

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI**

**FİZYOLOJİK SİNYALLER VE HAREKET VERİLERİ
KULLANILARAK DİKKAT EKSİKLİĞİ
HİPERAKTİVİTE BOZUKLUĞUNUN TESPİT
EDİLMESİNE YÖNELİK TEST SİSTEMİ
GERÇEKLEŞTİRİLMESİ VE ANALİZİ**

**Hazırlayan
Mustafa Yasin ESAS**

**Danışman
Prof. Dr. Fatma LATİFOĞLU**

Doktora Tezi

**Eylül 2023
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI**

**FİZYOLOJİK SİNYALLER VE HAREKET VERİLERİ
KULLANILARAK DİKKAT EKSİKLİĞİ
HİPERAKTİVİTE BOZUKLUĞUNUN TESPİT
EDİLMESİNE YÖNELİK TEST SİSTEMİ
GERÇEKLEŞTİRİLMESİ VE ANALİZİ
(Doktora Tezi)**

**Hazırlayan
Mustafa Yasin ESAS**

**Danışman
Prof. Dr. Fatma LATİFOĞLU**

**Bu çalışma, Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi
tarafından FBA-2022-11213 kodlu proje ile desteklenmiştir.**

**Eylül 2023
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Mustafa Yasin ESAS

İmza

“Fizyolojik Sinyaller ve Hareket Verileri Kullanılarak Dikkat Eksikliği Hiperaktivite Bozukluğunun Tespit Edilmesine Yönelik Test Sistemi Gerçekleştirilmesi ve Analizi” adlı Doktora tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan

Mustafa Yasin ESAS

İmza

Danışman

Prof. Dr. Fatma LATİFOĞLU

İmza

Biyomedikal Mühendisliği ABD Başkanı

Prof. Dr. Semra İÇER

İmza

TEŞEKKÜR

Çalışmalarım süresince her türlü yardımı ve fedakârlığı sağlayan, değerli vaktini bana ayıran, akademik gelişmemde her zaman yanımda olan kıymetli hocam Prof. Dr. Fatma LATİFOĞLU' na çok teşekkür ederim. Çalışmalarım sürecinde yardımlarını esirgemeyen ve değerli bilgileriyle çalışmalarına destek olan kıymetli hocam Doç. Dr. Esra DEMİRCİ' ye teşekkür ederim.

Maddi ve manevi olarak her zaman yanımda olan, beni daima destekleyen aileme, kıymetli eşim Merve ESAS' a ve oğlum Mehmet Selim ESAS' a teşekkür ederim.

Tez çalışması kapsamında FBA-2022-11213 kodlu proje ile gereken maddi desteği sağlayan Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi'ne teşekkür ederim.

Mustafa Yasin ESAS

Eylül 2023, KAYSERİ

FİZYOLOJİK SİNYALLER VE HAREKET VERİLERİ KULLANILARAK DİKKAT EKSİKLİĞİ HİPERAKTİVİTE BOZUKLUĞUNUN TESPİT EDİLMESİNE YÖNELİK TEST SİSTEMİ GERÇEKLEŞTİRİLMESİ VE ANALİZİ

Mustafa Yasin ESAS

**Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Doktora Tezi, Eylül 2023
Danışman: Prof. Dr. Fatma LATİFOĞLU**

ÖZET

Dikkat Eksikliği Hiperaktivite Bozukluğu (DEHB) ve onun alt türü olan Hiperaktivite Bozukluğu (HB) çocukluk çağının en yaygın görülen psikiyatrik rahatsızlıklarının başında gelmektedir. Hastalığın tanısı klinisyenin ve hastalık öyküsünü ifade eden ebeveyn veya öğretmenlerin objektif olmayan değerlendirmelerinden etkilenebilmektedir. Klinikte tanı, muayene ve çeşitli testlerle gerçekleştirilmekte olup doğrudan objektif değerlendirme araçları bulunmamaktadır.

Bu çalışmada DEHB tanısı olan bireylerde HB tespitinde objektif tanı araçları geliştirilmek üzere çeşitli hareket verileri ve fizyolojik kullanılmıştır. Kullanılan veriler ile DEHB ve HB tespiti için hasta/sağlıklı ayrımı yapan çalışmalar gerçekleştirilmiş olup bulguları sunulmuştur. Hasta ve sağlıklı grupların kontrollü şekilde tespitinin yapılabilmesi için görsel uyaran takip testi ve veri kayıt protokolleri geliştirilmiştir. Yapay sinir ağları, makine öğrenmesi algoritmaları, derin öğrenme algoritmaları kullanılarak elde edilen verilerle anlamı bulgular ortaya konulmuştur. Sadece EEG sinyalleri kullanılarak gerçekleştirilen çalışmada hasta / sağlıklı ayrımında 95% üzerinde başarı oranı, sadece EOG sinyalleri kullanılarak gerçekleştirilen çalışmada 88,89% başarı oranı, tüm veriler kullanılarak yapılan çalışmalarda 89,29% başarı oranı elde edilmiştir. Literatüre katkı sağlayacak özgün sonuçlar elde edilmiştir. Elde edilen sonuçların hastalığın tespitinde objektif tanı aracı olarak yakın gelecekte kullanılabileceği değerlendirilmektedir.

Anahtar Kelimeler: HB, DEHB, derin öğrenme, sınıflandırma, hastalık tespiti, jiroskop, ivmeölçer, nabız, GDC, EEG, EOG.

**DEVELOPMENT AND ANALYSIS OF A TEST SYSTEM FOR THE
DETECTION OF ATTENTION DEFICIT HYPERACTIVITY DISORDER
USING PHYSIOLOGICAL SIGNALS AND MOTION DATA**

Mustafa Yasin ESAS

Erciyes University, Graduate School of Natural and Applied Sciences

PhD Thesis, September 2023

Supervisor: Prof. Dr. Fatma LATİFOĞLU

ABSTRACT

Attention Deficit Hyperactivity Disorder (ADHD), and its subtype, Hyperactivity Disorder (HD), are among the most prevalent psychiatric disorders in childhood. Diagnosis of the disease can be influenced by the subjective evaluations of clinicians and non-objective assessments from parents or teachers reporting the patient's medical history. Clinical diagnosis is typically performed through examinations and various tests, with a lack of direct objective assessment tools.

In this study, various motion data and physiological signals were utilized to develop objective diagnostic tools for the detection of HD in individuals diagnosed with ADHD. Studies were conducted to distinguish between individuals with ADHD and HD and healthy individuals using the collected data, and the findings have been presented. Visual stimulus tracking tests and data recording protocols were developed to enable controlled identification of patient and healthy groups. Significant results were obtained using artificial neural networks, machine learning algorithms, and deep learning algorithms. A success rate of over 95% was achieved in a study conducted using only EEG signals for patient/healthy differentiation, 88.89% using only EOG signals, and 89.29% when all data were used. Unique results contributing to the literature were obtained. The obtained results are considered to be potentially used as an objective diagnostic tool for the disease in the near future.

Keywords: HD, ADHD, deep learning, classification, disease detection, gyroscope, accelerometer, pulse, GSR, EEG, EOG.

İÇİNDEKİLER

FİZYOLOJİK SİNYALLER VE HAREKET VERİLERİ KULLANILARAK DİKKAT EKSİKLİĞİ HİPERAKTİVİTE BOZUKLUĞUNUN TESPİT EDİLMESİNE YÖNELİK TEST SİSTEMİ GERÇEKLEŞTİRİLMESİ VE ANALİZİ

BİLİMSEL ETİĞE UYGUNLUK.....	ii
YÖNERGEYE UYGUNLUK.....	ii
KABUL VE ONAY.....	iv
TEŞEKKÜR.....	v
ÖZET	vi
ABSTRACT.....	vii
İÇİNDEKİLER	viii
KISALTMALAR.....	xi
TABLolar LİSTESİ.....	xiii
ŞEKİLLER LİSTESİ.....	xv
GİRİŞ.....	1

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. Tezin Konusu, İçeriği ve Problem Durumu.....	3
1.2. Tezin Amacı ve Önemi.....	4
1.3. Tezin Organizasyonu	5
1.4. Genel Bilgiler	6
1.4.1.Dikkat Eksikliği Hiperaktivite Bozukluğu (DEHB)	6
1.4.2. Hiperaktivite Bozukluğu (HB).....	8
1.4.3. Hareket Algılama	8
1.4.4. Jiroskop.....	10
1.4.5. İvmeölçer.....	11

1.4.6. Manyetometre.....	11
1.4.7. Fizyolojik Sinyaller	12
1.4.8. EKG ve Nabız	13
1.4.9. GDC.....	14
1.4.10. EOG.....	16
1.4.11. EEG	18
1.5. Literatür Araştırması	21

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Katılımcılar ve kayıt süreci	35
2.2. Materyal.....	36
2.2.1. Görsel uyaran takip testi	36
2.2.2. Nabız, GDC, ivmeölçeri jiroskop verileri kayıt sistemi.....	38
2.3. Yöntem	45
2.3.1. Yerel Ortalama Ayrışımı (Local Mean Decomposition – LMD) ve Ortogonallik Durumu	46
2.3.2. Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN)	47
2.3.3. Tekil Spektrum Analizi (Singular Spectrum Analysis - SSA)	48
2.3.4. Yapay Sinir Ağları (YSA).....	50
2.3.5. Güç Analizi	52
2.3.6. Higuchi'nin Fraktal Boyutu (Higuchi Fractal Dimension – HFD).....	53
2.3.7. Hjorth Parametreleri.....	53
2.3.8. Karar Ağaçları (Decision Tree – DT).....	54
2.3.9. K-En Yakın Komşu (K- Nearest Neighbors - K-NN)	55
2.3.10. Destek Vektör Makinesi (Support Vector Machine – SVM)	55
2.3.11. Değişken Mod Ayrıştırması (Variational Mode Decomposition - VMD)	56
2.3.12. Güçlü Yerel Ortalama Ayrıştırması (Robust Local Mean Decomposition - RLMD)	56
2.3.13. Derin Sinir Ağları (DSA).....	57
2.3.14. ResNet50.....	59
2.3.15. MobileNet.....	59

2.3.16. SqueezeNet	59
2.3.17. AlexNet	60
2.3.18. DenseNet.....	60
2.3.19. Tasarlanan Ağ Yapısı (EOGtNetV1).....	60
2.3.20. Tez Çalışması Verileriyle Yapılan İşlemler ve Tasarlanan Ağ Yapısı.....	61

3. BÖLÜM

BULGULAR

3.1. İvmeölçer Verilerine LMD Uygulaması Bulguları.....	68
3.2. Derin Sinir Ağıyla Aktivite Tanımlama Uygulaması Bulguları	72
3.3. EOG Sinyalleriyle YSA Kullanarak DEHB Tespiti Uygulaması Bulguları.....	74
3.4. EOG Sinyalleriyle Makine Öğrenmesi Kullanarak DEHB Tespiti Uygulaması Bulguları	77
3.5. EEG Sinyallerinin Derin Öğrenme Algoritmalarında Kullanılmasıyla DEHB Tespiti Uygulaması Bulguları	78
3.6. Göz Hareketlerine Dayalı EOG Sinyalleri Üzerinde Derin Öğrenme Algoritmaları Kullanılmasıyla DEHB Tespiti Uygulaması Bulguları	81
3.7. Tez Çalışması Verileriyle Yapılan İşlemlerden Elde Edilen Bulgular.....	82

4. BÖLÜM

TARTIŞMA-SONUÇ ve ÖNERİLER

4.1.Tartışma	91
4.2.Sonuç ve Öneriler.....	95
KAYNAKÇA	98
ÖZGEÇMİŞ.....	120

KISALTMALAR

DEHB	: Dikkat Eksikliği Hiperaktivite Bozukluğu
HB	: Hiperkaktivite Bozukluğu
GDC	: Galvanik Deri Cevabı
EDA	: Elektro Dermal Aktivite
EOG	: Elektrookülografi
EEG	: Elektroensefalografi
EKG	: Elektrokardiyogram
MEG	: Manyetoensefalografi
PPG	: Fotopletismografi
HRV	: Kalp atış hızı değişkenliği
DSM V	: Ruhsal Bozuklukların Tanısal ve Sayımsal El Kitabı 5. Baskı
MEMS	: Mikro Elektro-Mekanik Sistemler
sn	: Saniye
mV	: Milivolt
μV	: Mikrovolt
Hz	: Hertz
Ag-AgCl	: Gümüş-Gümüş Klorür
SVM	: Destek Vektör Makinesi
K-NN	: K-En Yakın Komşu
NB	: Navie Bayes
LR	: Lojistik Regresyon
RF	: Rastgele Orman
DT	: Karar Ağaçları

NG	: Nöral Gaz
YSA	: Yapay Sinir Ağı
DSA	: Derin Sinir Ağı
CNN	: Evrişimli Sinir Ağları
RNN	: Yinelemeli Sinir Ağları
FDA	: Amerika Birleşik Devletleri Gıda ve İlaç Dairesi
TBR	: Teta Beta Oranı
HFD	: Higuchi Fraktal Boyutu
FD	: Fraktal Boyut
LMD	: Yerel Ortalama Ayırıştırması
RLMD	: Sağlam Yerel Ortalama Ayırıştırması
VMD	: Değişken Mod Ayırıştırması
EMD	: Amprik Mod Ayırıştırması
SVD	: Tekil Değer Ayırışımı
SSA	: Tekil Spektrum Analizi
LM	: Levenberg Marquardt
RUBTS	: Referans Uyaran Birebir Takip Sayısı
ROT	: Renk Oyunu Tespiti

TABLOLAR LİSTESİ

Tablo 3.1. Merdiven inme ortogonallik değerleri	69
Tablo 3.2. Merdiven çıkma ortogonallik değerleri	70
Tablo 3.3. Koşu aktivitesi ortogonallik değerleri.....	71
Tablo 3.4. Yürüme aktivitesi ortogonallik değerleri.....	71
Tablo 3.5. Hareket grupları sınıflandırma başarıları.....	73
Tablo 3.6. Yönlere göre toplam hareket sayısının doğruluk oranları	75
Tablo 3.7. Görsel çeldirici durumunda doğruluk oranları.....	75
Tablo 3.8. Görsel uyaran tespiti doğruluk oranları	76
Tablo 3.9. İşitsel uyaran tespiti doğruluk oranları	76
Tablo 3.10. YSA sonucu sınıflandırma başarı oranları.....	77
Tablo 3.11. Yönlere göre referans uyaran birebir takip sayısı ve renk oyunu tespiti ortalama başarı oranları.....	77
Tablo 3.12. HFD ve Hjorth parametreleri tüm test bölümleri parametre ortalamaları ...	78
Tablo 3.13. Makine öğrenmesi sınıflandırma başarı oranları	78
Tablo 3.14. 19 Kanal EEG sinyaliyle elde edilen başarı oranları	79
Tablo 3.15. Tüm kanallar ve beyin bölgelerinden elde edilen başarı oranları.....	80
Tablo 3.16. Fp1 Kanalına RLMD ve VMD uygulaması sonucu başarı oranları	80
Tablo 3.17. EOG sinyali (Test-1) derin öğrenme algoritmaları – test başarı oranları	81
Tablo 3.18. EOG sinyali (Test-2) derin öğrenme algoritmaları – test başarı oranları	82
Tablo 3.19. EOG sinyali (Test-3) derin öğrenme algoritmaları – test başarı oranları	82
Tablo 3.20. Birinci durum, değerlendirme bulguları	83
Tablo 3.21. İkinci durum, 13 kanal tüm veriler değerlendirme bulguları.....	85
Tablo 3.22. İkinci durum, 8 kanal sinyal değerlendirme bulguları.....	85
Tablo 3.23. İkinci durum ivmeölçer verileri değerlendirme bulguları.....	85
Tablo 3.24. İkinci durum, jiroskop verileri değerlendirme bulguları	86
Tablo 3.25. İkinci durum, GDC sinyalleri değerlendirme bulguları.....	86
Tablo 3.26. İkinci durum, nabız sinyalleri değerlendirme bulguları.....	86
Tablo 3.27. İkinci durum, 5 kanal EOG ve EEG sinyalleri değerlendirme bulguları.....	87
Tablo 3.28. İkinci durum, yatay EOG sinyalleri değerlendirme bulguları	87
Tablo 3.29. İkinci durum, EEG (T3-T4) sinyali değerlendirme bulguları.....	87

