

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**ADHD BİREYLERİNİN FRONTAL LOB EEG SİNYALLERİNDE BİYOMETRİK
DOĞRULAMA İÇİN SİNYAL İŞLEME VE 1D-CNN YAKLAŞIMLARI**

RÜMEYSA NUR TEMİR

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Programı

OCAK 2025

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**ADHD BİREYLERİNİN FRONTAL LOB EEG SİNYALLERİNDE BİYOMETRİK
DOĞRULAMA İÇİN SİNYAL İŞLEME VE 1D-CNN YAKLAŞIMLARI**

RÜMEYSA NUR TEMİR

DANIŞMAN
Doç. Dr. Kutlucan GÖRÜR

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Programı

OCAK 2025

ONAY

Rümeysa Nur TEMİR tarafından hazırlanan “**ADHD BİREYLERİNİN FRONTAL LOB EEG SİNYALLERİNDE BİYOMETRİK DOĞRULAMA İÇİN SİNYAL İŞLEME VE 1D-CNN YAKLAŞIMLARI**” adlı tez çalışması 09/01/2025 tarihinde yapılan sınavla aşağıdaki jüri tarafından oybirliği ile Bandırma Onyedİ Eylül Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Doç. Dr., Kutlucan GÖRÜR
(Danışman)

İmza

Doç. Dr., Onursal ÇETİN
(Üye)

Dr. Öğr. Üyesi, Sıtkı AKKAYA
(Üye)

Bu tezin kabulü, Lisansüstü Eğitim Enstitüsü Yönetim Kurulu’nun .../.../...gün ve .../... sayılı kararı ile onaylanmıştır.

Prof. Dr. Ahmet AYDIN

Enstitü Müdürü

BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
YÜKSEK LİSANS ÇALIŞMASI
ETİK BEYANI

Bandırma Onyedi Eylül Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre hazırlamış olduğum “**ADHD BİREYLERİNİN FRONTAL LOB EEG SİNYALLERİNDE BİYOMETRİK DOĞRULAMA İÇİN SİNYAL İŞLEME VE 1D-CNN YAKLAŞIMLARI**” 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. 09/01/2025

Rümeysa Nur TEMİR

ÖNSÖZ

Biyometrik tanıma sistemleri günümüzde sınır kontrolünden mobil cihaz doğrulamaya kadar birçok gerçek hayat uygulamasında kullanılıyor. Her ne kadar yüz, parmak izi ve iris gibi çeşitli biyometrik özellikler üretkenlik açısından önemli bir noktaya ulaşmış olsa da, ana akım çözümlerde mevcut olmayan faydalı özelliklere sahip olabilecek diğer özelliklere dayanarak yenilikçi tanıma sistemleri tasarlamak için hala önemli araştırmalar yürütülmektedir. Bu bağlamda, fiziksel veya davranışsal özelliklerin kullanımına ek olarak, belirli bir görevi yerine getirirken sinir sistemi tarafından üretilen biyosinyallerin elde edilmesini içeren bilişsel biyometri son zamanlarda yüksek güvenliqli uygulamalar için önerilmiştir. Bu kategoriye ait dikkate değer örnekler arasında kalp aktivitesi, cilt elektrodermal aktivitesi ve ayrıca beyin aktivitesi yer almaktadır. Biyometrik tanımlayıcılar gibi bu tür özelliklerin kullanılması, doğal olarak canlılık tespitinin garanti edilmesine olanak tanır. Üstelik yukarıda bahsedilen etkinliklerin uzaktan kaydedilmesi oldukça zordur.

Beyin aktivitesi söz konusu olduğunda, ilgili sinyalleri kaydetmek için mevcut olası çözümler arasında fonksiyonel manyetik rezonans görüntüleme (fMRI), yakın kızılötesi spektroskopisi (NIRS), pozitron emisyon tomografisi (PET) ve manyetoensefalografi (MEG) yer almaktadır. Elektroensefalografi (EEG), ilgili edinim cihazlarının nispeten ucuz olması ve kullanım kolaylığı nedeniyle çoğunlukla biyometrik tanıma bağlamında ele alınmıştır. Bununla birlikte, biyometrik tanıma amacıyla EEG sinyallerinin kullanılmasına ilişkin ilk öneriler 80'li yıllara dayanmasına rağmen, EEG tabanlı biyometrik sistemlerin pratik uygulamalarda gerçekçi bir şekilde konuşlandırılabilmesinden önce bazı konuların hala düzgün bir şekilde ele alınması gerekmektedir. Donanım açısından bakıldığında, çok hantal ve giyilemeyecek kadar rahatsız edici olmadan, iyi bir sinyal-gürültü oranı (SNR) ile beyin sinyallerinin toplanmasına izin verebilecek yenilikçi toplama cihazlarının tasarlanması aslında arzu edilen bir durumdur. Kafa derisi yüzeyindeki farklı konumlar arasındaki elektrik potansiyeli farkını ölçmek için ıslak elektrotlar yaygın olarak tercih edilmektedir, ancak bu durum kafa derisine elektrolit jeli sürmeyi gerektirmekte olduğundan dolayı kişiye rahatsızlık vermekte ve göz ardı edilemeyecek bir kurulum süresine neden olmaktadır. Kuru elektrotlara dayanan alternatifler mevcuttur, ancak elde edilen sinyallerin kalitesi hala ıslak elektrotlarla garanti edilenle karşılaştırılmaz ve tipik olarak kullanılan elektrot şekli, uzun süreli alımlarda ağrıya neden olabilmektedir. Bununla beraber literatürde yapılan çalışmalarda sağlıklı bireyler üzerinden toplanan EEG sinyallerine

bağlı olarak oluşturulan biyometrik tanımlama ve doğrulama çalışmaları yaygındır. Fakat hiperaktivite bozukluğu olarak bilinen ADHD (Attention Deficit Hyperactivity Disorder) bireylerde EEG tabanlı biyometrik tanımlama ve doğrulama çalışmaları oldukça sınırlıdır.

Dikkat eksikliği hiperaktivite bozukluğu (DEHB/ADHD), tipik olarak çocukluk çağında teşhis edilen, dikkatsizlik, dürtüsellik ve bazı durumlarda hiperaktivite ile karakterize bir davranış bozukluğu olarak tanımlanmaktadır. ADHD belirtileri 12 yaşından önce başlar ve bazı çocuklarda üç yaş gibi erken bir yaşta bile fark edilir hale gelebilmektedir. ADHD, erkeklerde yaklaşık %12.1, kızlarda ise %3.9 oranında olduğu tahmin edilmektedir. 4-17 yaş arası yaklaşık 6.4 milyon Amerikalı çocuğa ADHD tanısı konmuştur. ADHD bozukluğu, çocukların dikkatlerini, davranışlarını, duygularını ve aktivitelerini kontrol etme becerilerini geliştirmelerini zorlaştırır. Sonuç olarak, genellikle ADHD bozukluğu olan bireyler ebeveynlerin yönetmesi zor olan şekillerde hareket ederler. Kalıcı yetişkin ADHD'si, zayıf akademik başarı ve iş performansı, artan antisosyal davranış riski, uyuşturucu ve alkol bağımlılığı gibi uzun vadeli ciddi sonuçlara neden olabilmektedir. Bu noktada ADHD bozukluğu olan bireylerde EEG sinyalleri üzerinden makine öğrenmesi ve sinyal işleme tekniklerini kullanılarak, biyometrik tanımlama veya doğrulama çalışmalarının gerekçesi önem arz etmektedir. Bu çalışmada sınırlı sayıdaki ADHD bireylerde derin öğrenme ve sinyal işleme teknikleri üzerinden bire-karşı diğerleri (*one-versus-the others*) modeli kullanılarak biyometrik doğrulama için sonuçlar araştırılmıştır.

Bu tez çalışması sırasında, tez konusunun belirlenmesinden başlayarak son aşamaya kadar her konuda benden yardımlarını esirgemeyen danışman hocam Sayın Doç. Dr. Kutlucan GÖRÜR'e şükranlarımı sunarım.

Bu günlere gelmemde büyük emekleri olan sevgili annem ve babam başta olmak üzere, canım ablam Yasemin TEMİR ÇAVUŞ'a ve değerli eşi Göksel ÇAVUŞ'a yoğun çalışma temposunda benden maddi ve manevi desteklerini esirgemedikleri için, varlıkları ile birer motivasyon kaynağı olan tatlı yeğenlerime teşekkür ederim.

ÖZET

YÜKSEK LİSANS TEZİ

EEG TABANLI BİYOMETRİK YAKLAŞIM

Rümeysa Nur TEMİR

Bandırma Onyedİ Eylül Üniversitesi

Lisansüstü Eğitim Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Kutlucan GÖRÜR

Ocak 2025, 72 sayfa

Bu tezde, biyometrik tanıma sistemlerinin güvenlik uygulamalarındaki önemi ve geleneksel yöntemlerin sınırlamaları incelenmiştir. Bilişsel biyometri kapsamında, sinir sisteminden elde edilen biyosinyallerin kullanımı ele alınmıştır. Özellikle EEG (elektroensefalografi) sinyalleri, uygun maliyetli ve kullanımı kolay cihazlar sayesinde biyometrik tanıma için tercih edilmektedir. Ancak, mevcut EEG tabanlı sistemlerde ergonomik tasarım ve sinyal kalitesi gibi sorunlar bulunmaktadır. Bu çalışmada, dikkat eksikliği ve hiperaktivite bozukluğu (ADHD) olan bireyler üzerinde EEG tabanlı biyometrik doğrulama yöntemleri araştırılmıştır. ADHD hastası bireylerden toplanan frontal lobdaki EEG verileri kullanılarak, sinyal işleme ve derin öğrenme teknikleriyle bir biyometrik doğrulama modeli geliştirilmiştir. Elde edilen sonuçlar, EEG sinyallerinin ADHD hastası bireylerde biyometrik doğrulama için kullanılabilirliğini göstermektedir. Bu çalışma, literatürde sınırlı olan ADHD bireyler üzerinde biyometrik tanıma araştırmalarına önemli bir katkı sağlamaktadır. Gelecekteki araştırmalar için daha geniş veri setleri ve gelişmiş cihazlar önerilmektedir.

Anahtar kelimeler: Biyometrik Tanıma, EEG, ADHD, Derin Öğrenme, Sinyal İşleme

ABSTRACT

M.Sc. THESIS

BIOMETRIC AUTHENTICATION OF ADHD INDIVIDUALS USING SIGNAL PROCESSING AND 1D-CNN APPROACHES ON FRONTAL LOBE EEG SIGNALS

RÜMEYSA NUR TEMİR

Bandırma Onyedi Eylül University

Institute of Graduate School

Department of Electrical and Electronics Engineering

Supervisor: Assoc. Prof. Kutlucan GÖRÜR

January 2025, 72 pages

This thesis explores the significance of biometric recognition systems in security applications and examines the limitations of traditional methods. Within the scope of cognitive biometrics, the utilization of biosignals derived from the nervous system is addressed. Specifically, electroencephalography (EEG) signals have emerged as a preferred choice for biometric recognition due to the affordability and user-friendliness of modern devices. However, current EEG-based systems face challenges related to ergonomic design and signal quality. This study investigates EEG-based biometric authentication methods in individuals with Attention Deficit Hyperactivity Disorder (ADHD). By utilizing EEG data collected from the frontal lobe of ADHD individuals, a biometric authentication model was developed through the application of signal processing and deep learning techniques. The results demonstrate the feasibility of using EEG signals for biometric authentication in individuals with ADHD. This work makes a significant contribution to the limited body of literature on biometric recognition in ADHD populations. For future research, the use of larger datasets and advanced devices is recommended to further enhance the reliability and applicability of EEG-based biometric systems.

Keywords: Biometric Recognition, EEG, ADHD, Deep Learning, Signal Processing

İÇİNDEKİLER

	Sayfa
ÖNSÖZ	iii
ÖZET	I
ABSTRACT	II
İÇİNDEKİLER	III
ŞEKİL LİSTESİ	IV
TABLO LİSTESİ	VI
SİMGE LİSTESİ	VII
KISALTMALAR LİSTESİ	VIII
1. GİRİŞ	1
2. MATERYAL VE YÖNTEM	14
2.1 BİYOMETRİK TANIMA SİSTEMLERİ	14
2.1.1 EEG Tabanlı Biyometrik Tanıma Sistemleri	14
2.1.2 ADHD ve EEG Sinyalleri	15
2.1.3 Derin Öğrenme ve Performans Metrikleri	20
2.1.3.1 1D-CNN Derin Öğrenme Modeli	23
2.1.4 Sinyal İşleme Yöntemleri	25
2.1.4.1 Ampirik Mod Ayrıştırması (EMD)	25
2.1.4.2 Bağımsız Bileşen Analizi (ICA)	25
2.1.4.3 Ayırık Dalgacık Dönüşümü (DWT)	26
2.1.4.4 t-SNE Ayrıştırma ve Saçılım Tekniği	26
3. BULGULAR	27
4. TARTIŞMA VE SONUÇ	65
5. KAYNAKLAR	67
ÖZGEÇMİŞ	72

ŞEKİL LİSTESİ

<u>Sekil</u>	<u>Sayfa</u>
Şekil 1-1 : Statik ve dinamik biyometrik sistemlere ait görsel	3
Şekil 1-2 : EEG tabanlı biyometrik sistem örneği.....	4
Şekil 1-3 : ADHD bireylerde EEG tabanlı biyometrik yaklaşım görseli.....	6
Şekil 2-1 : Beyin bölgeleri ve işlevleri.....	16
Şekil 2-2 : 10-20 sisteminde EEG kanal yerleşim örneği.....	17
Şekil 2-3 : MANOVA ve ADHD bireylerin EEG sinyalleri üzerinden ayrıştırılması.....	19
Şekil 2-4 : ADHD bireyler için EEG sinyalleri üzerinden biyometrik tanıma sinyal işleme adımları.....	21
Şekil 2-5 : Karmaşıklık matrisi gösterimi.....	22
Şekil 2-6 : 1D-CNN şematik gösterimi.....	24
Şekil 3-1 : ADHD bireylerde ICA uygulanmış EEG sinyalleri üzerinden t-SNE saçılım tabanlı biyometrik ayrım görseli; Soldaki görsel tüm EEG kanallarını, sağdaki ise yalnızca 7 frontal kanalı göstermektedir.....	40
Şekil 3-2 : ADHD bireylerde farklı sinyal işleme teknikleri uygulanmış EEG sinyalleri üzerinden t-SNE saçılım tabanlı biyometrik ayrım görseli; Soldaki görsel tüm EEG kanallarını, sağdaki ise yalnızca 7 frontal kanalı göstermektedir.....	42
Şekil 3-3 : ADHD bireylerde ICA uygulanmış EEG sinyalleri üzerinden t-SNE saçılım tabanlı <i>one-versus-the others</i> biyometrik ayrım görseli; Soldaki görsel tüm EEG kanallarını, sağdaki ise yalnızca 7 frontal kanalı göstermektedir.....	45
Şekil 3-4 : ADHD bireylerde farklı sinyal işleme teknikleri uygulanmış EEG sinyalleri üzerinden t-SNE saçılım tabanlı biyometrik ayrım görselleri; Soldaki görsel tüm EEG kanallarını, sağdaki ise yalnızca 7 frontal kanalı göstermektedir.....	48
Şekil 3-5 : ADHD bireylerde ham EEG sinyalleri üzerinden çok kanallı zaman- genlik görseli.....	50
Şekil 3-6 : ADHD bireylerde ham EEG sinyalleri üzerinden beyin haritalama görseli.....	52
Şekil 3-7 : ADHD bireylerde DWT uygulanmış EEG sinyalleri üzerinden beyin haritalama görseli.....	54
Şekil 3-8 : ADHD bireylerde ham EEG sinyalleri üzerinden korelasyon matrisi görseli.....	57
Şekil 3-9 : ADHD bireylerde ICA uygulanmış EEG sinyalleri üzerinden korelasyon matrisi görseli.....	59

Şekil 3-10 : ADHD bireylerde DWT uygulanmış EEG sinyalleri üzerinden korelasyon matrisi görseli.....	60
Şekil 3-11 : ADHD bireylerde ham EEG sinyalleri üzerinden farklı kanal çiftlerine bağlı olasılık yoğunluk fonksiyonu görseli.....	64



TABLO LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 2-1 : EEG frekans bantları ve genlikleri	18
Tablo 3-1 : Ham EEG sinyallerine göre ADHD bireylerde <i>one-versus-the others</i> biyometrik tanıma sonuçları.....	27
Tablo 3-2 : Ham EEG sinyallerine EMD uygulanmış ADHD bireylerde <i>one-versus-the others</i> biyometrik tanıma sonuçları	29
Tablo 3-3 : Ham EEG sinyallerine EMD+ICA uygulanmış ADHD bireylerde <i>one-versus-the others</i> biyometrik tanıma sonuçları.....	32
Tablo 3-4 : Ham EEG sinyallerine DWT uygulanmış ADHD bireylerde <i>one-versus-the others</i> biyometrik tanıma sonuçları.....	34
Tablo 3-5 : Ham EEG sinyallerine DWT+EMD uygulanmış ADHD bireylerde <i>one-versus-the others</i> biyometrik tanıma sonuçları.....	36
Tablo 3-6 : Ham EEG sinyallerine DWT+ICA uygulanmış ADHD bireylerde <i>one-versus-the others</i> biyometrik tanıma sonuçları.....	38

SİMGELER 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 LİSTESİ

Kısaltmalar	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 Görüntüleri (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	: Elektroensefalogram (Electroencephalogram)
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 Ömürlü Kısa-Dönem Belleği (Long Short-Term Memory)
STFT	: Kısa zamanlı Fourier Dönüşümü (Short Time Fourier Transform)
BiLSTM	: 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)
ADHD	: Dikkat Eksikliği ve Hiperaktivite Bozukluğu (Attention Deficit Hyperactivity Disorder)
SB	: Katılımcı (Subject)

1. GİRİŞ


Biyometrik sistemler, bireylerin benzersiz biyolojik ve davranışsal özelliklerini kullanarak kimlik doğrulama ve tanıma işlemleri gerçekleştiren otomatik sistemlerdir. Bu sistemler, parmak izi, yüz tanıma, iris veya retina taraması, ses tanıma ve el geometrisi gibi kişiye özgü fiziksel ve davranışsal verileri analiz ederek çalışır [1]. Biyometrik sistemlerin temel avantajları arasında şifre veya kart taşıma gereksinimini ortadan kaldırmaları, unutulma veya çalınma riskinin bulunmaması ve yüksek güvenlik sağlamaları yer almaktadır. Bu özellikleri sayesinde biyometrik sistemler, sağlık hizmetlerinden eğitim sektörüne, hükümet uygulamalarından personel devam kontrolüne kadar geniş bir kullanım alanına sahiptir [2]. Her bir biyometrik sistemin kendi içinde avantajları ve dezavantajları bulunmaktadır. Örneğin, parmak izi tanıma sistemleri yaygın olarak kullanılmakla birlikte, yüz tanıma ve iris tanıma sistemleri de son yıllarda ilginin arttığı ve kullanılmaya başlanan özelliklerdir [3]. Sonuç olarak, biyometrik sistemler, bireylerin benzersiz biyolojik ve davranışsal özelliklerini kullanarak kimlik doğrulama ve tanıma işlemlerini daha güvenli ve verimli hale getiren teknolojilerdir.

Statik biyometrik sistemler, bireylerin değişmeyen veya çok az değişen fiziksel özelliklerini kullanarak kimlik doğrulama yapan otomatik sistemlerdir. Bu sistemler, parmak izi, yüz geometrisi, iris ve retina desenleri gibi kişiye özgü biyolojik verileri analiz ederek çalışmaktadır. Örneğin, parmak izi tanıma sistemleri, her bireyin benzersiz parmak izi desenini kullanarak kimlik doğrulama yapar. Benzer şekilde, yüz tanıma sistemleri, yüzün genel şekli, gözler arasındaki mesafe ve diğer yüz özelliklerini analiz ederek kişileri tanımlar. Statik biyometrik sistemler, şifre veya kart taşıma gereksinimini ortadan kaldırarak güvenliği artırır ve kullanım kolaylığı sağlamaktadır [4] - [6].

