

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DİNLENME DURUMUNDA ELEKTROENSEFALOGRAFİ (EEG) ALFA FREKANSI
ÜZERİNDEN BİYOMETRİK TANIMLAMA VE KİMLİK DOĞRULAMA

HAZİM ÖZTÜRK

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Programı

OCAK 2024

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DİNLENME DURUMUNDA ELEKTROENSEFALOGRAFİ (EEG) ALFA FREKANSI
ÜZERİNDEN BİYOMETRİK TANIMLAMA VE KİMLİK DOĞRULAMA

HAZİM ÖZTÜRK

DANIŞMAN
Dr. Öğr. Üyesi Kutlucan GÖRÜR

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Programı

OCAK 2024

ONAY

Hazim ÖZTÜRK tarafından hazırlanan “**Dinlenme Durumunda Elektroensefalografi (EEG) Alfa Frekansı Üzerinden Biyometrik Tanımlama ve Kimlik Doğrulama**” adlı tez çalışması 12/01/2024 tarihinde yapılan sınavla aşağıdaki jüri tarafından oybirliği ile Bandırma Onyedi Eylül Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Dr. Öğr. Üyesi Kutlucan GÖRÜR
(Danışman)

Dr. Öğr. Üyesi Onursal ÇETİN
(Üye)

Dr. Öğr. Üyesi Sıtkı AKKAYA
(Üye)

İmza

Bu tezin kabulü, Fen Bilimleri Enstitüsü Yönetim Kurulu’nun .../.../20.... gün ve .../... sayılı kararı ile onaylanmıştır.

Doç. Dr. Abdullah YEŞİL

Enstitü Müdürü

BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI
ETİK BEYANI

Bandırma Onyedi Eylül Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre hazırlamış olduğum **“Dinlenme Durumunda Elektroensefalografi (EEG) Alfa Frekansı Üzerinden Biyometrik Tanımlama ve Kimlik Doğrulama”** adlı tezimin özgün bir çalışma olduğunu, tez hazırlanırken tüm aşamalarda bilimsel etik ilkelerine uygun davrandığımı, tez kapsamında sunulan tüm verileri bilimsel etik ilkelerine uygun elde ettiğimi, tezde faydalandığım tüm eserlere atıf yaptığımı ve kaynaklar kısmında bu eserleri gösterdiğimi beyan ederim. 12/01/2024

Hazim ÖZTÜRK

ÖNSÖZ

Kişilerin benzersiz özelliklerini taşıyan biyolojik sinyaller son yıllarda kimlik doğrulama ve tanımlama sistemlerinde sıklıkla kullanılmaktadır. Günümüzde, biyolojik sistemlerin bankacılık işlemlerinde, havaalanı güvenliğinde, hastalık teşhisi ve dijital cihazların güvenliği gibi alanlarda yaygın olarak kullanıldığı görülmektedir. Bu alanlarda kullanılan en yaygın biyolojik sinyaller parmak izi, yüz, avuç içi ve iris tanımadır. Ancak bu sinyallerin durağan olmaları, kullanıldığı sistemlerde bilgilerin çalınma ve kopyalanma gibi dezavantajları sebebiyle güvenlik açığı bulunmaktadır. Bu dezavantajların önüne geçebilmek, güvenilir ve güvenli bir biyometrik tanımlama ve kimlik doğrulama için kişiye özgü beyin sinyallerinden yararlanılmaktadır. Bu tez çalışmasında, EEG alfa frekansı kullanılarak biyometrik tanımlama ve kimlik doğrulama üzerine bir çalışma gerçekleştirilmiştir.

Bu tez çalışması sırasında, tez konusunun belirlenmesinden başlayarak son aşamaya kadar bana her konuda yardımcı olan danışman hocam Sayın Dr. Öğr. Üyesi Kutlucan GÖRÜR'e, bu günlere gelmemde büyük emekleri bulunan ve destekleriyle her zaman yanımda olan annem Ümmügül ÖZTÜRK ve babam Mehmet ÖZTÜRK'e teşekkürlerimi sunarım.

ÖZET

YÜKSEK LİSANS TEZİ

DİNLENME DURUMUNDA ELEKTROENSEFALOGRAFİ (EEG) ALFA FREKANSI ÜZERİNDEN BİYOMETRİK TANIMLAMA VE KİMLİK DOĞRULAMA

Hazim ÖZTÜRK

Bandırma Onyedli Eylül Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Kutlucan GÖRÜR

Ocak 2024, 91 sayfa

Biyometrik tanımlama ve kimlik doğrulama bir bireyin fiziksel ve davranışsal özelliklerini inceleyerek kişinin tanımlanması ve diğer kişilerden ayırt edilmesini sağlayan sistemlerdir. Gelişen teknolojinin sunduğu imkanlar doğrultusunda biyometrik tanımlama ve kimlik doğrulama sistemlerinin uygulama alanları ve bu konuda yapılan bilimsel çalışmalar her geçen gün artmaktadır. Biyometrik tanımlama ve kimlik doğrulama çalışmalarında kullanılan en yaygın biyolojik sinyaller parmak izi, yüz tanıma ve iris tanımadır. Bu sistemlerde canlılık tespitinin yapılamaması, yanıltılmalarının kolay olması ve aynı kalitede verinin alınamaması gibi dezavantajlarının üstesinden gelebilmek için farklı bir biyometrik yaklaşım olan beyin sinyallerine yönelinmiştir. Elektroensefalogram (EEG) kafa derisine bağlanan elektrotlar yardımıyla beyinde oluşan elektriksel aktiviteyi kayıt altına alınmasını sağlayan yöntemdir. Dinlenme durumunda yüksek güce sahip olan EEG alfa sinyalleri 8-13 Hz frekans bandında olup, kişilerin bilinçaltıyla ilişkilidir. Dinlenme durumunda elde edilen EEG sinyalleri bu frekans aralığında genlik ve sinyal gürültü oranı açısından yüksek bir değere sahiptir. EEG sinyallerinin kayıt sürecinde, kişilerden düşünsel ve uzuvsal eylem gerektirmeden dinlenme durumuna

geçilmesi istendiğinden bu durumda oluşan sinyaller beynin daha çok parietal ve oksipital bölgelerinde görülmektedir.

Bu çalışmada, dinlenme durumunda EEG alfa frekansı kullanılarak biyometrik tanımlama ve kimlik doğrulama uygulamaları gerçekleştirilmiştir. Veri setinde saniyede 512 Hz örnekleme frekansı kullanılarak yirmi kişiye ait EEG sinyalleri elde edilmiştir. Çalışmada uygulanan normalizasyon işlemi sonrası EEG veri seti 0-1 aralığındaki değerlere indirgenmiştir. Biyometrik tanımlama ve kimlik doğrulama için EEG alfa frekanslı sinyallere makine ve derin öğrenme modelleri uygulanmıştır. Biyometrik tanımlama ve kimlik doğrulama çalışmalarının performanslarının değerlendirilmesi için ise en yaygın performans metrikleri incelenmiştir. Biyometrik tanımlama çalışmasında, farklı örneklemeli derin öğrenme modellerinin performansı araştırılmış ve karşılaştırılmıştır. Biyometrik kimlik doğrulama çalışmasında ise yalnız iki kanal verisi üzerinden performans metrikleri değerlendirilmiştir. Tanımlama ve kimlik doğrulama çalışmalarının sonuçlarına bakıldığında tahmin performanslarının ve doğruluk değerlerinin oldukça yüksek olduğu görülmektedir. Bu çalışma ile düşük maliyetli, kullanımı kolay ve güvenilir bir biyometrik tanımlama ve kimlik doğrulama sistemi önerilmiştir.

Anahtar kelimeler: Dinlenme Durumu Alfa Frekansı, EEG, Makine Öğrenmesi, Biyometrik Tanımlama, Biyometrik Kimlik Doğrulama

ABSTRACT

M.Sc. THESIS

BIOMETRIC IDENTIFICATION AND AUTHENTICATION VIA RESTING STATE ELECTROENCEPHALOGRAPHY (EEG) ALPHA FREQUENCY

Hazim ÖZTÜRK

Bandırma Onyedi Eylül University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Supervisor: Asst. Prof. Dr. Kutlucan GÖRÜR

January 2024, 91 pages

Biometric identification and authentication are systems that enable an individual to be identified and distinguished from other individuals by examining their physical and behavioral characteristics. In line with the opportunities offered by developing technology, the application areas of biometric identification and identity verification systems and scientific studies on this subject are increasing day by day. The most common biological signals used in biometric identification and authentication studies are fingerprint, facial recognition and iris recognition. In order to overcome the disadvantages of these systems, such as not being able to detect liveness, being easy to mislead, and not being able to get the same quality data, a different biometric approach, brain signals, has been used. Electroencephalogram (EEG) is a method that allows recording the electrical activity in the brain with the help of electrodes attached to the scalp. EEG alpha signals, which have high power at rest, are in the 8-13 Hz frequency band and are associated with people's subconscious. EEG signals obtained at rest have a high value in terms of amplitude and signal-to-noise ratio in this frequency range. During the recording process of EEG signals, people are asked to go into a resting state without requiring mental and limb actions, and the signals formed in this state are seen mostly in the parietal and occipital regions of the brain.

In this study, biometric identification and authentication applications were carried out using EEG alpha frequency at rest. In the data set, EEG signals of twenty people were obtained using a sampling frequency of 512 Hz per second. After the normalization process applied in the study, the EEG data set was reduced to values in the range of 0-1. Machine and deep learning models have been applied to EEG alpha frequency signals for biometric identification and authentication. The most common performance metrics were examined to evaluate the performance of biometric identification and authentication studies. In the biometric identification study, the performance of different sampling deep learning models was investigated and compared. In the biometric authentication study, performance metrics were evaluated using only two channel data. When the results of the identification and authentication studies are examined, it can be seen that the prediction performances and accuracy values are quite high. In this study, a low-cost, easy-to-use and reliable biometric identification and authentication system is proposed.

Keywords: Resting State Alpha Frequency, EEG, Machine Learning, Biometric Identification, Biometric Authentication

İÇİNDEKİLER

	Sayfa
ÖZET	I
ABSTRACT	III
İÇİNDEKİLER.....	V
ŞEKİL LİSTESİ	VII
TABLO LİSTESİ.....	IX
SİMGE VE KISALTMA LİSTESİ.....	X
1. GİRİŞ.....	1
2. EEG SİNYAL ELDE EDİNİMİ VE EEG SİNYAL ÖZELLİKLERİ.....	15
2.1 Elektroensefalografi (EEG)	15
2.2 Beyin Lobları ve İşlevleri	16
2.3 10-20 Elektrot Sistemi	17
2.4 Veri Seti ve Elektrot Yerleşimi	18
3. SİNYAL İŞLEME YÖNTEMLERİ.....	20
3.1 Normalizasyon.....	20
3.2 Temel Bileşen Analizi (PCA)	21
3.3 Bağımsız Bileşen Analizi (ICA)	22
3.4 Ampirik Mod Ayrışımı (EMD).....	24
3.5 Ayrık Dalgacık Dönüşümü (DWT)	26
3.6 Minimum Fazlalık Maksimum Uygunluk (MRMR)	28
3.7 Relief (R).....	30
3.8 Hızlı Fourier Dönüşümü (FFT)	31
3.9 Güç Spektral Yoğunluğu (PSD).....	32
3.10 Sürekli Dalgacık Dönüşümü (CWT).....	32
4. MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE PERFORMANS KRİTERLERİ	35

4.1	Uzun Kısa Süreli Bellek (LSTM).....	36
4.2	Geçitli Tekrarlayan Birim (GRU).....	37
4.3	İki Yönlü Uzun Kısa Süreli Bellek (BiLSTM).....	37
4.4	Bir Boyutlu Evrişimli (Konvolüsyonel) Sinir Ağı (1D-CNN).....	38
4.5	Karar Ağaçları (DT).....	41
4.6	Doğrusal Ayırma Analizi (LDA)	43
4.7	k-Kat Çapraz Doğrulama	43
4.8	Performans Metrikleri	44
5.	ANALİZ VE BULGULAR.....	46
5.1	Biyometrik Tanımlama Çalışması.....	46
5.2	Biyometrik Kimlik Doğrulama Çalışması	62
6.	SONUÇ VE ÖNERİLER	80
7.	KAYNAKLAR.....	81
	ÖZGEÇMİŞ	91

ŞEKİL LİSTESİ

<u>Sekil</u>	<u>Sayfa</u>
Şekil 1-1: Biyometrik tanımlama ve doğrulama sistemlerine ait blok diyagram	12
Şekil 1-2: Biyometrik kimlik doğrulama modellerinin kategorizasyonu	13
Şekil 1-3: Biyometrik tanımlama sistemine ait blok diyagram	14
Şekil 2-1: Beyin lobları ve işlevleri	17
Şekil 2-2: Uluslararası 10-20 elektrot sistemi	18
Şekil 2-3: Veri kaydı için deneysel düzen	19
Şekil 3-1: Özellik çıkarma yöntemleri	20
Şekil 3-2: PCA yöntemi ile boyut azaltma işlemi	22
Şekil 3-3: İki ses sinyaline ait karışımın ICA yöntemi ile ayrıştırılması	23
Şekil 3-4: DWT ile 1 boyutlu sinyalin 3 oktava ayrıştırılması	27
Şekil 3-5: EEG frekans alt bantları için 5 seviyeli dalgacık ayrıştırma süreci	28
Şekil 4-1: Yapay zeka, makine öğrenmesi ve derin öğrenme arasındaki ilişki	35
Şekil 4-2: LSTM mimari iç yapısı	36
Şekil 4-3: GRU mimari iç yapısı	37
Şekil 4-4: BİLSTM mimari iç yapısı	38
Şekil 4-5: Evrişimli sinir ağına ait temel katmanlar	38
Şekil 4-6: Tipik bir evrişimli sinir ağının kapsamlı iç yapısı	39
Şekil 4-7: 1D-CNN şematik gösterimi	40
Şekil 4-8: 1D-CNN'de sınıf ve katlara ait değerlerin gösterimi	41
Şekil 4-9: Karar ağaçları blok diyagramı	42
Şekil 4-10: Üç kat çapraz doğrulamaya ait şema	44
Şekil 4-11: Karışıklık matrisine ait şema	45
Şekil 5-1: 1-2 kişilerine ait çok kanallı EEG sinyalleri	46
Şekil 5-2: 3-8 kişilerine ait çok kanallı EEG sinyalleri	47
Şekil 5-3: 9-14 kişilerine ait çok kanallı EEG sinyalleri	48
Şekil 5-4: 15-20 kişilerine ait çok kanallı EEG sinyalleri	49
Şekil 5-5: Dinlenme durumu EEG alfa frekansında 20 kişiye ait beyin haritası sonuçları ..	51
Şekil 5-6: Dinlenme durumunda EEG alfa frekansında yirmi kişiye ait CWT zaman- frekans analizi sonuçları	52

Şekil 5-7: 1-6 kişilerine ait dinlenme durumunda EEG alfa frekansında güç spektrum yoğunluğu (PSD) grafikleri.....	53
Şekil 5-8: 7-12 kişilerine ait dinlenme durumunda EEG alfa frekansında güç spektrum yoğunluğu (PSD) grafikleri.....	54
Şekil 5-9: 13-18 kişilerine ait dinlenme durumunda EEG alfa frekansında güç spektrum yoğunluğu (PSD) grafikleri.....	55
Şekil 5-10: 19-20 kişilerine ait dinlenme durumunda EEG alfa frekansında güç spektrum yoğunluğu(PSD) grafikleri.....	56
Şekil 5-11: 20 kişiye ait ham veri seti üzerinden farklı örnekleme frekanslı t-SNE biyometrik tanımlama saçılım grafikleri.....	57
Şekil 5-12: 20 kişiye ait ICA uygulanmış veri seti üzerinden farklı örnekleme frekanslı t-SNE biyometrik tanımlama saçılım grafikleri.....	58
Şekil 5-13: Biyometrik tanımlama performans sonuçlarına ait karşılaştırmalı grafiği	59
Şekil 5-14: 20 kişiye ait dinlenme durumu EEG alfa frekansı için biyometrik kimlik doğrulamada t-SNE saçılım grafikleri (Bir kişinin diğer kişilerden ayırt edilmesi / The One-versus-The Others).....	63
Şekil 5-15: 20 kişiye ait elektrot konumlarıyla ilgili her bir katılımcı için benzersiz korelasyon matrisi modelleri	64
Şekil 5-16: Ham veri sinyalleri ve ICA yöntemi uygulanmış sinyallere ait recurrence plot sonuçları	65
Şekil 5-17: Ham veri sinyalleri ve ICA yöntemi uygulanmış sinyallere ait Manova gruplama yöntemi ile biyometrik ayırım grafikleri	66
Şekil 5-18: Ham veri ve ICA yöntemi uygulanmış sinyaller için P7-P8 kanallarına ait olasılık yoğunluk dağılım grafikleri.....	67
Şekil 5-19: 1. Kişiye ait 3-fold karmaşıklık matrisi ve çapraz doğrulama ROC grafikleri..	69
Şekil 5-20: 1. Kişiye ait performans metrikleri sonuç grafiği	70
Şekil 5-21: 1. Katılımcıya ait AUC grafiği.....	70
Şekil 5-22: 20 kişinin biyometrik kimlik doğrulamasında ACC doğruluk grafiği.....	76
Şekil 5-23: 20 kişinin biyometrik kimlik doğrulamasında SENS duyarlılık grafiği	76
Şekil 5-24: 20 kişinin biyometrik kimlik doğrulamasında SPEC özgüllük grafiği	77
Şekil 5-25: 20 kişinin biyometrik kimlik doğrulamasında PREC kesinlik grafiği	77
Şekil 5-26: 20 kişinin biyometrik kimlik doğrulamasında F-score grafiği.....	78
Şekil 5-27: 20 kişinin biyometrik kimlik doğrulamasında AUC grafiği.....	78

TABLO LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 2-1: Farklı frekans değerlerine ait EEG sinyalleri.....	15
Tablo 2-2: EEG kanallarına ait elektrot dizilimi ve yerleşimi	19
Tablo 3-1: Temel relief algoritmasına ait pseudo kod.....	31
Tablo 4-1: 1D-CNN'de veri işlemede kullanılan mimari yapı.....	41
Tablo 5-1: EEG alfa frekansında yirmi kişinin RNN yöntemleri ile biyometrik tanımlama sonuçları	59
Tablo 5-2: 20 kişiye ait biyometrik tanımlamada karar ağaçları yöntemi sonuçları.....	60
Tablo 5-3: 20 kişiye ait biyometrik tanımlamada MRMR yöntemi sonuçları.....	60
Tablo 5-4: 20 kişiye ait biyometrik tanımlamada Relief yöntemi sonuçları	61
Tablo 5-5: 20 kişiye ait biyometrik tanımlamada EMD yöntemi sonuçları.....	61
Tablo 5-6: 20 kişiye ait biyometrik tanımlamada LDA yöntemi sonuçları.....	61
Tablo 5-7: 20 kişiye ait biyometrik tanımlamada DWT yöntemi sonuçları.....	62
Tablo 5-8: Ardışıl elektrot dizilimi	66
Tablo 5-9: 1-5 katılımcının DWT'de alfa frekansına ayrılmış alt sinyallere ait 1D-CNN kimlik doğrulama sonuçları (one-versus-others authentication)	72
Tablo 5-10: 6-10 katılımcının DWT'de alfa frekansına ayrılmış alt sinyallere ait 1D-CNN kimlik doğrulama sonuçları (one-versus-others authentication)	73
Tablo 5-11: 11-15 katılımcının DWT'de alfa frekansına ayrılmış alt sinyallere ait 1D-CNN kimlik doğrulama sonuçları (one-versus-others authentication)	74
Tablo 5-12: 16-20 katılımcının DWT'de alfa frekansına ayrılmış alt sinyallere ait 1D-CNN kimlik doğrulama sonuçları (one-versus-others authentication)	75

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
V	: Volt
Hz	: Hertz
μ	: Mikro
γ	: Gama
β	: Beta
α	: Alfa
θ	: Teta
δ	: Delta
f	: Frekans
db	: Desibel
i_t	: Giriş Kapısı
o_t	: Çıkış Kapısı
b	: Sapma Değeri
f_t	: Unutma Kapısı
W	: Ağırlık Vektörü
h_{t-1}	: Nöronların Çıkışı
σ	: Sigmoid Aktivasyon Fonksiyonu

Kisaltmalar	Açıklama
R	: Relief (Relieff)
F	: F Puanı (F-Score)
PREC	: Kesinlik (Precision)
ACC	: Doğruluk (Accuracy)
SPEC	: Özgüllük (Specificity)
SENS	: Duyarlılık (Sensitivity)
TP	: Doğru Pozitif (True Positive)
FP	: Yanlış Pozitif (False Positive)
TN	: Doğru Negatif (True Negative)
DT	: Karar Ağaçları (Decision Tree)
FN	: Yanlış Negatif (False Negative)

DL	: Derin Öğrenme (Deep Learning)
AI	: Yapay Zeka (Artificial Intelligence)
MI	: Motor Görünlülere (Motor imagery)
AGF	: Alçak Geçiren Filtre (Low pass filter)
ML	: Makine Öğrenmesi (Machine Learning)
EKG	: Elektrokardiyografi (Electrocardiography)
PPG	: Fotopletismografi (Photoplethysmography)
TAR	: Doğru Kabul Oranı (True Acceptance Rate)
FAR	: Yanlış Kabul Oranı (False Acceptance Rate)
AUC	: Eğri Altındaki Alan (Area Under The Curve)
EEG	: Elektroensefalografi (Electroencephalography)
FFT	: Hızlı Fourier dönüşümü (Fast Fourier Transform)
GRU	: Geçitli Tekrarlayan Birim (Gated Recurrent Unit)
RNN	: Yinelenen Sinir Ağları (Recurrent Neural Network)
CNN	: Erişimli Sinir Ağı (Convolutional Neural Network)
PSD	: Güç Spektrum Yoğunluğu (Power Spectral Density)
ERP	: Olaya İlişkin Potansiyeller (Event Related Potentzials)
BCI	: Beyin-Bilgisayar Arayüzü (Brain-Computer Interface)
LDA	: Doğrusal Ayırma Analiz (Lineer Diskriminant Analiz)
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
DFT	: Ayırık Fourier Dönüşümü (Discrete Fourier transform)
EMD	: Ampirik Mod Ayrışımı (Empirical Mode Decomposition)
DWT	: Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform)
ICA	: Bağımsız Bileşen Analizi (Independent Component Analysis)
CWT	: Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)
ROC	: Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
STFT	: Kısa zamanlı Fourier Dönüşümü (Short Time Fourier Transform)
BİLSTM	: İki Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short Term Memory)
1D-CNN	: Bir Boyutlu Evrişimli Sinir Ağı Modeli (1D Convolutional Neural Network)
MOFPA	: Çok Amaçlı Çiçek Tozlaşması Algoritması (multi-objective Flower

	Pollination Algorithm)
FSST	: Fourier Eşzamanlı Sıkıştırılmış Dönüşüm (Fourier Synchrosqueezed Transform)
MRMR	: Minimum Fazlalık Maksimum Uygunluk (Minimum Redundancy Maximum Relavance)
SSVEP	: Kalıcı durum görsel potansiyel (Steady state visual evoked potential)