Tablo 3.30. İkinci durum, EEG (F7-F8) sinyali değerlendirme bulguları	88
Tablo 3.31. İkinci durum, EEG (F3-F4) sinyali değerlendirme bulguları	88
Tablo 3.32. İkinci durum, GDC verileri değerlendirme bulguları	88
Tablo 3.33. Üçüncü durum, değerlendirme bulguları	89



ŞEKİLLER LİSTESİ

Şekil 1.1. EKG sinyali ve nabız tespitine ilişkin görsel	14
Şekil 1.2. GDC sinyali	16
Şekil 1.3. EOG elektrotları bağlantı şekilleri	17
Şekil 1.4. Göz hareketi ile EOG sinyali ilişkisi	18
Şekil 1.5. EEG 10-20 standardına göre elektrot yerleşimi	20
Şekil 1.6. 19 kanal EEG sinyali örneği	20
Şekil 2.1. Görsel uyaran takip testi	37
Şekil 2.2. MPU92/65-55 sensörünün cihaz kutusu içerisine yerleşimi	39
Şekil 2.3. GDC sensörü	40
Şekil 2.4. MikroSd hafıza kartı modülü	40
Şekil 2.5. EKG devresi (sol tarafta AD620 entegresi, sağda LM358 entegresi)	41
Şekil 2.6. Sensör kablolarının bulunduğu karın bölgesine takılan kemer	42
Şekil 2.7. Elektronik komponentlerin ve 9V beslemenin bulunduğu kemere takılan hazne	42
Şekil 2.8. Hazırlanan kayıt sistemi	43
Şekil 2.9. Kayıt sistemine ait akış diyagramı	44
Şekil 2.10. Kaydedilen veri örneği	45
Şekil 2.11. Tasarlanan ağ yapısı	48
Şekil 2.12. EOG sinyaline SSA işlemi öncesi (yukarıda) ve sonrası (aşağıda)	50
Şekil 2.13. Tasarlanan DSA Algoritması	58
Şekil 2.14. Tasarlanan ağ yapısı (EOGtNetV1)	61
Şekil 2.15. Derin Öğrenme Ağ Yapısı	64
Şekil 2.16. Karmaşıklık Matrisi	66
Şekil 3.1. Birinci durum, ortalama başarı yüzdeleri	84
Şekil 3.2. İkinci durum, ortalama en yüksek başarı yüzdeleri	89
Şekil 3.3. Üçüncü durum, ortalama başarı yüzdeleri	90

GİRİŞ

HB günümüzde çocukluk çağında toplumda sıklıkla karşılaşılan bir rahatsızlıktır. Bu rahatsızlık DEHB' nin alt türlerinden biri olup aşırı hareketlilik, dürtü kontrolsüzlüğü olarak tanımlanan nöropsikiyatrik bir hastalıktır. Özellikle ilkokul yaşlarında başlayıp yetişkinliğe kadar devam edebilmektedir. Nadiren yetişkinlerde de görülebilmektedir. Toplumda tanı kriterlerinden bağımsız olarak tanımlanmış önyargı içeren bir yaklaşım olmakla birlikte, HB tanısı klinisyenler tarafından konulabilmektedir.

HB çocukların akademik gelişimleri önünde büyük engel teşkil etmektedir. Bu hastalığa sahip çocuklar okul ortamında derslerine odaklanamamakta sürekli hareketlilik halleri ile eğitimde akranlarının ortalamasının altında kalabilmektedir. İlerleyen süreçte çocuğun okuldan ve eğitimden soğumasına sebep olacak durumlar meydana gelebilmektedir. Bu durum çocuğun hem kendisi için hem de toplumsal gelişmeye katkı sağlama açısından olumsuzluklar meydana getirebilmektedir. Klinisyenler psikiyatrik muayenenin yanı sıra, psikometrik değerlendirmeler ve Ruhsal Bozuklukların Tanısal ve Sayımsal El Kitabı (DSM V) tanı ölçütleri kullanarak tanı koyabilmektedir. Tanı sırasında çocuk hastalara ait öyküler aileler veya çocuğun öğretmeni tarafından dile getirilmekte ve tanı aşamasını yönlendirmektedir. Değerlendiriciyi etkileyebilen hasta öyküleri ve subjektiflik sağlayan objektif değerlendirme için yeterli olmayan testler ile HB tanısı konulabilmektedir. Bu durum da hasta çocuğa sağlıklı, sağlıklı çocuğa hasta tanısı konulması gibi olumsuz durumlara sebep olabilmektedir. Hastalık tanısının yaygın olarak kullanılan objektif bir tanı aracı bulunmamaktadır. Hatalı bir şekilde hasta tanısı konulması gereksiz ilaç kullanılmasına sebep olabilmekte ailenin ve çocuğun gereksiz bir tedavi süreci yaşamasına neden olabilmektedir. Hatalı bir şekilde sağlıklı tanısı konulması ise çocuğun eğitimini ve hayatının geri kalanını olumsuz etkileyebilmektedir. Hastalık düzeyi veya hastalığın tam olarak olup olmadığını tespit edecek veya tanıya destek olacak yardımcı sistemlerin bulunmaması nedeniyle objektif bir şekilde tanı konulması oldukça zordur.

Bu nedenle HB tanısı için objektif deęerlendirme araçlarının geliştirilmesi büyük önem arz etmektedir.

Yukarıda ifade edilen gerekçelerden dolayı bu tez çalışmasında HB tanısı için objektif deęerlendirme araçlarının geliştirilmesi birincil amacımız olarak ortaya konulmuştur. Objektif deęerlendirme araçları ile klinisyenin sübjektif deęerlendirme sonucu hatalı tanı koymasının önüne geçilmesi hedeflenmektedir.

Bu amaçla çift kör hekim deęerlendirmesi ile hasta ve sağlıklı olduğu belirlenen katılımcılardan elektrokardiyografi (EKG), nabız, galvanik deri cevabı (GDC), hareket verileri (jiroskop ve ivmeölçer), elektrookülografi (EOG) ve elektroensefalografi (EEG) sinyalleri gibi çeşitli parametreler kaydedilmiştir. Kayıt sırasında kullanılmak üzere kayıt sistemleri, test ve deney protokolleri ortaya konulmuştur. Elde edilen veriler makine öğrenmesi algoritmaları, derin öğrenme algoritmaları gibi teknikler kullanılarak analiz edilmiş ve HB' nun objektif tanısına destek olacak çeşitli bulgular sunulmuştur.

1. BÖLÜM

GENEL BİLGİLER VE LİTERATÜR ÇALIŞMASI

1.1. Tezin Konusu, İçeriği ve Problem Durumu

Bu tez kapsamında DEHB alt türlerinden biri olan HB hastalığının tanısı için objektif tanı araçları geliştirilmesi gerekliliği ortaya konulmuştur. DEHB çocukluk çağıının en sık görülen nöropsikiyatrik bozukluklarından biri olarak kabul edilmektedir [1,2]. DEHB' nin objektif bir tanı aracı bulunmamaktadır. Yani DEHB ve alt türlerinden olan HB bir laboratuvar tahlili ile veya bir görüntüleme tekniğiyle doğrudan tespit edilebilen bir hastalık değildir. Bu durum DEHB' nin belirtilerinin kişiden kişiye ve durumdan duruma değişebilmesiyle de ilişkilidir [3]. Bu tezde DEHB ve alt türlerinden olan HB' nin tanısı için objektif parametrelere dayalı olarak hastalık tespiti yapmak veya tanıya yardımcı olacak araçları ortaya koymak için çeşitli çalışmalar gerçekleştirilmiştir.

HB günümüzde toplumda çok yaygın olarak karşılaşılan bir hastalıktır. Toplumda HB bir hastalıktan ziyade hiperaktiflik durumu yani aşırı hareketlilik durumu olarak ifade edilmektedir. Bu nedenle birçok kişinin bireysel olarak çocuklarını hasta olarak değerlendirmedeği ve hiperaktivite durumuna yönelik çözüm aramadığı gözlemlenmektedir. Ancak HB tanısı ancak alanında uzman klinisyenlerce konulabilmektedir. Tespit edilen hastalar genellikle okuldaki öğretmenlerin ve rehberlik araştırma merkezlerinin tespitleri ile kliniğe yönlendirilmektedir. Bu nedenlerden ötürü DEHB ve HB' nin literatürde belirtilen oranlardan çok daha yüksek oranda toplumda görülme ihtimali yüksek olarak değerlendirilmektedir.

Tez kapsamında çift kör hekim değerlendirmesi ile hasta ve sağlıklı tanısı konulmuş çocuk ve ergenlerden çeşitli fizyolojik sinyaller, hareketliliğe ilişkin veriler kaydedilmiştir. Kayıt sürecine ilişkin bir ölçüm protokolü belirlenmiştir. Sonrasında elde

edilen veriler istatistiksel analiz, makine öğrenmesi ve derin öğrenme teknikleri ile analiz edilmiş ve bulgular değerlendirilmiştir.

Sonuç olarak, DEHB' nin ve HB' nin tanısı, subjektif bir değerlendirme sürecine dayanmaktadır. Klinikte subjektif süreçten dolayı hatalı tanı konulabilme potansiyeli yüksektir. Hatalı tanı sürecinin olumsuz etkilerini ortadan kaldırabilmek için objektif tanı araçlarının geliştirilmesi elzemdir. Tez çalışması bu kapsamda yapılmış olup elde edilen bulgular objektif tanı araçları için kaynak teşkil edebilecek niteliktedir.

1.2. Tezin Amacı ve Önemi

HB tespitinde objektif bir değerlendirme aracı bulunmamakta olup, tanı ve tedavi süreci klinisyenin tecrübesine ve yeteneğine bağlı olarak yürütülmekte ve sonuçlanmaktadır. Aşırı hareketlilik durumunun ailelerin veya öğretmenlerin belirttiği düzeyde olup olmadığı hususunda şüpheler oluşmaktadır. Klinisyenler ise sadece muayene sürecinde hastayı gözlemleyerek ve çeşitli testler uygulayarak tanı koyma konusunda yeterince objektif bir değerlendirme yapamamaktadır. Objektif bir değerlendirme işleminin sağlanması için HB tanısının ölçülebilir, ölçeklenebilir ve gözlemlenebilir bir şekilde konulması gerekmektedir. Bu kapsamda planlanan sistem ile objektif tanı konulabilmesi için mühendislik yöntemleri ile psikiyatri biliminin ortaklaşa çalışması sonucu tanı destek sistemi geliştirilmesi tez çalışmasının amacıdır.

DSM V [4] kriterlerine göre HB tanısı olan ve sağlıklı tanısı konulmuş bireylerin belirlenen süre boyunca fiziksel hareketlilikleri ile birlikte çeşitli fizyolojik parametrelerinin (GDC, EOG, EEG ve nabız) takibinin yapılması hedeflenmektedir. Belirlenen süre boyunca bireylerin fiziksel hareket miktarı (ivmeölçer, jiroskop, manyetometre sensörleri ile), ve fizyolojik parametreleri (GDC, EOG, EEG ve nabız) kayıt altına alınmıştır. Elde edilen parametre verilerinin değerlendirilip analiz edilmesi ile kişilerin hareketlilik düzeylerinin tespit edilmesi sağlanmıştır. Eş zamanlı olarak fizyolojik parametrelerin hareket verileri ile birlikte takip edilmesi ile hareket düzeylerinin fizyolojik parametreler ile olan ilişkisinin gözlenmesi hedeflenmiştir. Bu amaçla HB tanısına yönelik, bir tanı destek sisteminin geliştirilmesi ve böylece DSM V kriterlerinin subjektif değerlendirmeye dayalı olumsuzluklarının giderilmesi hedeflenmekte olup bu da tez çalışmasının önemini ortaya koymaktadır.

HB tanı ve tedavi takibinde ortak olarak kullanılan psikometrik testler dışında, uygulayan kişinin subjektifliğini ortadan kaldıracak objektif bir değerlendirme aracı bulunmamaktadır. Tez çalışması amaç, yöntem ve elde edilen bulgular kapsamında HB tespitine yönelik tamamen özgün bir tez çalışması olup; klinisyenlere yönelik tanıya yardımcı olacak bulgular ortaya konulmuştur.

Tez çalışmasının amaçları;

- DEHB ve özellikle alt türlerinden biri olan HB tanısında objektif değerlendirme araçlarının ortaya konulması,
- Klinisyenin subjektif etkisinin minimize edilerek sunulan objektif araçların klinikte kullanımının teşvik edilmesi,
- HB tanısına yönelik tanı destek sistemlerinin geliştirilmesi,
- Geliştirilen yöntemle ortaya konulan prototipler ve tespitlerin bilimsel gelişmeye katkı sunması amaçlanmaktadır.

Tez çalışmasının bilimsel yöntem olarak özgün değerleri şu şekilde sıralanabilir;

- HB tanısında kullanılan altın standart bir yöntem bulunmaması
- Non invazif ve objektif bir yöntem sunulmuş olması
- Sunulan yöntemin kullanım kolaylığı
- Sunulan yöntemin maliyet açısından ekonomik olması
- Ayrıca HB' nin etiyolojisine yeni bir bakış açısı getirilmesi, elde edilen bulguların tedavinin etkinliği ve düzenlenmesinde kullanılmasına olanak sağlaması sebebiyle özgün değer taşımaktadır.

1.3. Tezin Organizasyonu

Bu tez çalışmasında “Giriş” bölümünde kısaca çalışma hakkında bilgi verilmiş olup devamında tezin konusu, amacı, önemi ve özgünlüğü vurgulanmıştır. Çalışmanın

devamında konu hakkında genel bilgiler ve literatürde bulunan çalışmalar hakkında bilgiler sunulmuştur.

“Yöntem ve Materyal” bölümünde çalışmanın yöntemi, izlenen yol hakkında detaylıca bilgi verilmiştir. Tezin gerçekleştirilmesinde geliştirilen yöntemler ve donanımlar ortaya konulmuştur. Çalışma prosedürleri ifade edilmiştir. Tez kapsamında gerçekleştirilen bilimsel yayın çalışmalarının yöntemleri de bu bölümde ortaya konulmuştur. Bu bölümde ortaya konan bilgiler kullanılarak tez kapsamında bulgular elde edilmiştir.