Statik biyometrik sistemler, bireylerin değişmeyen fiziksel özelliklerini kullanarak kimlik doğrulama yapmaktadır. Ancak, bu sistemlerin bazı dezavantajları bulunmaktadır. Örneğin, parmak izi veya yüz görüntüleri gibi statik biyometrik veriler, yüksek çözünürlüklü fotoğraflar veya kalıplar kullanılarak taklit edilebilir, bu da güvenlik açıklarına yol açabilmektedir. Ayrıca, biyometrik veriler kişisel bilgiler arasında en hassas olanlardır ve kötüye kullanımı ile veri ihlalleri riski taşımaktadır. Biyometrik sistemlerin kurulumu ve bakımı maliyetli olabilir, bu da özellikle küçük işletmeler ve kuruluşlar için bir engel oluşturabilir. Teknolojik arızalar ve yanlış

tanıma gibi sorunlar, kullanıcı deneyimini olumsuz etkileyebilir. Bunun yanında, bazı kullanıcılar için biyometrik sistemler etkili olmayabilir; örneğin, parmak izi tarayıcıları yaşlı veya hastalıklı kişilerin parmak izlerini doğru okuyamayabilir. Bu dezavantajlar, statik biyometrik sistemlerin kullanımında dikkate alınması gereken önemli faktörlerdir [7] - [9].


Dinamik biyometrik sistemler, bireylerin ses tanıma, imza dinamikleri, yürüme analizi, klavye dinamikleri, göz hareketi takibi, kalp atış hızı analizi, yüz ifadeleri ve mikro ifadeler ile dokunmatik ekran dinamikleri gibi değişken ve gerçek zamanlı özelliklerini analiz ederek kimlik doğrulama yapmaktadır (bakınız; Şekil 1-1). Bu sistemler, özellikle ses tonu, yazma hızı, adım uzunluğu, göz hareketleri veya kalp ritmi gibi bireylere özgü davranışsal ve fizyolojik özelliklere dayanır ve taklit edilmesi zor olduğu için daha güvenlidir. Örneğin, telefon bankacılığı, dijital sözleşmeler, fiziksel güvenlik, çevrimiçi erişim kontrolü, giyilebilir cihazlar ve sanal gerçeklik gibi birçok alanda kullanılırken, doğal ve bireyselleşmiş özellikleri sayesinde sahtecilik riskini azaltmaktadır. Ancak, gerçek zamanlı analiz gerektirdiğinden dolayı bu sistemler karmaşık, maliyetli ve kullanıcı davranışlarındaki değişikliklere karşı duyarlı olmaktadır. Dinamik biyometrik sistemlerin en önemli avantajı, bireylere özgü davranışsal ve fizyolojik özelliklere dayanarak kimlik doğrulama yapmasıdır, bu da taklit edilmesini zorlaştırır ve statik sistemlere göre daha yüksek güvenlik sağlamaktadır. Bu sistemler, aynı anda birden fazla özelliği analiz edebilme yeteneğiyle güçlü doğrulama imkanı sunar ve kullanıcıların doğal davranışlarını (yürüme, konuşma, yazma gibi) analiz ettiği için kullanıcı dostudur. Uzaktan kimlik doğrulama yapılabilmesi (örneğin, ses tanıma ve yürüme analizi ile) ve çok faktörlü güvenlik için diğer biyometrik sistemlerle entegre edilebilmesi, dinamik biyometrik sistemlerin başka bir avantajıdır. Telefon bankacılığı, giyilebilir cihazlar, sanal gerçeklik uygulamaları ve fiziksel güvenlik gibi geniş bir kullanım alanı sunarken, bireysel davranışların değerlendirilmesi sayesinde yüksek doğruluk ve güvenlik sağlar [10] - [13].



Şekil 1-1 : Statik ve dinamik biyometrik sistemlere ait görsel

EEG (Elektroensefalografi) tabanlı biyometrik sistemler, bireylerin kimliklerini doğrulamak için beyin dalgalarını analiz ederek benzersiz bir biyometrik yöntem sunmaktadır (bakınız; Şekil 1-2). EEG, beynin elektriksel aktivitelerini ölçerek, bireyin bilişsel, motor ve duygusal tepkilerini analiz edebilmektedir. Bu sistemler dinlenim durumu EEG'si ile bireyin herhangi bir görev yapmadan doğal beyin aktivitelerini ölçebilirken, görev tabanlı EEG ile bireyden belirli bir bilişsel veya motor görevi gerçekleştirmesi istenerek daha özgün sinyaller elde edilebilir. Uyarılmış potansiyeller yöntemi, dış bir uyarana (örneğin, ışık, ses veya dokunma) verilen beyin tepkilerini analiz eder ve özellikle P300 gibi bileşenler kimlik doğrulamada kullanılabilir. Motor imgeleme, bireyden bir hareketi zihinsel olarak hayal etmesini ister ve motor kortekste oluşan sinyaller üzerinden analiz yapmaktadır. Duygusal tepkiler, bireyin mutluluk, stres gibi duygusal durumlarının beyin dalgalarındaki etkilerini değerlendirirken, beyin bağlantısallığı yöntemi EEG sinyallerindeki beyin bölgeleri arasındaki bağlantı düzenlerini analiz ederek kimlik doğrulama yapmaktadır. EEG sinyallerinin zamansal ve frekans özellikleri Fourier Dönüşümü, Wavelet Dönüşümü veya Ampirik Mod Ayrıştırma (EMD) gibi yöntemlerle çıkarılarak bireyin kimliğini doğrulamada kullanılabilmektedir. EEG tabanlı biyometrik sistemlerin benzersizliği, bireylerin beyin aktivitelerinin tamamen kendilerine özgü olmasından kaynaklanır ve bu sistemler sahtecilik girişimlerine karşı oldukça güvenlidir. Ayrıca, klinik ve nörolojik teşhis uygulamalarıyla entegre edilebilme avantajına sahiptir. Bununla birlikte, bu sistemlerin hassasiyeti, çevresel faktörlere duyarlılığı ve cihazların elektrot yerleştirme gereksinimi nedeniyle pratik kullanımı sınırlı olmaktadır. Hassas ve yüksek çözünürlüklü EEG cihazlarına duyulan ihtiyaç ve kullanıcı deneyimini etkileyen uzun kurulum süreleri, bu

teknolojinin yaygınlaşmasını sınırlayan başlıca faktörlerdir. Bununla birlikte, EEG tabanlı biyometrik sistemler güvenlik ve nörolojik araştırmalar için büyük bir potansiyele sahiptir [14]-[20].




Şekil 1-2 : EEG tabanlı biyometrik sistem örneği

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (ADHD), çocukluk döneminde başlayan ve yetişkinlikte de devam edebilen, dikkat, dürtü kontrolü ve hiperaktivite ile ilgili sorunlara yol açan nörogelişimsel bir bozukluktur. ADHD'nin kesin nedeni bilinmemekle birlikte, genetik yatkınlık, çevresel faktörler ve beyin yapısındaki farklılıklar gibi etkenlerin rol oynadığı düşünülmektedir. Bu bozukluk, genellikle üç temel belirtiden oluşur: dikkat eksikliği, hiperaktivite ve dürtüsellik. Dikkat eksikliği, detaylara dikkat edememe, dikkati sürdürmememe, unutkanlık ve görevleri tamamlama zorluğu gibi özelliklerle kendini gösterirken, hiperaktivite sürekli hareket halinde olma, yerinde duramama ve sessizce oturamama gibi davranışları içermektedir. Dürtüsellik ise sırasını bekleyememe, düşünmeden hareket etme ve başkalarının sözünü kesme gibi kontrolsüz davranışlarla öne çıkmaktadır. ADHD, belirtilerin yoğunluğuna ve türüne göre dikkat eksikliğinin baskın olduğu tip, hiperaktif-dürtüsel tip ve her iki özelliğin bir arada görüldüğü kombine tip olarak sınıflandırılmaktadır. Tedavi ve yönetim genellikle ilaç tedavisi, davranışsal terapi, eğitimsel destek ve yaşam tarzı düzenlemelerinin bir kombinasyonunu içermektedir. İlaçlar arasında metilfenidat (Ritalin) gibi stimülanlar ya da atomoksetin gibi alternatifler yer alırken, terapi özellikle çocuklarda dikkat ve dürtü kontrolüne

yardımcı olmaktadır. Eğitimsel destek, bireysel öğrenme planlarını içerirken düzenli uyku, sağlıklı beslenme ve fiziksel aktivite gibi yaşam tarzı düzenlemeleri de semptomların yönetilmesinde önemli bir rol oynamaktadır. Doğru tedavi ve destekle, ADHD'li bireyler yaşamlarında başarılı olabilir ve bu durumun zorluklarının üstesinden gelmektedir [21]-[24].

ADHD (Dikkat Eksikliği ve Hiperaktivite Bozukluğu) ile EEG (Elektroensefalografi) arasında güçlü bir ilişki bulunmaktadır, çünkü ADHD'nin nörogelişimsel bir bozukluk olması nedeniyle beyin aktivitesindeki farklılıkların tespiti için EEG sıklıkla kullanılan bir araçtır (bakınız; Şekil 1-3). EEG, beyindeki elektriksel aktiviteyi ölçen bir yöntemdir ve ADHD'li bireylerde genellikle belirli beyin dalgası paternleri normal popülasyona göre farklılık göstermektedir. Özellikle, ADHD'li bireylerde yavaş beyin dalgaları olan teta dalgalarının artışı ve daha hızlı dalgalar olan beta dalgalarının azalması gibi anormal bir teta/beta oranı sıkça rapor edilmiştir. Bu durum, dikkat ve kontrolle ilgili beyin bölgelerindeki (özellikle frontal korteks) disfonksiyonlara işaret etmektedir. EEG verileri, ADHD'nin değerlendirilmesinde yardımcı olabilir ve bazı durumlarda tanı sürecini desteklemek için kullanılmaktadır. Ayrıca, EEG tabanlı nörofeedback terapisi, bireylerin kendi beyin dalgalarını düzenlemeyi öğrenmeleri için kullanılan bir yöntemdir ve ADHD semptomlarının azaltılmasında etkili olmaktadır. Bunun yanında, EEG sinyalleri üzerinden beyindeki dikkat ve dürtü kontrolüne dair daha detaylı bilgi edinmek, ADHD'li bireylerin bireyselleştirilmiş tedavi ve yönetim planlarının oluşturulmasında fayda sağlamaktadır. EEG'nin sağladığı objektif veriler, ADHD'nin tanı ve tedavi sürecini destekleyerek, bireyin beyin aktivitesine dayalı bir yaklaşımla semptomlarının daha iyi anlaşılmasına olanak tanımaktadır [21]-[24].



Şekil 1-3 : ADHD bireylerde EEG tabanlı biyometrik yaklaşım görseli

Tez çalışmasında kullanılan veri seti, IEEE DataPort platformu üzerinden erişilebilen ve dikkat eksikliği ve hiperaktivite bozukluğu (ADHD) tanısı almış bireyler ile kontrol grubunda yer alan sağlıklı bireylere ait EEG verilerini içeren, "EEG Data for ADHD / Control Children" başlıklı kapsamlı bir veri setidir [25]. Bu veri seti, literatürde nadir bulunan bir kaynak niteliği taşıyarak, ADHD'li çocuklar ve sağlıklı kontrol grubundaki çocukların beyin aktivitelerini incelemeye olanak tanımaktadır. ADHD tanısı konmuş bireylerin EEG verilerinin biyometrik kimlik doğrulama sistemlerinde kullanımına dair yapılan çalışmalar oldukça sınırlı olduğundan, bu veri seti hem bilimsel hem de uygulamalı anlamda büyük bir boşluğu doldurmayı hedeflemektedir [26]. Çalışma kapsamında kullanılan veri seti, ADHD tanısı almış çocukların zihinsel süreçlerini, dikkat eksikliklerini ve nörogelişimsel farklılıklarını biyometrik bir perspektifle değerlendirebilmek için eşsiz bir fırsat sunmaktadır. ADHD ve kontrol grubuna ait EEG sinyalleri, literatürde sıkça karşılaşılan dinlenme durumunda alınan EEG verilerinden farklı olarak, dikkat yoğunlaştırıcı bir görev sırasında kaydedilmiştir. Bu görev, çocukların dikkat performanslarını ve zihinsel süreçlerini ölçmek amacıyla görsel dikkat temelli bir protokol üzerine kurgulanmıştır. Böylelikle, tezde bu özgün veri seti kullanılarak, ADHD'li bireylerin nörolojik özelliklerini değerlendirmek ve bu bireylerin biyometrik doğrulama sistemlerindeki potansiyel kullanımını ortaya koymak hedeflenmiştir. Söz konusu veri setinin kullanımı, ADHD bireylerinin EEG tabanlı biyometrik yöntemlerle incelenmesi ve bu popülasyon için kişiye özgü,

güvenilir kimlik doğrulama sistemlerinin geliştirilmesi için temel bir zemin oluşturmuş ve bu alandaki araştırmalar için öncü bir çalışma yapılmasına olanak tanımıştır [25], [26].

Bu tezde, dikkat eksikliği ve hiperaktivite bozukluğu (ADHD) bireyleri üzerine yapılan EEG tabanlı biyometrik araştırmalara odaklanılmış olup, literatürdeki mevcut çalışmaların kapsamlı bir değerlendirmesi sunulacaktır:

Shaveta Dargan ve Munish Kumar, biyometrik tanıma sistemleri üzerine yaptıkları kapsamlı bir literatür taramasında, tek modlu ve çok modlu biyometrik sistemleri detaylı bir şekilde incelemişlerdir. Çalışmada, biyometrik sistemlerin doğruluk ve etkinlik açısından analizleri yapılmış, farklı biyometrik modalitelerin avantajları ve sınırlılıkları belirtilmiştir. Araştırmada, örneğin, parmak izi tabanlı biyometrik sistemlerin doğruluk oranlarının %98'e ulaştığı, ancak gürültülü veri ve çevresel etkiler nedeniyle sistem performansının düşebileceği vurgulanmıştır. Çok modlu biyometrik sistemlerin ise, yanlış kabul oranlarını (False Acceptance Rate - FAR) %0.1'in altına düşürerek tek modlu sistemlere göre daha güvenilir ve doğru sonuçlar sağladığı gösterilmiştir. Ayrıca, derin öğrenme tabanlı yöntemlerin biyometrik sistemlerde doğruluğu artırdığı ifade edilmiştir. Örneğin, Convolutional Neural Network (CNN) kullanılarak yapılan çalışmalarda, yüz tanıma sistemlerinde doğruluk oranlarının %95'i aştığı ve sahtekarlık girişimlerine karşı daha dirençli olduğu belirtilmiştir. Araştırma, farklı modaliteler için önerilen yöntemlerin etkisini ve bu sistemlerin uygulamalarını sistematik bir şekilde özetlemiş, aynı zamanda literatürde kullanılan veri setleri, sınıflandırıcılar ve özellik çıkarım yöntemlerini detaylandırmıştır [27].

Behera ve arkadaşları, hareket sensörleri ve EEG (elektroensefalogram) sinyallerini birleştirerek, taşınabilir elektronik cihazlar için sağlam bir biyometrik kimlik doğrulama sistemi geliştirmiştir. Çalışmada, havada imza atma sırasında parmak hareketleri ve beyin aktiviteleri eş zamanlı olarak kaydedilmiştir. Bu iki farklı modaliteden elde edilen özellikler, Hidden Markov Model (HMM) ve Random Forest (RF) sınıflandırıcıları kullanılarak değerlendirilmiştir. Sonuçlar, EEG ve hareket verilerini birleştirmenin, sahte imza girişimlerine karşı güvenilirliği artırdığını göstermiştir. HMM kullanılarak ortalama %95,5 doğruluk oranı, RF kullanılarak ise %98,5 doğruluk oranı elde edilmiştir. Sistem, özellikle omuz üzerinden izleme (shoulder surfing) saldırılarına karşı dayanıklıdır ve kullanıcıdan bağımsız olarak doğru sonuçlar sağlamaktadır. Ayrıca, RF sınıflandırıcısının HMM'e göre daha yüksek doğruluk oranı sunduğu

belirtilmiştir. Çalışmada kullanılan sensörlerin düşük maliyetli ve taşınabilir olması, sistemin geniş bir kullanıcı kitlesi için uygulanabilirliğini artırmaktadır [28].

Luis Alfredo Moctezuma ve Marta Molinas, biyometrik sistemlerde kullanılmak üzere, dinlenme hâlindeki EEG sinyallerinden en az sayıda kanal seçimi için genetik algoritmaya dayalı bir yöntem geliştirmiştir. Çalışmada, EEG sinyalleri DWT ve EMD yöntemleriyle alt bantlara ayrılmış, bu bantlardan enerji ve fraktal özellikler çıkarılarak bireylerin modelleri oluşturulmuştur. Çalışmada, 109 katılımcının EEG sinyalleri üzerinde, gözlerin açık ve kapalı olduğu durumlarda deneyler yapılmıştır. Elde edilen sonuçlara göre, 64 EEG kanalıyla %100'e yakın True Acceptance Rate (TAR) ve %99.8'e varan True Rejection Rate (TRR) sağlanmıştır. Daha da önemlisi, sadece üç kanal kullanılarak %99.3 TAR ve %94.1 TRR elde edilmiştir. Bu bulgular, az sayıda kanal kullanılarak da yüksek doğrulukta biyometrik sistemlerin mümkün olabileceğini göstermektedir. Çalışma, düşük yoğunluklu EEG cihazları için uygun kanal kombinasyonlarını optimize ederek hem taşınabilirlik hem de uygulama kolaylığı sağlamayı amaçlamıştır [29].

Jayarathne ve arkadaşları, dinlenme hâlindeki EEG sinyalleriyle kişi tanıma üzerine yaptıkları çalışmalarında, yeni bir özellik olan "Inter-Hemispheric Amplitude Ratio" (IHAR) yöntemini tanıtmıştır. Bu yöntem, beynin iki hemisferindeki simetrik elektrot çiftlerinden elde edilen sinyallerin amplitüd oranlarını kullanarak bireylerin kimliklerini ayırt etmektedir. Çalışmada, IHAR özelliği, veri setlerini artırmak için kullanılan sinyal çoğaltma teknikleriyle genişletilmiş ve çeşitli makine öğrenmesi algoritmalarıyla test edilmiştir. Sonuçlara göre, 14 elektrot ile %100 doğruluk oranına ulaşılmış ve sadece dört frontal elektrot (AF3-AF4 ve F7-F8) kombinasyonu ile %99.0±0.8 doğruluk oranı elde edilmiştir. Kullanılan kNN sınıflandırıcı ile elde edilen sonuçlar, hem kullanıcı dostu hem de yüksek performans sağlayan bir sistemin oluşturulabileceğini göstermektedir. Ayrıca, dinlenme aşamasında elde edilen EEG sinyallerinin diğer aşamalara kıyasla daha stabil olduğu ve bu nedenle en yüksek doğruluk oranına ulaştığı belirtilmiştir. Bu bulgular, taşınabilir cihazlarda kullanılabilecek düşük maliyetli ve az elektrot gerektiren EEG biyometrik sistemlerinin geliştirilmesi için önemli bir adım teşkil etmektedir [30].

Walia ve arkadaşları, üç tamamlayıcı biyometrik özellik olan iris, parmak damarı ve parmak izi üzerine dayalı optimal bir skorlama düzeyi füzyon modeli geliştirerek sağlam bir çok modlu biyometrik sistem sunmuşlardır. Çalışmada, bireysel sınıflandırıcıların performansı,

evrimsel Geri İzleme Arama Optimizasyonu Algoritması (BSA) kullanılarak optimize edilmiş ve sınıflandırıcılar arasındaki çelişkili inançlar, Orantılı Çatışma Yeniden Dağıtım (PCR-6) kurallarıyla çözülmüştür. Önerilen sistem, dinamik ortamlarda hem güvenilirliği hem de doğruluğu artırarak ortalama %98.43 doğruluk oranı ve %1.57 EER (Equal Error Rate) elde etmiştir. Özellikle, bu füzyon modeli bireysel sınıflandırıcıların çelişkili skorlarını çözümleyerek, eş zamanlı sınıflandırıcılar arasında destekleme ya da bastırma işlevlerini gerçekleştirmiştir. Çalışma, çoklu biyometrik özellikleri birleştirmenin, yalnızca bir biyometrik özelliğe dayalı sistemlerden daha güvenli ve doğru olduğunu ortaya koymuş, aynı zamanda güncel teknikleri geride bırakarak uzman bir çok modlu biyometrik sistemin geliştirilmesine yönelik yeni yollar açmıştır [31].

Zhao ve arkadaşları, görsel uyarılmış potansiyellere (VEP) dayalı bir biyometrik tanıma sistemi geliştirmiş ve bu sistemi çevrimiçi uygulamalar için test etmiştir. Çalışmada üç farklı VEP türü (flaş-VEP, sürekli durum-VEP ve kod modüle edilmiş VEP) kişi tanıma amaçlı karşılaştırılmıştır. Kod modüle edilmiş VEP'ler (c-VEP), %100 doğruluk oranı (CRR) ile en yüksek başarıyı göstermiştir. İntra-oturum koşullarında 3.15 saniyelik VEP verileri kullanılarak %100 CRR elde edilmiş, çapraz oturum koşullarında ise 10.5 saniyelik verilerle %99.48 CRR sağlanmıştır. Ayrıca, çevrimiçi bir sistem 15 denek üzerinde test edilmiş ve 10.5 saniyelik VEP verileriyle %98.93 CRR elde edilmiştir. Bu çalışma, VEP sinyalleri arasında bireysel farkları tespit ederek yüksek doğruluk oranları sunmuş ve sistemin çevrimiçi uygulamalar için uygunluğunu göstermiştir. Özellikle, c-VEP paradigmasının hem stabilite hem de doğruluk açısından diğer yöntemlerden üstün olduğu vurgulanmıştır. Bu sistem, gerçek dünyada kişi tanıma uygulamaları için önemli bir potansiyele sahiptir [32].