1. GİRİŞ

Biyometrik tanımlama ve kimlik doğrulama sistemleri kişilerin karakteristik özelliklerini kullanarak diğer kişilerden ayırt edilebilmesini sağlayan sistemlerdir. Modern yaşamda duyulan ihtiyaçlar ve son yıllarda teknolojinin gelişmesiyle sunulan imkanlar sayesinde biyometrik tanımlama ve kimlik doğrulama sistemlerinin popülerliği her geçen gün artmaktadır. Biyometrik tanımlama ve doğrulama sistemlerinin gündelik yaşamda en çok rastlanılan uygulamaları retina, yüz ve parmak izinin kullanıldığı sistemlerdir [1]. Biyometrik kimlik doğrulama ve tanımlama sistemleri insan beyninin çalışmasına benzer özellikler göstererek kişileri tanıyabilmekte ve diğer kişilerden ayırt edebilmektedir. Biyometrik tanımlama ve doğrulama sistemleri genelde havalimanı kontrol noktaları, adli tıp, bankacılık, dijital platformlara giriş ve diğer güvenlik sistemleri gibi geniş bir uygulama alanına sahiptir. Bu sistemler yüksek doğruluk ve uygulama kolaylığına sahip olması gibi avantajları nedeniyle tercih edilirken, her zaman aynı kalitede verinin elde edilememesi, canlılık tespitinin yapılamaması ve yanıltılabilmesi gibi dezavantajlarından dolayı farklı biyometrik kimlik doğrulama ve tanımlama sistemlerine ihtiyaç duyulmaktadır. Bu nedenle canlılık durumunun gözlemlenebildiği, kişiye özgü benzersiz özelliklere sahip elektroensefalografi (EEG) sinyallerinin kullanıldığı biyometrik tanımlama ve kimlik doğrulama sistemleri tercih edilmeye başlanmıştır. Farklı frekanslardan oluşan EEG sinyalleri statik olmayan, dinamik ve kişiye özel karakteristik özelliklere sahiptir. EEG sinyalleri bir bireyin kimliğini ve benzersiz davranışlarını tanımlayan nitelikleri ortaya çıkarmaktadır. EEG beyindeki nöral aktivitenin dinamik ve invazif olmayan bir formu olup düşük maliyet, taşınabilirlik ve kullanım kolaylığı gibi avantajlarından dolayı biyometrik tanımlama ve kimlik doğrulama uygulamalarında sıklıkla kullanılmaktadır. İnsan beyninin morfolojik, anatomik yapısı ve işlevsel özelliklerini taşıyan EEG sinyallerinin benzersiz ve dinamik özellikleri, bireylerin birbirlerinden ayrıştırılmasında oldukça etkili yetenek sunmaktadır. Bu nedenle EEG ile gerçekleştirilen biyometrik yaklaşımların canlılık tespiti, taklitçi girişim tehdidine karşı yüksek doğrulama kapasitesi ve güvenilirlik dahil olmak üzere birçok avantajı bulunmaktadır [2]. EEG sinyallerinden elde edilen alfa dalgalarının frekans bandı 8-13 Hz aralığında yer almaktadır [3] [4]. Dinlenme durumundaki EEG sinyallerinin alfa frekanslı bileşeni diğer frekanslı bileşenlere oranla daha baskın olması nedeniyle biyometrik tanımlamada ve kimlik doğrulama çalışmalarında alfa frekansının kullanılmasıyla daha başarılı sonuçların elde edilebileceği düşünülmektedir. Literatürde dinlenme durumunda elde edilen EEG sinyallerinin alfa frekans bandının kullanıldığı sınırlı sayıda çalışma bulunmaktadır. Genellikle görsel

uyarımli potansiyeller ve uzuvsal hareket dūşūnseli ūzerinden gerēekleřtirilen EEG tabanlı biyometrik ēalıřmalara yoęunlařılmıřtır. Bu yōntemler iēin kullanılacak sinyallerin elde edilme ařamasında yūkksek dikkat ve kompleks deneysel dūzen gerektirmesi gibi dezavantajları bulunmaktadır [5], [6], [7], [8]. EEG alfa frekansı ile yapılan deneysel dūzende ise kiřiler dinlenme durumunda oldukları iēin yani kiřilerden herhangi bir dūřūnce eylemi iēerisine girmesi ya da herhangi bir hareketssel faaliyette bulunması istenmedięinden dolayı veriler oldukēa kolay bir řekilde toplanabilmektedir. Gōzlerin kapalı olduęu dinlenme durumunda beynin parietal ve oksipital loblarında oluřan EEG alfa frekanslı sinyaller beynin dięer loblarında oluřan sinyallere gōre oldukēa yūkksek bir gūce sahiptir [9] [10], [11], [12]. İnsan beyninde oluřan EEG sinyalleri kiřiden kiřiye deęiřen bir sinyal ōrūntūřune sahiptir. Bir bařka deyiřle her kiřide karakteristlik bir EEG alfa frekanslı sinyal oluřmaktadır. Gōrme ile iliřkili oksipital lobta gōzler kapalı olsa dahi bir sinyal oluřabildięi gōrūlebilmektedir. Bunun nedeni ise beyinde oluřan būtūn sinyallerin beynin kortikal lobundaki talamus bōlgesinden aktarılması ve bu bōlgenin hafıza ile iliřkili olmasıdır. Őzetle gōzlerin kapalı olduęu dinlenme durumunda kiřiler uyanık olduklarından dolayı kiřilerin hafızasını kullanarak bir dūřūnsel veya gōrsel eylemin iēine girmesi oksipital lobta yūkksek gūēlū bir sinyal oluřması iēin yeterlidir. Benzer řekilde beynin parietal lobu da hafıza ve algılama ile iliřkili olduęundan dolayı dinlenme durumunda iken oksipital lobda olduęu gibi parietal lobta da yūkksek gūēlū bir EEG alfa frekanslı sinyal oluřtuęu gōrūlmektedir [4] [13]. Bu ēalıřmada farklı zaman dilimli yirmi kiřiden alınan EEG alfa frekanslı sinyaller ūzerinden makine ve derin ōęrenme modelleri kullanılarak biyometrik tanımlama ve kimlik doęrulama ēalıřması gerēekleřtirilmiřtir. Ayrıca biyometrik tanımlama ēalıřmasında kullanılan derin ōęrenme modellerinin etkinlięi ve performansı arařtırılmıřtır. Biyometrik kimlik doęrulama ēalıřmasında ise kanal sayısının azaltılarak sadece iki kanaldan alınan veriler ūzerinden bir performans deęerlendirilmesi gerēekleřtirilmiřtir. ēalıřmanın amacı ēeřitli uygulama alanlarında kullanılabilecek, dūřūk maliyetli, gūvenilir ve gūvenlikli bir biyometrik tanımlama ve kimlik doęrulama sistemine ulařılmasıdır.

Gōrūr ve arkadařları ēalıřmalarında uzun kısa zamanlı hafıza (LSTM) derin ōęrenme modelini kullanarak motor gōrūntū (MI) sinyalleri ūzerinden FSST-ICA tabanlı EEG biyometrik kimlik doęrulama yaklařımını incelemiřlerdir. ēalıřmada EEG sinyalleri zaman-frekans (tf) ōzellik ēıkarımı gerēekleřtirebilmek iēin Fourier senkronize sıkıřtırılmıř dōnūřūm (FSST) iřlemi gerēekleřtirilmiřtir. FSST yōntemi zaman-frekans alanında gōrūntūsel ōzelliklere sahip dinamik ve duraęan olmayan EEG sinyallerinin iēin uygun olduęu gōzlenmiřtir. EEG sinyallerini ayırıřtırmak iēin baęımsız bileřen analizi (ICA) kullanılmıř performans ve doęruluk oranın

arttırılmaya yönelik ise Doğruluk kabul oranı (TAR), Yanlış Kabul oranı (FAR) kullanılmıştır. Biyometrik kimlik doğrulama sonuçlarına bakıldığında 7 kişi arasında “bire karşı diğerleri” MI-EEG (<30Hz) ham ve alt sinyallerden yüksek ortalama doğruluk (99,54%), duyarlılık (99,81%) ve özgüllük (99,41%) oranında oldukça başarılı sonuçların elde edildiği gözlenmiştir. Ayrıca TAR değeri (97,8%) ve FAR (0%) sonuçları çoklu denemelerde başarılı olduğu görülmektedir. Literatürde LSTM derin öğrenmesini kullanan biyometrik yaklaşım için ise FSST-ICA çerçevesinde mevcut literatürde çalışmanın daha önce yapılmadığı ve katkı sağlandığı gözlenmektedir. Bu yaklaşım ile oldukça düşük maliyetli ve güvenilir biyometrik tanımlama sistemi sunulmaktadır [2].

Kavsaoglu tez çalışmasında PPG sinyallerini kullanarak biyometrik kimlik tanımlama konusunda çalışma gerçekleştirmiştir. Çalışmada PPG sinyallerin temaslı ve temassız elde edilmesi iki farklı şekilde inceleme yapılarak tanımlama doğrulukları karşılaştırılmıştır. İlk olarak PPG sinyalleri otuz kişinin parmak ucunun cihaza bağlanması vasıtasıyla iki farklı zaman periyodunda alınarak elde edilmiştir. Bu alım sonrası 87.22%'lik bir doğruluk görüldüğü özellik sıralama ve seçme modelinin 3% oranında doğruluğu arttırdığı gözlemlenmiştir. Diğer yapılan çalışmada beş kişiden iki farklı zaman periyodunda temaslı ve temassız PPG sinyalleri aynı anda elde edilmiştir. Temaslı ve temassız olarak alınan sinyaller karşılaştırılarak tanımlama doğrulukları test edilmiştir. Bu çalışma sonucunda ise parmak ucundan alınan sinyaller ile yapılan çalışmanın 99.33% kamera ile elde edilen sinyallerde ise 84.66% sınıflandırma doğruluğu elde edilmiştir. PPG sinyallerin ön işlemez ham sinyallerde M tepe noktalarının tespiti için Tepe algılama algoritması olarak ASTA ve özellik sıralama için ise en iyiden başarısız sayılabilecek sıralama yapabilen uzaklık temelli denetimli özellik sıralama algoritması DBSFRA kullanılmıştır. Burada 1.38dk işlem süresi 88.11% doğruluk, işlem süresinin 5.56 dk olması durumunda ise doğruluk oranının 89% olduğu gözlenmiştir. DBSFRA ve sıralı özellik seçme algoritmasının birlikte kullanılması ile işlem süresinde ve doğruluk oranında katkı sağladığı görülmüştür [14].

Moctezuma ve arkadaşları çalışmalarında dinlenme durumundaki EEG sinyallerine dayalı bir biyometrik tanımlama önermişlerdir. Sinyallerin özelliklerini seçmek için öncelikle DWT ve EMD metotları kullanılmıştır. 109 kişiden dinlenme durumlarında gözler açık ve kapalı bulunduğu anlarda alınana görüntü verilerinde test edilmiştir. 64 elektrottan alınan 100% bir tar ve 99.8% trr elde edilmiştir. DWT yöntemi ile kanal sayısı üçe düşürülmüş ve gözlerin açık olduğu durumda 99.3% tar ve 94.1% trr elde edilmiştir. Gözler kapalı durumunda ise 99.7% tar ve 95% oranında trr elde edilmiştir. Çalışma sonucunda LOF, DWT ve EMD gibi yöntemler

kullanarak kanal sayılarının bir ila üç arasına düşürülse bile bir kişinin diğer yüz sekiz kişiden ayırt edilebilmesinde 90%' ın üzerinde bir başarı sağlandığını göstermiştir [15].

Yang ve arkadaşları çalışmalarında biyometrik tanıma için yeni bir özellik çıkarma ve elektrot yerleşiminin performansa etkisi incelenmiştir. Özellik çıkarma yöntemi ham EEG sinyali dalgacık dönüşümüne dayanmaktadır. Ayrıca logaritmik dalgacık katsayıları ayırık kosinüs dönüşümü (DCT) yöntemle işlenmiştir. Dalgacık bandından elde edilen veriler sınıflandırma için özellik vektörlerini oluşturulmak üzere kullanılır. Elektrot konumlarının kişi tanıma üzerine etkinliği araştırılmış ve performans arttırmak için elektrot konumlandırılması önerilerinde bulunulmuştur. Bu öneride hem doğrulama ve tanımlama senaryoları incelenmiştir. EEG motor hareket/görüntü seti (MM/I) ve UCI veri seti kullanılarak 98.24% ve 93.28%'lik tanımlama sonuçları elde edilmiştir. Eğitim ve test zaman ayırımının etkisi şablon yaşlanasını simüle etmek için EEG verileri ile de incelenmiştir. Diğer yöntemlere karşılaştırıldığında daha iyi performans göstermiştir [16].

Jyotishi ve arkadaşları, EKG sinyalleriyle derin öğrenme algoritmalarından uzun ve kısa süreli bellek (LSTM) yönteminden yararlanarak kişi tanımlaması için bir çalışma yapmışlardır. Model hem atım hem de atımlar arası değişimleri dikkate alarak EKG sinyallerini incelemektedir. Farklı zaman dilimlerinde elde edilen sinyallerin kişi tanımlama doğruluğu üzerindeki etkisi incelenmiştir. Modelin etkinliği PTB, MIT-BIH aritmi veri tabanı, ECG-ID ve CYBHi olmak üzere dört veri tabanı üzerinde kapsamlı bir şekilde test edilmiştir. PTB veri tabanındaki 290 denek için 97.3%'lük, CYBHi için 79.37% doğruluk elde edilmiştir. Diğer veri tabanları ise ECG-ID 93.11% MIT-BIH 96.81% sonuçlar elde edilmiştir [17].

Üçüncü, EEG tabanlı biyometrik kimlik tanımlama çalışmasında k-en yakın komşuluk algoritmasını kullanılmıştır. İlk çalışmasında bilgisayar imleci hareketleri sırasında kişilerin EEG verileri alınmış ve bu veriler kullanılarak biyometrik kimlik tanımlama çalışması gerçekleştirilmiştir. EEG sinyallerinin sınıflandırma işleminde k-en yakın komşuluk algoritması kullanılmıştır. Üç kişinin kimliği yukarı, aşağı, sağ, sol yön komutları veri kümesi üzerinden doğrulanırken yukarı için 93.86%, aşağı için 98.25%, sağ için 96.49% ve sol için 98.18% sınıflandırma doğruluğu elde edilmiştir. Çalışmasının diğer bir uygulamasında ise dört yağın koklatılması sonucunda ortaya çıkan EEG sinyalleri üzerinden sekiz kişinin biyometrik tanımlama işlemi gerçekleştirmiştir. Aynı yöntem ile yapılan bir başka sınıflandırma çalışmasında ise nane için 93.88%, karanfil için 95.44%, kekik için 96.13% ve biberiye yağları için 96.63% oranında doğruluk elde edilmiştir [18].

Mao ve arkadaşları, çalışmasında derin öğrenme yöntemlerinden Konvolüsyonel Sinir Ağı (CNN) kullanarak EEG tabanlı yeni bir biyometrik tanımlama sistemi önermişlerdir. Çalışmada önerilen CNN yöntemi ile ham EEG verisi üzerinden doğrudan yapılan biyometrik tanımlamada işlemi gerçekleştirilebilmektedir. Sanal gerçeklik etkileşimli simüle edilmiş sürüş ortamında aracı otoyolda şeritte tutma uygulaması esnasında 8-12 sn aralığında araca sarsıntı verilmiş sürücünün tepki süresi, şerit sapma ve sürüş kaynaklı yorgunluğu inceleyen bir deney sırasında elde edilen yüz kişinin verisi kullanılarak çalışma gerçekleştirilmiştir. Bu çalışma sonucunda 97% oranında doğruluk elde edilmiştir [19].

Zhang ve arkadaşları, tek kanallı taşınabilir cihazla elde edilen EEG verisi üzerinden biyometrik kimlik tanımlama fizibilitesini incelemişlerdir. Tek kanallı (single-channel) EEG sınıflandırma işlemi etkin bir şekilde geliştirilmiştir. Özellik çıkarmada karma metot (zaman, frekans, zaman-frekans), özellik seçmede Rayleigh quotient, sınıflandırma tasarımı ise ensemble classifier kullanılmıştır. Kırk altı kişiden gözleri açık şekilde alınan dinlenme durumundaki EEG verisi ile 2 sn'de 95.48% oranında doğruluk oranına sahip bir doğrulama işlemi gözlenmiştir [20].

Smitha ve arkadaşları, kişilerin görsel veya işitsel olarak tanıdık ya da tanıdık olmayan uyarıcılara karşı verdiği beyinsel tepkiyi (EEG sinyali) inceleyerek bir biyometrik tanımlama sistemi sunmuşlardır. Önerilen biyometrik kimlik tanımlama sisteminde EEG sinyallerinin alfa, beta, gama bantlarının güç spektral yoğunluğu kullanılmaktadır. Ses uyarıları için gama bandının güç yoğunluk spektrumu kullanılırken görsel uyarılar için alfa ve beta bantlarının güç yoğunluk spektrumları kullanılmaktadır. Çevrimiçi kimlik doğrulama sistemi için beş kişi katılmış olup 79.73% oranında doğruluk olduğu gözlenmiştir. Ayrıca 13.91% Yanlış kabul oranı (FAR) ve 26.66% yanlış reddetme oranı (FRR) elde edilmiştir [21].

Alsumari ve arkadaşları, çalışmalarında düşük miktarda EEG verisi üzerinde konvolüsyonel sinir ağı (CNN) modelinin eğitilmesini ve değerlendirilmesini içeren sağlam ve verimli bir EEG tabanlı tanıma sistemi tasarlamışlardır. Çalışmalarını kamuya açık bir veri kümesi üzerinden 99%'luk bir doğruluk ve 0.187%'lik bir eşit hata oranlı kimlik doğrulama performansı elde etmişlerdir. Tasarladıkları sistem sadece iki EEG kanalına ihtiyaç duyulmakta ve 5 saniyelik kısa bir zamansal dilimi üzerinde çalışabilmektedir [22].

Thomas P. ve arkadaşları çalışmalarında 109 kişinin 64 kanallı EEG verisi üzerinden biyometrik kimlik tanımlama sistemi incelenmiştir. EEG bantları incelendiğinde gözler açık durumunda beta bandının diğer frekans aralığına göre dahi iyi doğrulama oranlarına sahip

olduğu gözlenmiş ve 98.31% oranında doğruluk oranında güç spektral yoğunluklu entropi özelliklerinin birleşimi sistem performansını arttırdığı gözlenmiştir [23].

Di ve arkadaşları çalışmalarında dinlenme durumunda gözler açık ve kapalı durumlarındaki EEG sinyalleri analiz edilerek bir karşılaştırma yapılmıştır. İki çalışma arasındaki zaman aralığı en az iki hafta olarak belirlenmiştir. Çalışmaya katılan on yedi kişi dinlene durumunda hem gözler açık hem de gözlerin kapalı olduğu durumda yer almıştır. Her çalışma için dört oturum düzenlenmiş olup her bir oturum 150 s sürmektedir. Özellik çıkarımı için spektral ve istatistiksel yöntemler kullanılmıştır. Sınıflandırma doğruluklarını elde etmek için Öklid mesafesi, SVM ve LDA olmak üzere üç sınıflandırıcıdan yararlanılarak her bir çalışma ve iki çalışmanın özellikleri arasındaki performansı karşılaştırılmıştır. Gözlerin açık ve kapalı olduğu durumlardaki güç spektrum yoğunlukları kişilerin seçilmesi ve ayırt edilebilme imkânı olduğunu göstermektedir. Sınıflandırma doğrulukları üç yöntem için bakıldığında 99% oranında bir başarı sağladığı gözlenmiştir [24].

Wilaiprasitporn ve arkadaşları çalışmalarında tekrarlayan sinir ağları (RNN) ve konvolüsyonel sinir ağları (CNN) kullanılarak kaskad yapıları derin öğrenme yaklaşımı sunmuşlardır. Çalışmada uzun kısa süreli bellek (LSTM) ve geçitli tekrarlayan birim (GRU) olmak üzere RNN'nin iki türü ele alınmıştır. Farklı duygusal durumlardan kişi tanımlamada CNN-GRU ve CNN-LSTM yöntemlerinde otuz iki kişi için ortalama 99.90%-100% doğru tanıma oranına ulaşabildiği görülmektedir. Çalışmada sunulan yöntemlerin güç spektral yoğunluğunu kullanan destek vektör makine temelli sistemlere oranla daha iyi performans sağladığı görülmüştür. Çalışmalarında EEG elektrot sayısının 32'den 5'e düşürülmesinden sonra bile önerdikleri modelin ön bölgeden elde edilen optimum sonucu koruyarak 99.17%'ye kadar doğru sonucu verdiği görülmüştür. Ayrıca çalışmalarında İki derin öğrenme modelinin CNN-GRU ve CNN-LSTM'nin benzer performans gösterdiği CNN-GRU'nun ise daha kısa eğitim süresi ile aynı performansı sağlayabildiği görülmüştür [25].

Thomas P. ve arkadaşları çevrimiçi bir Elektroensefalogram önermektedir. Dinlenme durumunda EEG sinyallerinin bant güç özelliklerini kullanarak bir biyometrik tanımlama sistemi önermişlerdir. Çevrimiçi biyometrik tanımlama için önerilen sistemde gözler açık ve kapalı durumlarındaki beyin aktivitesi işlenmiştir. Çalışmada 6 kişi ve 14 kanaldan elde edilen veriler doğrultusunda 88.33% oranında tanımlama doğruluğu sağlandığı görülmüştür [26].

Alyasseri ve arkadaşları çalışmalarında EEG sinyallerinde çok amaçlı çiçek tozlaşması algoritması ve dalgacık dönüşüm (MOFPA-WT) yöntemine dayalı bir kimlik tanımlama önerilmiştir. Çok amaçlı çiçek tozlaşması algoritması ve dalgacık dönüşümünü (MOFPA-WT)

EEG motor görüntü sistemi üzerinde kullanmışlardır. Çalışmada katılımcılara iki görev verilmiş birincisinde hedefin sağda veya solda olma durumuna göre yumruğu açıp kapaması istenmiş diğer görevde ise bu eylemi düşünsel olarak yapması istenmiştir. Birinci görevde on bir kişinin katılımıyla gerçekleştirilen biyometrik kimlik tanımlama uygulamasında en yüksek TAR oranı 90% en düşük TAR oranı ise 10% elde edilmiştir. İkinci görevde ise en yüksek TAR değeri 91.42% ve en düşük FAR 8.58% olarak sonuçların elde edildiği görülmektedir [27].

Ong ve arkadaşları biyometrik kimlik tanımlamada kullanılan EEG sinyalleri için güç spektral yoğunluğu analizini kullanarak biyometrik kişi tanımlaması gerçekleştirmişlerdir. Çalışmalarında sınıflandırıcı olarak k-en yakın komşuluk algoritması kullanılmıştır. EEG sinyallerinin farklı frekans bantlarının kişi tanımlamada kullanımını araştıran çalışmalarında yaptıkları karşılaştırmalı sonuçları kişi tanımlama için en uygun bant aralığında 8-40 Hz olduğu göstermiştir. Yaptıkları tüm karşılaştırmalı kişi tanımlama testlerinde 80% üzerinde bir doğruluk elde edildiği gözlenmiş ve en yüksek doğruluk oranı ise 89.21% olduğu görülmüştür [28].

Puengdang ve arkadaşları çalışmalarında bireylerin birbirinden ayırt edilebilmesi için kalıcı durum görsel potansiyel (SSVEP) ve olaya ilişkin potansiyel (ERP) kombinasyonu kullanırken biyometrik kimlik tanımlama için ise uzun kısa süreli bellek (LSTM) modeli kullanılmıştır. Çalışmada yirmi gönüllüden alınan 7.5 Hz'lik EEG sinyallerini dikkate alındığı biyometrik kimlik tanımlama çalışmasında 91.44% doğruluk oranına ulaşmışlardır [29].

Moctezuma ve arkadaşları elli altı kanallı EEG tabanlı beyin sinyalleri kullanılarak olayla ilişkili potansiyeller (EPR) üzerinden biyometrik kişi tanımlama çalışması gerçekleştirmişlerdir. Özellik çıkarma işlemi ampirik mod (EMD) ayrıştırması ile yapılmıştır. Özellik çıkarma işlemi için her kanaldan çıkan Minkowski mesafesine dayalı iki içsel mod fonksiyonu (IMF) kullanılmıştır. Her IMF için iki enerji özelliği (anlık ve teager enerjisi) ve iki fraktal özellik (Higuchi ve Petrosian fraktal boyut) olmak üzere toplam dört özellik hesaplanmıştır. Destek vektör makinesi (SVM) sınıflandırma performansını değerlendirmek amacıyla on katlı çapraz doğrulama aşamasında kullanılmıştır. EEG verisinin yüksek yoğunluğundan dolayı kanal sayısını azaltmak veya artırmak için yaygın olarak kullanılan ve bilinen geriye doğru eleme ve ileriye doğru ekleme açgözlü algoritmaları kullanılmıştır. Kanal sayısı azaltılsa bile uyguladıkları yöntemin kişi tanımlama için uygun olduğu görülmüştür. Çok kalabalık bir popülasyonda uygulanan beş kanalda biyometrik tanımlama çalışmasında 89% doğruluk oranı elde edilmiştir [30].

Rahman ve arkadaşları EEG tabanlı biyometrik kimlik tanımlama sistemlerinde doğruluk oranının arttırılmasına yönelik EEG ve tuş dokunuş dinamiklerinin birleştirilmesine dayalı yeni

bir çalışma gerçekleştirmişlerdir. On kişinin katılımı ile gerçekleşen uygulamada sinyaller eş zamanlı olarak hem EEG hem de tuş dokunuş dinamiği olarak elde edilmiş ve veri seti oluşturulmuştur. Çalışmada Sınıflandırma aşaması öncesinde çok alanlı özellik çıkarımı (zaman, frekans, zaman-frekans) gerçekleştirilmiştir. Özellik seçme işleminde ise Gini safsızlığı kullanılmıştır. Tanımlama ve kimlik doğrulama için iki farklı sınıflandırıcı kullanılmıştır. Bunlar Rastgele Orman sınıflandırıcı ve beş kat çapraz doğrulama sınıflandırıcısıdır. Bu iki farklı sınıflandırıcı ile yapılan biyometrik kimlik tanımlama işlemi için sırasıyla 99.9% ve 99.6% doğruluk oranları elde edilmiştir. Ayrıca çalışmalarında 6 kat daha hızlı 93.64% doğruluk sağlayan ikili şablon eşleştirme tabanlı bir algoritma geliştirilmiştir [31].

Fraiwan ve arkadaşları epilepsi hastalarında cerrahi işlemlerden çok önemli bir adım olan fokal ve fokal olmayan nöbet kaynağını otomatik olarak ayırt etmek amacıyla bir çalışma gerçekleştirmişlerdir. Çalışmalarında hastaların EEG sinyalleri incelenerek uzun kısa süreli bellek (LSTM) algoritması kullanan bir derin öğrenme yaklaşımıyla biyometrik kimlik tanımlama gerçekleştirilmiştir. Başlangıçta her kanal z-skor normalizasyonu ve Savitzky-Golay filtreleme işlemi kullanılarak ön işleme tabi tutulmuştur. Eğitim sürecinde BiLSTM algoritması kullanılmış ve sınıflandırma işlemi için sırasıyla 4, 6, 10 kat çapraz doğrulama kullanılarak tanımlama işlemi gerçekleştirilmiştir. Önerilen algoritmanın ile yapılan biyometrik kimlik tanımlamada Cohen's kappa değeri 99.20%, doğruluk 99.60%, duyarlılık 99.55% ve özgüllük 99.65% değerleri elde edilmiştir [32].