“Bulgular” bölümünde, çalışmada izlenilen yöntem uygulanarak elde edilen tüm çıktılar sunulmuştur. Elde edilen bulguların hangi çalışmalar kapsamında ortaya konulduğu ifade edilmiştir.

Tez çalışmasının son bölümü olan “Tartışma-Sonuç ve Öneriler” bölümünde elde edilen tüm bulgular hakkında tartışmalı analizler ortaya konulmuş ve sonuçlar hakkında yorumlar yapılmıştır. Son olarak öneriler ifade edilerek tez çalışması tamamlanmıştır.

1.4. Genel Bilgiler

Bu bölümde tez çalışması kapsamındaki konular hakkında genel bilgilere yer verilmiştir.

1.4.1. Dikkat Eksikliği Hiperaktivite Bozukluğu (DEHB)

DEHB, çocukluk çağıının en yaygın nöropsikiyatrik bozukluklarından biri olarak kabul edilir [1,2]. DSM-V (Ruhsal Bozuklukların Tanısal ve İstatistiksel El Kitabı, Beşinci Baskı) adlı uluslararası sınıflandırma sistemine göre bu rahatsızlığın üç alt türü bulunmaktadır: dikkat eksikliği, aşırı hareketlilik ve dürtü kontrolsüzlüğü ve birleşik tip DEHB. DEHB genellikle erken çocukluk döneminde on iki yaşından önce ortaya çıkan bir nörogelişimsel bozukluktur [4]. 55.000'den fazla katılımcının yer aldığı 19 çalışmanın meta-analizine göre gençlerin %5.9' u DEHB tanı kriterlerini karşılamaktadır [5]. Başka bir meta-analiz Kuzey Amerika ve Avrupa, Asya, Afrika, Güney Amerika ve Okyanusya'da prevalansta anlamlı bir farklılık olmadığını göstermektedir ve bu sonuçlar çeyrek milyon genç insanı içeren 135 araştırma çalışmasına dayanarak belirtmiştir [6]. 26.000'den fazla katılımcının yer aldığı 20 çalışmanın meta-analizinde insanların %2.8'i DEHB kriterlerini karşılamaktadır [7]. DEHB, düşük okul performansı ve akademik başarı, akranlar ve aile ile kötü sosyal ilişkiler, artan saldırganlık, riskli davranışlar, erken

dönem madde deneyimi/kötüye kullanımı, içe yönelimli ve/veya dışa yönelimli eşlik eden bozukluklar gibi çeşitli eksikliklerle ilişkilidir [8]. DEHB'deki ana problemin, hiperaktif durum kadar zihinsel işlevlerin yetersizliğinden kaynaklandığı düşünülmektedir [9].

DEHB'nin teşhisinde özgül bir test yoktur. Teşhis, çoğunlukla klinik gözlemler ve bireyin öz raporlarına dayanır, çünkü DEHB'nin objektif bir tanı testi yoktur [10]. Bu, tanı sürecinde belirsizliğe neden olabilir ve bazen yanıltıcı veya yanlış tanılara yol açabilir [11].

Klinisyenler, dikkat dağınıklığı, hiperaktivite ve dürtüsellik belirtilerine dayanarak DEHB'yi teşhis eder ve tanı prosedürleri şunları içerir: DSM-V DEHB kriterlerinin değerlendirilmesi, bir tıbbi muayene, okuldan bilgi toplama, aile üyeleriyle yapılan görüşmeler hem ebeveynler hem de öğretmenler için Conners Derecelendirme Ölçeği gibi DEHB derecelendirme ölçekleri ve nöropsikolojik testler. Psikometrik testler DEHB teşhisi konusunda destek olabilmektedir. Ancak bu testler yalnızca DEHB teşhisi için özgül değildir [12–16].

DEHB belirtileri bireyden bireye farklılık göstermekte ve bu nedenle DEHB'nin teşhisinde klinik değerlendirme esas alınmaktadır [16]. Yıllar içinde, DEHB hakkında anlayışımız önemli ölçüde değişmiştir. İlk zamanlarda bu durum çoğunlukla erkek çocuklarında gözlenen ve disiplin eksikliği veya aşırı enerji olarak yorumlanan bir durum olarak değerlendirilirken [18] son araştırmalar DEHB'nin yetişkinlerde ve kadınlarda da yaygın olduğunu ve genetik, çevresel ve nörobiyolojik faktörlerin bir kombinasyonu tarafından oluştuğunu göstermiştir [19].

DEHB'nin tedavisinde genellikle ilaç ve davranışçı terapi kullanılır [20]. İlaç tedavisi, DEHB belirtilerini yönetmek için sıklıkla kullanılan bir yaklaşımdır ve genellikle belirtileri hafifletir [21]. Davranışsal terapiler ise öz disiplin, problem çözme yetenekleri ve sosyal becerileri geliştirmeye odaklanır [22]. Stimülanlar en etkili ilaç tedavisi olarak görülür. Ancak bireylerin tedaviye yanıtı değişkenlik gösterir ve tedavi genellikle bireye özel olarak planlanır [23]. DEHB'nin yönetiminde ayrıca yaşam tarzı değişiklikleri, eğitim destekleri ve psikososyal müdahaleler de önemlidir [24].

DEHB'nin toplumdaki yaygınlığına gelince, dünya çapında %5-7 civarında bir prevalans oranı bildirilmiştir [17,25]. Ancak tanı kriterlerindeki farklılıklar ve tanı yöntemlerinin

belirsizliđi nedeniyle, bu oranlar bölgeden bölgeye ve hatta aynı bölgedeki farklı çalışmalarda bile deđiřebilir [26].

Sonuç olarak DEHB karmařık ve geniř çapta etkileri olan bir bozukluktur. Hem bireylerin hem de toplumun genelini etkileyen bu durum, daha fazla arařtırma ve anlayıř gerektirir. Öte yandan teřhisi desteklemek ve öznel deđerlendirmeyi azaltmak veya ortadan kaldırmak için objektif deđerlendirme araçları sınırlıdır. DEHB tanısı koymak için geliřtirilmiř, uygulayıcının subjektif etkisini tamamen ortadan kaldıran, objektif aynı zamanda non-invazif bir deđerlendirme aracı henüz bulunmamaktadır.

1.4.2. Hiperaktivite Bozukluđu (HB)

HB bir önceki bařlıkta DEHB' in alt türü olarak ifade edilmiřtir. Tanısı ve toplumda görölme sıklıđı ile ilgili hususlar DEHB ile genel olarak ayrıřtırılmamaktadır çünkü DEHB tanımı içerisinde HB' yi de bulundurur. HB, DEHB içerisinde olan bir tür olup; ařırı hareketlilik, dürtü kontrolsüzlüđu olarak tanımlanmakta olan çocukluk çağında yaygın olarak görülen nöropsikiyatrik bir hastalıktır [4]. Toplumda tanı kriterlerinden bađımsız olarak tanımlanmıř önyargı içeren bir yaklařım olmakla birlikte, hiperaktivite tanısı klinisyenler tarafından konulabilmektedir. Klinisyenler psikiyatrik muayenenin yanı sıra, DSM-V tanı ölçütleri kullanarak tanı koyabilmektedir. Tanı sırasında çocuk hastalara ait öyküler aileler tarafından dile getirilmekte ve tanı ařamasını yönlendirmektedir. Deđerlendiriciyi etkileyebilen hasta öyküleri ve subjektiflik sađlayan objektif deđerlendirme için yeterli olmayan testlerle HB tanısı konulabilmektedir. Böylece hastalık düzeyi veya hastalıđın tam olarak olup olmadıđını tespit edecek veya tanıya destek olacak yardımcı sistemlerin bulunmaması nedeniyle objektif bir řekilde tanı konulması oldukça zordur.

1.4.3. Hareket Algılama

Hareket algılama teknolojileri son yıllarda büyük ilerlemeler göstermiřtir. İvmeölçerler, jiroskoplar ve manyetometreler gibi non-invazif sensörler bireylerin hareketlilik düzeylerini anlama ve deđerlendirme konusunda artan bir řekilde kullanılmaktadır [27]. Hareketlilik analizi bireylerin günlük yařam aktivitelerinin ve fiziksel performansının ölçölmesi ve deđerlendirilmesi sürecini kapsar. Bu süreç hareketlerin sayısal veriye

dönüştürülmesi ve bu verilerin analizi için çeşitli sensörlerin kullanılmasını gerektirir [28].

İvmeölçerler bir cismin hızlanma özelliklerini ölçerken jiroskoplar dönen bir cismin eksen etrafındaki açısal hızını ölçer. Manyetometreler bir cismin yerçekimi ve manyetik alan etkisi altında döndüğü yöne dair bilgi sağlar [29]. Bu sensörler bir araya getirildiğinde karmaşık hareketlerin üç boyutlu bir şekilde analiz edilmesi ve yorumlanması yeteneğine sahip olurlar [30].

Hareket algılama sensörleri fiziksel hareketlerin analizi ve tespiti için geniş bir uygulama yelpazesine sahiptir. Sağlık hizmetleri alanında hastaların ve sporcuların hareketliliğini değerlendirmek için giderek daha fazla kullanılmaktadırlar. Hareket algılama özellikle yaşlanan popülasyon için hareketlilik kaybını belirlemek ve düşme riskini tahmin etmek için önemli bir araç olmuştur [31].

Non-invaziv sensörler, sağlık sektöründe hızla benimsenmiştir ve hastaların hareketlilik, fonksiyon ve genel sağlık durumunu izlemek için kullanılırlar. Örneğin ivmeölçerler yürüme hızını, adım sayısını ve yürüme süresini ölçmek için kullanılırken jiroskoplar bir kişinin yürüyüş kalıplarındaki değişiklikleri ve dengesini tespit etmek için kullanılabilir [32].

Spor bilimleri alanında sporcuların performansını değerlendirme ve iyileştirme amacıyla da hareket algılama teknolojileri kullanılmaktadır. Bir atletin koşu biçimini analiz etmek yaralanma riskini azaltmak ve performansı artırmak için koşu formunu düzeltme fırsatları sunabilir [33]. İvmeölçerler ve jiroskoplar, koşu, yüzme, bisiklete binme gibi sporlarda hareketlerin detaylı analizini sağlayabilir. Ayrıca bir kişinin hareket kalıplarını ve performansını analiz etmek için kullanılmaktadırlar [34].

İvmeölçerler, jiroskoplar ve manyetometreler gibi non-invaziv sensörler, bireylerin hareketlilik düzeylerini anlama ve değerlendirme konusunda önemli bir role sahiptir. Bu sensörler, hareket analizi ve değerlendirmesinin yapılması konusunda büyük bir etkiye sahiptirler. Bu alanda yapılan çalışmalarda yaygın olarak kullanılmaktadırlar [35]. Ayrıca çeşitli vücut hareketlerinin ve fizyolojik sinyallerin eldesi için non-invaziv sensörler birçok farklı sektörde ve uygulamada önemli bir rol oynar. Gelecekte, bu sensörlerin daha

da yaygınlaşacağı ve daha geniş bir uygulama yelpazesinde kullanılacağı öngörülmektedir [36].

Tez çalışması kapsamında vücut üzerine non-invazif bir biçimde yerleştirilen hareket bilgisini algılayabilecek sensörler ile bireyin günlük hayatında ne kadar hareketli olduğu bilgisi kaydedilerek daha sonra veri analizi ve sinyal işleme çalışmaları ile sağlıklı ve hasta bireylerin ayırt edilebilmesi için çalışmalar ortaya konulmuştur. Çalışmanın detayları Materyal ve Metod bölümünde açıklanmaktadır.

1.4.4. Jiroskop

Jiroskoplar günümüzde teknolojik inovasyonun öncülerinden biri olmuştur. Çeşitli alanlarda çığır açan uygulamaları sayesinde yaygın kullanım alanlarına sahiptir [37]. Farklı ölçeklerde karmaşık sistemlerin rotasyonel hareketlerini ölçmede vazgeçilmez bir araç olan jiroskoplar temel prensiplerini açısal momentum yasalarından alır [38].

Jiroskoplar çevresel kuvvetlere karşı açısal hızlarını koruma özelliği olan cihazlardır. Bu çevresel hareketlerden bağımsız olarak sabit bir rotasyonel eksen sağlar. Bu özellik dönen bir disk veya tekerlek kullanılarak başlangıçta uygulanmış olsa da günümüz jiroskopları genellikle optik veya halka lazer jiroskopları gibi daha hafif ve daha az bakım gerektiren cihazlardır [39].

Jiroskoplar son yıllarda büyük teknolojik gelişmeler sayesinde çok çeşitli uygulamaları kapsayan geniş bir alanda kullanılmaktadır. Özellikle navigasyon sistemlerinde stabilite kontrolünde ve hareket algılama cihazlarında yaygın olarak kullanılırlar [40]. Örneğin jiroskoplar akıllı telefonlarda ve video oyun kontrol cihazlarında hareketi algılamak için kullanılır. Ayrıca uçaklarda ve gemilerde de navigasyon ve stabilite kontrolü için kullanılırlar [41].

Son yıllarda MEMS (Micro-Electro-Mechanical Systems) teknolojisinin gelişmesi jiroskop teknolojisinin daha küçük boyutlarda üretimini sağlamış ve genel kullanımını büyük ölçüde etkilemiştir. Bu teknoloji jiroskopları daha küçük, daha hafif ve daha az enerji tüketen cihazlar haline getirirken aynı zamanda hassasiyetlerini ve güvenilirliklerini artırmıştır [42]. Bu gelişmeler, jiroskopların çok çeşitli taşınabilir elektronik cihazlarda kullanılmasını mümkün kılmıştır.

Jiroskoplar çeşitli endüstrilerde kritik bir bileşen haline gelmiştir ve önemleri gün geçtikçe daha da artmaktadır. Teknolojik ilerlemeler sayesinde, jiroskopların gelecekte daha da etkili hale geleceği öngörülmektedir.

1.4.5. İvmeölçer

İvmeölçerler bir cismin ivmesini ölçme yetenekleri ile modern teknolojinin önemli bir parçasıdır. Bu cihazların arabalardan kişisel sağlık asistanı uygulamalara kadar birçok kullanım alanı bulunmaktadır. Sağlık izleme sistemi aktivite takibi ve rotasyon planlaması gibi bir dizi farklı uygulama için kullanılmaktadır [43].

İvmeölçerler, cisimlerin ivmesini ölçmek için kullanılan sensörlerdir. İvmeölçerler, genellikle bir kütlenin ivmeyle hareket etmesine neden olan bir kuvveti ölçer. Bu ölçüm, genellikle elektrik sinyaline dönüştürülür ve sonuç olarak ivme değeri elde edilir [44].

İvmeölçerler bir dizi farklı alanda kullanılır. Örneğin otomobillerde ve uçaklarda aracın hareket yönünü ve hızını belirlemek için kullanılır. Ayrıca, depremleri algılamak ve kaydetmek için kullanılan sismometrelerde de bulunurlar [45].

Sağlık alanında ivmeölçerler hasta izleme ve rehabilitasyon uygulamalarında kullanılır. Bu cihazlar hastaların fiziksel aktivitelerini ve hareketlerini izlemek için kullanılabilir. Ayrıca ivmeölçerler hasta ve sağlıklıların hareketlerini ve ilerlemelerini izlemek için de kullanılabilir [46].