Yang ve arkadaşları, EEG tabanlı biyometrik kimlik tanıma için yeni bir özellik çıkarım yöntemi geliştirmiş ve elektrot yerleşiminin performans üzerindeki etkisini incelemiştir. Çalışmada, ham EEG sinyallerine dalgacık dönüşümü uygulanarak elde edilen dalgacık katsayılarının logaritmaları hesaplanmış ve ardından ayrık kosinüs dönüşümü (DCT) kullanılarak özellik vektörleri oluşturulmuştur. Önerilen özellik çıkarım yöntemi hem tanıma hem de doğrulama senaryolarında değerlendirilmiştir. Motor Hareket/İmgeleme EEG veri seti (MM/I) kullanılarak yapılan testlerde, önerilen Wavelet-Log-DCT (WLD) özelliği, tanıma senaryosunda %98.24, doğrulama senaryosunda ise %0.5 EER ile en yüksek başarıyı göstermiştir. UCI EEG veri seti üzerinde yapılan çalışmalarda ise WLD, tanıma senaryosunda %93.28 doğruluk oranı elde etmiştir. Ayrıca, sadece dört elektrot kullanılarak

yüksek doğruluk oranlarına ulaşılmıştır. Örneğin, MM/I veri setinde, dış dairede yer alan uzak elektrot kombinasyonları kullanıldığında, tanıma oranları yaklaşık %9 oranında artmıştır. WLD özelliğinin zaman ayrımı (template-aging) etkisine karşı daha dayanıklı olduğu ve eğitim ile test setleri arasında birkaç dakikalık ayrım olduğunda performans kaybının %14 ile sınırlı kaldığı belirtilmiştir. Bu çalışma, daha az sayıda elektrot ile yüksek doğruluk sağlayan EEG biyometrik sistemleri için önemli bir adım teşkil etmekte ve taşınabilir cihazlar için daha az müdahaleci çözümler sunmaktadır [33].

Chen ve arkadaşları, hızlı seri görsel sunum (RSVP) paradigması ve kuru elektrotlar kullanarak yüksek güvenli bir EEG tabanlı giriş sistemi geliştirmiştir. Çalışmada, katılımcılara üç sembol içeren bir şifre seçmeleri ve bu şifre ile birlikte diğer sembollerin hızlı bir şekilde sunulduğu RSVP prosedürüne katılmaları sağlanmıştır. Şifre sembolleri, ERP (Event-Related Potential) bileşenlerini artırarak makine öğrenmesi teknikleri ile tespit edilmiştir. Sistem, hem yaş hem de cinsiyet açısından çeşitli 29 katılımcı üzerinde test edilmiştir. Kuru elektrotlarla ortalama %100 kabul oranına (True Acceptance Rate - TAR) ulaşılmış ve giriş süresi 27 saniye olarak belirlenmiştir. Yanlış kabul oranı (False Acceptance Rate - FAR) 3.33×10^{-5} olarak ölçülmüştür. Ayrıca, ıslak elektrotlarla yapılan ölçümlerde giriş süresi daha kısa olup, 13.5 saniye olarak hesaplanmıştır. Çalışma, ERP bileşenlerinin sağlamlığını ve sistemin doğruluğunu, yüksek güvenlik gereksinimlerini karşılamak amacıyla optimize etmiştir [34].

Moctezuma ve Molinas, EEG tabanlı biyometrik kimlik doğrulama ve yetkisiz kullanıcı tespiti için dört hedefli bir optimizasyon yöntemi geliştirmiştir. Çalışmada, Empirical Mode Decomposition (EMD) kullanılarak EEG sinyallerinden alt bantlar çıkarılmış ve her banttan enerji ve fraktal özellikler hesaplanmıştır. Özellik vektörleri, bir sınıflı ve çok sınıflı destek vektör makineleri (SVM) ile değerlendirilmiştir. Optimizasyon işlemi, Non-Dominated Sorting Genetic Algorithm (NSGA-II ve NSGA-III) ile gerçekleştirilmiş, en iyi kanal kombinasyonları belirlenmiştir. Üç kanal kombinasyonu ile %83 doğruluk, %91 TAR (True Acceptance Rate) ve %88 TRR (True Rejection Rate) sağlanmıştır. Daha geniş kanal kombinasyonlarıyla doğruluk oranı %98'e, TAR %95'e ve TRR %93'e ulaşmıştır. Rastgele oluşturulan 10 farklı alt kümede, 8 kanal kombinasyonu ile doğruluk 97 ± 0.02 , TAR 81 ± 0.12 ve TRR 85 ± 0.10 olarak ölçülmüştür. Çalışma, az sayıda kanal ile yüksek doğruluk sağlayan bir sistem sunmuş ve taşınabilir EEG cihazları için önemli bir adım atmıştır. Özellikle, belirlenen kanal kombinasyonlarının parietal ve oksipital alanlardan geldiği vurgulanmıştır. Bu sistem,

biyometrik kimlik doğrulama ve yetkisiz giriş tespiti için endüstriyel seviyede uygulamalara yönelik bir potansiyel taşımaktadır [35].

Zhao ve arkadaşları, kod modülasyonlu görsel uyaran potansiyellerine (c-VEP) dayalı bir birey tanıma yöntemi geliştirmiştir. Bu çalışmada, 25 katılımcıdan elde edilen EEG sinyalleri kullanılarak c-VEP tabanlı bir tanıma sistemi tasarlanmış ve değerlendirilen sekiz farklı uyaran modeli ile birey tanıma performansı incelenmiştir. Sistem, özellikle intra-sesyon ve çapraz-sesyon performanslarını değerlendirmek için iki farklı gün boyunca veri toplayarak uzun süreli doğruluğu test etmiştir. Intra-sesyon koşullarında, 5.25 saniyelik EEG verisi ile %100 doğru tanıma oranı (CRR) elde edilmiştir. Çapraz-sesyon koşullarında ise 10.5 saniyelik EEG verisi kullanılarak %99.43 CRR sağlanmıştır. Çalışmada kullanılan state-of-the-art algoritmalar ve kişiye özgü şablon eşleştirme yöntemi, sistemin doğruluğunu ve kararlılığını artırmıştır. Özellikle, TRCA (Task-Related Component Analysis) yönteminin çapraz-sesyon koşullarında CCA (Canonical Correlation Analysis) yöntemine göre daha yüksek bir performans sunduğu vurgulanmıştır. Bu sonuçlar, kısa süreli EEG verisi ile yüksek doğrulukta tanıma sağlamanın mümkün olduğunu göstermekte ve c-VEP tabanlı sistemlerin gerçek dünya uygulamalarında kullanılabilirliğini desteklemektedir [36].

Wilaiprasitporn ve arkadaşları, affektif EEG tabanlı birey tanıma için derin öğrenme (CNN-GRU ve CNN-LSTM) yöntemlerini önererek farklı ruh hâllerinden etkilenmeyen bir sistem geliştirmiştir. Çalışmada, DEAP veri setindeki EEG verileri 2D görüntüye dönüştürülmüş ve zamansal bilgiyi analiz eden GRU veya LSTM ile birleştirilmiştir. Bu yöntemler %100 doğru tanıma oranına (CRR) ulaşmış, 32 elektrotla ve 5 elektrotla sırasıyla %99.17 doğruluk elde edilmiştir. CNN-GRU, CNN-LSTM'ye göre daha hızlı eğitim süresi göstermiş ve affektif durumların etkilerini minimize etmiştir. Önerilen model, geleneksel yöntemlere göre daha yüksek doğruluk sağlamıştır [37].

Maiorana, EEG tabanlı biyometrik tanıma için derin öğrenme yaklaşımlarını detaylı bir şekilde inceleyerek, bu yöntemlerin gerçek dünya senaryolarında kimlik doğrulama performansını artırma potansiyelini araştırmıştır. Çalışma, 45 katılımcıdan 5 farklı kayıt oturumu boyunca toplanan EEG verilerini kullanmış ve bu veriler, 15 aylık bir zaman dilimini kapsayan çeşitli zihinsel görevler sırasında kaydedilmiştir. Araştırmada, ham EEG verileri ve el ile çıkarılan özellikler kullanılarak, konvolüsyonel sinir ağları (CNN), tekrarlayan sinir ağları (RNN) ve bunların birleşimleriyle elde edilen yenilikçi sinir ağı mimarileri önerilmiştir. EC (eyes-closed)

protokolü altında en iyi doğrulama performansı %96 üzerinde bir doğruluk oranı ile elde edilmiştir. Modelin eğitim sürecinde kullanılan ham verilerden çıkarılan MFCC (Mel-Frekans Kepstral Katsayıları) ve otoregresif (AR) modelleme gibi özelliklerin, öğrenme sürecine önemli katkılar sağladığı belirtilmiştir. Sonuçlar, önerilen derin öğrenme tabanlı yaklaşımların, EEG sinyalleri üzerinde yüksek doğruluk oranlarına ulaştığını ve özellikle uzun süreli biyometrik tanıma senaryolarında güvenilir performans sağladığını göstermektedir [38].

Vadher ve arkadaşları, EEG tabanlı biyometrik kimlik doğrulama için askeri uygulamalara uygun, çok görevli, çok oturumlu ve çok katılımcılı bir sistem geliştirmiştir. Çalışmada, M3CV veri seti kullanılarak EEG sinyalleri mel spektrogramlarına dönüştürülmüş ve konvolüsyonel sinir ağları (CNN) modeliyle analiz edilmiştir. Bu model, çoklu oturumlar ve görevler arasında doğruluk ve güvenilirlik sağlamak üzere tasarlanmıştır. Sistem, %99.86 doğrulama doğruluğu, %98.49 eğitim doğruluğu ve %99.91 precision, recall ve F1-score değerleriyle üstün performans göstermiştir. Ayrıca, mel spektrogramlarının, diğer özellik çıkarım yöntemlerine göre daha iyi sonuçlar sağladığı belirtilmiştir. Önerilen sistem, özellikle askeri üsler ve silah depoları gibi yüksek güvenlik gerektiren ortamlar için gerçek zamanlı kimlik doğrulama sağlayarak yetkisiz erişimi önleme kapasitesine sahiptir. Çalışma, EEG tabanlı biyometrik sistemlerin güvenlik alanında geniş bir potansiyele sahip olduğunu göstermiştir [39].

Beyrouthy ve arkadaşları, EEG tabanlı biyometrik sistemlerin 5G ve IoT entegrasyonu bağlamında mevcut eğilimlerini ve gelecekteki potansiyel uygulamalarını kapsamlı bir şekilde incelemiştir. Çalışma, EEG'nin özellikle sinyallerin kararlılığı, düşük maliyeti ve eşsizliği nedeniyle IoT çözümlerinde artan rolüne odaklanmaktadır. EEG tabanlı sistemlerin güvenlik ve doğruluk açısından geleneksel biyometrik yöntemleri aştığı, özellikle dinamik bilişsel tepkileri yakalayarak daha güvenilir kimlik doğrulama sağladığı belirtilmiştir. Araştırmada, EEG tabanlı sistemlerin 5G'nin düşük gecikme süresi ve yüksek bant genişliği ile desteklenerek gerçek zamanlı beyin aktivitesinin izlenmesini mümkün kıldığı vurgulanmıştır. Ayrıca, IoT cihazlarının taşınabilir EEG sistemlerini daha hafif ve erişilebilir hâle getirdiği, uzaktan izleme ve ambulatuvar EEG çalışmaları için kullanışlılık sağladığı ifade edilmiştir. Çalışma, IoT ve 5G'nin EEG uygulamalarını, nörolojik bozuklukların izlenmesinden beyin-bilgisayar arayüzlerine kadar geniş bir yelpazede geliştirme potansiyelini ortaya koymaktadır [40].

Ömer Kasim ve Mustafa Tosun, fotik uyarı ile elde edilen EEG sinyallerine dayalı bir biyometrik kimlik doğrulama yöntemi geliştirmiştir. Çalışmada, 16 kanaldan 3 saniyelik

segmentlere ayrılmış EEG sinyallerinin 1–49 Hz arasındaki güç yoğunluğu değerleri, Kaiser Penceresi kullanılarak periodogram yöntemiyle hesaplanmıştır. Elde edilen bu güç yoğunluğu değerleri, 1D-CNN modeli ile eğitilerek sınıflandırma yapılmıştır. Sağlıklı bireyler ve dikkat eksikliği hiperaktivite bozukluğu (ADHD) olan bireylerden elde edilen fotik uyarı EEG verileri kullanılarak yapılan deneylerde, önerilen yöntemin %97.17 doğruluk oranı sağladığı tespit edilmiştir. Sağlıklı bireyler için doğruluk oranı %96.99, ADHD olan bireyler için ise %97.35 olarak ölçülmüştür. Bu sonuçlar, EEG tabanlı biyometrik sistemlerde fotik uyarı ile elde edilen verilerin yüksek doğrulukla kimlik doğrulamada kullanılabileceğini kanıtlamaktadır. Ayrıca, farklı fotik uyarı frekanslarının sinyallerin bireysel özelliklerini değiştirmediği ve sistemin güvenilirliğini artırdığı belirtilmiştir. Bu çalışma, EEG sinyalleri ile fotik uyarı kullanımının kimlik doğrulama sistemlerinde kabul edilebilirliğini artırarak, biyometrik doğrulama alanına önemli bir katkı sağlamıştır [26].

Tez çalışmamızda, EEG tabanlı biyometrik kimlik doğrulama sistemine yeni yöntemler eklenmiş ve özellikle dikkat eksikliği ve hiperaktivite bozukluğu (ADHD) olan bireyler üzerinde odaklanılmıştır. Sağlıklı bireylerle bir karşılaştırma yapılmaksızın, ADHD bireylerinin kimlik doğrulama süreçlerindeki özgün özellikleri analiz edilmiştir. Veri işleme sürecinde, Empirical Mode Decomposition (EMD), Discrete Wavelet Transform (DWT) ve Independent Component Analysis (ICA) gibi ön işleme yöntemleri uygulanmış, ardından t-SNE saçılım grafikleri ile görselleştirme yapılmıştır. Özellik çıkarımı ve sınıflandırma aşamasında 1D-CNN derin öğrenme modeli kullanılmıştır. Ayrıca, analizlerde frontal lobdan seçilmiş 7 kanal üzerinden çalışılmıştır. Frontal lobun dikkat ve bilişsel süreçlerdeki kritik rolü göz önünde bulundurulmuş ve EEG sinyallerinin bu bölgeden toplanması sayesinde kolay ve taşınabilir bir sistem tasarlanması hedeflenmiştir. Frontal bölgedeki elektrot yerleşiminin pratikliği, sinyallerin toplanmasını daha erişilebilir ve kullanıcı dostu hâle getirmiştir. Kimlik doğrulama, "*one-versus-the-others*" biyometrik modeline dayandırılarak gerçekleştirilmiş ve bireylerin seçimi MANOVA (Multivariate Analysis of Variance) yöntemi ile yapılmıştır. Tezde, güç spektrumu analizi ve beyin haritalama sonuçları detaylı bir şekilde sunulmuştur. Elde edilen bulgular, görsel uyarım tabanlı EEG sinyalleriyle, ADHD bireylerin biyometrik kimlik doğrulama süreçlerinde yüksek doğruluk ve güvenilirlik sağlanabileceğini göstermektedir. Çalışmamızın, bu kapsamda literatürde bilinen ilk örnek olma özelliği taşıdığı değerlendirilmektedir.

2. MATERYAL VE YÖNTEM

Bu çalışmada, dikkat eksikliği ve hiperaktivite bozukluğu (ADHD) olan bireylerin biyometrik tanımlama ve doğrulama süreçlerinde EEG sinyallerinin potansiyelini değerlendirmek amacıyla, derin öğrenme modelleri ve gelişmiş sinyal işleme yöntemleri kullanılarak kapsamlı bir analiz gerçekleştirilmiştir.

2.1 BİYOMETRİK TANIMA SİSTEMLERİ

Biyometrik tanıma sistemleri, bireylerin kimlik doğrulamasını sağlamak için benzersiz fizyolojik ve davranışsal özelliklerini kullanarak güvenilir ve doğrulanabilir çözümler sunmaktadır. Fizyolojik özellikler arasında parmak izi, iris, yüz geometrisi, retina ve beyin sinyalleri (EEG) gibi değişmeyen ve bireye özgü veriler öne çıkmaktadır. Davranışsal özellikler ise imza dinamiği, göz hareketleri, yürüyüş analizi ve tuş vuruş ritimleri gibi kişisel davranış kalıplarını temel almaktadır. Bu sistemler tek bir biyometrik veriye dayanan tekil biyometrik sistemler (unimodal) ya da birden fazla biyometrik özelliği bir araya getiren çoklu biyometrik sistemler (multimodal) olarak sınıflandırılır. Özellikle çoklu biyometrik sistemler, doğruluk oranlarını artırarak sahte giriş ve saldırıların üstesinden gelme konusunda üstün performans göstermektedir. Son yıllarda EEG tabanlı biyometrik sistemler, yüksek sinyal kararlılığı ve dış saldırılara karşı dayanıklılığı nedeniyle dikkat çekmektedir [26]-[31].

2.1.1 EEG Tabanlı Biyometrik Tanıma Sistemleri

EEG verileri, beynin işlevsel ve anatomik yapısındaki kişiye özgü farklılıkları yansıtarak yüksek doğruluk oranlarına ulaşabilmektedir. Örneğin, görsel uyaranlara bağlı olarak elde edilen görsel uyarılmış potansiyeller (VEP) kullanılarak yapılan çalışmalar, kısa sürede %99'un üzerinde doğru tanıma oranlarına ulaşmıştır. Bununla birlikte, geleneksel parmak izi ve iris tanıma gibi yöntemler, taşınabilir elektronik cihazlar için geliştirilmiş çok modlu sistemlerle birleştirildiğinde hem hız hem de güvenlik açısından önemli iyileştirmeler sağlamaktadır. Bu bağlamda, biyometrik sistemlerin kullanımı, kişisel kimlik doğrulamanın yanı sıra siber güvenlik, adli bilişim, finansal işlemler ve erişim kontrolü gibi geniş bir uygulama yelpazesinde yaygınlaşmakta ve teknolojik gelişmelere paralel olarak sürekli evrim geçirmektedir. Özellikle


yapay zekâ ve derin öğrenme algoritmalarının entegrasyonu, biyometrik verilerden daha doğru ve güvenilir sonuçların elde edilmesini sağlamaktadır [26]-[32].

2.1.2 ADHD ve EEG Sinyalleri

ADHD bireylere ait EEG sinyalleri üzerinden biyometrik tanıma, literatürde açık bir araştırma konusudur ve özellikle sinyal işleme ile analitik yöntemlerin doğru bir şekilde uygulanmasıyla önemli bir potansiyel taşımaktadır. Bu tezde, EEG sinyallerinden anlamlı ve ayırtıcı özelliklerin çıkarılması için klasik yöntemlerden ziyade yenilikçi analiz teknikleri araştırılmıştır. Özellikle, t-SNE (t-Distributed Stochastic Neighbor Embedding) yöntemi ile EEG verilerinin düşük boyutlu temsilleri elde edilmiş ve bu temsiller üzerinde biyometrik sınıflandırma açısından anlamlı olan saçılım desenleri incelenmiştir. Bu analiz, ADHD bireylerinin EEG sinyallerinde gözlemlenen farklılıkların görselleştirilmesi ve gruplar arasında ayrışmanın belirlenmesi açısından kritik bir adım olmuştur [26]-[32].


Bunun yanı sıra, beyin haritalama grafikleri kullanılarak farklı kanallar arasındaki aktivite paternleri detaylı bir şekilde değerlendirilmiş ve bu grafikler üzerinden bireylerin biyometrik kimliklerini belirleyebilecek özellikler araştırılmıştır. Özellikle farklı kanal çiftlerinde olasılık yoğunluk fonksiyonları analiz edilerek, biyometrik ayrımın hangi kanal çiftlerinde daha belirgin olduğu tespit edilmiştir. Bu yaklaşım, ADHD bireylerinin beyin aktivitesindeki bölgesel ve bireysel farklılıkların biyometrik tanıma performansına nasıl katkı sağladığını anlamak için önemli bir yol göstermektedir [26]-[32].