Yu ve arkadaşları biyometrik kimlik tanımlamada kullanılan EEG sinyalleri için konvolüsyonel sinir ağı (CNN) algoritmasının fizibilitesini incelemişlerdir. Özellikle kararlı durum görsel uyarılmış potansiyellerin (SSVEP) düşük frekans bileşenleri kullanılarak biyometrik tanımlama işlemi gerçekleştirilmiştir. CNN modelini optimize etmek amacıyla farklı parametre konfigürasyonları arasında ayırt edici özellikleri değerlendirilmiştir. Sekiz kişinin katılımıyla elde edilen çalışmada 97% oranında doğruluk elde edildiği görülmüştür [33].

Choi ve arkadaşları çalışmalarında dış uyaranlar kullanılmadan dinlenme durumundaki EEG sinyalleri üzerinden kimlik doğrulama işlemi gerçekleştirmişlerdir. Gözler açık ve kapalı iken alfa aktivitesindeki değişiklikler dikkate alınarak kişilere özel özellikler çıkarılmıştır ve her bir kişinin tanımlanması için çapraz korelasyon yöntemi kullanılmıştır. Yapılan biyometrik tanımlama çalışmasında 88.4% oranında doğruluk elde edildiği görülmüştür [34].

Sooriyaarachchi ve arkadaşları akıllı cihazlar için davranışsal bir biyometrik yöntem olarak müzik kaynaklı beyin dalga kalıplarını kullanan kimlik doğrulama çalışması gerçekleştirilmiştir. Çalışmada katılımcılara en sevdiği şarkı ve popüler bir İngilizce şarkı

dinletilerek EEG verileri elde edilmiş ve değerlendirilmiştir. Kullanıcı tanımlamasında dört kanal için 98% doğruluk elde edilirken kullanıcı doğrulaması için ise 97% oranında bir başarı elde edilmiştir. Tek kanallı yapılan çalışmada kullanıcı tanımlama doğruluğu 85% iken iki kanalla yapılan çalışmada ise 95% oranında başarı elde edildiği görülmektedir [35].

Seha ve arkadaşları kararlı durum İşitsel Uyarılmış Potansiyeller (AEP'ler) kullanılarak EEG tabanlı biyometrik kimlik tanımlama sistemi önerilmiştir. Beyin dalgalarının işitsel uyarılmış potansiyelleri sisteme iki adımlı kimlik doğrulama ve iptal edilebilirlik gibi ekstra özellikler katmaktadır. Kırk kişinin katıldığı uygulamada 40 Hz ve 80 Hz iki frekans bandında çoklu işitsel tonlar tarafından uyarılırken alınan beyin dalgaları kaydedilmiştir. Kanonik korelasyon analizi kullanılarak beyin bilgisayar arayüz teknikleriyle AEP'lerin tahmini gerçekleştirilmiştir. AEP'lerin farklı frekans bantlarındaki enerji dağılımı kişiye özgü özellikleri temsil etmektedir. 80 Hz simülasyonunda 96.46%'ya varan doğru tanıma oranı ve 0% gibi düşük bir eşik hata oranı elde edildiği gözlenmiştir [36].

Bidgoly ve arkadaşları kullanıcılara özgü EEG sinyalleri ile derin öğrenme yöntemleri aracılığıyla bir biyometrik kimlik tanımlama uygulaması gerçekleştirmişlerdir. Gram-Schmidt ortogonalleştirme işlemi sayesinde yalnızca 3 kanaldan biyometrik kimlik çalışması gerçekleştirebilmektedir. Çalışmada Oz, T7 ve Cz elektrotları üzerinden alınan sinyaller konvansiyonel sinir ağı (CNN) kullanılarak sınıflandırma işlemine tabi tutulmuştur. Önerilen metotla kimlik doğrulama sisteminde 98% oranında bir başarı elde edildiği gözlenmiştir [37].

Bashar çalışmasında kalp ve beyin elektrik sinyallerinin (EKG ve EEG) entegre edilmesiyle biyometrik kimlik tanımlama gerçekleştirilmiştir. Dalgacık alanı istatistiksel özelliği kullanılarak çoklu sınıflayıcılar (KNN, LDA ve ESAVM) kullanılmıştır. Ön işlemden sonra, sinyale (EKG/EEG) çok ölçekli dalgacık paket ayrıştırması uygulanmıştır. Özellik vektörleri dalgacık paket istatistikleri (WPS) kullanılarak dönüştürülmüş sinyalden elde edilmiştir. On katılımcı ile gerçekleştirilen tek özellik verileri ile yapılan sınıflandırma işleminde EKG ile 54.7%; EEG ile 74.9% oranlıları söz konusu iken birleştirilmiş sınıflandırıcı ile tek özellik EKG ile 66% EEG ise 87.3% doğruluk oranına sahip olduğu görülmüştür [38].

Kong ve arkadaşları yaptıkları çalışmada çeşitli görevler altında kişi tanımlama için faz senkronizasyonu (PS) özelliklerini çıkaran yeni bir EEG tabanlı biyometrik tanımlama yöntemi önerilmiştir. Farklı frekans bantlarındaki faz kilitleme değeriyle (PLV) faz senkronizasyon özellikleri (PS) nicelleştirilmiştir. Daha sonra, boyutu azaltmak amacıyla temel bileşen analizini (PCA) kullanılmıştır. Ardından, bir projeksiyon uzayı oluşturmak için doğrusal diskriminant analizini (LDA) kullanılarak özellikler projeksiyon uzayına yansıtılmıştır. Son olarak, sınıf

etiketine bir özellik vektörü atanmıştır. Yapılan tanımla çalışmasında özellikle beta ve gama bantlarında 97%'e ulaşan doğruluk oranları elde edilmiştir [39].

Khare ve arkadaşları EEG sinyalleri kullanarak şizofreni hastalığının tespiti üzerine bir biyometrik tanımlama çalışması gerçekleştirmişlerdir. Çalışmalarında özellik çıkarma tabanlı yöntemlerin sınırlamalarının üstesinden gelebilmek için zaman-frekans analizi ve konvolüsyonel sinir ağı (CNN) kombinasyonu önerilmiştir. Çalışma esnasında katılımcılara üç basılabilir buton testi uygulanarak normal kişiler ve şizofren hastaları tespit edilmeye çalışılmıştır. EEG sinyalleri sürekli dalgacık dönüşümü, kısa zamanlı Fourier dönüşümü ve yumuşatılmış sahte Wigner-Ville dağılımı (SPWVD) teknikleri kullanılarak skalogram, spektrogram ve SPWVD tabanlı zaman-frekans gösterimi (TFR) grafikleri elde edilmiştir. SPWVD tabanlı TFR ve CNN modeli kullanarak 93.36%'lık bir doğruluk elde edildiği görülmüştür. SPWVD-CNN'yi birleşiminden oluşan modeli ile şizofreni hastalıklarının tespiti için uygun bir model olduğu görülmektedir [40].

Chen ve arkadaşları sürekli EEG sinyallerinden insan duygu sınıflandırılması için çift yönlü bir Geçitli Tekrarlayan Birim (GRU) ağı modeli önerilmiştir. Modelin yapısı EEG sinyallerinin hiyerarşik yapısını yansıtırken, dikkat mekanizması ise EEG örneklerinin ve epoklarının iki seviyesinde kullanılmıştır. DEAP veri seti üzerinde katılımcılar arası duygu sınıflandırma deneyleri yapılarak önerilen modelin performansı değerlendirilmiştir. Değerlik ve uyarılma boyutlarında EEG sinyalinin 1 sn bölümlerinde en iyi derin temel LSTM modelinde 4.2% ve 4.6% iyi sığ temel modelinde ise sırasıyla 11.7% ve 12% oranında daha iyi performans elde edilmiştir. Ayrıca, EEG sinyallerinin epok uzunluğunun artmasıyla önerilen modelin sınıflandırma performansının arttığı görülmektedir [41].

El-Fiqi ve arkadaşları ham kararlı durum görsel uyarılmış potansiyelli (SSVEP'ler) konvolüsyon sinir ağları (CNN'ler) analizi kullanılarak kişi tanımlama ve doğrulama gerçekleştirmişlerdir. Dört ve on denekten oluşan SSVEP veri kümesi üzerinde önerilen CNN modeli ve klasik iki model arasında karşılaştırma yapılmıştır. Önerilen metot diğer metotlara oranla 45.5% daha iyi performans göstererek 96.8% oranında bir tanımlama doğruluğu performansı elde edilmiştir. Yanlış Kabul Oranı (FAR) 1.53% ve Kişi doğrulama için Kabul Oranı (TAR) 97.09% olarak bulunmuştur. Kişi doğrulama uygulamasında ise önerilen metot diğer metotlar ile karşılaştırıldığında 11.8% daha iyi performans göstererek 98.34% ortalama doğruluğu elde edilmiştir [42].

Zeng ve arkadaşları yüz görüntüsü tabanlı hızlı bir biyometrik kimlik doğrulama için seri görsel sunum (RSVP) paradigması önerilmiştir. Bu paradigma iki tür biyometrik özellik olan yüz

ve EEG'yi bir araya getirerek daha spesifik ve istikrarlı bir biyometrik özellik ortaya çıkarmaktadır. Tanıdık ve tanıdık olmayan kişi görüntüleri üzerinden olayla ilişkili görsel potansiyel birleşenleri araştırılmış ve farklı durumlar için önemli farklılıklar bulunmuştur. Buna dayanarak Hiyerarşik Diskriminant Bileşen Analizi (HDCA) ve Genetik Algoritma (GA) tabanlı bir biyometrik kimlik tanımlama yöntemi önerilmiştir. Önerilen metodun etkinliği ve sağlamlığını göstermek için doğruluk ve kararlılık incelenmiştir. Önerilen yöntemle 6 saniye içinde 94.26% oranında kimlik doğrulama doğruluğu elde edilebilmektedir. 30 günlük bir süre için ortalama zaman aralığında önerilen yöntem 88.88%'lik ortalama doğruluğa ulaşabilmektedir [43].


Taran Epilepsi tanısında kullanılan fokal EEG sinyalinin tanımlanması için varyasyonel mod ayrıştırması (VMD) öne sürülmüştür. VMD, EEG gibi homojen olmayan sinyallerin işlenmesi için sınırlamaları gösteren uyarlanabilir bir sinyal ayrıştırma tekniğidir. Çalışmada VMD'nin kısıtlamalarının üstesinden gelmek için kümeleme-VMD (CVMD) önerilmiştir. CVMD aşamasında homojen olmayan EEG sinyalleri optimum olarak homojen EEG sinyaline dönüştürülür. Önerilen yöntem ile fokal EEG sinyalleri ve doğruluk, duyarlılık ve özgüllük performans ölçümleri sırasıyla 96%, 94.69% ve 97.39% olarak bulunmuştur [44].

Fan ve arkadaşları çalışmalarında tren sürücülerinin yorgunluk ve dikkat dağınıklığını tespit etmek amacıyla EEG sinyalleri kullanılarak bir biyometrik tanımlama çalışması gerçekleştirmişlerdir. Bu çalışmada sürücünün alınına yerleştirilen bir EEG başlığı üzerinden benzersiz EEG verileri elde edildikten sonra bu EEG verilerinden entropi, ritmik enerji oranı ve frontal asimetri oranı dahil olmak üzere çok sayıda özellik çıkarıldığı görülmektedir. Kişilerin yorgunluk ve dikkat dağınıklığını ölçümünde çoklu çeşitli özellik çıkarımı (CatB-FS) algoritması ve bir zaman serisi topluluk öğrenme yöntemi önerilmiştir. Önerilen yöntemin 5 sn'lik zaman dilimi için ortalama tespit doğruluğu 92.7% oranına ulaştığı görülmüştür. Yorgunluğun ve dikkat dağınıklığının hassasiyet değeri sırasıyla 95.96% ve 93.48% olduğu görülmüştür [45].

Nagar ve arkadaşları beyin bilgisayar arayüzü (BCI) kullanarak EEG sinyalleri üzerinden stres seviyesini tahmin edilmesine yönelik bir çalışma gerçekleştirmişlerdir. Tek elektrotlu EEG cihazı kullanılarak beyin haritalama tabanlı stres tanımlama sistemi önerilmektedir. Altmış üç katılımcıdan alınan EEG kayıtları alfa, beta, delta ve teta bantlarının bant gücü oranlarından yeni bir özellik kombinasyonu çıkarılmıştır. Destek vektör makinesi ve k-en yakın komşu makine öğrenme yöntemleri kullanılarak önerilen metodun performansı değerlendirilmiştir. K-en yakın komşuluk yöntemi kullanılarak en yüksek ortalama sınıflandırma doğruluğu 74.43% olarak elde edildiği gözlenmektedir [46].

Baghel ve arkadaşları konvolüsyonel sinir ağı (CNN) kullanılarak on dört kanallı EEG sinyallerinden yanlış veya doğru ifade verilip verilmediğinin tespitine yönelik bir çalışma gerçekleştirilmiştir. EEG verilerindeki gürültünün giderilmesi için zaman alanı filtrelemesi kullanılmıştır. Önerilen yöntemde bir kişinin doğru veya yanlış ifade vermesinin tespitinde 84.44%'e varan doğruluk oranına ulaşıldığı gözlenmektedir. Önerilen yöntemin non-invaziv, verimli ve sağlamdır ve düşük zaman karmaşıklığına sahip olduğu görülmüştür [47].


Peng ve arkadaşları dinlenme durumunda EEG sinyalleri üzerinden kişilerin sağlıklı veya depresyonda olup olmadığının tespitine yönelik bir çalışma gerçekleştirmişlerdir. Çalışmada fonksiyonel bağlantı matrisleri oluşturmak için faz gecikmesi indeksi kullanılmıştır. Kendall sıra korelasyon katsayısı yüksek ayırt edici güce sahip özellikleri belirlemek için kullanılmıştır. Çalışmada yirmi yedi depresyon hastası kişinin ve yirmi sekiz sağlıklı kişinin sınıflandırılmasında çeşitli sınıflandırıcılar kullanılmıştır. Sınıflandırıcı performansını değerlendirmek için permütasyon testleri kullanılmıştır. Deneklerin 92%'sinden fazlasının ikili doğrusal SVM tarafından doğru bir şekilde sınıflandırıldığı ve doğruluk oranının 98% oranında olduğu görülmektedir [48].



Şekil 1-1: Biyometrik tanımlama ve doğrulama sistemlerine ait blok diyagram

Biyometrik kimlik doğrulama ve biyometrik tanımlama birbiri ile ilişkili olmasına rağmen birbirinden farklı kavramlardır. Biyometrik tanımlamada bir veri kümesi içindeki örüntülerin ne kadar yüksek tanımlama doğruluğuna sahip olduğu önemliken biyometrik kimlik doğrulamada ise tek bir bireyin örüntüsünün ne kadar yüksek tanımlama doğruluğuna sahip olduğu önemlidir.


Biyometrik tanımlama ve doğrulama sistemlerine ait blok diyagram Şekil 1-1’de görülmektedir [49]. Biyometrik tanımlama, güvenliğin yüksek seviyede olmadığı uygulamalarda (sosyal medyada bir fotoğraf üzerindeki etiketlenen kişiler vb.) kullanılırken, biyometrik kimlik doğrulama ise güvenliğin yüksek seviyede olduğu (banka hesap erişimi, kişisel dijital cihazlara giriş vb.) uygulamalarda kullanılmaktadır.



Şekil 1-2: Biyometrik kimlik doğrulama modellerinin kategorizasyonu

Fiziksel biyometri (yüz, parmak izi, iris vb.) ve davranışsal biyometri (ses, hareket vb.) içeren biyometrik tabanlı kimlik doğrulama için birçok model kullanılmaktadır. Kullanıcı kimlik doğrulama için kullanılan modellerin kategorizasyonu Şekil 1-2 görülmektedir [50].

Dinlenme durumundaki EEG alfa frekanslı sinyallerin kullanıldığı biyometrik tanımlama sistemine ait blok diyagram Şekil 1-3’de gösterilmektedir.



Şekil 1-3: Biyometrik tanımlama sistemine ait blok diyagram

2. EEG SİNYAL ELDE EDİNİMİ VE EEG SİNYAL ÖZELLİKLERİ

2.1 Elektroensefalografi (EEG)

Beyindeki nöronların ürettiği elektriksel potansiyel farkları kafa derisi üzerinden elektrotlar vasıtasıyla kayıt edilmesini sağlayan sistemlere elektroensefalografi (EEG) denilmektedir. Kafa derisi yüzeyinden beyinde üretilen elektriksel sinyallerin ölçülmesi EEG ile sağlanmaktadır. Farklı frekans aralığındaki sinyallerin birleşmesiyle EEG kayıtları oluşmaktadır [51]. Kısa sürede kolay bir şekilde elde edilebilmesi, maliyetinin düşük ve basit ekipmanlar içermesi gibi avantajlarından dolayı EEG sinyalleri yaygın olarak kullanılmaktadır. Genel olarak EEG sinyalleri durağan olmayan ve zamanla değişen sinyallerdir [52]. EEG sinyalleri farklı frekans bantlarına sahip Teta, Gama, Delta, Beta ve Alfa dalgalarından oluşmaktadır. EEG sinyalleri 10 ile 200 μV aralığında genliğe ve 0-100 Hz frekans aralığına sahiptir. Bir EEG kaydından uygun sinyaller elde edilebilmek için filtreler kullanılmaktadır. Dinlenme durumunda iken daha yüksek genliğe sahip olan alfa dalgaları 8-13 Hz frekans aralığında bulunmaktadır. Genliği kişiden kişiye değişse de yetişkinlerde oluşan sinyalin genellikle 50 μV 'un altında olduğu görülmektedir. En yüksek ve en iyi değerlikli EEG alfa frekansı gözlerin kapalı olduğu ve dinlenme durumunda elde edilmektedir [53]. Oksipital lob EEG alfa frekanslı sinyallerin ana kaynağıdır [54].

Tablo 2-1: Farklı frekans değerlerine ait EEG sinyalleri

EEG Sinyalleri	Simge	Frekans	Genlik
Delta	δ	<4 Hz	20- 200 μV
Teta	θ	4-8 Hz	20- 100 μV
Alfa	α	8-13 Hz	20- 60 μV
Beta	β	13-30 Hz	2- 20 μV
Gama	γ	>30 Hz	3- 5 μV

EEG dalgalarında farklı frekans aralıklarına sahip sinyaller bulunur. Bu sinyaller bant geçiren filtreler yardımıyla ayrıştırılır. Farklı frekans değerlerine ait EEG sinyalleri Tablo 2-1’de görülmektedir [55], [56].

Delta dalgaları derin uyku, genel anestezi gibi beyin düşünsel olarak aktif olmadığı durumlarda ortaya çıkmaktadır.

Teta dalgaları rüya, anestezi ve stres gibi beyin düşük performans gösterdiği durumlarda görülmektedir.


Alfa dalgaları gözlerin kapalı olduğu uykuya geçilmemiş halde fiziksel ve zihinsel aktivitenin gerçekleştirilmediği dinlenme durumunda yüksek seviyede gözlenmektedir.

Beta dalgaları bir problemi düşünürken, karar alma ve verme süreçlerinde, dinleme durumunda, bir konu üzerine odaklanıldığı ve yoğunlaştığı esnada gözlerin açık olduğu durumlarda belirmektedir.

Gama dalgaları üst düzey bilişsel işlem görevlerinde, yüksek uyarılma ve yoğun stres içerisinde iken görülmektedir [57].

2.2 Beyin Lobları ve İşlevleri


Beyin loblarına ait bölümler ve bu bölümlerin görevleri Şekil 2-1’de görülmektedir [58]. Beynin kırıksık görünümünü sağlayan en dış kısımda bulunan katman serebral korteks olarak adlandırılmaktadır. Beynin frontal, oksipital, parietal ve temporal olmak üzere dört ana lobu bulunmaktadır. Parietal lob basınç, sıcaklık, ağrı ve dokunma gibi duyuşsal bilgilerin birleştirilmesinden sorumludur. Frontal lob genel olarak akıl yürütme, duyuşsal düzenleme, problem çözme ve planlama gibi yüksek yönetici fonksiyonlarının işlendiği yerdir. Beyinde görsel işlemenin oluştuğu en önemli kısım oksipital lob olarak bilinmektedir. Özellikle anıların oluştuğu, işitme ve dil tanıma gibi duyuşsal verilerin işlenmesinden sorumlu beyin bölgesi temporal lobtur [59].



Şekil 2-1: Beyin lobları ve işlevleri

2.3 10-20 Elektrot Sistemi

EEG sinyallerinin ölçümünde kafa derisine yerleştirilen elektrotların konumu uluslararası 10-20 elektrot sistemi ile standart hale gelmiştir. Elektrotların konumu ve yerleşimi beynin serebrar anatomisine bağlıdır [60]. Uluslararası 10-20 elektrot sistemi EEG testi ve deneyi için elektrotlara ait konumlarının belirlenmesi ve uygulanması amacıyla kullanılan uluslararası standartlar kapsamında kabul görmüş bir sistemdir. Bu sistemin standartlaşması ile beraber elde edilen veriler birbirleriyle karşılaştırılabilen veya farklı kişilerden alınan verilerle kıyaslanabilir duruma gelmektedir. Bir başka deyişle kişilerin karakteristik özelliklerinin ortaya çıkarılması ve ortaya çıkarılan bu özelliklerin karşılaştırılabilme imkanı sağlanmıştır [61]. Standart hale gelmiş ölçümlerin 20% ve 10%'una göre elektrot konumları belirlenmektedir. Elektrot isimleri harf ve sayılar ile oluşturulmaktadır. Harfler, üzerinde bulunduğu beyin lobunun ilk harfini temsil etmektedir. Çift sayılar beynin sağ kısmını, tek sayılar ise sol kısmını belirtmektedir. C harfi ise beyin merkez bölgesini ifade etmektedir. Orta çizgi beyin eşit iki parçaya ayrıldığını belirtmesinden dolayı bu orta çizgi sıfır noktası olarak kabul edilmektedir. Orta çizgiye yakın elektrot isimlerinde ilgili beyin loblarını belirten harflerin yanına z harfi eklenmektedir. Beynin uç kısmını ifade etmek için beyin ön kısmında bulunan frontal lob harfinin yanına polar ifadesinin baş harfi getirilerek bu kısımdaki elektrotlar FP olarak adlandırılmaktadır [62]. Uluslararası 10-20 elektrot sistemine ait görsel Şekil 2-2'de verilmiştir.



Şekil 2-2: Uluslararası 10-20 elektrot sistemi

2.4 Veri Seti ve Elektrot Yerleşimi

Bu çalışmanın veri seti yirmi katılımcının dinlenme durumunda gözler açık ve kapalı iken gerçekleştirilen deneysel protokoldeki elektroensefalografik (EEG) kayıtlarından oluşturulmuştur. EEG kayıtları içerisinde filtreler yardımıyla alfa dalgaları ayrıştırılarak çalışmaya uygun veri seti oluşturulmuştur. Çalışmaya yedi kadın ve on üç erkek olmak üzere toplam yirmi kişi katılmıştır. Katılımcıların yaş ortalaması 25.8'dir. On altı elektrottan oluşan EEG başlık 10-20 uluslararası elektrot sistemine uygun şekilde yerleştirilmiştir. Referans elektrodu sağ kulak memesine, toprak elektrodu ise AFZ kısmına yerleştirilmiştir. EEG elektrotları kafa derisine sırasıyla FP1, FP2, FC5, FC6, FZ, T7, CZ, T8, P7, P3, Pz, P4, P8, O1, Oz, O2 konumlarına yerleştirilmiştir. EEG kanallarını ait elektrot yerleşimi Tablo 2-2'de gösterilmektedir. Dinlenme durumunda parietal ve oksipital bölgelerden elde edilen EEG alfa frekanslı sinyallerin analizi gerçekleştirilmektedir.

Tablo 2-2: EEG kanallarına ait elektrot dizilimi ve yerleşimi

EEG KANALLARINA AİT ELEKTROT YERLEŞİMİ															
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
FP1	FP2	FC5	FC6	FZ	T7	CZ	T8	P7	P3	PZ	P4	P8	O1	OZ	O2


Saniyede 512 Hz örnekleme frekansı ile EEG sinyalleri elde edilmiştir. Her katılımcı için on sn'lik periyotlardan oluşan on örneklem alınmıştır. İlk koşulda gözler kapalı iken beş örneklem, ikinci koşulda ise gözleri açık iken beş örneklem olacak şekilde toplam on örneklem ile veri seti oluşturulmuştur. Çalışmada kullanılan veri seti ayrıca kişilerin cinsiyet, yaş ve mental yorgunluk durumunda içermektedir [63]. Dinlenme durumunda yapılan EEG kaydına ait deneysel düzen Şekil 2-3'te görülmektedir.



