



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



MOTOR İMGELEME EEG
SİNYALLERİNİN ZAMAN-FREKANS
SPEKTROGRAMI TEMELLİ
SINIFLANDIRMA YÖNTEMLERİNİN
İNCELENMESİ VE KARŞILAŞTIRILMASI

MEHMET GÜROCAK

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisliği Anabilim

Dalı

Elektrik-Elektronik Mühendisliği Programı

DANIŞMAN

Dr. Öğr. Üyesi Veysel Gökhan BÖCEKÇİ

EŞ-DANIŞMAN

Dr. Öğr. Üyesi Ulvi BAŞPINAR

İSTANBUL, 2024



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



MOTOR İMGELEME EEG
SİNYALLERİNİN ZAMAN-FREKANS
SPEKTROGRAMI TEMELLİ
SINIFLANDIRMA YÖNTEMLERİNİN
İNCELENMESİ VE KARŞILAŞTIRILMASI

MEHMET GÜROCAK
(523121015)

YÜKSEK LİSANS TEZİ
Elektrik-Elektronik Mühendisliği Anabilim
Dalı
Elektrik-Elektronik Mühendisliği Programı

DANIŞMAN
Dr. Öğr. Üyesi Veysel Gökhan BÖCEKÇİ

EŞ-DANIŞMAN
Dr. Öğr. Üyesi Ulvi BAŞPINAR

İSTANBUL, 2024

ÖNSÖZ

Bu tez çalışmasının laboratuvar testleri ve analizleri Marmara Üniversitesi Elektrik-Elektronik Mühendisliği (Türkçe) Anabilim Dalı Elektrik-Elektronik Mühendisliği (Türkçe) Programı laboratuvarlarında ve laboratuvarın kendi imkânları ile gerçekleştirilmiştir.

Bu araştırma, FYL-2023-11101 numarası ile yürütülen proje kapsamında Marmara Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından desteklenmiştir.

Yüksek lisans eğitimim sırasında ve çalışmalarım boyunca yardım, destek, güler yüzü ve deneyimlerini esirgemeyen çok kıymetli hocalarım Dr. Öğr. Üyesi Veysel Gökhan BÖCEKÇİ ve Dr. Öğr. Üyesi Ulvi BAŞPINAR’a,

Çalışmamızın testlerinde katılımcı olarak bulunan ve testler esnasında yardımlarını ve iş birliklerini esirgemeyen tüm katılımcılara,

Teşekkürlerimi içtenlikle sunmayı bir borç bilirim.

Eylül 2024

Mehmet GÜROCAK

İÇİNDEKİLER

ÖNSÖZ	iii
İÇİNDEKİLER.....	iv
ÖZET	vii
ABSTRACT	ix
SEMBOLLER.....	xi
KISALTMALAR	xii
ŞEKİL LİSTESİ	xv
TABLO LİSTESİ.....	xviii
1. GİRİŞ	1
2. GENEL BİLGİLER.....	4
2.1. Biyomedikal Sinyaller	4
2.1.1. Beyin sinyallerinin oluşması	7
2.1.1.1. Nöronların Yapısı ve Fonksiyonu	7
2.1.1.2. Elektriksel potansiyel	8
2.1.1.3. Sinaptik iletim	8
2.1.2. Beyin sinyallerinin ölçülmesi	8
2.2. EEG	11
2.2.1. EEG'nin ölçülmesi	12
2.2.1.1. Ölçüm aletleri	13
2.2.2. MI-EEG	14
2.2.3. EEG kanalları	15
2.2.3.1. C3 ve C4 kanalları	17
2.2.4. ERD-ERS olayı	19
2.2.4.1. Olayla ilişkili desenkronizasyon (ERD)	19
2.2.4.2. Olayla ilişkili senkronizasyon (ERS)	20
2.2.4.3. ERD ve ERS'nin motor imgeleme EEG ile ilişkisi	20
2.3. Sinyal Analizi	21
2.3.1. Sinyal ön işleme	21
2.3.1.1. Gürültü ve artefaktların temizlenmesi	21
2.3.1.2. Empedans kontrolü	22
2.3.1.3. Temel hat düzeltmesi	22
2.3.2. Spektrogram	23
2.3.2.1. Spektrogram oluşturma yöntemleri	24

2.4.	Görüntü İşleme ve Analizi.....	29
2.4.1.	Görüntü işleme süreci.....	29
2.4.2.	Görüntü analizi süreci.....	29
2.4.3.	Görsel çıkarma işlemi.....	30
2.4.4.	Gama düzeltmesi	31
2.5.	Sınıflandırma	32
2.5.1.	Sınıflandırmanın temel adımları.....	33
2.5.2.	Sınıflandırma algoritmaları.....	33
2.5.3.	Yapay sinir ağları (ANN)	34
2.5.3.1.	Yapay sinir ağlarının temel yapısı	34
2.5.3.2.	Nöronlar ve aktivasyon fonksiyonları	35
2.5.3.3.	İleri yayılım (forward propagation).....	35
2.5.3.4.	Geri yayılım (backward propagation) ve öğrenme.....	36
2.5.3.5.	CNN.....	36
2.5.3.7.	LSTM	38
2.5.3.8.	GoogLeNet	39
2.5.3.9.	Görüş transformatörü (ViT).....	40
2.6.	Değerlendirme	41
2.6.1.	Eğitim ve test ayrımı	41
2.6.2.	Konfüzyon matrisi	41
2.6.3.	Değerlendirme metrikleri	42
2.6.4.	Alıcı çalışma karakteristik eğrisi (ROC) ve ROC eğrisi altındaki alan (AUC)	43
2.6.5.	Kappa istatistiği	43
2.6.6.	Log-kayıp (log loss)	43
2.6.7.	Çapraz doğrulama (cross-validation)	43
3.	MATERYAL VE YÖNTEM.....	44
3.1.	MI-EEG Sinyallerinin Toplanması.....	44
3.2.	EEG Veri Toplama Cihazının Kullanımı	50
3.3.	Kanalların Seçilmesi.....	51
3.4.	Ham Veri	52
3.5.	Segmentasyon.....	54
3.6.	Ön İşleme Adımları	56
3.7.	Spektrogramların Oluşturulması	58
3.8.	Kanalların Spektrogram Görüntülerinin Çıkarılması	64

3.9.	Renk Yükseltme	67
3.10.	Gama Düzeltmesi Uygulanması	69
3.11.	Sınıflandırma	70
3.11.1.	CNN.....	71
3.11.2.	RNN.....	72
3.11.3.	LSTM	74
3.11.4.	EfficientB	75
3.11.5.	Görüş Transformatörü (ViT)	76
3.12.	Değerlendirme	77
4.	BULGULAR VE TARTIŞMA.....	79
5.	SONUÇ	88
KAYNAKLAR.....		90
ÖZGEÇMİŞ		

ÖZET

MOTOR İMGELEME EEG SİNYALLERİNİN ZAMAN-FREKANS SPEKTROGRAMI TEMELLİ SINIFLANDIRMA YÖNTEMLERİNİN İNCELENMESİ VE KARŞILAŞTIRILMASI

Bu çalışmada, motor imgeleme elektroensefalografi (MI-EEG) sinyallerinin zaman-frekans spektrogramı temelli sınıflandırma yöntemleri incelenmiş ve karşılaştırılmıştır. Sınıflandırma yöntemleri olarak Konvolüsyonel Sinir Ağları, Özyinelemeli Sinir Ağları, Uzun-Kısa Vadeli Bellek, EfficientNet ve Görüş Transformatörü modelleri kullanılmıştır.

Motor imgeleme, bireylerin hareket etmeksizin bir hareketi zihinsel olarak hayal etmeleri sürecidir ve bu süreçte beynin ilgili motor bölgeleri aktif hale gelir. Bu sinyaller, beynin motor korteksinde oluşan elektriksel aktivitelerin ölçülmesiyle elde edilir ve bu sinyallerin analizi, çeşitli hareketlerin algılanması ve sınıflandırılması için önemlidir.

Bu çalışma kapsamında, 8 farklı denekten sağ el, sol el, sağ ayak ve sol ayak imgeleme verileri toplanmıştır. Oluşturulan uygulama ile bilgisayar destekli deney yönetimi kullanılarak katılımcıların uygulama tarafından verilen yönergeleri takip etmeleri sağlanmıştır. Toplanan verilere segmentasyon, bant geçiren filtre ve baz düzeltmesi işlemleri uygulanmış ve her biri sinyal zaman-frekans spektral analiz yöntemleri ile spektrograma dönüştürülmüştür. Spektrogram dönüşümünde özellikle C3 ve C4 kanallarının verileri kullanılmış ve bu iki kanalın spektrogram görüntüleri, enerji farklılıkların mümkün olduğunca ön planda olması için birbirinden çıkarılmıştır. Elde edilen çıkarılmış görüntüler, derin öğrenme yöntemleri ile sınıflandırılmıştır.

Bu çalışmada yapılan sınıflandırma sonuçlarına göre en iyi sonuçlara Konvolüsyonel Sinir Ağları modeli ile ulaşılmış ve sağ el-sol el sınıflandırmalarında %75,53, sağ ayak-sol ayak sınıflandırmalarında %72,81 doğruluk oranı elde edilmiştir. Bu sonuçlar, motor imgeleme Elektroensefalografi (EEG) sinyallerinin zaman-frekans spektrogramları kullanılarak etkin bir şekilde sınıflandırılabilirliğini göstermektedir. Özellikle, literatürde az sayıda bulunan sağ ayak-sol ayak imgelemeleri de sağ el-sol el imgelemeleri ile ele alınmıştır.

Çalışma, MI-EEG sinyallerinin sınıflandırılmasında zaman-frekans analiz yöntemlerinin etkinliğini ortaya koyarak, beyin-bilgisayar arayüzü ve nörorehabilitasyon alanlarında uygulamaların geliştirilmesine katkı sağlamaktadır.



ABSTRACT

EXAMINATION AND COMPARISON OF TIME-FREQUENCY SPECTROGRAM-BASED CLASSIFICATION METHODS FOR MOTOR IMAGERY EEG SIGNALS

In this study, classification methods based on time-frequency spectrograms of motor imagery electroencephalography (MI-EEG) signals were examined and compared. The classification methods used include Convolutional Neural Networks, Recurrent Neural Networks, Long Short-Term Memory, EfficientNet, and Vision Transformer models.

Motor imagery is the process where individuals mentally visualize a movement without physically performing it, during which the relevant motor regions of the brain become active. These signals are obtained by measuring the electrical activities occurring in the motor cortex of the brain, and the analysis of these signals is crucial for detecting and classifying various movements.

In this study, motor imagery data for the right hand, left hand, right foot, and left foot were collected from 8 different subjects. The participants were instructed to follow the guidelines provided by the application using computer-assisted experiment management. The collected data were subjected to segmentation, band-pass filtering, and baseline correction, and each signal was transformed into a spectrogram using time-frequency spectral analysis methods. In the spectrogram transformation, the data from the C3 and C4 channels were specifically used, and the spectrogram images of these two channels were subtracted from each other to highlight the energy differences as much as possible. The obtained differential images were classified using deep learning methods.

According to the classification results in this study, the best results were achieved with the Convolutional Neural Networks model, with an accuracy rate of 75.53% for right hand-left hand classifications and 72.81% for right foot-left foot classifications. These results demonstrate that motor imagery electroencephalography (EEG) signals can be effectively classified using time-frequency spectrograms. Notably, right foot-left foot imagery, which is less frequently studied in the literature, was also considered alongside right hand-left hand imagery.

This study highlights the effectiveness of time-frequency analysis methods in classifying MI-EEG signals, contributing to the development of applications in brain-computer interface and neurorehabilitation fields.



SEMBOLLER

C3	: Elektroensefalografi Sol Korteks Elektrodu
C4	: Elektroensefalografi Sağ Korteks Elektrodu
Ca²⁺	: Kalsiyum İyonu
Cl⁻	: Klor İyonu
Cz	: Merkez Elektrodu
K⁺	: Potasyum İyonu
Na⁺	: Sodyum İyonu

KISALTMALAR

ADC	: Analog-Digital Converter (Analog-Dijital Çevirici)
ANN	: Artifical Neural Network (Yapay Sinir Ağı)
AUC	: Area Under the ROC Curve (ROC Eğrisi Altındaki Alan)
BCI	: Brain Computer Interface (Beyin Bilgisayar Arayüzü)
CNN	: Convolutional Neural Network (Konvolüsyonel Sinir Ağı)
CSP	: Common Spatial Pattern (Ortak Uzamsal Desen)
CWT	: Continuous Wavelet Transform (Sürekli Dalgacık Dönüşümü)
DP	: Doğru Pozitif
DN	: Doğru Negatif
EDA	: Elektrodermal Aktivite
EEG	: Electroencephalography (Elektroensefalografi)
EKG	: Electrocardiography (Elektrokardiyografi)
EMD	: Empirical Mode Decomposition (Ampirik Mod Ayırıştırma)
EMG	: Electromyography (Elektromiyografi)
EP	: Evoked Potential (Uyarılmış Potansiyel)
ERD	: Event-Related Desynchronization (Olay-İlişkili Desenkronizasyon)
ERG	: Electroretinography (Elektroretinografi)
ERP	: Event-Related Potential (Olay-İlişkili Potansiyel)
ERS	: Event-Related Synchronization (Olay-İlişkili Senkronizasyon)
ERSP	: Event-Related Spectral Perturbation (Olay-İlişkili Spektral Bozulma)
FFT	: Fast Fourier Transform (Hızlı Fourier Dönüşümü)
FMRI	: Functional Magnetic Resonance Imaging (Fonksiyonel Manyetik Rezonans Görüntüleme)
FN	: False Negative (Yanlış Negatif)

FP	: False Positive (Yanlış Pozitif)
FPR	: False Positive Rate (Yanlış Pozitif Oranı)
ICA	: Independent Component Analysis (Bağımsız Bileşen Analizi)
IMF	: Intrinsic Mode Functions (İç İçe Mod İşlevleri)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Hafıza)
MEG	: Magnetoencephalography (Manyetoensefalografi)
MI	: Motor Imagery (Motor İmgeleme)
MI-EEG	: Motor Imagery Electroencephalography (Motor İmgeleme Elektroensefalografi)
MRI	: Magnetic Resonance Imaging (Manyetik Rezonans Görüntüleme)
NIRS	: Near-Infrared Spectroscopy (Yakın Kızılötesi Spektroskopisi)
NLP	: Natural Language Processing (Doğal Dil İşleme)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
ROC	: Receiver Operating Characteristic Curve (Alıcı Çalışma Karakteristik Eğrisi)
STFT	: Short-Time Fourier Transform (Kısa Süreli Fourier Dönüşümü)
SVM	: Support Vector Machine (Destek Vektör Makineleri)
TF-CNN	: Time-Frequency Convolutional Neural Network (Zaman-Frekans Konvolüsyonel Sinir Ağı)
TN	: True Negative (Gerçek Negatif)
TP	: True Positive (Gerçek Pozitif)
TPR	: True Positive Rate (Gerçek Pozitif Oranı)
ViT	: Vision Transformer (Görüş Transformatörü)
WVD	: Wigner-Ville Distribution (Wigner-Ville Dağılımı)

YN : Yanlış Negatif

YP : Yanlış Pozitif



ŞEKİL LİSTESİ

Şekil 2.1	Çeşitli Biyomedikal Sinyaller ve Elektrot Pozisyonları [29]	4
Şekil 2.2	Örnek Bir EEG Başlığı [32]	5
Şekil 2.3	Ölçüm Esnasında Oksimetre [35]	6
Şekil 2.4	Nöronların Yapısı [39]	7
Şekil 2.5	EEG Ölçümü Temsili Gösterimi [43]	9
Şekil 2.6	MEG Cihazı [46]	10
Şekil 2.7	ECOG'da EEG'den Farklı Olarak Elektrotlar Doğrudan Beyne Yerleştirilir [49]	11
Şekil 2.8	Frekanslarına Göre Beyin Dalgaları [55]	12
Şekil 2.9	İletken Jel ve EEG Başlığı [57]	13
Şekil 2.10	BCI Uygulaması [62]	15
Şekil 2.11	Aynı Anda Farklı Kanallardan Alınan Sinyaller	16
Şekil 2.12	C3 ve C4 Elektrodlarının Konumları [68]	18
Şekil 2.13	C3 ve C4 Kanalları ERD-ERS Olayı [77]	21
Şekil 2.14	Filtreleme Sonrası EEG Sinyali [79]	22
Şekil 2.15	Temel Hat Düzeltmesi Uygulanmış Sinyal Örneği [82]	23
Şekil 2.16	Aynı Sinyale Ait Örnek Dalga Formu ve Spektrogram Görüntüleri [83]	24
Şekil 2.17	Görüntü Çıkarma Tekniği ile Nesne Takibi [104]	31
Şekil 2.18	Gama Düzeltmesi Uygulanmış Görsel [107]	32
Şekil 2.19	Confussion Matrix Gösterimi	42
Şekil 3.1	Çalışmanın Genel Süreci	45
Şekil 3.2	Oturum Yapısı	46
Şekil 3.3	PsychoPy Programından Çalışmaya Ait Uygulamamızın Görüntüsü	47
Şekil 3.4	Sağ, Sol, Sağ Ayak ve Sol Ayak Aşamalarının PsychoPy Süreci	48

Şekil 3.5 Uygulamada Katılımcılara Verilen Komutlar	48
Şekil 3.6 Veri Alma Sürecinin Şematiği	49
Şekil 3.7 Test ve Veri Kayıt Süreci	50
Şekil 3.8 EEG Başlığı Bağlantı Şeması.....	51
Şekil 3.9 Elektrotların 10-20 Sistemine Göre Pozisyonları ve C3–C4 Elektrotlarının Konumları.....	52
Şekil 3.10 EEG Değişkeninin İçeriği	54
Şekil 3.11 EEG.Event Değişkeninin İçeriği	54
Şekil 3.12 Segmentasyon İşlemi Sonunda Bir Katılımcıya Ait Sol Ayak Verileri	55
Şekil 3.13 Bir Katılımcıya Ait İmgeleme EEG Sinyalinin Bant Geçiren Filtre Öncesi ve Sonrası	56
Şekil 3.14 Temel Hat Düzeltmesi Uygulanmış Sinyal.....	57
Şekil 3.15 El ve Ayak İmgelemelerine Ait C3 ve C4 Kanallarının Spektrogram Görüntüleri	61
Şekil 3.16 Sağ El İmgeleme C3 Elektrodu Spektrogram Görüntüsünün İncelenmesi .	62
Şekil 3.17 ERSP Uygulanmadan Gerçekleştirilen Bir Wavelet Spektrogram Dönüşümü	63
Şekil 3.18 STFT ile Oluşturulan Spektrogram Görüntüsü	64
Şekil 3.19 Bir Piksel Üzerinde Çıkarma İşleminin Gösterimi	65
Şekil 3.20 C3 ve C4 Elektrotlarının Çıkarılması Sonucu Oluşan Görüntüler	67
Şekil 3.21 Renk Arttırma Uygulanmış Görseller	69
Şekil 3.22 Gama Düzeltmesi Uygulanmış Görseller.....	70
Şekil 3.23 Oluşturulan CNN Sınıflandırma Modeli	72
Şekil 3.24 Oluşturulan RNN Mimarisi	73
Şekil 3.25 Oluşturulan LSTM Modeli.....	75
Şekil 3.26 Oluşturulan EfficientB Modeli.....	76

Şekil 4.1 El İmgeleme Doğruluk Karşılaştırma Grafiği	82
Şekil 4.2 Ayak İmgeleme Doğruluk Karşılaştırma Grafiği	84



TABLO LİSTESİ

Tablo 3.1 İmgeleme Hareketi ve Kontrol Sinyali Eşleştirmesi	48
Tablo 4.1 CNN El İmgeleme Sınıflandırma Doğruluk ve F1 Skoru Sonuçları.....	79
Tablo 4.2 CNN Ayak İmgeleme Sınıflandırma Doğruluk ve F1 Skoru Sonuçları	80
Tablo 4.3 El İmgeleme Sınıflandırma Doğruluk Tablosu	81
Tablo 4.4 Ayak İmgeleme Sınıflandırma Doğruluk Tablosu	83
Tablo 4.5 Wavelet ve FFT Karşılaştırma Tablosu – El İmgeleme.....	85
Tablo 4.6 Ayak İmgeleme CNN Üzerinde Gama Correction Karşılaştırma Tablosu	86
Tablo 4.7 El ve Ayak İmgeleme Karşılaştırmaları	87



BÖLÜM 1

1. GİRİŞ

EEG, beynin elektriksel aktivitelerinin ölçülmesi için kullanılan bir tekniktir ve beyin-bilgisayar arayüzleri (BCI), nörorehabilitasyon ve çeşitli nörobilimsel araştırmalar gibi alanlarda geniş bir uygulama alanı bulmaktadır [1]. EEG sinyalleri, beynin yüzeyinde bulunan elektrotlar aracılığıyla ölçülür ve bu sinyaller, beyin aktivitelerinin zaman içindeki dinamiklerini anlamamıza olanak tanır [2].

Motor imgeleme (MI) ise bireylerin hareket etmeksizin bir hareketi zihinsel olarak hayal etmeleri sürecidir ve bu süreçte beynin ilgili motor bölgeleri aktif hale gelir [3]. Motor imgeleme olayının, beyin-bilgisayar arayüzleri (BCI) ve nöro rehabilitasyon gibi alanlarda geniş bir kullanım alanı bulunmaktadır [4]. MI-EEG sinyalleri, beynin motor korteksinde oluşan elektriksel aktivitelerin ölçülmesiyle elde edilir ve bu sinyallerin analizi, çeşitli hareketlerin algılanması ve sınıflandırılması için kritik öneme sahiptir [5]. Motor imgeleme sürecinde, EEG sinyallerinde olayla ilişkili desenkronizasyon (ERD) ve olayla ilişkili senkronizasyon (ERS) olarak adlandırılan karakteristik değişiklikler gözlemlenir [6,7]. ERD, motor korteksin aktif hale gelmesiyle alfa ve beta ritimlerinin azalmasını ifade ederken ERS motor görevin tamamlanması veya dinlenme sırasında bu ritimlerin artışını ifade eder. ERD ve ERS, motor imgeleme sürecinin analizi ve sınıflandırılmasında önemli rol oynar. Bu fenomenler, beynin motor bölgelerindeki elektriksel aktivitenin dinamiklerini yansıtarak, farklı motor imgeleme görevlerinin ayırt edilmesini sağlar.

EEG sinyalleri, zamanla değişen dinamik özelliklere sahip sinyaller olduğu için, bu sinyallerin analizinde hem zaman hem de frekans bileşenleri dikkate alınmalıdır. Zaman-frekans spektral analiz, bu iki boyutu birleştirerek sinyallerin farklı frekans bantlarındaki değişimlerini zaman içinde görselleştiren bir yöntemdir [8]. Bu analiz, özellikle EEG sinyallerinin dinamik yapısını incelemek için kritik öneme sahiptir. Sinyallerin zamana bağlı frekans içeriğini ortaya çıkaran zaman-frekans spektrogramları motor imgeleme gibi süreçlerin beyin üzerindeki etkilerinin daha detaylı bir şekilde incelenmesine olanak tanır [9]. Çalışmamızda MI-EEG sinyalleri elde edildikten sonra dalga formlarından spektrogramlara dönüştürülerek zaman-frekans analizinin sağlıklı şekilde yapılması

sağlanmıştır.

EEG sinyallerinin analizi için zaman-frekans spektral analiz yöntemleri sinyallerin hem zaman hem de frekans bileşenlerini analiz ederek, sinyalin dinamik özelliklerini daha ayrıntılı bir şekilde ortaya koyar. Hızlı Fourier dönüşümü (FFT) ve sürekli dalgacık dönüşümü (CWT) gibi yöntemler, EEG sinyallerinin zaman-frekans analizinde kullanılır. Bu analiz yöntemleri, özellikle beyin dalgalarının belirli frekans bantlarındaki değişimlerini incelemek için oldukça etkilidir [2,10–12].

MI-EEG çalışmalarında, özellikle motor korteksin üzerindeki elektrotlar olan C3 ve C4 kanalları kritik öneme sahiptir [13]. C3 elektrodu sol motor korteks, C4 elektrodu ise sağ motor korteks üzerinde bulunur. Bu elektrotlar, motor imgeleme görevleri sırasında elde edilen EEG sinyallerinde belirgin değişimler gösterir. C3 ve C4 kanalları, sağ ve sol el hareketlerinin yanı sıra ayak hareketlerinin de analizinde önemli veriler sağlar.

Beyin-bilgisayar arayüzleri (Brain Computer Interface- BCI) alanında motor imgeleme (MI) ile elektroensefalografi (EEG) sinyalleri arasındaki ilişkiyi araştıran çalışmalar, son yıllarda büyük ilgi görmüştür. MI-EEG sinyallerinin analizi ve sınıflandırılması, bu teknolojilerin rehabilitasyon, robotik protezlerin kontrolü, oyun teknolojileri ve daha birçok uygulama alanında kullanılabilmesini sağlamaktadır [14–16].