Akıllı telefonlarda ve tabletlerde ivmeölçerler cihazın yatay veya dikey konumunu belirlemek için kullanılır. Bu ekranın döndürülmesini sağlar [47]. Ayrıca, oyunlar ve diğer uygulamaların hareketle etkileşim kurmasına olanak sağlar.

İvmeölçerler bir dizi farklı teknolojiye ve uygulamada hayati bir role sahiptir. İnsanların ivmelerini hassas bir şekilde ölçme yetenekleri aktivitelerini tanımlamaya yardımcı olmakta ve böylece onları sağlık alanında bir dizi farklı uygulama için ideal bir seçenek yapmaktadır [48].

1.4.6. Manyetometre

Manyetometreler manyetik alan yoğunluğunu ve yönünü ölçen cihazlardır [49]. Bu cihazlar elektronik navigasyon, jeoloji, arkeoloji ve uzay bilimleri gibi bir dizi farklı

disiplinde önemli bir rol oynar. Son yıllarda manyetometrelerin biyomedikal ve sanal gerçeklik gibi uygulama alanları da bulunmaktadır.

Manyetometreler temelde manyetik alanların özelliklerini ölçen hassas cihazlardır. Ölçüm prensipleri ve hassasiyetleri kullanılan manyetometre türüne bağlıdır [50]. Çeşitli manyetometre tipleri bulunmaktadır. Vektör manyetometreler ve toplam alan manyetometreleri ve bunların alt türleri olarak genel olarak sınıflandırılabilir [51].

Biyomedikal uygulamalar manyetometrelerin gelişen kullanım alanlarından biridir. Örneğin Manyetoensefalografi (MEG) yaşayan insan beynindeki nöral aktiviteyi non-invazif bir şekilde görüntülemeyi sağlar. Yüksek zaman ve konum çözünürlüğüne sahip olan MEG cihazları nöronlarda akan elektrik akımının ürettiği zayıf manyetik alanları tespit edebilmektedir [52].

Sanal gerçeklik bir başka önemli manyetometre uygulama alanıdır. Sanal gerçeklik cihazları genellikle kullanıcıların baş hareketlerini izlemek için manyetometreleri kullanır. Bu cihazlar kullanıcının sanal bir ortamda fiziksel olarak hareket yönünü algılamayı sağlamaktadır [53].

Manyetometreler manyetik alanları tespit ederek konum ve hareket yönü gibi hususlarda bilgi edinmemizi sağlamaktadır.

1.4.7. Fizyolojik Sinyaller

Fizyolojik sinyaller vücut fonksiyonlarının ölçümünü temsil eder. Bu sinyaller genellikle sinir, kas ve diğer hücreler tarafından oluşturulan elektriksel sinyallerdir. EKG, EEG, EOG, GDC, nabız vb. gibi çeşitleri bulunmaktadır [54].

Fizyolojik sinyaller genellikle zamanla değişen durağan olmayan elektriksel dalgalanmalardır. Bu sinyaller, vücut fonksiyonlarını ve aktivitelerini yansıtır [55]. Sinyallerin genliği ve frekansı genellikle ölçülen fizyolojik süreçler hakkında değerli bilgiler sağlar [56].

Fizyolojik sinyaller biyomedikal araştırma ve klinik uygulamalar için vazgeçilmez bir araçtır. Vücut işlevlerinin zamanla nasıl değiştiğini anlamak için kullanılmaktadır.

Fizyolojik sinyaller sağlık durumunun değerlendirilmesinde ve tedavi kararlarında kritik bir rol oynamaktadır.

1.4.8. EKG ve Nabız

EKG kalp hücrelerinin oluşturduğu elektriksel aktivitenin kaydedilmesi işlemidir [57]. EKG kalbin normal ve anormal fonksiyonlarının değerlendirilmesinde kullanılan kritik bir araçtır. Kalpteki iletim ve ritim bozuklukları EKG üzerinde değerlendirilebilir. Her kalp atışı kalp hücrelerinin bir depolarizasyon ve repolarizasyon döngüsü boyunca elektriksel değişiklikler üretmesiyle oluşur. Bu değişiklikler yani EKG sinyalleri elektrotlar aracılığıyla yakalanır ve EKG cihazı tarafından işlenerek bir çizgi grafiği üretilir. Bu çizgi grafiği kalbin farklı bölgelerinin birbirini izleyen depolarizasyon ve repolarizasyon dalgalarını yansıtır [58]. Elektrotlar vücudun belirli bölgelerine yerleştirilir ve kalpten gelen elektriksel sinyalleri algılar. Bu sinyaller amplifikatörler tarafından güçlendirilir ve kâğıda veya dijital bir görüntüye dönüştürülür [59].


EKG'nin temel bileşenleri P dalgası, QRS kompleksi ve T dalgasıdır. P dalgası atriyumların (kalbin üst odaları) depolarizasyonunu; QRS kompleksi ventriküllerin (kalbin alt odaları) depolarizasyonunu; T dalgası ise ventriküllerin repolarizasyonunu (iyileşme) gösterir [60].

EKG'nin kullanımı birçok farklı kalp rahatsızlığını teşhis etmek için kullanılır. Örneğin anormal kalp ritimleri (aritmiler), kalp krizi belirtileri ve kalbin yapısındaki değişiklikler [61]. EKG ayrıca kalp hastalığı risk faktörlerinin değerlendirilmesi ve mevcut tedavi rejimlerinin izlenmesi için de kullanılır [62]. EKG kalbin elektriksel aktivitesinin non-invaziv ve doğru bir şekilde izlenmesini sağlar. Bu da sağlık uzmanlarına hastaların kardiyovasküler sağlık durumları hakkında önemli bilgiler verir. Bu yöntemin kullanımı hastaların kardiyovasküler rahatsızlıklarının erken teşhisini ve etkili tedavisini sağlar [63].

Nabız hızı dakikadaki kalp atışlarının sayısıdır ve genellikle kalp hızını belirlemek için kullanılır [64]. Nabız, kalbin her atışında kanın damarlar boyunca itilmesiyle hissedilen ritmik dalgalanmalardır [65]. Nabız hızı genellikle dakikadaki kalp atış sayısını belirtmektedir. Nabız genellikle bilekte veya boyunda manuel olarak ölçülür. Ancak elektronik cihazlar da nabız hızını ölçmek için kullanılabilir. Sağlıklı bir yetişkinin

dinlenme nabız hızı genellikle dakikada 60-100 atış arasındadır [66]. EKG kalp hızını doğru bir şekilde belirlemede nabız hızı ölçümüne ek olarak önemli bir araç haline gelir [67].

EKG de bulunan QRS kompleksi kalp hücrelerinin ventriküllerde (kalbin alt odaları) uyarıldığı ve kasıldığı andan itibaren oluşur [68]. Nabız ise kalbin kasılma aktivitesinin bir sonucudur. Her kalp atışında ventriküller kasılır ve kanı aorta ve pulmoner arterlere pompalar. Bu kan akışı arterler boyunca hareket eder ve sonunda arter duvarlarında basınç dalgalanmalarına neden olur. Bu dalgalanmalar nabız olarak algılanır [69]. Bu nedenle her normal QRS kompleksi genellikle bir nabız atımına karşılık gelir. Ancak bazı durumlarda özellikle ciddi aritmi veya kalp yetmezliği gibi durumlarda her QRS kompleksi bir nabza karşılık gelmeyebilir [70]. Kalp açısından sağlıklı bir insanda nabız dakikadaki QRS sayısı olarak değerlendirilebilir. EKG sinyali ve sinyalden nabız tespitine ilişkin görsel Şekil 1.1’de görülebilir.



Şekil 1.1. EKG sinyali ve nabız tespitine ilişkin görsel

1.4.9. GDC

GDC veya diğer bir deyişle Elektro Dermal Aktivite (EDA) derinin elektriksel iletkenliğinin bir ölçüsüdür ve insan sempatik sinir sistemindeki değişikliklerin bir göstergesini sağlayabilmektedir [71]. Bu durum derideki ter bezlerinin aktivitesindeki


değişikliklerle ilişkilidir. Çünkü ter iletken bir sıvıdır ve bu yüzden terleme miktarındaki değişiklikler derinin iletkenliğinde değişikliklere yol açar [72].

İnsan vücudunda ekrin ve apokrin olmak üzere iki tür ter bezi bulunmaktadır. Apokrin ter bezleri özellikle koltuk altı ve genital bölgelerde bulunur. Bu bezler daha çok hormonal etkilere yanıt olarak aktive olurlar ve GDC' nin daha az yaygın bir bileşenini oluşturur [73]. GDC de ağırlıklı olarak etkin olan bileşen ekrin ter bezleridir. Ekrin ter bezlerinin termal uyaranlardan çok psikolojik uyaranlara karşı duyarlı olduğuna yönelik çalışmalar bulunmaktadır. Ter bezlerinde sempatik sinir sisteminin aktivasyonuna bağlı olarak ter miktarı ve ter bezi sayısı değişir. Ter, bez kanallarını doldurdukça normalde dirençli olan cilt yüzeyinde daha iletken bir yol oluşturur. Terin yüksekliği arttıkça bu yolu oluşturan direnç azalır. Kanallardaki ter seviyesindeki değişiklikler bu direnç değerlerini değiştirir ve bu da GDC de gözle görülür değişikliklere yol açar. İnsan ter bezlerini sempatik sinir sistemi kontrol etmektedir ve bu kontrol mekanizması aynı anda hem sinir aktivitesini ölçen hem de GDC veya diğer bir deyişle EDA' yı kaydeden çalışmalarla kanıtlanmıştır. Normal oda sıcaklığı ve vücut ısı düzenlemesi durumlarında sempatik sinir aktivitesi ve cilt iletkenlik yanıtları (skin conductivity responses -SCRs) arasında yüksek bir ilişki bulunmuştur [74].

GDC çeşitli ölçüm ve psikofizyolojik araştırmaların çeşitli alanlarında uygulanır. Örneğin yalan dedektörü amacıyla da kullanılan poligraf testleri GDC' yi bir ölçüm bileşeni olarak kullanır [75].

Ayrıca GDC duygusal yanıtların, stres seviyelerinin ve hatta belirli psikiyatrik bozuklukların ölçülmesi için de kullanılabilir. Bu uygulamalar depresyon, anksiyete bozuklukları ve posttravmatik stres bozukluğu gibi durumların tedavisinde önemli bir rol oynayabilir [76].

GDC vücudumuzun belirli psikolojik ve fizyolojik durumlara yanıt olarak nasıl tepki verdiğini anlamak için önemli bir araçtır. Bu fenomen insan duygusal yanıtını, stresi ve hastalığı anlamada ve ölçmede değerli bir araç olmuştur. GDC sinyaline ilişkin görsel Şekil 1.2' de sunulmuştur.



Şekil 1.2 GDC sinyali

1.4.10. EOG

EOG insan gözünün elektriksel aktivitesini ölçmek için kullanılan bir yöntemdir. EOG yaklaşık kırk yıl önce göz hareketlerinin kaydedilmesi için en yaygın olarak kullanılan bir yöntemdi ve bugün hala kullanılmaktadır. Bu yöntem göz çevresine yerleştirilen elektrotlar aracılığıyla cilt üzerindeki elektriksel potansiyel farklılıkların ölçülmesine dayanmaktadır [77].

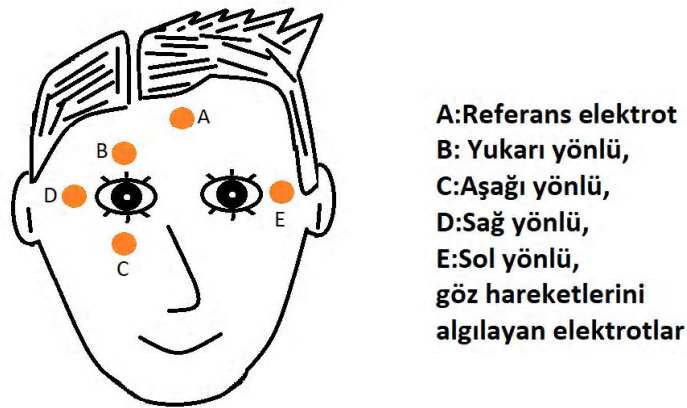
EOG göz küresinin ön (kornea tarafından oluşturulan pozitif kutup) ve arka (retina tarafından oluşturulan negatif kutup) bölümü arasındaki elektriksel potansiyel farkı ölçen bir tekniktir. Bu özellik göz hareketlerinin ve göz kırpmalarının tespiti için kullanılabilir. Gözlerin doğrudan odaklanması durumunda gözlerin çevresine konumlandırılan elektrotlar tarafından sabit bir temel potansiyel kaydedilir. Genellikle gümüş-gümüş klorür elektrotlar (Ag-AgCl) kullanılır. Potansiyelin maksimum seviyede ölçülebilmesi için elektrotların gözlere olabildiğince yakın yerleştirilmesi gerekmektedir. Gözlerin hareketi esnasında kutupların elektrotlardan uzaklaşması veya onlara yaklaşmasıyla birlikte bir potansiyel değişikliği gözlemlenir. Bu değişikliğin yönü gözlerin hareket yönüne bağlıdır. EOG ölçümleri kas potansiyelleri veya kablolar ve çevresel elektrik hatlarından kaynaklanan küçük elektromanyetik gürültüler gibi faktörler tarafından etkilenebilir [78].

EOG ölçümleri genellikle milivolt (mV) cinsinden genlik değerleri ile ifade edilir. Standart bir EOG sinyali genellikle 0.05 mV ila 3.5 mV arasında bir genlik değerine sahiptir [79]. EOG sinyallerinin frekans bandı çok düşüktür. Genellikle 0 Hertz (Hz) den 10 Hz'e kadar değişir [80]. Çünkü göz hareketlerinin hızı genellikle bu frekans bandı içinde değişir.


EOG göz hareketlerini ölçen bir teknik olduğu için birçok uygulama alanı vardır. Bu teknik genellikle çeşitli araştırmalar, insan bilgisayar ara yüzü uygulamalarında ve klinik çalışmalarda kullanılır. Örneğin EOG teknolojisi uyanıklığı ve dikkat seviyesini belirlemek için kullanılabilir. EOG sinyalleri sürücülerin uyanıklık seviyelerini izlemek ve sürüş sırasında dikkat dağılmasını belirlemek için kullanılabilir [81].

Bunun yanı sıra EOG kullanıcının göz hareketlerini izleyerek bilgisayarların ve diğer elektronik cihazların kontrol edilmesine olanak sağlayan bir insan-bilgisayar etkileşimi teknolojisi olarak kullanılmaktadır. Örneğin tekerlekli sandalye kullanıcıları EOG teknolojisi yardımıyla tekerlekli sandalyelerini kontrol edebilmektedir [82].

Şekil 1.3'te EOG elektrotlarının kafa yüzeyine bağlantı noktaları gösterilmiştir. Şekil 1.4'te ise yatay elektrotlar ile (Şekil 1.3'te D ve E elektrotları) elde edilen EOG sinyalinin göz hareketleri ile ilişkisinin grafik olarak gösterimi yer almaktadır.