Bu bağlamda, sinyal işleme süreci içerisinde kullanılan yöntemler arasında sinyal ön-işleme yöntemleri, gruplar arası farklılık analizi ve olasılık yoğunluk fonksiyonlarının incelenmesi yer almaktadır. Farklı sinyal ön-işleme yöntemleri, ADHD bireylerde öne çıkan ve biyometrik olarak ayırt edici niteliklere sahip EEG paternleri belirlenmiş, bu paternler hem sınıflandırma modellerine entegre edilmiş hem de bireylerin farklı beyin aktivite modlarını temsil etmek için kullanılmıştır. Özellikle, t-SNE ile düşük boyutlu görselleştirme ve beyin haritaları gibi ileri analiz teknikleri, bu sinyallerin zengin biyometrik bilgi taşıdığını ve bu bilginin modern biyometrik sistemlerde etkin bir şekilde kullanılabileceğini göstermektedir. Bu tezde, bu yöntemlerin birleşimi araştırılarak ADHD bireylerin EEG sinyalleri üzerinden benzersiz ve güvenilir bir biyometrik doğrulama sisteminin temelleri incelenmiştir.



Şekil 2-1 : Beyin bölgeleri ve işlevleri

Beyin, işlevsel olarak dört ana loba ayrılır: Frontal, Parietal, Temporal ve Occipital loblardır. Frontal lob, karar verme, problem çözme, motor kontrol ve kişilik gibi yüksek bilişsel işlevlerden sorumludur (bakınız; Şekil 2 -1). Parietal lob, dokunma, basınç, sıcaklık ve ağrı gibi duysal bilgileri işler ve mekânsal farkındalık sağlar. Temporal lob, işitme, hafıza ve dil anlama görevlerini üstlenir ve bir müzik dinlerken aktif olur. Occipital lob ise görsel bilgilerin işlenmesinden sorumlu olup bir nesneye bakıldığında devreye girer. Bu lobların yanı sıra merkezi bölge, motor kontrol ve duysal entegrasyonu sağlayarak el hareketlerini planlar ve koordine eder. Tüm bu bölgeler birlikte çalışarak insanın düşünme, hareket, duyum ve hissetme gibi temel işlevlerini yerine getirmektedir [41].



Şekil 2-2 : 10-20 sisteminde EEG kanal yerleşim örneği

10-20 sistemi, EEG elektrotlarının kafa üzerine standart bir şekilde yerleştirilmesini sağlayan uluslararası bir yöntemdir (bakınız; Şekil 2-2). Bu sistemde elektrotlar, kafa yüzeyindeki belirli anatomik referans noktalarına (nasion, inion ve kulaklar) göre yerleştirilir. 10 ve 20, elektrotlar arasındaki mesafenin toplam kafa çevresinin %10'u veya %20'si kadar olmasını ifade etmektedir. Bu sistem, beynin farklı bölgelerindeki elektriksel aktiviteleri ölçmek için standart bir yapı sunmaktadır. Elektrot yerleşimi örneği:

Frontal bölge: Fp1, Fp2, F3, F4, F7, F8

Merkez bölge: C3, C4, Cz

Parietal bölge: P3, P4, Pz

Temporal bölge: T3, T4, T5, T6

Occipital bölge: O1, O2

Bu sistemin amacı, hem klinik hem de araştırma amaçlı EEG kayıtlarında standartlaşmayı sağlamaktır. Elektrotlar, beyin aktivitesinin en iyi şekilde ölçülmesini sağlayacak şekilde simetrik olarak yerleştirilir ve her bir elektrot, beynin belirli bir bölgesinden gelen sinyalleri temsil eder [42].


Tablo 2-1 : EEG frekans bantları ve genlikleri

EEG Signals	Symbol	Frequency	Amplitude
Delta	δ	<4 Hz	20- 200 μ V
Theta	θ	4-8 Hz	20- 100 μ V
Alpha	α	8-13 Hz	20- 60 μ V
Beta	β	13-30 Hz	2- 20 μ V
Gamma	γ	>30 Hz	3- 5 μ V

EEG frekans bantları, beynin farklı aktivitelerini temsil eden belirli dalga aralıklarıdır (bakınız; Tablo 2-1). Delta (0.5–4 Hz) en düşük frekanslı olup derin uyku ve yenileyici süreçlerle ilişkilidir, genelde frontal bölgelerde görülür. Theta (4–8 Hz) rahatlama, hafıza ve meditasyon gibi durumları temsil eder ve temporal ile parietal bölgelerde yoğunlaşır. Alpha (8–13 Hz) sakin zihin durumları, dinlenme ve gözler kapalı rahatlamayla ilişkilidir, genellikle occipital ve parietal bölgelerde belirgindir. Beta (13–30 Hz) uyanıklık, odaklanma ve problem çözme gibi aktif zihinsel durumlarla ilişkilendirilir, frontal ve merkezi bölgelerde görülür. Gamma (30–100 Hz) ise yüksek düzeyde bilişsel işlevler, öğrenme ve hafıza birleştirme ile bağlantılı olup beynin birçok bölgesinde senkronize aktivite gösterir. Bu bantlar, beynin farklı zihinsel ve fiziksel durumlarını anlamak için kritik öneme sahiptir [43], [44].

Bu tezde, ADHD tanılı çocuklara ait EEG verileri üzerinde çalışılmıştır. Kullanılan EEG verisi, IEEE DataPort platformunda açık erişimde sunulan "EEG data for ADHD / Control children" başlıklı veri setinden alınmıştır. Bu veri seti, 7-12 yaş arası 61 ADHD tanılı çocuk ve 60 sağlıklı kontrol çocuğundan elde edilen EEG kayıtlarını içermektedir. Ancak bu çalışmada sadece ADHD tanılı bireylere ait EEG verileri incelenmiştir. ADHD tanısı, deneyimli psikiyatristler tarafından DSM-IV kriterlerine uygun olarak konulmuş ve bu çocuklar en fazla altı ay süreyle Ritalin tedavisi görmüştür. EEG kayıtları, 10-20 uluslararası sistemi kullanılarak 19 kanaldan (Fz, Cz, Pz, C3, T3, C4, T4, Fp1, Fp2, F3, F4, F7, F8, P3, P4, T5, T6, O1, O2) gerçekleştirilmiştir ve örnekleme frekansı 128 Hz olarak belirlenmiştir. Referans elektrotlar, A1 ve A2 olmak üzere her iki kulak memesine yerleştirilmiştir.

Kayıt protokolü, ADHD’li çocuklarda yaygın olan görsel dikkat eksikliklerini incelemek amacıyla görsel dikkat görevlerini içermektedir. Katılımcılara, üzerinde 5 ila 16 arasında değişen sayıda çizgi film karakteri bulunan görseller gösterilmiş ve bu karakterlerin sayılması istenmiştir. Görseller, çocukların cevaplarına bağlı olarak kesintisiz bir şekilde sunulmuş ve kayıt süresi, her çocuğun tepki hızına göre değişiklik göstermiştir. Bu tez kapsamında, veri setindeki ADHD grubundan 7 katılımcı, MANOVA yöntemi kullanılarak seçilmiştir. MANOVA analizi, kanallar arası varyasyonları değerlendirerek biyometrik tanımda ayrıştırıcı özelliklere sahip katılımcıları belirlemek için kullanılmıştır. Seçilen katılımcılara ait EEG verileri üzerinde analizler gerçekleştirilmiş ve biyometrik tanıma modellerinin oluşturulmasında bu verilerden faydalanılmıştır. Kullanılan veri seti ve analiz süreci, bu tezin metodolojik bütünlüğünü güçlendirmiş ve ADHD bireylerde biyometrik tanıma alanında önemli bulguların elde edilmesine katkı sağlamıştır [25]. Frontal lobdan elde edilen verilerin kullanılması, bu lobun dikkat ve bilişsel süreçlerdeki kritik rolü nedeniyle hem pratik hem de bilimsel anlamda önemli bir tercih olmuştur. Çalışmada, frontal lob bölgesindeki toplamda 7 elektrot seçilmiş ve bu elektrotlardan elde edilen sinyaller analiz edilmiştir.



Şekil 2-3 : MANOVA ve ADHD bireylerin EEG sinyalleri üzerinden ayrıştırılması

Bu şekil, tez çalışmasında kullanılan EEG verilerindeki ADHD bireylerin MANOVA analizi sonuçlarını görselleştiren bir dendrogram grafiğidir (bakınız; Şekil 2-3). MANOVA, kanallar arası varyasyonları değerlendirerek ADHD grubu içerisinde anlamlı farklılık gösteren EEG kanallarını ve katılımcıları belirlemek için kullanılmıştır. Grafik, benzer özelliklere sahip katılımcıların kümelenmesini sağlar. Dendrogramda yatay eksen katılımcılar ya da kanallar

yer alırken, dikey eksen, kümeler arasındaki uzaklığı veya benzerlik seviyesini temsil etmektedir. Burada görüldüğü gibi, bazı katılımcılar ya da EEG kanalları düşük benzerlik seviyelerinde birleşirken, grafiğin sağ tarafına doğru kümeler daha büyük ve daha az benzerliğe sahip gruplar olarak ayrılmaktadır. Bu durum, ADHD bireylerinin EEG verilerinde bazı kanalların biyometrik tanımlamada daha belirgin ayrıştırıcı özellikler taşıdığını göstermektedir. Bu analiz sonucunda seçilen 7 kişi ve ilgili kanallar, biyometrik tanıma modellerinde kullanılmak üzere belirlenmiştir. MANOVA analizinin sağladığı bu görsel bilgi, özellikle ADHD grubundaki bireysel farklılıkların EEG kayıtları üzerinden başarılı bir şekilde ayrıştırılabildiğini kanıtlamaktadır [20].

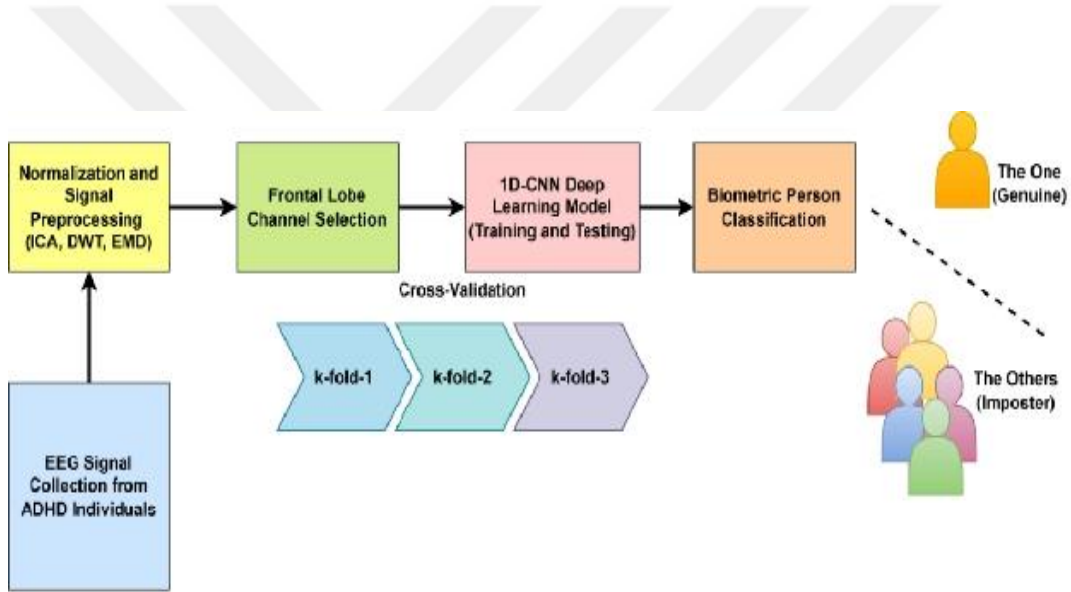
2.1.3 Derin Öğrenme ve Performans Metrikleri

Derin öğrenme, elektroensefalogram (EEG) sinyalleri üzerinde analiz yapmak için güçlü bir araç olarak ortaya çıkmıştır. EEG sinyalleri, beyin-bilgisayar arayüzleri, nörolojik çalışmalar ve biyometrik sistemlerde yaygın olarak kullanılmakta olup özellik çıkarımı, sınıflandırma ve yorumlama açısından gelişmiş yöntemler gerektiren, durağan olmayan, düşük genlikli ve çok kanallı sinyallerdir. Geleneksel sinyal işleme teknikleri genellikle zaman veya frekans alanında el ile çıkarılan özelliklere dayanırken, derin öğrenme bu süreci otomatikleştirerek ham EEG verilerinden doğrudan ayrıştırıcı temsilleri öğrenir. Evrişimli Sinir Ağları (CNN) ve Tekrarlayan Sinir Ağları (RNN) gibi derin öğrenme modelleri, EEG sinyallerinden mekansal, zamansal ve spektral özellikleri çıkarmak için yaygın olarak kullanılır. Örneğin, CNN'ler EEG kanalları arasındaki mekansal desenleri öğrenirken, özellikle Uzun Kısa Süreli Bellek (LSTM) ağları gibi RNN'ler EEG sinyallerinin zamansal bağımlılıklarını modellemede etkilidir. 1D-CNN mimarileri, ham EEG verilerini işlemek için sıklıkla tercih edilir, çünkü zamansal bilgiyi korurken hesaplama maliyetini de azaltır [20], [44] - [46].

Derin öğrenme modelleri uygulanmadan önce EEG sinyalleri genellikle ön işleme adımlarından geçirilir. Bu adımlar, sinyal kalitesini artırmak için göz kırpması ve kas gürültüsü gibi artefaktların Bağımsız Bileşen Analizi (ICA) veya Ampirik Mod Ayrıştırma (EMD) yöntemleriyle giderilmesini ve belirli frekans bantlarının (delta, theta, alfa, beta ve gamma) filtrelenmesini içerir. Ön işleme, giriş verilerinin gürültüsüz ve derin öğrenme modelleri için uygun hale getirilmesini sağlar. Derin öğrenme modelleri, EEG tabanlı sınıflandırma görevlerinde yaygın olarak kullanılmaktadır. Bu uygulamalar arasında zihinsel durumların tespiti, nörolojik bozuklukların (örneğin ADHD, epilepsi) teşhisi ve biyometrik kimlik doğrulama yer

alır. Örneğin, EEG tabanlı biyometri çalışmaları, bireyler arasındaki benzersiz beyin dalgası desenlerini kullanarak yüksek doğruluk ve dayanıklılık sunar [20], [26], [44] - [46].

Bu tez çalışmasında, 1D-CNN modeli ve ön işleme yöntemleri olarak Bağımsız Bileşen Analizi (ICA), Ayırık Dalgacık Dönüşümü (DWT) ve Ampirik Mod Ayırıştırma (EMD) kullanılmıştır. Çalışmada, ADHD tanılı bireylerin EEG verileri üzerinden biyometrik tanıma performansları detaylı bir şekilde araştırılmıştır. Bu yöntemlerin kombinasyonu, sinyaldeki gürültü ve artefaktların azaltılmasını sağlarken, 1D-CNN modeli, ayırıştırıcı özellikleri öğrenerek yüksek doğrulukla bireysel tanıma gerçekleştirmiştir. Elde edilen sonuçlar, ADHD bireylerde EEG tabanlı biyometrik tanıma sistemlerinin etkinliğini ortaya koymaktadır. ADHD bireyler için EEG sinyalleri üzerinden biyometrik tanıma sinyal işleme adımları Şekil 2-4’de gösterilmiştir.



Şekil 2-4 : ADHD bireyler için EEG sinyalleri üzerinden biyometrik tanıma sinyal işleme adımları

Bu çalışmada, EEG sinyalleri kullanılarak ADHD bireylerin biyometrik tanıma performansını değerlendirmek amacıyla bir sinyal işleme süreci gerçekleştirilmiştir. İlk adımda, EEG sinyalleri ADHD bireylerden toplanmış ve bu veriler ICA, DWT ve EMD yöntemleri kullanılarak normalizasyon ve ön işleme aşamasından geçirilmiştir. Ardından, dikkat ve bilişsel işlevlerle ilişkili olduğu için frontal lob kanalları seçilmiştir. Ön işlenmiş sinyaller, özelliklerin öğrenilmesi için 1D-CNN (Tek Boyutlu Evrişimli Sinir Ağı) derin öğrenme modeline aktarılmış, model eğitilmiş ve test edilmiştir. Sınıflandırma sonucunda bireyler, "Genuine" (Gerçek Kişi) ve "Imposter" (Sahte Kişi) olarak ayrılmış, k-fold çapraz doğrulama yöntemi ile sistemin performansı değerlendirilmiştir. Bu süreçte uygulanan yöntemler, biyometrik tanıma sisteminin doğruluğunu ve güvenilirliğini artırmaktadır [20], [46].

		Predicted	
		Positive	Negative
Actual	Positive	True Positive (TP)	False Negative (FN)
	Negative	False Positive (FP)	True Negative (TN)

Şekil 2-5 : Karmaşıklık matrisi gösterimi


Karmaşıklık matrisi (Confusion matrix) üzerinden sınıflandırma performansını değerlendiren temel metrikler; doğruluk (ACC), duyarlılık (SENS) ve özgüllük (SPEC) olarak tanımlanır (bakınız; Şekil 2-5). Doğruluk (ACC), sınıflandırıcının doğru tahminlerinin toplam tahmin sayısına oranı olup $(TP + TN) / (TP + TN + FP + FN)$ formülü ile hesaplanır. Duyarlılık (SENS), pozitif sınıfların doğru tahmin edilme oranını ifade eder ve $TP / (TP + FN)$ formülü ile bulunur. Özgüllük (SPEC) ise negatif sınıfların doğru tahmin edilme oranını gösterir ve $TN / (TN + FP)$ formülü kullanılarak hesaplanır. AUC (Eğri Altındaki Alan), sınıflandırıcının pozitif ve negatif sınıfları ayırt etme yeteneğini ölçer ve ROC (Receiver Operating Characteristic) eğrisi altındaki alanı temsil eder. AUC değeri 0.5 ile 1.0 arasında değişir; 1.0 değeri mükemmel bir ayırım performansını, 0.5 değeri ise rastgele tahmini ifade eder. Bu metrikler; doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) değerleri üzerinden elde edilir ve sınıflandırma performansını bütüncül olarak değerlendirmek için kritik bir rol oynar [20], [46].

2.1.3.1 1D-CNN Derin Öğrenme Modeli

Evrişimli sinir ağları (Convolutional Neural Networks), 1989 yılında LeCun ve çalışma arkadaşları tarafından gradyan tabanlı bir yaklaşımla tanıtılmış olup ileri beslemeli bir yapay sinir ağı ve derin öğrenme mimarisidir. Evrişimli sinir ağları temel olarak bir giriş katmanı, bir çıkış katmanı ve bu katmanlar arasında yer alan birden fazla gizli katmandan oluşur [26], [48]-[52].

Tipik bir evrişimli sinir ağında (Convolutional Neural Network - CNN), gizli katman üç tür katmandan oluşur: evrişim, havuzlama ve tam bağlantılı (fully connected) katmanlar. Evrişim katmanı, evrişimli sinir ağının ilk katmanı ve temel yapı taşıdır. Hesaplamaların büyük bir kısmı bu katmanda gerçekleşir. Bazı modellerde evrişim katmanlarını havuzlama katmanı takip ederken, diğer modellerde ek evrişim katmanları bu katmanların ardından gelir. Havuzlama katmanı, evrişim özelliklerinin uzamsal boyutunu azaltmaktan sorumludur ve boyutların azaltılmasıyla birlikte, veri işlemek için gereken hesaplama gücünü de düşürür. Havuzlama katmanı, ortalama havuzlama (average pooling) ve maksimum havuzlama (max pooling) olmak üzere iki tür havuzlama işlemi gerçekleştirir. Boyut küçültmenin yanı sıra, havuzlama katmanı aynı zamanda gürültü bastırma işlevi de görür. Tam bağlantılı katman, evrişimli sinir ağının son katmanıdır. Her bir katmanla birlikte CNN'nin karmaşıklığı artar ve görüntünün daha büyük kısımları tanımlanır. Çok katmanlı ileri beslemeli bir yapıya sahip olan evrişimli sinir ağlarında, her katman bir sonraki katmanın giriş katmanı olarak işlev görür [26], [48]-[52].

Evrişimli sinir ağları (Convolutional Neural Networks - CNN), görüntü, video, ses, imge ve metin işleme gibi uygulamalarda artan kullanımının yanı sıra, sınıflandırma ve biyometrik kimlik doğrulama gibi diğer alanlarda da son yıllarda popülerlik kazanmıştır. 1D-CNN, verilerdeki basit desenleri tanımlamak ve bu basit desenleri kullanarak daha yüksek seviyeli katmanlar oluşturmak konusunda oldukça başarılıdır. Ayrıca, 1D-CNN, genel veri kümesinin kısa bölümlerinden ilgi çekici özellikler elde edebilir [26], [48]-[52]. 1D-CNN'nin şematik gösterimi, Şekil 2-6'te sunulmaktadır.



