumoto, Y., Nishikawa, N., Makino, S., Yamada, T., & Rutkowski, T. M.** (2012). Auditory steady-state response stimuli based BCI application - The optimization of the stimuli types and lengths. *2012 Conference Handbook - Asia-Pacific Signal and Information Processing Association Annual Summit and Conference, APSIPA ASC 2012*.
- [69] **Müller-Putz, G. R., Scherer, R., Neuper, C., & Pfurtscheller, G.** (2006). Steady-state somatosensory evoked potentials: Suitable brain signals for brain-computer interfaces? *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 14(1). <https://doi.org/10.1109/TNSRE.2005.863842>.
- [70] **Ahn, M., Hong, J. H., & Jun, S. C.** (2012). Feasibility of approaches combining sensor and source features in brain-computer interface. *Journal of Neuroscience Methods*, 204(1). <https://doi.org/10.1016/j.jneumeth.2011.11.002>.
- [71] **Vialatte, F. B., Maurice, M., Dauwels, J., & Cichocki, A.** (2010). Steady-state visually evoked potentials: Focus on essential paradigms and future perspectives. *In Progress in Neurobiology* (Vol. 90, Issue 4). <https://doi.org/10.1016/j.pneurobio.2009.11.005>.
- [72] **Tausk, D. v., & Tumulka, R.** (2010). Can we make a Bohmian electron reach the speed of light, at least for one instant? *Journal of Mathematical Physics*, 51(12). <https://doi.org/10.1063/1.3520529>.
- [73] **Jeannerod, M.** (1995). Mental imagery in the motor context. *Neuropsychologia*, 33(11). [https://doi.org/10.1016/0028-3932\(95\)00073-C](https://doi.org/10.1016/0028-3932(95)00073-C).
- [74] **Pfurtscheller, G., & Neuper, C.** (2001). Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, 89(7). <https://doi.org/10.1109/5.939829>.
- [75] **Özkahraman, A., Ölmez, T., & Dokur, Z.** (2024). Impact of Noise Elimination Methods on Classification Performance in Motor Imagery EEG. In P. Mylonas, D. Kardaras, & J. Caro (Eds.), *Novel and Intelligent Digital Systems: Proceedings of the 4th International Conference (NiDS 2024)* (pp. 78-89). (*Lecture Notes in Networks and Systems; Hac. 1170 LNNS*). Springer Science and Business Media Deutschland GmbH. https://doi.org/10.1007/978-3-031-73344-4_6.

- [76] Gratton, G., Coles, M. G. H., & Donchin, E. (1983). A new method for off-line removal of ocular artifact. *Electroencephalography and Clinical Neurophysiology*, 55(4). [https://doi.org/10.1016/0013-4694\(83\)90135-9](https://doi.org/10.1016/0013-4694(83)90135-9).
- [77] Griffin, D. W., & Lim, J. S. (1984). Signal Estimation from Modified Short-Time Fourier Transform. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 32(2). <https://doi.org/10.1109/TASSP.1984.1164317>.
- [78] Özkahraman, A., Ölmez, T., & Dokur, Z. (2024). Determination of the common electrodes for users and increasing the classification accuracy of motor imagery EEG. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-024-10789-9>.
- [79] Arizumi, N., & Aksenova, T. (2019). Fast Continuous Wavelet Transform for Brain Computer Interface using piecewise polynomials. *2019 IEEE 19th International Symposium on Signal Processing and Information Technology, ISSPIT 2019*. <https://doi.org/10.1109/ISSPIT47144.2019.9001739>.
- [80] Cohen, M. X. (2022). A tutorial on generalized eigendecomposition for denoising, contrast enhancement, and dimension reduction in multichannel electrophysiology. *NeuroImage*, 247. <https://doi.org/10.1016/j.neuroimage.2021.118809>.
- [81] Makeig, S., Bell, A. J., Jung, T. P., & Sejnowski, T. J. (1995). Independent Component Analysis of Electroencephalographic Data. *NIPS 1995: Proceedings of the 8th International Conference on Neural Information Processing Systems*.
- [82] Baig, M. Z., Aslam, N., & Shum, H. P. H. (2020). Filtering techniques for channel selection in motor imagery EEG applications: a survey. *Artificial Intelligence Review*, 53(2). <https://doi.org/10.1007/s10462-019-09694-8>.
- [83] Haufe, S., Meinecke, F., Görgen, K., Dähne, S., Haynes, J. D., Blankertz, B., & Bießmann, F. (2014). On the interpretation of weight vectors of linear models in multivariate neuroimaging. *NeuroImage*, 87. <https://doi.org/10.1016/j.neuroimage.2013.10.067>.
- [84] Özkahraman, A., Ölmez, T., & Dokur, Z. (2025). Performance Improvement with Reduced Number of Channels in Motor Imagery BCI System. *Sensors*, 25(1), 120. <https://doi.org/10.3390/s25010120>.
- [85] Ghorbanzade, G., Nabizadeh-ShahreBabak, Z., Samavi, S., Karimi, N., Emami, A., & Khadivi, P. (2020). Selection of Proper EEG Channels for Subject Intention Classification Using Deep Learning. *arXiv preprint arXiv:2007.12764*.
- [86] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-December. <https://doi.org/10.1109/CVPR.2016.90>.