EEG sinyallerinin, özellikle motor korteks üzerindeki C3 ve C4 kanallarından elde edilen verilerinin zaman-frekans spektral analiz yöntemleriyle incelenmesi, motor imgeleme görevlerinin belirlenmesinde ve sınıflandırılmasında kritik öneme sahiptir. Benzer şekilde, kalbin elektriksel aktivitesini ölçen elektrokardiyogram (EKG) ve kasların elektriksel aktivitesini ölçen elektromyogram (EMG) gibi yöntemler, ilgili organların fonksiyonlarının izlenmesi ve analiz edilmesinde kullanılır. Zaman frekans spectrogramı temelli çalışmalar incelendiğinde Lu ve arkadaşlarının zaman-frekans spektrogramına dayalı mikro-doppler özellik çıkarımı çalışması örnek olarak verilebilir [17]. Bu çalışmada yerde hareket eden hedefler üç tür harekete ayrılmış, bu hareket türlerini kategorize etmek için zaman frekans spektrogramı ve mikro-Doppler imzasına dayalı yeni bir özellik çıkarma yöntemi önerilmiştir. Deneysel sonuçlar, önerilen özneteliklerin iyi bir ayırt etme yeteneği ve tatmin edici bir sınıflandırma performansı elde edebildiğini göstermiştir.

Shajil ve arkadaşları tarafından yapılan çalışmada beyin bilgisayar arayüzünü geliştirmek adına MI-EEG sinyalleri zaman frekans spektrogramı ve CNN tabanlı olarak sınıflandırılmıştır [18]. MI-EEG sinyallerinin spektrogramları CNN'e girdi olarak verilmiş, tek bir evrişimli katman CNN, sol el, sağ el, her iki el ve ayak MI EEG sinyallerini sınıflandırmak için tasarlanmıştır. Tasarlanan sınıflandırıcı, on iki sağlıklı kişiden alınan MI sinyalleri kullanılarak değerlendirilmiştir.

Akça ve arkadaşları tarafından bir robotik kolun kontrol edilmesi üzerine yapılan çalışmada MI – EEG sinyallerinin sınıflandırılması için yeni bir yöntem önerilmiştir. EEG sinyalleri, spektrogram görüntülerine dönüştürülmüş, spektrogram yöntemi uygulandıktan sonra elde edilen görüntüler ile derin öğrenme gerçekleştirilmiştir [19].

Bu ve bunlar gibi çalışmalar MI-EEG sinyallerinin zaman–frekans spektrogramı temelli sınıflandırmalarda etkili olduğunu göstermekle beraber diğer sinyallere nazaran MI – EEG sinyalleri üzerinde spektrogram temelli çalışmalar daha azdır. MI-EEG sinyallerinin sınıflandırma yöntemleri ise çalışmamızın bir diğer bacağına oluşturmaktadır. Bu kapsamda çeşitli Yapay Sinir Ağı modelleri ile spektrogramların sınıflandırılmış ve bu yöntemler karşılaştırılmıştır. Çalışmada Konvolüsyonel Sinir Ağı (Convolutional Neural Network–CNN), Özyinelemeli Sinir Ağı (Recurrent Neural Network–RNN), Uzun-Kısa Vadeli Bellek (Long Short-Term Memory–LSTM), EfficientNet ve Görüş Transformatörü (Vision Transformer–ViT) modelleri kullanılarak sınıflandırmalar yapılmış ve karşılaştırılmıştır [20–27].


Bu çalışmada, motor imgeleme sırasında elde edilen MI-EEG sinyalleri, spektral analiz yöntemleri kullanılarak zaman-frekans spektrumlarına dönüştürülmüş ve bu süreçte C3 ve C4 kanallarının spektrogram görüntülerine odaklanılmıştır. Elde edilen bu spektrogramlar, ERD (Olayla İlişkili Desenkronizasyon) ve ERS (Olayla İlişkili Senkronizasyon) olaylarından faydalanılarak analiz edilmiştir. Bu analizler sonucunda, farklı motor imgeleme görevleri, çeşitli sınıflandırma algoritmaları ile başarılı bir şekilde sınıflandırılmıştır. Spektrogramların sağladığı detaylı zaman-frekans çözünürlüğü, imgeleme hareketlerinin beyindeki yansımalarını daha hassas bir şekilde ortaya koymuştur. Bu sayede, sınıflandırma işlemleri sırasında motor korteksin farklı bölgelerindeki aktivite değişimleri net bir şekilde gözlemlenmiş ve analiz edilmiştir.

BÖLÜM II

2. GENEL BİLGİLER

2.1. Biyomedikal Sinyaller

Biyolojik veya tıbbi bir kaynaktan iletilen herhangi bir sinyale biyomedikal sinyaller adı verilir. Sinyal kaynağı; moleküler seviyede, hücre seviyesinde veya organ seviyesinde olabilir. Bu sinyallere klinikte ve araştırma laboratuvarında ölçümler sonucunda ulaşılabilir. Elektriksel aktivite olan elektrokardiyogram; konuşma sinyalleri; beyindeki elektriksel aktivite olarak tanımlanan EEG; beynin belirli çevresel uyarılara verdiği elektriksel tepkiler olarak ifade edilen, işitsel, görsel, somatosensör gibi uyarılmış potansiyeller (EP); beyindeki yerel bölgelerden gelen alan potansiyelleri elektronörogramlar; bireysel nöronlardan veya kalp hücrelerinden gelen aksiyon potansiyeli sinyalleri; kastaki elektriksel aktivite elektromiyogram (EMG) veya gözden alınan elektoretinogram biyomedikal sinyallere örnek olarak verilebilir [28].



Şekil 2.1 Çeşitli Biyomedikal Sinyaller ve Elektrot Pozisyonları [29]

Klinik olarak biyomedikal sinyaller öncelikle tanı ve tedaviyi değerlendirmek amacıyla spesifik biyolojik durumların tespit edilmesi veya tahmin edilmesi için elde edilir. Bazı temel araştırma durumlarında, belirli biyolojik sistemlerin kodunun çözülmesi ve nihai modellenmesi için de kullanılırlar.

Biyomedikal sinyallerin ölçüm yöntemleri de insan vücudundan elde edilen biyolojik verilerin toplanmasını, analiz edilmesini ve yorumlanmasını içeren önemli bir alandır. Bu sinyallerin ölçülmesi, çeşitli cihazlar ve teknikler aracılığıyla gerçekleştirilir [30].

Elektriksel biyomedikal sinyallerin ölçümünde genellikle elektrotlar kullanılır. Örneğin, EKG ölçümlerinde göğüs ve ekstremitelere yerleştirilen elektrotlar, kalbin elektriksel aktivitesini kaydederler. Benzer şekilde, EEG ölçümleri için kafa derisine yerleştirilen elektrotlar, beyin dalgalarını izler. Elektrotlar, biyolojik dokular arasındaki elektriksel potansiyel farklarını algılayarak bu sinyalleri elektriksel bir forma dönüştürür [31].



Şekil 2.2 Örnek Bir EEG Başlığı [32]

Mekanik biyomedikal sinyallerin ölçümü genellikle basınç sensörleri gibi cihazlar ile gerçekleştirilir. Örneğin, kan basıncı ölçümleri yapılırken tansiyon aletleri kullanılır. Bu aletler, arterdeki basıncı algılayan ve bunu dijital bir sinyale dönüştüren sensörlere sahiptir. Solunum hızı ve hacmi gibi parametrelerin ölçümünde ise spirometreler kullanılır ve bu cihazlar, nefes alıp verme sırasında hava akışını ve hacmini ölçerek solunum fonksiyonlarını değerlendirir [33].

Optik biyomedikal sinyallerin ölçümünde ise ışık temelli teknolojiler kullanılır. Örneğin, pulse oksimetreler, parmak ucu veya kulak memesi gibi bölgelere yerleştirilen sensörlere sahiptir. Cihaz, bu sensörler aracılığıyla kan oksijen doygunluğunu ölçer. Bu cihazlar, dokuya gönderilen ışığın Emilimini ve geri yansımalarını analiz ederler ve oksijen seviyelerini belirlerler [34].



Şekil 2.3 Ölçüm Esnasında Oksimetre [35]

Kimyasal biyomedikal sinyallerin ölçümü için de kullanılan biyosensörler mevcuttur. Kan şekeri seviyelerini ölçmek için yaygın olarak kullanılan glikoz metreler buna bir örnektir. Bu cihazlar, kandaki glikoz konsantrasyonunu belirlemek için elektrokimyasal sensörleri kullanırlar. Bu şekilde biyosensörler, belirli bir kimyasal maddenin varlığını

veya konsantrasyonunu algılamış olurlar [36].

2.1.1. Beyin sinyallerinin oluşması

Beyin sinyalleri, nöron adı verilen özel hücreler tarafından oluşturulurlar ve iletilmeleri de yine bu hücreler vasıtasıyla olur. Bu sinyallerin oluşumu ve iletimi elektrokimyasal olaylar sayesinde gerçekleşir [37,38].

2.1.1.1. Nöronların Yapısı ve Fonksiyonu


Nöronlar, beyin ve sinir sisteminin temel yapı taşlarıdır. Bir nöronun başlıca bileşenleri şunlardır:

Hücre gövdesi (Soma): Nöronun çekirdeği ve diğer organelleri içerir.

Dendritler: Diğer nöronlardan gelen sinyalleri alır.

Akson: Sinyalleri diğer nöronlara, kaslara veya bezlere iletir.

Sinaps: Bir nöronun aksonunun diğer bir nöronun dendriti veya hücre gövdesi ile bulunduğu noktadır.



Şekil 2.4 Nöronların Yapısı [39]

2.1.1.2. Elektriksel potansiyel

Nöronlar elektriksel potansiyel farkları kullanarak iletişim kurarlar. Nöronun zarının iki tarafındaki iyon konsantrasyonlarında farklılıklar bulunur ve bu farklılıklar bahsi geçen potansiyel farkların oluşmasına sebebiyet verir. Başlıca iyonlar sodyum (Na^+), potasyum (K^+), kalsiyum (Ca^{2+}) ve klor (Cl^-) iyonlarıdır [40,41].

Dinlenme Potansiyeli: Nöron uyarılmadığı zaman, hücre zarının içi dışına göre negatif yüklüdür. Bu potansiyel fark yaklaşık -70 mV civarındadır.

Aksiyon Potansiyeli: Nöron yeterince uyarıldığında, hücre zarının elektriksel potansiyeli hızlı bir şekilde değişir. Na^+ iyonları hücre içine, K^+ iyonları hücre dışına hareket eder. Bu hareket, zarın potansiyelinin pozitif yönde değişmesine neden olur ve yaklaşık +30 mV'a ulaşır. Aksiyon potansiyeli, elektriksel bir impuls olarak akson boyunca iletilir [38,41].

2.1.1.3. Sinaptik iletim

Aksiyon potansiyeli aksonun sonuna ulaşır. Bu esnada sinaptik veziküller nörotransmitter adı verilen kimyasalları serbest bırakır. Nörotransmitterler, sinaptik boşluk (sinaps) üzerinden diğer nöronun dendritlerine ulaşır ve bu nöronun zarındaki reseptörlere bağlanır. Bu bağlanma ise yeni bir aksiyon potansiyelinin oluşmasını tetikler [42].

2.1.2. Beyin sinyallerinin ölçülmesi

Beyin sinyallerini ölçmek ve elektrik sinyallerine çevirmek için çeşitli teknikler kullanılır.


Elektroensefalografi: EEG, beyin aktivitelerini ölçmek için en yaygın kullanılan yöntemlerden biridir.

Elektrotlar: EEG cihazı, kafa derisine yerleştirilen çok sayıda elektrottan oluşur ve bu elektrotlar, beyin yüzeyindeki elektriksel aktiviteleri algılar.

Potansiyel Farkları: Beyin hücreleri (nöronlar) sinyal gönderdiğinde yukarıda da anlatıldığı gibi elektriksel potansiyel farkları oluşur ve EEG elektrotları, oluşan bu potansiyel farkları ölçer.

Sinyal İşleme: Ölçülen potansiyel farkları, analog sinyaller olarak kaydedilirler ve bu

analog sinyaller, daha sonra dijital sinyallere dönüştürülerek bilgisayar tarafından analiz edilir.



Şekil 2.5 EEG Ölçümü Temsili Gösterimi [43]


Magnetoensefalografi (MEG): MEG, beyin aktivitelerini ölçmek için manyetik alan değişikliklerini kullanır.

Nöronlar elektriksel sinyal gönderdiğinde, küçük manyetik alan değişiklikleri meydana gelir. MEG cihazı, bu manyetik alan değişikliklerini ölçer.

MEG cihazı, genellikle sıvı helyum ile soğutulan çok hassas sensörler kullanır. Bu sensörler, manyetik alan değişikliklerini yüksek hassasiyetle tespit edebilir. Ölçülen manyetik sinyaller, EEG’de olduğu gibi analogdan dijitale dönüştürülür ve bilgisayarlar tarafından analiz edilir.

Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI): fMRI, beyin aktivitelerini ölçmek için kan akışındaki değişiklikleri kullanır.

Beyin hücreleri aktif olduğunda bu hücrelerin ihtiyaç duydukları oksijen miktarında artma meydana gelir. fMRI, MRI teknolojisini kullanır ve kan akışındaki bu değişiklikleri ölçer. fMRI, BOLD olarak adlandırılan, kan oksijen seviyesine bağlı sinyaller kullanır. Ölçülen sinyaller, bilgisayar ortamında işlenir ve beyin aktivitelerinin görselleştirilmesini sağlayan görüntüler oluşturulur [44,45].




Şekil 2.6 MEG Cihazı [46]

Elektrokortikografi (ECoG): ECoG ölçüm yönteminde elektrotlar doğrudan beyin yüzeyine yerleştirilirler ve beyin aktiviteleri bu şekilde ölçülür. Bu yöntem tıbbi uzmanlık gerektirdiği için genellikle cerrahi müdahaleler esnasında kullanılır [47,48].

Elektrotlar, doğrudan beyin yüzeyine yerleştirilir ve böylece daha derin ve hassas ölçümlerin yapılabilmesi sağlanır. Çalışma mantığı EEG ile aynıdır. Bu yöntemde de EEG'de olduğu gibi beyin yüzeyindeki elektriksel potansiyel farklar ölçülür ve ölçülen sinyaller, dijital sinyallere dönüştürülerek analiz edilir.

Optik Yöntemler: Bu yöntemde beyin aktivitelerini ölçmek için ışık kullanılır. Yakın kızılötesi spektroskopisi (NIRS) buna örnek olarak verilebilir.

Yakın kızılötesi ışık dokulardan yansıyarak geri döner. NIRS cihazları, geri dönen ışığı algırlar. Bu noktada oksijen seviyelerindeki değişiklikleri ölçerler.




Şekil 2.7 ECoG'da EEG'den Farklı Olarak Elektrotlar Doğrudan Beyne Yerleştirilir
[49]

2.2. EEG

Elektroensefalografi, beynin elektriksel aktivitesini kaydetmek ve analiz etmek için sıklıkla kullanılan bir yöntemdir. EEG ölçüm süreci elektrotlar aracılığıyla gerçekleştirilir ve beynin farklı bölgelerinde oluşan elektriksel sinyallerin ölçülmesi amaçlanır. Bu elektrotlar beyin dalgalarını kaydetmek üzere kafa derisine yerleştirilir.

Beyindeki sinir hücrelerinin elektrik seviyesi mili volt düzeyindedir ve zamanla değişen dalga biçiminde kaydedilir. EEG'de kaydedilen beyin dalgaları frekanslarına göre delta (0-4 Hz), teta (4-7 Hz), alfa (8-12 Hz), beta (12-18 Hz) ve gama (30 Hz den büyük) olarak tanımlanmıştır [50–52].

EEG, epilepsi gibi nörolojik bozuklukların teşhisinde önemli bir rol oynar. EEG, epileptik nöbetler sırasında beyinde meydana gelen anormal elektriksel aktiviteleri tespit edilmesinden uyku bozukluklarının tespit edilmesine kadar bir çok alanda kullanılır [53,54].



Şekil 2.8 Frekanslarına Göre Beyin Dalgaları [55]


2.2.1. EEG'nin ölçülmesi

Elektrotlar kafa derisine yerleştirilir. Ölçüm esnasında elektrotların deri ile iyi bir temas sağlaması için genellikle iletken bir jel kullanılır. Bu jel vasıtasıyla elektrotlar ve cilt arasındaki elektriksel direnç azaltılır ve sinyalin daha net bir şekilde alınması sağlanır.

Elektrotlar düzgün şekilde yerleştirildikten sonra, beyin yüzeyindeki elektriksel aktiviteler, özellikle de nöronların toplu sinaptik aktivitelerinden kaynaklanan küçük elektriksel potansiyel değişiklikler algılanır. Nöronlar iletişim kurarken, hücre zarları boyunca gerçekleşen iyon hareketleri, küçük elektriksel potansiyel değişiklikler meydana getirir. Elektrotlar, bu potansiyel değişiklikleri algılar ve çok düşük voltajda (mikro volt mertebesinde) elektrik sinyalleri olarak kaydeder.

Bu zayıf elektrik sinyalleri, beyin dalgalarının detaylı ve net bir şekilde incelenebilmesini sağlamak için amplifikatörler tarafından güçlendirilir. Güçlendirilmiş bu analog sinyaller, analiz için kaydedilmeye hazır hale getirilmek üzere, EEG cihazının analog-dijital

çevirici (ADC) birimi tarafından dijital sinyallere dönüştürülür [56].



Şekil 2.9 İletken Jel ve EEG Başlığı [57]

2.2.1.1. Ölçüm aletleri

EEG ölçüm cihazları, beyin elektriksel aktivitelerini kaydetmek ve analiz etmek için kullanılan, beyin dalgalarının doğru ve hassas bir şekilde ölçülmesi için tasarlanmış çeşitli bileşenlerden oluşan tıbbi cihazlardır.

Elektrotlar: EEG cihazının en kritik bileşenlerinden biri olan elektrotlar, beyin yüzeyindeki elektriksel aktiviteleri algılamak üzere kafa derisine yerleştirilir.

Elektrotlar genellikle metal (örneğin altın, gümüş veya gümüş-klorür) diskler şeklindedir ve kafa derisi ile arasındaki iletkenliği arttırmak için iletken bir jel ile kullanılırlar [58].

Elektrotların doğru yerleştirilmesi ve sabitlenmesi için standart 10-20 elektrot sistemi kullanılır [59].

Elektrot kapları ve iletken malzemeler: Elektrotların kafa derisine sabitlenmesi ve doğru konumlandırılması için elektrot kapları veya şapka benzeri aparatlar kullanılır.

Amplifikatörler: Elektrotlar tarafından algılanan elektriksel sinyaller çok zayıftır (mikrovolt mertebesinde). Bu nedenle, sinyallerin amplifikatörler tarafından güçlendirilmesi gerekir. Sinyalin kalitesini artırmak, gürültü seviyesini düşürmek, böylece beyin dalgalarını daha net bir şekilde analiz edilebilir hale getirmek için amplifikatörler kullanılır [56].

Analog-dijital çevirici (ADC): Güçlendirilmiş analog sinyaller, sinyallerin bilgisayar ortamında analiz edilmesini ve saklanması mümkün kılmak üzere ADC aracılığıyla dijital sinyallere dönüştürülür.

Bilgisayar ve yazılım: Gerekli bilgisayar ve yazılım sistemi sayesinde dijital sinyaller işlenir, frekans bileşenleri çıkarılır, artefaktlar ve gürültüler temizlenir, analiz edilir, EEG kayıtları grafiksel olarak sunulabilir, raporlar oluşturulabilir ve görüntülenebilir.

2.2.2. MI-EEG

Motor imgeleme (MI), bireyin belirli bir hareketi fiziksel olarak yapmadan o hareketi yaptığını hayal etmesi, yapıyormuş gibi zihninde canlandırması sürecidir. Örneğin, bir kişi sağ elini hareket ettirmeyi düşünmesi bir imgeleme hareketidir. Bu süreç, motor korteksin aktive olmasına yol açar ve beyin, bu hareket gerçekleşmese bile, bu hareketi yapıyormuş gibi elektriksel aktiviteler üretir [60,61].

MI-EEG ölçüm sürecinde, herhangi bir EEG ölçümünde olduğu gibi elektrotlar kafa derisine yerleştirilir. Elektrotlar yerleştirilirken genellikle motor korteks bölgesini kapsayacak şekilde yerleştirilmesine dikkat edilir. Katılımcıya sağ elini kaldırma, sol elini yumruk yapma veya ayaklarını hareket ettirme gibi belirli motor imgeleme görevleri verilir ve bu hareketleri düşünmesi istenir. Katılımcı bu hareketleri sadece zihninde canlandırır, fiziksel olarak gerçekleştirmez. Motor imgeleme sırasında ortaya çıkan beyin aktiviteleri, EEG elektrotları aracılığıyla kaydedilir. Bu sinyaller, genellikle 0.5 Hz ile 100 Hz frekans aralığındadır ve farklı motor imgeleme görevleri sırasında farklı frekans bantlarında (örneğin alfa, beta ritimleri) gözlemlenir.

Kaydedilen EEG sinyalleri, çeşitli sinyal işleme teknikleri kullanılarak analiz edilir.

Motor imgeleme EEG sinyalleri analiz edildikten sonra, sonuçlar çeşitli uygulamalarda


kullanılır. Örnek olarak; BCI ile kullanıcıların düşünce gücüyle cihazları kontrol edebilmesi, nörorehabilitasyon süreçlerinde felçli hastaların motor becerilerini yeniden kazanması verilebilir.



Şekil 2.10 BCI Uygulaması [62]

2.2.3. EEG kanalları

Elektrotlar, beynin farklı bölgelerinden gelen elektriksel aktivitelerin tutarlı bir şekilde kaydedilmesini sağlayan standart 10-20 sistemi kullanılarak kafa derisi üzerinde belirli noktalara yerleştirilir. Elektrotlar, hareketlerinin önlenmesi ve ölçümlerin kararlılığını artırmak için elastik bantlar veya özel şapkalar kullanılarak kafa derisine sabitlenir.



Şekil 2.11 Aynı Anda Farklı Kanallardan Alınan Sinyaller

Beynin farklı bölgelerinin aktivitelerini eş zamanlı olarak kaydedip analiz ederek beyin işlevlerinin daha kapsamlı bir şekilde anlaşılmasını sağlayan EEG kanalları, beyin yüzeyindeki farklı bölgelerin elektriksel aktivitelerini ayrı ayrı ve hassas bir şekilde ölçülmesini sağlar.

EEG cihazları, genellikle 8, 16, 32, 64 veya daha fazla kanal kapasitesine sahiptir. Kanal sayısının artması, beyin aktivitelerinin daha yüksek çözünürlükle kaydedilmesini sağlar.

Kanallar, iki elektrot arasındaki potansiyel farkını ölçen bipolar veya elektriksel aktiviteden etkilenmeyen bir noktada yer alan bir referans elektrota göre potansiyel farkını ölçen referanslı olarak yapılandırılabilir.

Kanalların frekans tepkisi, beyin dalgalarının geniş bir spektrumda incelenebilmesini sağlamak adına, genellikle 0.5 Hz ile 100 Hz arasında hassas ölçümler yapabilmelidir. Beyin sinyallerinin daha net ve doğru bir şekilde kaydedilmesine olanak tanımaları için kanalların gürültü seviyesi düşük olmalıdır [63].

Sinyal kalitesini arttırmak maksadıyla elektrotların ciltle iyi bir temas kurup kurmadığını kontrol etmek için empedans ölçümleri yapılır [64].

EEG kanalları ayrıca istenmeyen sinyalleri ve gürültüleri ortadan kaldırmak ve EEG elektrotlarının ve kanallarının doğru ve güvenilir bir şekilde beyin aktivitelerini ölçmesini sağlamak için filtreler kullanır.

2.2.3.1. C3 ve C4 kanalları

C3 ve C4 kanalları, beynin sol ve sađ hemisferindeki motor alanlarını temsil eden, motor imgeleme, hareket ve diđer motor işlevlerle ilgili aktiviteleri izlemek ve EEG ölçümlerinde beynin motor korteksi üzerindeki elektriksel aktiviteleri kaydetmek için kullanılan spesifik elektrot pozisyonlarıdır [65].

C3 ve C4 Kanallarının Konumu

C3 ve C4 elektrotları, elektrotların kafa derisi üzerinde tutarlı ve standart bir şekilde yerleştirilmesini sağlayarak beynin farklı bölgelerindeki aktivitelerin karşılaştırılabilir şekilde kaydedilmesini mümkün kılan standart 10-20 yerleştirme sisteminde belirlenen pozisyonlardadır.