Şekil 2-6 : 1D-CNN şematik gösterimi

Bu çalışmada, biyometrik tanıma için kullanılan 1D-CNN (1D Convolutional Neural Network) mimarisi, zaman serisi verilerinin analizi ve sınıflandırılması amacıyla tasarlanmıştır. Modelin giriş katmanında, giriş özellik sayısını temsil eden bir "sequenceInputLayer" kullanılmıştır. Özellik çıkarımı için iki adet "convolution1dLayer" katmanı eklenmiştir. İlk konvolüsyon katmanında, filtre boyutu 5 ve filtre sayısı 50 olarak belirlenmiştir. Daha fazla özellik çıkarımı sağlamak amacıyla eklenen ikinci konvolüsyon katmanında, filtre sayısı iki katına çıkarılmıştır. Her iki konvolüsyon katmanında da veri kaybını önlemek için "causal" padding kullanılmıştır. Konvolüsyon katmanlarından sonra, doğrusal olmayan aktivasyon işlevi için "reluLayer" kullanılmıştır. Daha sonra, modelin öğrenme sürecini hızlandırmak ve çıktıların normalize edilmesini sağlamak amacıyla "layerNormalizationLayer" eklenmiştir. Özelliklerin boyutunu azaltmak ve bilgiyi özetlemek için "globalAveragePooling1dLayer" katmanı yer almıştır. Tam bağlantılı katmanda, sınıflandırma için iki sınıfı temsil eden "fullyConnectedLayer" kullanılmıştır. Bu katmanın ardından, sınıflandırma işlemini tamamlamak için "softmaxLayer" ve "classificationLayer" eklenmiştir. Modelin eğitim parametreleri arasında mini batch boyutu %100 ve toplam epoch sayısı 250 olarak belirlenmiştir. Bu yapı sayesinde modelin zaman serisi verilerinde yüksek performans göstermesi amaçlanmıştır.

2.1.4 Sinyal İşleme Yöntemleri

EEG ve biyolojik zaman serilerinde sinyal işleme, ham sinyalde bulunan gürültülerin azaltılması, anlamlı özelliklerin çıkarılması ve sınıflandırma performansını artırmak için kullanılan bir dizi teknikten oluşur. Bu yöntemler, sinyalin farklı bileşenlerini analiz ederek, zaman, frekans ve uzay boyutlarında derinlemesine bilgi sağlar. Son yıllarda, EEG ve biyolojik zaman serilerinde derin öğrenme modelleri kullanılmaya başlanmıştır. Özellikle 1D-CNN gibi modeller, ham sinyalden anlamlı özellikleri otomatik olarak öğrenebilir. Bu yöntemler, özellik çıkarma ve sınıflandırma süreçlerini birleştirerek uçtan uca öğrenme imkanı sunar. Bu yöntemler, EEG ve biyolojik zaman serileri üzerindeki analizlerde gürültü azaltma, özellik çıkarma ve sınıflandırma performansını artırmak için geniş bir uygulama alanı bulur. Tez çalışmasında, bu yöntemlerin uyarlanması, verilerden maksimum bilgi elde edilmesine olanak tanımaktadır [26], [48]-[52].

2.1.4.1 Ampirik Mod Ayırıştırması (EMD)

Ampirik Mod Ayırıştırma (Empirical Mode Decomposition - EMD) algoritması, doğrusal olmayan ve durağan olmayan sinyalleri, Amplitüd Modülasyonu ve Frekans Modülasyonu bileşenlerinden oluşan İçsel Mod Fonksiyonları (Intrinsic Mode Functions - IMFs) adı verilen bir dizi bileşene ayırmak için kullanılan adaptif ve veri bağımlı bir tekniktir. Bu ayırıştırma analizi yöntemi, içsel modların anlık frekansını ifade eden güçlü bir zaman-frekans analizi tekniğidir. IMFs, zamanla değişen frekans değerlerini elde etmek için anlamlı ve anlık frekans bilgilerini içerir ve diğer yöntemlere göre daha iyi zaman çözünürlüğü sunar. Bu özellikleri sayesinde EMD, EEG sinyallerinin analizi ve işlenmesinde önemli bir araç olarak kullanılmaktadır [47].

2.1.4.2 Bağımsız Bileşen Analizi (ICA)

Bağımsız Bileşen Analizi (ICA), karışık sinyalleri istatistiksel olarak bağımsız bileşenlere ayırmak için kullanılan güçlü bir istatistiksel yöntemdir. EEG sinyallerinin işlenmesinde, karışık EEG kanallarını mekânsal olarak sabit ve zamansal olarak bağımsız bileşenlere ayırıştırır. ICA, her yineleme döngüsünde karışım matrisini belirleyerek bu matrisi ters çevirir ve kaynak bileşenleri elde eder. Böylece, beyin aktiviteleri ile kas hareketleri veya kalp atımı gibi artefaktlar ayrıştırılabilir. Mekânsal ve zamansal bağımsızlık özellikleri sayesinde, ICA, göz kırpması gibi belirgin artefaktların yanı sıra nöral sinyalleri de başarıyla izole edebilir. EEG

verilerinin lineer karışım olduğu varsayımına dayanan bu yöntem, gürültü ve artefaktlardan arındırılmış anlamlı verilerin elde edilmesine olanak tanır [20], [47].

2.1.4.3 Ayırık Dalga Dönüşümü (DWT)

Ayrık Dalga Dönüşümü (DWT), durağan olmayan EEG sinyallerini farklı frekans bantlarına ayırarak analiz etmek için güçlü bir araçtır. Zaman-frekans çözünürlüğündeki daha iyi ayarlanabilir denge nedeniyle, dalga dönüşümü Fourier dönüşümüne kıyasla daha üstün zaman-frekans özelliklerine sahiptir. Dalga dönüşümü, bir pencere fonksiyonu gibi davranan küçük bir dalga olarak tanımlanır. DWT, ana dalganın (mother wavelet) genişliğini değiştirerek yüksek ve düşük frekans bileşenlerini iyi bir çözünürlükle ayrıştırabilir. Ana dalganın sıkıştırılmış (veya genişletilmiş) ve kaydırılmış versiyonları, sırasıyla ölçekleme ve kaydırma parametreleri olan a ve b değiştirilerek elde edilir. Hedeflenen alfa frekans bandının 8–30 Hz aralığında olduğu bildirilmektedir. Bu frekans bandı, alfa (8–13 Hz) ve beta (14–30 Hz) dalgalarını içermektedir. Bu çalışmada, kaydedilen veriler üzerinde belirli frekansları (0–13 Hz) çıkarmak için, 128 Hz örnekleme frekansı ile 4. seviyede db5 (Daubechies) türü dalga kullanılarak ayırık dalga dönüşümü (DWT) uygulanmıştır [20].

2.1.4.4 t-SNE Ayrışım ve Saçılım Tekniği

t-SNE (t-Distributed Stochastic Neighbor Embedding), yüksek boyutlu verilerin iki veya üç boyutlu alanlara indirgenmesi için kullanılan etkili bir boyut azaltma ve görselleştirme tekniğidir. Bu yöntem, özellikle karmaşık veri kümelerinin içsel yapısını ortaya çıkarmak ve görselleştirmek için kullanılır. t-SNE, yüksek boyutlu uzaylarda yakın olan veri noktalarını düşük boyutlu alanlarda da yakın olacak şekilde eşleyerek yerel ve global yapıların korunmasını sağlar. EEG, genomik veri analizi, biyometrik sistemler gibi birçok alanda kullanılan bu teknik, özellikle verilerin kümelenmesini ve sınıflar arasındaki ayrımı görselleştirmede başarılıdır. Ancak, hesaplama karmaşıklığı ve parametre hassasiyeti gibi zorluklar içermektedir. Buna rağmen, t-SNE'nin etkili görselleştirme yetenekleri, veri analizi ve keşif süreçlerinde sıkça tercih edilmesini sağlamaktadır [20], [47], [53].

3. BULGULAR

Bu çalışmada, ADHD bireylerin EEG sinyallerine dayalı biyometrik kimlik doğrulama potansiyelini araştırmak amacıyla derin öğrenme ve sinyal işleme yöntemleri kullanılarak kapsamlı bir analiz gerçekleştirilmiştir. EEG sinyallerinden elde edilen özelliklerin hem doğruluk oranı hem de sınıflandırma başarısı açısından etkili olduğu görülmüştür. Kullanılan sinyal işleme ve modelleme yöntemleri, ADHD bireylerin özgün beyin aktivitelerinin güvenilir bir şekilde tanımlanmasını sağlamış ve bu bireylerin biyometrik sistemlerde ayırt edici özelliklerini başarılı bir şekilde ortaya koymuştur.

Tablo 3-1 : Ham EEG sinyallerine göre ADHD bireylerde *one-versus-the others* biyometrik tanıma sonuçları

SB_1				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	99.53	99.53	99.06	99.37
SENS	100	100	100	100
SPEC	99.50	99.50	99.00	99.33
AUC	0.996	0.996	0.997	0.996
SB_2				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	99.53	98.12	100	99.21
SENS	100	76.92	100	92.30
SPEC	99.50	99.50	100	99.66
AUC	0.997	0.991	1	0.996
SB_3				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	96.24	96.72	97.65	96.87
SENS	61.53	57.14	69.23	62.63
SPEC	98.50	99.50	99.50	99.16
AUC	0.986	0.990	0.981	0.985
SB_4				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA

ACC	98.59	99.53	98.12	98.74
SENS	76.92	92.85	76.92	82.23
SPEC	100	100	99.50	99.83
AUC	0.993	1	0.996	0.996
SB_5				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	100	97.19	98.59	98.59
SENS	100	78.57	92.30	92.38
SPEC	100	98.50	99.00	99.16
AUC	1	0.986	0.993	0.993
SB_6				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	100	100	100	100
SENS	100	99.53	100	99.84
SPEC	100	92.85	100	97.61
AUC	1	0.960	1	0.986
SB_7				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	99.53	99.53	100	99.68
SENS	92.30	92.85	100	95.05
SPEC	100	100	100	100
AUC	1	0.993	1	0.997

Tablo 3-1, ADHD bireylerde EEG tabanlı biyometrik doğrulama için 1D-CNN derin öğrenme modelinin performans sonuçlarını gösterilmektedir. Genel olarak, modellerin Accuracy (Doğruluk) ve Specificity (Özgüllük) değerlerinin çok yüksek olduğu ve doğru ve spesifik sonuçlar verdiği görülüyor. Örneğin, Katılımcı_1'in ortalama doğruluğu %99.37 ve özgüllüğü %99.33 iken, Katılımcı_6'nın ortalama doğruluğu %100 ve özgüllüğü ise %97.61'dir. Sensitivity (Duyarlılık) metriklerinde ise bazı modellerde düşük değerler bulunuyor. Örneğin, Katılımcı_3'ün ortalama duyarlılığı %62.63 gibi düşük bir değere sahip, bu da ADHD bireylerinin tanımlanmasında yetersizlik olabileceğini gösteriyor. Diğer yandan, Katılımcı_7'nin duyarlılık ortalaması %95.05 ile daha yüksektir. AUC (Eğri Altındaki Alan) değerleri genellikle %98-100 arasında seyrediyor. Katılımcı_2 ve Katılımcı_4'ün AUC değerleri

ortalama %99.6 ile oldukça yüksektir. Sonuç olarak, 1D-CNN derin öğrenme modeli, ham EEG sinyalleri üzerinden ADHD bireylerin tanımlanmasında etkili, ancak bazı modellerdeki duyarlılık oranları açısından iyileştirmeler gerekebilir.

Katılımcı_1 için tüm K-Fold'larda duyarlılık (SENS) %100 ve eğri altındaki alan (AUC) %99.6-99.7 arasında değişerek çok yüksek performans göstermiştir, doğruluk (ACC) %99.37 ve özgüllük (SPEC) %99.33 gibi yüksek ve dengeli değerlerde seyretmiştir. Katılımcı_2'de duyarlılık (SENS) K-Fold 2'de %76.92 iken diğer katlarda %100 olması ortalama %92.30'a ulaşmıştır; doğruluk ve özgüllük değerleri %99.21 ve %99.66 ile oldukça yüksektir. Katılımcı_3 için genel olarak duyarlılık %62.63 ile düşük kalmış, bu da ADHD bireylerin tanımlanmasında yetersizlik olabileceğini gösterirken, doğruluk ve özgüllük değerleri %96.87 ve %99.16 ile yüksek seviyededir. Katılımcı_4'te, duyarlılık %82.23 ile kabul edilebilir düzeyde olup doğruluk %98.74, özgüllük %100 ve AUC %99.6 ile oldukça yüksektir. Ayrıca, Katılımcı_5'te doğruluk %98.59, duyarlılık %92.38, özgüllük %99.16 ve AUC %99.3 ile yüksek performans görülmektedir. Katılımcı_6, %99.84 duyarlılık ve %97.61 özgüllük ile birlikte %100 doğruluk oranı ve %98.6 AUC ile dikkat çekici sonuçlar sergilemiştir. Son olarak, Katılımcı_7 %99.68 doğruluk, %95.05 duyarlılık, %100 özgüllük ve %99.7 AUC ortalamalarıyla genel olarak yüksek performans göstermiştir.

Tablo 3-2 : Ham EEG sinyallerine EMD uygulanmış ADHD bireylerde *one-versus-the others* biyometrik tanıma sonuçları

SB_1				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	94.83	93.89	93.92	94.21
SENS	23.07	30.76	21.42	25.08
SPEC	99.50	98.00	99.00	98.83
AUC	0.856	0.810	0.903	0.856
SB_2				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	95.30	93.92	92.01	93.74
SENS	30.76	14.28	38.46	27.83
SPEC	99.50	99.50	95.50	98.16
AUC	0.743	0.721	0.893	0.785

SB_3				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	93.45	91.07	92.48	92.33
SENS	14.28	23.07	7.69	15.01
SPEC	99.00	95.50	98.00	97.5
AUC	0.778	0.692	0.730	0.733
SB_4				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	94.39	92.95	93.42	93.58
SENS	35.71	15.38	23.07	24.72
SPEC	98.50	98.00	98.00	98.16
AUC	0.816	0.754	0.728	0.766
SB_5				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	92.99	91.07	91.54	91.86
SENS	35.71	15.38	15.38	22.15
SPEC	97.00	96.00	96.50	96.5
AUC	0.800	0.736	0.822	0.786
SB_6				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	95.32	94.36	94.85	94.84
SENS	71.42	38.46	42.85	50.91
SPEC	97.00	98.00	98.00	97.66
AUC	0.968	0.898	0.934	0.933
SB_7				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	100	97.18	100	99.06
SENS	100	61.53	100	87.17
SPEC	100	99.50	100	99.83
AUC	1	0.988	1	0.996

Tablo 3-2, ADHD bireyler üzerinde EEG tabanlı biyometrik doğrulama için EMD sinyal işleme tekniği uygulanarak elde edilen sonuçları göstermektedir. Ortalama değerlere göre yorumlamak gerekirse, doğruluk (ACC) oranları genel olarak yüksektir ve en yüksek %99.06 ile Katılımcı_7'de, en düşük %91.86 ile Katılımcı_5'te gözlenmiştir. Duyarlılık (SENS) oranları ise bazı katılımcılar için oldukça düşük seviyelerde (örneğin, Katılımcı_3 için %15.01) kalmakla beraber, bazı katılımcılar için oldukça yüksektir (örneğin, Katılımcı_7 için %87.17). Bu, modelin bazı bireylerde ADHD semptomlarını doğru şekilde ayırt edebilme yeteneğinde eksiklikler olabileceğini göstermektedir. Özgüllük (SPEC) değerleri tüm katılımcılarda çok yüksek olup %96.5 ile %99.83 arasında değişmektedir, bu da modelin ADHD olmayan bireyleri doğru şekilde tanımlamada çok başarılı olduğunu göstermektedir. AUC değerleri genellikle yüksek seviyededir; en yüksek AUC %99.6 ile Katılımcı_7'de, en düşük AUC ise %73.3 ile Katılımcı_3'te gözlenmiştir. Bu değerler, modelin genel performansının büyük oranda tatmin edici olduğunu ancak bazı bireyler için iyileştirmeler yapılması gerektiğini göstermektedir. Genel olarak, EMD uygulanan 1D-CNN derin öğrenme modeli doğruluk ve özgüllük açısından yüksek performans sergilemekte, ancak duyarlılık oranlarında bazı katılımcılar için iyileştirmeler gerekmektedir. Bu durum, modelin bazı ADHD bireylerde daha titiz ve hassas bir şekilde çalışması gerektiğini ortaya koymaktadır.

Tablo 3-2, ADHD bireyler üzerinde EEG tabanlı biyometrik doğrulama için EMD sinyal işleme tekniği uygulanarak elde edilen sonuçları göstermektedir. EMD, karmaşık zaman serilerini daha basit bileşenlere ayırarak analiz eden ve non-linear ile non-stationary sinyallerin (doğrusal olmayan ve durağan olmayan) içindeki farklı frekans bileşenlerini belirlemekte kullanılan bir tekniktir. Bu yöntem ham EEG sinyallerindeki gürültüleri azaltarak ve önemli özellikleri daha net çıkararak sinyalleri daha anlaşılır hale getirir. Tablo 3-1'deki ham EEG sinyallerinden elde edilen sonuçlara bakıldığında, doğruluk ve özgüllük değerlerinin yüksek olduğu, ancak bazı katılımcılarda duyarlılık oranlarının düşük olduğu görülmektedir. EMD uygulanmış sinyallerin kullanıldığı Tablo 3-2'deki sonuçlara bakıldığında ise, modelin performansında bazı iyileşmeler gözlenmiştir. Özellikle, Katılımcı_7'nin duyarlılık oranı %87.17 gibi yüksek bir değere ulaşırken, diğer bazı katılımcılarda düşük duyarlılık oranları devam etmiştir. Genel olarak, doğruluk ve özgüllük değerleri yüksek kalmaya devam etmiştir. Bu sonuçlar, EMD'nin ham EEG sinyallerini daha temiz ve analiz edilebilir hale getirerek biyometrik doğrulama süreçlerinde önemli iyileştirmeler sağladığını göstermektedir. Dolayısıyla, EMD yöntemi yalnızca sinyalin doğrusal olmayan ve durağan olmayan doğasını düzenlemekle kalmamış, aynı zamanda belirli katılımcılarda model performansını artırmıştır.

Tablo 3-3 : Ham EEG sinyallerine EMD+ICA uygulanmış ADHD bireylerde *one-versus-the others* biyometrik tanıma sonuçları

SB_1				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	100	100	100	100
SENS	100	100	100	100
SPEC	100	100	100	100
AUC	1	1	1	1
SB_2				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	95.30	93.92	92.01	93.74
SENS	30.76	14.28	38.46	27.83
SPEC	99.50	99.50	95.50	98.16
AUC	0.743	0.721	0.893	0.785
SB_3				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	93.42	92.48	88.78	91.56
SENS	30.76	15.38	0	15.38
SPEC	97.50	97.50	95.00	96.66
AUC	0.754	0.893	0.724	0.790
SB_4				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	91.07	91.54	92.05	91.55
SENS	15.38	15.38	14.28	15.01
SPEC	96.00	96.50	97.50	96.66
AUC	0.870	0.740	0.692	0.767
SB_5				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	91.54	94.83	92.52	92.96
SENS	7.69	46.15	28.57	27.47
SPEC	97.00	98.00	97.00	97.33
AUC	0.836	0.804	0.787	0.606

SB_6				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	94.39	98.12	93.42	95.31
SENS	42.85	69.23	38.46	50.18
SPEC	98.00	100	97.00	98.33
AUC	0.930	0.943	0.868	0.913
SB_7				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	98.59	99.06	99.53	99.06
SENS	84.61	92.30	92.85	89.92
SPEC	99.50	99.50	100	99.66
AUC	0.994	0.999	1	0.997

Çeşitli katılımcılar (Katılımcı_1'den Katılımcı_7'ye) üzerinde gerçekleştirilen sınıflandırma performansı değerlendirildiğinde (bakınız Tablo 3-3), ADHD bireylerine ait EEG sinyalleri üzerinde EMD ve ICA kullanılarak yapılan ön işleme adımlarının sonuçları üzerinde önemli bir değişkenlik gözlenmektedir. Bu EEG verileri, biyometrik bir yaklaşım olarak "*one-versus-the-others*" yöntemi ile 1D-CNN kullanılarak sınıflandırılmıştır. Tablodaki sonuçlara göre, Katılımcı_1 ve Katılımcı_7 gibi katılımcılarda model, neredeyse mükemmel doğruluk ve AUC değerlerine ulaşarak yüksek bir sınıflandırma başarısı sergilemiştir. Özellikle Katılımcı_1 için doğruluk ve AUC değerleri %100 ve 1 olarak hesaplanmış, bu da modelin bu katılımcı için tüm pozitif ve negatif vakaları hatasız bir şekilde sınıflandırabildiğini göstermektedir.