Şekil 2-3: Veri kaydı için deneysel düzen

3. SİNYAL İŞLEME YÖNTEMLERİ

EEG sinyalleri kişinin duygu ve düşüncelerini doğrudan değerlendirmeye izin vermektedir. Beyin bilgisayar arayüzü bu sinyalleri toplama amacıyla kullanılmaktadır. Birçok öznelik çıkarma yöntemi incelendiğinde elektrotun uygun özellikte olması ve konumunun seçimi genellikle nöro-bilimsel bulgulara dayanmaktadır. Basit ve gelişmiş özellik çıkarma yöntemlerine ait şema Şekil 3-1’de görülmektedir. Özellik çıkarımı için doğrusal ve doğrusal olmayan birçok yöntem literatürde bulunmaktadır. Doğrusal yöntemler hızlı fourier dönüşümü (FFT), dalgacık dönüşümü (WT), temel bileşen analizi (PCA), bağımsız bileşen analizi (ICA) ve dalgacık paket ayrışımını (WPD) içermektedir. Yüksek dereceli spektral (HOS), lyapunov üstel methodu (LLE), fraktal boyut (FD), hurst üstel katsayısı (H) ve korelasyon boyutu (CD) ise doğrusal olmayan yöntemlerden bazılarıdır [64].



Şekil 3-1: Özellik çıkarma yöntemleri

3.1 Normalizasyon

Normalizasyon büyük verilerin ölçeklendirilmesinde ve haritalama uygulamalarında sıklıkla kullanılan bir tekniktir. Verilerin özelliğini kaybetmeden önceden karar verilen aralıklarda verilerin değerlerini sınırlandırmak için kullanılan faydalı bir işlem adıdır [65]. Çalışmada sınıflandırma işlemi öncesi ham EEG sinyallerine uygulanan normalizasyon işlemine

ait matematiksel bağıntı Denklem (1)'de görülmektedir [66]. Normalizasyon işlemi sonrası veri seti 0-1 aralığında değerlere indirgenir.

$$X_S^{norm} = \frac{X_S - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$


Burada X_S normalize edilecek değeri, $X_{\max}$ veri seti içerisindeki en büyük değeri, $X_{\min}$ veri seti içerisindeki en küçük değeri, X_S^{norm} ise normalize edilmiş değeri ifade etmektedir.

3.2 Temel Bileşen Analizi (PCA)

Temel bileşen analizi (PCA), yüksek hacimli veri boyutlarını daha düşük hacimli veri boyutlarına indirmek için kullanılan yöntemdir. PCA bir veri seti içerisinde en yüksek değeri taşıyan özellikleri belirlemek için özelliklerin varyans değerini kullanmaktadır [67]. PCA bir sinyali, zamansal ve mekansal artıklıktan kurtararak sinyalin temel özelliklerini değiştirmeden boyut azaltılmasına katkı sağlamaktadır. Bu yöntemle ortalamadan çıkarılan veri değerleri veri ortalamasına göre merkezlenir ve bu merkezlenmiş verilerin en yüksek varyansına göre temel bileşenler belirlenmektedir. PCA yöntemine ait matematiksel bağıntı Denklem (2)'de gösterilmektedir [68].

$$C(X) = \sum_{i=1}^N \frac{(X_i X_i^T)}{N} \quad (2)$$

Biyometrik tanımlama çalışmalarında EEG alfa frekanslı ham verilerden özellik vektörü tespit edildikten sonra veri boyutunu azaltmak amacıyla PCA yöntemi uygulanmıştır. PCA yöntemi uygulandıktan sonra boyutları indirgenmiş vektöre öznitelik vektörü denmektedir. Yirmi adet katılımcının her biri için on altı kanaldan alınan verilerle bir veri seti oluşturulmuştur. Veri setine PCA yöntemi uygulanarak kanal sayısı onaltı kanaldan üç kanala indirgemiştir. PCA boyut indirgeme işlemine ait blok diyagram Şekil 3-2'de görülmektedir.



Şekil 3-2: PCA yöntemi ile boyut azaltma işlemi


3.3 Bağımsız Bileşen Analizi (ICA)

Çok değişkenli verileri analiz etmenin temel bir yolu olarak 1990'lı yıllarda Jutten & Herault tarafından geliştirilen bağımsız bileşen analizi (ICA), rassal bir vektörün bir lineer dönüşümünü öğrenmek için kullanılan istatistiksel bir yöntemdir. ICA metodunda amaç gaussian olmayan, maksimum derecede bağımsız bileşenleri elde etmek ve bileşenleri arasında minimum istatistiksel bağımlılığı sağlamaktır. Bir başka deyişle bağımsız bileşen analizi (ICA) bir veri kümesinden o veri kümesinin olgusunun altında yatan yararlı ve temel veriyi, kaynağı elde etmeye çalışmaktadır. Bu nedenle literatürde ICA kör kaynak ayırma (BSS) yöntemlerinden biri olarak kabul edilmektedir.

ICA, verilerin doğrusal ayrıştırmasını klasik yöntemler olan faktör analizi ve temel bileşen analizi (PCA) gibi öğrenmeye çalışmaktadır. Ancak klasik çok değişkenli istatistiksel modellerden temel farkı klasik yöntemlerin aksine orijinal sinyalin tanımlanmasını sağlarken bunun yanı sıra sinyalin altına yatan gaussian olmayan bileşenleride verebilmesidir. ICA'nın klasik yöntemlere göre bir başka farklı özelliği ise gözlemlenen verilerde karışık halde bulunan temel bileşenleri ve kaynakları ayırabilmesidir. ICA, tek bir veri kümesi formatında giriş verisini alması açısından denetimsiz bir yöntemdir. Sistemin istenen 'çıkıtısını' bilmek veya veri matrisini bölmek gerekli değildir [69].

Bağımsız bileşen analizini betimsel olarak bir örnek üzerinden anlatmak gerekirse, kapalı bir odada iki kişinin ve iki mikrofonun olduğunu varsayalım. Kişiler eş zamanlı olarak konuştuklarında mikrofonlara bu iki kişinin sesi iletilir. Şekil 3-3'deki gibi mikrofon çıkışlarında bu iki ses sinyalinin karışımı gözlemlenir. Bu iki sinyal karışımı göz önüne alındığında, ICA iki orijinal sesi veya kaynak sinyalini ayırt edebilme imkanı sağlamaktadır. Bu örnekte ses sinyali kullanılmıştır ancak ICA iki veya daha fazla ölçülmüş sinyal karışımından oluşan herhangi bir kümeden kaynak sinyallerini çıkarabilme yeteneğine sahiptir. Bağımsız bileşen analizi ICA yöntemi cep telefonu sinyallerinin analizi, beyin görüntüleme işlemleri, fonksiyonel manyetik

rezonans görüntüleme (fMRI), hisse senedi fiyatları, ses sinyalleri analizi ve EEG sinyalleri üzerinden tanımlama işlemleri gibi geniş bir kullanım alanına sahiptir [70].



Şekil 3-3: İki ses sinyaline ait karışımın ICA yöntemi ile ayrıştırılması

ICA'yı matematiksel olarak tanımlamak için istatistiksel bir yöntem olan gizli değişkenler modeli kullanılabilir. N adet bağımsız bileşenden oluşan n adet doğrusal $x_1, \dots, x_n$ karışımlarını gözlemlediğimizi varsayalım. Bu durumda x_i 'ye ait ICA modeli Denklem (3) ile ifade edilir [67].

$$x_i(t) = a_{i1}s_1(t) + a_{i2}s_2(t) + \dots + a_{in}s_n(t) \quad i = 1, 2, \dots, n \quad (3)$$

Denklem (3)'te toplamlar yerine vektör-matris gösterimini kullanmak uygundur. ICA modelinin vektör-matris gösterimi Denklem (4)' deki gibi ifade edilmektedir.

$$\begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_n(t) \end{bmatrix} = A \cdot \begin{bmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_n(t) \end{bmatrix}, \quad A = [a_{i1}, a_{i2}, \dots, a_{in}] \quad (4)$$

A karışım katsayılarını, x karışımları, s bağımsız (kaynak) bileşenleri temsil etmektedir. Denklem (4)'ün bir başka gösterimi ise Denklem (5) olarak basitleştirilebilir.

$$x = As \quad (5)$$

Denklem (6) bağımsız bileşenlerin elde edilmesini matematiksel olarak ifade etmektedir.

$$s = A^{-1}x \quad (6)$$

3.4 Ampirik Mod Ayırımı (EMD)

Ampirik Mod Ayırması (EMD) Huang ve arkadaşları tarafından 1998 yılında durağan ve doğrusal olmayan sinyalleri analiz etmek için yeni ve etkili bir yöntem olarak önerilmiştir [71]. Bu yöntem karmaşık ve çok ölçekli bir sinyali, sonlu sayıda sıfır ortalamalı bileşenin toplamına ayırabilmektedir. Bu sonlu sayıda sıfır ortalamalı bileşenler İçsel Mod Fonksiyonları (IMF) olarak adlandırılır ve anlık frekansı analitik sinyal yöntemi (Hilbert Huang dönüşümü) ile hesaplanarak sinyalin fiziksel olarak anlamlı bir karakterizasyonunu ortaya koyar. IMF'ler sinyalin belirli bir zaman ölçeğindeki tekrar eden davranışını yakalayarak daha iyi zaman çözünürlüğü elde etmek için anlık frekans bilgilerini verir. EMD, daha ince zamansal ölçeklerden (yüksek frekans modları) başlayarak daha yoğun zamansal ölçeklere (düşük frekans modları) kadar sinyalin çeşitli içsel zaman ölçekleri ile ilişkili olan enerjinin sıralı olarak çıkarılmasına dayanmaktadır. Ampirik mod ayrıştırması sinyali genlik modülasyonlu ve frekans modülasyonlu bileşenlerine ayırıştırarak iç modların anlık frekansını ifade edebilen güçlü bir zaman-frekans analiz imkanı sunmaktadır [72].

Fourier veya dalgacık dönüşümleri gibi ampirik mod ayrışımı da bir zaman sinyalini bir dizi temel sinyallere indirger. Ancak, fourier veya dalgacık dönüşümlerinden farklı olarak, amprilik mod ayrıştırılmasında temel fonksiyonlar verilerin kendisinden türetilir. Hilbert dönüşümü IMF'lere uygulandığında sinyalin anlık frekansı ve genliği bulunur.

Ampirik mod ayrıştırma (EMD) çok ölçekli bir $x(t)$ sinyalini uyarlamalı olarak L sayısında İçsel Mod Fonksiyonlarına (IMF) $h_i(t)$ ayırıştırır. Bu ayrıştırmaya ait ifade Denklem (7)'de görülmektedir.

$$x(t) = \sum_{i=1}^L h_{(i)}(t) + r(t), \quad 1 \leq i \leq L \quad (7)$$

Burada $r(t)$ sıfır ortalamalı olmayan yavaş değişen bir fonksiyon olarak artakalındır. EMD'nin temel kavramı sinyalin fiziksel özellikleri ortaya çıkaran uygun zaman ölçeklerini belirlemek ve sinyali içsel mod fonksiyonlarına ayrıştırmaktır. İçsel mod fonksiyonları aşağıdaki koşulları sağlayan sinyallerdir.

1) Tüm veri kümesinde, ekstremum sayısı ya sıfır geçiş sayısına eşit olmalı ya da en fazla bir farklı olmalıdır,

2) Herhangi bir noktada, yerel maksimumlar tarafından tanımlanan zarfın ve yerel minimumlar tarafından tanımlanan zarfın ortalama değeri sıfır olmalıdır.

EMD prosedürü, zaman serisini bir dizi IMF'ye ve bir artığa ayrıştırmak için uygulanabilir. Her bir IMF sinyaline Hilbert dönüşümü uygulanarak her bir IMF'nin anlık frekansını ve genliğini hesaplanabilir. Tüm bu süreç Hilbert Huang Dönüşümü olarak adlandırılır.

EMD'nin önemi zaman domeninden çıkmadan bir sinyali parçalayabilmektedir. EMD süreci daha çok doğrusal olmayan ve durağan olmayan doğal gerçek sinyalleri analiz etmek için kullanışlıdır. EMD orijinal sinyal için tam ve neredeyse ortogonal bir temel oluşturan fonksiyonları filtreler. IMF olarak bilinen bu fonksiyonlar bütünlüğü sağladığı için sinyali tanımlamada yeterlidir. EMD'nin özü, bir sinyali tümü zaman domeninde olan fonksiyonlara ayrıştırılması ve zamanla değişen frekanslar için orijinal sinyal uzunluğunu koruyabilmesidir. Bu da genellikle Fourier ve Dalgacık dönüşümünde gizlidir. Ayrıştırmanın genel sonucu sinyalden en yüksek frekansı ortadan kaldırmaktır. Sinyalin özünde bulunan yararlı bilgileri çıkarmak için EMD yöntemi kullanılmaktadır.

Uygulama kolaylığı ve geniş uygulama alanındaki etkinliği sayesinde biyomedikal sinyallerin analiz edilmesi, sesli sinyallerindeki gürültünün ayrıştırılması, ham petrol fiyatlarını analiz edilmesi, karbon emisyonlarını tahmin etmek ve modellemek gibi birçok alanda kullanılmaktadır.

EMD çok ölçekli doğrusal ve durağan olmayan sinyali tamamen veri odaklı bir şekilde içsel mod fonksiyonu olarak bilinen sıfır ortalamalı sinyallere uyarlayarak ayrıştırır. EMD'nin prensibi sinyalin her biri ayrı bir zaman ölçeğinde gömülü bir karakteristik salınımı temsil eden IMF'lerden oluştuğu varsayımına dayanmaktadır [71].


3.5 Ayırık Dalgacık Dönüşümü (DWT)

İlk olarak "dalgacık" olarak adlandırılan kavramdan 1909 yılında Alfred Haar tarafından yazılan bir tezde bahsedildiği görülmektedir [73]. Dalgacık dönüşümü çok çözünürlüklü analiz özelliklerine sahiptir ve sinyalin hem zaman hem de frekans alanlarındaki yerel özelliklerini karakterize edebilir. Bu yöntem, genişleme ve öteleme gibi hesaplama fonksiyonları aracılığıyla sinyaller üzerinde çok ölçekli analiz gerçekleştirir.

Ayrık dalgacık dönüşümü (DWT), farklı seviyelere sahip iki kanallı bir filtre bankası tarafından uygulanan en temel ve en yaygın kullanılan dalgacık dönüşümüdür. Ayrık dalgacık dönüşümü (DWT) zaman ve ölçek açısından ayırıktır yani dalgacık dönüşüm katsayıları gerçek (kayan noktalı) değerlere sahiptir. Ancak bu katsayılarda kullanılan zaman ve ölçek değerleri tam sayıdır. Ayrık Dalgacık Dönüşümü (DWT) bir sinyali bir dizi karşılıklı ortogonal dalgacık temel fonksiyonuna ayırıştırır. Bu fonksiyonlar, sinüzoidal temel fonksiyonlardan uzamsal olarak lokalize olmaları, yani toplam sinyal uzunluğunun sadece bir kısmında sıfır olmamaları bakımından farklıdır. Ayrıca, dalgacık fonksiyonları ana dalgacık olarak bilinen ortak bir ϕ fonksiyonunun genişletilmiş, çevrilmiş ve ölçeklendirilmiş versiyonlarıdır. DWT yöntemine ait matematiksel formül Denklem (8) ile ifade edilmektedir [74]. İlgili denklemde a ve b ifadeleri sırasıyla ölçü ve geçiş parametrelerini belirtmektedir.

$$DWT(a,b) = \frac{1}{\sqrt{a}} \sum_n x(n) \psi^*\left(\frac{n-b}{a}\right) \quad (8)$$

DWT, sürekli dalgacık dönüşümünün ölçek ve yer değiştirme gücüne göre ayrıştırılmasıyla elde edilir, bu nedenle ikili dalgacık dönüşümü olarak da adlandırılır. Birçok sinyal için düşük frekanslı bileşen esas olması nedeniyle sinyalin özelliklerini içerir ve yüksek frekanslı bileşen sinyalin ayrıntılarını veya farklılıklarını verir. DWT ayrıştırmasında düşük frekanslı bilgi sinyalin yüksek ölçeğini temsil eder, bu da sinyalin bir yaklaşımıdır. Yüksek frekanslı bilgi ise sinyalin düşük ölçeğini temsil eder, bu da sinyalin detayıdır. Yaklaşık sinyal, sürekli ayrıştırma işlemi aracılığıyla sürekli olarak ayrıştırılır ve sinyal birçok düşük çözünürlüklü bileşene ayrıştırılabilir. Teorik olarak, ayrıştırma sınırsız olarak devam edebilir. Pratik uygulamalarda, uygun ayrıştırma katmanı sayısı genellikle sinyalin özelliklerine veya uygun standartlara göre seçilir.




Şekil 3-4: DWT ile 1 boyutlu sinyalin 3 oktava ayrıştırılması

DWT ile bir boyutlu sinyalin üç oktava ayrıştırılması Şekil 3-4'te görülmektedir. DWT ile bir sinyal bir ya da birden fazla çözünürlük seviyelerine (oktav) ayrıştırılabilmektedir. Alçak geçiren filtre (AGF) ortalama sinyali üretirken yüksek geçiren filtre detay sinyali üretir. Çoklu çözünürlük analizinde, bir seviyedeki ortalama sinyal, bir sonraki oktavda ortalama ve detay sinyallerini üreten başka bir filtre setine gönderilir. Detay sinyaller tutulur, ancak daha yüksek oktav ortalamaları ters dönüşüm sırasında yeniden hesaplanabilecekleri için atılabilmektedir. Her kanalın çıkışında girişteki veri miktarının yalnızca yarısı kadar veri bulunur. Böylece, dalgacık temsili yaklaşık olarak orijinal sinyal ile aynı boyuttadır. DWT sinyal boyutlarına bağlı olarak 1-D, 2-D, 3-D vb. boyutlarda olabilir.

Fourier dönüşümü ile karşılaştırıldığında, frekansla değişen bir "zaman-frekans" penceresi sağlayabilmektedir. Fourier analizinde olduğu gibi, DWT de ters çevrilebilir. Bu sayede orijinal sinyal DWT temsilinden tamamen geri kazanılabilir. Ayrıca sinyallerin belirli yönlerini tam olarak vurgulayabilir.

Ayrık Dalgacık Dönüşümü (DWT) video sıkıştırma, nesne tanıma, sayısal analiz gibi birçok uygulamada kullanılabilmektedir [75].

Çalışmada 512 Hz örnekleme frekanslı kayıt verisi üzerinden belirli frekansı çıkarmak için 5. seviyede db5 dalgacık tipi uygulanmıştır. Beş seviyeli dalgacık ayrıştırma süreci Şekil 3-5'de görülmektedir.



Şekil 3-5: EEG frekans alt bantları için 5 seviyeli dalgacık ayrıştırma süreci

3.6 Minimum Fazlalık Maksimum Uygunluk (MRMR)

Maksimum alaka düzeyi ve minimum artıklık (MRMR) yöntemi öznelikleri seçerken, sınıf etiketleriyle en alakalı olanı araştırmakta ve bunun yanı sıra seçilen öznelikler arasındaki fazlalığı minimize etmeye çalışmaktadır [76]. MRMR kriteri, örüntü tanıma için bir filtre özelliği ölçütü olduğundan, ham özellik kümesinden maksimum bağımlılık, maksimum alaka ve minimum artıklık ile özellik alt kümesini seçmeyi amaçlar. Ancak MRMR yalnızca tek bir özelliğin katkısını dikkate alır. MRMR her seferinde bir özelliği seçerek yinlemeli olarak çalışır. Her adımda, bir fark (ilgililik eksi artıklık) veya bölüm (ilgililik bölü artıklık) yaklaşımını kullanarak kalan seçilmemiş özellikler arasında maksimum puana sahip özelliği hesaplar. MRMR yalnızca denetlenen veri kümeleri için çalışır ve tüm özellikler tamamen kategorik veya sayısal olmalıdır.

MRMR, fazlalığı ve alaka düzeyini ölçmek için karşılıklı bilgi teorisini benimser. Bir başka deyişle algoritma her bir özneliği ayrık bir rastlantı değişkeni olarak görür ve iki öznelik x ve y olmak üzere, arasındaki benzerlik değerini tespit etmek için aralarındaki karşılıklı bilgiyi $I(x;y)$ kullanır. MRMR, özellikler arasındaki fazlalığı ve karşılıklı bilgisine

$I(x;y)$ dayalı sınıf ile özellikler arasındaki korelasyonu hesaplayan bir filtre özellik ölçüm kriteridir. Kategoriyile en alakalı olan ve ham özellik setindeki diğer özelliklerden en az fazlalığa sahip olan özellikleri seçmektedir. Karşılıklı bilgi $I(x;y)$ Denklem (9) ile ifade edilir [77].

$$I(x:y) = \iint p(x,y) \log \frac{p(x,y)}{p(x)p(y)} dx dy \quad (9)$$

Burada $p(x,y)$, x ve y rasgele değişkenlerinin ortak olasılık yoğunluğu, $p(x)$ ve $p(y)$ sırasıyla x ve y 'nin marjinal olasılık yoğunluklarıdır.

Bir örnek özellik kümesi $S = \{f_1, f_2, \dots, f_n\}$ ve bir örnek sınıf c için S ve c arasındaki alaka düzeyi her bir özellik f_i ve c sınıfı arasındaki tüm karşılıklı bilgilerin ortalamasıdır ve Denklem (10) ile ifade edilir.

$$D(S, c) = \frac{1}{|S|} \sum_{f_i \in S} I(f_i; c) \quad (10)$$

Burada $|S|$, S 'deki özelliklerin sayısı belirtirken $I(f_i; c)$ ise f_i özelliği ile c sınıfı arasındaki karşılıklı bilgiyi ifade eder.

S 'deki tüm özelliklerin fazlalığı, f_i özelliği ile f_j özelliği arasındaki tüm karşılıklı bilgilerin ortalamasıdır ve denklem (11) ile ifade edilir.

$$R(S) = \frac{1}{|S|^2} \sum_{f_i, f_j \in S} I(f_i; f_j) \quad (11)$$

MRMR yöntemi, örneklerin maksimum ilişkiye $D(S, c)$ ve minimum artıklığa $R(S)$ sahip optimum özelliklerini arar. Yani MRMR için özellik ölçütü kriteri Denklem (12) ile ifade edilmektedir.

$$mRMR = \max(D(S, c) - R(S)) \quad (12)$$

3.7 Relief (R)

İlk olarak Kira ve Rendell tarafından 1992 yılında örnek tabanlı öğrenmeden esinlenerek formüle edilen Relief algoritması, özelliklerin alaka düzeyini tahmin eden ve bunları sınıflandırma amacıyla sadece önemli özelliklerin muhafaza edileceği bir uygunluk eşiği belirlenerek sıralayan denetimli bir özellik sıralama algoritmasıdır [78], [79]. Özellik seçimine özellikle özellik etkileşimlerine duyarlı bir filtre yöntemi yaklaşımı getiren Relief algoritması, nominal ve sayısal niteliklerle ilgilenebilir. Ancak eksik/kayıp verilerle baş edemez ve ikili sınıf problemleri için tasarlanmıştır [80]. Relief algoritmalarının arkasındaki temel fikir, özniteliğin birbirine yakın örnekler arasında ne kadar iyi ayırım yapabildiğini temel alarak özniteliklerin kalitesini tahmin etmektir. Pek çok sezgisel ölçüm, niteliklerin kalitesini tahmin etmek için niteliklerin koşullu (hedef değişkene göre) bağımsızlığını varsayarken, relief algoritmaları bu varsayımı yapmaz. Verimli olmalarının yanı sıra bağlamsal bilgilerin farkındadırlar ve nitelikler arasında güçlü bağımlılıkların olduğu problemlerde niteliklerin kalitesini doğru bir şekilde tahmin edebilirler. Relief algoritmaları çoğunlukla model öğrenilmeden önce bir ön hazırlık aşamasında uygulanan bir özellik alt kümesi seçme yöntemi olarak görülmüştür ve en başarılı ön işleme algoritmalarından biridir. Aslında relief algoritmaları genel özellik tahmin edicileridir ve çeşitli ortamlarda başarıyla kullanılmıştır.

Bireysel değerlendirme filtreleme özellik seçim yöntemi olarak relief, her özellik için özelliğin 'kalitesini' veya hedef kavramla 'ilgililiğini / alakalılığını' (yani son nokta değerini tahmin etmek) tahmin etmek için kullanılabilecek bir vekil istatistik (a Proxy statistic) hesaplar. Her bir niteliğe, birbirine çok yakın olan öğeleri ayırt etmeye yarayan ağırlıklar atanır. Sınıflandırma veri setleri söz konusu olduğunda, her örnek için relief aynı sınıf (en yakın isabet) içindeki ve farklı bir sınıf (en yakın ıska) içindeki en yakın elemanları araştırır ve her bir A özniteliğinin ağırlığını örnek değeri ve en yakın isabet ve en yakın ıskalama değerleri arasındaki farkla orantılı olarak günceller [79].

Relief algoritmasında girdi her eğitim örneği için nitelik değerlerinden ve sınıf değerinden oluşan bir vektör, çıktı ise niteliklerin kalitesine ilişkin tahminlerin olduğu W vektörüdür. Temel relief algoritmasına ait sözde kod yedi adımdan oluşur. Tüm özniteliklerin ağırlığı başlangıçta sıfıra ayarlanır (adım 1). Daha sonra rastgele bir R_i örneği seçilir (adım 3). Biri R_i 'nin ait olduğu aynı sınıftan en yakın isabet H olarak bilinen ve diğeri en yakın ıska M olarak bilinen farklı sınıftan en yakın iki komşusu bulunur (adım 4). Artık tüm nitelik ağırlıkları R_i , M ve H'nin (5. ve 6. adım) değerine bağlı olarak güncellenir. Tüm bu süreç m sayıda

tekrarlanır. Burada a nitelik sayısını ifade eder. Temel relief algoritmasına ait pseudo Tablo 3-1’de verilmiştir [81].