C3 kanalı, kafa derisinin orta hattının (vertex, yani Cz elektrodu) solunda, yaklaşık olarak merkezi motor korteksin üzerinde yer alır. Bu bölge, sol hemisferdeki motor aktiviteleri temsil eder ve genellikle sađ vücut hareketleriyle ilişkilidir.


C4 kanalı ise kafa derisinin orta hattının sađında, yaklaşık olarak merkezi motor korteksin üzerinde yer alır. Bu bölge, sađ hemisferdeki motor aktiviteleri temsil eder ve genellikle sol vücut hareketleriyle ilişkilidir.

C3 ve C4 kanallarının fonksiyonları

C3 ve C4 kanalları, motor korteksin uyarılması, hareket imgelemesi veya fiziksel hareket sırasında ortaya çıkan beynin motor fonksiyonları ile ilgili elektriksel aktiviteleri kaydeder.

- **Motor imgeleme:** C3 ve C4 kanalları, bireyin belirli bir hareketi düşündüğü veya hayal ettiği zaman ortaya çıkan beyin aktivitelerini kaydeder. Bu, motor imgeleme EEG çalışmaları için kritik önem taşır [66].
- **Motor aktivite:** Fiziksel hareketler sırasında, C3 ve C4 kanalları motor korteksin aktivitesini kaydeder. Örneğin, sađ elin hareketi sırasında C3 kanalında artan aktivite gözlemlenirken, sol elin hareketi sırasında C4 kanalında artan aktivite gözlemlenir [67].
- **Nörrehabilitasyon:** Felç veya diđer motor bozukluklardan etkilenen hastaların motor becerilerini yeniden kazanmasına yardımcı olmak için C3 ve C4 kanalları

kullanılır. Motor imgeleme ve nörorehabilitasyon tekniklerinde, bu kanallar aracılığıyla beyin aktivitesi izlenir ve hastaların motor korteksini yeniden eğitmeleri sağlanır.



Şekil 2.12 C3 ve C4 Elektrodlarının Konumları [68]

C3 ve C4 kanallarının analizi

C3 ve C4 kanallarından elde edilen EEG sinyalleri, çeşitli sinyal işleme teknikleri kullanılarak analiz edilir. Bu analizler, motor aktivitelerle ilgili spesifik beyin dalgalarının ve ritimlerinin incelenmesini sağlar:

- **ERD/ERS analizi:** Olayla ilişkili desenkronizasyon (ERD) ve olayla ilişkili senkronizasyon (ERS), motor aktivitelerle ilişkili beyin dalgalarının analizinde kullanılır. Motor imgeleme sırasında, belirli frekans bantlarında (genellikle alfa ve beta) ERD veya ERS gözlemlenir [69,70].
- **Zaman-frekans analizi:** EEG sinyallerinin zaman içindeki frekans bileşenlerini incelemek için zaman-frekans analizi yapılır. Bu analiz, motor imgeleme sırasında ortaya çıkan dinamik değişiklikleri yakalar.

- **Ortak uzamsal desenler (CSP):** EEG sinyallerinde farklı motor imgeleme görevlerine karşılık gelen mekânsal desenleri bulmak için kullanılır ve bu desenler daha sonra sınıflandırma işlemlerinde kullanılır.

MI-EEG ile C3-C4 kanalları arasındaki ilişki

C3 ve C4 kanalları, motor imgeleme sırasında motor korteksin aktivitesini kaydeder ve bu sinyaller, beyin-bilgisayar arayüzleri ve nörorehabilitasyon gibi uygulamalarda kullanılır.

Motor imgeleme sırasında, birey sağ veya sol elini hareket ettirdiğini hayal eder ve bu zihinsel süreç, motor kortekste belirgin elektriksel aktivitelere yol açar. C3 kanalı, sol hemisferdeki motor korteksin üzerinde bulunduğu için sağ elin imgelemesi sırasında; C4 kanalı ise sağ hemisferdeki motor korteksin üzerinde bulunduğu için sol elin imgelemesi sırasında daha fazla aktivite gösterir. Bu farklılıklar, EEG sinyallerinde belirgin değişiklikler olarak kaydedilir ve analiz edilir.

MI-EEG sinyalleri üzerinde gerçekleştirilen analizler; motor imgeleme sırasında C3 ve C4 kanallarında gözlemlenen belirgin beyin dalgalarını ve ritim değişikliklerini ortaya çıkarır. Örneğin, motor imgeleme sırasında alfa (8-13 Hz) ve beta (13-30 Hz) frekans bantlarında, motor imgelemenin başlaması ve bitmesiyle ilişkili olan desenkronizasyon (ERD) ve senkronizasyon (ERS) gözlemlenebilir [71,72].

2.2.4. ERD-ERS olayı

Motor hareketler, motor imgeleme, duysal uyarılar veya bilişsel görevler gibi çeşitli süreçleri içeren ERD (Olayla İlişkili Desenkronizasyon) ve ERS (Olayla İlişkili Senkronizasyon), beyin aktivitelerinin belirli bir olay veya görevle ilişkili olarak değişimlerini tanımlayan kavramlardır [72].

2.2.4.1. Olayla ilişkili desenkronizasyon (ERD)

ERD, bir olayın veya görevin başlamasıyla beynin herhangi bir bölgesinde belirli frekans bantlarındaki (genellikle alfa ve beta bantları) beyin dalgalarının gücünde azalma (desenkronizasyon) meydana gelmesi durumudur. Bu durum, nöral aktivitenin artması ve nöronların daha az senkronize çalışmaya başlamasıyla ilişkilidir.

ERD, genellikle motor hareketler, motor imgeleme veya dikkat gerektiren bilişsel görevler sırasında gözlemlenir. Alfa (8-13 Hz) ve beta (13-30 Hz) bantlarında belirgin olur. Örneğin, motor korteks üzerindeki alfa ritimlerinde azalma, motor aktivitenin başladığını gösterir. ERD, nöral aktivitenin arttığı ve beyin kaynaklarının belirli bir görev için harekete geçtiği anlamına gelir.

2.2.4.2. Olayla ilişkili senkronizasyon (ERS)


ERS, bir olayın veya görevin tamamlanmasının ardından herhangi bir beyin bölgesine ait belirli frekans bantlarındaki (genellikle alfa ve beta bantları) beyin dalgalarının gücünde artış (senkronizasyon) meydana gelmesi durumudur. Bu durum, nöral aktivitenin azalması ve nöronların daha senkronize çalışmaya başlamasıyla ilişkilidir.

ERS, genellikle bir motor hareketin veya bilişsel görevin tamamlanmasının ardından gözlemlenir. Alfa ve beta bantlarında daha belirgindir. Örneğin, motor hareketin sona ermesinden sonra motor korteks üzerindeki alfa ritimlerinde artış, motor aktivitenin sona erdiğini gösterir. ERS, nöral aktivitenin azaldığı ve beyin kaynaklarının dinlenme moduna geçtiği, nöronların daha az aktif olduğu ve daha senkronize desenlerde ateşlediği anlamına gelir.

2.2.4.3. ERD ve ERS'nin motor imgeleme EEG ile ilişkisi

C3 ve C4 kanallarında ERD ve ERS süreçleri, motor imgeleme aktivitelerinin izlenmesinde ve analiz edilmesinde kullanılır.

C3 kanalı, sol hemisferdeki motor korteksi temsil eder ve sağ el veya ayak imgelemesi sırasında belirgin ERD gösterir. Bu, frekans bandındaki güç azalması olarak gözlemlenir. Benzer şekilde, C4 kanalı sağ hemisferdeki motor korteksi temsil eder ve sol el veya ayak imgelemesi sırasında belirgin ERD gösterir. ERS olayları ise, bu durumun tam tersi olarak ortaya çıkar ve belirli frekans bantlarında güç artışı olarak görünür [73–76].



Şekil 2.13 C3 ve C4 Kanalları ERD-ERS Olayı [77]

2.3. Sinyal Analizi


Elektroensefalografi sinyallerinin analizi, beyin aktivitelerinin detaylı bir şekilde incelenmesi ve yorumlanması için kullanılan çeşitli teknik ve yöntemleri içerir. EEG sinyallerinin analizi, genellikle ham verilerin ön işlenmesi, özellik çıkarımı ve sınıflandırma aşamalarını içerir.

2.3.1. Sinyal ön işleme

EEG sinyallerinin analizi öncesinde, sinyallerin kalitesini artırmak ve analiz için uygun hale getirmek amacıyla ham veriler çeşitli ön işleme adımlarından geçirilir.

2.3.1.1. Gürültü ve artefaktların temizlenmesi

EEG sinyalleri, göz kırpma, kas hareketleri ve çevresel gürültüler gibi artefaktlardan etkilenebilir. Bu artefaktların temizlenmesi için çeşitli filtreleme teknikleri kullanılır. Yüksek geçiren ve alçak geçiren filtreler, belirli frekans aralıklarındaki gürültüleri temizlemek için kullanılır. Ayrıca, bağımsız bileşen analizi (ICA) gibi gelişmiş yöntemler, artefaktların sinyallerden ayrıştırılmasında etkili olabilir [78].




Şekil 2.14 Filtreleme Sonrası EEG Sinyali [79]

2.3.1.2. Empedans kontrolü

Elektrotların ciltle iyi bir temas kurup kurmadığını kontrol etmek için empedans ölçümleri yapılır [80].

2.3.1.3. Temel hat düzeltmesi

Temel hat düzeltmesi (baseline correction), EEG sinyallerindeki başlangıç seviyesini düzeltmek ve olayla ilişkili potansiyellerin (ERP) daha doğru bir şekilde analiz edilmesini sağlamak için yapılan bir işlemdir. Bu işlem, belirli bir zaman penceresi (genellikle olay öncesi) içinde ölçülen sinyalin ortalamasının çıkarılmasıyla gerçekleştirilir. Bu sayede, olay sırasında meydana gelen gerçek beyin aktiviteleri daha net bir şekilde ortaya çıkar ve sinyaldeki yavaş dalgalanmalar veya sapmalar düzeltilir. Temel hat düzeltmesi, özellikle ERP çalışmalarında ve zamanla değişen sinyallerin analizinde önemlidir [81].





Şekil 2.15 Temel Hat Düzeltmesi Uygulanmış Sinyal Örneği [82]

2.3.2. Spektrogram

Spektrogram, bir sinyalin frekans içeriğinin zaman içinde nasıl değiştiğini, sinyalin frekans bileşenlerinin yoğunluğunu (güç veya genlik) renk veya gri tonlama ile kodlayarak gösteren bir grafik türüdür [83].

Spektrogramın eksenlerinden birisi zamanı temsil eder. Bu eksen, sinyalin zaman içindeki değişimini izlemek için kullanılır. Eksenlerden diğeri ise frekansı temsil eder ve bu eksen, sinyalin farklı frekans bileşenlerini gösterir [84].

Spektrogramdaki renk veya gri tonlamalar, sinyalin belirli bir frekanstaki güç yoğunluğunu gösterir. Genellikle, yüksek yoğunluklar parlak renkler veya koyu tonlar, düşük yoğunluklar ise daha soluk renkler veya açık tonlar ile temsil edilir.



Şekil 2.16 Aynı Sinyale Ait Örnek Dalga Formu ve Spektrogram Görüntüleri [83]

2.3.2.1. Spektrogram oluşturma yöntemleri

Spektrogram hesaplama, sinyalin zaman içindeki frekans bileşenlerini analiz etmek için kullanılan bir dizi matematiksel yöntemi içerir. Spektrogramın hesaplanmasında en yaygın kullanılan yöntem kısa zamanlı Fourier dönüşümü (STFT) olmakla birlikte, çeşitli başka yöntemler de mevcuttur.

Kısa zamanlı fourier dönüşümü

STFT, bir sinyalin zaman içindeki frekans bileşenlerini analiz etmek için kullanılan, sinyali küçük zaman dilimlerine bölen ve her dilimde Fourier dönüşümünü hesaplayan yaygın bir yöntemdir. Bu şekilde, sinyalin zaman-frekans düzlemindeki değişiklikleri görselleştirilir ve analiz edilir. STFT ile spektrogram oluşturma süreci birkaç adımdan oluşur.

İlk adım, sinyalin belirli bir zaman dilimini temsil eden ve genellikle Hamming penceresi gibi pencere fonksiyonları kullanılarak oluşturulan kısa segmentlere ayrılmasıdır. Pencereleme işlemi, sinyalin uç noktalarındaki keskin değişiklikleri yumuşatır ve spektral sızıntıyı azaltır, bu da daha doğru frekans analizi sağlar [85].

Bir sonraki adım, her pencere için sinyalin frekans bileşenlerini belirlemeye yarayan Fourier dönüşümünün hesaplanmasıdır. Her pencere için hesaplanan FFT, hesaplama süresini önemli ölçüde azaltarak büyük veri kümelerinin hızlı ve verimli bir şekilde işlenmesini sağlar ve pencerelenmiş sinyalin frekans bileşenlerini ortaya çıkarır [86].

Fourier dönüşümünden elde edilen kompleks sayılar, genlik veya güç spektrumuna dönüştürülür. Genlik spektrumu, her frekanstaki sinyal gücünü gösterir ve bu işlem, sinyalin belirli bir zaman dilimindeki frekans bileşenlerinin yoğunluğunu ve enerjisini ortaya koyar. Genlik spektrumu, genellikle logaritmik ölçeklerde ifade edilir ve frekans ekseninde gösterilir.

Son adım, her pencerenin frekans bileşenlerinin zaman-frekans düzlemine yerleştirilmesidir. Zaman eksenini, pencerelerin başlangıç noktalarına karşılık gelirken, frekans eksenini her penceredeki frekans bileşenlerini temsil eder. Yüksek yoğunluklar parlak renkler veya koyu tonlarla, düşük yoğunluklar ise daha soluk renkler veya açık tonlarla gösterilir.

Dalgacık dönüşümü (wavelet transform)

Dalgacık Dönüşümü (Wavelet Transform) ile spektrogram oluşturma sürecinde sinyal ölçeklendirilmiş ve kaydırılmış dalgacık fonksiyonlarıyla temsil edilir ve zaman içinde frekans bileşenlerinin değişimini analiz edilir [87].

Dalgacık dönüşümünde analiz edilecek sinyalin özelliklerine uygun olarak uygun bir dalgacık fonksiyonunun seçilmesidir. Bahsi geçen bu fonksiyonlar sinyalin farklı özelliklerini vurgulamak için çeşitli ölçeklerde ve zaman kaymalarında uygulanır. Yaygın olarak kullanılan dalgacık fonksiyonları arasında Morlet, Haar ve Daubechies dalgacıkları bulunur [88].

Bir sonraki adım, dalgacık fonksiyonunun sinyal üzerinde farklı ölçeklerde ve zaman kaymalarında uygulanmasıdır. Ölçekleme, dalgacığın genişletilip daraltılması anlamına

gelir ve bu işlem, farklı frekans bileşenlerini analiz etmeye yararken kaydırma işlemi dalgacığın sinyal boyunca zaman ekseninde hareket ettirilmesi anlamına gelir ve bu sayede sinyalin zaman içindeki değişimleri incelenir [89].

Her ölçek ve kaydırma için sinyalin dalgacık dönüşümü hesaplanır. Bu işlem, sinyalin dalgacık fonksiyonuna olan projeksiyonlarını verir ve bu projeksiyonlar, sinyalin zaman-frekans düzlemindeki enerji yoğunluğunu temsil eden dalgacık katsayıları olarak adlandırılır [87].

Son adım, elde edilen dalgacık katsayılarının zaman-frekans düzleminde görselleştirilmesidir. Zaman eksenini, dalgacık fonksiyonunun kaydırmalarını temsil ederken, frekans eksenini ise dalgacık fonksiyonunun ölçeklemelerini gösterir. Dalgacık katsayıları, yoğunluklarına göre renk veya gri tonlama ile kodlanarak görselleştirilir [87].

Wigner-ville dağılımı (wigner-ville distribution, WVD)

Wigner-Ville Dağılımı ile spektrogram oluşturma'nın ilk adımı sinyalin farklı zamanlarındaki kendi kendine korelasyonunu ifade eden ve faz bilgisini içeren oto-kovaryans fonksiyonunu hesaplamaktır. Matematiksel olarak, bir $x(t)$ sinyali için oto-kovaryans fonksiyonu $R_x(t, \tau)$ şu şekilde tanımlanır [90]:

$$R_x(t, \tau) = x(t + \tau/2) \cdot x^*(t - \tau/2) \quad (2.1)$$

burada τ , zaman gecikmesi ve x^* ise sinyalin kompleks eşlenik değeridir.

Bir sonraki adım, oto-kovaryans fonksiyonunun Fourier dönüşümünün alınmasıdır. Bu adım, sinyalin frekans bileşenlerinin zaman-frekans düzleminde temsil edilmesini sağlar. Fourier dönüşümü, oto-kovaryans fonksiyonunun zaman gecikmesi değişkenine (τ) uygulanarak gerçekleştirilir:

$$W_x(t, f) = \int_{-\infty}^{\infty} R_x(t, \tau) \cdot e^{-j2\pi f\tau} d\tau \quad (2.2)$$

Bu işlem, oto-kovaryans fonksiyonunun her bir zaman anındaki frekans bileşenlerini ortaya çıkarır ve sinyalin zaman-frekans düzleminde enerji yoğunluğunu temsil eder. Fourier dönüşümünden elde edilen sonuçlar, zaman-frekans düzleminde görselleştirilir. Zaman eksenini, sinyalin farklı zaman anlarını, frekans eksenini ise sinyalin frekans

bileşenlerini temsil eder. Wigner-Ville Dağılımı, sinyalin enerjisinin zaman ve frekans bileşenleri arasındaki dağılımını renk veya gri tonlama ile kodlayarak gösterir [91–93].

Choi-williams dağılımı (choi-williams distribution, CWD)

Choi-Williams Dağılımı, Wigner-Ville Dağılımı'ndaki çapraz terimlerin etkisini azaltmak için geliştirilmiştir. CWD, zaman-frekans düzleminde sinyal enerjisini temsil ederken yüksek çözünürlük sağlar ve çapraz terimlerin etkisini minimize eder. Choi-Williams Dağılımı ile spektrogram oluşturma süreci birkaç adımda gerçekleşir [94].

İlk adım, sinyalin oto-kovaryans fonksiyonunun hesaplanmasıdır. Bir sonraki adım, oto-kovaryans fonksiyonuna, çapraz terimlerin etkisini azaltmak için çekirdek fonksiyonu (kernel) uygulanmasıdır. Bu çekirdek fonksiyonu $\Phi(\theta, \tau)$ şu şekilde tanımlanır [94]:

$$\Phi(\theta, \tau) = e^{-\frac{(\theta\tau)^2}{\sigma}} \quad (2.3)$$

burada θ frekans değişkeni ve σ çekirdek parametresidir. Bu çekirdek fonksiyonu, oto-kovaryans fonksiyonuna ağırlık vererek çapraz terimlerin etkisini azaltır.

Çekirdek fonksiyonu ile ağırlıklandırılmış oto-kovaryans fonksiyonunun Fourier dönüşümü alınır. Bu işlem, oto-kovaryans fonksiyonunun her bir zaman anındaki frekans bileşenlerini ortaya çıkarır ve sinyalin zaman-frekans düzleminde enerji yoğunluğunu temsil eder [94].

Son olarak, elde edilen zaman-frekans dağılımı görselleştirilir. Zaman eksenini, sinyalin farklı zaman anlarını, frekans eksenini ise sinyalin frekans bileşenlerini temsil eder. Choi-Williams Dağılımı, sinyalin enerjisinin zaman ve frekans bileşenleri arasındaki dağılımını renk veya gri tonlama ile kodlayarak gösterir.

Ampirik mode ayrıştırma (empirical mode decomposition, EMD)

Empirik Mode Ayrıştırma, sinyalleri iç içe mod fonksiyonlarına (Intrinsic Mode Functions, IMFs) ayrıştırarak zaman-frekans analizi yapmaya olanak tanıyan bir yöntemdir. EMD, sinyalin farklı zaman ölçeklerinde ayrışmasını sağlar ve her bir IMF, sinyalin belirli bir frekans bileşenini temsil eder. EMD ile spektrogram oluşturma süreci birkaç adımdan oluşur.

İlk adım, sinyalin tekrarlayan sarmalama (sifting) işlemi ile IMFs'e ayrıştırılmasıdır. Bu işlem, sinyaldeki yerel maksimum ve minimum noktaların belirlenmesi ve bu noktalardan interpolasyon yapılarak bir üst zarf ve alt zarf oluşturulmasıyla başlar. Üst ve alt zarfların ortalaması alınarak sinyalin ortalama eğrisi elde edilir. Bu ortalama eğri, sinyalden çıkarılır ve kalan sinyal, IMF adayını oluşturur. Bu süreç, elde edilen IMF adayının belirli durma kriterlerine uyması sağlanana kadar tekrarlanır. İlk IMF elde edildikten sonra, bu IMF sinyalden çıkarılır ve kalan sinyal üzerinde aynı işlem tekrar edilir. Bu adımlar, tüm IMF'ler elde edilene kadar devam eder [95].

Her bir IMF elde edildikten sonra, sinyalin kompleks zarfını oluşturan ve anlık frekansın belirlenmesine yardımcı olan Hilbert dönüşümü uygulanarak sinyalin anlık frekans ve genlik bilgileri hesaplanır. Matematiksel olarak, Hilbert dönüşümü şu şekilde ifade edilir [96]:

$$H(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{s(\tau)}{t-\tau} d\tau \quad (2.4)$$

burada $s(t)$ sinyalin gerçek kısmı, $H(t)$ ise Hilbert dönüşümü ile elde edilen analitik sinyalin sanal kısmıdır.

Elde edilen anlık frekans ve genlik bilgileri, zaman-frekans düzleminde görselleştirilir. Her bir IMF'nin anlık frekans bileşenleri zaman ekseninde, genlik bileşenleri ise renk veya gri tonlama ile kodlanarak gösterilir.

S-Transformu

S-Transformu, her bir frekans bileşeni için farklı ölçeklerde, sinyalin belirli bir zaman dilimini temsil eden ve pencerenin genişliği frekansa bağlı olarak değişen Gauss pencereleri kullanarak sinyalin zaman-frekans analizini gerçekleştirir. Sinyalin zaman-frekans çözünürlüğünü optimize etmek adına yüksek frekanslar için dar, düşük frekanslar için geniş pencereler kullanılır [97].

Bir sonraki adım, pencerelenmiş sinyalin Fourier dönüşümünün hesaplanmasıdır. Bu işlem, pencerelenmiş sinyalin frekans bileşenlerini belirler ve genellikle hızlı Fourier dönüşümü (FFT) algoritması ile gerçekleştirilir. Fourier dönüşümü, sinyalin her bir

zaman anındaki frekans bileşenlerini ortaya çıkarır. S-Transformu, sinyalin t anındaki ve f frekansındaki bileşenini şu şekilde hesaplar [97]:

$$S(t,f) = \int_{-\infty}^{\infty} x(\tau) \cdot |f| \cdot e^{-\pi f^2(t-\tau)^2} e^{-2\pi f\tau} d\tau \quad (2.5)$$

burada $x(\tau)$ sinyal, $e^{-\pi f^2(t-\tau)^2}$ Gauss penceresi, t zaman ve f frekanstır.

Fourier dönüşümünden elde edilen sonuçlar, zaman-frekans düzleminde görselleştirilir.

2.4. Görüntü İşleme ve Analizi

Görüntü işleme, dijital görüntülerin iyileştirilmesi, dönüştürülmesi ve değiştirilmesi işlemlerini içeren bir süreçtir. Bu süreç, görüntü verilerinin bilgisayarlar tarafından işlenmesini ve çeşitli görsel efektler, iyileştirmeler veya analizler için kullanılmasını sağlar.

Görüntü işleme ve analizi, tıbbi görüntüleme, uydu görüntüleme, sanayi ve üretim, güvenlik ve gözetim, eğlence ve multimedya gibi geniş bir uygulama yelpazesine sahiptir.

2.4.1. Görüntü işleme süreci

Görüntü işlemede çeşitli teknikler ve süreçler kullanılır. Bunlardan en sık kullanılanlarına değinecek olursak;

Gürültü azaltma işleminde, filtreleme teknikleri kullanılarak rastgele parazitlerin ve gürültülerin giderilmesi hedeflenir. Kontrast artırma sürecinde görüntülerin daha net ve belirgin hale getirilmesi için histogram eşitleme veya kontrast ayarı gibi teknikler kullanılır. Normalizasyon sürecinde piksel değerlerinin belirli bir aralığa getirilmesiyle görüntü işlemenin tutarlılığı artırılır. Dönüşüm işlemlerinde geometrik dönüşümler, ölçekleme, döndürme ve kaydırma gibi işlemler uygulanırken renk dönüşümleri ise Red, Green, Blue (RGB) renk modelinden grayscale'e dönüşüm gibi farklı renk uzaylarına dönüşüm işlemlerini içerir [98–101].

2.4.2. Görüntü analizi süreci

Görüntü analizi sürecinde de görüntü işlemede olduğu gibi farklı teknikler ve süreçler kullanılır.