Ancak, Katılımcı_2, Katılımcı_3 ve Katılımcı_4 gibi katılımcılarda duyarlılık değerlerinin oldukça düşük olması (ortalama %15-28 aralığında), modelin bu katılımcılar için pozitif vakaları doğru şekilde tespit etmekte zorlandığını göstermektedir. Buna karşılık, özgüllük değerleri tüm katılımcılar için %95'in üzerinde kalarak tutarlı ve yüksek bir performans sergilemiş, bu da modelin negatif vakaları doğru bir şekilde tanımlamada oldukça başarılı olduğunu ortaya koymaktadır. Örneğin, Katılımcı_2'nin özgüllük değeri ortalama %98.16 olarak ölçülmüştür. Genel olarak değerlendirildiğinde, EMD ve ICA gibi ön işleme yöntemleri kullanılarak elde edilen EEG verileriyle model, bazı katılımcılarda (özellikle Katılımcı_1 ve Katılımcı_7) yüksek performans gösterirken, diğer katılımcılarda (Katılımcı_2, Katılımcı_3 ve

Katılımcı_4) duyarlılık oranının düşük olması, modelin genelleme yeteneğinin artırılması gerektiğine işaret etmektedir. Bu nedenle, modelin tüm katılımcılar için daha dengeli bir performans sergilemesi için daha etkin özellik çıkarma veya ön işleme tekniklerinin uygulanmasının gerekliliği öne çıkmaktadır.

Tablo 3-4 : Ham EEG sinyallerine DWT uygulanmış ADHD bireylerde *one-versus-the others* biyometrik tanıma sonuçları

SB_1				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	96.24	94.39	92.48	94.37
SENS	69.23	28.57	30.76	42.85
SPEC	98.00	99.00	96.50	97.83
AUC	0.980	0.955	0.914	0.949
SB_2				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	95.32	93.42	94.83	94.52
SENS	42.85	46.15	46.15	45.05
SPEC	99.00	96.50	98.00	97.83
AUC	0.899	0.947	0.944	0.930
SB_3				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	92.95	95.32	95.77	94.68
SENS	7.69	35.71	38.46	27.28
SPEC	98.50	99.50	99.50	99.16
AUC	0.867	0.906	0.860	0.877
SB_4				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	92.95	93.42	93.92	93.43
SENS	23.07	46.15	21.42	30.21
SPEC	97.50	96.50	99.00	97.66
AUC	0.855	0.923	0.865	0.881
SB_5				

%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	96.71	95.30	95.77	95.92
SENS	61.53	53.84	38.46	51.27
SPEC	99.00	98.00	99.50	98.83
AUC	0.964	0.925	0.963	0.950
SB_6				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	96.71	93.42	96.72	95.61
SENS	61.53	46.15	50.00	52.56
SPEC	99.00	96.50	100	98.5
AUC	0.960	0.956	0.897	0.937
SB_7				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	96.72	95.30	94.36	95.46
SENS	71.42	30.76	30.76	44.31
SPEC	98.50	99.50	98.50	98.83
AUC	0.980	0.908	0.959	0.949

Önceki Tablo 3-3 ile yeni Tablo 3-4 arasındaki sonuçlar incelendiğinde, DWT kullanılarak ön işleme yapılmış verilerde (Tablo 3-4), EMD ve ICA içermeyen sonuçların özellikle duyarlılık açısından belirgin farklılıklar sergilediği görülmektedir. Tablo 3-3'te EMD ve ICA kullanılarak ön işleme yapılmış EEG sinyalleri üzerinde Katılımcı_1 ve Katılımcı_7 gibi katılımcılar için mükemmel yakın doğruluk ve AUC değerlerine ulaşılmış, duyarlılık oranları düşük kalırken özgüllük değerleri oldukça yüksek seyretmiştir. Ancak, DWT uygulanan Tablo 3-4'te, duyarlılık değerlerinde genel bir iyileşme gözlemlenmiş olsa da, bazı katılımcılar için hala düşük seviyelerde kalmıştır. Örneğin, Tablo 3-4'te Katılımcı_2 ve Katılımcı_3'te duyarlılık oranları ortalama %27-52 aralığında bulunurken, Tablo 3-3'te bu oranlar daha da düşük seviyelerdeydi (%15-30 aralığı). Bununla birlikte, her iki tabloda da özgüllük değerleri benzer şekilde yüksek kalmış ve negatif vakaların doğru sınıflandırılmasında tutarlı bir başarı gösterilmiştir. Genel olarak, DWT kullanımı duyarlılık oranlarını bir miktar artırsa da, modelin genelleme yeteneğini daha fazla geliştirmek için daha sofistike özellik çıkarma ve ön işleme yöntemlerine ihtiyaç duyulduğu açıkça görülmektedir.

Tablo 3- 5 : Ham EEG sinyallerine DWT+EMD uygulanmış ADHD bireylerde *one-versus-the others* biyometrik tanıma sonuçları

SB_1				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	91.07	94.39	91.54	92.33
SENS	38.46	42.85	23.07	34.79
SPEC	94.50	98.00	96.00	96.16
AUC	0.707	0.853	0.737	0.765
SB_2				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	93.42	91.58	94.83	93.27
SENS	30.76	35.71	69.23	45.23
SPEC	97.50	95.50	96.50	96.5
AUC	0.838	0.871	0.811	0.84
SB_3				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	92.01	88.73	91.12	90.62
SENS	15.38	38.46	14.28	22.70
SPEC	97.00	92.00	96.50	95.16
AUC	0.814	0.820	0.838	0.824
SB_4				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	92.95	90.65	93.42	92.34
SENS	38.46	21.42	30.76	30.21
SPEC	96.50	95.50	97.50	96.5
AUC	0.818	0.636	0.872	0.775
SB_5				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	92.95	93.92	92.48	93.11
SENS	15.38	42.85	30.76	29.66
SPEC	98.00	97.50	96.50	97.33

AUC	0.909	0.922	0.843	0.891
SB_6				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	93.89	94.85	95.77	94.83
SENS	23.07	50.00	46.15	39.74
SPEC	98.50	98.00	99.00	98.5
AUC	0.853	0.854	0.911	0.872
SB_7				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	96.71	93.45	94.36	94.84
SENS	53.84	28.57	30.76	37.72
SPEC	99.50	98.00	98.50	98.66
AUC	0.974	0.852	0.876	0.900


Bu tabloya göre (bakınız Tablo 3-5), ADHD bireylerinin EEG sinyalleri üzerinde hem DWT hem de EMD kullanılarak biyometrik sınıflandırma yapılmıştır. Katılımcı_2 ve Katılımcı_3 için doğruluk oranları %93.27 ile %90.62 arasında değişmektedir, duyarlılık ise daha düşük olup %45.23 ile %22.70 arasındadır. Özellikle Katılımcı_3 için duyarlılık %22.70 gibi oldukça düşük bir değerde kalmıştır, ancak özgüllük %96.5 ile %95.16 arasında yüksek düzeyde seyretmiştir. AUC değerleri de 0.84 ile 0.824 arasında değişmiş olup, genel ayırım gücünün kabul edilebilir düzeyde olduğunu göstermektedir. Katılımcı_5-7 için doğruluk oranları %93.11 ile %95.46 arasında olup, özellikle Katılımcı_6'da %94.83'e ulaşmıştır. Duyarlılık ise %29.66 ile %52.56 arasında değişmekte olup, Katılımcı_6 ve Katılımcı_5 için duyarlılık oranlarında özgüllük değerleri ise %97.33 ile %98.83 arasında olup, oldukça yüksektir. AUC değerleri de 0.891 ile 0.949 arasında değişmektedir. Genel değerlendirme olarak tüm katılımcılarda özgüllük ve doğruluk değerleri yüksek kalmış, bu da modelin negatif vakaları başarılı bir şekilde ayırt edebildiğini göstermektedir. Ancak duyarlılık oranları genel olarak daha düşük olup, özellikle Katılımcı_1, Katılımcı_3 ve Katılımcı_4'te %30'un altında kalmıştır. Bununla birlikte, Katılımcı_6 ve Katılımcı_5'te duyarlılık oranlarında önemli bir artış gözlenmiş ve modelin pozitif vakaları daha iyi tespit ettiği görülmüştür. AUC değerleri genel olarak iyi seviyelerde olsa da, duyarlılık oranlarını daha da iyileştirmek, modelin pozitif vakaları ayırt etme yeteneğini geliştirmek için önem arz etmektedir.

Tablo 3- 6 : Ham EEG sinyallerine DWT+ICA uygulanmış ADHD bireylerde *one-versus-the others* biyometrik tanıma sonuçları

SB_1				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	95.30	94.39	96.71	95.46
SENS	46.15	35.71	61.53	47.79
SPEC	98.50	98.50	99.00	98.66
AUC	0.823	0.959	0.985	0.922
SB_2				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	95.79	96.24	94.36	95.46
SENS	42.85	61.53	30.76	45.04
SPEC	99.50	98.50	98.50	98.83
AUC	0.961	0.936	0.917	0.938
SB_3				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	93.92	94.39	93.89	94.06
SENS	14.28	14.28	15.38	14.64
SPEC	99.50	100	99.00	99.5
AUC	0.915	0.985	0.905	0.935
SB_4				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	93.42	94.39	94.36	94.05
SENS	30.76	21.42	23.07	25.08
SPEC	97.50	99.50	99.00	98.66
AUC	0.861	0.818	0.793	0.824
SB_5				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	97.18	93.92	92.01	94.37
SENS	69.23	50.00	30.76	49.99
SPEC	99.00	97.00	96.00	97.33
AUC	0.970	0.945	0.869	0.928







SB_6				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	95.30	94.36	94.85	94.83
SENS	53.84	38.46	57.14	49.81
SPEC	98.00	98.00	97.50	97.83
AUC	0.971	0.898	0.924	0.931
SB_7				
%	K-FOLD_1	K-FOLD_2	K-FOLD_3	ORTALAMA
ACC	93.92	95.30	94.36	94.52
SENS	28.57	23.07	46.15	32.59
SPEC	98.50	100	97.50	98.66
AUC	0.963	0.947	0.910	0.94


Tablo 3-6’da, ADHD bireylerine ait EEG sinyalleri üzerinde 0-8 Hz bant genişliğinde (DWT) ICA (Independent Component Analysis) kullanılarak yapılan sınıflandırma sonuçları yer almaktadır. Bu iki tabloda her bir katılımcı için doğruluk, duyarlılık, özgüllük ve AUC değerleri karşılaştırılmıştır. Katılımcı_1-4 için ortalama doğruluk %94.05 ile %95.46 arasında değişmekte olup, yüksek doğruluk değerleri elde edilmiştir. Duyarlılık oranları ise %14.64 ile %47.79 arasında değişmekte olup, özellikle Katılımcı_3’te duyarlılık %14.64 ile oldukça düşüktür. Özgüllük ise %98.50 ile %99.50 arasında yüksek seviyelerde seyretmektedir, bu da negatif vakaların doğru sınıflandırıldığını göstermektedir. AUC değerleri de 0.824 ile 0.938 arasında değişmiş olup, özellikle Katılımcı_1 ve Katılımcı_2 için yüksek ayırım gücü sağlamaktadır. Katılımcı_5-7 için doğruluk %94.37 ile %94.83 arasında olup, genellikle oldukça başarılı sonuçlar elde edilmiştir. Duyarlılık değerleri %32.59 ile %49.99 arasında değişmekte olup, Katılımcı_7’de en düşük (%32.59), Katılımcı_5’te ise en yüksek (%49.99) duyarlılık değerleri gözlemlenmiştir. Özgüllük değerleri %97.33 ile %98.83 arasında değişmektedir. AUC değerleri de 0.928 ile 0.94 arasında seyretmektedir. Genel değerlendirme olarak doğruluk ve özgüllük değerleri yüksek seviyelerde kalmış olup, modelin negatif vakaları doğru sınıflandırmada başarılı olduğu görülmektedir. Duyarlılık oranları genel olarak daha düşük kalmış ve pozitif vakaların tespit edilmesinde bazı zorluklar yaşanmıştır. Ancak AUC değerleri genel olarak iyi düzeylerde olup, modelin genel performansını yansıtmaktadır. Duyarlılık oranlarını artırmak, modelin pozitif vakaları tespit etme yeteneğini iyileştirmek için önem arz etmektedir.



Şekil 3-1 : ADHD bireylerde ICA uygulanmış EEG sinyalleri üzerinden t-SNE saçılım tabanlı biyometrik ayırım görseli; Soldaki görsel tüm EEG kanallarını, sağdaki ise yalnızca 7 frontal kanalı göstermektedir

Görselde iki tane t-dağıtılmış Stokastik Komşu Yerleştirme (t-SNE) kümeleme çizimi bulunuyor. Her iki çizimde de ICA uygulamalı EEG sinyalleri temelinde biyometrik ayırım sonuçları gösteriliyor. Sol tarafta tüm kanalların kullanıldığı durumdaki t-SNE kümelenmesi yer alıyor. Bu çizimde farklı renkler, potansiyel olarak farklı biyometrik özellikleri temsil eden kümeleri ifade ediyor. Sağ tarafta ise sadece 7 kanal kullanılarak yapılan t-SNE kümelenmesi bulunuyor. Sol çizimde olduğu gibi, sağ çizimde de farklı renkler farklı kümeleri gösteriyor. Her iki çizimde de t-SNE boyutlarını temsil eden x ve y eksenleri bulunuyor ve üst sol köşede kümeleri farklı sayısal etiketler ve renklerle gösteren bir açıklama kısmı yer alıyor. 7 kanallı ve tüm kanalları içeren t-SNE kümelenmelerine baktığımızda, tüm kanalları içeren grafikte (sol tarafta) daha belirgin ve ayrı kümeler olduğu görülüyor. Her renk farklı bir küme olduğunu belirtiyor ve kümeler arasında açık bir ayırım var. 7 kanallı grafikte (sağ tarafta) ise kümeler daha dağınık ve iç içe geçmiş durumda. Bu durum, tüm kanalların kullanıldığı analizde biyometrik ayırımın daha net ve kesin yapıldığını gösteriyor. ICA, EEG sinyallerinde farklı kaynaklardan gelen karmaşık sinyalleri bağımsız bileşenlere ayırmak için kullanılır. EEG sinyalleri, genellikle beyin aktivitesinin yanı sıra göz kırpması, kas hareketleri, kalp atışı gibi çeşitli biyolojik ve çevresel gürültüler içerir. ICA, bu karışık sinyalleri ayrıştırarak saf beyin aktivitesini ortaya çıkarmaya çalışır. Sonuç olarak, biyometrik ayırimda daha doğru ve güvenilir sonuçlar elde edilir. Bu bağlamda, tüm kanalların kullanımı ve ICA'nın uygulanması, EEG sinyallerindeki gürültüyü ve karışıklığı azaltarak daha net biyometrik ayırım yapılmasını sağlamış gibi görünüyor. Bu da özellikle biyometrik doğrulamanın ve kimlik tespitinin kritik olduğu uygulamalarda büyük bir avantaj sağlar.













Şekil 3-2 : ADHD bireylerde farklı sinyal işleme teknikleri uygulanmış EEG sinyalleri üzerinden t-SNE saçılım tabanlı biyometrik ayrım görseli; Soldaki görsel tüm EEG kanallarını, sağdaki ise yalnızca 7 frontal kanalı göstermektedir

Yukarıdaki t-SNE saçılım grafikleri (bakınız Şekil 3-2), DWT , ICA ve EMD gibi ön işleme teknikleri, EEG sinyalleri üzerinde biyometrik ayrımı artırmak amacıyla kullanılan önemli yöntemleri t-SNE saçılım grafiği üzerinden göstermektedir. DWT, sinyalleri farklı frekans bileşenlerine ayırarak her bileşenin zamansal özelliklerini ortaya çıkarırken, ICA sinyaldeki bağımsız bileşenleri ayırarak, gürültüden arındırılmış daha saf EEG sinyalleri sunar. EMD ise sinyali doğal modlarına ayrıştırarak sinyalin altta yatan dinamiklerini analiz etmeyi sağlar. Bu teknikler t-SNE (t-Distributed Stochastic Neighbor Embedding) gibi boyut indirgeme yöntemleriyle görselleştirildiğinde, EEG sinyallerinin bireyler arasında nasıl kümelendiği ve ayrıldığı gözlemlenebilir. DWT ile işlenmiş sinyaller t-SNE grafikleri üzerinde belirgin frekans bazlı kümelenmeler oluştururken, ICA uygulamaları sinyallerin gürültüden arındırılmasıyla bireyler arası daha temiz ve net ayrımlar sağlar. EMD, sinyaldeki doğal salınımları açığa

ıkararak bireyler arası biyometrik farklılıkları daha kompleks bir yapıda sunabilir. zellikle kanalların azaltılmasıyla, bireyler arası kmelenme t-SNE grafikleri zerinde daha belirgin hale gelmektedir. Sonu olarak, DWT, ICA ve EMD'nin birlikte veya ayrı ayrı kullanımı, EEG sinyalleri zerinde yapılan biyometrik sınıflandırmaların doėruluėunu artırmakta ve her bir tekniėin t-SNE zerinde farklı kmeleme zellikleri sunduėu grlmektedir.




















Şekil 3-3 : ADHD bireylerde ICA uygulanmış EEG sinyalleri üzerinden t-SNE saçılım tabanlı *one-versus-the others* biyometrik ayırım görseli; Soldaki görsel tüm EEG kanallarını, sağdaki ise yalnızca 7 frontal kanalı göstermektedir

Yukarıdaki t-SNE grafikleri (bakınız Şekil 3-3), ICA kullanılarak işlenmiş EEG sinyallerinin, bireysel biyometrik özelliklerin ayrıştırılmasında nasıl kümelendiğini göstermektedir. Grafiklerde her bir Katılımcı'ya ait sinyallerin, "*one-versus-the-others*" yaklaşımıyla diğer Katılımcı'lardan nasıl ayrıştığı t-SNE algoritmasıyla iki boyutlu olarak görselleştirilmiştir. Sol tarafta tüm kanallar kullanarak elde edilen sonuçlar, sağ tarafta ise sadece 7 kanal kullanarak elde edilen sonuçlar yer almaktadır. Tüm kanallar kullanıldığında her bir Katılımcı için daha belirgin ayrışma gözlemlenmektedir ve özellikle mavi renk ile işaretlenmiş Katılımcı'lar (Katılımcı_1, 2, 3 vb.) diğer Katılımcı'lardan daha belirgin kümelenebilir. Bu ayrışma, ICA'nın sinyaldeki bağımsız bileşenleri etkili bir şekilde ayrıştırarak biyometrik özelliklerin çıkarılmasına katkı sağladığını göstermektedir. Kanalların sayısı 7'ye indirildiğinde, Katılımcı'lar arasındaki ayrışmanın bir miktar azaldığı görülmekle birlikte, bazı Katılımcı'lar (özellikle Katılımcı_1 ve Katılımcı_2) için diğer Katılımcı'lardan farklı bölgelerde kümelenebilir. 7 kanal kullanımı, tüm kanallar kadar güçlü bir ayırım sağlamasa da, biyometrik ayrıştırmada etkili sonuçlar sunmaya devam etmektedir. Genel olarak, ICA'nın uygulanmasıyla elde edilen t-SNE grafikleri, bireyler arasındaki biyometrik farkların daha net bir şekilde görselleştirilmesine olanak tanımış ve her bireyin beyin sinyallerindeki özgün biyometrik özelliklerin diğer Katılımcı'lardan ayrışmasını sağlamıştır. Özellikle tüm kanallar kullanıldığında ayırım daha belirgin olmakta, ancak sınırlı kanal kullanımıyla da etkili ayırım devam etmektedir. Bu bulgular, EEG sinyalleri üzerinden biyometrik kimlik doğrulama sistemlerinin geliştirilmesi açısından önem taşımaktadır.