Tablo 3-1: Temel relief algoritmasına ait pseudo kod

Adım 1:	set all weights $W[A] := 0.0$;
Adım 2:	for $i := 1$ to m do begin
Adım 3:	randomy select an instance R_i ;
Adım 4:	find nearest hit H and nearest miss M ;
Adım 5:	for $A := 1$ to a do
Adım 6:	$W[A] := W[A] - \text{diff}(A, R_i, H)/m + \text{diff}(A, R_i, M)/m$;
Adım 7:	end;

Temel relief algoritmasına ait sözde kodun 6. adımında kullanılan fark işlevi nominal nitelikler için Denklem (13), sayısal özellikler için Denklem (14) olarak ifade edilir.

$$\text{diff}(A, I_1, I_2) = \begin{cases} 0; & \text{value}(A, I_1) = \text{value}(A, I_2) \\ 1; & \text{otherwise} \end{cases} \quad (13)$$

$$\text{diff}(A, I_1, I_2) = \frac{|\text{value}(A, I_1) - \text{value}(A, I_2)|}{\max(A) - \min(A)} \quad (14)$$

3.8 Hızlı Fourier Dönüşümü (FFT)

Ayrık fourier dönüşümünün daha hızlı hesaplanması olarak tanımlanan hızlı fourier dönüşümü (FFT), giderek artan ağırlıklı toplamalarının sıralı olarak birleştirilmesini sağlayan akıllı bir hesaplama tekniğidir. FFT algoritması, ayrık fourier dönüşümü (DFT) hesaplamaları için gerekli aritmetik işlemlerin sayısını birkaç büyüklük sırasına göre azaltır. Bu şekilde işlemlerin pratik olarak yapılmasına olanak sağlamaktadır [82]. Hızlı algoritmalar kullanıldığında sonlu ayrık fourier dönüşümün kullanımı ve özellikleri pratik bir hal almaktadır. Güç spektrumu analizi ve filtre simülasyonu gibi sinyal analizlerini kolaylaştırarak hızlı işlem yapılmasına imkan tanımaktadır. Ayrık fourier dönüşümü katsayılarının iteratif olarak hesaplanmasında hızlı fourier dönüşümü zaman tasarrufu ve verimlilik sağlamaktadır [83]. FFT

hesaplama süresinin azaltılmasının yanı sıra sistematik hataları (yuvarlama hataları) önemli ölçüde azaltmaktadır. FFT ile yuvarlama hataları ve hesaplama süreleri genellikle $(\log 2N)/N$ faktörü ile azaltılmaktadır. Burada N , zaman serisindeki veri örneklerinin sayısını temsil etmektedir [84].

3.9 Güç Spektral Yoğunluğu (PSD)

Bir sinyalin frekansa karşı ölçüsü güç spektral yoğunluğu (PSD) olarak bilinmektedir. Bir başka deyişle PSD sinyalin gücünün frekansla nasıl dağıldığını göstermektedir. PSD genel olarak geniş bantlı rastgele sinyallerin analizi ve karakterize edilmesi için kullanılmaktadır. PSD'nin genliği, sinyali sayısallaştırmak için kullanılan spektral çözünürlük ile normalize edilir. Geleneksel olarak durağan bir sinyalin güç spektral yoğunluğu, hızlı fourier dönüşümüne (FFT) dayalı optimum algoritmalar kullanılarak ayrık fourier dönüşümün (DFT) hesaplanmasıyla elde edilmektedir. N örnekten oluşan bir sinyal için periodogram olarak bilinen güç spektral yoğunluğu ise Denklem (15) ile elde edilmektedir [85].

$$P_x(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n) e^{-j2\pi f n} \right|^2 = \frac{1}{N} |X(f)|^2 \quad (15)$$

3.10 Sürekli Dalgacık Dönüşümü (CWT)

Durağan olmayan EEG sinyallerinin zaman frekans analizi frekansın zamana göre değişimini ifade etmektedir. Zaman-frekans analizi için STFT (kısa zamanlı Fourier dönüşümü) ve CWT (sürekli dalgacık dönüşümü) olmak üzere iki yol bulunmaktadır.

STFT fourier dönüşümünün (FT) zayıf zaman çözünürlüğünün üstesinden gelmek ve sinyallerin frekans bilgisini sağlamak amacıyla geliştirilmiştir. STFT bir sinyalin zaman-frekans gösterimini sunmaktadır. Sinyalin ayrıca frekansının zamanla nasıl değiştiğinin analizinde kullanılmaktadır. STFT $x(n)$ sinyalini sabit uzunlukta bir pencere fonksiyonuyla (W) baştan sona hareket ettirerek fourier dönüşümlerini elde eder. STFT'ye ait matematiksel bağıntı Denklem (16) ile ifade edilmektedir [2].

$$S(m, k) = \sum_{n=0}^{N-1} x(n) W(n-m) e^{-j\frac{2\pi}{N} k(n-m)} \quad (16)$$

Eş zamanlı sıkıştırma dönüşümü ölçek veya frekans katsayılarını yeniden atayarak doğrusal zaman-frekans gösterimini keskinleştirmek amacıyla geliştirilmiş bir son işlem metodudur.

STFT, Fourier dönüşümünü her kısa segmentte ayrı ayrı hesaplar. Dolayısıyla STFT'de her frekans bandı için pencere uzunluğu aynıdır. Bu düşük frekans bandında doğru bir tahmin yapmak için çok kısa, ancak yüksek frekans bandının durağan olmayan aktiviteyi yakalaması için çok uzun olmaktadır. STFT'lerden farklı olarak CWT, farklı frekans bantları için farklı pencere uzunlukları kullanılır. Bu nedenle, CWT hem düşük frekanslı aktivite için iyi bir frekans çözünürlüğüne hem de yüksek frekanslı aktivite için iyi bir zaman çözünürlüğüne sahip olmaktadır [86].

CWT sinyalleri analiz etmek ve onlardan bilgi çıkarmak için kullanılan matematiksel bir araçtır. CWT özünde, bir sinyali kendisini oluşturan dalgacıklara ayırmanın ve her bir dalgacığı farklı ölçeklerde analiz etmenin bir yoludur. CWT'nin en önemli avantajlarından biri zaman-frekans analizi yapabilmesidir. Bu, sinyali farklı ölçeklerde analiz ederek ve zaman içindeki frekans dağılımları hakkında bilgi çıkararak elde edilir. CWT farklı zaman noktalarında sinyalin ayrıntılı bir analizini sağlayabilir ve zaman içinde sinyaldeki değişiklikleri izlemelerine olanak tanımaktadır. CWT Özellikle frekans dağılımının zaman içinde değiştiği durağan olmayan sinyalleri analiz etmek için kullanışlıdır. Ayrıca CWT ile sinyallerin farklı ölçeklerde analiz edilebilmesi sayesinde sinyalin detaylı analizi gerçekleştirilebilmektedir.

CWT, sabit bir ayırık ölçek kümesi yerine sürekli bir ölçek aralığı kullanması bakımından ayırık dalgacık dönüşümünden (DWT) farklıdır. Bu, onu daha esnek hale getirir ve sinyalin daha ayrıntılı bir şekilde analiz edilmesine olanak tanır. Öte yandan DWT, analizin doğruluğunu sınırlayabilen sabit bir ölçek kümesi kullanır. CWT'nin DWT'ye göre bir diğer avantajı da yüksek frekanslarda sinyalin daha doğru bir temsilini sağlayabilmesidir. DWT, sinyalin yüksek frekanslı bileşenlerinin analizde doğru bir şekilde temsil edilmediğinde ortaya çıkan örtüşme adı verilen bir olgudan muzdarip olabilir. Ancak CWT bu sorundan muzdarip değildir ve tüm frekanslarda sinyalin daha doğru bir temsilini sağlayabilmektedir.

Sürekli dalgacık dönüşümü dalgacık fonksiyonu, ölçekleme fonksiyonu ve CWT formülü de dahil olmak üzere çeşitli matematiksel kavramlara dayanmaktadır. Dalgacık fonksiyonu, sinyalleri farklı ölçeklerde analiz etmek için kullanılan matematiksel bir fonksiyondur. Dalgacık fonksiyonu tipik olarak sıfırdan başlayan, kısa bir süre için salınan ve sonra sıfıra dönen düzgün bir fonksiyon olarak tanımlanır. Dalgacığın şekli, süresi ve frekansı analizin özel ihtiyaçlarına uyacak şekilde ayarlanabilir. Dalgacık fonksiyonları, ortogonallik, kompakt destek ve

pürüzsüzlük gibi belirli bir şekle ve özelliklere sahip olacak şekilde seçilir. Ortogonalite, dalgacık fonksiyonunun bir sinyali örtüşmeyen alt bantlara ayırmak için kullanılabilmesini sağlamaktadır. Kompakt destek dalgacık fonksiyonunun sonlu bir aralık dışında sıfır olmasını sağlamaktadır. Bu durum sonlu destekli sinyalleri analiz etmek için kullanışlıdır. Düzgünlük, dalgacık fonksiyonunun türevlenebilir olmasını sağlayabilmesi nedeniyle düzgün değişimlere sahip sinyalleri analiz etmek için önemlidir. Ölçekleme fonksiyonu, farklı ölçeklerdeki sinyalleri analiz etmek için kullanılan matematiksel bir fonksiyondur. Bir sinyale uyacak şekilde çevrilebilen ve ölçeklendirilebilen alçak geçiren bir filtredir. Ölçekleme fonksiyonu tipik olarak sıfırdan başlayan, uzun süre salınan ve sonra sıfıra dönen düzgün bir fonksiyon olarak tanımlanır. Ölçekleme fonksiyonu, farklı ölçeklerde dalgacık fonksiyonu oluşturmak için kullanılır. Ölçekleme fonksiyonu genellikle bir sinyali bir dizi düşük geçişli alt banda ayırmak için kullanılan bir dizi ölçekleme katsayısı üretmek için kullanılır. Sürekli dalgacık dönüşümüne ait formül Denklem (17) ile ifade edilmektedir.


$$C(a,b) = \int f(t)\psi(t-a,b)dt \quad (17)$$

Burada $C(a,b)$ belirli bir ölçek (a) ve konum (b) için dalgacık katsayısı, $f(t)$ analiz edilecek sinyal ve $\Psi(t-a,b)$ a ölçeğinde ve b konumunda dalgacık fonksiyonudur.

Sürekli dalgacık dönüşümü sinyal işleme, görüntü sıkıştırma ve örüntü tanıma dahil çok çeşitli uygulamalarda kullanılabilen güçlü bir tekniktir. Bu teknik sinyal işlemede giderek daha popüler hale gelmiş ve görüntü işleme, ses sinyali işleme ve jeofizik dahil birçok alanda uygulamaları bulunmaktadır. Sinyal işleme bilimsel araştırmalarda giderek daha önemli bir rol oynamaya devam ettikçe, CWT'nin uzun yıllar boyunca önemli bir araç olmaya devam etmesi muhtemeldir [87].

4. MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE PERFORMANS KRİTERLERİ

Yapay zeka (AI) makinelerin deneyimlerden öğrenmesini, yeni girdilere uyum sağlamasını ve insan benzeri görevleri yerine getirmesini mümkün kılar. Makine öğrenmesi (ML), makinelere verilerden ve geçmiş deneyimlerden otomatik olarak öğrenme yeteneği sağlarken, minimum insan müdahalesi ile tahminlerde bulunmak için kalıpları tanımlayan bir yapay zeka disiplini. Derin öğrenme (DL), makine öğrenme yöntemleri ailesinin bir parçası olup belirli bir göreve özgü algoritmaların aksine veri temsillerini öğrenmeye dayalı çalışan algoritmaları kapsamaktadır [88]. Yapay zeka, makine öğrenmesi ve derin öğrenme arasındaki ilişki Şekil 4-1’de gösterilmektedir.



Şekil 4-1: Yapay zeka, makine öğrenmesi ve derin öğrenme arasındaki ilişki

Tekrarlayan sinir ağı (RNN) dizi verilerini işlemek için tasarlanmıştır. RNN gücü zaman ilişkisini ve mantıksal özellikleri keşfetme yeteneğinde yatmaktadır [89]. Tekrarlayan sinir ağı (RNN) zamanla değişen bir sinyalin altında yatan bilgisini öğrenmede oldukça iyidir. En yaygın kullanılan RNN çeşitleri LSTM, GRU, BiLSTM modelleridir [90]. RNN zamansal bilgi üzerinde çalışmaktadır.

4.1 Uzun Kısa Süreli Bellek (LSTM)

RNN'nin geliştirilmiş bir mimarisi olan uzun kısa süreli bellek (LSTM) bilgileri daha iyi saklamaktadır. Bu sayede LSTM, standart RNN'in kısa süreli bellek problemini ortadan kaldırmaktadır. Bir başka deyişle LSTM modelinde bilgiler daha uzun süreli olarak tutulabilmektedir [91]. LSTM geçmiş bilgileri hatırlayarak tahminde bulunmaktadır. LSTM modeline ait matematiksel bağıntılar Denklem (18), (19), (20), (21) ve (22)' de görülmektedir.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (18)$$


$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (19)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (20)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (21)$$

$$h_t = o_t * \tanh(C_t) \quad (22)$$


Burada σ sigmoid aktivasyon fonksiyonu, W ağırlık vektörü, b bias değeri, o_t çıkış, i_t giriş ve f_t unutma kapısı ifade etmektedir. Giriş değeri x_t iken, h_{t-1} ise t-1 zamanında nöronun çıkışını belirtmektedir. LSTM mimarisinin iç yapısına ait gösterim Şekil 4-2'de görülmektedir.



Şekil 4-2: LSTM mimari iç yapısı

4.2 Geçitli Tekrarlayan Birim (GRU)


Standart RNN'nin kaybolan gradyan probleminin üstesinden gelmek için geçitli tekrarlayan birim (GRU) modeli RNN'nin geliştirilmiş bir versiyonu olarak sunulmuştur. GRU LSTM'in daha basit bir sürümü olarak tasarlanmıştır. Daha düşük hesaplama tekniğine sahip olması ve yapısının daha basit olması sayesinde LSTM modeli ile karşılaştırıldığında daha hızlı ve anlaşılır bir modeldir. LSTM modelinden farklı olarak GRU modelinde tek bir kapının hem unutma hem de güncelleme kararını aynı anda kontrol etmektedir[74]. GRU mimarisinin iç yapısına ait gösterim Şekil 4-3'de görülmektedir.



Şekil 4-3: GRU mimari iç yapısı

4.3 İki Yönlü Uzun Kısa Süreli Bellek (BiLSTM)


Çift yönlü LSTM anlamına gelmekte olan iki yönlü uzun kısa süreli bellek (BiLSTM), LSTM modelinin geliştirilmiş bir versiyonudur. BiLSTM modelinin LSTM modelinden farkı, ortak giriş ve çıkışı iki LSTM hücresi paylaşır. İki yönüde kullanabilmesi sayesinde giriş verilerinden farklı özellikleri öğrenebilmektedir [92]. BiLSTM modelinin en önemli özelliklerinden biri geçmiş ve gelecek verileri değerlendirerek buna göre uygun bir model çıkışı sağlamasıdır [93]. BiLSTM mimarisinin iç yapısına ait gösterim Şekil 4-4'te görülmektedir.



Şekil 4-4: BiLSTM mimari iç yapısı

4.4 Bir Boyutlu Evrişimli (Konvolüsyonel) Sinir Ağı (1D-CNN)

İlk olarak 1989 yılında LeCun ve arkadaşları tarafından gradyan temelli bir yaklaşımla sunulan evrişimli sinir ağları bir diğer adıyla konvolüsyonel sinir ağları ileri beslemeli bir yapay sinir ağı ve derin öğrenme mimarisidir. Evrişimli sinir ağları temel olarak bir girdi katmanından, bir çıktı katmanından ve girdi ile çıktı katmanları arasındaki birden fazla gizli katmanlardan oluşur. Evrişimli sinir ağına ait temel katmanlar Şekil 4-5’de görülmektedir.




Şekil 4-5: Evrişimli sinir ağına ait temel katmanlar

CNN algoritmasına ait matematiksel bağıntı Denklem (23) ile gösterilmektedir [94].

$$y_k = \sum_{n=0}^{N-1} x_n h_{k-n} \quad (23)$$


Tipik bir evrişimli sinir ağında gizli katman üç katman türü içerir. Bunlar evrişim katmanları, havuzlama katmanları ve tam bağımlı katmanlardır [95]. Tipik bir evrişimli sinir ağının kapsamlı iç yapısı Şekil 4-6'da görülmektedir.



Şekil 4-6: Tipik bir evrişimli sinir ağının kapsamlı iç yapısı


Evrişim katmanı, evrişimli sinir ağının ilk katmanıdır ve temel yapı taşıdır. Hesaplamaların büyük çoğunluğu bu katmanda gerçekleşir. Evrişimli katmanları bazı modellerde havuzlama katmanı takip ederken bazı modellerde ise ek evrişimli katmanlar takip eder. Havuzlama katmanı, evrişimli özelliğin uzamsal boyutunun azaltılmasından sorumludur ve boyutları azaltarak veri işlemek için gereken hesaplama gücünü azaltır. Havuzlama katmanında ortalama havuzlama ve maksimum havuzlama olmak üzere iki tür havuzlama işlemi gerçekleştirilir. Havuzlama katmanı boyut azaltmanın yanı sıra aynı zamanda gürültü bastırma görevi de görmektedir. Tam bağımlı katman ise son katmandır. Her katmanla birlikte CNN'nin karmaşıklığı artar ve görüntünün daha büyük bölümleri tanımlanmaktadır. Yapay sinir ağlarından çok katmanlı ileri beslemeli bir mimariye sahip olan evrişimli sinir ağında (CNN) her katman kendisinden sonraki katmanın giriş katmanı işlevini görür.

Evrişimli sinir ağı görüntü, video, ses, görüntü ve metin işleme gibi uygulamalarda her geçen gün artan kullanımının yanı sıra son yıllarda diğer sınıflandırma ve biyometrik kimlik tanımlama gibi uygulamalarda da popüler hale gelmiştir [96]. CNN verilerdeki basit örüntüleri belirlemede ve üst düzey katmanları oluşturmak için bu basit örüntüleri kullanma başarılıdır. CNN algoritmaları alansal bilgi üzerinde çalışmaktadır. 1D-CNN genel veri kümesinin kısa bölümlerinden ilgilenilen özelliklerini elde edebilmektedir [97]. 1D-CNN'ye ait şematik gösterim Şekil 4-7'de görülmektedir.



Şekil 4-7: 1D-CNN şematik gösterimi

Çalışmada uygulanan 1D-CNN üzerindeki eğitim ve test süreçlerinde, iki sınıfa ait (the one-versus-the others) veri setlerindeki her etiket için 64 örnek x 2 kanal kullanılmıştır. İki kanal için kullanılan elektrotlar Fp1 ve Fp2 elektrotlarıdır. 1D-CNN yönteminde sınıf ve katlara ait değerler Şekil 4-8'de gösterilmektedir. Böylece biyometrik kimlik doğrulama çalışmalarında EEG alfa frekansında 2 kanal verisi üzerinden performans değerlendirilmesi gerçekleştirilmiştir. 1-D CNN'de veri işlemede kullanılan mimari yapı Tablo 4-1'de görülmektedir.



Şekil 4-8: 1D-CNN'de sınıf ve katlara ait değerlerin gösterimi

Tablo 4-1: 1D-CNN'de veri işlemede kullanılan mimari yapı


FilterSize (Filtre Boyutu)	4
NumFilters (Filtre Sayısı)	4
Aktivasyon Fonksiyonu	ReLU
MiniBatchSize	100
Training Optimization	Adam
MaxEpochs	120

4.5 Karar Ağaçları (DT)

Bir karar ağacı, örnek uzayının özyinelemeli bir bölümü olarak ifade edilen bir sınıflandırıcıdır. Karar ağacı, köklü bir ağaç oluşturan düğümlerden oluşur, yani kök olarak bilinen bir düğüme sahip yönlendirilmiş bir ağaçtır. Kök düğümü haricindeki düğümlerin bir giriş ucu bulunmaktadır. Bir düğümün çıkış ucu var ise bu düğüm iç veya test düğümü olarak

adlandırılır. Geriye kalan diğer düğümler ise yaprak veya terminal olarak adlandırılır ve karar olarak bilinmektedir. Karar ağaçlarındaki iç düğümler örnek uzayını iki veya daha fazla alt uzaya bölerken giriş öznitelik değerlerinin ayrık fonksiyonunu dikkate almaktadır. En yaygın ve en basit durumda her test sadece bir özniteliği dikkate alarak örnek uzayı özniteliğin değerine göre bölümlenir. Sayısal özniteliklerin olduğu durumlarda, koşul bir aralığı ifade eder [98].

Karar ağacındaki bütün yapraklar atandıkları sınıfta en uygun hedef değeri göstermektedir. Diğer bir seçenek olarak ise yaprak, hedef niteliğin belirli bir değere sahip olma olasılığını gösteren bir olasılık vektörü tutabilir. Örnekler, ağaç kökünden başlayarak bir yaprağa doğru yol boyunca uygulanan testlerin neticeleri doğrultusunda ilerletilerek sınıflandırılır. Karar ağaçlarına ait blok diyagram Şekil 4-9'da gösterilmektedir.



Şekil 4-9: Karar ağaçları blok diyagramı

Karar ağacı algoritmaları, karar almak için öznitelik değerlerini kullanarak sınıflandırmaya dayanır. Karar ağacı verileri kararlar alınmayana kadar kökten bir yaprak düğüme sınıflandırır. Karar ağacı, verileri çok kolay bir şekilde temsil eder ve kullanıcılar tarafından yorumlanır. Bu nedenle karar ağacı sınıflandırma algoritmaları sonuçların daha kolay gösterimi ve kolay uygulanabilirliği gibi avantajlarından ötürü yaygın olarak kullanılmaktadır. Karar ağacının uygulanması veri hacmi, kullanılan bellek ve ölçeklenebilirliğe göre paralel veya seri olarak yapılabilmektedir [99].

4.6 Doğrusal Ayırma Analizi (LDA)

Doğrusal ayırma analizi (LDA) veri sınıflandırması ve boyut azaltılması için kullanılan en yaygın teknikler arasındadır. LDA sınıf içi frekansların eşit olmadığı ve performansların rastgele sınıflar içinde incelendiği durumları kolaylıkla analiz edebilmektedir. Bu yöntem sınıflar arası varyansın sınıf içi varyansa oranını maksimize ederek maksimum ayrılabilirliği sağlar [100]. LDA iki veya daha fazla sınıfa ait örnekleri ayırtmak için bir doğrusal sınıflandırıcı kullanarak özelliklerin doğrusal kombinasyonunu bulmaya çalışır. Diğer bir deyişle her bir sınıfa ayırabilen uzaya ait vektörleri elde etmeye çalışan bir yöntemdir. LDA ayırt edici fonksiyonları belirler. Bu fonksiyonlar aracılığıyla gruplar arasındaki ayırma en baskın ayırt edici değişkenleri elde etmektedir. Bu yaklaşım mevcut verilerin birleşimi olan yeni bir değişken üretir. Aynı sınıftaki verileri birbirine yaklaştırırken farklı sınıflardaki verileri birbirinden uzaklaştırır [101].

LDA, tüm sınıfların doğrusal olarak ayrılabilirliği varsayımına dayanır. Bu bakış açısıyla, sınıfları birbirinden ayırmak için özellik uzayında hiper düzlemleri temsil eden birden fazla LDA fonksiyonu oluşturulur. Genellikle özellikleri iki farklı sınıf arasında sınıflandırmak için kullanılsa da doğrusal ayırma analizi ikiden fazla sınıfa sahip veri kümelerini ayırmak için de kullanılabilir. İki sınıflı bir veri seti için, her bir sınıfa ait veriler, bu iki sınıfın ayrılmasını maksimize eden bir hiper düzlem ile ayrılır. Bu hiper düzlem, iki sınıfın ortalamaları arasındaki mesafeyi maksimize etme ve her bir kategori arasındaki varyasyonu minimize etme kriterlerine göre oluşturulur [102].

PCA ile karşılaştırıldığında görülen en büyük fark PCA özellik sınıflandırma yapar iken LDA veri sınıflandırması yapmaktadır. PCA'da orijinal veri setleri farklı bir uzaya dönüştürüldüğü için orijinal veri setinin şekli ve konumu değişirken LDA'da ise veri setinde konum değişimi görülmez sadece daha fazla sınıf ayrılabilirliği ve karar bölgesi çizilmesi sağlanır. Ayrıca LDA özellik verisinin dağılımının daha iyi anlaşılmasına yardımcı olur [100].