Şekil 1.3. EOG elektrotları bağlantı şekilleri



Şekil 1.4. Göz hareketi ile EOG sinyali ilişkisi

1.4.11. EEG

EEG beyindeki nöronların aktiviteleri sonucunda ürettikleri elektriksel sinyallerin ve voltaj değişimlerinin kişinin kafa yüzeyine yerleştirilen elektrotlar aracılığıyla izlenmesi ve kaydedilmesi işlemidir. Non-invaziv bir yöntem olan EEG beyin aktivitesini uzun süre boyunca kayıt altına alabilir ve sinyalleri ölçebilir. Dolayısıyla EEG beyin aktivitesine bağlı sağlık problemlerinin teşhisinde analiz amaçlı kullanılır. EEG bir kişinin beyin nöral aktivitesi ile ilgili veriler sağlar [83]. Bu veriler nöroloji, biyomedikal mühendislik ve beyin-bilgisayar ara yüzeyi çalışmaları gibi araştırma alanlarında kullanılır. EEG'nin düşük maliyetli ve invaziv olmayan bir yöntem olması birçok nöroloji çalışması için onu önemli bir veri kaynağı yapmaktadır [84].

EEG sinyalleri beyindeki düşünme, algılama ve duygusal yanıtlar gibi çeşitli fonksiyonları kontrol eder. EEG' nin en yaygın uygulamalarından biri beyin farklı bölgelerinde oluşan elektriksel aktivitenin kaydedilmesidir. Bu genellikle hastanın kafasına yerleştirilen ve deriden elektriksel aktiviteyi kaydeden bir dizi elektrot ile yapılır [85]. Bu kayıtlar genellikle bir bilgisayara kaydedilir ve daha sonra analiz edilir.


EEG sinyallerinin genlik ve frekansı beynin farklı aktivite düzeylerini yansıtır. Genlik bir EEG sinyalinin 'yüksekliği' veya 'derinliği' olarak tanımlanabilir ve genellikle mikrovolt (μV) cinsinden ölçülür. Frekansı ise bir sinyalin 'hızı' olarak tanımlanır ve genellikle Hz cinsinden ölçülür. EEG sinyali genliği genel olarak 10 – 200 μV aralığındadır. EEG sinyalleri genellikle beş ana frekans bandına ayrılır: Delta (0.5-4 Hz), Teta (4-8 Hz), Alfa (8-14 Hz), Beta (14-30 Hz) ve Gama (30 Hz ve üstü) [86]. Her bir frekans bandı belirli bir beyin durumunu veya aktivitesini temsil eder. Örneğin delta dalgaları genellikle derin uyku sırasında, teta dalgaları ise hafif uyku sırasında gözlenir. Alfa dalgaları genellikle rahatlama ve huzur hallerinde, beta dalgaları ise aktif düşünme veya konsantrasyon durumlarında görülür. Gama dalgaları ise genellikle yüksek seviye bilgi işleme aktiviteleri ile ilişkilidir [87].

EEG sinyallerinin ölçümü ve analizi bir dizi farklı teknik ve araç gerektirmektedir. Bunlar genellikle zaman ve frekans alanındaki analizler, istatistiksel analizler, dalgacık dönüşümleri gibi hesaplamaları içerir [88].

EEG sinyallerinin kayıt işlemleri sırasında elektrotların hastanın kafasına nasıl yerleştirileceği konusunda standart uygulamalar bulunmaktadır. Bu standart genellikle 10-20 sistem olarak adlandırılır ve en yaygın kullanılan elektrot yerleştirme sistemi olarak kabul edilir. 10-20 sistemine göre elektrotlar kafa yüzeyine 19 farklı konuma yerleştirilir. Bu konumlar, frontal (ön), temporal (yan), parietal (üst, arkaya doğru) ve occipital (arka) bölgeleri kapsar. Her bir elektrot yerleştirme noktası, bulunduğu konumu ve sırasını belirtmek için belirli bir harf ve numara kombinasyonu ile adlandırılır. Örneğin, "F" frontal bölgeyi, "T" temporal bölgeyi, "P" parietal bölgeyi, ve "O" occipital bölgeyi temsil eder. Sağ ve sol hemisferler arasındaki simetriyi belirtmek için numaralar kullanılır; tek numaralar sol hemisferi, çift numaralar ise sağ hemisferi temsil eder [89].


10-20 sistemi elektrotların kafatası üzerinde belirli noktalara yerleştirilmesini önerir. Bu noktalar kafatasının ölçümlerine dayanır ve elektrotların birbirine olan uzaklıkları genellikle kafatasının toplam uzunluğunun veya genişliğinin %10 veya %20'si kadardır. Bu sistem farklı bireyler arasında elektrot yerleştirme konumlarının tutarlı olmasını sağlar ve araştırmacıların elde ettikleri verileri karşılaştırabilmelerine olanak tanır [90].

10-20 sistemi EEG sinyallerinin kaydedilmesinde standart bir yaklaşım sağlamaktadır. Bu sayede farklı çalışmalar ve hasta grupları arasında sonuçların karşılaştırılabilir olması mümkün kılınmaktadır.



Şekil 1.5. EEG 10-20 standardına göre elektrot yerleşimi [183]

Şekil 1.5’ te 10-20 standardına göre elektrotların yerleşimleri görülmektedir. Aşağıda Şekil 1.6’ da ise bu standarda göre kayıt gerçekleştirilmiş bir EEG sinyali görülmektedir.



Şekil 1.6. 19 kanal EEG sinyali örneği

1.5. Literatür Araştırması

Tez çalışması kapsamında gerçekleştirilen tüm çalışmalar için yapılan literatür taraması aşağıda sunulmuştur. Literatür taraması farklı konu başlıkları içermektedir. Çünkü tez içeriği bir çok konudan oluşmakta olup hareket tespiti, fizyolojik sinyaller, ivmeölçer, jiroskop sensörleri, DEHB gibi tez içeriğinde bulunan tüm konuları içeren farklı konu başlıkları altında literatür taraması gerçekleştirilmiştir.

Hareket tespiti ve çeşitli fizyolojik sinyallerin tespiti için giyilebilir cihazlara ve bunların uygulamalarına yönelik yapılan literatür taraması aşağıda sunulmuştur.

- Yeon Hwa Kwak ve arkadaşları giyilebilir cihaz için esnek kalp atışı sensörü üzerine bir çalışma yapmışlardır. Esnek bir gerilim ölçer sensörünün kalp atış hızı tespiti için giyilebilir bir uygulamada kullanıldığını göstermişlerdir. Bu polimer bazlı gerilim ölçer sensörü, polimer ve metal, yani poliimid ve nikel-krom ile çift taraflı bir imalat yöntemi kullanılarak imal edilmiştir. Bu gerilim ölçer sensörü için imalat işlemi, ticari hale getirilmesini kolaylaştıran geleneksel esnek baskılı devre kartı işlemleriyle uyumlu olduğu belirtilmiştir. Üretilen sensör, minimum 6,25 Pa algılanabilir kuvveti olan, 930 kPa'dan daha fazla uygulanan normal bir kuvvet için doğrusal bir ilişki göstermiştir. Bu sensör ayrıca 5 mm ila 100 mm arasında bir bükülme yarıçapını doğrusal olarak da tespit edebilmektedir. Oluşturulan optik fotopletismografi (PPG) sensörlerine kıyasla oldukça hassas olan ince, esnek, kompakt ve ucuz (seri üretim için) kalp atış hızı algılama sensörü olduğu belirtilmiştir. Sadece kalp nabzının zamanlamasını değil, aynı zamanda nabız sinyalinin genliğini veya şeklini de algılayabileceği ifade edilmektedir. Önerilen gerilim ölçer sensörünün kalp atışı algılaması gerektiren akıllı cihazlar için çeşitli uygulamalara uygulanabileceği belirtilmiştir [91].
- Yafei Yin ve arkadaşları insan cildine entegre esnek giyilebilir elektronik cihazların termal yönetimi üzerine çalışma yapmışlardır. Esnek giyilebilir elektronik cihazlar, kıyafetle kaplanacak olan insan vücudunun hayati belirtilerini izlemek için doğrudan insan derisine entegre edilebilir. Kıyafet etkisi dikkate alınarak insan derisi ile bütünleşmiş esnek giyilebilir elektronik cihazları incelemek için analitik bir model geliştirilmiştir. Pennes biyo-ısı transferi denkleminin ve Fourier ısı iletimi denkleminin eşleştirme modeli, tüm sistemin

termal davranışını göz önüne almak için benimsenmiştir. Giysiler, çevre sınırları arasında konveksiyon, iletim ve radyasyon dahil olmak üzere karmaşık sınır koşullarında giysi liflerinden ve havadan oluşan bir tür kompozit malzeme olarak modellenmiştir. Sistemin öngörülen analitik sıcaklık dağılımı, sonlu elemanlar analizi ile doğrulanır. Sistematik parametrelerin karakteristik sıcaklıklar üzerindeki etkileri, yani elektronik bileşenin sıcaklığı ve cihaz / cilt ara yüzündeki maksimum sıcaklık, ısı dağılımının tasarımı ve giysi etkisinin tartışılması için kapsamlı bir şekilde araştırılmaktadır. Sunulan sonuçların, gerçek çalışma koşullarında esnek giyilebilir elektronik cihazların termal yönetimi için kılavuzluk sağlayabileceği değerlendirilmektedir [92].

- Shitong Huang ve arkadaşları giyilebilir EKG cihazlarıyla zihinsel yorgunluk durumunun tespiti üzerine çalışma yapmışlardır. Serebrovasküler / kardiyovasküler hastalıklar (CCVD) gibi aşırı işle ilgili bozukluklar ve fazla çalışmayla ilgili zihinsel bozukluklar, özellikle Doğu Asya ülkelerinde dünya çapında önemli bir meslek ve halk sağlığı sorunudur. Giyilebilir akıllı cihazlar günümüzde ucuz, kullanışlı, popüler ve yaygın olarak bulunabildiğinden, zihinsel yorgunluk durumunu saptamak için giyilebilir akıllı EKG cihazları kullanma olasılığını araştırmakla ilgilenilmiştir. Toplamda, 35 sağlıklı katılımcı üzerinde Doğu Çin'deki bir devlet üniversitesinde çalışılmıştır. Tüm deney boyunca, her bir katılımcı Bluetooth iletimini temel alan verileri yüklemek için bir akıllı telefona bağlanmış giyilebilir bir cihaz takmıştır. Yorgunluk durumunu değiştirmek için her katılımcıdan yaklaşık 80 dakika süren bir sınavı bitirmeleri istenmiştir (30 mantıksal referans ve hesaplama problemleri ve 25 hafıza testi). Sekiz kalp atış hızı değişkenliği (HRV) göstergeleri, yani NN.mean (normal ile normal aralığın ortalaması), rMSSD (ardışık farkların kök ortalama karesi), PNN50 (NN50'nin toplam NN sayısına bölünmesi oranı), TP (toplam spektral güç), HF (0.15 Hz'den 0.4 Hz'e kadar yüksek frekans), LF (0.04 Hz'den 0.15 Hz'e kadar düşük frekans), VLF (0.0033 Hz'den 0.04 Hz'e kadar çok düşük frekans) ve LF / HF oranı aralıklarla toplanmıştır. Tüm deney boyunca minimum özellik seçimi yapıldıktan sonra, NN.mean, rMSSD, PNN50, TP, LF ve VLF olan diğer analizler için altı gösterge kalmıştır. Dört algoritma, destek vektör makinesi (SVM), K-en yakın komşu (KNN), Navie Bayes (NB) ve lojistik regresyon (LR) yorgunluk durumunu otomatik olarak tespit eden sınıflandırıcıları oluşturmak için

kullanılmış olup en iyi performans % 75,5 doğruluğa sahip olan KNN ile sağlanmıştır. NN.mean, PNN50, TP ve LF zihinsel yorgunluk tespiti için en önemli HRV göstergeleri olarak tespit edilmiştir. KNN dört algoritma arasında en iyi sonucu vermiş olup olası özellik kombinasyonlarının tümü için % 65,37 ortalama hassasiyete ulaşmıştır [93].

- Timo Sztyler ve arkadaşları giyilebilir cihazlarla pozisyona bağlı aktivite tanıma üzerine çalışma yapmışlardır. Giyilebilir cihazlarla güvenilir insan etkinliği tanıma, insan merkezli yaygın uygulamaların geliştirilmesini sağlamaktadır. Cihaz pozisyonunun kullanıcıya bağlı olduğu veya bir kullanıcının ilk eğitim verilerini toplayamadığı gerçek yaşam durumları için sağlam bir giyilebilir tabanlı aktivite tanıma sistemi geliştirilmesi amaçlanmıştır. Sonuç olarak bu çalışmada ivme ölçer verilerine dayanan konuya özel ve çapraz konulara yönelik aktivite tanıma yaklaşımlarına ilişkin kapsamlı deneyler ile giyilebilir cihazın vücuttaki pozisyonunu tanıma sorununa odaklanılmıştır. % 89'luk bir F ölçüsü ile vücut üstü pozisyonunu öngören bir cihaz lokalizasyonu yöntemi ve ortak fiziksel özellikleri göz önünde bulunduran bir çapraz aktivite tanıma yaklaşımı sunulmuştur. Bu bağlamda 15 katılımcıdan farklı vücut pozisyonlarında 7 giyilebilir cihaz taşıdıkları 8 ortak etkinlik için toplanan gerçek bir veri seti sunulmuştur. Sonuçlar cihaz konumunun tespit edilmesinin, ortak aktiviteler için aktivite tanıma sonucunu sürekli olarak iyileştirdiğini göstermektedir. Çapraz konular modellerinde belde birkaç kişi için aynı aktivite için hızlanma modellerinin en benzer olduğu en uygun cihaz yeri olarak tanımlanmıştır [94].
- Tetsuya Akagi ve arkadaşları gömülü kontrolör kullanılarak düşük maliyetli akıllı giyilebilir hareket algılama cihazı geliştirilmesi üzerine çalışmışlardır. Giyilebilir cihazların hasta bakımı ve rehabilitasyondaki önemi bilinmektedir. Çalışmanın amacı giyilebilir bir hareket sensörü geliştirmektir. Önceki çalışmalarında “Cilt Yer Değiştirme Sensörü” test edilmesi önerilmiştir. Bu “Cilt Yer Değiştirme Sensörü” cildin yer değiştirmesini ölçerek insan vücudunun hareketini ölçebilmektedir. Bu çalışmada ofset sinyali cilt yer değiştirme sensöründen ve amplifikasyon faktöründen otomatik olarak ayarlayabilen ucuz bir akıllı giyilebilir hareket algılama cihazı önerilmiş ve test edilmiştir. Ek olarak test edilen cihaza kablosuz bir iletişim cihazı monte edilmiştir [95].