Şekil 3-4 : ADHD bireylerde farklı sinyal işleme teknikleri uygulanmış EEG sinyalleri üzerinden t-SNE saçılım tabanlı biyometrik ayırım görselleri; Soldaki görsel tüm EEG kanallarını, sağdaki ise yalnızca 7 frontal kanalı göstermektedir

DWT ve EMD kullanılarak işlenmiş EEG sinyalleriyle elde edilen t-SNE grafikleri, Katılımcı'ların biyometrik ayırımının nasıl gerçekleştiğini gözler önüne sermektedir. Grafikte, tüm kanallar ve sadece 7 kanal kullanılarak elde edilen sonuçlar karşılaştırıldığında, her iki durumda da Katılımcı'lar arası ayrışmanın görülebildiği anlaşılmaktadır. Ancak, tüm kanallar kullanıldığında Katılımcı'lar arası ayrışma daha belirgin hale gelirken, 7 kanal kullanıldığında bu ayrışma daha sınırlı kalmaktadır. DWT ve EMD'nin EEG sinyallerindeki farklı frekans bileşenlerini ve modlarını ayrıştırarak biyometrik özelliklerin çıkarılmasını sağladığı bu grafikte açıkça görülmektedir. Bununla birlikte, bazı Katılımcı'ların diğerlerine göre daha zor ayrıldığı (örneğin, Katılımcı_1 ve Katılımcı_2 gibi) bu sonuçlar, sinyallerin biyometrik ayırımında kanalların sayısının etkili bir faktör olduğunu göstermektedir. DWT ve EMD uygulamaları, sinyaldeki gürültüyü azaltıp önemli bileşenleri öne çıkararak, Katılımcı'lar arası farkların t-SNE grafikleri üzerinde daha iyi gözlemlenmesini sağlar.


ICA ile ayrılmış t-SNE grafikleri ile DWT ve EMD kullanılarak işlenmiş t-SNE grafikleri arasındaki temel farklar, her yöntemin sinyal işleme kapasitesi ve biyometrik ayırıştırma yeteneklerinden kaynaklanmaktadır. ICA, sinyaldeki bağımsız bileşenleri ayırıştırarak gürültüyü temizler ve her bileşeni bağımsız hale getirir; bu da sinyaldeki gürültülerin minimize edilmesi ve sadece beyin aktivitesine dayalı bileşenlerin çıkarılması anlamına gelir. Bu nedenle, ICA ile işlenmiş t-SNE grafikleri genellikle daha temiz, daha belirgin kümelenmeler sunar ve Katılımcı'ların sinyalleri arasındaki ayrışma daha nettir. DWT ve EMD ise sinyalleri frekans ve modlara ayırarak biyometrik ayırım yapar, ancak bu yöntemler ICA kadar gürültü temizleme yeteneğine sahip değildir. Sonuç olarak, t-SNE grafikleri üzerinde Katılımcı'lar arasındaki ayrışma biraz daha belirsiz olabilir ve sinyallerde gürültüden kaynaklanan daha fazla karışıklık olabilir. ICA, sinyali bağımsız bileşenlerine ayırdığı için her bir Katılımcı'nın sinyalleri diğer Katılımcı'ların sinyallerinden daha net bir şekilde ayrışırken, DWT ve EMD yöntemleri ile elde edilen t-SNE grafiklerinde Katılımcı'lar arası ayrışma daha flu olabilir ve kümelenmeler daha dağınık görünebilir. DWT ve EMD frekans tabanlı ayırıştırma yaparak sinyalin zamana bağlı frekans bileşenlerini analiz eder ve modlara ayırarak her moddaki frekans bileşenlerini ortaya çıkarırken, ICA sinyali bileşenlerine ayırarak frekans bileşenlerine odaklanmaz ve daha çok bileşenlerin bağımsızlığına vurgu yapar. Dolayısıyla, ICA ile elde edilen t-SNE grafikleri, Katılımcı'lar arasında daha net ayrışmalar ve kümelenmeler sunarken, DWT ve EMD ile işlenen t-SNE grafikleri frekans ve modların ayırıştırılmasına dayalı olup Katılımcı'lar arası ayırım daha az net olabilir.






Şekil 3-5 : ADHD bireylerde ham EEG sinyalleri üzerinden çok kanallı zaman - genlik görseli

Bu sinyaller, ADHD bireylerinden alınan EEG verilerini gösteren zaman-genlik grafikleri içermektedir. Her bir katılımcı için 19 kanal üzerinden alınan sinyaller farklı renklerle gösterilmiştir ve her kanalın zaman içindeki dalga formu görüntülenmiştir. Sinyaller, kanal bazlı varyasyonları ortaya koyarak biyometrik ayırım yapabilme potansiyeline işaret etmektedir. Bu sinyallerin, zaman frekans çözümlemesi ve diğer biyometrik analiz yöntemleriyle detaylandırılması, kişisel farklılıkların daha net şekilde ortaya çıkmasına olanak sağlayabilir. Özellikle, t-SNE ile görselleştirilen verilerde, farklı frekans bileşenlerinin ayrıştırılmasında kullanılan EMD ve ICA yöntemlerinin, bu tür biyometrik sinyallerin ayırımında ne kadar etkili olduğunu ortaya koymaktadır.







Şekil 3-6 : ADHD bireylerde ham EEG sinyalleri üzerinden beyin haritalama görseli

Yukarıdaki beyin haritalama görsellerinde (bakınız Şekil 3-6), farklı deneklere ait ham EEG sinyallerinin beyin haritalaması gösterilmektedir. Her görselde EEG elektrotlarının yerleştirildiği bölgeyi içeren bir kafa üst görünümü bulunmakta ve renk skalası kullanılarak farklı EEG sinyal güç seviyeleri (μV^2 cinsinden) temsil edilmektedir. EEG elektrot noktaları küçük dairelerle gösterilmekte olup, renk skalası sağ tarafta yer almakta ve EEG sinyal gücünün μV^2 cinsinden değerlerini göstermektedir; sarı ve kırmızı tonlar daha yüksek, mavi tonlar ise daha düşük güç seviyelerini ifade etmektedir. Her denneğin beyin haritası farklı desenler sergileyerek, farklı biyolojik sinyallerin ve beyin aktivitelerinin kişiler arası değişiklik gösterebileceğini ortaya koymaktadır. Bu çeşitlilik, EEG sinyallerinin biyometrik ayırım ve kimlik doğrulamada kullanılabilir potansiyelini gözler önüne sermektedir. ADHD (Attention Deficit Hyperactivity Disorder) olan bireylerin beyin haritalama çalışmalarında genellikle prefrontal korteks gibi alanlarda farklılıklar gözlemlenir. Bu bölgelerdeki aktivite, dikkat, yürütücü işlevler ve hareket kontrolü ile ilişkilidir. ADHD olan bireylerde prefrontal korteks gibi

bölgelerde düşük aktivite görülebilir. Yukarıdaki EEG beyin haritaları, ham EEG sinyallerinin genelde beyin yüzeyinden ölçülen potansiyel farklarını göstermekte ve ADHD olan bireylerde özellikle dikkat, yürütücü işlevler ve motor kontrolü içeren alanlarda büyük farklar görülebilir. ADHD için dikkat ve yürütücü işlevlerin yer aldığı ön beyin bölgelerinde (özellikle prefrontal kortekste) ölçülen EEG sinyalleri genellikle daha başarılı sonuç verebilir; bu yüzden ham EEG sinyallerinde bu bölgelere odaklanılması daha doğru sonuçlar sağlar. Verilen beyin haritalarında her bireyin beyin aktivite desenlerinin farklı olduğu gözlenmekte, ADHD bireyler için spesifik bölgelerin incelenmesi gerektiği ortaya konmaktadır.












Şekil 3-7 : ADHD bireylerde DWT uygulanmış EEG sinyalleri üzerinden beyin haritalama görseli

Bu beyin haritalama grafikleri, farklı bireylerin ham EEG sinyallerinden DWT (Discrete Wavelet Transform) kullanılarak alfa frekans bandı (8-12 Hz) çıkarılmış sinyalleri göstermektedir ve her bir grafikte voltaj varyansları (μV^2) beyin yüzeyine göre dağılım olarak sunulmaktadır. İlk iki grafikte, Katılımcı_1 ve Katılımcı_2'nin alfa frekans bandındaki EEG sinyallerindeki voltaj dağılımının genel yapısı görülmektedir. Katılımcı_1'de belirgin enerji yoğunluğu sağ yarımkürede yoğunlaşmışken, Katılımcı_2'de daha merkezi bir yoğunluk ve yayılım gözlenmektedir. Bu, her iki bireyin alfa bandındaki aktivite profillerinin biyometrik ayırım açısından önemli farklılıklar gösterdiğini ortaya koymaktadır. Katılımcı_3 ve Katılımcı_4'ün beyin haritalarında ise alfa frekans bandındaki aktivite sol frontal bölgede belirgin farklılıklar göstermektedir; Katılımcı_3'te daha yoğun bir aktivite gözlemlenirken, Katılımcı_4'te aktivite daha dengeli ve yayılmış durumdadır. Katılımcı_5'te alfa bandındaki aktivite sol yarımkürede daha yoğunlaşmışken, Katılımcı_6'da merkez bölgede yoğun bir alfa aktivitesi görülmektedir. Son olarak, Katılımcı_7'de alfa bandındaki beyin aktivitesi nispeten

daha düşük seviyelerde olmakla birlikte, sol frontal bölgede belirgin enerji yoğunluğu gözlenmektedir. Bu haritalar, bireyler arasında alfa frekans bandındaki EEG sinyallerinin mekansal dağılımındaki farklılıkları gösterirken, aynı zamanda bu bandın biyometrik ayırım için önemli ipuçları sunduğunu ortaya koymaktadır.

DWT ile alfa frekans bandı çıkarılmış beyin haritaları ile ham EEG beyin haritalarını karşılaştırdığımızda, kişiye özel ve bölge bazlı değişikliklerin ortaya çıktığı görülmektedir. DWT ile alfa bandı çıkarılması, ham sinyallerdeki yüksek frekanslı bileşenleri azaltarak, beyin aktivitelerinin daha spesifik bir frekans aralığındaki (8-13 Hz) değişikliklerini ön plana çıkarır. Bu frekans bandı genellikle dikkat ve meditasyon gibi bilişsel durumlarla ilişkilidir ve ADHD bireylerinde bu bandın aktivitesinde farklılıklar gözlemlenebilir. DWT ile alfa bandı çıkarılmış sonuçlarda, her bireyin beyin haritasında dikkat çeken aktivite yoğunluklarının farklı bölgelerde yer aldığını görüyoruz; örneğin bazı bireylerde frontal bölgelerde yoğun aktivite gözlemlenirken, diğerlerinde parietal bölgelerde yoğunlaşma olabilir. ADHD'li bireylerde bu bandın aktiviteleri kişiden kişiye farklılık gösterebilir, bu da semptomların biyolojik yansıması olarak değerlendirilir. Bölgesel olarak, prefrontal ve parietal bölgelerdeki alfa aktivitesi, dikkat ve bilişsel kontrol süreçleriyle ilişkilidir ve bu bölgelerde gözlemlenen anomaliler ADHD'nin belirtilerini daha belirgin kılar. Biyometrik kullanım açısından DWT ile çıkarılan alfa bandı, her bireyin benzersiz beyin aktivitesi paternlerini ortaya koyarak kişisel bir biyometrik imza niteliği taşır. ADHD gibi nörogelişimsel bozuklukları olan bireylerde, bu frekans bandının bölgesel dağılımı kişisel tanımlama için kritik bir rol oynayabilir. Özellikle beyin-bilgisayar arayüzü (BCI) sistemlerinde, bu biyometrik işaretler ADHD tanısı olan bireylerdeki farklılıkları anlamak ve kimlik doğrulama için etkili bir şekilde kullanılabilir. Sonuç olarak, DWT ile elde edilen alfa bandı EEG verilerindeki kişi bazlı ve bölgesel değişiklikler, ADHD bireylerinin beyin aktivitelerindeki farklılıkları vurgulamakta ve bu verilerin biyometrik kimlik doğrulama sistemlerinde kullanım potansiyelini göstermektedir.












Şekil 3-8 : ADHD bireylerde ham EEG sinyalleri üzerinden korelasyon matrisi görseli

Ham EEG sinyallerine ait korelasyon matrislerine bakıldığında, her bir ADHD bireyi arasında kanal bazlı olarak belirgin farklar gözlenmektedir ve her birey için kanallar arası korelasyonun derecesi farklılık göstermektedir. Korelasyon matrisi, her bir kanalın diğer kanallarla olan ilişkisinin gücünü temsil eder ve genellikle 1'e yakın değerler yüksek korelasyonu, 0'a yakın değerler ise düşük korelasyonu ifade eder. Katılımcı_1'de, kanallar arasında genellikle orta düzeyde korelasyonlar bulunmakta ve beynin farklı bölgelerinin senkronize çalıştığını ancak belirgin bir baskın korelasyon olmadığını gözlemliyoruz, bu bireyde kanallar arası çeşitlilik fazladır. Katılımcı_2'de, kanallar arasında daha güçlü ve homojen korelasyonlar göze çarpmakta ve belirli kanallar arasındaki korelasyonların daha yüksek olduğu gözlemlenmektedir, bu da bu bireyin beyin aktivitesinde belirli bölgelerin daha senkronize çalıştığını işaret ediyor olabilir. Katılımcı_3'te ise düşük korelasyonların daha baskın olduğu bir yapı mevcut ve korelasyonların çoğunlukla zayıf olduğu görülmekte, bu da beyin bölgeleri arasındaki iletişimin daha az organize olabileceğini düşündürülebilir. Katılımcı_4'te ise kanallar arasındaki korelasyonlarda büyük varyasyonlar var ve bazı kanallar arasında güçlü korelasyonlar bulunurken, bazıları neredeyse hiç korelasyon göstermemekte, bu da bireyin beyindeki belirli bölgelerin diğer bölgelerle çok az bağlantılı olduğunu gösterebilir. Katılımcı_5'te korelasyonlar oldukça zayıf ve düzensiz olup, bu da bu bireyin beyin aktivitelerinin farklı kanallar arasında tutarsız ve düşük senkronize olduğunu işaret ediyor olabilir. Katılımcı_6'da ise diğer bireylere kıyasla negatif korelasyonların daha fazla olduğu görülmekte, bu da belirli kanallar arasında ters işleyen bir ilişki olduğunu ve bazı beyin bölgelerinin diğerlerine göre zıt bir aktivite gösterdiğini gösterebilir. Katılımcı_7'de belirgin bir negatif korelasyon görülmekte ve bazı kanalların birbirine tamamen ters bir aktivite gösterdiği işaret edilebilir, ayrıca genel olarak korelasyonların zayıf olduğu gözlemlenmektedir. Bu bireysel farklılıklar, ADHD'li bireylerin beyin aktivitesindeki çeşitlilikleri yansıtmakta ve her



bireyin beyin sinyallerinde bölge bazlı farklılıklar sergilediğini göstermektedir, bu farklar biyometrik açıdan her bireyin benzersiz beyin aktivite paternine sahip olduğunu ortaya koyabilir ve özellikle kanallar arası korelasyonların bireyler arasında değişiklik göstermesi, biyometrik sınıflandırma ve kimlik doğrulama açısından önemli olabilir.






Şekil 3-9 : ADHD bireylerde ICA uygulanmış EEG sinyalleri üzerinden korelasyon matrisi görseli

ICA uygulanmış EEG sinyallerinin korelasyon matrisleri incelendiğinde, her bireyin beyin aktiviteleri arasında farklılıklar olduğu görülmektedir. Bireyler arasında kanallar arasındaki korelasyon seviyeleri değişiklik göstermekte, bazı bireylerde yüksek korelasyon gözlenirken, bazı bireylerde negatif korelasyonlar ortaya çıkabilmektedir. Bu farklılıklar, bireylerin beyin aktivitelerinin bölgesel olarak nasıl dağıldığına dair bilgi sağlayabilir ve biyometrik kimlik doğrulama sistemlerinde ayırt edici bir özellik olarak kullanılabilir. Özellikle ADHD bireylerinde, beyin aktivitesinin belirli bölgelerde farklılık göstermesi, bu bireylere özgü sinyallerin tanımlanması için kullanılabilir ve biyometrik uygulamalarda etkin bir yöntem olabilir.


















Şekil 3-10 : ADHD bireylerde DWT uygulanmış EEG sinyalleri üzerinden korelasyon matrisi görseli


Bu DWT uygulanmış EEG sinyallerine ait korelasyon grafikleri, kanallar arasındaki ilişkiyi ortaya koymak için incelenmiştir. Kişiden kişiye önemli farklılıklar gözlenmektedir. Katılımcı_1 ve Katılımcı_5'te oldukça düşük korelasyonlar baskınken, diğer bireylerde (özellikle Katılımcı_2 ve Katılımcı_4) belirgin bir korelasyon paterni görülmektedir. Bu durum, bireylerin

EEG sinyalleri arasındaki bölgesel bağlantıların farklılık gösterdiğini işaret ediyor olabilir. Örneğin, bazı bireylerde frontal ve parietal bölgeler arasındaki güçlü korelasyonlar, diğer bireylerde zayıf olabilir. Bu farklılıklar, ADHD gibi nörolojik bozuklukların biyometrik modellenmesinde kullanılabilir. Kişiyi özel beyin dalga paternleri, biyometrik kimlik doğrulama gibi uygulamalarda değerlendirilebilir ve belirli frekans bandlarının çıkarılmasıyla sinyallerin karakteristiği daha net belirlenebilir. Bu bağlamda, özellikle alfa frekans bandı gibi bölgesel aktivite farkları, ADHD tanısında biyometrik sinyaller olarak işlev görebilir.









Şekil 3-11 : ADHD bireylerde ham EEG sinyalleri üzerinden farklı kanal çiftlerine bağlı olasılık yoğunluk fonksiyonu görseli

Şekil 3-11'e göre olasılık dağılım grafiklerindeki her bir kanalda aynı birey (same-subject) için olasılık yoğunluğu, bireyin farklı kanallarındaki korelasyon değerlerine göre dağılıyor. Aynı bireyde kanallar arası korelasyon değerleri yüksek ve dar bir dağılıma sahipken, farklı bireyler (cross-subject) arasındaki kanalların korelasyonu daha düşük ve geniş dağılıyor. Bu sonuçlar, EEG verilerindeki bireyler arasındaki farklılıkların, aynı birey içinde kanallar arası korelasyona kıyasla daha belirgin olduğunu gösteriyor. Biyometrik açıdan bu, aynı bireyin kanallar arası korelasyonunun belirgin bir karakteristik olarak kullanılabileceğini, farklı bireyler için bu korelasyonun ayırt edici olacağını gösterir. Dolayısıyla, bu olasılık dağılımlarına dayalı bir sınıflandırma algoritması, kişilerin biyometrik olarak tanınmasını sağlayabilir. Grafiklere göre, Katılımcı_1'in aynı birey içindeki korelasyonu yüksek ve dar bir dağılım gösterirken, diğer bireylerle karşılaştırıldığında düşük ve geniş bir aralıkta kalıyor, bu da Katılımcı_1'in EEG kanallarının daha güçlü içsel bir korelasyona sahip olduğunu ve diğer bireylerden ayırt edilebildiğini gösteriyor; benzer şekilde, Katılımcı_2'nin içsel korelasyonu yüksek, cross-subject korelasyonu ise düşük ve geniş dağılımlı olup bu da biyometrik olarak ayırt edici olduğunu işaret ediyor; Katılımcı_3'te özellikle Fp1-Fp3 ve Fp2-Fp3 kanallarında güçlü içsel bir korelasyon gözlemleniyor ve bu da biyometrik fark yaratıyor; aynı şekilde, Katılımcı_4 ve Katılımcı_5 de yüksek same-subject korelasyonlarıyla cross-subject korelasyonlarına göre ayrışıyor ve bu bireylerin EEG verilerinin biyometrik tanımlama için kullanılabilir olduğunu gösteriyor; genel olarak, her bireyin EEG sinyallerinde kanallar arası korelasyonun aynı bireyde güçlü, farklı bireylerde ise zayıf olması, kişiye özgü biyometrik modeller geliştirilmesine olanak tanıyor.

4. TARTIŞMA ve SONUÇ

Bu tez çalışmasının temel amacı, dikkat eksikliği ve hiperaktivite bozukluğu (ADHD) tanısı almış bireylerin EEG sinyallerinde barındırdığı ayırt edici özellikleri kullanarak, biyometrik tanıma sistemlerinin etkinliğini ortaya koymaktır. Bu doğrultuda, EEG sinyallerinden anlamlı ve ayırmacı özellikler çıkararak, bu özelliklerin kişisel kimlik doğrulama süreçlerine entegre edilmesi hedeflenmiştir. Çalışmada, Ampirik Mod Ayırıştırma (EMD), Ayırık Dalga Dönüşümü (DWT) ve Bağımsız Bileşen Analizi (ICA) gibi ileri sinyal işleme teknikleri kullanılarak sinyallerin temizlenmesi ve önemli bileşenlerin ayrıştırılması sağlanmıştır. Ayrıca, t-SNE yöntemi ile elde edilen düşük boyutlu veri temsilleri sayesinde, sinyaller arasındaki gruplar arası ayrışım görselleştirilmiş ve analiz edilmiştir. Derin öğrenme yaklaşımında ise, 1D-CNN modeli hem özellik çıkarma hem de sınıflandırma aşamalarında kullanılarak, ADHD bireylerin EEG sinyallerindeki karmaşık paternlerin başarılı bir şekilde yakalanması sağlanmıştır. Özellikle frontal lob verilerinin tercih edilmesi, dikkat ve bilişsel süreçlerdeki kritik rolü nedeniyle çalışmanın pratik ve bilimsel önemini artırmıştır. Sonuç olarak, bu tez, EEG sinyallerinde mevcut olan özgün ve ayırt edici özelliklerin, ADHD bireylerde kişisel biyometrik tanıma sistemlerinin geliştirilmesinde etkin bir kaynak oluşturabileceğini deneysel verilerle kanıtlamayı amaçlamaktadır. Elde edilen yüksek bireysel doğrulama oranları, "*one-versus-the-others*" modelinin de desteğiyle, bu yöntemin biyometrik uygulamalarda kullanılabilirliğini ortaya koymaktadır.