- [87] **Goodfellow, I., Bengio, Y., & Courville, A.** (2016). Deep learning An MIT Press Book. *In Nature* (Vol. 29, Issue 7553).
- [88] **Ölmez, T., & Dokur, Z.** (2021). Strengthening the Training of Convolutional Neural Networks By Using Walsh Matrix. ArXiv, abs/2104.00035.
- [89] **Dokur, Z., & Ölmez, T.** (2020). Heartbeat classification by using a convolutional neural network trained with Walsh functions. *Neural Computing and Applications*, 32(16). <https://doi.org/10.1007/s00521-020-04709-w>.
- [90] Papers with Code. (n.d.). Pointwise convolution. Papers with Code. Retrieved December 30, 2024, from <https://paperswithcode.com/method/pointwise-convolution>.
- [91] BCI Competitions III-3a (2005), <http://www.bbc.de/competition/iii/>.
- [92] BBCI. (n.d.). BCI Competition III Dataset IIIa Description. Retrieved from https://www.bbc.de/competition/iii/desc_IIIa.pdf.
- [93] BCI Competitions IV-2a (2008), <http://www.bbc.de/competition/iv/>.
- [94] **Brunner, C., Leeb, R., Müller-Putz, G., Schlögl, A., & Pfurtscheller, G.** (2008). BCI Competition 2008 – Graz data set A [Data set]. Institute for Knowledge Discovery, Graz University of Technology. https://www.bbc.de/competition/iv/desc_2a.pdf.
- [95] **Yi, W., Qiu, S., Wang, K., Qi, H., Zhang, L., Zhou, P., He, F., & Ming, D.** (2014). Evaluation of EEG oscillatory patterns and cognitive process during simple and compound limb motor imagery. *PLoS ONE*, 9(12). <https://doi.org/10.1371/journal.pone.0114853>.
- [96] **Aristimunha, B., Carrara, I., Guetschel, P., Sedlar, S., Rodrigues, P., Sosulski, J., Narayanan, D., Bjareholt, E., Quentin, B., Schirmermeister, R. T., Kalunga, E., Darmet, L., Gregoire, C., Abdul Hussain, A., Gatti, R., Goncharenko, V., Thielen, J., Moreau, T., Roy, Y., Jayaram, V., Barachant, A., & Chevallier, S.** (2023). Mother of all BCI Benchmarks (MOABB) [Software]. <https://doi.org/10.5281/zenodo.10034223>.
- [97] **Larson, E.** (2023, November 20). MNE-Python [Software]. Zenodo. <https://doi.org/10.5281/zenodo.10161630>.
- [98] **Gramfort, A., Luessi, M., Larson, E., Engemann, D. A., Strohmeier, D., Brodbeck, C., Goj, R., Jas, M., Brooks, T., Parkkonen, L., & Hämäläinen, M. S.** (2013). MEG and EEG data analysis with MNE-Python. *Frontiers in Neuroscience*, 7, Article 267, 1–13. <https://doi.org/10.3389/fnins.2013.00267>.
- [99] **Yüksel A.** (2017) Classification methods for motor imagery based brain computer interfaces. PhD Dissertations. Istanbul Technical University. Institute of Science and Technology.
- [100] **Qi, F., Wu, W., Yu, Z. L., Gu, Z., Wen, Z., Yu, T., & Li, Y.** (2021). Spatiotemporal-Filtering-Based Channel Selection for Single-Trial EEG Classification. *IEEE Transactions on Cybernetics*, 51(2). <https://doi.org/10.1109/TCYB.2019.2963709>.