- Eleonora Mencarini ve arkadaşları spor sırasında giyilebilir cihazlar tasarlama konusunda tırmanış sporu üzerine bir vaka çalışması yapmışlardır. Bu çalışmada yüksek fiziksel, duygusal ve bilişsel katılım gerektiren bir spor olan kaya tırmanışı için giyilebilir bir cihazın ortak tasarım süreci sunulmuştur. Dağcılarının ihtiyaçlarının ön araştırmasından temel olarak öz yeterlilik, güven ve macera gibi spora özgü değerlerin tırmanışı etkilediği ortaya çıkmıştır. Bu tür değerler teknolojinin işlevsel amacının ötesinde giyilebilir cihazların dağcılarını nasıl desteklemesi gerektiğini vurgulamaktadır. Bu görüşlere dayanarak eğitmen ve stajyerler arasındaki iletişimi güçlendirmeyi amaçlayan ve tırmanış dersinde kullanışlılığını ve kullanılabilirliğini değerlendiren bir vibrotaktil giyilebilir cihaz tasarlanmış ve uygulanmıştır. Uygulanan giyilebilir cihazın, dağcılarının ihtiyaçlarından ortaya çıkan tasarım kriterlerini nasıl karşıladığını tartışan ve genel olarak spor için giyilebilir cihazların tasarımına yeni bir bakış açısı kazandıran bir çalışma ortaya çıkarılmıştır [96].
- Jinnan Zhang ve arkadaşları giyilebilir grafen kaplı fiber sensörler kullanarak sporda insan hareketlerinin izlenmesi üzerine çalışmışlardır. İnsan hareketinin izlenmesi spordaki performanslarını geliştirmek isteyen profesyonel sporcular için önemlidir. Bu çalışmada giyilebilir grafen kaplı bir fiber algılayıcı üretilmiştir. Basketbol ve futbol oynarken temel hareketlerin izlenmesi sağlanmıştır. Vücut hareketlerinin çoğu, ince hareketler bile sensör tarafından doğru bir şekilde tanımlanabilmiştir. Kaydedilen algılama verileri, çok yüksek hassasiyet ve çok geniş bir algılama aralığı göstermiştir. Ölçümler sırasında gösterilen yüksek tekrarlanabilirlik ve hızlı tepki kabiliyeti, üretilmiş sensörlerin spor hareket izleme uygulamaları için büyük potansiyele sahip olduğunu göstermiştir [97].
- Lauren C. Benson ve arkadaşları, laboratuvarın dışında yürüme ve koşma analizi için giyilebilir cihazların kullanımı üzerine sistematik bir incelemede bulunmuşlardır. Kantitatif yürüyüş analizi, patoloji, yaralanma veya diğer yürüyüş karakteristiğinin belirteçleri için yürüme ve koşu paternlerini değerlendirmişlerdir. Derleme çalışmasında laboratuvar dışı ortamlarda yürüyüş analizi için giyilebilir cihazların nasıl kullanıldığını tespit etmek amaçlanmıştır. PubMed, Medline, CINAHL, EMBASE ve SportDiscus bilimsel veri tabanları kullanılmıştır. Katılımcılar, protokoller, algılayıcılar ve analizler konusunda ilgili

her makaleden bilgi alınmıştır. Toplam 61 makale incelenmiştir (47 yürüyüş analizi, 13 koşu analizi, biri yürüyüş ve koşu dahil analiz). Retrospektif çalışmalarda benzersiz yürüme kalitesi ölçümleri üreten küçük, göze çarpmayan giyilebilir cihazlar kullanılmıştır. Sonuçlar, giyilebilir cihazların taşınabilirliği ve erişilebilirliğinin sağladığı avantajlara rağmen, gerçek zamanlı yürüyüş modellerini analiz etmek için uzun süreler boyunca, çok sayıda katılımcı arasında ve doğal yürüyüş ve koşu ortamlarında yürüyüşü izlemek için daha fazla çalışmaya ihtiyaç olduğu yönündedir. Ayrıca hareket sensörleri kullanılarak yapılan çalışmalarda, bir fiziksel hareketin farklı vücut ölçülerine sahip insanlarda benzer sensör çıktıları verebildiği vücut bölgesinin bel bölgesi olduğu tespit edilmiştir [98].

Hareket analizi, ivmeölçer, jiroskop, GDC / EDA, insan aktivitesi tanıma konuları üzerinde yapılan çalışmalar incelenmiş olup bu kapsamda literatür taraması sonucu elde edilen bazı bilgiler aşağıda sunulmuştur.

- Uyku sırasında el bileğinin elektrodermal aktivitesinin analizi üzerine bir çalışmada uyku evreleri sırasında GDC / EDA kaydı gerçekleştirilmiştir. Uykunun rem, non-rem bölümlerinde GDC / EDA kayıtlarında farklılıklar, cilt iletkenliğinde değişimler gözlenmiştir [99].
- EDA'ya dayalı psikolojik stres seviyesi tespiti üzerine bir çalışmada dinlenme halinde, otoyolda araç sürüşü sırasında ve şehir içi araç sürüşü sırasında stres seviyelerinin GDC / EDA sinyallerine dayalı olarak ayırt edilmesi çalışması yapılmış ve %81.82 lik başarı oranı elde edilmiştir [100].
- Çocuklarda hiperaktivite elektrodermal korelasyonları üzerine bir çalışmada GDC / EDA verileri hiperaktif grupta ve hiperaktif olmayan grupta incelenmiştir. Hiperaktif çocuklarda sağlıklılara göre bazal deri iletkenliğinin düşük olduğu, GDC'lerin daha az ve daha küçük olduğu bulunmuştur. Hiperaktif çocuklara uygulanan uyarıcı ilaçlar, normal çocuk seviyelerine doğru bazal düzeyde iletkenlik ve GDC aktivitesini artırma eğilimi görülmüştür [101].
- DEHB olan kızlarda EEG ve EDA üzerine yapılan bir çalışmada DEHB olan kızlarda daha düşük ortalama cilt iletkenlik seviyesi tespit edilmiştir [102].
- Akıllı telefon hareket verileri kullanarak İnsan Aktivitesi Tanıma çalışması yapılmış olup, aktivite tanımanın zorluklarını aşmak için cihazın oryantasyonu /

kalibrasyonu ve konumundaki farklılaşmaya dayalı iki katmanlı çok stratejili bir çalışma yapılmıştır. Simülasyon sonuçları, önerilen iki katmanlı çok stratejili çalışmanın etkinliğini göstermektedir [103].

- Akıllı telefon ivmeölçerinin fiziksel aktivite tanımda kullanımı araştırılmıştır. Bununla birlikte bir jiroskop ve manyetometrenin rolü hem tek başına hem de bir ivmeölçer ile birlikte kullanıldığında değerlendirilmiştir. Bu amaçla bu üç akıllı telefon sensörünün etkinlik tanımadaki rolü araştırılmıştır. Genel olarak bir ivmeölçer ve bir jiroskopun birbirini tamamladığı ve böylece tanıma sürecini daha güvenilir hale getirdiği tespit edilmiştir. Üstelik çoğu durumda, jiroskop sadece bir ivmeölçer ile birlikte tanıma doğruluğunu iyileştirmekle kalmamış, aynı zamanda tek başına kullanıldığında makul bir performans sağlamıştır. Manyetometre için sonuçların teşvik edici olmadığı belirtilmiştir. Değerlendirmelere dayanarak tüm durumlarda hangi sensörün diğerlerinden daha iyi performans gösterdiğine dair kesin bir genel açıklama yapmanın zor olduğunu gösterilmiştir. Çünkü tanıma performanslarının akıllı telefonun konumuna, seçilen sınıflandırıcıya ve tanınan etkinliğe bağlı olarak değiştiği ifade edilmiştir [104].
- Başka bir çalışmada günlük yaşam aktivitelerinin tanınması için telefonlarda bulunan ivmeölçer, jiroskop ve manyetometre sensörlerinden elde edilen verilerin birleştirilmesine odaklanılmıştır. Bu çalışmada geliştirilen sistem veri toplama, veri işleme, veri birleştirme ve yapay sinir ağları (YSA) gibi sınıflandırma yöntemlerini içermektedir. YSA' nın çoklu ayarları uygulanmış ve değerlendirilmiştir. Elde edilen en iyi doğruluğun % 89,51 olduğu görülmüştür [105].
- Bu çalışmada bir akıllı telefonda toplanan ivmeölçer ve jiroskop verileri kullanarak etkinlik tanıma görevi için iki aşamalı sürekli bir Hidden Markov modeli yaklaşımı önerilmiştir. Sınıflandırma için en uygun özellik altkümelerini belirlemek amacıyla Random Forest (RF) değişken önem ölçütlerinden yararlanılmıştır. Deneyler azaltılmış sayıda özelliğin kullanılmasıyla, önerilen yöntemin diğer sınıflandırma algoritmalarına kıyasla rekabetçi performans gösterdiğini ve % 91.76 oranında doğruluk sağladığını göstermiştir [106].
- Bu çalışmada aktivite tanımlama için ivmeölçer ve jiroskop sinyallerini kullanan cep telefonu tabanlı bir sistem önerilmiştir. Önerilen sistemi değerlendirmek için

30 gönüllünün yürüme, yatma, merdiven çıkma, oturma ve ayakta durma gibi günlük aktiviteler gerçekleştirdiği bir veri seti kullanılmıştır. Sonuç olarak jiroskoptan çıkarılan özelliklerin yürüyüş ve merdiven çıkma gibi dinamik etkinliklerin tanınması açısından sınıflandırma doğruluğunu arttırdığı gösterilmiştir [107].

- Yapılan literatür taraması sonucu HB olan çocuklarda ivmeölçer hareket verilerinin kaydedildiği bir çalışmaya rastlanmıştır [108]. Ancak bu çalışma HB tanısına yönelik bir tanı destek sistemi geliştirmek amacıyla yapılmış bir çalışma değildir. Çalışmada HB olan ve olmayan çocuklarda sadece ivmeölçer sensörü ile kayıt alınmış, alınan kayıtlarda da sadece adım sayısı ve aktivite enerji harcaması hesabı yapılmıştır. Elde edilen verilerle de istatistiksel analiz yapılmıştır. Bu çalışmanın sonucunda tanıya yardımcı bir bulgu üzerinde tartışılmamıştır.
- Bir çalışmada ivmeölçer, jiroskop verileri ve harekete dayalı çeşitli parametreler kullanılarak bir kullanıcının hareket verileriyle ağırlığını veya cinsiyetini belirlemek veya yeniden tanımlamak için bir çalışma gerçekleştirilmiştir. Bu amaçla derin otomatik kodlayıcıları eğitmek için bir çok amaçlı kayıp fonksiyonu önerilmiştir. Eğitim süreci kodlayıcının kullanıcı tarafından tanımlanabilir desenleri görmezden gelmesini düzenlemekte ve kod çözücüyü eğitim setindeki kullanıcılardan bağımsız olarak çıktığı şekillendirmeye ayarlamaktadır. Önerilen anonimleştirici otomatik kodlayıcı ile dönüştürülen 24 kullanıcının verileriyle etkinlik tanıma doğruluğunun %92'nin üzerinde ve kullanıcı tanıma doğruluğunun %7'den az olduğu bir durumda kullanışlılık ve gizlilik arasında umut vaat eden bir sonuç elde edildiği belirtilmiştir [109].
- DSA modeli ve tek eksenli bir ivmeölçer sensörü kullanılarak koşu sırasında dikey zemin kuvvetinin tahminine yönelik bir çalışma incelenmiştir. Bu çalışmada dikey yer reaksiyon kuvvetini tahmin etmek için sinir ağı modeli ve ivmeölçer kullanımı incelenmiştir. Tahminler vücut ağırlığının 0.017' sinden daha az bir ortalama karekök hatası ve 0.99' dan daha büyük bir çapraz korelasyon katsayısı vermiştir. Sonuçlar sinir ağının çarpma kuvvetini ve aktif kuvveti, farklı çalışma hızlarında 0.10 ile 0.18 vücut ağırlığı arasında değişen ortalama hatalarla tahmin edebileceğini göstermiştir [110].
- İvmeölçer verilerinden Evrişimli Sinir Ağları (Convolutional Neural Network – CNN) kullanarak gerçek zamanlı insan aktivitesi tanıma üzerine bir çalışma

incelenmiştir. Bu çalışmada kullanıcıdan bağımsız derin öğrenmeye dayalı bir yaklaşım sunulmuştur. Çalışma yerel özellik çıkarımı için CNN yapılarını basit istatistiksel özelliklerle birlikte kullanmayı önermiştir. Sonuçlar düşük hesaplama maliyetiyle manuel özellik çıkarımı mühendisliğine ihtiyaç duymadan yüksek performans elde edileceğini göstermiştir [111].

- Bir çalışmada çoklu sensör verilerinden hayvan davranışlarını çıkarmak için bir çözüm geliştirmek üzere CNN yapısı kullanılmıştır. Bu çalışmaya temelde biyomedikal 3D görüntü segmentasyonu için geliştirilen CNN ağı adapte edilmiştir. Ağ yapısı etiketli bir veri setinde test edilmiştir. Bu veri seti serbest koşan genç yeşil deniz kaplumbağaları üzerine yerleştirilen çoklu sensörler (ivmeölçerler, jiroskoplar ve derinlik kaydediciler) ile eşleştirilmiş hayvan kaynaklı video kaydedicilerden toplanmıştır. 1D verilere dayalı olarak önerilen model, yeşil deniz kaplumbağaları için altı davranış kategorisini %88 AUC skoruyla tahmin edebilmiştir. Bu çalışma deniz kaplumbağalarının davranışını belirlerken jiroskopun ivmeölçerden daha bilgilendirici olduğunu ve tasarlanan sinir ağı yapısının yalnızca ivmeölçerlerin ham verisi kullanıldığında davranışı ayırt edemediğini ortaya koymuştur [112].
- Tip 1 diyabetli kişilerden toplanan bileklik ivmeölçer verilerinden aktivite tespiti ve sınıflandırma çalışması yapılan bir çalışma incelenmiştir. Özellikle aktiviteyi yoğunluğuna ve bireysel uygunluğuna göre hareketsiz, hafif, orta veya yoğun olarak tespit edip derecelendirebilen bir yöntem ve belirli kullanıcı davranışlarını tahmin etmek için denetimli öğrenme çerçevesinde aktivite sınıflandırması yapan bir yöntem sunulmuştur. Aktivite seviye derecelendirmesi için popülasyon sonuçları, çok sınıflı ortalama doğruluk %99, belirli bir davranış tahmin etme konusunda en iyi performans gösteren doğruluk %92 tespit edilmiştir. Araştırma tip 1 diyabetli kişilerdeki üç eksenli ivmeölçer verilerinden fiziksel aktivite ve hareketsizlik bilgisinin iyi bir doğruluk ve hassasiyetle tespit edilebileceğini, derecelendirilebileceğini ve sınıflandırılabilirliğini göstermiştir [113].
- Bir çalışmada bilekten takılan PPG sensörlerinden aktivite tanıma için DSA kullanılmıştır. Konvolüsyonel ve tekrarlayan sinir ağıları, ham PPG sinyalinden farklı türdeki günlük aktiviteleri (örneğin yürüme, koşma, zıplama) tahmin etmek için kullanılmıştır. 12 katılımcının bileklerinde takılı olan akıllı saatlerden gelen verileri kullanarak, sonuçlar beş tür aktiviteyi (durma, yürüme, koşma, zıplama

ve oturma) tahmin etme yaklaşımının uygulanabilirliğini göstermiştir. Bu çalışma PPG sensörlerinin insan aktiviteleri için nasıl kullanılabileceğine dair yeni bilgiler sağlamıştır. Sonuçlar insan hareketlerini algılamak için PPG sinyallerini kullanmanın önemini vurgulamaktadır [114].

DEHB tespitinde EEG sinyallerinin kullanılmasına yönelik literatürde yapılmış olan çalışmalar incelenmiş olup bazıları aşağıda sunulmuştur.