Görüntü analizi sürecinde, görüntüdeki belirli desenler, şekiller ve doku özelliklerinin çıkarımıyla başlayan işlem, kenar tespiti ve doku analizi gibi adımlarla devam eder. Segmentasyon sürecinde, görüntüyü anlamlı bölgelere ayırarak, eşikleme ve bölge büyütme gibi teknikler uygulanır. Sınıflandırma adımında, destek vektör makineleri ve konvolüsyonel sinir ağları kullanılarak nesneler kategorilere ayrılır. Nesne tanıma aşamasında ise şablon eşleme gibi tekniklerle görüntüdeki belirli nesneler tespit edilip etiketlenir [102].

2.4.3. Görsel çıkarma işlemi

İki görselin birbirinden çıkarılması işlemi, bir görüntüdeki değişiklikleri veya farklılıkları tespit etmek için kullanılan bir görüntü işleme tekniğidir. Bu işlem, genellikle görüntüdeki hareketleri, nesne değişikliklerini veya zaman içindeki farklılıkları analiz etmek için kullanılır.

Görüntü çıkarma işleminin ilk adımı, görüntülerin hazırlanmasıdır. Bu aşamada, görüntüler aynı boyutta değilse, ilk olarak iki görüntüyü aynı boyuta getirmek gereklidir. Ardından, bazı çalışmalarda gerekli olan renkli görüntüleri, gri tonlamalı (grayscale) hale getirme işlemi uygulanır. Böylece renk bilgisi olmadan sadece yoğunluk değerleri üzerinden işlem yapılarak daha basit ve etkili bir sonuç elde edilmesi sağlanabilir [103].

Görüntülerin hazırlanmasından sonra, görüntülerin çıkarılması aşamasına geçilir. Bu aşamada, iki görüntünün her bir pikseli için fark hesaplanır. Bu fark, bir görüntüdeki piksel değerinden diğer görüntüdeki piksel değerinin çıkarılmasıyla elde edilir. Matematiksel olarak, fark görüntüsü şu şekilde hesaplanır:

$$\text{Fark Görüntüsü } (x, y) = |I_1(x, y) - I_2(x, y)| \quad (2.6)$$

burada $I_1(x,y)$ ve $I_2(x,y)$ sırasıyla birinci ve ikinci görüntüdeki (x, y) koordinatlarındaki piksel değerleridir. Mutlak değer alınarak negatif farkların pozitif olarak değerlendirilmesi sağlanır.

Hesaplanan fark değerleri, yeni bir görüntü olarak saklanır. Bu sonuç görüntüsü, iki orijinal görüntü arasındaki farklılıkları temsil eder. Yüksek fark değerleri, büyük

değişiklikleri veya farklılıkları gösterir, düşük fark değerleri ise küçük değişiklikleri veya farklılıkları gösterir.



Şekil 2.17 Görüntü Çıkarma Tekniği ile Nesne Takibi [104]

Görüntü çıkarma işleminin uygulama alanları oldukça geniştir. Hareket tespiti, güvenlik kameraları ve gözetim sistemlerinde sahnedeki hareketleri veya değişiklikleri tespit etmek için görüntü çıkarma kullanılır.

2.4.4. Gama düzeltmesi

Gamma düzeltme (gamma correction), dijital görüntülerin parlaklık ve kontrastını ayarlamak için kullanılan bir yöntemdir. İnsan gözü, karanlık bölgelerdeki değişikliklere daha duyarlıdır, bu nedenle görüntülerin görsel olarak daha doğal ve doğru görünmesi için gamma düzeltme kullanılır [105].

Gamma düzeltme, bir görüntüdeki piksel değerlerini belirli bir gamma değeri (γ) kullanarak dönüştürme işlemidir. Bu dönüşüm, görüntünün parlaklık ve kontrastını kontrol etmeye yardımcı olur. Gamma düzeltme, görüntünün daha açık veya daha koyu görünmesini sağlamak için uygulanabilir [106].

Matematiksel olarak, gamma düzeltme şu şekilde ifade edilir:

$$I_{\text{çıkış}} = I_{\text{giriş}}^{\gamma} \quad (2.7)$$

Burada:

$I_{çıkış}$, gamma düzeltmesi uygulanmış piksel değerini temsil eder.

$I_{giriş}$, orijinal piksel değerini temsil eder (0 ile 1 arasında normalize edilmiş).

γ , gamma değeri olarak adlandırılan bir sabittir.

Gamma değeri γ 1'den büyükse, görüntü daha koyu hale gelir. γ 1'den küçükse, görüntü daha açık hale gelir.



Şekil 2.18 Gama Düzeltmesi Uygulanmış Görsel [107]

Gamma düzeltme işlemi, genellikle aşağıdaki adımlarla gerçekleştirilir:

İlk adım olarak, görüntüdeki piksel değerleri 0 ile 1 arasında normalize edilir. Bu, her pikselin yoğunluk değerinin $[0, 1]$ aralığına getirilmesi anlamına gelir. Normalize edilmiş piksel değerlerine gamma düzeltme fonksiyonu ($I_{çıkış} = I_{giriş}^{\gamma}$) uygulanır. Bu işlem, her pikselin yeni parlaklık değerini hesaplar. Gamma düzeltme uygulandıktan sonra, görüntüdeki piksel değerleri tekrar orijinal aralığına (genellikle 0-255 aralığı) ölçeklenir.

2.5. Sınıflandırma

Sınıflandırma, bir veri kümesindeki örneklerin belirli kategorilere veya sınıflara ayrılması sürecidir. Bu süreç, genellikle makine öğrenmesi ve istatistiksel yöntemler kullanılarak gerçekleştirilir ve çok sayıda uygulama alanında, özellikle görüntü işleme, metin madenciliği, konuşma tanıma ve biyomedikal sinyal işleme gibi alanlarda yaygın olarak

kullanılır.

2.5.1. Sınıflandırmanın temel adımları

Sınıflandırma sürecinin ilk adımı, analiz edilecek verilerin toplanmasıdır. Bu veriler, çeşitli kaynaklardan (örneğin, görüntüler, metinler, ses kayıtları) elde edilebilir. Toplanan bu veriler genellikle ham halde bulunduğu ve doğrudan sınıflandırma algoritmalarına uygulanamadığı için veri temizleme, gürültü giderme, normalizasyon ve özellik çıkarımı gibi ön işleme adımları gerçekleştirilir. Veri ön işlemenin ardından verilerin sınıflandırma algoritmaları tarafından işlenebilir bir biçime dönüştürülmesi ve verilerden anlamlı bilgilerin (özelliklerin) çıkarılması süreci olan özellik çıkarma uygulanır. Sonraki adım olarak sınıflandırma algoritmaları arasında bulunan karar ağaçları, destek vektör makineleri, yapay sinir ağları (Artificial Neural Networks, ANN) ve k-en yakın komşu (k-NN) gibi modellerden uygun olanın seçimi yapılır [108].

Model seçildikten sonra seçilen model, etiketlenmiş eğitim verileri kullanılarak eğitilir. Model, verilerdeki örüntüleri öğrenir ve her bir sınıfın karakteristik özelliklerini tanımayı öğrenir. Model eğitildikten sonra eğitilen modelin performansı, doğruluk, kesinlik, hatırlama (recall) ve F1 skoru gibi metrikler kullanılarak modelin ne kadar iyi genelleme yapabildiği ve yeni verileri ne kadar doğru sınıflandırabildiği ölçüldüğü değerlendirme aşamasına geçilir. Eğitim ve değerlendirme adımlarından sonra ise model test verileri üzerinde test edilir. Test verileri, modelin daha önce görmediği yeni verilerden oluşur. Bu adım, modelin gerçek dünya performansını değerlendirmek için kritik öneme sahiptir. Başarılı bir şekilde eğitilmiş ve test edilmiş model, gerçek dünya uygulamalarında kullanılmak üzere uygulanır. Model, yeni gelen verileri sınıflandırmak için kullanılabilir [108].

2.5.2. Sınıflandırma algoritmaları

Yaygın olarak kullanılan sınıflandırma metotlarından birkaçı aşağıda verilmiştir [109]:

Karar ağaçları: Karar ağaçları, veri örneklerini çeşitli özelliklerine göre dallara ayırarak sınıflandıran ağaç yapısındaki modellerdir. Her dal, belirli bir özelliğe dayalı bir karar kuralını temsil eder ve her yaprak düğüm, bir sınıf etiketini temsil eder.

Destek vektör makineleri: SVM, iki sınıfı en iyi ayıran hiper düzlemi bulmaya çalışan güçlü bir sınıflandırma algoritmasıdır. SVM, sınıfları ayıran en geniş marjı bulmayı hedefler ve özellikle yüksek boyutlu verilerde etkili sonuçlar verir.

Yapay sinir ağları (ANN): Yapay sinir ağları, insan beyninin işleyişine benzer şekilde çalışan ve veri örnekleri arasındaki karmaşık ilişkileri öğrenebilen çok katmanlı yapılar içerir.

Derin öğrenme olarak bilinen daha karmaşık versiyonları, çok katmanlı derin sinir ağları kullanarak büyük veri kümeleri üzerinde yüksek doğruluklu sınıflandırma yapabilir.

2.5.3. Yapay sinir ağları (ANN)

Yapay sinir ağları, insan beyninin çalışma prensiplerinden esinlenerek geliştirilmiş makine öğrenmesi modelleridir. Bu modeller, öğrenme ve karar verme süreçlerini taklit ederek, veri örnekleri arasındaki karmaşık ilişkileri öğrenebilir ve genelleme yapabilirler. Yapay sinir ağları, çok sayıda bağlı "nöron" veya "düğüm" içeren katmanlardan oluşur. Bu katmanlar, verilerden özellikleri çıkarır ve sınıflandırma, regresyon veya diğer görevler için kullanılır.

2.5.3.1. Yapay sinir ağlarının temel yapısı

Yapay sinir ağları, genellikle üç ana katmandan oluşur: giriş katmanı, gizli katmanlar (hidden layers) ve çıkış katmanı [110].

Giriş katmanı (input layer): Bu katman, ağın dış dünya ile etkileşime girdiği kısımdır. Giriş katmanındaki nöronlar, verinin özelliklerini temsil eder ve her bir nöron bir özellik ile ilişkilidir.

Gizli katmanlar (hidden layers): Her biri diğer katmanlarla bağlı çok sayıda nöron içeren gizli katmanlar, giriş ve çıkış katmanları arasında yer alır ve verilerin işlenmesi ve öğrenilmesi sürecinde önemli bir rol oynar. Bu katmanlar, verilerdeki karmaşık ilişkileri ve desenleri öğrenir. Gizli katman sayısı ve her katmandaki nöron sayısı, ağın mimarisine bağlıdır.

Çıkış katmanı (output layer): Çıkış katmanı, ağın sonuçlarını veya tahminlerini üreten kısımdır. Çıkış katmanındaki nöronlar, sınıflandırma problemlerinde sınıf etiketlerini

veya regresyon problemlerinde sürekli deęerleri temsil eder.

2.5.3.2. Nöronlar ve aktivasyon fonksiyonları

Her nöron, kendisine gelen girdileri alır, bu girdileri ağırlıklandırır ve bir aktivasyon fonksiyonu aracılığıyla bir çıkış üretir. Ağırlıklar, öğrenme sürecinde ayarlanarak ağın performansını optimize eder. Nöronların çıkışlarını hesaplamak için yaygın olarak kullanılan aktivasyon fonksiyonları şunlardır [111]:

Sigmoid fonksiyonu: Grafięi karakteristik S şeklinde veya sigmoid eğriye sahip olan bir matematiksel fonksiyondur. Çıkış deęeri 0 ile 1 arasındadır. Özellikle, iki sınıflı sınıflandırma problemlerinde kullanılır.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.8)$$

Tanh (hiperbolik tanjant) fonksiyonu: Çıkış deęeri -1 ile 1 arasında olan bir aktivasyon fonksiyonudur.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.9)$$

ReLU (rectified linear unit) fonksiyonu: Giriş deęeri negatifse 0, pozitifse kendisi olan bir fonksiyondur. Derin ağılarda yaygın olarak kullanılır çünkü gradyan azalma sorununu hafifletir.

$$\text{ReLU}(x) = \max(0, x) = \begin{cases} x & \text{if } x \geq 0 \\ 0 & \text{if } x < 0 \end{cases} \quad (2.10)$$

2.5.3.3. İleri yayılım (forward propagation)

İleri yayılım, ağın giriş verilerini alarak çıkış üretmesi sürecidir. Bu süreçte, giriş katmanından başlayarak her katmandaki nöronlar, kendilerine gelen girdileri ağırlıklandırır, aktivasyon fonksiyonunu uygular ve sonraki katmana iletir. Bu işlem, çıkış katmanına kadar devam eder ve nihai tahmin üretilir.

2.5.3.4. Geri yayılım (backward propagation) ve öğrenme

Geri yayılım, ağıın tahminlerini optimize etmek için kullanılan bir öğrenme algoritmasıdır. Bu süreçte, ağıın ürettiğı tahmin ile gerçek değer arasındaki hata hesaplanır ve bu hata, ağırlıkları güncellemek için geriye doğru yayılır. Geri yayılım algoritması, gradyan inişi (gradient descent) gibi optimizasyon tekniklerini kullanarak ağırlıkları ayarlar.

Bir kısmı makalemizde de kullanılan birkaç yapay sinir ağı modeli ve çalışma prensipleri aşağıda verilmiştir.

2.5.3.5. CNN

Konvolüsyonel Sinir Ağları, özellikle görüntü ve video işleme görevlerinde yaygın olarak kullanılan derin öğrenme mimarileridir. CNN'ler, geleneksel yapay sinir ağlarına kıyasla daha iyi performans gösterir çünkü yerel özellikleri ve uzamsal hiyerarşileri yakalama yeteneğine sahiptirler. CNN'ler, konvolüsyon katmanları, havuzlama katmanları (pooling layers) ve tamamen bağlantılı katmanlar (fully connected layers) gibi bileşenlerden oluşur [112].

CNN'in çalışma prensibi

- **Giriş Katmanı:** Giriş katmanı, genellikle bir görüntüyü temsil eden piksel değerlerinden oluşur. Örneğin, 28x28 piksel boyutunda bir gri tonlamalı görüntü, 784 nöronlu bir giriş katmanı olarak temsil edilir.
- **Konvolüsyon ve havuzlama katmanları:** Giriş katmanındaki görüntü, bir veya daha fazla konvolüsyon ve havuzlama katmanından geçirilir. Bu katmanlar, görüntüdeki önemli özellikleri çıkarır ve öznitelik haritaları oluşturur. Örneğin, ilk konvolüsyon katmanı, kenarları ve basit şekilleri tespit edebilirken, sonraki katmanlar daha karmaşık özellikleri çıkarabilir.
- **Tamamen bağlantılı katmanlar:** Konvolüsyon ve havuzlama katmanlarından elde edilen öznitelik haritaları, tamamen bağlantılı katmanlara iletilir. Bu katmanlar, öznitelik haritalarını düzleştirir ve sınıflandırma veya regresyon görevleri için kullanır.
- **Çıkış katmanı:** Çıkış katmanı, sınıflandırma problemlerinde sınıf etiketlerini,

regresyon problemlerinde ise sürekli deęerleri üretir. Örneęin, bir görüntü sınıflandırma probleminde, çıkış katmanı birden fazla sınıf için olasılık deęerleri verebilir.

CNN'in eęitimi

CNN'lerin eęitimi, ileri yayılım (forward propagation) ve geri yayılım (backward propagation) adımlarını içerir. İleri yayılım sırasında, giriş verileri aę boyunca ileri doğru iletilir ve tahminler üretilir. Geri yayılım sırasında ise, tahminler ile gerçek deęerler arasındaki hata hesaplanır ve bu hata, aęın aęırlıklarını güncellemek için geriye doğru yayılır. Bu süreç, aęın performansını optimize etmek için birçok kez tekrarlanır.

2.5.3.6. RNN

Rekürrent Sinir Aęları (Recurrent Neural Networks, RNN), özellikle sıralı verilerin (zaman serileri, metin, konuşma, video gibi) işlenmesi ve analizi için tasarlanmış bir yapay sinir aęı mimarisidir. RNN'lerin en belirgin özellięi, döngüsel (rekürrent) bağlantıları sayesinde geçmiş bilgilere dayalı olarak karar verebilme yeteneęidir. Bu özellik, RNN'leri zaman baęımlılıęı olan verilerde oldukça etkili hale getirir [113].

RNN'in temel yapısı

RNN'lerin temel yapısı, standart sinir aęlarından farklı olarak, her adımda önceki adımın çıktısını dikkate alır. Bu, RNN'lerin önceki zaman adımlarındaki bilgileri depolamasını ve bu bilgileri mevcut adımda kullanmasını sağlar. Bir RNN, tekrarlanan bir katman yapısına sahiptir.

RNN'in çalışma prensibi

RNN'ler, zaman adımlarındaki verileri sırasıyla işler ve her adımda önceki adımın bilgisini kullanarak güncel durumu belirler. Bu süreç, dizisel verilerdeki baęımlılıklarını ve ilişkileri modellemek için oldukça etkilidir. RNN'in çalışma prensibi şu adımlardan oluşur:

İlk zaman adımı için gizli durum genellikle sıfır veya rastgele bir başlangıç deęeri ile başlar. Her zaman adımında, giriş verisi ve önceki gizli durum kullanılarak yeni gizli

durum hesaplanır. Bu süreç, tüm zaman adımları boyunca tekrarlanır. Her zaman adımında, gizli durumdan çıktı üretilir. Çıktı, sınıflandırma veya regresyon gibi görevler için kullanılabilir.

2.5.3.7. LSTM

Uzun Kısa Süreli Bellek ağları, Rekürrent Sinir Ağları ailesinin bir üyesidir ve özellikle uzun süreli bağımlılıkları öğrenmekte zorlanan klasik RNN'lerin bu sorununu çözmek için tasarlanmıştır. LSTM'ler, zaman serisi verilerindeki uzun süreli bağımlılıkları daha etkili bir şekilde öğrenebilir ve modelleyebilir [114].

LSTM'nin çalışma mekanizması

LSTM hücresinin çalışma mekaniği aşağıdaki adımlarla açıklanabilir [114]:

- **Unutma kapısı (forget gate):** Bu kapı, hücre durumundan hangi bilgilerin atılacağını belirler. Unutma kapısı, önceki gizli durum (h_{t-1}) ve mevcut giriş (x_t) kullanılarak ve sigmoid fonksiyonu uygulanarak hesaplanır.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.11)$$

burada σ sigmoid fonksiyonudur, W_f ve b_f ise sırasıyla ağırlık matrisi ve bias terimidir.

- **Giriş kapısı (input gate):** Bu kapı, yeni bilgilerin hücre durumuna ne kadar ekleneceğini belirler. Giriş kapısı, önceki gizli durum ve mevcut giriş kullanılarak sigmoid fonksiyonu ile hesaplanır.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.12)$$

- **Hücre durumu güncellemesi:** Yeni hücre durumu, unutma kapısının ve giriş kapısının çıktılarının birleşimi ile hesaplanır. Önce hücre durumu adayları ($\check{C}_t$) tanh aktivasyon fonksiyonu kullanılarak hesaplanır.

$$\check{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2.13)$$

Ardından, hücre durumu güncellenir:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \check{C}_t \quad (2.14)$$

- **Çıkış kapısı (output gate):** Bu kapı, hücre durumundan hangi bilgilerin çıkışa gönderileceğini belirler. Çıkış kapısı, önceki gizli durum ve mevcut giriş kullanılarak sigmoid fonksiyonu ile hesaplanır.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.15)$$

- **Gizli durumun güncellenmesi:** Güncellenmiş hücre durumu, çıkış kapısı ile çarpılarak yeni gizli durumu oluşturur.

$$h_t = o_t \cdot \tanh(C_t) \quad (2.16)$$

2.5.3.8. GoogLeNet

Bu model, derin öğrenme mimarisinde hem derinlik hem de genişlik açısından yenilikçi bir yaklaşım sunar. GoogLeNet modelinin temel amacı, hesaplama verimliliğini artırırken aynı zamanda modelin performansını da yükseltmektir. Bunu, farklı boyutlardaki filtrelerin ve havuzlama katmanlarının bir arada kullanıldığı GoogLeNet modülleri aracılığıyla gerçekleştirir [115].

GoogLeNet modelinin mimarisi

GoogLeNet modelinin mimarisi, bir dizi GoogLeNet modülünden ve geleneksel sinir ağı katmanlarından oluşur. İlk versiyon olan Inception v1, toplam 22 katmandan oluşur ve yaklaşık 5 milyon parametre içerir. Bu, diğer derin öğrenme modellerine kıyasla daha hafif ve hesaplama açısından verimli bir yapıdır.

- **Giriş katmanı:** İlk katman, genellikle bir veya daha fazla konvolüsyon ve havuzlama katmanından oluşur ve giriş verisini (örneğin, bir görüntüyü) başlangıçta işleyerek daha küçük boyutlara ve daha yüksek seviyede özelliklere dönüştürür.
- **GoogLeNet modülleri:** Bu modüller, farklı boyutlardaki konvolüsyon filtrelerini ve havuzlama işlemlerini paralel olarak uygular. Her GoogLeNet modülü, girdiyi çeşitli yollardan işleyerek zengin bir özellik haritası üretir ve bu özellik haritaları birleştirilir.

- **Tam bağlantılı katmanlar (fully connected layers):** Inception modüllerinden sonra gelen katmanlar, genellikle tam bağlantılı katmanlardır. Bu katmanlar, modelin nihai çıktısını (örneğin, sınıf etiketlerini) üretir.
- **Çıkış katmanı:** Çıkış katmanı, genellikle sınıflandırma problemlerinde softmax aktivasyon fonksiyonunu kullanır ve her sınıf için olasılık değerleri üretir.

2.5.3.9. Görüş transformatörü (ViT)

Görüş Transformatörü (ViT), görüntü işleme görevlerinde kullanılan ve klasik konvolüsyonel sinir ağlarına alternatif olarak tasarlanmış bir derin öğrenme modelidir. ViT, Transformer mimarisini kullanarak görüntü sınıflandırma görevlerinde yüksek performans sergiler. Transformer'lar, başlangıçta doğal dil işleme (NLP) görevlerinde kullanılmak üzere geliştirilmiş olsa da ViT ile birlikte görüntü işleme alanında da etkili bir şekilde uygulanmıştır [116].

Görüş transformatörü mimarisi

ViT'nin temel yapısı, Transformer mimarisinin özelliklerini kullanarak görüntüleri analiz eder. ViT'nin çalışma prensibi, görüntüleri küçük parçalara (patch) bölerek her bir parçayı bir diziye dönüştürmek ve ardından bu diziyi Transformer katmanlarına beslemektir [117].

- **Görüntülerin parçalara bölünmesi:** Giriş görüntüsü, belirli bir boyutta küçük parçalara (patch) bölünür. Örneğin, 16x16 boyutunda parçalara ayrılabilir. Bu parçalar, görüntünün küçük alt bölgeleridir ve her biri bir vektör olarak temsil edilir. Bu parçaların her biri, düzleştirilerek (flatten) bir dizi vektör haline getirilir. Örneğin, 16x16 boyutundaki bir parça, 256 boyutlu bir vektör olarak temsil edilir.
- **Lineer projeksiyon:** Düzleştirilmiş parçalar, bir lineer projeksiyon katmanından geçirilir ve belirli bir boyutta (örneğin, 768 boyutunda) bir diziye dönüştürülür. Bu işlem, her parçanın özelliklerini daha yüksek bir boyutlu alanda temsil eder.
- **Pozisyon kodlaması (position embedding):** Transformer'lar sıralı verilerde pozisyon bilgisini korumak için pozisyon kodlaması kullanır. Görüntü parçalarının sıralı yapısını

korumak için her bir parçaya pozisyon kodlaması eklenir. Bu, modelin parçaların sırasını anlamasına yardımcı olur.

- **Transformer katmanları:** Görüntü parçaları, klasik Transformer mimarisindeki çoklu başlıklı dikkat (multi-head attention) ve besleme ileri ağı (feed-forward network) katmanlarından geçirilir. Bu katmanlar, her parçanın diğer parçalarla olan ilişkisini öğrenir ve önemli özellikleri çıkarır.

- **Sınıflandırma kafası (classification head):** Transformer katmanlarından geçen ve dikkat mekanizmasıyla işlenen çıktılar, bir sınıflandırma kafasına beslenir. Bu katman, genellikle bir tam bağlantılı (fully connected) katmandan oluşur ve softmax aktivasyon fonksiyonu kullanılarak sınıf olasılıklarını tahmin eder.