- [101] **Dai, C., Pi, D., & Becker, S. I.** (2020). Shapelet-Transformed Multi-channel EEG Channel Selection. *ACM Transactions on Intelligent Systems and Technology*, 11(5). <https://doi.org/10.1145/3397850>.
- [102] **Park, S. M., Kim, J. Y., & Sim, K. B.** (2018). EEG electrode selection method based on BPSO with channel impact factor for acquisition of significant brain signal. *Optik*, 155. <https://doi.org/10.1016/j.ijleo.2017.10.085>.
- [103] **Naebi, A., Feng, Z., Hosseinpour, F., & Abdollahi, G.** (2021). Dimension reduction using new bond graph algorithm and deep learning pooling on eeg signals for bci. *Applied Sciences* (Switzerland), 11(18). <https://doi.org/10.3390/app11188761>.
- [104] **Sun Z., Fan C., Jia T., Li Q., Wu X.** (2023). EEG Channel Selection Based on Neuron Proportion with SNN for Motor Imagery Classification. *International Conference on Neuromorphic Computing (ICNC)*. <https://doi.10.1109/ICNC59488.2023>.
- [105] **Sun Z., Fan C., Jia T., Qing Li Q., Wu X.** (2024). EEG Channel Selection Based on Neuron Proportion with SNN for Motor Imagery Classification. *Journal of Neural Engineering*. 21. 016029. <https://doi.org/10.1088/1741-2552/ad2496>.
- [106] **Tanaka, T., Uehara, T., & Tanaka, Y.** (2016). Dimensionality reduction of sample covariance matrices by graph fourier transform for motor imagery brain-machine interface. *IEEE Workshop on Statistical Signal Processing Proceedings*, 2016-August. <https://doi.org/10.1109/SSP.2016.7551798>.
- [107] **Wei, Q., Wang, Y., & Lu, Z.** (2013). Cultural-based multi-objective particle swarm optimization for EEG channel reduction in multi-class brain-computer interfaces. *Applied Mechanics and Materials*, 239–240. <https://doi.org/10.4028/www.scientific.net/AMM.239-240.1027>.

ÖZGEÇMİŞ

Ad Soyad : Ali ÖZKAHRAMAN

ÖĞRENİM DURUMU :

- **Lisans** : 09.09.2011, Doğu Akdeniz Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği.
- **Yüksek Lisans** : 26.01.2018, İstanbul Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Elektronik Mühendisliği

MESLEKİ DENEYİM:

- 2015-2025 yılları arasında İstanbul Teknik Üniversitesi'nde araştırma görevlisi olarak çalıştı.
- Şubat 2015 - Ağustos 2015 tarihleri arasında İskenderun Teknik Üniversitesi'nde araştırma görevlisi olarak çalıştı.
- 2013-2015 yılları arasında Karabük Üniversitesi'nde araştırma görevlisi olarak çalıştı.

DOKTORA TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Özkahraman, A.**; Ölmez, T.; Dokur, Z. Performance Improvement with Reduced Number of Channels in Motor Imagery BCI System. *Sensors* 2025, 25, 120. <https://doi.org/10.3390/s25010120>.
- **Özkahraman, A.**, Ölmez, T. & Dokur, Z. Determination of the common electrodes for users and increasing the classification accuracy of motor imagery EEG. *Neural Comput & Applic* (2024). <https://doi.org/10.1007/s00521-024-10789-9>.
- **Özkahraman, A.**, Ölmez, T., Dokur, Z. (2024). Impact of Noise Elimination Methods on Classification Performance in Motor Imagery EEG. In: Mylonas, P., Kardaras, D., Caro, J. (eds) *Novel and Intelligent Digital Systems: Proceedings of the 4th International Conference (NiDS 2024)*. NiDS 2024. Lecture Notes in Networks and Systems, vol 1170. Springer, Cham. https://doi.org/10.1007/978-3-031-73344-4_6.