4.7 k-Kat Çapraz Doğrulama

İki veya daha fazla yöntemin tahmin doğruluğunun karşılaştırılmasında rastgele yöntemle ilişkili önyargıyı mümkün mertebe minimum seviyeye indirmek için k-kat çapraz doğrulama kullanılmaktadır. K-kat çapraz doğrulamada, tüm veriler rastgele k adet birbirini dışlayan ve yaklaşık olarak eşit boyutlu alt kümelerine bölünür. Sınıflandırma algoritması eğitilip ve k defa

test edilir. Her durumda, katlardan biri test verisi olarak alınır ve kalan katlar ise eğitim verilerini oluşturur. Böylece her eğitim-test konfigürasyonu için k farklı test sonucu bulunmaktadır. Bu sonuçların ortalaması algoritmanın test doğruluğunu verir. Eğer bir sinir ağı bir problemin eğitim setini öğrenirse, o probleme genelleme yapmaktadır. Yani, bu tip eğitilmiş sinir ağı, eğitilmemiş test setleri için de benzer sonuçlar verir. Ancak, bir sinir ağı eğitimi ezberlemeye başlarsa yapılan genelleşme azalmaya başlar ve performansı eğitimsiz test setleri için iyileştirilemeyebilir. K-kat çapraz doğrulama yöntemi sinir ağı yapıları kullanılarak ne kadar iyi genelleme yapılabileceğini göstermektedir [103]. Bu çalışmada, 3 kat çapraz doğrulama yaklaşımı kullanılarak biyometrik kimlik doğrulamanın performansı tahmin edilmiştir. Çalışmada kullanılan 3 kat çapraz doğrulamaya ait şematik gösterim Şekil 4-10'da görülmektedir.



Şekil 4-10: Üç kat çapraz doğrulamaya ait şema

4.8 Performans Metrikleri

Bir problemin çözümü için en uygun metodun bulunması ve örüntü tanımlama görevlerinde makina öğrenme modellerinin değerlendirilmesi için performans metrikleri anahtar niteliğindedir. Veri bilminde uygun metriklerin seçimi kritik öneme sahiptir. Temel metriklerden diğer metriklerin elde edilmesi için Şekil 4-11'deki karışıklık matrisi kullanılmaktadır. Doğru tahminlerin sayısının toplam tahmin sayısına oranı sınıflandırma doğruluğu (ACC) olarak adlandırılır. Fakat sadece ACC parametresi üzerinden bir algoritmanın performansını değerlendirmek yeterli olmamaktadır. Bu yüzden özgüllük (SPEC), duyarlılık (SENS), kesinlik (PREC), AUC ve f-skoru (F) dahil olmak üzere diğer istatistiksel performans ölçütleri bu bağlamda dikkate alınmaktadır. F-skor kesinlik ve duyarlılığın harmonik

ortalamasıdır. Biyometrik tanımlama ve kimlik doğrulama çalışmalarında derin öğrenme modellerinin performanslarını ölçmek için dikkate alınan değerlendirme metrikleri önem arz etmektedir.

		Tahmin / Predicted	
		Pozitif / Positive	Negatif / Negative
Gerçek / Actual	Pozitif / Positive	Doğru Pozitif True Positive(TP)	Yanlış Negatif False Negative (FN)
	Negatif / Negative	Yanlış Pozitif False Positive (FP)	Doğru Negatif True Negative (TN)

Şekil 4-11: Karışıklık matrisine ait şema

Biyometrik tanımlama ve kimlik doğrulama çalışmalarında kullanılan en yaygın metrikler; doğruluk (ACC), kesinlik (PREC), özgüllük (SPEC), duyarlılık (SENS), f-score ve AUC değerleridir. ACC, SPEC, SENS, PREC ve f-score değerlerine ait formüller sırasıyla Denklem (24), (25), (26), (27), (28)'de belirtilmektedir [104]. Formüllerdeki FP yanlış pozitif, FN yanlış negatif, TP doğru pozitif ve TN doğru negatifi ifade etmektedir.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (24)$$

$$SPEC = \frac{TN}{TN + FP} \quad (25)$$

$$SENS = \frac{TP}{TP + FN} \quad (26)$$

$$PREC = \frac{TP}{TP + FP} \quad (27)$$

$$F - score = 2 \times \frac{PREC \times SENS}{PREC + SENS} \quad (28)$$


5. ANALİZ VE BULGULAR

Bu bölümde dinlenme durumunda EEG alfa frekansında biyometrik kimlik tanımlama ve doğrulama çalışmalarına ait analiz ve bulgular yer almaktadır. Biyometrik kimlik tanımlama ve doğrulama çalışmalarında makine öğrenme modellerinde yaygın olarak kullanılan; doğruluk (ACC), duyarlılık (SENS), özgüllük (SPEC), kesinlik (PREC), kesinlik ve duyarlılık değerlerinin harmonik ortalaması (f-score), eğri altında kalan alan (AUC) gibi parametre metrikleri üzerinden çalışmaların performansı değerlendirilmiştir.


5.1 Biyometrik Tanımlama Çalışması

Dinlenme durumu EEG alfa frekansında gerçekleştirilen biyometrik tanımlama çalışmasına ait analiz ve bulgular bu kısımda ele alınmaktadır.


Dinlenme durumunda EEG alfa frekansında ilk iki katılımcıya ait çok kanallı sonuçları Şekil 5-1, üç-sekiz katılımcılarına ait EEG sinyal sonuçları Şekil 5-2'de, dokuz-ondört nolu katılımcılarına ait EEG sinyal sonuçları Şekil 5-3'de, son altı katılımcıya EEG sinyallerine ait grafikler Şekil 5-4'de gösterilmektedir. Her kişiye ait EEG sinyalleri onaltı kanaldan oluşmakta olup, kişilerin EEG sinyallerinin uzunlukları ve sinyal seviyeleri birbirinden farklı olduğu görülmektedir. Elde edilen sinyaller μV düzeyindedir.




Şekil 5-1: 1-2 kişilerine ait çok kanallı EEG sinyalleri




Subject-3




Subject-4




Subject-5



Subject-6




Subject-7




Subject-8


Şekil 5-2: 3-8 kişilerine ait çok kanallı EEG sinyalleri




Subject-9




Subject-10




Subject-11



Subject-12




Subject-13




Subject-14


Şekil 5-3: 9-14 kişilerine ait çok kanallı EEG sinyalleri




Subject-15




Subject-16




Subject-17



Subject-18



Subject-19




Subject-20

Şekil 5-4: 15-20 kişilerine ait çok kanallı EEG sinyalleri


EEG sinyalleri elde edilirken kişilerin dinlenme durumuna geçerek herhangi bir düşünsel aktivite içerisinde bulunmaması beklenmektedir. Fakat EEG kayıtları esnasında kişilerin hangi düşünce içerisinde olduğu ya da hangi düşünce görevini gerçekleştirdiğini gözlemlemek oldukça zordur. Kişilerin düşünsel aktivite içerisine girerek tam bir dinlenme süreci içerisinde bulunmaması durumunda beynin central lob, frontal lob gibi farklı loblarında da bir sinyal gözlenmesi muhtemeldir. Özellikle kişilerin zihinsel aktivitelerinde uzuv düşünsellerin gerçekleştirilmesi ve hayal edilmesinde bu uzuvlardan dolayı beyinde oluşan sinyallerin central lobta oluşması muhtemeldir. Örneğin bir parmağımızın hareketini gerçekleştirmek istediğimizde ya da parmağımızı bir yere dokundurduğumuz anda beynin merkez bölgesinde bulunan central lob çalışmakta ve beynin bu lobunda bir sinyal meydana gelmektedir.

Yirmi katılımcının (subject) dinlenme durumundaki EEG alfa frekansı üzerinden elde edilen kişiye özel beyin haritalama görüntüleri Şekil 5-5'te verilmektedir. Katılımcıların EEG kayıtlarına ait sinyal yoğunluğunun bölgesel dağılımını gösteren beyin haritalama görüntüleri biyometrik tanımlama çalışmasında katılımcıların içerisinde bulunduğu duruma ait bir öngörü sağlamaktadır. Beyin haritalama görüntülerindeki sinyallerin güç spektral yoğunluğuna ait değerler μV^2 düzeyindedir. Dinlenme durumunda EEG alfa frekansında genel olarak beklendiği gibi yirmi kişinin oksipital ve parietal loblarında güç yoğunluklarının oluştuğu gözlenmektedir. Oksipital lob ve parietal lobun dışında bazı katılımcılarda gözlerin kapalı olmasına rağmen zihinsel bir görev yerine getirilmesinden dolayı frontal lobta sinyallerin etkili olduğu, bazı katılımcılarda ise zihinsel uzuv düşünsellerinin hayalinden dolayı central lobta da sinyallerin oluştuğu görülmektedir.


Yirmi kişinin dinlenme durumunda EEG alfa frekansında CWT yöntemi ile yapılan zaman-frekans analizine ait gösterim Şekil 5-6'da görülmektedir. Dinlenme durumunda elde edilen EEG alfa frekansındaki sinyaller 10 sn'lik zaman penceresinde incelendiğinde sinyallerin oldukça yüksek güce sahip olduğu görülmüştür. Bu yüksek güçlü sinyaller katılımcıların bazılarında gözler açık bazılarında ise gözler kapalı durumunda iken elde edilmiştir. Oluşan sinyallerin frekans değerleri incelendiğinde genellikle alfa frekansı olarak bilinen 8-13 Hz aralığında yoğunlaştığı görülmektedir. Parietal ve oksipital lob bölgelerinden elde edilen sinyallerin büyük oranda beklenen frekans aralığında oluştuğu gözlenmiştir. Grafiklerin sağ tarafında bulunan renk haritasındaki renkler ve seviyeler sinyalin güç yoğunluk büyüklüğünü ifade etmektedir. Sarı renkli bölgeler grafiklerdeki en yüksek güç yoğunluğunun oluştuğu zaman ve frekans aralığını ifade etmektedir.




Şekil 5-5: Dinlenme durumu EEG alfa frekansında 20 kişiye ait beyin haritası sonuçları




Şekil 5-6: Dinlenme durumunda EEG alfa frekansında yirmi kişiye ait CWT zaman- frekans analizi sonuçları




Şekil 5-7: 1-6 kişilerine ait dinlenme durumunda EEG alfa frekansında güç spektrum yoğunluğu (PSD) grafikleri



Şekil 5-8: 7-12 kişilerine ait dinlenme durumunda EEG alfa frekansında güç spektrum yoğunluğu (PSD) grafikleri



Şekil 5-9: 13-18 kişilerine ait dinlenme durumunda EEG alfa frekansında güç spektrum yoğunluğu (PSD) grafikleri




Şekil 5-10: 19-20 kişilerine ait dinlenme durumunda EEG alfa frekansında güç spektrum yoğunluğu(PSD) grafikleri

Dinlenme durumunda katılımcıların güç spektral yoğunluk (PSD) grafikleri ilk altı kişi için Şekil 5-7’de, ikinci altı kişi için Şekil 5-8’de, üçüncü altı kişi için Şekil 5-9’da ve son iki katılımcı için ise Şekil 5-10’da görülmektedir. EEG sinyallerinin seviyeleri μV düzeyinde iken güç spektral yoğunluğundaki güç sinyalleri μV^2 birimiyle ifade edilmektedir. Güç spektral yoğunluğu grafikleri incelendiğinde yirmi katılımcıya ait beynin oksipital ve parietal bölgelerinde 8-13 Hz bandında diğer frekanslara göre daha yüksek bir güç ve güç yoğunluğu olduğu gözlenmektedir. Güç yoğunluğu analiz sonuçlarından beklenildiği gibi yüksek güç bölgesinin alfa frekans bandı 8-13Hz aralığında olduğu ve en yüksek güç spektral yoğunluğunun ise 10 Hz civarında olduğu görülmektedir. Elde edilen güç spektral yoğunluk sonuçları kişiler arasında farklılık yaratan bir karakteristiğe sahip olduğunu göstermektedir. Ayrıca en yüksek güç ve güç yoğunluğu değerlerinin her katılımcı için farklı EEG kanallarında olduğu gözlenmektedir.

Dinlenme durumundaki yirmi kişinin EEG alfa frekanslı verileri üzerinden yapılan biyometrik kimlik tanımlama çalışmasının t-SNE saçılım grafik dağılımları Şekil 5-11’de görülmektedir. Yirmi kişiye ait on altı kanallı ham veri seti üzerinden farklı örnekleme frekansları (256-512-1024) için t-SNE boyut azaltma ve görselleştirme tekniği ile saçılım grafikleri elde edilmiştir. Ayrıca dinlenme durumunda alfa frekansının yoğun olduğu parietal ve oksipital bölgelerde bulunan 8 adet kanala ait ham veri seti üzerinden 1024 örnekleme frekansı için t-SNE saçılım grafikleri incelenmiştir. Saçılım grafiklerinde görülen her renk ayrı bir katılımcıyı temsil etmektedir. Yüksek doğruluğa sahip biyometrik tanımlama elde edebilmek


için t-SNE saçılım grafiklerinde bir kişiye ait verilerin kendi içerisinde (intra-class) bir araya gelmesi ve farklı kişilerden ise (inter-class) uzaklaşması gerekmektedir.



Şekil 5-11: 20 kişiye ait ham veri seti üzerinden farklı örnekleme frekanslı t-SNE biyometrik tanımlama saçılım grafikleri

Yirmi kişiye ait ICA yöntemi uygulanmış veri seti üzerinden t-SNE biyometrik tanımlama saçılım grafikleri Şekil 5-12’de görülmektedir. ICA yöntemi uygulanmış on altı kanallı veri setinin, farklı frekans uzunluklarındaki (256-512-1024) sonuçlarının yanısıra oksipital ve parietal bölgede bulunan 8 adet kanala ait t-SNE biyometrik tanımlama saçılım grafikleri elde edilmiştir. ICA yöntemi uygulanmış veri setlerinde özellikle saçılımların kendi içindeki (intra-class) dağılımların daha çok toparlandığı ve farklı bireyler arası (interclass) dağılımın ise birbirlerinden daha çok ayrıştığı görülmektedir. Özetle aynı kişilere ait veriler

birbirine ne kadar yakınlaşır ve diğer kişilerden bu veriler ne kadar uzaklaşırsa biyometrik tanımlamanın o derece başarılı olduğu söylenebilir. Bu sonuçlar ICA yöntemi uygulanmış veri seti üzerinden yapılan biyometrik kimlik tanımlama çalışmasının ham veri seti üzerinden gerçekleştirilen çalışmaya göre daha başarılı olduğunu göstermektedir. Dinlenme durumu EEG alfa frekansında yirmi kişinin t-SNE saçılım grafiklerinden de görüleceği üzere kişilerin ayrışması açısından (farklı renklere sahip kişilerin net şekilde birbirinden ayrılabilirdiği) oldukça iyi sonuçlar elde edildiği gözlenmiştir.




Şekil 5-12: 20 kişiye ait ICA uygulanmış veri seti üzerinden farklı örnekleme frekanslı t-SNE biyometrik tanımlama saçılım grafikleri

Tablo 5-1: EEG alfa frekansında yirmi kişinin RNN yöntemleri ile biyometrik tanımlama sonuçları

	128 Sample			256 Sample			512 Sample		
(%)	GRU	BiLSTM	LSTM	GRU	BiLSTM	LSTM	GRU	BiLSTM	LSTM
ACC	85.38	95	90	90	95	95	95	100	99.95
SENS	100	100	100	100	100	100	100	100	100
SPEC	94.74	100	100	100	100	100	100	100	100

Kişilerin farklı örnekleme frekansı ve farklı derin öğrenme metodları altında yapılan biyometrik tanımlama çalışmasında doğruluk (ACC), duyarlılık (SENS) ve özgüllük (SPEC) performans metriklerine ait sonuçlar Tablo 5-1’de görülmektedir.



Şekil 5-13: Biyometrik tanımlama performans sonuçlarına ait karşılaştırmalı grafiği

Farklı örnekleme uzunlukları için LSTM, BiLSTM ve GRU modellerinin biyometrik tanımlama performans metriklerine ait ACC, SENS ve SPEC sonuçlarının karşılaştırmalı grafiği Şekil 5-13’te görülmektedir.

Yirmi kişiye ait veri setine 80% eğitim 20% test işlemi uygulandıktan sonra farklı zaman aralıklı örnekler için derin öğrenme modellerinin biyometrik tanımlama doğruluk performansları incelenmiştir. Derin öğrenme modellerinden BiLSTM modelinde en iyi doğruluk performansı %100 olarak 512 örnek uzunluğunda elde edilmiştir. Tanımlama sonuçlarındaki doğruluğun zaman dilimlerindeki veri uzunlukları ile doğru orantılı olarak arttığı gözlenmiştir. Bu çalışmada

RNN derin öğrenme yöntemleri ile 85-99% aralığında doğruluk performansları görülmektedir. Yuvarlama hatası nedeniyle 100% oranında sonuçlara ulaşılabilir.

Yirmi kişinin biyometrik tanımlama çalışmalarında 80% eğitim ve %20 test süreci üzerinden analizler gerçekleştirilmiştir. Eğitim verilerinde epoch ve nöron değerleri 100 olarak alınmıştır.

Tablo 5-2: 20 kişiye ait biyometrik tanımlamada karar ağaçları yöntemi sonuçları

Decision Tree									
%	128 Sample			256 Sample			512 Sample		
	gdi	twoing	deviance	gdi	twoing	deviance	gdi	twoing	deviance
ACC	98.63	98.65	98.74	99.52	99.65	99.68	99.5	99.6	99.8
SENS	100	100	100	100	100	100	100	100	100
SPEC	99.57	99,58	99,62	100	100	100	100	100	100

Yirmi kişiye ait biyometrik tanımlama çalışmasında karar ağaçları yöntemi uygulandığında elde edilen doğruluk, duyarlılık ve özgüllük değerleri Tablo 5-2’de görülmektedir.

Tablo 5-3: 20 kişiye ait biyometrik tanımlamada MRMR yöntemi sonuçları

MRMR									
%	128 Sample			256 Sample			512 Sample		
	gru	bilstm	lstm	gru	bilstm	lstm	gru	bilstm	lstm
ACC	90	100	95	94.56	100	97.83	96,21	100	99,74
SENS	100	100	100	100	100	100	100	100	100
SPEC	100	100	100	100	100	100	100	100	100

Yirmi kişiye ait biyometrik tanımlama çalışmasında MRMR yöntemi uygulandığında elde edilen doğruluk, duyarlılık ve özgüllük değerleri Tablo 5-3’de görülmektedir.

Tablo 5-4: 20 kişiye ait biyometrik tanımlamada Relief yöntemi sonuçları

RELİEF									
%	128 Sample			256 Sample			512 Sample		
	gru	bilstm	lstm	gru	bilstm	lstm	gru	bilstm	lstm
ACC	90,23	100	95,12	92,4	100	96,8	99,23	100	99,63
SENS	100	100	100	100	100	100	100	100	100
SPEC	100	100	100	100	100	100	100	100	100

Yirmi kişiye ait biyometrik tanımlama çalışmasında relief yöntemi uygulandığında elde edilen doğruluk, duyarlılık ve özgüllük değerleri Tablo 5-4’de görülmektedir.

Tablo 5-5: 20 kişiye ait biyometrik tanımlamada EMD yöntemi sonuçları

EMD									
%	128 Sample			256 Sample			512 Sample		
	gru	bilstm	lstm	gru	bilstm	lstm	gru	bilstm	lstm
ACC	90,42	98,61	93,67	92,45	100	95,6	95,60	100	99,95
SENS	100	100	100	100	100	100	100	100	100
SPEC	100	100	100	100	100	100	100	100	100

Yirmi kişiye ait biyometrik tanımlama çalışmasında EMD yöntemi uygulandığında elde edilen doğruluk, duyarlılık ve özgüllük değerleri Tablo 5-5’de görülmektedir.

Tablo 5-6: 20 kişiye ait biyometrik tanımlamada LDA yöntemi sonuçları

LDA			
%	128 Sample	256 Sample	512 Sample
ACC	96,52	97,82	100
SENS	100	100	100
SPEC	100	100	100

Yirmi kişiye ait biyometrik tanımlama çalışmasında LDA yöntemi uygulandığında elde edilen doğruluk, duyarlılık ve özgüllük değerleri Tablo 5-6’de görülmektedir.

Tablo 5-7: 20 kişiye ait biyometrik tanımlamada DWT yöntemi sonuçları

DWT- (Level-5)			
%	PCA	MRMR	RELİEF
ACC	99.56	99.36	99.72
SENS	100	100	100
SPEC	100	100	100

Yirmi kişiye ait biyometrik tanımlama çalışmasında DWT yöntemi uygulandığında elde edilen doğruluk, duyarlılık ve özgüllük değerleri Tablo 5-7’de görülmektedir.

Yöntemlerin sonuçları incelendiğinde yüksek performansa sahip bir biyometrik tanımlama çalışması gerçekleştirildiği görülmektedir.


5.2 Biyometrik Kimlik Doğrulama Çalışması

Dinlenme durumu EEG alfa frekansında gerçekleştirilen biyometrik kimlik doğrulama çalışmasına ait analiz ve bulgular bu kısımda ele alınmaktadır.


Dinlenme durumunda EEG alfa frekansında Şekil 5-14’deki t-SNE saçılım grafiklerinde görüldüğü üzere bir kişinin diğer kişilerden ayırt edilebilmesinin oldukça yüksek olduğu görülmektedir. Dinlenme durumunda EEG alfa frekansında biyometrik tanımlama çalışmasında olduğu gibi biyometrik kimlik doğrulama çalışmasındaki t-SNE saçılım grafik sonuçlarında kişiler arasında yüksek ayırt edilebilirliği göstermektedir.

Yirmi kişiye ait elektrot konumlarıyla ilgili her bir katılımcı için benzersiz korelasyon matrisi modelleri Şekil 5-15’de görülmektedir. Yirmi kişinin on altı kanalına ait benzersiz korelasyon matrisi modelleri incelendiğinde her bir kişinin korelasyon grafiğinin birbirlerinden farklı olduğu görünmektedir. Grafiklerdeki renklerin açık olması korelasyonun o bölgede yüksek olduğunu ifade etmektedir. Birinci katılımcının korelasyon grafiği incelendiğinde farklı loblarda korelasyonun birbirlerinden bağımsız olduğu on altı kanaldan alınan verilerin belirli bir bölgede yoğunlaşmadığı görülmektedir. İkinci katılımcının korelasyon matris grafiği incelendiğinde ise en yüksek korelasyonun on dört ile on altı kanalları arasında olduğu yani oksipital bölgede yoğunlaştığı görülmektedir. Altıncı katılımcının grafiği incelendiğinde ise on bir ile on altı

kanalları arası yüksek bir korelasyonun olduğu yani parietal ve oksipital bölgelerde yoğunlaştığı görülmektedir. Bazı katılımcılarda ise farklı beyin bölgelerinde korelasyonun olduğu görülebilmektedir.



Şekil 5-14: 20 kişiye ait dinlenme durumu EEG alfa frekansı için biyometrik kimlik doğrulamada t-SNE saçılım grafikleri (Bir kişinin diğer kişilerden ayırt edilmesi / The One-versus-The Others)




Şekil 5-15: 20 kişiye ait elektrot konumlarıyla ilgili her bir katılımcı için benzersiz korelasyon matrisi modelleri

Katılımcıların grafikleri genel olarak incelendiğinde EEG alfa frekansında beklendiği üzere çoğunlukla oksipital ve parietal loblarda (9-16 nolu kanallar) korelasyonun daha yüksek olduğu gözlenmektedir.

Üç katılımcının ham veri sinyalleri ve ICA yöntemi uygulanmış sinyallerine ait recurrence plot sonuçları Şekil 5-16'da görülmektedir. Buradaki kanallara ait elektrot dizilimi (P7, P3, PZ, P4) ardışıl olarak sıralanmış olup ilgili dizilim Tablo 5-8'de görülmektedir. Bu kanallara ICA yöntemi uygulandığında örüntülerin birbirlerinden daha ayırık hale geldiği görülmektedir. Böylece ICA uygulanmış modelden daha yüksek biyometrik kimlik doğrulama performans sonucu beklenmektedir.

Tablo 5-8: Ardışıl elektrot dizilimi


ELEKTROT DİZİLİMİ				
KANAL NUMARASI	9	10	11	12
KANAL İSMİ	P7	P3	PZ	P4



Şekil 5-17: Ham veri sinyalleri ve ICA yöntemi uygulanmış sinyallere ait Manova gruplama yöntemi ile biyometrik ayırım grafikleri

Ham veri sinyalleri ve ICA yöntemi uygulanmış sinyallere ait manova gruplama yöntemi ile biyometrik ayırım grafikleri Şekil 5-17'de görülmektedir. Ham veri sinyalleri manova gruplama yöntemi ile analiz edildiğinde on dokuz nolu katılımcının diğer katılımcılara oranla en çok ayrıştığı gözlenmektedir. Ham veri setinde sonuçlar incelenmeye devam edildiğinde ikinci olarak en çok ayrışımın iki nolu katılımcıda olduğu görülmektedir. ICA yöntemi uygulanmış veri sinyallerinde ise manova gruplama analiz sonuçları tekrar on dokuz nolu kişinin diğer katılımcılara oranla daha fazla ayrıştığı göstermektedir. Ayrıca en fazla ayrışmanın görüldüğü ikinci kişinin on iki nolu katılımcının olduğu görülmüştür. Çok değişkenli varyans analizi

(manova) grup önemini hesaplamak ve her bir kişiyi çeşitli gruplar arasında dağıtmak için uygulanmıştır. ICA yöntemi tabanlı ayırma kabiliyeti çerçevesi her bir bireyin ayırt edilmesine yardımcı olmaktadır. Katılımcıların manova yoluyla kümelenebilirliği her bir grup için tanımlanan puanlar üzerinden grup ayrımını ifade etmektedir.