2.6. Değerlendirme

Sınıflandırma modellerinin değerlendirilmesi, modelin performansını ölçmek ve sonuçlarını anlamak için kritik bir adımdır. Değerlendirme süreci, modelin ne kadar iyi çalıştığını belirlemek ve iyileştirme gereken alanları tespit etmek için çeşitli metriklerin ve tekniklerin kullanılmasını içerir. İşte sınıflandırma modellerinin değerlendirilmesinde yaygın olarak kullanılan yöntemler ve metrikler [118]:

2.6.1. Eğitim ve test ayrımı

Değerlendirme sürecinin ilk adımı, veri kümesini eğitim ve test setlerine ayırmaktır. Eğitim seti, modelin öğrenmesi için kullanılırken, test seti modelin performansını bağımsız olarak değerlendirmek için kullanılır. Ayrıca, modelin daha güvenilir bir şekilde değerlendirilmesi için çapraz doğrulama (cross-validation) gibi yöntemler de kullanılabilir.

2.6.2. Konfüzyon matrisi

Konfüzyon matrisi, sınıflandırma modellerinin performansını değerlendirmek için temel bir araçtır. Gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi gösterir. İkili sınıflandırma için konfüzyon matrisi şu dört öğeyi içerir:

Doğru pozitifler (DP): Doğru şekilde pozitif olarak sınıflandırılan örnekler.

Doğru negatifler (DN): Doğru şekilde negatif olarak sınıflandırılan örnekler.

Yanlış pozitifler (YP): Yanlış şekilde pozitif olarak sınıflandırılan örnekler.

Yanlış negatifler (YN): Yanlış şekilde negatif olarak sınıflandırılan örnekler.

DP	YP
YP	DN

Şekil 2.19 Confussion Matrix Gösterimi

2.6.3. Değerlendirme metrikleri

Konfüzyon matrisine dayalı olarak, çeşitli metrikler hesaplanabilir [118]:

- **Doğruluk (accuracy):** Tüm doğru tahminlerin toplamının, toplam örnek sayısına oranıdır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.17)$$

- **Hassasiyet (precision):** Pozitif olarak tahmin edilenlerin ne kadarının gerçekten pozitif olduğunu gösterir.

$$\text{Hassasiyet} = \frac{TP}{TP+FP} \quad (2.18)$$

- **Duyarlılık (recall):** Gerçek pozitiflerin ne kadarının doğru şekilde tespit edildiğini gösterir.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (2.19)$$

- **F1 skoru:** Hassasiyet ve duyarlılığın harmonik ortalamasıdır. Dengeli bir değerlendirme sunar.

$$\text{F1 Skoru} = 2 \cdot \frac{\text{Duyarlılık} \cdot \text{Hassasiyet}}{\text{Duyarlılık} + \text{Hassasiyet}} \quad (2.20)$$

- **Özgüllük (specificity):** Negatif örneklerin ne kadarının doğru şekilde tespit edildiğini gösterir.

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (2.21)$$

2.6.4. Alıcı çalışma karakteristik eğrisi (ROC) ve ROC eğrisi altındaki alan (AUC)

ROC eğrisi: Doğru pozitif oranı (TPR) ve yanlış pozitif oranı (FPR) arasındaki ilişkiyi gösterir. Modelin tüm olası eşik değerleri için performansını değerlendirmeye olanak tanır [118].

AUC: ROC eğrisi altındaki alanı ölçer. AUC, modelin sınıflandırma yeteneğini özetleyen tek bir değerdir. AUC değeri 0.5'e yakınsa model rastgele tahmin yapıyor demektir; 1'e yaklaştıkça modelin performansı iyileşir [118].

2.6.5. Kappa istatistiği

Kappa istatistiği, sınıflandırıcı ile rastgele şansa dayalı sınıflandırma arasındaki anlaşma seviyesini ölçer. Kappa, 0 ile 1 arasında bir değer alır; 0 rastgele şans anlamına gelirken, 1 mükemmel sınıflandırma anlamına gelir [119].

2.6.6. Log-kayıp (log loss)

Log-kayıp, sınıflandırma problemlerinde modelin doğruluk oranını ölçen bir metriktir. Modelin verdiği olasılık tahminlerinin kalitesini değerlendirir. Düşük log-kayıp değeri, daha iyi model performansını gösterir.

2.6.7. Çapraz doğrulama (cross-validation)

Çapraz doğrulama, veri kümesini birkaç alt kümeye ayırarak modelin performansını daha güvenilir bir şekilde değerlendirmeyi sağlar. En yaygın kullanılan yöntemlerden biri k-katlı çapraz doğrulamadır (k-fold cross-validation). Bu yöntem, veri kümesini k alt kümeye ayırır ve her alt küme bir kez test seti olarak kullanılırken diğer k-1 alt küme eğitim için kullanılır. Bu işlem k kez tekrarlanır ve ortalama performans metriği hesaplanır [120].

BÖLÜM III

3. MATERYAL VE YÖNTEM


MI-EEG sinyallerinin zaman-frekans spektrogramı temelli sınıflandırma yöntemleri incelenirken aşağıdaki aşamalar üzerinden ilerlenmiştir

- MI-EEG sinyallerinin toplanması,
- Veri ön işleme adımlarının uygulanması,
- C3 ve C4 kanallarının zaman-frekans spektrogramlarının elde edilmesi,
- Oluşturulan spektrogramlara görüntü çıkarma (image subtraction) uygulanarak belirgin özelliklerin ön plana çıkarılması,
- Seçilen sınıflandırma yöntemlerinin teorik temellerinin ve uygulanabilirliklerinin araştırılması.
- Seçilen sınıflandırma metodu ile elde edilmiş olan spektrogramların sınıflandırılması,
- Performans sonuçlarının istatistiksel analizi.

3.1. MI-EEG Sinyallerinin Toplanması


Çalışmanın amacına uygun olarak, motor imgeleme sürecini gerçekleştirebilecek sağlıklı bireyler seçilmiştir. Çalışmada, katılımcılardan 1'i kadın olmak üzere toplam 8 kişi üzerinden veriler toplanmıştır. Katılımcılardan 2'si sol, 6'sı sağ elini daha sık kullanmaktadır. Katılımcıların 2'si 20-25 yaş aralığından, 3'ü 30-35 yaş aralığından, diğer 3'ü ise 40-45 yaş aralığından seçilmiştir. Veriler toplanırken her bir katılımcı üzerinde bir oturum yapılmıştır. Her oturum, aralarında 10 dakika dinlenme süresi verilerek ayrılan 4 bölümden, her bir bölüm ise 10 tekrardan oluşmaktadır.

Çalışmanın akış şeması Şekil 3.1'de gösterilmektedir. Bu görsel, MI-EEG sinyallerinin toplanmasından başlayarak, sınıflandırmaya kadar olan tüm süreci özetlemektedir.



Şekil 3.1 Çalışmanın Genel Süreci


Testlerin içeriği ise sırasıyla sağ el, sol el, sağ ayak ve sol ayak imgelemelerinden meydana gelmektedir. Bir oturuma ait çalışma ve test ilişkisini gösteren şematik Şekil 3.2’de verilmiştir.



Şekil 3.2 Oturum Yapısı

Testler esnasında, her katılımcıdan sırasıyla sağ el, sol el, sağ ayak ve sol ayak hareketlerini zihinsel olarak canlandırmaları istenmiştir. Bu işlem sırasında, mümkün olduğunca basit bir yöntem uygulanmış ve beynin imgeleme dışında herhangi bir fonksiyonunu aktif hale getirecek unsurlardan kaçınılmıştır.

Testler esnasında katılımcılara komut vermek üzere PsychoPy yazılım paketi kullanılarak bilgisayar destekli deney yönetimi uygulaması oluşturulmuştur [121]. Bu uygulama ile her bir test aşamasında katılımcılara belirli komutların verilmesi sağlanmıştır. Uygulama, testlerin başlangıcında katılımcılara hangi hareketi zihinsel olarak canlandıracaklarını bildiren görsel ve sesli komutlardan oluşturulmuştur. Her test arasında belirli bir dinlenme süresi verilmiştir. Bu şekilde, katılımcıların zihinsel yorgunluğunu en aza indirmek ve her test için tutarlı veriler elde etmek amaçlanmıştır.



Şekil 3.3 PsychoPy Programından Çalışmaya Ait Uygulamamızın Görüntüsü

Şekil 3.3'te yer alan PsychoPy programında süreç sırasıyla; “hoş geldiniz, sağ bekle, sağ, sol bekle, sol, sağ ayak bekle, sağ ayak, sol ayak bekle, sol ayak ve son” aşamalarından oluşmaktadır. Bu aşamalardan hoş geldiniz ve son bölümlerinde kullanıcıya sadece görsel olarak hoş geldiniz ve end yazıları gösterilmektedir ve bu bölümler görüldüğü üzere döngü içerisinde olmayıp sadece bir kez çalıştırılmaktadır.


Sağ bekle, sol bekle, sağ ayak bekle ve sol ayak bekle aşamaları ise Şekil 3.3'te de görüldüğü gibi 5 saniye boyunca bir görsel sergilenmesi ile başlamaktadır. Bu 5 saniyenin son 1 saniyesinde uyarı sesi verilmesi ve veri kayıt bilgisayarına sinyal gönderilmesi ile devam etmektedir. Bu aşamalarda sergilenen görsel bir artı işareti olup kullanıcının odaklanma sürecinde olduğunu ifade eder. Son saniyede kullanıcıya verilen uyarı sesi ise odaklanma sürecinin bittiğini ve imgeleme sürecinin başlamakta olduğunu kullanıcıya bildirir. Yine son saniyede veri kayıt bilgisayarına gönderilen sinyal ise yapılacak olan imgeleme hareketine göre belirlenen bir sinyal olmakla beraber sinyal işleme sırasında kullanıcının hangi imgeleme hareketini yaptığını ve buna ne zaman başladığını belirlemek için kullanılır. Tablo 3.1'de hangi imgeleme hareketinin hangi sinyal etiketine karşılık geldiği gösterilmektedir.

Tablo 3.1 İmgeleme Hareketi ve Kontrol Sinyali Eşleştirmesi

İmgeleme Hareketi	Gönderilen Sinyalin Etiketi
Sağ El İmgeleme	S1
Sol El İmgeleme	S2
Sağ Ayak İmgeleme	S3
Sol Ayak İmgeleme	S4


Böylece veri analizi sırasında gördüğümüz etiket ile hangi imgeleme hareketinin ne zaman başladığı bilinmiş olacaktır.

PsychoPy programındaki sağ, sol, sağ ayak ve sol ayak aşamalarının süreçleri ise Şekil 3.4'te verilmiştir. Şekilden de görüleceği gibi aşamalarda kullanıcıya bir görsel ve bir metin gösterilmektedir.



Şekil 3.4 Sağ, Sol, Sağ Ayak ve Sol Ayak Aşamalarının PsychoPy Süreci

Görselde kullanıcıya hangi imgeleme hareketini yapacağı resim ile gösterilmektedir. Şekil 3.5'te her bir aşamada katılımcılara hangi imgeleme hareketini yapacağını gösteren resimler yer almaktadır.




Şekil 3.5 Uygulamada Katılımcılara Verilen Komutlar

Aşamaların sonunda yer alan metinde ise 'rest' komutu yer almakta ve katılımcıya dinleme sürecine girdiği belirtilmektedir.

Döngü içerisinde yer alan aşamaların her biri sırasıyla gerçekleşmekte bu süreç tam 10 kez tekrarlanmaktadır. Katılımcı dinlendikten sonra bu 10'lu set 3 kez daha yapılmakta ve sonuçta 40 tekrar meydana gelmektedir. Böylece her bir katılımcıdan her bir imgeleme hareketi için 40 kayıt alınmaktadır.

Özetle; uygulama, katılımcıların odaklanmalarının istendiği aşama ile başlamaktadır. Bu aşamada, ekranda katılımcılara 5 saniye boyunca bir artı işareti sergilenmektedir. Artı işaretini kullanıcıya hazır olmasını bildiren bir uyarı sesi kesmekte ve ardından ekranda sağ ok, sol ok ile ayak ve el kombinasyonlarından oluşan bir simge gösterilerek katılımcıdan belirtilen imgelemeyi yapması beklenmektedir. Bu komuttan sonra, katılımcı 4 saniye boyunca verilen imgeleme hareketini gerçekleştirmektedir. İmgeleme sürecinin ardından, ekranda "dinlen" komutu gösterilmekte ve bir sonraki imgeleme için dinlenme ve odaklanma sürecine girilmektedir. Bu döngü, bir test için tüm kombinasyonlarda tekrar edilmektedir. Testin tüm aşamaları Şekil 3.6'te gösterilmektedir.



Şekil 3.6 Veri Alma Sürecinin Şematiği

Şekil 3.7'te, bir katılımcı MI-EEG test süreci esnasında gösterilmektedir. Tüm test boyunca katılımcılardan komutları veren monitörü takip etmeleri ve mümkün olduğunca odaklanmaları istenmiştir. Ayrıca, test süreci boyunca beyin aktivitelerine sebep olabilecek tüm fiziksel hareketlerden sakınmaları da katılımcılara hatırlatılmıştır.



Şekil 3.7 Test ve Veri Kayıt Süreci

Testlerin uzun sürmesi neticesinde odaklanmanın kaybolduğu testler esnasında tespit edilmiştir. Bu sebeple testler 4 çalışma aşamasına bölünmüş ve katılımcıların dinlenmeleri sağlanarak veri toplama süreci son haline getirilmiştir.

Şekil 3.7’de, sağdaki bilgisayarda katılımcılara komutlar verilirken, soldaki bilgisayar ise beyin aktivitelerinin kaydedilmesi ve izlenmesi amacıyla kullanılmıştır. Böylece hem test süreci hem de veri kayıt ve izleme süreci eşzamanlı olarak yürütülmüştür.


3.2. EEG Veri Toplama Cihazının Kullanımı

MI-EEG sinyallerini kaydetmek için, elektrotlar vasıtasıyla beyinden elektriksel aktiviteleri ölçen EEG cihazı kullanılmıştır. Bu cihaz; elektrotlar, amplifikatör, kablolar ve veri kayıt ile analiz yazılımlarından oluşmaktadır. Bu çalışmada Brain Products firmasının LiveAmp EEG ölçüm cihazı kullanılmıştır.

Sensör, sinyallerin alınmasını sağlayan elektrotlardan oluşmaktadır. Bu elektrotlar vasıtasıyla veriler toplanır ve EEG başlığı, veri toplama cihazına, uyumlu adaptörler aracılığıyla bağlanır. Veriler buradan da bluetooth veya usb kablo vasıtasıyla bilgisayara

aktarılır.

Şekil 3.8’da EEG veri toplama cihazının bağlantı şeması gösterilmektedir.



Şekil 3.8 EEG Başlığı Bağlantı Şeması


3.3. Kanalların Seçilmesi

Motor korteksin üzerindeki konumlarından dolayı motor imgeleme sinyallerinde C3 ve C4 kanalları seçilmiştir.

Motor korteks, vücudun hareketlerini kontrol eden beyin bölgesidir. Bu bölgedeki nöronal aktiviteler motor imgeleme sırasında belirgin bir şekilde değişiklik gösterir.

C3 ve C4 elektrotları, sırasıyla sol ve sağ hemisferlerdeki motor korteksin el ve ayak hareketlerinden sorumlu bölgelerine yakın konumlanmıştır.

Şekil 3.9’da, beynin farklı bölgelerine yerleştirilen elektrotları ve 10-20 sistemine göre yerleşimlerini gösteren bir şema bulunmaktadır. Bu şemada, C3 ve C4 elektrotlarının motor korteks üzerindeki konumları net bir şekilde görülmektedir. C3 elektrodu sol hemisferde, C4 elektrodu ise sağ hemisferde yer alır ve her iki elektrot da motor imgeleme çalışmaları için ideal konumdadır.



Şekil 3.9 Elektrotların 10-20 Sistemine Göre Pozisyonları ve C3–C4 Elektrodlarının Konumları

3.4. Ham Veri

Veriler; EEG sinyal verileri, VHDR dosyası ve VMRK dosyası olacak şekilde üç dosya halinde kaydedilmektedir. EEG sinyal verileri dosyası adından da anlaşılacağı gibi EEG sinyallerinin tutulduğu dosya iken VHDR dosyası EEG kaydının başlık dosyasıdır ve EEG verisinin nasıl yapılandırıldığını tanımlar. VMRK dosyası ise EEG kaydında yer alan olay işaretleyicilerini içerir.

Bu dosyaların içeriğine erişmek için MATLAB üzerinde çalışan bir açık kaynaklı yazılım paketi olan EEGLAB uygulamasını kullanılmış, EEGLAB üzerinden VHDR dosyası açılarak verilere ulaşılmıştır.

EEGLAB, EEG verilerinin analiz ve görselleştirilmesi için kullanılır. EEGLAB, özellikle beyin dalgaları verileriyle çalışırken yaygın olarak kullanılır ve zaman-frekans analizleri, bağımsız bileşen analizi (ICA), olayla ilişkili potansiyeller (ERP), spektral analizler gibi işlemler yapmaya olanak tanır [122].

EEGLAB yazılımı kullanılarak her bir katılımcının dosyaları teker teker yüklenmiş ve analiz edilmiştir. Dosyalara MATLAB ortamında erişildiğinde şu değişkenleri barındığı görülmüştür: ALLCOM, ALLEEG, CURRENTSET, CURRENTSTUDY, EEG, LASTCOM, PLUGINLIST, STUDY, globalvars ve tmpEEG. ALLEEG yapısı, farklı deney koşullarına veya deneklere ait tüm EEG veri setlerini içermekte olup, bu veri setleri arasında toplu işlemler yapmayı mümkün kılmaktadır. EEG değişkeni, sinyallerin ham verilerini, kanal bilgilerini, olay işaretleyicilerini ve bağımsız bileşen analizi (ICA) sonuçlarını içeren, analiz edilen en son veri setini temsil ederken, CURRENTSET değişkeni aktif olan veri setinin izini sürmektedir. Ayrıca, CURRENTSTUDY ve STUDY yapıları, birden fazla veri seti üzerinde toplu analizlerin yönetimini sağlamakta, PLUGINLIST ise EEGLAB içinde kullanılan ek bileşenlerin listesini içermektedir.

Özellikle üzerinde çalışacağımız EEG değişkeninin, EEG sinyallerinin yanı sıra bu sinyallere ait çeşitli meta verileri içermektedir. Veriler, bir matriks formatında depolanmıştır ve bu matriksin boyutları, kanallar (elektrotlar) ve zaman noktaları ile belirlenir. Bu matriks, zaman içinde ölçülen beyin aktivitesini temsil eder ve her bir hücre, belirli bir zamanda, belirli bir kanal üzerinden ölçülen EEG sinyal değerini içerir. Buna ek olarak, times vektörü, bu zaman noktalarına karşılık gelen milisaniye cinsinden zaman değerlerini içermektedir.

Bağımsız bileşen analizi (ICA) ile ilgili bilgiler, icaact, icawinv, icasphere ve icaweights gibi değişkenlerde saklanmıştır. Bu alanlar, EEG sinyallerinden artefaktların (örneğin, göz hareketleri) ayrıştırılması için kullanılan ICA modelinin sonuçlarını içerir.

Olay işaretleyicileri, event yapısında saklanır ve bu işaretleyiciler, deney sırasında belirli olayların (örneğin, uyarıcıların verilmesi) zamanlarını belirtir. Bu olaylar, EEG verileri ile senkronize bir şekilde analiz edilerek olayla ilişkili potansiyellerin (ERP) incelenmesine olanak tanır.

Ayrıca, chanlocs yapısı, EEG sinyallerinin kaydedildiği elektrotların kafa üzerindeki konumlarını belirtir, bu da topografik analizlerin yapılmasına imkân tanır.

Şekil 3.10'da EEG sinyal dosyasının içeriği ve EEG değişkeninin içeriği görülmektedir. EEG verileri EEG.data değişkeni içerisinde yer almaktadır.

Field	Value	Name	Value
session	[]	ALLCOM	1x3 cell
comments	'Original file: kayıt_1.ee...	ALLEEG	1x1 struct
nbchan	19	CURRENTSET	1
trials	1	CURRENTSTUDY	0
pnts	1822040	EEG	1x1 struct
srate	1000	globalvars	8x1 cell
xmin	0	LASTCOM	'[ALLEEG EEG CU...
xmax	1.8220e+03	PLUGINLIST	1x6 struct
times	1x1822040 double	STUDY	[]
data	19x1822040 single	tmpEEG	1x1 struct
icaact	[]		
icawinv	[]		
icasphere	[]		
icaweights	[]		
icachansind	[]		
chanlocs	1x19 struct		
urchanlocs	[]		
chaninfo	1x1 struct		
ref	'common'		

Şekil 3.10 EEG Değişkeninin İçeriği

Şekil 3.11’de EEG.Type değişkeninin içeriği yer almaktadır. Görselde type sütununa dikkat ettiğimizde imgeleme hareketlerinin etiketlerinin yer aldığı görülmektedir. Böylece kaydın kaçınıcı saniyesinde hangi imgeleme hareketinin yapıldığı bilgisine ulaşılabilmektedir.

Fields	latency	duration	channel	bvtime	bvmknum	visible	type	code	urevent
1	1	NaN	0	987914872	1		'boundary'	'New Segm...	1
2	17020	1	0		2		'S 1'	'Stimulus'	2
3	28018	1	0		3		'S 2'	'Stimulus'	3
4	39022	1	0		4		'S 3'	'Stimulus'	4
5	50020	1	0		5		'S 4'	'Stimulus'	5
6	61030	1	0		6		'S 1'	'Stimulus'	6
7	72023	1	0		7		'S 2'	'Stimulus'	7
8	83017	1	0		8		'S 3'	'Stimulus'	8
9	94034	1	0		9		'S 4'	'Stimulus'	9
10	105019	1	0		10		'S 1'	'Stimulus'	10
11	116023	1	0		11		'S 2'	'Stimulus'	11
12	127022	1	0		12		'S 3'	'Stimulus'	12
13	138026	1	0		13		'S 4'	'Stimulus'	13
14	149023	1	0		14		'S 1'	'Stimulus'	14
15	160019	1	0		15		'S 2'	'Stimulus'	15

Şekil 3.11 EEG.Event Değişkeninin İçeriği

3.5. Segmentasyon

Segmentasyon işlemi, belirli kanallardan alınan EEG verilerinin, olayların gerçekleştiği zamandan itibaren tanımlanan bir zaman aralığı içinde çıkarılmasını içerir. EEG verilerine segmentasyon uygulanarak, belirli olay türleri ile ilişkili beyin aktivitesinin analiz edilmesi sağlanacaktır.


İlk olarak, her bir olay türü için segmentasyon işlemi gerçekleştirilmiştir. Olay türleri ('S 1', 'S 2', 'S 3', 'S 4') EEG verilerindeki EEG.event.type alanında saklanmaktadır. Bu olay türlerine göre veri noktalarının indeksleri belirlenmiş ve her bir olay türü için segmentasyon işlemi yapılmıştır.

Her bir segmentin içerdiği veri noktasının sayısı 8000 olarak belirlenmiştir. Yani olay başladıktan sonraki 8 saniye alınmıştır ki bu süre odaklanma ve imgeleme süreçlerinin kapsayacak şekilde özellikler seçilmiştir.

Her bir olay tipi için, ilgili olayların zaman noktaları (latency) alınmış ve bu zaman noktalarına dayalı olarak EEG verisi segmentlere ayrılmıştır.

Örneğin, 'S 1' olay tipine ait veriler bulunmuş ve bu olayların gerçekleştiği zamandan önce ve sonra belirli bir süre boyunca EEG verisi çıkarılmıştır. Aynı işlem, 'S 2', 'S 3', ve 'S 4' olay tipleri için de uygulanmıştır.

Bu işlemler sonucunda, sağ el, sol el, sağ ayak ve sol ayak hareketlerine karşılık gelen olaylar için C3 ve C4 kanallarından alınan EEG verileri, belirli bir zaman aralığında segmentlere ayrılmış ve analiz için hazır hale getirilmiştir.



The screenshot shows a data viewer window titled 'sampledDataLeftFootA'. Below the title bar, it indicates '2x40 cell'. The data is presented in a table with 10 columns and 2 rows. The columns are numbered 1 through 10. The first row contains 10 truncated text strings, each starting with '1x8000 sin...'. The second row contains 10 truncated text strings, each starting with '1x8000 sin...'. The table is part of a larger application window, with a close button visible in the top right corner of the title bar.

1	2	3	4	5	6	7	8	9	10
1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...
1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...	1x8000 sin...

Şekil 3.12 Segmentasyon İşlemi Sonunda Bir Katılımcıya Ait Sol Ayak Verileri

Segmentasyon işlemi sonucunda her katılımcı için 4 adet 2x40 boyutunda bir cell değişkeni oluşur. Bu cell hücrelerinden her biri bir imgeleme hareketine ait verileri içerir. Şekil 3.12’de bir katılımcıya ait sol ayak verileri yer almaktadır. Değişkendeki birinci satır C3 kanalına ait verileri içermekte iken ikinci satır C4 kanalına ait verileri içermektedir. Sütunlar ise katılımcıya ait 40 ayak imgeleme hareketini ifade etmektedir. Her bir hücre içerisindeki 8000 örnek ise sinyalin imgeleme hareketinin bulunduğu bölümün 8 saniyelik kısmının alındığını göstermektedir. Burada amaç imgeleme hareketinden önceki 4 saniyelik bölüm ile imgeleme hareketinin bulunduğu 4 saniyelik bölümün alınmasıdır.