Alfa frekansı, beynin elektriksel aktivitelerinden biri olup 8–13 Hz aralığında yer almakta ve zihinsel durumlarla ilişkilendirilmektedir [54]-[56]. Literatürde, alt alfa bandı (8 Hz) dinlenme veya uyanıklık durumlarında aktif hale gelirken, üst alfa bandı (10–11 Hz) bilişsel işlem ve dikkat gerektiren görevler sırasında devreye girmektedir. Bu çalışmada, ADHD'li bireylerin frontal loblarındaki alfa frekansı bağlantılarında belirgin farklılıklar gözlemlenmiştir. Ayrıca, kullanımı kolay biyometrik sistemlerin geliştirilmesi amacıyla frontal lob üzerine yoğunlaşmıştır. Alt alfa bandında (8 Hz) ADHD'li bireylerde, kontrol grubuna kıyasla artan bağlantı (koherens) tespit edilmiştir; bu durum, dinlenme halinde bile anormal derecede yüksek bağlantı seviyelerine işaret etmektedir. Buna karşılık, üst alfa bandında (10–11 Hz) gözlemlenen azalan bağlantılar, frontal lobun bilişsel işleme ve dikkat görevleri sırasında yeterince etkin bağlanamadığını göstermektedir. Literatürde yer alan bulgular, görsel uyaranlara verilen yanıtlarda ADHD'li bireylerde frontal loblar arasında aşırı bağlantı gözlemlendiğini ve bunun uyarana bağlı aşırı bağlantı durumunu işaret ettiğini ortaya koymaktadır. Elde edilen bu bulgular,

ADHD'nin frontal lobdaki bağlantı eksikliği ile aşırı bağlantı durumlarının bir kombinasyonunu yansıttığını göstermekte ve alfa frekansının dikkat süreçleri ile bilişsel işlev bozukluklarının anlaşılmasında kritik bir parametre olduğunu desteklemektedir [54]-[56]. Frontal lobdan elde edilen veriler, bu lobun dikkat ve bilişsel süreçlerdeki merkezi rolü nedeniyle çalışmada önemli bir analiz kaynağı olarak değerlendirilmiştir. Bu kapsamda, frontal lob bölgesindeki toplam 7 elektrot seçilmiş ve bu elektrotlardan elde edilen sinyaller detaylı bir şekilde incelenmiştir. Elde edilen EEG sinyali özelliklerinin, hem doğruluk oranı hem de sınıflandırma başarısı açısından etkili olduğu belirlenmiştir. Bununla birlikte, ADHD bireylerde sinyallerin gürültülü yapısı ve artefaktların etkisi, bazı kanallarda çözülmesi gereken zorluklar yaratmıştır. Bu sorunların üstesinden gelmek için, çoklu sinyal işleme tekniklerinin birleştirilmesi, hem sinyal kalitesini artırmak hem de sınıflandırma performansını optimize etmek için etkili olmuştur.

Bu tez, ADHD bireylerde EEG tabanlı biyometrik sistemlerin uygulanabilirliğini ortaya koyan ilk çalışmalar arasında yer alması sebebiyle literatüre önemli bir katkı sunmaktadır; elde edilen sonuçlar, bu sistemlerin ADHD bireylerde yüksek doğruluk oranlarıyla kimlik doğrulama yapabildiğini gösterirken, gelecek çalışmalarda daha geniş ve dengeli veri setlerinin kullanılarak sınıflandırma performansının artırılması, farklı derin öğrenme mimarilerinin karşılaştırılarak en etkili modelin belirlenmesi, elektrot sayısının azaltılarak daha taşınabilir sistemlerin geliştirilmesi ve EEG sinyallerindeki gürültüyü minimize etmek amacıyla daha sofistike artefakt giderme tekniklerinin uygulanması gibi noktalara odaklanılması gerektiğini ortaya koymaktadır.

Sonuç olarak, bu çalışma ADHD bireylerin EEG sinyallerinin biyometrik sistemlerde kullanım potansiyelini başarıyla göstermiş ve gelecekte bu alandaki araştırmalara öncülük edebilecek bir zemin oluşturmuştur.

5. KAYNAKLAR

- [1] A. Genovese, V. Piuri, and F. Scotti, “Biometric Systems,” 2014, pp. 7–32. doi: 10.1007/978-3-319-10365-5_2.
- [2] A. Sarkar and B. K. Singh, “A review on performance, security and various biometric template protection schemes for biometric authentication systems,” *Multimed. Tools Appl.*, vol. 79, no. 37–38, pp. 27721–27776, Oct. 2020, doi: 10.1007/s11042-020-09197-7.
- [3] A. K. Jain and A. Kumar, “Biometric Recognition: An Overview,” 2012, pp. 49–79. doi: 10.1007/978-94-007-3892-8_3.
- [4] S. Salturk and N. Kahraman, “Deep learning-powered multimodal biometric authentication: integrating dynamic signatures and facial data for enhanced online security,” *Neural Comput. Appl.*, vol. 36, no. 19, pp. 11311–11322, Jul. 2024, doi: 10.1007/s00521-024-09690-2.
- [5] K. Ishikawa, K. Fujita, and T. Hamamoto, “Biometrics Verification Using Dynamic and Static Eye Shapes,” in 2006 International Symposium on Intelligent Signal Processing and Communications, IEEE, Dec. 2006, pp. 235–238. doi: 10.1109/ISPACS.2006.364875.
- [6] L. Chen, “A Multimodal Biometric Recognition System based on Finger Snapping and Information Fusion,” in 2020 5th International Conference on Information Science, Computer Technology and Transportation (ISCTT), IEEE, Nov. 2020, pp. 84–100. doi: 10.1109/ISCTT51595.2020.00024.
- [7] D. Polunina, O. Zolotukhina, O. Nehodenko, and I. Yarosh, “Methods of Biometric Authentication for Person Identification,” 2024, pp. 327–339. doi: 10.1007/978-3-031-52760-9_23.
- [8] I. Vorobyeva, D. Guriel, M. Ferguson, and H. Oladapo, “Benefits and issues of biometric technologies. Are biometrics worth using?,” in IEEE SOUTHEASTCON 2014, IEEE, Mar. 2014, pp. 1–8. doi: 10.1109/SECON.2014.6950706.
- [9] A. Sarkar and B. K. Singh, “A review on performance, security and various biometric template protection schemes for biometric authentication systems,” *Multimed. Tools Appl.*, vol. 79, no. 37–38, pp. 27721–27776, Oct. 2020, doi: 10.1007/s11042-020-09197-7.
- [10] S. Salturk and N. Kahraman, “Deep learning-powered multimodal biometric authentication: integrating dynamic signatures and facial data for enhanced online security,” *Neural Comput. Appl.*, vol. 36, no. 19, pp. 11311–11322, Jul. 2024, doi: 10.1007/s00521-024-09690-2.
- [11] P. Patil and S. Agarwal, “Dynamic Multimodal Biometric System,” 2021, pp. 12–19. doi: 10.1007/978-981-16-1086-8_2.

- [12] M. Diaz, A. Fischer, M. A. Ferrer, and R. Plamondon, "Dynamic Signature Verification System Based on One Real Signature," *IEEE Trans. Cybern.*, vol. 48, no. 1, pp. 228–239, Jan. 2018, doi: 10.1109/TCYB.2016.2630419.
- [13] H. Qiu et al., "Feasibility of Wrist-Worn, Cancelable, Real-Time Biometric Authentication via HD-sEMG and Dynamic Gestures," *IEEE Trans. Instrum. Meas.*, vol. 72, pp. 1–11, 2023, doi: 10.1109/TIM.2023.3327490.
- [14] H. Nisar, J. Y. Cheong, and V. V. Yap, "EEG-Based Biometrics for User Identification Using Deep Learning Method," in *2024 IEEE 8th International Conference on Signal and Image Processing Applications (ICSIPA)*, IEEE, Sep. 2024, pp. 1–6. doi: 10.1109/ICSIPA62061.2024.10686270.
- [15] K. P. Thomas and A. P. Vinod, "Toward EEG-Based Biometric Systems: The Great Potential of Brain-Wave-Based Biometrics," *IEEE Syst. Man, Cybern. Mag.*, vol. 3, no. 4, pp. 6–15, Oct. 2017, doi: 10.1109/MSMC.2017.2703651.
- [16] F. A. Yassine and G. Abdelkader, "EEG-based Biometric Authentication Using Machine and Deep Learning Approachs : A Review," in *2024 8th International Conference on Image and Signal Processing and their Applications (ISPA)*, IEEE, Apr. 2024, pp. 1–8. doi: 10.1109/ISPA59904.2024.10536762.
- [17] A. Rahman et al., "Multimodal EEG and Keystroke Dynamics Based Biometric System Using Machine Learning Algorithms," *IEEE Access*, vol. 9, pp. 94625–94643, 2021, doi: 10.1109/ACCESS.2021.3092840.
- [18] F. Gondesén, M. Marx, and D. Gollmann, "EEG-Based Biometrics," in *Biometric-Based Physical and Cybersecurity Systems*, Cham: Springer International Publishing, 2019, pp. 287–318. doi: 10.1007/978-3-319-98734-7_11.
- [19] A. B. Tatar, "Biometric identification system using EEG signals," *Neural Comput. Appl.*, vol. 35, no. 1, pp. 1009–1023, Jan. 2023, doi: 10.1007/s00521-022-07795-0.
- [20] K. Gorur, E. Olmez, Z. Ozer, and O. Cetin, "EEG-Driven Biometric Authentication for Investigation of Fourier Synchrosqueezed Transform-ICA Robust Framework," *Arab. J. Sci. Eng.*, vol. 48, no. 8, pp. 10901–10923, Aug. 2023, doi: 10.1007/s13369-023-07798-6.
- [21] J. Slater, R. Joobar, B. L. Koborsy, S. Mitchell, E. Sahlas, and C. Palmer, "Can electroencephalography (EEG) identify ADHD subtypes? A systematic review," *Neurosci. Biobehav. Rev.*, vol. 139, p. 104752, Aug. 2022, doi: 10.1016/j.neubiorev.2022.104752.
- [22] A. Alim and M. H. Imtiaz, "Automatic Identification of Children with ADHD from EEG Brain Waves," *Signals*, vol. 4, no. 1, pp. 193–205, Feb. 2023, doi: 10.3390/signals4010010.

- [23] M. Adamou, T. Fullen, and S. L. Jones, "EEG for Diagnosis of Adult ADHD: A Systematic Review With Narrative Analysis," *Front. Psychiatry*, vol. 11, Aug. 2020, doi: 10.3389/fpsyt.2020.00871.
- [24] B. TaghiBeyglou, A. Shahbazi, F. Bagheri, S. Akbarian, and M. Jahed, "Detection of ADHD cases using CNN and classical classifiers of raw EEG," *Comput. Methods Programs Biomed. Updat.*, vol. 2, p. 100080, 2022, doi: 10.1016/j.cmpbup.2022.100080.
- [25] "eeg-data-adhd-control-children." [Online]. Available: <https://ieee-dataport.org/open-access/eeg-data-adhd-control-children>
- [26] Ö. Kasim and M. Tosun, "Biometric Authentication from Photic Stimulated EEG Records," *Appl. Artif. Intell.*, vol. 35, no. 15, pp. 1407–1419, Dec. 2021, doi: 10.1080/08839514.2021.1981660.
- [27] S. Dargan and M. Kumar, "A comprehensive survey on the biometric recognition systems based on physiological and behavioral modalities," *Expert Syst. Appl.*, vol. 143, p. 113114, Apr. 2020, doi: 10.1016/j.eswa.2019.113114.
- [28] S. K. Behera, P. Kumar, D. P. Dogra, and P. P. Roy, "A Robust Biometric Authentication System for Handheld Electronic Devices by Intelligently Combining 3D Finger Motions and Cerebral Responses," *IEEE Trans. Consum. Electron.*, vol. 67, no. 1, pp. 58–67, Feb. 2021, doi: 10.1109/TCE.2021.3055419.
- [29] L. A. Moctezuma and M. Molinas, "Towards a minimal EEG channel array for a biometric system using resting-state and a genetic algorithm for channel selection," *Sci. Rep.*, vol. 10, no. 1, p. 14917, Sep. 2020, doi: 10.1038/s41598-020-72051-1.
- [30] I. Jayarathne, M. Cohen, and S. Amarakeerthi, "Person identification from EEG using various machine learning techniques with inter-hemispheric amplitude ratio," *PLoS One*, vol. 15, no. 9, p. e0238872, Sep. 2020, doi: 10.1371/journal.pone.0238872.
- [31] G. S. Walia, T. Singh, K. Singh, and N. Verma, "Robust multimodal biometric system based on optimal score level fusion model," *Expert Syst. Appl.*, vol. 116, pp. 364–376, Feb. 2019, doi: 10.1016/j.eswa.2018.08.036.
- [32] H. Zhao, Y. Chen, W. Pei, H. Chen, and Y. Wang, "Towards online applications of EEG biometrics using visual evoked potentials," *Expert Syst. Appl.*, vol. 177, p. 114961, Sep. 2021, doi: 10.1016/j.eswa.2021.114961.
- [33] S. Yang, S. Hoque, and F. Deravi, "Improved Time-Frequency Features and Electrode Placement for EEG-Based Biometric Person Recognition," *IEEE Access*, vol. 7, pp. 49604–49613, 2019, doi: 10.1109/ACCESS.2019.2910752.

- [34] Y. Chen et al., “A High-Security EEG-Based Login System with RSVP Stimuli and Dry Electrodes,” *IEEE Trans. Inf. Forensics Secur.*, vol. 11, no. 12, pp. 2635–2647, Dec. 2016, doi: 10.1109/TIFS.2016.2577551.
- [35] L. A. Moctezuma and M. Molinas, “Multi-objective optimization for EEG channel selection and accurate intruder detection in an EEG-based subject identification system,” *Sci. Rep.*, vol. 10, no. 1, p. 5850, Apr. 2020, doi: 10.1038/s41598-020-62712-6.
- [36] H. Zhao, Y. Wang, Z. Liu, W. Pei, and H. Chen, “Individual Identification Based on Code-Modulated Visual-Evoked Potentials,” *IEEE Trans. Inf. Forensics Secur.*, vol. 14, no. 12, pp. 3206–3216, Dec. 2019, doi: 10.1109/TIFS.2019.2912272.
- [37] T. Wilaiprasitporn, A. Dittaporn, K. Matchaparn, T. Tongbuasirilai, N. Banluesombatkul, and E. Chuangsuwanich, “Affective EEG-Based Person Identification Using the Deep Learning Approach,” *IEEE Trans. Cogn. Dev. Syst.*, vol. 12, no. 3, pp. 486–496, Sep. 2020, doi: 10.1109/TCDS.2019.2924648.
- [38] E. Maiorana, “Deep learning for EEG-based biometric recognition,” *Neurocomputing*, vol. 410, pp. 374–386, Oct. 2020, doi: 10.1016/j.neucom.2020.06.009.
- [39] H. Vadher et al., “EEG-based biometric authentication system using convolutional neural network for military applications,” *Secur. Priv.*, vol. 7, no. 2, Mar. 2024, doi: 10.1002/spy2.345.
- [40] T. Beyrouthy, N. Mostafa, A. Roshdy, A. Karar, and S. Alkork, “Review of EEG-Based Biometrics in 5G-IoT: Current Trends and Future Prospects,” *Appl. Sci.*, vol. 14, no. 2, p. 534, Jan. 2024, doi: 10.3390/app14020534.
- [41] “Physiology, Cerebral Cortex Functions.” [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK538496/>
- [42] “the-10-20-system-for-eeeg.” [Online]. Available: <https://info.tmsi.com/blog/the-10-20-system-for-eeeg>
- [43] V. Perez, A. Duque, V. Hidalgo, and A. Salvador, “EEG frequency bands in subjective cognitive decline: A systematic review of resting state studies,” *Biol. Psychol.*, vol. 191, p. 108823, Sep. 2024, doi: 10.1016/j.biopsycho.2024.108823.
- [44] “Electroencephalography.” [Online]. Available: <https://en.wikipedia.org/wiki/Electroencephalography>
- [45] K. M. Hossain, M. A. Islam, S. Hossain, A. Nijholt, and M. A. R. Ahad, “Status of deep learning for EEG-based brain–computer interface applications,” *Front. Comput. Neurosci.*, vol. 16, Jan. 2023, doi: 10.3389/fncom.2022.1006763.

- [46] X. Wang, Y. Ren, Z. Luo, W. He, J. Hong, and Y. Huang, "Deep learning-based EEG emotion recognition: Current trends and future perspectives," *Front. Psychol.*, vol. 14, Feb. 2023, doi: 10.3389/fpsyg.2023.1126994.
- [47] K. Gorur, "Fourier Synchrosqueezing Transform-ICA-EMD Framework Based EOG-Biometric Sustainable and Continuous Authentication via Voluntary Eye Blinking Activities," *Biomimetics*, vol. 8, no. 4, p. 378, Aug. 2023, doi: 10.3390/biomimetics8040378.
- [48] K. Gorur, M. Bozkurt, M. Bascil, and F. Temurtas, "GKP Signal Processing Using Deep CNN and SVM for Tongue-Machine Interface," *Trait. du Signal*, vol. 36, no. 4, pp. 319–329, Oct. 2019, doi: 10.18280/ts.360404.
- [49] H. W. Loh et al., "Deep neural network technique for automated detection of ADHD and CD using ECG signal," *Comput. Methods Programs Biomed.*, vol. 241, p. 107775, Nov. 2023, doi: 10.1016/j.cmpb.2023.107775.
- [50] A. Jaya Prakash, K. K. Patro, M. Hammad, R. Tadeusiewicz, and P. Pławiak, "BAED: A secured biometric authentication system using ECG signal based on deep learning techniques," *Biocybern. Biomed. Eng.*, vol. 42, no. 4, pp. 1081–1093, Oct. 2022, doi: 10.1016/j.bbe.2022.08.004.
- [51] M. S. Asif et al., "Hybrid Deep Learning and Discrete Wavelet Transform-Based ECG Biometric Recognition for Arrhythmic Patients and Healthy Controls," *Sensors*, vol. 23, no. 10, p. 4635, May 2023, doi: 10.3390/s23104635.
- [52] Y. Sun, F. P.-W. Lo, and B. Lo, "EEG-based user identification system using 1D-convolutional long short-term memory neural networks," *Expert Syst. Appl.*, vol. 125, pp. 259–267, Jul. 2019, doi: 10.1016/j.eswa.2019.01.080.
- [53] I. Kottlarz et al., "Extracting Robust Biomarkers From Multichannel EEG Time Series Using Nonlinear Dimensionality Reduction Applied to Ordinal Pattern Statistics and Spectral Quantities," *Front. Physiol.*, vol. 11, Feb. 2021, doi: 10.3389/fphys.2020.614565.
- [54] G. Leisman and R. Melillo, "Front and center: Maturational dysregulation of frontal lobe functional neuroanatomic connections in attention deficit hyperactivity disorder," *Front. Neuroanat.*, vol. 16, Aug. 2022, doi: 10.3389/fnana.2022.936025.
- [55] R. A. Barkley, G. Grodzinsky, and G. J. DuPaul, "Frontal lobe functions in attention deficit disorder with and without hyperactivity: A review and research report," *J. Abnorm. Child Psychol.*, vol. 20, no. 2, pp. 163–188, Apr. 1992, doi: 10.1007/BF00916547.
- [56] M. Murias, J. M. Swanson, and R. Srinivasan, "Functional Connectivity of Frontal Cortex in Healthy and ADHD Children Reflected in EEG Coherence," *Cereb. Cortex*, vol. 17, no. 8, pp. 1788–1799, Aug. 2007, doi: 10.1093/cercor/bhl089.

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: 3. Uluslararası Çağdaş Akademik Araştırma Konferansı ICCAR 2024 / ADHD’li Bireylerin EEG Sinyalleri ile Biyometrik Tanımlanması: Frontal Lob Tabanlı 1D-CNN, EMD ve t-SNE Yaklaşımı