- DEHB ve şizofreni hastalarından elde edilen olaya bağlı potansiyel sinyallerinin analiz edildiği bir çalışma incelenmiştir. Benzer yaş, cinsiyet ve eğitim durumuna sahip 132 sağlıklı kontrol ve 63 DEHB ile 68 şizofreni hastasından katılımcıların davranışları ve EEG verileri kaydedilmiştir. Bu çalışma ile olaya bağlı potansiyel sinyallerinin kullanımı yaklaşımının DEHB ve şizofrenide fonksiyonel bozukluğu ortaya çıkarmak için uygun olduğu, DEHB ve şizofrenide niteliksel olarak farklı bilişsel bozukluk desenlerinin olduğu belirlenmiştir [115].
- DEHB'li çocuklarda EEG sinyallerini kullanarak motor beceriler üzerine yapılan bir çalışmada, hareket becerilerinin yoğun fiziksel aktivite ile dinlenme durumu arasındaki ilişkisi değerlendirilmiştir [116].
- DEHB ve DEHB olmayan bireylerin sınıflandırılması üzerine yapılan bir çalışmada Gauss karışım modelini kullanarak DEHB ve Evrensel Arka Plan modelinin tanımlanabileceği bir olasılık oranı dedektörü tasarlanabileceği belirtilmiştir. Bu çalışmanın sonucunda dikkat ağı aşamasında kaydedilen EEG sinyallerinin kullanılmasıyla, önerilen yöntemle yüksek tespit ve düşük hata oranlarının aynı anda elde edilebileceği belirlenmiştir [117].
- DEHB ve DEHB olmayan bireylerin zaman/frekans özellikleri kullanılarak makine öğrenmesi tabanlı sınıflandırılması üzerine bir çalışma incelenmiştir. Stroop görevi sırasında kaydedilen EEG olaya bağlı potansiyel sinyallerinin zaman-frekans alanındaki özellikleri analiz edilmiştir. En iyi ayırt edici özellikleri elde etmek için Destek Vektör Makinesi kullanılmıştır. En iyi üç özellik ve beş özellik kullanıldığında, eğitim veri seti için sınıflandırma doğruluğunun sırasıyla %98 ve %99.5'e yükseldiği tespit edilmiştir. Test veri seti için doğruluk oranı %100 olarak belirtilmiştir. Kapsamlı deneylere dayanarak EEG sinyallerinin delta bandının istatistiksel parametrelerle birlikte sınıflandırma çalışmasında en belirgin frekans bandı olduğu belirtilmiştir [118].

- DEHB tanısında tek kanal ve çok kanal EEG sinyallerinin performans analizine yönelik bir çalışmada gözler açık ve kapalı durumda 22 birleşik tip DEHB hastası ve 21 sağlıklı erkek kontrol grubundan 8 kortikal bölgeden EEG sinyali kaydedilmiştir. DEHB'li bireyleri sağlıklı bireylerden ayırt etme performansları analiz edilmiş olup DEHB bireylerinin yüksek doğrulukla sınıflandırılabilceği değerlendirilmiştir [119].
- Ergen DEHB'de cinsiyet tespiti üzerine yapılan bir çalışmada EEG ve EDA sinyalleri aynı anda kaydedilmiştir. DEHB'li erkeklerde teta aktivitesinin arttığı, DEHB'li kadınlarda ise EDA sinyallerinin azaldığı görülmüştür [120].
- Bir çalışmada "EndeavorRx" adlı bir mobil oyunun DEHB tedavisinde etkinliği test edilmiştir. İlaç olarak kullanılmak üzere oluşturulan bu mobil oyun aynı zamanda FDA onayı almıştır. Son yıllarda teknolojinin hayatımıza daha fazla entegre olmasıyla birlikte DEHB tanısı, takibi ve tedavisi için bilgisayar ve mobil ortamlarda kullanılabilecek uygulamalar üzerine yapılan çalışmalar önem kazanmıştır [121].

EEG sinyalleri ile DEHB tespiti üzerine yapılan literatürdeki çalışmalar incelenmiş olup çalışmalardan bazıları aşağıda sunulmuştur.

- Bir derleme çalışmasında EEG sinyallerinin yetişkinlerde DEHB teşhisi için kullanımını incelenmiştir. Derleme çalışmasında 21 makale değerlendirilmiştir. EEG'nin DEHB teşhisi konusunda yardımcı olabileceği sonucuna varılmış olup hala sonuçların yetersiz olduğu belirtilmiştir. Çocuklarda DEHB için önemli bir belirteç olarak kabul edilen teta beta oranının (TBR), yetişkinlerde oldukça tutarsız olduğu belirtilmiştir [122].
- 6-18 yaşlarındaki 1253 DEHB'li ve 517 sağlıklı çocuk ve ergenin EEG TBR'sini inceleyerek DEHB teşhisi için EEG TBR'nin kullanılabilirliğini bildiren bir çalışma incelenmiştir. TBR'nin DEHB'nin güvenilir bir teşhis ölçütü olarak kabul edilemeyeceği ve teşhis ölçütünden ziyade bir prognoz ölçütü olarak kullanılabileceği belirtilmiştir [123].
- Başka bir benzer çalışma TBR parametresi kullanılarak 185 katılımcının 166'sında DEHB'nin doğru bir şekilde tespit edildiğini belirtmiştir. Başka bir çalışma TBR'nin yüksek bir DEHB ayırım potansiyeli olduğunu ancak klinik değerlendirmede tek başına alternatif olmak için yetersiz olduğunu belirtmiştir [124].

- DEHB tespit etmek için EEG sinyallerini kullanarak manuel bir şekilde modellenmiş tek boyutlu bir sinyal sınıflandırma sistemi temelli yeni bir özellik çıkarım yöntemi sunulan bir çalışma incelenmiştir. Önerilen yöntem yönlendirilmiş bir grafik ve sekiz noktalı yıldız desen (EPSPat) ile öğrenme ağı modelidir. Yöntem EEG sinyallerindeki anormallikleri analiz etmeye odaklanmıştır. DEHB'nin yüksek bir doğruluk oranıyla tespit edildiği vurgulanmıştır [125].
- DEHB ve sağlıklı bireyler arasında ayırım yapmak için olayla ilgili EEG verilerine derin öğrenme yöntemleri uygulanan bir çalışma incelenmiştir. Çalışmada ayrıca aynı derin öğrenme yöntemleri kullanılarak DEHB alt tiplerinin belirlenmesi çalışılmıştır. Sonuçlar uygulanan derin öğrenme modelinin ("EEGNet") hem DEHB alt tiplerini hem de sağlıklı kontrolleri %83'e kadar doğrulukla ayırt edebildiğini göstermiştir [126].
- DEHB alt tiplerini belirleyip belirleyemediği konusunda EEG'yi araştıran başka bir çalışma, EEG'nin DEHB'yi belirlemek için önemli sonuçlar verdiğini ancak alt tipleri tanımlamakta yetersiz kaldığını göstermiştir [127].
- DEHB varlığını tespit etmek için EEG'nin potansiyelini değerlendiren bir çalışma incelenmiştir. EEG belirteci, DEHB'li 16 katılımcının 15'inde (duyarlılık %94) tespit edilmiştir. DEHB benzeri semptomlar gösteren ancak DEHB'li olmayan hiçbir hastada EEG belirteçlerinin tespit edilmediği (özellik %100) belirtilmiştir. Bu sonuçlar, EEG'nin DEHB'yi tespit etmek için bir belirteç olarak kullanılabileceğini göstermiştir [128].
- DEHB'li katılımcılarda EEG sinyallerindeki değişiklikleri 11 yıl arayla analiz eden bir çalışma incelenmiştir. İlk muayenenin yapıldığı zaman 8-12 yaşlarındaki yirmi beş erkek, 11 yıl sonra yeniden değerlendirilmiştir. EEG gözler kapalıyken dinlenirken kaydedilmiş ve delta, teta, alfa ve beta dalgaları her iki dönem için hesaplanmıştır. Bulgulara göre çocukluktan yetişkinliğe EEG aktivitesinde önemli değişiklikler gözlenmiştir. Katılımcıların EEG'lerinde önemli gelişimsel değişiklikler bulunmuştur [129].
- DEHB'li çocukları belirlemek için EEG tabanlı bir derin öğrenme çalışması incelenmiştir. Çalışmada incelenen yöntemler arasında CNN öğrenme yeteneklerinin dikkat çekici olduğu belirtilmiştir [130]. 20 sağlıklı ve 20 DEHB'li yetişkin üzerinde gerçekleştirilen başka bir çalışmada farklı yöntemler ve veri

setleri kullanılarak sınıflandırmadan elde edilen sonuçlar, CNN'nin yüksek doğruluk elde ettiğini ve RNN'yi (Recurrent Neural Networks) önemli ölçüde geride bıraktığını göstermiştir [131]. Başka bir çalışmada DEHB tanımlaması için CNN teknikleri kullanıldığında %90 doğruluk oranına ulaşılabileceği gösterilmiştir [132]. Başka bir çalışmada 31 DEHB ve 30 sağlıklı çocuktan alınan EEG sinyalleri önışlemden geçirilmiş ve teta, alfa, beta ve gama frekans bandlarına ayrılmış ve bir görüntü matrisi oluşturulmuştur. 13 katmanlı CNN yapısı kullanılarak yapılan sınıflandırma çalışmasında %90'ın üzerinde genel başarı oranlarına ulaşıldığı belirtilmiştir [133].

- DEHB teşhisinde EEG kullanımına ilişkin son 75 yılı kapsayan bir derleme çalışmasında DEHB için basit bir teşhis kriteri bulmanın mümkün olmadığı belirtilmiştir. Çalışmada EEG'nin DEHB'yi teşhis etmek veya teşhisinde yardımcı olmak için bir araç olarak kullanılmaya hazır olmadığı belirtilmiştir. Ancak EEG kullanılarak bildirilen yüksek (>90%) doğruluk oranlarına sahip DEHB tespit çalışmalarının anatomik ve fonksiyonel MRI verilerini kullanan son teknoloji ileri düzey sınıflandırma çalışmalarından çok daha başarılı olduğu belirtilmiştir [134].
- EEG sinyallerinin spektral özelliklerinin DEHB sınıflandırması üzerindeki etkisi konusunda bir çalışma incelenmiştir. Çalışmanın birincil amacının DEHB teşhisi için en etkili EEG kanalını ve en etkili kayıt durumunu ortaya çıkarmak olduğu belirtilmiştir. Bu şekilde daha az kanalla ve daha yüksek doğrulukla DEHB sınıflandırması yapılması hedeflenmiştir. Bulgulara göre "Fp1, F7" kanalında %88 (gözler açık) doğruluk hesaplandığı belirtilmiştir. "Fp1, F7" kanalının en yüksek başarıyı verdiği görülmüştür [135]. Başka bir çalışmada DEHB'li bireylerle sağlıklı bireyler arasında beyin ön bölgesindeki bilgi akışında farklılıklar bulunmuştur [136].

Göz takibi, göz izleme sistemleri, EOG ve DEHB üzerine yapılmış literatürdeki çalışmalardan bazıları aşağıda sunulmuştur.

- Bir çalışmada konsantrasyon yeteneği ve problem çözme faktörleri değerlendirilmiştir. Odaklanma için göz kırpma hızı, göz kırpma gücü ve baş pozisyonu hesaplanmıştır. Bu çalışmada iki psikolojik tepki ile EOG parametresi arasındaki ilişki incelenmiştir. Odaklanma yeteneğine karşılık gelen EOG parametresi ile psikolojik tepki arasındaki niteliksel ilişki doğrulanabilir olduğu

ifade edilmiş ve yakın gelecekte sanal sınıflarda e-öğrenime yönelik uygulanabileceği değerlendirilmiştir [137].

- Tek kanallı EOG kullanarak uyku aşamalarının otomatik skorlamasını içeren bir çalışma incelenmiştir. Farklı istatistiksel özellikleri kullanarak tek kanallı EOG sinyalleri değerlendirilmiştir. Çalışmanın sonucunda tek kanallı EOG'nin uyku sınıflandırma çalışmalarında tek kanallı EEG'den daha iyi performans gösterdiği belirlenmiştir [138].
- EOG sinyalleri temel alınarak göz hareketlerinin yönünü değerlendiren yapay sinir ağı kullanan bir çalışmada yeni bir akıllı algılama modeli önerilmiştir. Geleneksel göz hareketi takip yöntemlerine ek olarak model, tik tespiti ve göz kırpmasını içermektedir. EOG sinyallerinin özellikleri çıkarılıp beslenerek ileri beslemeli bir yapay sinir ağına verilmiştir. Sonuçlara göre önerilen modelin göz hareketlerinin tespit edilmesinde kullanışlı bir yöntem olacağı değerlendirilmiştir [139].
- Göz takibi / göz izleme alanında video görüntüleri, kızılötesi ışık algılama ve EOG sinyalleri kullanarak sistemler geliştirilmiştir. Hough dönüşümü, Kalman filtresi, biyometrik tanıma ve "Likelihood" modelleme gibi farklı teknikler, göz takibi sistemlerinde video görüntülerini kullanmıştır [140-143]. Bununla birlikte DEHB tanısı üzerine yapılan literatürde, göz hareketine dayalı sınırlı çalışmalar bulunmaktadır. Bir çalışmada DEHB'li yetişkinlerde sakkadik göz hareketi bozuklukları bildirilmiştir [144]. Tsang ve arkadaşları DEHB'li çocuklarda görsel dikkatin azaldığını ve sosyal sabitleme süresinin sağlıklı bireylere göre daha kısa olduğunu rapor etmişlerdir [145]. Marotta ve arkadaşları DEHB'de görülen kişilerarası ve sosyal sorunları incelemişler ve özellikle sosyal uyarıcılara karşı sağ-sol göz takibinde ve göz sabitlemede sorunlar olduğunu rapor etmişlerdir [146]. DEHB'nin tanısında davranışsal değişikliklerle dinamik göz hareketi ve gözbebeği değişiklikleri üzerine yapılan başka bir çalışma nöropsikolojik test skorları ile belirtilen parametrelerin ilişkilerinin kullanışlı olabileceğini göstermiştir [147].
- DEHB tespiti için EOG sinyallerinin kullanıldığı sınırlı sayıda çalışma bulunmaktadır. Bir çalışmada 30 ADHD ve 30 sağlıklı çocuğun EOG sinyallerinden yaklaşık entropi ve Petrosian'ın fraktal boyut özellikleri çıkarılmıştır. Daha sonra iki gruptan elde edilen özellikler bir destek vektör

makinesi (SVM) ve neural gas (NG) kullanılarak sınıflandırılmıştır. SVM ile %84.6 başarı oranı, NG kullanıldığında ise %78.1 elde edilmiştir [148].