Segmentasyon işlemi tüm katılımcılara uygulandığında ise 8 katılımcının her birine ait 4'er tane (her biri bir imgeleme hareketini temsil eden) 2x40 cell değişkeni oluşmuştur.

3.6. Ön İşleme Adımları


Toplanan MI-EEG verileri, analize uygun hale getirilmesi için ön işleme adımlarından geçirilmiştir.

Ön işleme adımlarından ilki tüm sinyallerde kaçınılmaz olan gürültü gidermedir. Çalışmada el ve ayak imgeleme sinyallerinin en çok görüldüğü frekans aralığı olan 8–30 Hz. arasında bant geçiren filtre uygulanmıştır [123].

Kullandığımız bant geçiren filtrenin sistem transfer fonksiyonu denklemi şu şekildedir:

$$H(s) = \frac{s}{s^2 + \frac{\omega_0}{Q}s + \omega_0^2} \quad (3.1)$$

Burada s , Laplace değişkenini temsil ederken; ω_0 sistemin merkez frekansını belirler; Q ise kalite faktörüdür ve band genişliği ile ilişkilidir. Bu transfer fonksiyonu, belirli bir rezonans frekansında ve belirli bir band genişliğinde sinyalleri geçirir ve diğer frekanslardaki sinyalleri bastırır.




Şekil 3.13 Bir Katılımcıya Ait İmgeleme EEG Sinyalinin Bant Geçiren Filtre Öncesi ve Sonrası

Şekil 3.13’de bir katılımcıya ait sol ayak imgeleme EEG sinyalinin bant geçiren filtreye girmeden önce ve bant geçiren filtreden sonraki dalga formu görüntüleri gösterilmektedir.

Gürültü giderme işleminden sonra, EEG sinyallerine temel hat düzeltmesi uygulanmıştır. Bu işlem, sinyallerde zamanla ortaya çıkan trendlerin ortadan kaldırılarak, sinyalin doğru bir şekilde analiz edilmesini sağlamak amacıyla gerçekleştirilmiştir. Her bir motor aktiviteyle ilişkili sinyallerin (sol el, sağ el, sol ayak ve sağ ayak) farklı frekans bantlarında elde edilen veri setlerine bu düzeltme işlemi uygulanmıştır.

Bu aşamada, her bir veri seti için, sinyaldeki düşük frekanslı trendler (örneğin, yavaş dalgalanmalar) hesaplanarak sinyalden çıkarılmıştır. Her bir segment için veri hücreleri üzerinde gerçekleştirilen bu işlem, sinyallerin smooth (düzgünleştirme) fonksiyonu kullanılarak 30 veri noktasında yumuşatılmış bir trendin çıkarılması ile yapılmıştır. Bu trend çıkarıldıktan sonra, elde edilen baseline corrected sinyal, daha doğru ve güvenilir sonuçlar elde etmek için analiz edilmeye hazır hale getirilmiştir.



Şekil 3.14 Temel Hat Düzeltmesi Uygulanmış Sinyal

Şekil 3.13’te ilk görsel temel hat düzeltmesi uygulanmamış bir sinyali ikinci görsel ise

aynı sinyalin temel hat düzeltmesi uygulanmış halini göstermektedir. Y eksenine bakıldığında ikinci görselde genlik değerlerinin düştüğü görülmektedir. Aslında bu durum genlik değerlerinin düşmesinden ziyade hatta bozulma olmasından kaynaklanmaktadır. Temel hat düzeltmesi uygulandığında tüm sinyalin düzeltildiği görülmektedir.

3.7. Spektrogramların Oluşturulması

C3 ve C4 kanallarından elde edilen sinyaller spektrogramlara dönüştürülmüştür. Bu işlem ile, sinyallerin zaman-frekans düzleminde görselleştirilmesi sağlanarak, belirli frekans bantlarındaki güç değişimlerinin zaman içinde gözlemlenmesi sağlanmıştır.

Spektrogram dönüşümü için dalgacık dönüşümü (wavelet transform) yöntemi kullanılmıştır. Dalgacık dönüşümü olarak morlet dalgacığı seçilmiştir. Morlet dalgacığı, EEG sinyalleri gibi geniş frekans aralığına sahip ve zamanla değişkenlik gösteren sinyallerin analizi için yaygın olarak tercih edilir. [124]. Bu dalgacık hem zaman hem de frekans çözünürlüğünü optimize eder, bu da EEG sinyallerinin karmaşık yapısını zaman-frekans domeninde detaylı olarak incelemeyi mümkün kılar. Morlet Dalgacığı şu şekilde tanımlanır:

$$\Psi(t) = \frac{1}{\sqrt{\sigma\sqrt{\pi}}} e^{iw_0t} e^{-\frac{t^2}{2\sigma^2}} \quad (3.2)$$

Burada $\Psi(t)$ Morlet dalgacığı, w_0 merkezi frekans ve σ ise zaman çözünürlüğünü ifade eden parametrelerdir.

Dalgacık dönüşümü ile spektrogramlar elde edilirken, Olaya Bağlı Güç Bozulması (Event Related Spektral Perturbation- ERSP) yöntemi uygulanarak ilerlenmiştir. ERSP, belirli bir olayla ilişkili frekans bantlarındaki güç değişimlerini ölçer ve motor imgeleme sırasında ortaya çıkan beyin aktivitelerinin daha net bir şekilde tanımlanmasına yardımcı olur [125]. ERSP'nin matematiksel ifadesi şu şekildedir:

$$ERSP(f, t) = \frac{|W_x(f, t)|^2}{|W_{baseline}(f)|^2} \quad (3.3)$$

Burada $ERSP(f, t)$ Frekans (f) ve zaman (t) için hesaplanan ERSP, $W_x(f, t)$ Zaman-

frekans domeninde sinyalin dalgacık dönüşümü ve $W_{baseline}(f)$ Temel (baseline) durumunda aynı frekanstaki güç olarak temsil edilir.

ERSP uygulaması sırasında, testin ilk 4 saniyesindeki odaklanma süreci referans alınmıştır. İmgeleme sürecinde elde edilen veriler, odaklanma sürecine göre değişimleri gözlemlemek için kullanılmıştır. Bu sayede, motor imgeleme görevleri sırasında farklı zaman noktalarında ve frekans bantlarında meydana gelen aktivite değişiklikleri ayrıntılı olarak analiz edilebilmiştir.

ERSP analizi sayesinde özellikle Olay İlişkili Desenkronizasyon (ERD) ve Olay İlişkili Senkronizasyon (ERS) olaylarının gözlemlenmesi sağlanmıştır. ERD, belirli bir motor imgeleme görevi sırasında ilgili frekans bandında güç azalması olarak ortaya çıkar ve şu şekilde ifade edilir:

$$ERD(f, t) = 100 \times \frac{P_{baseline}(f) - P_{task}(f, t)}{P_{baseline}(f)} \quad (3.4)$$

ERS ise frekans bandındaki güç artışı ile tanımlanır:


$$ERS(f, t) = 100 \times \frac{P_{task}(f, t) - P_{baseline}(f)}{P_{baseline}(f)} \quad (3.5)$$

Burada $P_{task}(f, t)$ görev sırasında hesaplanan güç spektrumunu ve $P_{baseline}(f)$ temel (baseline) durumunda hesaplanan güç spektrumunu ifade eder.


C3 ve C4 kanallarından elde edilen spektrogramlar, motor imgeleme sürecindeki ERD ve ERS olaylarını görselleştirir. C3 kanalı, sol hemisferdeki motor korteksi temsil eder ve sağ el veya ayak imgelemesi sırasında belirgin ERD gösterir. Bu, spektrogramda frekans bandındaki güç azalması olarak görünür. Benzer şekilde, C4 kanalı sağ hemisferdeki motor korteksi temsil eder ve sol el veya ayak imgelemesi sırasında belirgin ERD gösterir. ERS olayları ise, bu durumun tam tersi olarak ortaya çıkar ve spektrogramlarda belirli frekans bantlarında güç artışı olarak görünür.

Şekil 3.15'da motor imgeleme görevleri sırasında C3 ve C4 kanallarından elde edilen spektrogramlar gösterilmektedir. Her bir alt başlık (a-f), farklı imgeleme görevlerine (sol el, sağ el, sol ayak ve sağ ayak) ait ERSP sonuçlarını içermektedir. Sol el imgelemesi


sırasında (a ve b), C3 kanalında (a) ERS (güç artışı) gözlemlenirken, C4 kanalında (b) ERD (güç azalması) gözlemlenmiştir. Benzer şekilde, sağ el imgelemesi sırasında (c ve d), C4 kanalında (d) ERS, C3 kanalında (c) ERD olayları belirgindir. Ayak imgeleme görevlerinde de (e, f, g ve h) el imgelemelerine birebir benzer olayların gözlemlendiği görülmüştür. Özellikle imgeleme aşamasının başlangıcı olan 4. saniyeden sonra meydana gelen bu değişimler, motor imgeleme sırasında frekans bantlarındaki güç değişimlerini zaman içinde detaylı bir şekilde sunarak, beyin aktivitelerinin değişimlerini görselleştirmiştir.




a) Sol El C3




b) Sol El C4



c) Sağ El C3




d) Sağ El C4



e) Sol Ayak C3

f) Sol Ayak C4




g) Sağ Ayak C3

h) Sağ Ayak C4

Şekil 3.15 El ve Ayak İmgelemelerine Ait C3 ve C4 Kanallarının Spektrogram Görüntüleri

Şekil 3.16’da sağ el imgeleme C3 elektrodu spektrogram görüntüsü yer almaktadır. Görselde bulunan x çizgisinden önceki alan odaklanma, x-y çizgileri arasında kalan alan komut verme ve y-z çizgileri arasında kalan alan ise imgeleme sürecinin meydana geldiği bölümleri göstermektedir. Görselde enerji değişiminin en iyi gözlemlenebildiği frekans aralığı 0–15 Hz olarak göze çarpmaktadır. Bu frekans aralığına baktığımızda imgelemenin başladığı y çizgisinden sonra yer alan B alanı enerji seviyesinin imgeleme öncesindeki A alanı enerji seviyesinden daha yüksek seviyede olduğu açıkça görülebilmektedir.




Şekil 3.16 Sağ El İmgeleme C3 Elektrodu Spektrogram Görüntüsünün İncelenmesi

Sağ el ve ayak imgelemelerinde C3 elektroduna ait verilerde yukarıda anlatıldığı gibi bir durum beklenirken C4 elektrodunda ise tam tersi bir durum beklenmektedir. Yani B alanına baktığımızda daha düşük bir enerji seviyesi (mavi tonları) ile karşılaşılması beklenen durumdur ki Şekil 3.15 (b)'ye baktığımızda bu durum net bir şekilde görülebilmektedir. Sol el ve ayak imgelemelerinde ise yukarıda anlatılan durumun tam tersinin meydana gelmesi beklenmektedir.


Çalışmamız sırasında ERSP uygulanmadan spektrogram dönüşümleri gerçekleştirilerek de sınıflandırmalar yapılmış ve sonuçlar alınmaya çalışılmıştır. Şekil 3.17'de ERSP uygulanmadan oluşturulan bir spektrogram yer almaktadır. Spektrograma bakıldığında enerji seviyelerinin yükseldiği yerler görülebilmektedir fakat bu herhangi bir olaya bağlı olmadığı için sinyaller arasında bir standart oluşmasını sağlayamamaktadır. Örneğin çok düşük bazı enerji seviyeleri spektrogramda görülememekte ve bu da bunların analizde kullanılamamasına sebebiyet vermektedir. Oysaki MI-EEG sinyalleri düşük seviyeli sinyaller olduğundan bu şekilde analizden kaçan birçok bölüm olacaktır. Oysa ERSP'de bir olay ile karşılaştırıldığı için enerji seviyesi düşük olsa bile karşılaştırılan olaydan

büyük veya küçük olması bunu analizde kullanılması için yeterli olacağından en ince detaylar bile analiz edilebilmektedir.



Şekil 3.17 ERSP Uygulanmadan Gerçekleştirilen Bir Wavelet Spektrogram Dönüşümü

Şekil 3.18’de ise ERSP kullanılmadan STFT ile oluşturulan bir spektrogram yer almaktadır. Yine herhangi bir olaya bağlı olmadığı için pek de anlam ifade etmeyen görüntüler oluşturulmuştur. Çalışmanın ilk aşamalarında elde edilen bu görüntüler ile sınıflandırma denemeleri yapılmış fakat başarısız sonuçlar elde edilmiştir. ERSP çalışmaya dahil edildikten sonra sınıflandırma oranlarında ciddi derecede artış meydana gelebilmiştir.



Şekil 3.18 STFT ile Oluşturulan Spektrogram Görüntüsü

3.8. Kanalların Spektrogram Görüntülerinin Çıkarılması

Her iki hemisferdeki motor korteks aktivitelerini karşılaştırmak ve asimetric aktivite değişimlerini daha net gözlemlemek amacıyla C3 kanallarının spektrogram görüntüleri, C4 kanallarının spektrogram görüntülerinden çıkarılmıştır. C3 ve C4 kanallarının spektrogramlarının çıkarılması, bu farklılıkları vurgulayarak, spesifik aktivite değişikliklerini ortaya çıkarmaya yardımcı olur.

Görsellerin birbirlerinden çıkarılması işlemi sırasında, her iki görüntüdeki her bir pikselin renk değeri birbirlerinden çıkarılır. Her iki görüntüde aynı piksel konumundaki RGB değerleri çıkarılır ve sonuçta elde edilen piksel değeri, iki görüntü arasındaki renk farkını gösterir. Eğer iki piksel değeri birbirine çok yakınsa, çıkarma işlemi sonucunda ortaya çıkan renk değeri gri tonlarında olabilir. Eğer iki görüntü arasında büyük farklar varsa, piksel farkları daha yüksek değerlere sahip olabilir ve daha belirgin renklere dönüşebilir. Bizim amacımız da C3 ve C4 kanalları arasında renk farklılıkların çok olduğu bölgeleri ön plana çıkarmak ve ERSP sonucunda oluşan azalma ve artma düşük seviyedeysen dahi

bu seviyeyi daha belirgin hale getirmektir.



C3 RGB Değerleri



C4 RGB Değerleri



C3 – C4 Çıkarması Sonucu Oluşan RGB Değerleri



C3



C4



Çıkarılmış

Şekil 3.19 Bir Piksel Üzerinde Çıkarma İşleminin Gösterimi

Şekil 3.19’da bir piksel üzerinden çıkarma işlemi anlatılmıştır. Görselde C3 ve C4 değerlerine ait RGB değerleri görülmektedir. Çıkarma işleminden önce R değeri baskın şekilde ön plana çıkmamakta ve enerji yüklemesi meydana geldiğini tam olarak sergileyememektedir. C4’te ise enerji düşmesi görülmekte ve baskın bir şekilde belli olmamaktadır. Çıkarma işlemi gerçekleştirildiğinde R değeri ön plana çıkmakta ve enerji seviyesinde bir yükselme olduğu net şekilde görülebilmektedir. Oysaki bu durum çıkarma işlemi öncesi net bir şekilde gözlemlenememektedir. Piksel değerlerinin altında ise C3, C4 ve çıkarılmış pikseldeki renkler görülmektedir. Buradan da görüleceği gibi R değeri

ön plana çıkmaktadır. Bu işlemin yüzlerce piksele uygulandığını düşünürsek R değeri ciddi oranda ön plana çıkacaktır. Verilerin doğru şekilde alındığı varsayılırsa bunun bir sol el imgeleme işlemi olduğu sonucuna ulaşılabilecektir.

Çıkarma işlemi sırasında, bazı piksellerde birinci görüntüdeki renk değeri, ikinci görüntüdeki renk değerinden küçük olabilir. Bu durumda, negatif bir fark oluşur. Görüntü işleme sistemleri negatif piksel değerlerini doğrudan temsil edemeyeceği için, bu tür değerler sıfıra (siyah) indirgenir.


Çıkarma işlemi sonucunda elde edilen görüntüler, C3 kanalındaki aktivitenin C4 kanalındaki aktiviteye göre ne kadar ve nasıl farklılaştığını gösterir. Eğer C3 kanalında belirgin bir ERS olayı gözlemlenirken, C4 kanalında bu kadar belirgin bir değişim yoksa, bu durum çıkarma işlemi sonucunda net bir şekilde görünecektir.

Spektrogram çıkarma işlemi, motor imgeleme sırasında hemisferler arasındaki asimetric beyin aktivitelerinin daha hassas bir şekilde analiz edilmesini sağlar.

Şekil 3.20, Şekil 3.16'da bulunan C3 ve C4 kanallarının spektrogramlarının çıkarılması sonucu elde edilen görüntüleri göstermektedir.


Her bir spektrogramda, frekans bantlarındaki güç değişimlerinin özellikle 4. Saniyeden sonra nasıl farklılık gösterdiği ve hemisferler arasındaki asimetric beyin aktivitelerinin nasıl ortaya çıktığı net bir şekilde gözlemlenebilmektedir.

Görsellerde özellikle 0–15 Hz arasındaki bölgeye odaklandığımızda 4000-8000 ms aralığındaki enerji seviyesinin 0-4000 ms aralığındaki enerji seviyesine göre daha yüksek (maviden kırmızıya doğru bir geçiş) olduğu açıkça görülebilmektedir. Sağ el hareketinde ise bu durumun tam tersi bir durum meydana gelmektedir.



a) Çıkarılmış Sol El

b) Çıkarılmış Sağ El



c) Çıkarılmış Sol Ayak

d) Çıkarılmış Sağ Ayak

Şekil 3.20 C3 ve C4 Elektrotlarının Çıkarılması Sonucu Oluşan Görüntüler

3.9. Renk Yükseltme

Renk yükseltme, görüntülerin daha parlak veya dikkat çekici hale getirilmesi amacıyla yapılmış bir renk artırma işlemidir. Özellikle karanlık veya düşük parlaklığa sahip görüntülerde, parlak piksellerin vurgulanmasını sağlar.

Görüntüleri birbirlerinden çıkardıktan sonra belirgin olan renkleri daha da ön plana çıkarmak için uygulanmaktadır. Amaç farkları mümkün olduğunca ön plana çıkarmak ve sınıflandırmanın en iyi sonuçları vermesini sağlamaktır.

Bu işlemde eğer bir pikselin RGB değerlerinin tümü 50'nin altındaysa, bu piksel tamamen siyah ([0, 0, 0]) olarak ayarlanmıştır. Eğer pikseldeki kırmızı (R), yeşil (G) veya mavi (B)

değerlerinden biri 50'nin üzerindeyse; R, G veya B'nin değeri 255 olarak değiştirilir (maksimum parlaklık). Değerler 50'nin altındaysa, o kanalın mevcut değeri korunur. Böylece yüksek olan renkler daha da ön plana çıkarılmış olur.

Bir diğer yöntemde ise RGB değerlerinden en yüksek olan bulunur ve tüm RGB değerler bu en yüksek değere bölünerek yükseltme katsayısı ile çarpılır. Örneğin;

Kırmızı : 140

Yeşil : 105

Mavi : 201

Yükseltme faktörünü 2 kabul edersek;


Kırmızı = $(140/201) \wedge 2,0 * 201 = 97$

Yeşil = $(105/201) \wedge 2,0 * 201 = 55$

Mavi = $(201/201) \wedge 2,0 * 201 = 201$


Görüldüğü gibi yüksek değere sahip olan mavi renk bu işlem sonucunda daha da ön plana çıkarılmıştır.

Şekil 3.21'de, Şekil 3.20'de bulunan çıkarılmış görseller renk arttırma işlemi uygulanmıştır. Bu renk arttırma işlemi yukarıda anlatılan birinci yöntem kullanılarak gerçekleştirilmiştir. İki şekil birbirleriyle karşılaştırıldığında farkların ne kadar ön plana çıktığı görülebilmektedir.



a) Sol El

b) Sağ El



c) Sol Ayak

d) Sağ Ayak

Şekil 3.21 Renk Arttırma Uygulanmış Görseller


3.10. Gama Düzeltmesi Uygulanması

Çıkarma işlemi sonucunda elde edilen spektrogram görüntülerine, daha net bir görselleştirme sağlamak amacıyla gama düzeltme (gamma correction) uygulanmıştır. Bu işlem, özellikle sinyalin ince detaylarını ve küçük değişiklikleri daha görünür kılmak için kullanılmıştır.

$$V_{out} = AV_{in}^{\gamma} \quad (3.6)$$


Burada V_{out} , gama düzeltmesi uygulanmış çıkış yoğunluğunu (output intensity); V_{in} , orijinal giriş yoğunluğunu (input intensity); γ , gama değerini (gamma value) ifade etmektedir.

Şekil 3.22, çıkarılmış spektrogram görüntülerine gama düzeltme uygulanmış hallerini göstermektedir. Gama düzeltme uygulanmış spektrogramlarda, motor imgeleme sırasında hemisferler arasındaki ERD ve ERS olaylarının daha açık bir şekilde görülebilmesi sağlanmıştır.



a) Sol El

b) Sağ El



c) Sol Ayak

d) Sağ Ayak

Şekil 3.22 Gama Düzeltmesi Uygulanmış Görseller

3.11. Sınıflandırma

Gama düzeltme veya renk artırma işlemi ile optimize edilen spektrogram görüntüleri, sınıflandırma sürecine tabi tutulmuştur. Sınıflandırma işleminde, CNN, RNN, LSTM, EfficientNet ve ViT modelleri kullanılmıştır. Sınıflandırma işlemleri Python ortamında gerçekleştirilmiştir. Sınıflandırma işlemle uygulanırken karşılaştırma yapabilmek adına her model için mümkün olduğunca basit mimariler oluşturulmuştur.

Sınıflandırma işlemi Colab ortamında gerçekleştirilmiştir. Bu sebeple eğitim ve test verileri Google Drive'a yüklenmiş ve işlemler burada yapılmıştır.

Öncelikle, Python programlama dilinde derin öğrenme modelleri oluşturmak ve veri işlemleri yapmak için çeşitli kütüphaneler içe aktarılmıştır. Görüntü verilerini ve ilgili etiketleri matris olarak saklamak ve çeşitli matematiksel işlemler yapmak için NumPy, Görüntüleri yüklemek ve işlemek için Pillow, Derin öğrenme modelini oluşturmak için TensorFlow ve Keras, Verilerin k-fold çapraz doğrulama ile bölünmesi ve sınıflandırma performansının F1 skoru ile değerlendirilmesi süreçleri için scikit-learn ve Verilerin eğitim süreci sırasında görselleştirilmesi için Matplotlib kütüphaneleri kullanılmıştır.

Görüntü verilerinin modellenmesi için ise ilk adım olarak, belirtilen dizin içerisindeki görüntülerin yüklenmesi ve işlenmesi gerekmektedir. Her görüntü RGB formatına dönüştürülmüş ve modelin giriş boyutuna uygun olarak yeniden boyutlandırılmıştır. Aynı zamanda, veriler 255'e bölünerek 0 ile 1 arasında normalize edilmiştir.


3.11.1. CNN

İlk olarak veri setindeki her bir görüntü RGB formatında 256x256 piksel boyutlarına dönüştürülmüştür. Etiketler, kategorik formata dönüştürülerek model için uygun hale getirilmiştir.

İlk evrişimsel katman ile, 32 filtre kullanarak 7x7 boyutunda çekirdekler (kernels) ile görüntüdeki özelliklerin çıkarılması sağlanmıştır. Evrişim işlemini takiben, havuzlama katmanı (pooling) ile boyut azaltılarak önemli özelliklerin korunması ve gereksiz bilgilerin elenmesi sağlanmıştır.

İkinci evrişimsel katmanda 64 filtre ile yine 7x7 çekirdekler kullanarak daha derin özellikler çıkarılmış ve bunu takiben bir başka havuzlama katmanı kullanılmıştır.

Evrişimsel ve havuzlama katmanlarının ardından, veriyi tek boyutlu bir vektöre dönüştürerek tam bağlantılı katmanlara hazırlayan flatten katmanı eklenmiştir. Flatten katmanının ardından tam bağlantılı katman ile öğrenilen özelliklerin işlenmesi ve bu katmanda bir dropout uygulanarak aşırı öğrenmenin (overfitting) önüne geçilmesi sağlanmıştır. Son olarak, softmax aktivasyon fonksiyonuna sahip çıkış katmanı, her bir sınıf için olasılık değerleri üretmiştir. Oluşturulan CNN modelinin mimarisi Şekil 3.23'te gösterilmektedir.