Şekil 5-18: Ham veri ve ICA yöntemi uygulanmış sinyaller için P7-P8 kanallarına ait olasılık yoğunluk dağılım grafikleri

EEG alfa frekansında ilk on katılımcının P7 ve P8 kanalları ile oluşturulan ham veri ve ICA yöntemi uygulanmış sinyallere ait olasılık yoğunluk dağılım grafikleri Şekil 5-18'de görülmektedir. Parietal lob bölgesindeki elektrot konumları (P7-P8) arasındaki korelasyon katsayılarının olasılık yoğunluk dağılım fonksiyonları eşleştirilmiş katılımcılar arasında ayırma kabiliyetini göstermek için kullanılmaktadır. En büyük farklılaşma (en küçük kesişim alanı) daha iyi kimlik doğrulama ayırma anlamına gelir ve en küçük farklılaşma (en büyük kesişim alanı) zayıf ayırmacılık performansına işaret etmektedir.


Ham veri sinyallerinin olasılık yoğunluk dağılım grafiklerine bakıldığında sinyaller arasındaki kesişimin daha düşük olmasından dolayı katılımcı üç ve dört birbirlerinden en çok ayrışabilir durumdadır. Diğer taraftan ham veri sinyallerinin olasılık yoğunluk dağılım grafiklerine bakıldığında sinyaller arasındaki kesişimin en fazla olmasından dolayı katılımcı bir ve iki en az ayrışabilir durumdadır.

ICA uygulanmış sinyallerin olasılık yoğunluk dağılım grafiklerine bakıldığında en çok ayrışabilir durumdaki katılımcıların bir ve iki nolu katılımcılar olduğu görülürken, en az ayrışabilir durumda ise katılımcı üç ve dördün olduğu görülmektedir.

Birinci katılımcıya ait bir boyutlu CNN yöntemi uygulanmış farklı üç fold için karmaşıklık matrisi ve çapraz doğrulama ROC (alıcı İşletim karakteristiği) grafikleri Şekil 5-19'de ise görülmektedir. Birinci katılımcının diğer katılımcılar ile oluşturduğu karmaşıklık matrisi incelendiğinde birinci sınıf (class-1) birinci katılımcıyı, ikinci sınıf (class-2) ise diğer katılımcıları temsil etmektedir. Birinci kat (fold-1) matrisinde bakıldığında birinci sınıf için elli üç adet veri girişi yapılmış ve elli üçünde doğru sınıfla olduğu görülmekte ikinci sınıfa bakıldığında ise yüz iki adet veri girişi yapıldığı bunlardan doksan dört adetinin doğru sınıfta olduğu sekiz adet verinin ise yanlış sınıfta olduğu görülmektedir. Kat ikiye (fold-2) ait karmaşıklık matrisi incelendiğinde birinci sınıf için elli dört adet veri girişi yapıldığı elli dört adet hepsinin doğru sınıfa aktarıldığı, ikinci sınıfta ise yüz bir adet veri girişinin yapıldığı bunlardan seksen sekiz adet doğru sınıflandırmada kaldığı on üç adet ise yanlış sınıfta olduğu görülmektedir. Kat üçe (fold-3) ait karmaşıklık matrisi incelendiğinde ise birinci sınıf için elli üç adet veri girişi yapıldığı elli üç adet hepsinin doğru sınıfta aktarıldığı, ikinci sınıfta ise yüz bir adet veri girişi yapıldığı bunlardan doksan altı adetinin doğru sınıflandırmada kaldığı beş adet ise yanlış sınıfta olduğu görülmektedir.




Şekil 5-19: 1. Kişiyi ait 3-fold karmaşıklık matrisi ve çapraz doğrulama ROC grafikleri



Şekil 5-20: 1. Kişiyeye ait performans metrikleri sonuç grafiğı

Birinci kişiyeye ait üç farklı fold durumunda performans metrik grafiğı Şekil 5-20’de görölmektedir. En yüksek doğruluk, duyarlılık, kesinlik ve f-score değeri fold-3 çapraz doğrulama durumunda elde edilmiştir.



Şekil 5-21: 1. Katılımcıya ait AUC grafiğı

Birinci katılımcıya ait üç farklı fold durumunda AUC sonuçları Şekil 5-21’de görölmektedir. Grafik incelendiğinde AUC değeri fold-1 ve fold-3 durumunda maksimum değere ulaştığı gözlenmiştir.

İlk beş katılımcıya ait 1-D CNN biyometrik kimlik doğrulama performans sonuçları Tablo 5-9’de görülmektedir. İlk beş kişinin performans metrik sonuçlarına bakıldığında en yüksek ortalama doğruluk oranının 95.68% ile üç nolu katılımcıya ait olduğu görülmektedir. Bu sonuç ilk beş kişi içerisinde biyometrik doğrulamada üç nolu katılımcının diğer dört katılımcıya göre daha fazla ayrıştığını göstermektedir. Tabloda diğer biyometrik kimlik doğrulama performans sonuçlarına bakıldığında ise üç nolu katılımcının 100% oranında duyarlılık, 93.42% oranında özgüllük, 95.68% oranında kesinlik, 97.78% oranında f-score ve AUC değeri 1 olarak diğer dört katılımcıya göre en yüksek değerlere sahip olduğu görülmektedir.

İkinci beş kişinin biyometrik kimlik doğrulama performans sonuçları Tablo 5-10’de görülmektedir. İkinci beş kişinin performans metrik sonuçlarına bakıldığında en yüksek ortalama doğruluk oranının 97.19% ile yedi nolu katılımcıya ait olduğu görülmektedir. Bu sonuç ikinci beş kişi içerisinde biyometrik kimlik doğrulamada yedi nolu katılımcının diğer dört katılımcıya göre daha fazla ayrıştığını göstermektedir. Tabloda diğer biyometrik kimlik doğrulama performans sonuçlarına bakıldığında ise yedi nolu katılımcının 100% oranında duyarlılık, 95.71% oranında özgüllük, 97.19% oranında kesinlik, 98.53% oranında f-score ve AUC değeri 1 olarak diğer dört katılımcıya göre en yüksek değerlere sahip olduğu görülmektedir.

Üçüncü beş kişinin biyometrik kimlik doğrulama performans sonuçları Tablo 5-11’te görülmektedir. Üçüncü beş kişinin performans metrik sonuçlarına bakıldığında en yüksek ortalama doğruluk oranının 98.93% ile on bir nolu katılımcıya ait olduğu görülmektedir. Bu sonuç üçüncü beş kişi içerisinde biyometrik kimlik doğrulamada on bir nolu katılımcının diğer dört katılımcıya göre daha fazla ayrıştığını göstermektedir. Tabloda diğer biyometrik kimlik doğrulama performans sonuçlarına bakıldığında ise on bir nolu katılımcının 100% oranında duyarlılık, 98.37% oranında özgüllük, 98.93% oranında kesinlik, 99.46% oranında f-score ve AUC değeri 1 olarak diğer dört katılımcıya göre en yüksek değerlere sahip olduğu görülmektedir.

Dördüncü beş kişinin biyometrik kimlik doğrulama performans sonuçları Tablo 5-12’de görülmektedir. Dördüncü beş kişinin performans metrik sonuçlarına bakıldığında en yüksek ortalama doğruluk oranının 96.55% ile on sekiz nolu katılımcıya ait olduğu görülmektedir. Bu sonuç dördüncü beş kişi içerisinde biyometrik doğrulamada on sekiz nolu katılımcının diğer dört katılımcıya göre daha fazla ayrıştığını göstermektedir. Tabloda diğer biyometrik kimlik doğrulama performans sonuçlarına bakıldığında ise on sekiz nolu katılımcının 100% oranında duyarlılık, 94.73% oranında özgüllük, 96.55% oranında kesinlik, 98.24% oranında f-score ve AUC değeri 1 olarak diğer dört katılımcıya göre en iyi değerlere sahip olduğu görülmektedir.

Tablo 5-9: 1-5 katılımcının DWT’de alfa frekansına ayrılmış alt sinyallere ait 1D-CNN kimlik doğrulama sonuçları
(one-versus-others authentication)

sb1				
%	fold-1	fold-2	fold-3	Ortalama
ACC	94.84	91.61	96.75	94.40
SENS	100	100	100	100
SPEC	92.16	87.13	95.05	91.45
PREC	86.89	80.6	91.38	86.29
F-score	92.98	89.26	95.5	92.58
AUC	1	0.921	1	0.974
sb2				
%	fold-1	fold-2	fold-3	Ortalama
ACC	90.97	100	90.32	93.76
SENS	100	100	100	100
SPEC	86.14	100	85.29	90.48
PREC	79.41	100	77.94	85.78
F-score	88.52	100	87.6	92.04
AUC	0.861	1	0.853	0.905
sb3				
%	fold-1	fold-2	fold-3	Ortalama
ACC	98.05	96.79	92.21	95.68
SENS	100	100	100	100
SPEC	97.03	95.1	88.12	93.42
PREC	94.64	91.53	81.54	89.24
F-score	97.25	95.58	89.83	94.22
AUC	1	1	1	1
sb4				
%	fold-1	fold-2	fold-3	Ortalama
ACC	92.21	100	93.51	95.24
SENS	100	100	100	100
SPEC	88.12	100	90.1	92.74
PREC	81.54	100	84.13	88.56
F-score	89.83	100	91.38	93.74
AUC	1	1	0.901	0.967
sb5				
%	fold-1	fold-2	fold-3	Ortalama
ACC	94.84	91.61	96.75	94.40
SENS	100	100	100	100
SPEC	92.16	87.13	95.05	91.45
PREC	85.48	92.98	73.97	84.14
F-score	92.17	96.36	85.04	91.19
AUC	1	1	0.814	0.938

Tablo 5-10: 6-10 katılımcının DWT’de alfa frekansına ayrılmış alt sinyallere ait 1D-CNN kimlik doğrulama sonuçları (one-versus-others authentication)

sb6				
%	fold-1	fold-2	fold-3	Ortalama
ACC	92.21	89.74	93.51	91.82
SENS	100	100	100	100
SPEC	88.12	84.31	90.1	87.51
PREC	81.54	77.14	84.13	80.94
F-score	89.83	87.1	91.38	89.44
AUC	1	1	1	1
sb7				
%	fold-1	fold-2	fold-3	Ortalama
ACC	91.56	100	100	97.19
SENS	100	100	100	100
SPEC	87.13	100	100	95.71
PREC	91.56	100	100	97.19
F-score	95.59	100	100	98.53
AUC	1	1	1	1
sb8				
%	fold-1	fold-2	fold-3	Ortalama
ACC	92.9	78.71	87.66	86.42
SENS	100	100	100	100
SPEC	89.22	67.33	81.19	79.25
PREC	82.81	62.07	73.61	72.83
F-score	90.6	76.6	84.8	84.00
AUC	0.892	0.944	0.997	0.944
sb9				
%	fold-1	fold-2	fold-3	Ortalama
ACC	89.68	97.42	87.01	91.37
SENS	100	100	100	100
SPEC	84.31	96.04	80.2	86.85
PREC	76.81	93.1	72.6	80.84
F-score	86.89	96.43	84.13	89.15
AUC	1	1	1	1
sb10				
%	fold-1	fold-2	fold-3	Ortalama
ACC	95.48	97.42	92.86	95.25
SENS	100	100	100	100
SPEC	93.14	96.04	89.11	92.76
PREC	88.33	93.1	82.81	88.08
F-score	93.81	96.43	90.6	93.61
AUC	1	0.96	0.991	0.984


Tablo 5-11: 11-15 katılımcının DWT’de alfa frekansına ayrılmış alt sinyallere ait 1D-CNN kimlik doğrulama sonuçları (one-versus-others authentication)

sb11				
%	fold-1	fold-2	fold-3	Ortalama
ACC	100	96.79	100	98.93
SENS	100	100	100	100
SPEC	100	95.1	100	98.37
PREC	100	91.53	100	97.18
F-score	100	95.58	100	98.53
AUC	1	1	1	1
sb12				
%	fold-1	fold-2	fold-3	Ortalama
ACC	89.03	94.84	91.56	91.81
SENS	100	100	100	100
SPEC	83.33	92.08	87.13	87.51
PREC	75.71	87.1	80.3	81.04
F-score	86.18	93.1	89.08	89.45
AUC	0.859	0.975	0.95	0.928
sb13				
%	fold-1	fold-2	fold-3	Ortalama
ACC	100	90.32	88.39	92.90
SENS	100	100	100	100.00
SPEC	100	85.15	82.35	89.17
PREC	100	78.26	74.65	84.30
F-score	100	87.8	85.48	91.09
AUC	1	1	1	1
sb14				
%	fold-1	fold-2	fold-3	Ortalama
ACC	94.19	100	91.61	95.27
SENS	100	100	100	100.00
SPEC	91.09	100	87.25	92.78
PREC	85.71	100	80.3	88.67
F-score	92.31	100	89.08	93.80
AUC	1	1	1	1
sb15				
%	fold-1	fold-2	fold-3	Ortalama
ACC	98.06	87.66	97.42	94.38
SENS	100	100	100	100.00
SPEC	97.06	81.19	96.04	91.43
PREC	94.64	73.61	93.1	87.12
F-score	97.25	84.8	96.43	92.83
AUC	1	1	1	1

Tablo 5-12: 16-20 katılımcının DWT’de alfa frekansına ayrılmış alt sinyallere ait 1D-CNN kimlik doğrulama sonuçları (one-versus-others authentication)


sb16				
%	fold-1	fold-2	fold-3	Ortalama
ACC	94.81	92.26	92.26	93.11
SENS	100	100	100	100
SPEC	92.08	88.24	88.12	89.48
PREC	86.89	81.54	81.82	83.42
F-score	92.98	89.83	90	90.94
AUC	1	1	0.997	0.999
sb17				
%	fold-1	fold-2	fold-3	Ortalama
ACC	96.79	90.91	97.4	95.03
SENS	100	100	100	100.00
SPEC	95.1	86.14	96.04	92.43
PREC	91.53	79.1	92.98	87.87
F-score	95.58	88.33	96.36	93.42
AUC	1	1	0.96	0.987
sb18				
%	fold-1	fold-2	fold-3	Ortalama
ACC	97.42	96.1	96.13	96.55
SENS	100	100	100	100
SPEC	96.08	94.06	94.06	94.73
PREC	92.98	89.83	90	90.94
F-score	96.36	94.64	94.74	95.25
AUC	1	1	1	1
sb19				
%	fold-1	fold-2	fold-3	Ortalama
ACC	92.26	94.19	87.01	91.15
SENS	100	100	100	100
SPEC	88.12	91.18	80.2	86.5
PREC	81.82	85.48	72.6	79.97
F-score	90	92.17	84.13	88.77
AUC	0.881	1	0.843	0.908
sb20				
%	fold-1	fold-2	fold-3	Ortalama
ACC	91.61	91.56	98.06	93.74
SENS	100	100	100	100
SPEC	87.13	87.13	97.06	90.44
PREC	80.6	80.3	94.64	85.18
F-score	89.26	89.08	97.25	91.86
AUC	0.949	0.938	0.997	0.961

Yirmi kişinin biyometrik kimlik doğrulama sonuçlarına bakıldığında en iyi sonucun on bir nolu katılımcıya ait olduğu görülmektedir. Bu sonuç yirmi kişi içerisinde biyometrik kimlik doğrulamada on bir nolu katılımcının diğer on dokuz katılımcıya göre daha fazla ayrıştığını göstermektedir.




Şekil 5-22: 20 kişinin biyometrik kimlik doğrulamasında ACC doğruluk grafiği

EEG alfa frekansında yirmi kişinin biyometrik kimlik doğrulamasında 3-fold çapraz doğrulamaya ait ortalama ACC doğruluk grafiği Şekil 5-22’de görülmektedir. En düşük ortalama ACC doğruluğu 86.42% ile sekiz nolu katılımcıya ait iken en yüksek ACC doğruluğu 98.93% ile on bir nolu katılımcıya ait olduğu görülmektedir.




Şekil 5-23: 20 kişinin biyometrik kimlik doğrulamasında SENS duyarlılık grafiği

EEG alfa frekansında yirmi kişinin biyometrik kimlik doğrulamasında 3-fold çapraz doğrulamaya ait ortalama SENS duyarlılık grafiği Şekil 5-23'de görülmektedir. Tüm katılımcıların için yüksek ortalama duyarlılık değeri elde edildiği görülmektedir.




Şekil 5-24: 20 kişinin biyometrik kimlik doğrulamasında SPEC özgüllük grafiği

EEG alfa frekansında yirmi kişinin biyometrik kimlik doğrulamasında 3-fold çapraz doğrulamaya ait ortalama SPEC özgüllük grafiği Şekil 5-24'te görülmektedir. En düşük ortalama SPEC özgüllük 79.25% ile sekiz nolu katılımcıya ait iken en yüksek SPEC özgüllük 98.37% ile on bir nolu katılımcıya ait olduğu görülmektedir.




Şekil 5-25: 20 kişinin biyometrik kimlik doğrulamasında PREC kesinlik grafiği

EEG alfa frekansında yirmi kişinin biyometrik kimlik doğrulamasında 3-fold çapraz doğrulamaya ait ortalama PREC kesinlik grafiği Şekil 5-25’de görülmektedir. En düşük ortalama PREC kesinliği 72.83% ile sekiz nolu katılımcıya ait iken en yüksek PREC kesinliği 97.19% ile yedi katılımcıya ait olduğu görülmektedir.



Şekil 5-26: 20 kişinin biyometrik kimlik doğrulamasında F-score grafiği



Şekil 5-27: 20 kişinin biyometrik kimlik doğrulamasında AUC grafiği

EEG alfa frekansında yirmi kişinin biyometrik kimlik doğrulamasında 3-fold çapraz doğrulamaya ait ortalama f-score grafiği Şekil 5-26’da görülmektedir. En düşük ortalama f-score

değeri 84% ile sekiz nolu katılımcıya ait iken en yüksek f-score 98.53% ile on bir ve yedi nolu katılımcıya ait olduğu görülmektedir.

EEG alfa frekansında yirmi kişinin biyometrik kimlik doğrulamasında 3-fold çapraz doğrulamaya ait ortalama AUC grafiği Şekil 5-27’de görülmektedir. En düşük ortalama AUC değeri 0.905 ile iki nolu katılımcıya ait iken en yüksek AUC değeri 1 olarak birçok katılımcıda elde edilmiştir.



6. SONUÇ VE ÖNERİLER

Yirmi katılımcıdan alınan 512 Hz örnekleme frekansına sahip dinlenme durumunda EEG alfa dalgaları ile makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak biyometrik tanımlama ve kimlik doğrulama çalışması gerçekleştirilmiştir. Biyometrik tanımlama ve kimlik doğrulama çalışmaları için EEG alfa frekansında yirmi kişiden elde edilen verilere sırasıyla 80% eğitim ve 20% test işlemi uygulanmıştır.

Yirmi kişinin biyometrik tanımlama sonuçlarına bakıldığında pari beynin parietal ve oksipital bölgelerinde beklenen 8-13 Hz frekans bandında EEG sinyallerinin daha yoğun olduğu gözlenmiştir. Katılımcıların güç spektrum yoğunluklarına bakıldığında 10 Hz civarında en yüksek sinyal gücüne erişildiği görülmektedir. Yirmi kişiye ait saçılım grafikleri incelendiğinde ICA yöntemi uygulanmış grafiklerin biyometrik tanımlamada daha başarılı olduğu görülmektedir. Biyometrik tanımlamada kullanılan RNN modelleri arasında en yüksek doğruluk oranının 512 örnekleme BİLSTM modelinde olduğu görülmüştür.

Yirmi kişinin biyometrik kimlik doğrulama çalışmasında ise bir kişiye karşı diğer kişilerin ayrıştırılması oranlarının oldukça başarılı olduğu gözlenmiştir. Yirmi kişiye ait on altı kanallı benzersiz korelasyon matrisi modellerine bakıldığında korelasyon bölgelerinin genellikle oksipital ve parietal bölgelerde yoğunlaştığı gözlenmektedir. 1D-CNN yöntemi ile yapılan uygulamada Fp1 ve Fp2 elektrotları kullanılarak sadece iki kanal üzerinden biyometrik kimlik doğrulama performansları incelenmiştir. Kanal sayısının on altı kanaldan iki kanala düşürüldüğünde bile oldukça yüksek doğruluk oranı elde edildiği görülmektedir.

Çalışma, EEG sinyallerinin farklı frekans aralıklarında ve uygun beyin bölgelerinde bulunan kanallardan alınacak verilere diğer makine ve derin öğrenme yöntemleri kullanılarak ileride yapılacak biyometrik kimlik doğrulama ve tanımlama çalışmalarına katkı sağlayacağı öngörülmektedir. Kanal sayısının az ve doğruluk oranının yüksek olması gibi avantajları nedeniyle biyometrik kimlik doğrulama sistemleri için kullanımı kolay ve düşük maliyetli bir yaklaşım sunmaktadır.

7. KAYNAKLAR

- [1] B. Eraslan, K. Gorur, ve F. Temurtas, “Novel Biometric Approach Based on Diaphragmatic Respiratory Movements Using Single-Lead EMG Signals”, *IETE J Res*, 2023, doi: 10.1080/03772063.2023.2176368.
- [2] K. Gorur, E. Olmez, Z. Ozer, ve O. Cetin, “EEG-Driven Biometric Authentication for Investigation of Fourier Synchrosqueezed Transform-ICA Robust Framework”, *Arab J Sci Eng*, Ağu. 2023, doi: 10.1007/s13369-023-07798-6.
- [3] D. M. Groppe vd., “Dominant frequencies of resting human brain activity as measured by the electrocorticogram”, *Neuroimage*, c. 79, ss. 223-233, Eki. 2013, doi: 10.1016/j.neuroimage.2013.04.044.
- [4] C. Wetzel, “Memories may be sorted by the thalamus before being stored long term”. Erişim: 05 Eylül 2023. [Çevrimiçi]. Erişim adresi: <https://www.newscientist.com/article/2366970-memories-may-be-sorted-by-the-thalamus-before-being-stored-long-term/>
- [5] M. Wang, S. Wang, ve J. Hu, “Cancellable Template Design for Privacy-Preserving EEG Biometric Authentication Systems”, *IEEE Transactions on Information Forensics and Security*, c. 17, ss. 3350-3364, 2022, doi: 10.1109/TIFS.2022.3204222.
- [6] M. Wang, S. Wang, ve J. Hu, “PolyCosGraph: A Privacy-Preserving Cancelable EEG Biometric System”, *IEEE Trans Dependable Secure Comput*, 2022, doi: 10.1109/TDSC.2022.3218782.
- [7] M. Fraschini, A. Hillebrand, M. Demuru, L. Didaci, ve G. L. Marcialis, “An EEG-based biometric system using eigenvector centrality in resting state brain networks”, *IEEE Signal Process Lett*, c. 22, sy 6, ss. 666-670, Haz. 2015, doi: 10.1109/LSP.2014.2367091.
- [8] D. La Rocca vd., “Human brain distinctiveness based on EEG spectral coherence connectivity”, *IEEE Trans Biomed Eng*, c. 61, sy 9, ss. 2406-2412, 2014, doi: 10.1109/TBME.2014.2317881.
- [9] L. Ronconi, N. A. Busch, ve D. Melcher, “Alpha-band sensory entrainment alters the duration of temporal windows in visual perception”, *Sci Rep*, c. 8, sy 1, Ara. 2018, doi: 10.1038/s41598-018-29671-5.
- [10] Y. Chen vd., “Amplitude of fNIRS Resting-State Global Signal Is Related to EEG Vigilance Measures: A Simultaneous fNIRS and EEG Study”, *Front Neurosci*, c. 14, Ara. 2020, doi: 10.3389/fnins.2020.560878.