Şekil 3.23 Oluşturulan CNN Sınıflandırma Modeli


Bu süreçte, öğrenme hızını adaptif olarak ayarlayarak modelin daha hızlı ve stabil bir şekilde öğrenmesini sağlayan Adamax optimizasyon algoritması kullanılmıştır ve kayıp fonksiyonu olarak kategorik çapraz entropi seçilmiştir.

3.11.2. RNN

Bir diğer sınıflandırma modeli olarak RNN kullanılmıştır. Eğitim verilerinin ayrılması, gerekli kütüphanelerin yüklenmesi, verilerin yüklenmesi ve ön işlem adımları burada da CNN ile aynı şekilde uygulanmıştır. Görüntüler, Simple RNN modeline giriş olarak

kullanılmak üzere 256x256 boyutuna yeniden boyutlandırılmış ve normalize edilmiştir.

Modelde, iki Simple RNN katmanı kullanılmış ve ardından tam bağlantılı katmanlar eklenmiştir. Modelin ilk katmanı olarak Simple RNN kullanılmış ve iki ardışık Simple RNN katmanı ile veriden özellikler çıkarılmıştır. İlk Simple RNN katmanı, 128 birim içerirken, ikinci katman 64 birimden oluşmaktadır. Bu katmanlardan elde edilen veriler tam bağlantılı (dense) katmana aktarılmış ve sınıflandırma işlemi softmax aktivasyon fonksiyonu ile gerçekleştirilmiştir.



Şekil 3.24 Oluşturulan RNN Mimarisi

Modelin giriş katmanı, 256x256 boyutundaki 3 kanallı (RGB) görüntüleri almak üzere yapılandırılmıştır. Bu giriş, modelin işleyebileceği biçime dönüştürülmüştür çünkü Simple RNN, zaman serisi verileriyle çalışmak üzere tasarlanmış bir yapı olduğundan, görüntülerin belirli bir sıralı yapıya dönüştürülmesi gerekmektedir.

Reshaping Layer giriş görüntüsünü Simple RNN katmanlarının işleyebilmesi için zaman serisi yapısına dönüştürür. RGB formatında olan görüntüler (256x256x3), iki boyutlu olarak ele alınarak 256 zaman adımı (time step) ve her zaman adımında 256x3 boyutlu özellikler olacak şekilde yeniden şekillendirilir.

İlk simple RNN katmanı her bir zaman adımı için 128 boyutlu bir çıktı oluşturur ve her zaman adımı sırasındaki bağımlılıkları yakalar. İkinci Simple RNN katmanı ise ilk katmanın çıktısını alır ve son bir özet temsil oluşturur.

3.11.3. LSTM

LSTM, değerleri rastgele aralıklarla hatırlayan gelişmiş bir RNN mimarisidir. Bu modelde öğrenilen ilerleme kaydedildiğinde saklanan değerler değiştirilmez.

Modelin girdi boyutu (256, 256, 3) olup, 256x256 çözünürlüğünde 3 kanallı (RGB) görüntülerden oluşmaktadır.

Görüntünün orijinal 3 boyutlu formatı (256, 256, 3) iken, reshape katmanı ile her bir piksel satırı 768 boyutunda (256x3) bir vektöre dönüştürülür. Bu katman, görüntünün LSTM'ye uygun bir formatta işlenmesini sağlar. Yeni şekil RNN'de olduğu gibi (256, 768) olur.


İlk LSTM katmanı her bir zaman adımında 128 boyutlu bir çıktı üretir. Bu LSTM katmanı zaman serisi verilerindeki uzun süreli bağımlılıkları öğrenir ve çıktılarını sonraki LSTM katmanına iletir.

İkinci LSTM katmanı, ilk katmandan gelen veriyi işler ve 64 boyutlu bir çıktı üretir. Bu katman, son zaman adımında elde edilen çıktı ile devam eder.

Dense katmanı ise 64 nörondan oluşur ve RELU aktivasyon fonksiyonu kullanılır. Dense katmanı, LSTM katmanlarının öğrenmiş olduğu karmaşık özellikleri işleyerek daha anlamlı hale getirir.

Dropout katmanı, aşırı öğrenmeyi (overfitting) önlemek amacıyla, eğitim sırasında nöronların %20'sini rastgele devre dışı bırakır. Bu katman, modelin genelleme yeteneğini artırmaya yardımcı olur.

Son katman olan çıkış katmanı 2 nöron içerir ve softmax aktivasyon fonksiyonu kullanılır. Bu katman, iki sınıf arasında bir olasılık dağılımı üretir ve modelin hangi sınıfa ait olduğunu tahmin eder.




Şekil 3.25 Oluşturulan LSTM Modeli

3.11.4. EfficientB

EfficientNetB0, Google tarafından geliştirilen ve görüntü sınıflandırma için verimli bir çözüm sunan derin öğrenme modellerinden biridir. Bu çalışmada kullanılan model,

önceden eğitilmiş EfficientNetB0 modelini temel alır.



Şekil 3.26 Oluşturulan EfficientB Modeli

Giriş katmanı, modelin beklediği veri formatını tanımlanmaktadır. Bu modelde giriş görüntülerinin boyutu (256, 256, 3) olarak belirlenmiştir. Bu, her bir görüntünün 256x256 piksel boyutunda ve RGB formatında olduğunu göstermektedir.

EfficientNetB katmanında EfficientNetB0 modeli çağrılmaktadır. EfficientNetB0, önceden eğitilmiş bir modeldir ve milyonlarca görüntü üzerinde eğitilmiştir. Burada model sadece özellik çıkarımı görevini üstlenmektedir. Bu işlem sonucunda model, giriş görüntülerindeki önemli özellikleri çıkarır.

İlk dense katmanında, EfficientNetB0 tarafından çıkarılan özellikler işlenir ve 64 nöronlu bir tam bağlantılı katman ile sıkıştırılır. Dropout katmanı, aşırı öğrenmeyi (overfitting) engellemek için kullanılırken son dense katmanında ise sınıflandırma işlemi yapılır.

3.11.5. Görüş Transformatörü (ViT)

Transformer modelleri, dizesel verilerde yüksek doğruluk sağlayan yapılar olup, doğal dil

işleme (NLP) görevlerinde elde ettikleri başarılarından sonra görüntü işleme (computer vision) alanına da uyarlanmıştır.

Modelde kullanılan Patch Embedding (Parça Gömme) Katmanında giriş görüntüsü küçük parçacıklara bölünür ve bu parçacıklar birer vektör haline getirilir. Örneğin, görüntü 256x256 piksel boyutundaysa, bu katmanda görüntü belirli sayıda parçalara bölünür ve her parça bir öznitelik vektörü haline dönüştürülür. Her bir parçacık, belirlenen boyutlara indirgenir ve daha sonraki Transformer katmanları için bir girdi olarak kullanılır.

Modelin en önemli bileşeni Transformer bloklarıdır. Bu bloklar, çok başlı dikkat (Multi-Head Attention) ve ileri besleme ağı (Feed Forward Network) içerir. Her bir Transformer bloğu, giriş verisini dikkat mekanizmasından geçirir, ardından ileri besleme ağı ile işler. Bu işlem, derin öğrenme ağlarının belirli özelliklere odaklanmasını sağlar. Bu bloklar, modelin dikkatli bir şekilde veriyi incelemesini ve dikkat başlıklarıyla hangi kısımların önemli olduğunu öğrenmesini sağlar.

Global average pooling katmanında Transformer bloklarından gelen çok boyutlu çıktılar tek bir ortalama vektöre indirgenir. Böylece görüntüdeki tüm önemli özellikler tek bir vektöre toplanmış olur.

Yoğun (dense) katmanlar, sınıflandırma işleminin yapıldığı kısımdır. Global average pooling katmanından gelen tek boyutlu vektör, dense katmanlarına verilir ve burada sınıflandırma yapılır.

3.12. Değerlendirme

Bu çalışmada, sınıflandırma modelinin performansını değerlendirmek için, 10 katlı çapraz doğrulama (cross-validation) yöntemi uygulanmıştır.

Bu yöntemle göre, veri seti 10 eşit parçaya bölünmüştür. Her bir parça sırayla test verisi olarak kullanılırken diğer 9 parça eğitim verisi olarak kullanılmıştır. Bu işlem 10 kez tekrarlanır ve her bir tekrarda farklı bir parça test verisi olarak seçilir. Bu süreç, veri setinin tamamının model tarafından görülmesini ve modelin genelleme yeteneğinin daha doğru bir şekilde değerlendirilmesini sağlar.

Değerlendirme metrikleri olarak doğruluk (accuracy) ve F1 skoru kullanılmıştır.

Doğruluk, modelin doğru sınıflandırdığı örneklerin toplam örneklere oranını ifade eder.

F1 skoru, sınıflandırma modelinin performansını, rasgele sınıflandırma ile karşılaştırarak değerlendirir. F1 skoru, doğruluğun yanıltıcı olabileceği dengesiz veri setlerinde daha güvenilir bir performans ölçütüdür. Hassasiyet (Precision) ve Duyarlılık (Recall) skorlarının harmonik ortalamasıdır.

10 katlı çapraz doğrulama (cross validation) yöntemi ile her bir tekrar ve katman için doğruluk ve F1 skoru hesaplanmış ve bu değerlerin ortalaması alınarak modelin genel performansı değerlendirilmiştir.



BÖLÜM IV

4. BULGULAR VE TARTIŞMA

Bu çalışmada, motor imgeleme spektrogramlarının sınıflandırılması için CNN, RNN, LSTM, EfficientNet ve ViT modelleri kullanılmış ve modellerin performansları 10 katlı çapraz doğrulama yöntemi ile değerlendirilmiştir. Elde edilen sonuçlar, CNN modelinin motor imgeleme EEG sinyallerinin sınıflandırılmasında diğer modellere göre daha başarılı bir performans sergilediğini göstermektedir.

Tablo 4.1, motor imgeleme el hareketlerinin sınıflandırılmasında CNN modelinin her bir katılımcı için elde ettiği doğruluk oranlarını göstermektedir. Herbir katılımcı için doğruluk oranları ayrı ayrı hesaplanmış ve bu değerler tabloda sunulmuştur. CNN modeli, tüm katılımcılar için ortalama %75,53 doğruluk oranı ile yüksek bir performans sergilemiştir. Özellikle katılımcı 6 için ulaşılan %88,5 doğruluk oranı kayda değer bir sonuç olmuştur. Bu sonuçlar motor imgeleme EEG sinyallerinin zaman-frekans spektral analiz yöntemleri ve CNN kullanılarak etkin bir şekilde sınıflandırılabileceğini göstermektedir.

Tablo 4.2’de ise motor imgeleme (MI) ayak hareketlerinin sınıflandırılmasında CNN modelinin her bir katılımcı için elde ettiği doğruluk oranları sunulmuştur. Ayak imgelemede %72,81 doğruluk oranına ulaşıldığı görülmektedir.

Tablo 4.1 CNN El İmgeleme Sınıflandırma Doğruluk ve F1 Skoru Sonuçları

KATILIMCILAR	K1	K2	K3	K4	K5	K6	K7	K8
DOĞRULUK	75	68,4	77,7	71,7	72,1	88,5	69,7	81,1
ORTALAMA DOĞRULUK: 75,53								
F1	0,70	0,64	0,74	0,68	0,69	0,85	0,65	0,80
ORTALAMA F1 SKOR: 0,72								

El ve ayak imgeleme sonuçları birlikte değerlendirildiğinde ikisinin de birbirlerine yakın sonuçlar verdiği görülmekle beraber katılımcı hemen hemen tüm katılımcılarda ve

ortalamada el imgeleme üzerinde daha yüksek bir başarı oranına ulaşılmıştır. Bu sonuçlarla beraber C3 ve C4 elektrotlarının bulunduğu bölgenin el imgelemede olduğu gibi ayak imgelemede de aktif olduğu söylenebilir.

CNN sınıflandırmasına ait F1 skoru sonuçları da Tablo 4.1 ve Tablo 4.2’de verilmiştir. F1 skorunun doğruluk sonuçları ile tutarlı olduğu görülmektedir. Bu sonuçlar ile birlikte modelimizin sınıflar arası dengeli bir performans koruduğu söylenebilir.

Tablo 4.2 CNN Ayak İmgeleme Sınıflandırma Doğruluk ve F1 Skoru Sonuçları

KATILI MCILA R	K1	K2	K3	K4	K5	K6	K7	K8
CNN	71,25	72,5	69,25	73,25	68,75	72,5	67,5	87,5
ORTALAMA DOĞRULUK: 72,81								
F1	0,70	0,68	0,67	0,70	0,68	0,70	0,65	0,87
ORTALAMA F1 SKOR: 0,70								


CNN, RNN, LSTM, EfficientNet ve ViT modelleri ile yapılan sınıflandırmaların sonuçları karşılaştırılmıştır ve en yüksek doğruluk oranlarının CNN modeli ile alındığı sonucuna ulaşılmıştır.

Seçilen yapay sinir ağı modelleri ile yapılan el imgeleme sınıflandırmalarının doğruluk sonuçları Tablo 4.3’te gösterilmiştir. CNN, el imgeleme sınıflandırmasında ortalama %75,53 doğruluk oranı ile en yüksek performansı sergilemiştir. Diğer modellerle kıyaslandığında, RNN %60,15, LSTM %63,9, EfficientNet %54,53 ve ViT %71,09 doğruluk oranlarına ulaşmıştır. Bu sonuçlar, CNN modelinin motor imgeleme EEG sinyallerinin sınıflandırılmasında diğer modellere kıyasla daha etkili olduğunu göstermektedir.

Tablo 4.3 El İmgeleme Sınıflandırma Doğruluk Tablosu

KATILIMCILAR	CNN	RNN	LSTM	EFFCNT. NET	ViT
KATILIMCI 1	75	61,25	50	56,25	72.5
KATILIMCI 2	68,4	50	63,75	53,75	73.75
KATILIMCI 3	77,7	41,25	60	47,5	71.25
KATILIMCI 4	71,7	63,75	57,5	57,5	71.25
KATILIMCI 5	72,1	62,5	66,25	53,75	65
KATILIMCI 6	88,5	78,75	82,5	62,5	77.5
KATILIMCI 7	69,75	50	56,25	50	66.25
KATILIMCI 8	81,1	73,75	75	55	71.25
ORTALAMA	75,53	60,15	63,9	54,53	71.09

Şekil 4.1, test edilen 5 farklı yöntemin her biri altında her bir deneğin doğruluğunu karşılaştıran bir çubuk grafiği göstermektedir. Grafikler, 5 yöntemin performansını daha net bir şekilde temsil etmektedir ve çoğu katılımcı için, hemen hemen tüm katılımcılar için CNN'in üstünlüğü net bir şekilde görülmektedir.




Şekil 4.1 El İmgeleme Doğruluk Karşılaştırma Grafiği

Ayak imgeleme sınıflandırmasında, CNN modeli ortalama %72,81 doğruluk oranı ile yine en yüksek performansı sergilemiştir. Diğer modellerle kıyaslandığında, RNN %60,46, LSTM %60,4, EfficientNet %56,56 ve ViT %66,72 doğruluk oranlarına ulaşmıştır. Bu sonuçlar, CNN modelinin motor imgeleme spektrogramlarını sınıflandırmada diğer modellere göre daha etkili olduğunu göstermektedir.

Tablo 4.4 Ayak İmgeleme Sınıflandırma Doğruluk Tablosu

KATILIMCILAR	CNN	RNN	LSTM	EFFICIENT NET	VİT
KATILIMCI 1	71,25	56.25	62.50	55.00	63.75
KATILIMCI 2	72,5	58.75	53.75	57.50	73.75
KATILIMCI 3	69,25	60.00	53.75	60.00	66.25
KATILIMCI 4	73,25	61.25	61.25	60.00	72.50
KATILIMCI 5	68,75	57.50	61.25	47.50	62.50
KATILIMCI 6	72,5	55.00	58.75	62.50	61.25
KATILIMCI 7	67,5	62.50	57.50	55.00	67.50
KATILIMCI 8	87,5	72.50	75.00	55.00	66.25
ORTALAMA	72,81	60,46	60,4	56.56	66.72

Şekil 4.2’de bu kez de ayak imgeleme için çubuk grafiği verilmiştir. Burada da el imgelemede olduğu gibi katılımcı hemen hemen katılımcılarda ve ortalamada CNN’in en iyi performansı gösterdiği görülmektedir.



Şekil 4.2 Ayak İmgeleme Doğruluk Karşılaştırma Grafiği

CNN'in diğer modeller ile karşılaştırıldıktan sonra en iyi performansı göstermesi üzerine bu aşamadan sonraki çalışmalarda CNN üzerinden ilerlenmiştir.

Çalışmanın bu aşamasında Dalgacık Dönüşümü ve Hızlı Fourier Dönüşümü (Fast Fourier Transfor – FFT) yöntemleri karşılaştırılmıştır. Spektrogramlar oluşturulurken wavelet dönüşümü ve FFT ayrı ayrı kullanılmış ve oluşan spektrogramlar üzerinden sınıflandırmalar yapılmıştır. El imgelemesi üzerinde yapılan bu sınıflandırmalarda wavelet yöntemi ile elde edilen doğruluk oranı %75,53 iken, FFT yöntemi ile %72,65 olmuştur. Bu, wavelet tabanlı spektral analiz yönteminin daha yüksek performans sağladığını göstermektedir.

Tablo 4.5 Wavelet ve FFT Karşılaştırma Tablosu – El İmgeleme

KATILIMCILAR	WAVELET - CNN	FFT - CNN
KATILIMCI 1	75	72,5
KATILIMCI 2	68,4	67,5
KATILIMCI 3	77,7	70
KATILIMCI 4	71,7	63,75
KATILIMCI 5	72,1	75
KATILIMCI 6	88,5	85
KATILIMCI 7	69,75	70
KATILIMCI 8	81,1	77,5
ORTALAMA	75,53	72,65

İncelemeler üzerinde gama düzeltme uygulanan ve uygulanmayan spektrogramlar ile sınıflandırmalar yapılmıştır. Tablo 4.6’da da görülebileceği gibi ayak imgeleme üzerinde gama düzeltmesi uygulanan spektrogramlar ile yapılan sınıflandırma %72,81 doğruluk oranı ile daha yüksek performans göstermiştir. Gama düzeltme uygulanmamış normal spektrogramlarda ise doğruluk oranı %70,78 olarak elde edilmiştir.

Tablo 4.6 Ayak İmgeleme CNN Üzerinde Gama Correction Karşılaştırma Tablosu

KATILIMCILAR	GAMA DÜZELTME	NORMAL
KATILIMCI 1	71,25	66,25
KATILIMCI 2	72,5	70
KATILIMCI 3	69,25	68,75
KATILIMCI 4	73,25	60
KATILIMCI 5	68,75	72,5
KATILIMCI 6	72,5	71,25
KATILIMCI 7	67,5	70
KATILIMCI 8	87,5	87,5
ORTALAMA	72,81	70,78

Tablo 4.7’de motor imgeleme görevlerinde farklı kombinasyonların sınıflandırma doğruluk oranları sunulmuştur. Çalışmada, sağ el-sol ayak, sol el-sağ ayak, sağ el-sağ ayak ve sol el-sol ayak kombinasyonları kullanılmıştır. Beklenildiği gibi farklı hemisferde bulunan imgelemelerin bulunduğu kombinasyonların sınıflandırma oranlarının aynı hemisferde bulunanlara oranla daha yüksek bir oranda olduğu görülmektedir.

Tablo 4.7 El ve Ayak İmgeleme Karşılaştırmaları

KATILIMCILAR	SAĞ EL – SOL AYAK	SOL EL – SAĞ AYAK	SAĞ EL – SAĞ AYAK	SOL EL – SOL AYAK
KATILIMCI 1	67,5	70	71,25	68,75
KATILIMCI 2	68,75	75	65	68,75
KATILIMCI 3	72,5	63,75	68,75	68,75
KATILIMCI 4	70	70	68,75	66,25
KATILIMCI 5	68,75	70	67,5	65
KATILIMCI 6	71,25	82,5	76,25	83,75
KATILIMCI 7	70	67,5	66,25	68,75
KATILIMCI 8	81,25	78,75	71,25	76,25
ORTALAMA	71,25	72,18	69,37	70,78

BÖLÜM V

5. SONUÇ

Bu çalışmada, motor imgeleme (MI) EEG sinyallerinin zaman-frekans spektrogramları kullanılarak sınıflandırılması ele alınmıştır. Derin öğrenme yöntemleri, özellikle Konvolüsyonel Sinir Ağları (CNN), MI-EEG sinyallerinin sınıflandırılmasında yüksek doğruluk oranları ile başarılı olmuştur.

Çalışmada, CNN modelinin diğer derin öğrenme modelleri olan RNN, LSTM, EfficientNet ve ViT ile karşılaştırıldığında en yüksek performansı sergilediği görülmüştür. CNN, el imgeleme sınıflandırmalarında ortalama %75,53 doğruluk oranı ile öne çıkmış, ayak imgeleme sınıflandırmalarında ise %72,81 doğruluk oranına ulaşmıştır. Bu sonuçlar, CNN modelinin motor imgeleme EEG sinyallerinin sınıflandırılmasında diğer modellere göre daha etkili olduğunu göstermiştir.

Bu çalışma için önerdiğimiz yöntem wavelet tabanlı spektral analiz ile gama düzeltme işleminin bir kombinasyonudur. Bu yöntem, Fourier Dönüşümü (FFT) ile karşılaştırıldığında, motor imgeleme EEG sinyallerinin sınıflandırılmasında daha yüksek doğruluk oranları sağlamaktadır.

Wavelet dönüşümü, yüksek zaman-frekans çözünürlüğü sunarak, EEG sinyallerinin spektral özelliklerini daha hassas bir şekilde yakalamaktadır. Bu durum, sinyallerin karmaşık yapısını daha iyi temsil etmekte ve sınıflandırma algoritmalarının performansını artırmaktadır. Gama düzeltme işlemi ise, spektral analiz sırasında elde edilen verilerin daha iyi normalize edilmesine ve önemli özelliklerin daha belirgin hale getirilmesine katkıda bulunmaktadır. Bu kombinasyon, el ve ayak imgeleme görevlerinde elde edilen sınıflandırma doğruluğunu önemli ölçüde artırmıştır.

Bu çalışma, wavelet tabanlı spektral analiz yönteminin FFT'ye göre daha üstün bir performans sağladığını ve C3-C4 kanalları arasındaki farkların dikkate alınmasıyla sınıflandırma doğruluğunun daha da iyileştirilebileceğini göstermektedir. Motor imgeleme görevlerinin farklı kombinasyonlarında CNN modelinin başarılı performansı, bu modelin motor korteksin farklı bölgelerindeki aktivite değişikliklerini etkili bir şekilde yakalayabildiğini göstermiştir. Özellikle sağ el ve sol ayak, sol el ve sağ ayak

kombinasyonlarındaki yüksek doğruluk oranları, motor imgeleme görevlerinin beyindeki asimmetrik aktivite değişimlerini doğru bir şekilde yansıttığını ortaya koymaktadır. Bu çalışmada, benzer çalışmalarda genellikle göz ardı edilen ayak imgeleme sinyalleri de el imgeleme sinyalleriyle birlikte toplanmış ve analiz edilmiştir. Ayak sinyalleri, zayıflıklarından dolayı birçok araştırmada yeterince değerlendirilmemiştir; ancak, bu çalışma, ayak sinyallerinin de motor korteksin aktivitesini doğru bir şekilde yansıtabileceğini ve akıllı protez geliştirme çalışmalarına önemli katkılar sağlayabileceğini ortaya koymaktadır. Bu durum, özellikle motor imgeleme görevlerinin beyindeki asimmetrik aktivite değişimlerini tespit etmek ve motor fonksiyonların nörorehabilitasyonu için önemli çıkarımlar sunmaktadır.

Gelecek çalışmalarda, daha büyük ve çeşitli veri setlerinin kullanılması, farklı sınıflandırma algoritmalarının denenmesi, metodolojinin iyileştirilmesi ile daha yüksek doğruluk oranlarına ulaşılması ve sağ el, sol ayak, sol el ve sağ ayak imgelemelerinin dahil olduğu 4 sınıflı bir sınıflandırma modelinin oluşturulması hedeflenmektedir.

Sonuç olarak, bu çalışma, MI-EEG sinyallerinin sınıflandırılmasında zaman-frekans analiz yöntemlerinin etkinliğini ortaya koyarak, BCI ve nörorehabilitasyon alanlarında uygulamaların geliştirilmesine önemli katkılar sağlamaktadır. Bu alandaki gelecekteki çalışmalar, MI-EEG sinyallerinin daha iyi anlaşılmasına ve pratik uygulamalarda kullanımının artırılmasına yönelik önemli adımlar atacaktır.

KAYNAKLAR

- [1] Elashmawi W H, Ayman A, Antoun M, Mohamed H, Mohamed S E, Amr H, Talaat Y and Ali A 2024 A Comprehensive Review on Brain–Computer Interface (BCI)-Based Machine and Deep Learning Algorithms for Stroke Rehabilitation *Applied Sciences* **14** 6347
- [2] Zhang H, Zhou Q-Q, Chen H, Hu X-Q, Li W-G, Bai Y, Han J-X, Wang Y, Liang Z-H, Chen D, Cong F-Y, Yan J-Q and Li X-L 2023 The Applied Principles of Eeg Analysis Methods in Neuroscience and Clinical Neurology *Military Medical Research* **10** 67
- [3] Decety J 1996 The Neurophysiological Basis of Motor Imagery *Behavioural Brain Research* **77** 45–52
- [4] Vavoulis A, Figueiredo P and Vourvopoulos A 2023 A Review of Online Classification Performance in Motor Imagery-Based Brain–Computer Interfaces for Stroke Neurorehabilitation *Signals* **4** 73–86
- [5] Majoros T and Oniga S 2022 Overview of the EEG-Based Classification of Motor Imagery Activities Using Machine Learning Methods and Inference Acceleration with FPGA-Based Cards *Electronics* **11** 2293
- [6] Brunner I, Lundquist C B, Pedersen A R, Spaich E G, Dosen S and Savic A 2024 Brain Computer Interface Training with Motor Imagery and Functional Electrical Stimulation for Patients with Severe Upper Limb Paresis After Stroke: A Randomized Controlled Pilot Trial *Journal of NeuroEngineering and Rehabilitation* **21** 10
- [7] Jeon Y, Nam C S, Kim Y-J and Whang M C 2011 Event-Related (de)synchronization (erd/Ers) During Motor Imagery Tasks: Implications for Brain–Computer Interfaces *International Journal of Industrial Ergonomics* **41** 428–36
- [8] Zhang Z 2019 Spectral and Time-Frequency Analysis *EEG Signal Processing and Feature Extraction* ed L Hu and Z Zhang (Singapore: Springer) pp 89–116
- [9] Anon Motor Imagery Classification using EEG Spectrograms <https://arxiv.labs.arxiv.org/html/2211.08350> *ar5iv*
- [10] Chaddad A, Wu Y, Kateb R and Bouridane A 2023 Electroencephalography Signal Processing: A Comprehensive Review and Analysis of Methods and Techniques *Sensors* **23** 6434
- [11] Singh A K and Krishnan S 2023 Trends in Eeg Signal Feature Extraction Applications *Front. Artif. Intell.* **5**
- [12] Chiarion G, Sparacino L, Antonacci Y, Faes L and Mesin L 2023 Connectivity Analysis in Eeg Data: A Tutorial Review of the State of the Art and Emerging Trends *Bioengineering* **10** 372
- [13] Yilmaz C M and Yilmaz B H 2023 Advancements in Image Feature-Based Classification of Motor Imagery Eeg Data: A Comprehensive Review *TS* **40**
- [14] Baniqued P D E, Stanyer E C, Awais M, Alazmani A, Jackson A E, Mon-Williams M A, Mushtaq F and Holt R J 2021 Brain–Computer Interface Robotics for Hand Rehabilitation After Stroke: A Systematic Review *Journal of NeuroEngineering and Rehabilitation* **18** 15
- [15] Chen J, Xia Y, Zhou X, Vidal Rosas E, Thomas A, Loureiro R, Cooper R J, Carlson T and Zhao H 2023 fNIRS-EEG BCIs for Motor Rehabilitation: A Review *Bioengineering* **10** 1393

- [16] Lun X, Zhang Y, Zhu M, Lian Y and Hou Y 2023 A Combined Virtual Electrode-Based ESA and CNN Method for MI-EEG Signal Feature Extraction and Classification *Sensors* **23** 8893
- [17] Du L, Li L, Wang B and Xiao J 2016 Micro-Doppler Feature Extraction Based on Time-Frequency Spectrogram for Ground Moving Targets Classification With Low-Resolution Radar *IEEE Sensors Journal* **16** 3756–63
- [18] Shajil N, Mohan S, Srinivasan P, Arivudaiyanambi J and Arasappan Murrugesan A 2020 Multiclass Classification of Spatially Filtered Motor Imagery EEG Signals Using Convolutional Neural Network for BCI Based Applications *J. Med. Biol. Eng.* **40** 663–72
- [19] Ak A, Topuz V and Midi I 2022 Motor imagery EEG signal classification using image processing technique over GoogLeNet deep learning algorithm for controlling the robot manipulator *Biomedical Signal Processing and Control* **72** 103295
- [20] Yan H, Zhang E, Wang J, Leng C, Basu A and Peng J 2023 Hybrid Conv-ViT Network for Hyperspectral Image Classification *IEEE Geoscience and Remote Sensing Letters* **20** 1–5
- [21] Liang J, Wang D and Ling X 2021 Image Classification for Soybean and Weeds Based on ViT *J. Phys.: Conf. Ser.* **2002** 012068
- [22] Zhang D, Liu Z and Shi X 2020 Transfer Learning on EfficientNet for Remote Sensing image Classification *2020 5th International Conference on Mechanical, Control and Computer Engineering (ICMCCE) 2020 5th International Conference on Mechanical, Control and Computer Engineering (ICMCCE)* pp 2255–8
- [23] Shamila Ebenezer A, Deepa Kanmani S, Sivakumar M and Jeba Priya S 2022 Effect of image transformation on EfficientNet model for COVID-19 CT image classification *Materials Today: Proceedings* **51** 2512–9
- [24] Wang J, Yang Y, Mao J, Huang Z, Huang C and Xu W 2016 CNN-RNN: A Unified Framework for Multi-Label Image Classification *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* pp 2285–94
- [25] Zhang X, Sun Y, Jiang K, Li C, Jiao L and Zhou H 2018 Spatial Sequential Recurrent Neural Network for Hyperspectral Image Classification *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **11** 4141–55
- [26] Tatsunami Y and Taki M 2022 Sequencer: Deep LSTM for Image Classification *Advances in Neural Information Processing Systems* **35** 38204–17
- [27] Liu Q, Zhou F, Hang R and Yuan X 2017 Bidirectional-Convolutional LSTM Based Spectral-Spatial Feature Learning for Hyperspectral Image Classification *Remote Sensing* **9** 1330
- [28] Kutz M 2003 *Standard Handbook of Biomedical Engineering & Design* (McGraw-Hill Education)
- [29] Anon https://www.researchgate.net/figure/Polysomnography-leads-and-parameters-EEG-Electroencephalogram-EOG-Electrooculography_fig2_349396920 *ResearchGate*
- [30] Cichocki A, Baumert M and Porta A 2016 Biomedical Signal Processing: From a Conceptual Framework to Clinical Applications
- [31] Escobar J J M, Matamoros O M and Padilla R T 2020 Biomedical Signal Acquisition Using Sensors under the Paradigm of Parallel Computing

- [32] Mitsar B MCScap-26 CLASSIC (E-type Ag/AgCl electrodes) – Mitsar :: Neurodiagnostics :: Electroencephalography (EEG) <https://mitsar-eeeg.com/product/mcscap-e-type-classic/>
- [33] Mannée D C, de Jongh F and van Helvoort H 2020 Telemonitoring Techniques for Lung Volume Measurement: Accuracy, Artifacts and Effort *Front. Digit. Health* **2**
- [34] Zhao Y, Applegate M B, Istfan R, Pande A and Roblyer D 2018 Quantitative Real-Time Pulse Oximetry with Ultrafast Frequency-Domain Diffuse Optics and Deep Neural Network Processing *Biomed. Opt. Express, BOE* **9** 5997–6008
- [35] Yüksek S 2023 Pulse Oksimetre nedir <file:///C:/Users/HP/Zotero/storage/3R4BS9VM/pulse-oksime-re-nedir.html>
- [36] Kim M 2022 Optics & Photonics News - The Quest for Noninvasive Glucose Monitoring
- [37] Anon Fundamentals of Neuroscience/Neural Signaling - Wikiversity file:///C:/Users/HP/Zotero/storage/FHG72NWB/Neural_Signaling.html
- [38] Anon Neurons | Organismal Biology Georgia Tech Biological Sciences <file:///C:/Users/HP/Zotero/storage/2MY4YDKU/neurons.html>
- [39] Kıvrak B E Vücudumuzdaki En Uzun Hücreler: Sinir Hücrelerinin Yapısı ve İşlevi - bilimUP *Vücudumuzdaki En Uzun Hücreler: Sinir Hücrelerinin Yapısı ve İşlevi - bilimUP*
- [40] Raimondo J V, Burman R J, Katz A A and Akerman C J 2015 Ion dynamics during seizures *Front. Cell. Neurosci.* **9**
- [41] Anon Membrane potential (resting membrane potential) <https://www.khanacademy.org/science/biology/human-biology/neuron-nervous-system/a/the-membrane-potential> *Khan Academy*
- [42] Anon 2016 Action potentials and synapses <file:///C:/Users/HP/Zotero/storage/BR54IQMD/action-potentials-and-synapses.html>
- [43] Anon Eastern Mindfulness | Optimization For Excellence <https://easternmindfulness.com/>
- [44] Davies H Functional Magnetic Resonance Imaging [fMRI] <file:///C:/Users/HP/Zotero/storage/PXGQ8AIJ/functional-magnetic-resonance-imaging-fmri.html>
- [45] Anon How FMRI works <https://www.open.edu/openlearn/body-mind/health/health-sciences/how-fmri-works> *Open Learning*
- [46] Anon Who is MEGIN? - MEGIN <file:///C:/Users/HP/Zotero/storage/W749WJKP/who-is-megin.html>
- [47] Burkhardt J, Sharma A, Tan J, Franke L, Leburu J, Jeschke J, Devore S, Friedman D, Chen J and Haehn D 2022 N-Tools-Browser: Web-Based Visualization of Electrocorticography Data for Epilepsy Surgery *Front. Bioinform.* **2**
- [48] Panov F, Levin E, de Hemptinne C, Swann N C, Qasim S, Miocinovic S, Ostrem J L and Starr P A 2017 Intraoperative electrocorticography for physiological research in movement disorders: principles and experience in 200 cases *J Neurosurg* **126** 122–31
- [49] Anon Figure 2.10: Invasive and non-invasive electrodes generate different... https://www.researchgate.net/figure/Invasive-and-non-invasive-electrodes-generate-different-brain-signals_fig17_338257885 *ResearchGate*

- [50] Anon Understanding Brain Waves: Beta, Alpha, Theta, Delta + Gamma [https:// www.diygenius.com/the-5-types-of-brain-waves/](https://www.diygenius.com/the-5-types-of-brain-waves/)
- [51] Abhang P and Mehrotra S 2016 Brain Waves - an overview | ScienceDirect Topics
- [52] Kruizinga H 2016 Your 5 Brainwaves: Delta, Theta, Alpha, Beta and Gamma *Lucid*
- [53] Services D of H & H EEG test file:///C:/Users/HP/Zotero/storage/F2Q94M99/eeeg-test.html
- [54] Peters B and Patel S 2023 What It's Like to Have an EEG Test Done *Verywell Health*
- [55] Anon 2020 Beyin Dalgaları file:///C:/Users/HP/Zotero/storage/XAVTIPVN/beyin-dalgaları.html
Yücel BİNİCİ
- [56] Davies H An Introduction to EEG
- [57] Farnsworth B 2019 EEG (Electroencephalography): The Complete Pocket Guide - iMotions
- [58] Zhang A, Shyam A B, Cunningham A M, Williams C, Brissenden A, Bartley A, Amsden B, Docoslis A, Kontopoulou M and Ameri S K 2023 Adhesive Wearable Sensors for Electroencephalography from Hairy Scalp *Advanced Healthcare Materials* **12** 2300142
- [59] Nagwade P, Parandeh S and Lee S 2023 Prospects of soft biopotential interfaces for wearable human-machine interactive devices and applications *ss* **3** N/A-N/A
- [60] Mulder T 2007 Motor imagery and action observation: cognitive tools for rehabilitation *Journal of Neural Transmission* **114** 1265
- [61] Vasilyev A, Liburkina S, Yakovlev L, Perepelkina O and Kaplan A 2017 Assessing motor imagery in brain-computer interface training: Psychological and neurophysiological correlates *Neuropsychologia* **97** 56–65
- [62] Anon 2016 Felçliler için robot kol geliştirildi | Teknolog file:///C:/Users/HP/Zotero/storage/BEAN57B9/felçliler-icin-robot-kol-gelistirildi.html
- [63] Faulkner M, Hannan S, Aristovich K, Avery J and Holder D 2018 Characterising the frequency response of impedance changes during evoked physiological activity in the rat brain *Physiol. Meas.* **39** 034007
- [64] Uguz İ and Shepard K Spatially controlled, bipolar, cortical stimulation with high-capacitance, mechanically flexible subdural surface microelectrode arrays | Science Advances
- [65] Triana-Guzman N, Guerrero-Mendez C D, Moreno-Arevalo B S, Orjuela-Cañon A D and Jutínico-Alarcon A L 2024 Exploring Motor Imagery and Execution of Lower Limb Tasks: EEG Analysis during Transitions from Sitting to Standing
- [66] Tung S W, Guan C, Ang K K, Phua K S, Wang C, Zhao L, Teo W P and Chew E 2013 Motor imagery BCI for upper limb stroke rehabilitation: An evaluation of the EEG recordings using coherence analysis *Annu Int Conf IEEE Eng Med Biol Soc* **2013** 261–4
- [67] Kim T-H and Cruz A 2011 Differences in brain activation during motor imagery and action observation of golf putting *Scientific Research and Essays* **6**
- [68] Anon Positions of EEG channel locations. The reference electrode is located... file:///C:/Users/HP/Zotero/storage/HKV9JJ74/Positions-of-EEG-channel-locations-The-reference-electrode-is-located-on-the-nasion_fig1_272753.html

- [69] Yi W, Qiu S, Wang K, Qi H, He F, Zhou P, Zhang L and Ming D 2016 EEG oscillatory patterns and classification of sequential compound limb motor imagery *Journal of NeuroEngineering and Rehabilitation* **13** 11
- [70] Rimbert S and Lotte F 2022 ERD modulations during motor imageries relate to users' traits and BCI performances 2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC) 2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC) pp 203–7
- [71] Bagyaraj S, Apurva S and Asha R 2020 Brain wave classification for divergent hand movements *IJPAP*
- [72] Pfurtscheller G and Silva F L da 2017 C40EEG Event-Related Desynchronization and Event-Related Synchronization *Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields* ed D L Schomer, F H Lopes da Silva, D L Schomer and F H Lopes da Silva (Oxford University Press) p 0
- [73] Ismail L, Karwowski W, Hancock P A, Taiar R and Fernandez-Sumano R 2023 Electroencephalography (EEG) Physiological Indices Reflecting Human Physical Performance: A Systematic Review Using Updated PRISMA *JIN* **22** 62
- [74] Yang C, Chen Z and Wang S 2024 The Impact of Visual and Kinesthetic Motor Imagery on Mental Fatigue and Classification Performance in Untrained Participants: International Journal of Human–Computer Interaction: Vol 0, No 0 - Get Access
- [75] Wang Y, Wang Y-T and Jung T-P 2012 Translation of EEG Spatial Filters from Resting to Motor Imagery Using Independent Component Analysis *PLOS ONE* **7** e37665
- [76] Penalzoza C I, Alimardani M and Nishio S 2018 Android Feedback-Based Training Modulates Sensorimotor Rhythms During Motor Imagery *IEEE Transactions on Neural Systems and Rehabilitation Engineering*
- [77] Anon ERD/ERS curves (left side) and grand average topographies (right side)... | Download Scientific Diagram file:///C:/Users/HP/Zotero/storage/7DYGtBLY/ERD-ERS-curves-left-side-and-grand-average-topographies-right-side-of-left-arm_fig2_335464330.html
- [78] Abbass H A 2014 Calibrating Independent Component Analysis with Laplacian Reference for Real-Time EEG Artifact Removal *Neural Information Processing* ed C K Loo, K S Yap, K W Wong, A T Beng Jin and K Huang (Cham: Springer International Publishing) pp 68–75
- [79] Rahman A Original EEG signal and its stepwise filtering effect (according to the... | Download Scientific Diagram file:///C:/Users/HP/Zotero/storage/6CDVXAWL/Original-EEG-signal-and-its-stepwise-filtering-effect-according-to-the-proposal-on-the_fig3_342.html
- [80] Nguyen D T, Kosobrodov R and Barry M 2013 electrode contact impedance: Topics by Science.gov
- [81] Woodman G 2013 A Brief Introduction to the Use of Event-Related Potentials (ERPs) in Studies of Perception and Attention - PMC
- [82] Anon Baseline Correction in Essential FTIR Spectroscopy Software file:///C:/Users/HP/Zotero/storage/2GVH5ZN9/baselineCorrection.html
- [83] Anon 2020 Understanding Spectrograms file:///C:/Users/HP/Zotero/storage/2WKVZHL8/understanding-spectrograms.html

- [84] Wyse L 2024 Audio spectrogram representations for processing with Convolutional Neural Networks *ar5iv*
- [85] Leiber M, Marnissi Y and Barrau A Differentiable short-time Fourier transform with respect to the hop length *ar5iv*
- [86] Skrapas K, Boultadakis G, Karakasiliotis A and Frangos P 2005 Time - frequency analysis of radar signals for ISAR applications *Proceedings of 2nd International Conference on Recent Advances in Space Technologies, 2005. RAST 2005*. Proceedings of 2nd International Conference on Recent Advances in Space Technologies, 2005. RAST 2005. pp 699–703
- [87] Mallat S 1998 Welcome - A Wavelet Tour of Signal Processing
- [88] Jr D A S 1993 *Foundations, Applications, and Assessment of Wavelets* (Institute for Telecommunication Sciences)
- [89] Buś S and Jędrzejewski K 2016 Digital signal processing techniques for pitch shifting and time scaling of audio signals *Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments 2016 Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments 2016* vol 10031 (SPIE) pp 1484–93
- [90] Anon 3.7. Autocorrelation and autocovariance — Introduction to Speech Processing file:///C:/Users/HP/Zotero/storage/RFNY4W43/Autocorrelation_and_autocovariance.html
- [91] Khezri M and Jahed M 2007 An Inventive Quadratic Time-Frequency Scheme Based on Wigner-Ville Distribution for Classification of sEMG Signals *2007 6th International Special Topic Conference on Information Technology Applications in Biomedicine 2007 6th International Special Topic Conference on Information Technology Applications in Biomedicine* pp 261–4
- [92] Zoukaneri I M and Porsani M J 2013 High-resolution time frequency analysis using Wigner-Ville Distribution and the Maximum Entropy Method: Application for gas and hydrates identification *13th International Congress of the Brazilian Geophysical Society & EXPOGEF, Rio de Janeiro, Brazil, 26?29 August 2013 SEG Global Meeting Abstracts (Brazilian Geophysical Society)* pp 957–61
- [93] Shankara Narayana Rao B V 2009 Two-dimensional Wigner-Ville transforms and their basic properties *Theses and Dissertations - UTB/UTPA*
- [94] Hussein A F, Hashim S J, Aziz A F A, Rokhani F Z and Adnan W A W 2017 Performance Evaluation of Time-Frequency Distributions for ECG Signal Analysis *J Med Syst* **42** 15
- [95] Wang C, Li H and Zhao D 2018 A Preconditioning Framework for the Empirical Mode Decomposition Method *Circuits Syst Signal Process* **37** 5417–40
- [96] Roy I G 2024 Hilbert Transform: A Brief Overview *Reson* **29** 671–89
- [97] Ranjan R, Jindal N and Singh A K 2020 Fractional S-Transform and Its Properties: A Comprehensive Survey *Wirel. Pers. Commun.* **113** 2519–41
- [98] Rivera-Aguilar B A, Cuevas E, Pérez M, Camarena O and Rodríguez A 2024 A new histogram equalization technique for contrast enhancement of grayscale images using the differential evolution algorithm *Neural Comput & Applic* **36** 12029–45
- [99] Qi Y, Yang Z, Sun W, Lou M, Lian J, Zhao W, Deng X and Ma Y 2022 A Comprehensive Overview of Image Enhancement Techniques *Arch Computat Methods Eng* **29** 583–607

- [100] Koo K-M and Cha E-Y 2017 Image recognition performance enhancements using image normalization *Human-centric Computing and Information Sciences* **7** 33
- [101] Güneş A, Kalkan H and Durmuş E 2016 Optimizing the color-to-grayscale conversion for image classification *SIViP* **10** 853–60
- [102] Manakitsa N, Maraslidis G S, Moysis L and Fragulis G F 2024 A Review of Machine Learning and Deep Learning for Object Detection, Semantic Segmentation, and Human Action Recognition in Machine and Robotic Vision *Technologies* **12** 15
- [103] Arar S 2020 Image Arithmetic in DSP: Image Averaging and Image Subtraction - Technical Articles
- [104] Saligrama V Fig. 3. Background subtraction results for real video: (a) original... file:///C:/Users/HP/Zotero/storage/TNWJ37U2/Background-subtraction-results-for-real-video-a-original-frame-top-left-detection_fig2_22439665.html *ResearchGate*
- [105] Rahman S, Rahman M M, Abdullah-Al-Wadud M, Al-Quaderi G D and Shoyaib M 2016 An adaptive gamma correction for image enhancement *EURASIP Journal on Image and Video Processing* **2016** 35
- [106] Panigrahi S, Roul A and Dash R 2022 A Pixel Dependent Adaptive Gamma Correction Based Image Enhancement Technique *Computational Intelligence in Pattern Recognition* ed A K Das, J Nayak, B Naik, S Vimal and D Pelusi (Singapore: Springer Nature) pp 141–50
- [107] Anon gamma_corrected_lady.jpg (750×333) file:///C:/Users/HP/Zotero/storage/A26XKJEB/gamma_corrected_lady.html
- [108] Esme E 2024 Enhancing classification accuracy through feature extraction: a comparative study of discretization and clustering approaches on sensor-based datasets *Knowl Inf Syst* **66** 339–56
- [109] Asmianto, Pusawidjayanti K, Hafiizh M and Supeno I 2022 Comparative of classification algorithm: Decision tree, SVM, and KNN for heart diseases prediction *AIP Conference Proceedings* **2639** 030005
- [110] Montesinos López O A, Montesinos López A and Crossa J 2022 Fundamentals of Artificial Neural Networks and Deep Learning *Multivariate Statistical Machine Learning Methods for Genomic Prediction* ed O A Montesinos López, A Montesinos López and J Crossa (Cham: Springer International Publishing) pp 379–425
- [111] Dubey S R, Singh S K and Chaudhuri B B 2022 Activation Functions in Deep Learning: A Comprehensive Survey and Benchmark *ar5iv*
- [112] O'Shea K and Nash R An Introduction to Convolutional Neural Networks *ar5iv*
- [113] Mienye I D, Swart T G and Obaido G 2024 Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications *Information* **15** 517
- [114] Anon Long Short-Term Memory (LSTM) — Dive into Deep Learning 1.0.3 documentation file:///C:/Users/HP/Zotero/storage/2DEZU336/lstm.html
- [115] Boesch G 2024 GoogLeNet Explained: The Inception Model that Won ImageNet *viso.ai*
- [116] Al-hammuri K, Gebali F, Kanan A and Chelvan I T 2023 Vision transformer architecture and applications in digital health: a tutorial and survey *Visual Computing for Industry, Biomedicine, and Art* **6** 14

- [117] Adaloglou N 2021 How the Vision Transformer (ViT) works in 10 minutes: an image is worth 16x16 words *AI Summer*
- [118] Anon Evaluating a Classification Model file:///C:/Users/HP/Zotero/storage/GLAFH577/machine-learning-evaluate-classification-model.html *ritchieng.github.io*
- [119] Naidu G, Zuva T and Sibanda E M 2023 A Review of Evaluation Metrics in Machine Learning Algorithms *Artificial Intelligence Application in Networks and Systems* ed R Silhavy and P Silhavy (Cham: Springer International Publishing) pp 15–25
- [120] Allgaier J and Pryss R 2024 Cross-Validation Visualized: A Narrative Guide to Advanced Methods *Machine Learning and Knowledge Extraction* **6** 1378–88
- [121] Peirce J W 2007 PsychoPy—Psychophysics software in Python *Journal of Neuroscience Methods* **162** 8–13
- [122] Anon 2024 EEGLAB file:///C:/Users/HP/Zotero/storage/ZR43RVE4/EEGLAB.html *Wikipedia*
- [123] Kong X, Wu C, Chen S, Wu T and Han J 2024 Efficient Feature Learning Model of Motor Imagery EEG Signals with L1-Norm and Weighted Fusion *Biosensors* **14** 211
- [124] Wang H, Chen Z, Zou S and Zhao L 2010 [The continuous analysis of EEG's alpha wave by morlet wavelet transform] *Sheng Wu Yi Xue Gong Cheng Xue Za Zhi* **27** 746–8, 752
- [125] Zhang Z and Koike Y 2022 Clustered event related spectral perturbation (ERSP) feature in right hand motor imagery classification *Front. Neurosci.* **16**