- [11] J. Lian *vd.*, “Reduced Resting-State EEG Power Spectra and Functional Connectivity after 24 and 36 Hours of Sleep Deprivation”, *Brain Sci*, c. 13, sy 6, s. 949, Haz. 2023, doi: 10.3390/brainsci13060949.
- [12] E. Ívarsson *vd.*, “A Novel Technique to Trigger High Beta and Low Gamma Activity in Patients with Schizophrenia”, içinde *IFMBE Proceedings*, Springer, 2020, ss. 1064-1070. doi: 10.1007/978-3-030-31635-8_129.
- [13] Z. Liu, J. A. de Zwart, B. Yao, P. van Gelderen, L.-W. Kuo, ve J. H. Duyn, “Finding thalamic BOLD correlates to posterior alpha EEG”, *Neuroimage*, c. 63, sy 3, ss. 1060-1069, Kas. 2012, doi: 10.1016/j.neuroimage.2012.08.025.
- [14] A. R. Kavsaoglu (2014), “PPG (fotopletismografi) sinyalleri ile biyometrik tanımlama sistemi”, Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- [15] L. A. Moctezuma ve M. Molinas, “Towards a minimal EEG channel array for a biometric system using resting-state and a genetic algorithm for channel selection”, *Sci Rep*, c. 10, sy 1, Ara. 2020, doi: 10.1038/s41598-020-72051-1.
- [16] S. Yang, S. Hoque, ve F. Deravi, “Improved Time-Frequency Features and Electrode Placement for EEG-Based Biometric Person Recognition”, *IEEE Access*, c. 7, ss. 49604-49613, 2019, doi: 10.1109/ACCESS.2019.2910752.
- [17] D. Jyotishi ve S. Dandapat, “An LSTM-Based Model for Person Identification Using ECG Signal”, *IEEE Sens Lett*, c. 4, sy 8, Ağu. 2020, doi: 10.1109/LSSENS.2020.3012653.
- [18] M. Üçüncü (2019), “K-en yakın komşuluk algoritmasını kullanarak EEG tabanlı kişi tanıma”, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.
- [19] Z. Mao, W. Xiang Yao, ve Y. Huang, *EEG-Based Biometric Identification with Deep Learning*. 2017. doi: 10.1109/NER.2017.8008425.
- [20] R. Zhang, B. Yan, L. Tong, J. Shu, X. Song, ve Y. Zeng, “Identity Authentication Using Portable Electroencephalography Signals in Resting States”, *IEEE Access*, c. 7, ss. 160671-160682, 2019, doi: 10.1109/ACCESS.2019.2950366.
- [21] K. G. Smitha, K. P. Thomas, ve A. P. Vinod, “Online Electroencephalogram (EEG) based biometric authentication using visual and audio stimuli”, 2016 IEEE EMBS Conference on Biomedical Engineering and Sciences (IECBES), 2016, ss. 454-459. doi: 10.1109/IECBES.2016.7843492.

- [22] W. Alsumari, M. Hussain, L. Alshehri, ve H. A. Aboalsamh, “EEG-Based Person Identification and Authentication Using Deep Convolutional Neural Network”, *Axioms*, c. 12, sy 1, Oca. 2023, doi: 10.3390/axioms12010074.
- [23] K. P. Thomas ve A. P. Vinod, “Biometric identification of persons using sample entropy features of EEG during rest state”, içinde *IEEE*, 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 2016, ss. 003487-003492. doi: 10.1109/SMC.2016.7844773.
- [24] Y. Di, X. An, F. He, S. Liu, Y. Ke, ve D. Ming, “Robustness Analysis of Identification Using Resting-State EEG Signals”, *IEEE Access*, c. 7, ss. 42113-42122, 2019, doi: 10.1109/ACCESS.2019.2907644.
- [25] T. Wilaiprasitporn, A. Ditthaporn, K. Matchaparn, T. Tongbuasirilai, N. Banluesombatkul, ve E. Chuangsuwanich, “Affective EEG-Based Person Identification Using the Deep Learning Approach”, *IEEE Trans Cogn Dev Syst*, c. 12, sy 3, ss. 486-496, Eyl. 2020, doi: 10.1109/TCDS.2019.2924648.
- [26] K. P. Thomas, A. P. Vinod, ve N. Robinson, “Online biometric authentication using subject-specific band power features of EEG”, içinde *ACM International Conference Proceeding Series*, Association for Computing Machinery, Mar. 2017, ss. 136-141. doi: 10.1145/3058060.3058068.
- [27] Z. A. A. Alyasseri, A. T. Khader, M. A. Al-Betar, J. P. Papa, ve O. A. Alomari, “EEG-based Person Authentication Using Multi-objective Flower Pollination Algorithm”, içinde *2018 IEEE Congress on Evolutionary Computation (CEC)*, 2018, ss. 1-8. doi: 10.1109/CEC.2018.8477895.
- [28] Z. Y. Ong, A. Saidatul, Z. Ibrahim, ve Institute of Electrical and Electronics Engineers, “Power Spectral Density Analysis for Human EEG-based Biometric Identification”, içinde *2018 International Conference on Computational Approach in Smart Systems Design and Applications (ICASSDA)*, 2018, ss. 1-6. doi: 10.1109/ICASSDA.2018.8477604.
- [29] S. Puengdang, S. Tuarob, T. Sattabongkot, ve B. Sakboonyarat, “EEG-Based Person Authentication Method Using Deep Learning with Visual Stimulation”, içinde *2019 11th International Conference on Knowledge and Smart Technology (KST)*, IEEE, 2019, ss. 6-10. doi: 10.1109/KST.2019.8687819.
- [30] L. A. Moctezuma ve M. Molinas, “Event-related potential from EEG for a two-step Identity Authentication System”, içinde *2019 IEEE 17th International Conference on*

- Industrial Informatics (INDIN)*, 2019, ss. 392-399. doi: 10.1109/INDIN41052.2019.8972231.
- [31] A. Rahman vd., “Multimodal EEG and Keystroke Dynamics Based Biometric System Using Machine Learning Algorithms”, *IEEE Access*, c. 9, ss. 94625-94643, 2021, doi: 10.1109/ACCESS.2021.3092840.
- [32] L. Fraiwan ve M. Alkhodari, “Classification of Focal and Non-Focal Epileptic Patients Using Single Channel EEG and Long Short-Term Memory Learning System”, *IEEE Access*, c. 8, ss. 77255-77262, 2020, doi: 10.1109/ACCESS.2020.2989442.
- [33] T. Yu, C. S. Wei, K. J. Chiang, M. Nakanishi, T. P. Jung, ve P. Sajda, “EG-Based User Authentication Using a Convolutional Neural Network”, içinde *2019 9th International IEEE/EMBS Conference on Neural Engineering (NER)*, IEEE, 2019, ss. 1011-1014. doi: 10.1109/NER.2019.8716965.
- [34] G. Y. Choi, S. I. Choi, ve H. J. Hwang, “Individual Identification Based on Resting-State EEG”, içinde *2018 6th International Conference on Brain-Computer Interface (BCI)*, 2018, ss. 1-4. doi: 10.1109/IWW-BCI.2018.8311515.
- [35] J. Sooriyaarachchi, S. Seneviratne, K. Thilakarathna, ve A. Y. Zomaya, “MusicID: A Brainwave-Based User Authentication System for Internet of Things”, *IEEE Internet Things J*, c. 8, sy 10, ss. 8304-8313, May. 2021, doi: 10.1109/JIOT.2020.3044726.
- [36] S. N. A. Seha ve D. Hatzinakos, “EEG-Based Human Recognition Using Steady-State AEPs and Subject-Unique Spatial Filters”, *IEEE Transactions on Information Forensics and Security*, c. 15, ss. 3901-3910, 2020, doi: 10.1109/TIFS.2020.3001729.
- [37] A. J. Bidgoly, H. J. Bidgoly, ve Z. Arezoumand, “Towards a universal and privacy preserving EEG-based authentication system”, *Sci Rep*, c. 12, sy 1, Ara. 2022, doi: 10.1038/s41598-022-06527-7.
- [38] K. Bashar, “ECG and EEG Based Multimodal Biometrics for Human Identification”, içinde *Proceedings - 2018 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2018*, Institute of Electrical and Electronics Engineers Inc., Oca. 2019, ss. 4345-4350. doi: 10.1109/SMC.2018.00734.
- [39] W. Kong, L. Wang, S. Xu, F. Babiloni, ve H. Chen, “EEG Fingerprints: Phase Synchronization of EEG Signals as Biomarker for Subject Identification”, *IEEE Access*, c. 7, ss. 121165-121173, 2019, doi: 10.1109/ACCESS.2019.2931624.

- [40] S. K. Khare, V. Bajaj, ve U. R. Acharya, “SPWVD-CNN for Automated Detection of Schizophrenia Patients Using EEG Signals”, *IEEE Trans Instrum Meas*, c. 70, 2021, doi: 10.1109/TIM.2021.3070608.
- [41] J. X. Chen, D. M. Jiang, ve Y. N. Zhang, “A Hierarchical Bidirectional GRU Model with Attention for EEG-Based Emotion Classification”, *IEEE Access*, c. 7, ss. 118530-118540, 2019, doi: 10.1109/ACCESS.2019.2936817.
- [42] H. El-Fiqi, M. Wang, N. Salimi, K. Kasmarik, M. Barlow, ve H. Abbass, “Convolution Neural Networks for Person Identification and Verification Using Steady State Visual Evoked Potential”, içinde *Proceedings - 2018 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2018*, Institute of Electrical and Electronics Engineers Inc., Oca. 2019, ss. 1062-1069. doi: 10.1109/SMC.2018.00188.
- [43] Y. Zeng vd., “EEG-based identity authentication framework using face rapid serial visual presentation with optimized channels”, *Sensors (Switzerland)*, c. 19, sy 1, Oca. 2019, doi: 10.3390/s19010006.
- [44] S. Taran ve V. Bajaj, “Clustering variational mode decomposition for identification of focal EEG signals”, *IEEE Sens Lett*, c. 2, sy 4, Ara. 2018, doi: 10.1109/LSSENS.2018.2872415.
- [45] C. Fan, Y. Peng, S. Peng, H. Zhang, Y. Wu, ve S. Kwong, “Detection of Train Driver Fatigue and Distraction Based on Forehead EEG: A Time-Series Ensemble Learning Method”, *IEEE Transactions on Intelligent Transportation Systems*, c. 23, sy 8, ss. 13559-13569, Ağu. 2022, doi: 10.1109/TITS.2021.3125737.
- [46] P. Nagar ve D. Sethia, “Brain Mapping Based Stress Identification Using Portable EEG Based Device”, içinde *2019 11th International Conference on Communication Systems & Networks (COMSNETS)*, 2019, ss. 601-606. doi: 10.1109/COMSNETS.2019.8711009.
- [47] N. Baghel, M. Singh, Dutta M. K., Burget R., ve Myska V., “Truth identification from EEG signal by using convolution neural network: lie detection”, içinde *2020 43rd International Conference on Telecommunications and Signal Processing (TSP)*, 2020, ss. 550-553. doi: 10.1109/TSP49548.2020.9163497.
- [48] H. Peng vd., “Multivariate Pattern Analysis of EEG-Based Functional Connectivity: A Study on the Identification of Depression”, *IEEE Access*, c. 7, ss. 92630-92641, 2019, doi: 10.1109/ACCESS.2019.2927121.

- [49] S. Bakheet, A. Al-Hamadi, ve R. Youssef, "A Fingerprint-Based Verification Framework Using Harris and SURF Feature Detection Algorithms", *Applied Sciences (Switzerland)*, c. 12, sy 4, Şub. 2022, doi: 10.3390/app12042028.
- [50] M. Abuhamad, A. Abusnaina, D. Nyang, ve D. Mohaisen, "Sensor-Based Continuous Authentication of Smartphones' Users Using Behavioral Biometrics: A Contemporary Survey", *IEEE Internet of Things Journal*, c. 8, sy 1. Institute of Electrical and Electronics Engineers Inc., ss. 65-84, 01 Ocak 2021. doi: 10.1109/JIOT.2020.3020076.
- [51] L. Santos-Mayo, L. M. San-Jose-Revuelta, ve J. I. Arribas, "A computer-aided diagnosis system with EEG based on the p3b wave during an auditory odd-ball task in schizophrenia", *IEEE Trans Biomed Eng*, c. 64, sy 2, ss. 395-407, Şub. 2017, doi: 10.1109/TBME.2016.2558824.
- [52] J. Kaur ve A.Kaur (2015), "A Review on Analysis of EEG Signals", *2015 International Conference on Advances in Computer Engineering and Applications (ICACEA)*, ss. 957-960.
- [53] E. Niedermeyer, "The Normal EEG of the Waking Adult", içinde *The normal EEG of the waking adult. Electroencephalography: Basic principles, clinical applications, and related fields*, Lippincott Williams & Wilkins, 1999, ss. 149-173.
- [54] O. M. Matamoros, J. J. M. Escobar, R. T. Padilla, ve I. L. Reyes, "Neurodynamics of patients during a dolphin-assisted therapy by means of a fractal intraneural analysis", *Brain Sci*, c. 10, sy 6, ss. 1-23, Haz. 2020, doi: 10.3390/brainsci10060403.
- [55] H. F. Posada-Quintero, N. Reljin, J. B. Bolkhovsky, A. D. Orjuela-Cañón, ve K. H. Chon, "Brain Activity Correlates With Cognitive Performance Deterioration During Sleep Deprivation", *Front Neurosci*, c. 13, Eyl. 2019, doi: 10.3389/fnins.2019.01001.
- [56] H.N. Oon, A. Saidatul, ve Z. Ibrahim (2018), "Analysis on non-Linear features of electroencephalogram (EEG) signal for neuromarketing application", *In 2018 international conference on computational approach in smart systems design and applications (ICASSDA)*, ss. 1-8, doi: 10.1109/ICASSDA.2018.8477618.
- [57] M. I. Al-Kadi, M. B. I. Reaz, ve M. A. Mohd Ali, "Evolution of electroencephalogram signal analysis techniques during anesthesia", *Sensors (Switzerland)*, c. 13, sy 5. MDPI AG, ss. 6605-6635, 2013. doi: 10.3390/s130506605.
- [58] N. Sulaiman vd., "Offline LabVIEW-Based EEG Signals Analysis to Detect Vehicle Driver Microsleep", içinde *Lecture Notes in Bioengineering*, Springer, 2020, ss. 271-289. doi: 10.1007/978-981-15-3270-2_29.

- [59] The Queensland Üniversitesi, “Lobes of the brain”, <https://qbi.uq.edu.au/brain/brain-anatomy/lobes-brain>. Erişim: 10 Kasım 2023. [Çevrimiçi]. Erişim adresi: <https://qbi.uq.edu.au/brain/brain-anatomy/lobes-brain>
- [60] R. W. Homan, “The 10-20 Electrode System And Cerebral Location”, *American Journal of EEG Technology*, c. 28, sy 4, ss. 269-279, 1988, doi: 10.1080/00029238.1988.11080272.
- [61] M. Khazi, A. Kumar, ve V. M. J, “Analysis of EEG Using 10:20 Electrode System”, *Int J Innov Res Sci Eng Technol*, c. 1, sy 2, ss. 185-191, 2012.
- [62] M. Seeck vd., “The Standardized EEG Electrode Array Of The IFCN”, *Clinical Neurophysiology*, c. 128, ss. 2070-2077, 2017, doi: 10.1016/j.clinph.2017.06.254.
- [63] G. Cattan, P. L. C. Rodrigues, ve M. Congedo, “EEG Alpha Waves Dataset”, 2018, doi: 10.5281/zenodo.2348891.
- [64] S. Vaid, P. Singh, ve C. Kaur, “EEG signal analysis for BCI interface: A review”, içinde *International Conference on Advanced Computing and Communication Technologies, ACCT*, Institute of Electrical and Electronics Engineers Inc., Nis. 2015, ss. 143-147. doi: 10.1109/ACCT.2015.72.
- [65] H. Yüce ve A. O. Özkan, “Normalizasyon Yöntemlerinin Biyomedikal Verilerde Sınıflandırma Performansına Etkisi”, *European Journal of Science and Technology*, Ara. 2021, doi: 10.31590/ejosat.1011723.
- [66] N. Yalçın, G. Tezel, ve C. Karakuzu, “Epilepsy diagnosis using artificial neural network learned by PSO”, *Turkish Journal of Electrical Engineering and Computer Sciences*, c. 23, sy 2, ss. 421-432, Mar. 2015, doi: 10.3906/elk-1212-151.
- [67] M. S. Başçıl, A. Y. Tesneli, ve F. Temurtaş, “Spectral Feature Extraction Of EEG Signals And Pattern Recognition During Mental Tasks Of 2-D Cursor Movements For BCI Using SVM And ANN”, *Australas Phys Eng Sci Med*, c. 39, sy 3, ss. 665-676, 2016, doi: 10.1007/s13246-016-0462-x.
- [68] K. Gorur, K. Gorur, M. Recep Bozkurt, M. Serdar Bascil, ve F. Temurtas, “Comparative Evaluation for PCA and ICA on Tongue-Machine Interface Using Glossokinetic Potential Responses”, *Celal Bayar University Journal of Science*, c. 16, sy 1, ss. 35-46, 2020, doi: 10.18466/cbayarfbe.571994.
- [69] A. Hyvärinen, “Independent component analysis: Recent advances”, *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, c. 371, sy 1984. Royal Society, 13 Şubat 2013. doi: 10.1098/rsta.2011.0534.

- [70] J. V Stone (2004), “Independent Component Analysis: A Tutorial Introduction (Bradford Books)”.
- [71] S. Maheshwari ve A. Kumar (2014), “Empirical Mode Decomposition: Theory & Applications”, *International Journal of Electronic and Electrical Engineering*, c. 7, sy 8, ss. 873-878.
- [72] K. Gorur, “Fourier Synchrosqueezing Transform-ICA-EMD Framework Based EOG-Biometric Sustainable and Continuous Authentication via Voluntary Eye Blinking Activities”, *Biomimetics*, c. 8, sy 4, Ağu. 2023, doi: 10.3390/biomimetics8040378.
- [73] A. Al Muhit, Md. S. Islam, ve M. Othman, “VLSI implementation of discrete wavelet transform (DWT) for image compression”, içinde *2nd international conference on autonomous robots and agents*, Ara. 2004, ss. 421-433.
- [74] K. Gorur ve B. Eraslan, “The Single-Channel SSVEP-based Biometric Approach Using RNN-based Deep Models: A Systematic Comparison”, 2022, doi: 10.21203/rs.3.rs-1304515/v1.
- [75] M. Weeks, “Discrete Wavelet Transform: Architectures, Design and Performance Issues”, *Journal of VLSI Signal Processing*, c. 35, ss. 155-178, 2003.
- [76] G. Gülgezen vd., “MRMR Algoritması Kullanılarak Kararlı Öznitelik Seçimi Stable Feature Selection Using MRMR Algorithm”.
- [77] S. Xie, Y. Zhang, D. Lv, X. Chen, J. Lu, ve J. Liu, “A new improved maximal relevance and minimal redundancy method based on feature subset”, *Journal of Supercomputing*, c. 79, sy 3, ss. 3157-3180, Şub. 2023, doi: 10.1007/s11227-022-04763-2.
- [78] C. Eiras-Franco, B. Guijarro-Berdiñas, A. Alonso-Betanzos, ve A. Bahamonde, “Scalable feature selection using ReliefF aided by locality-sensitive hashing”, *International Journal of Intelligent Systems*, c. 36, sy 11, ss. 6161-6179, Kas. 2021, doi: 10.1002/int.22546.
- [79] R. J. Urbanowicz, M. Meeker, W. La Cava, R. S. Olson, ve J. H. Moore, “Relief-based feature selection: Introduction and review”, *Journal of Biomedical Informatics*, c. 85. Academic Press Inc., ss. 189-203, 01 Eylül 2018. doi: 10.1016/j.jbi.2018.07.014.
- [80] O. Reyes, C. Morell, ve S. Ventura, “Scalable extensions of the ReliefF algorithm for weighting and selecting features on the multi-label learning context”, *Neurocomputing*, c. 161, ss. 168-182, Ağu. 2015, doi: 10.1016/j.neucom.2015.02.045.
- [81] M. R. Sikonja ve I. Kononenko (2003), “Theoretical and Empirical Analysis of ReliefF and RReliefF”, c. 53, ss. 23-69, 2003, doi: 10.1023/A:1025667309714.

- [82] H. J. Nussbaumer, “Fast Fourier Transform and Convolution Algorithms”, içinde *The Fast Fourier Transform*, 1982, ss. 80-111. doi: doi.org/10.1007/978-3-642-81897-4_4.
- [83] W. T. Cochran, J. W. Cooley, D. L. Favon, H. D. Helms, R. A. Kaenel, ve W. W. Lang, “What Is the Fast Fourier Transform?”, *Proceedings of the IEEE*, ss. 1664-1674, 1967. doi: 10.1109/PROC.1967.5957.
- [84] A. Gasmi, “What is Fast Fourier Transform? Focus on Nutritional Pharmacology View project Health informatics and physiological signals processing View project”, doi: 10.13140/RG.2.2.28731.49444.
- [85] M. Fernández-Ros, J. A. Gázquez Parra, R. M. García Salvador, ve N. N. Castellano, “Optimization of the periodogram average for the estimation of the power spectral density (PSD) of weak signals in the ELF band”, *Measurement (Lond)*, c. 78, ss. 207-218, Oca. 2016, doi: 10.1016/j.measurement.2015.10.006.
- [86] Letswave, “https://letswave.cn/tu_ch1_5”, (Erişim tarihi: (15.11.2023)).
- [87] Clayton M., “The power of the Continuous Wavelet Transform (CWT) in machine learning”, MLearning.ai (Erişim tarihi : 20.10.2023).
- [88] M. Coşkun, Ö. Yildirim, A. Uçar, ve Y. Demir (2017), “An overview of popular deep learning methods”, *European Journal of Technic EJT*, c. 7, sy 2, ss. 165-176.
- [89] L. Lin, X. Chen, Y. Shen, ve L. Zhang, “Towards automatic depression detection: A bilstm/1d cnn-based model”, *Applied Sciences (Switzerland)*, c. 10, sy 23, ss. 1-20, Ara. 2020, doi: 10.3390/app10238701.
- [90] D. Jyotishi ve S. Dandapat, “An LSTM-Based Model for Person Identification Using ECG Signal”, *IEEE Sens Lett*, c. 4, sy 8, Ağu. 2020, doi: 10.1109/LENS.2020.3012653.
- [91] E. Gavcar ve H. M. Metin (2021), “Hisse Senedi Değerlerinin Makine Öğrenimi (Derin Öğrenme) İle Tahmini”, *Ekonomi ve Yönetim Araştırmaları Dergisi* , c. 10, sy 2, ss. 1-11.
- [92] K. Smagulova ve A. P. James, “A Survey On LSTM Memristive Neural Network Architectures And Applications”, *European Physical Journal: Special Topics*, c. 228, ss. 2313-2324, 2019, doi: 10.1140/epjst/e2019-900046-x.
- [93] K. Gorur ve B. Eraslan, “The single-channel dry electrode SSVEP-based biometric approach: data augmentation techniques against overfitting for RNN-based deep models”, *Phys Eng Sci Med*, c. 45, sy 4, ss. 1219-1240, Ara. 2022, doi: 10.1007/s13246-022-01189-1.

- [94] K. Gorur, M. R. Bozkurt, M. S. Bascil, ve F. Temurtas, “GKP signal processing using deep CNN and SVM for tongue-machine interface”, *Traitement du Signal*, c. 36, sy 4, ss. 319-329, Ağu. 2019, doi: 10.18280/ts.360404.
- [95] H. W. Loh *vd.*, “Deep neural network technique for automated detection of ADHD and CD using ECG signal”, *Comput Methods Programs Biomed*, c. 241, Kas. 2023, doi: 10.1016/j.cmpb.2023.107775.
- [96] Ö. Kasim ve M. Tosun, “Biometric Authentication from Photic Stimulated EEG Records”, *Applied Artificial Intelligence*, c. 35, sy 15, ss. 1407-1419, 2021, doi: 10.1080/08839514.2021.1981660.
- [97] R. Du, S. Zhu, H. Ni, T. Mao, J. Li, ve R. Wei, “Valence-arousal classification of emotion evoked by Chinese ancient-style music using 1D-CNN-BiLSTM model on EEG signals for college students”, *Multimed Tools Appl*, c. 82, sy 10, ss. 15439-15456, Nis. 2023, doi: 10.1007/s11042-022-14011-7.
- [98] L. Rokach ve O. Maimon (2005), “Decision Trees”, içinde *Data Mining and Knowledge Discovery Handbook*, ss. 165-192.
- [99] P. Sharma ve A. P. R. Bhatia, “Implementation of decision tree algorithm to analysis the performance.”, 2012.
- [100] S. Balakrishnama ve A. Ganapathiraju (1998), “Linear discriminant analysis-a brief tutorial”, *Institute for Signal and information Processing*, ss. 1-8.
- [101] M. Yıldız, E. Bergil, ve C. (2014) Oral, “EEG işaretlerinin epileptik analizi için boyut azaltmanın etkileri”, *SAU J. Sci*, c. 18, sy 2, ss. 93-97, doi: 10.16984/saufbed.43803.
- [102] M. N. EKERSULAR ve A. ALKAN, “Detection of COVID-19 Disease with Machine Learning Algorithms from CT Images”, *Gazi University Journal of Science*, ss. 1-1, May. 2023, doi: 10.35378/gujs.1150388.
- [103] F. Temurtas, “A comparative study on thyroid disease diagnosis using neural networks”, *Expert Syst Appl*, c. 36, sy 1, ss. 944-949, Oca. 2009, doi: 10.1016/j.eswa.2007.10.010.
- [104] I. Ozer, I. Kocak, ve O. Cetin, “Towards investigation of transfer learning framework for Globotruncanita genus and Globotruncana genus microfossils in Genus-Level and Species-Level prediction”, *Engineering Science and Technology, an International Journal*, c. 48, s. 101589, Ara. 2023, doi: 10.1016/j.jestch.2023.101589.

ÖZGEÇMİŞ

Kişisel Bilgiler		
Adı Soyadı		
Doğum Yeri		
Doğum Tarihi		
Uyruğu		
Telefon		
E-Posta Adresi		
Web Adresi		

	Eğitim Bilgileri
	Lisans
Üniversite	
Fakülte	
Bölümü	
Mezuniyet Yılı	

Yüksek Lisans	
Üniversite	
Enstitü Adı	
Anabilim Dalı	
Programı	

Makale ve Bildiriler
Bildiri: 5. Uluslararası Dicle Bilimsel Araştırmalar ve İnovasyon Kongresi (isarc'23)