- Başka bir çalışmada sağlıklı bireylerle DEHB'li kişilerin EOG sinyalleri arasında bir fark olduğu yaklaşımla EOG biyo-geribildiriminin DEHB semptomlarını azaltmada etkili olacağı önerilmiştir. Çalışma DEHB'yi tedavi etmek için bir EOG biyogeribildirim protokolü önermiştir. Odaklanmış bir dikkat görevi sırasında EOG sinyallerinin farklı özellikleri hem hasta hem de sağlıklı gruptan çıkarılmıştır. Daha sonra iki grubu ayırt etmede en etkili özellikler genetik algoritma kullanılarak belirlenmiştir. Çalışmanın sonuçlarına göre DEHB grubunun EOG sinyallerinde düşük frekans bandı gücü (0.5-4.125 Hz), entropi ve fraktal boyut değerleri, sağlıklı çocuklardan anlamlı derecede düşük tespit edilmiştir ($P < .001$). Entropi ve fraktal boyut iki grubu ayırt etmede en etkili özellikler olarak seçilmiştir. EOG sinyallerinin entropi ve fraktal boyutlarının DEHB tedavisi için kullanılabileceği değerlendirilmiştir [149].
- Daha önce yürüttüğümüz bir çalışmada DEHB tanısı için bir EOG ölçüm sistemi geliştirilmiştir. Kontrollü EOG sinyali elde etmek için bir görsel uyaran yazılımı geliştirilmiş ve EOG sinyalleri kaydedilmiştir. 8 DEHB ve 8 sağlıklı katılımcı ile çalışma gerçekleştirilmiştir. Görsel uyaran yazılımıyla EOG sinyalinden elde edilen veriler istatistiksel olarak analiz edilmiş olup sağlıklı ve hasta gruplar anlamlı şekilde ayırt edilmiştir [150].
- Gerçekleştirdiğimiz başka bir çalışmada DEHB ve sağlıklı bireyler EOG sinyalleriyle makine öğrenme yöntemleri kullanılarak sınıflandırılmıştır. 53 hasta ve 36 sağlıklı kontrol ile görsel uyaran takip testi sırasında EOG sinyalleri kaydedilmiştir. Veriye özgü özellikler, Higuchi fraktal boyutu (HFD) ve Hjorth parametreleri elde edilmiş ve makine öğrenmesi yöntemleriyle sınıflandırılmıştır. %80'in üzerinde bir sınıflandırma başarısı elde edilmiştir [151].

2. BÖLÜM

YÖNTEM VE MATERYAL

Bu tez çalışmasında Erciyes Üniversitesi Çocuk ve Ergen Psikiyatrisi Anabilim Dalı'nda HB tanısı konulan ve sağlıklı tanısı konulan 8-13 yaş grubu çocuk ve ergenlerden çeşitli veriler elde edilmiştir. Çalışma kapsamında EOG, EEG, nabız, GDC, ham tek kanal EKG fizyolojik sinyalleri ve ivmeölçer ve jiroskop sensörleri ile harekete ilişkin veriler eş zamanlı olarak kaydedilmiştir. Kaydedilen verilere göre hasta ve sağlıklı tanısının konulması amacıyla algoritma tasarımı gerçekleştirilmiştir. Veriler ön işlemeden geçirildikten sonra sınıflandırma çalışması yapılmıştır. Elde edilen sonuçlar ortaya konularak tartışılmıştır. İlgili fizyolojik sinyaller ve harekete ilişkin ivmeölçer ve jiroskop sensörleri ile elde edilmiş veriler ile tez çalışmasını destekleyici ve alt yapı oluşturucu nitelikte birçok çalışma gerçekleştirilmiştir. Yapılan çalışmalara ait yöntemler bu bölümde sunulmuştur. Bu bölümde kullanılan materyal, verilerin eldesi için geliştirilen sistem tasarımı, kayıt süreci, elde edilen verilere uygulanan işlemler, verilerle ilgili yapılan çalışmalarda kullanılan yöntemler hakkında bilgi verilmiştir.

Öncelikle bu bölümde materyal detaylı olarak ifade edilmiştir. Sonra yapılan çalışmalarda kullanılan yöntemler hakkında detaylı bilgiler verilmiştir. Son olarak da gerçekleştirilen sistem tasarımı ve tasarlanan sistemden elde edilen verilere yönelik yapılan işlemler açıklanmıştır.

2.1. Katılımcılar ve kayıt süreci

Tez çalışması kapsamında HB tanısı olan ve sağlıklı tanısı olan grupların belirlenmesi için çift kör hekim değerlendirmesi gerçekleştirilmiştir. İki hekimin de hasta tanısı koyduğu bireyler hasta gruba, sağlıklı tanısı koyduğu bireyler sağlıklı gruba dahil

edilmiştir. Bir hekimin hasta tanısı koyarken diğer hekimin sağlıklı tanısı koyduğu bireyler ise çalışmaya dahil edilmemiştir. Katılımcıların çalışmaya dahil edilmesi Erciyes Üniversitesi Tıp Fakültesi Tıbbi Etik Kurulu tarafından onaylanmış olup çalışma Helsinki Bildirgesi'ne uygun olarak gerçekleştirilmiştir. (Etik Kurul Karar No: 2018/487 kapsamında tez çalışması gerçekleştirilmiştir. Ayrıca 2015/90 numaralı etik kurul kararı kapsamında da çalışmalar gerçekleştirilmiştir.) Katılımcılar 18 yaş altı olması sebebiyle bilgilendirilmiş onam formları hem katılımcılardan hem de ebeveynlerinden alınmıştır. Çalışmaya 10 sağlıklı 30 HB tanılı olmak üzere her iki cinsiyette ayrım gözetmeksizin toplam 40 kişi katılmıştır. Katılımcıların göz hareketlerinin kontrollü takibinin yapıldığı bir bilgisayar tabanlı test ile birlikte tüm verileri (nabız, GDC, EOG, EEG, jiroskop ve ivmeölçer verileri) kaydedilmiştir. Test yaklaşık 3 dakika uzunluğundadır. Testten önce ise katılımcılardan tasarlanan kayıt sistemi ile serbest bir şekilde (herhangi bir hareket kısıtlaması olmaksızın) yaklaşık beş dakika boyunca nabız, GDC, ivmeölçer ve jiroskop verileri kaydedilmiştir. Bilgisayar tabanlı test işlemi gerçekleştirilmesi aşamasında da benzer şekilde kayıt alınmıştır. Bilgisayar tabanlı test tamamlandıktan sonra yine aynı şekilde EEG ve EOG olmaksızın bir beş dakika daha kayıt alınmıştır. Kayıtlar üzerinde çalışma gerçekleştirilmiştir.

2.2. Materyal

Tez çalışmasında EOG ve EEG sinyallerinin kaydedilmesi için BIOPAC firmasının MP-150 kayıt cihazıyla birlikte EOG ve EEG modülleri kullanılmıştır. MP-150 cihazında EOG kayıtları Şekil 1.3' te gösterildiği şekilde elektrot bağlantıları yapılarak kaydedilmiştir. Tüm kayıtlarda kullanılan elektrotlar tek kullanımlık Ag-AgCl elektrotlardır. EEG kayıtları ise bir EEG başlığı ile Şekil 1.5' te gösterilen 10-20 sistemi ile kaydedilmiştir. Aşağıda öncelikle EEG ve EOG sinyallerinin kontrollü takibinin sağlandığı bilgisayar tabanlı görsel uyaran takip testi açıklanmıştır. Sonra nabız, GDC, ivmeölçer ve jiroskop verilerinin kaydedilmesi için tasarlanan sisteme ait bilgiler sunulmuştur.


2.2.1. Görsel uyaran takip testi

Görsel uyaran takip testi bilgisayar tabanlı bir testtir. EOG ve EEG sinyallerinin kontrollü bir şekilde kaydedilmesini sağlamaktadır. Katılımcıdan test sırasında ekranda görünen bir topun takip edilmesi istenir. Testte görsel ve işitsel çeldiriciler bulunmaktadır. Test

kalibrasyon sonrası üç aşamadan oluşmaktadır. Kalibrasyon sırasında siyah zemin üzerinde beyaz renkli top sağ, sol, yukarı ve aşağı hareket etmektedir. Kalibrasyon sonrasında testin ilk aşaması başlamaktadır. İlk aşamada belirlenen yönlerde belirlenen zaman aralıklarında top hareket etmektedir. İlk aşamada görsel ve işitsel çeldiriciler bulunmamaktadır. İkinci aşamada top ile farklı yönlerde ekranda çıkan kedi ve köpek görselleri, görsel çeldiriciler olarak ekranda belirlemektedir. Üçüncü aşamada ise görsel çeldiricilere ek olarak arka planda çocuk sesleri ve siren sesi şeklinde işitsel çeldiriciler bulunmaktadır. Toplam test süresi yaklaşık 3 dakika sürmektedir (testin birinci bölümü 55 saniye, ikinci bölümü 60 saniye, üçüncü bölümü 60 saniyedir). Sağlıklı ve hasta katılımcıların tamamının EOG ve EEG kayıtları bu test sırasında alınmıştır.

Çalışmada katılımcı ekranın 30 cm karşısında, alın hizası ekranın orta noktasına gelecek şekilde konumlandırılarak EOG ve EEG kaydı gerçekleştirilmiştir. 24” ebatında monitör kullanılmıştır. Teste ait örnek görsel aşağıda sunulmuştur (Şekil 2.1).

Görsel uyaran takip testi ile EEG ve EOG’ nin kontrollü bir test protokolü çerçevesinde hasta ve sağlıklılardan aynı şartlar altında kayıt altına alınması sağlanmıştır. Test ile EOG, EEG sinyal kayıtları eş zamanlı olarak gerçekleştirilmiştir.



Şekil 2.1. Görsel uyaran takip testi

2.2.2. Nabız, GDC, ivmeölçeri jiroskop verileri kayıt sistemi

Hareket verilerinin (ivmeölçer, jiroskop) ve GDC, nabız sinyallerinin kaydedileceği cihaz tasarımı geliştirilmiş olup geliştirilen cihazla kayıtlar alınmıştır.

İvmeölçer ve jiroskop verilerinin tespiti için çeşitli sensörler araştırılmıştır. Yaptığımız ön çalışmalar sonucunda özellikle hareket verileri için (ivmeölçer ve jiroskop) MPU-9250, MPU-9255/65, MPU-6050 sensörlerinin uygun olduğu değerlendirilmiştir.

Tez çalışması kapsamında geliştirilen kayıt sisteminde MPU-9255 hareket sensörü kullanılmıştır. Bu sensör 3 eksen (x, y, z) ivme, 3 eksen jiroskop ve 3 eksen manyetometre verisi algılayabilmektedir.

MPU-9255/65 jiroskop çıkışlarını sayısallaştırmak için üç adet 16-bit analog-dijital dönüştürücü (ADC), ivmeölçer çıkışlarını sayısallaştırmak için üç adet 16-bit ADC ve manyetometre çıkışlarını sayısallaştırmak için üç adet 16-bit ADC içermektedir. Hem hızlı hem de yavaş hareketlerin hassas takibi için, kullanıcı tarafından programlanabilen jiroskop tam ölçek aralığı $\pm 250, \pm 500, \pm 1000$ ve $\pm 2000^\circ / \text{sn}$ (dps), kullanıcı tarafından programlanabilen ivmeölçer tam ölçek aralığı $\pm 2g, \pm 4g, \pm 8g$ ve $\pm 16g$ ve bir manyetometre tam ölçek aralığı $\pm 4800 \mu T$ dir [152]. Belirtilen bu özellikler sayesinde yüksek hassasiyete sahip olduğundan insansız hava araçları dahil olmak üzere birçok hareket verisine dayalı projede kullanılabilmektedir.

Veri kayıt sisteminde mikroişlemci/mikrodenetleyici için arduino nano kullanılmıştır. Yeterli analog/dijital çıkış pin sayısı stabil çalışması ve düşük güç tüketimi bu geliştirme kartının kullanım sebepleridir. Arduino nano [153] kullanılmasının en büyük sebebi ise çok küçük boyutta olmasıdır. El işçiliğiyle arduino nano boyutunda mikrodenetleyici / işlemci içeren bir devre tasarımı geliştirilmesi çok zor olacağından bu geliştirme kartı kullanılmıştır.


Verilerin kaydedilebilmesi için arduino nano ile uyumlu sd/mikro sd kart modülü [154] kullanılmıştır. İstenilen örnekleme frekansında veri kaydını yüksek kapasitelerde yapabilme imkanı sunulmuştur.

Kayıt sisteminin güç beslemesi için kullanım kolaylığı ve kolay erişilebilirlik sebeplerinden ötürü 9 V pil kullanılmıştır [155].

Galvanik deri cevabı/ elektro dermal aktivite (GDC / EDA) ve nabız verilerinin kaydı için piyasada bulunan ürünler incelenmiştir. GDC için Grove-GSR marka modelli sensör kullanılmıştır [156].


Nabız verisi için çeşitli sensörler incelenmiş olup birçok sensörün parmak ve bilek dışında efektif çalışmadığı değerlendirilmiştir. Bu kapsamda gövdeden sağlıklı bir şekilde nabız verisini elde edebilmek için tek kanal EKG devresi hazırlanmıştır. EKG sinyalindeki QRS sayılarına göre nabız tespiti yapılmıştır. EKG devresinde enstrümantasyon yükselteci olarak AD620AN [157] serisi op-amp entegresi kullanılmıştır. Enstrümantasyon yükseltecin kazanç ayarı yapılan R_g direnci $5.6\text{ k}\Omega$ seçilmiştir. Filtreleme ve seviye yükselteci için ise LM358 serisi [158] op-amp kullanılmıştır. Bu şekilde nabız elde etmek üzere EKG devresi hazırlanmıştır.

Özetlemek gerekirse kayıt sistemi elektronik komponentlerin bulunduğu kutu içerisinde MPU9255/65 hareket sensörü, Grove-GSR GDC sensörü, EKG devresi, MikroSd hafıza kartı modülü, Arduino Nano geliştirme kartı ve 9 V güç için besleme devresi bulunmaktadır. Cihaz kutusu kendi tasarladığımız kemere takılan kumaş bir taşıyıcı hazne aracılığıyla bel bölgesine takılmaktadır. Cihazdan çıkan sensör kabloları lastikli ve arkadan cırt-cırtlı kendi tasarımıımız bir kumaş kemer üzerindedir. Kumaş sensör kemeri, göbek deliğinin üst bölgesine yani karın bölgesine sıkıca yerleştirildikten sonra cihaz üzerindeki butona basılarak kayıt başlatılmaktadır. Sistem ile ilgili görseller aşağıda sunulmuştur.




Şekil 2.2 MPU92/65-55 sensörünün cihaz kutusu içerisine yerleşimi

Şekil 2.2 de hareket sensörü ve elektronik komponentlerin yerleştirildiği kutu içerisindeki durumu görülmektedir.




Şekil 2.3. GDC sensörü

Şekil 2.3' te Grove-GSR marka GDC sensörü ve kablo bağlantı görülmektedir.




Şekil 2.4. MikroSd hafıza kartı modülü

Şekil 2.4’ te mikro sd hafıza kartı modülü ve kablo bağlantıları görülmektedir.




Şekil 2.5. EKG devresi (sol tarafta AD620 entegresi, sağda LM358 entegresi)

Şekil 2.5’ te nabız eldesi için tasarlanan EKG devresi ve bağlantıları görülmektedir. Tüm komponentlerin Arduino Nano geliştirme kartı ile bağlantıları yapılmıştır. Bağlantılar yapıldıktan sonra test işlemleri yapılmıştır. Test işlemleri sonucunda kayıt sisteminin sorunsuz çalıştığı tespit edilmiştir. Tüm komponentler kutu içerisinde sıcak silikon kullanılarak sabitlenmiştir.



Şekil 2.6. Sensör kablolarının bulunduğu karın bölgesine takılan kemer



Şekil 2.7. Elektronik komponentlerin ve 9V beslemenin bulunduğu kemere takılan hazne

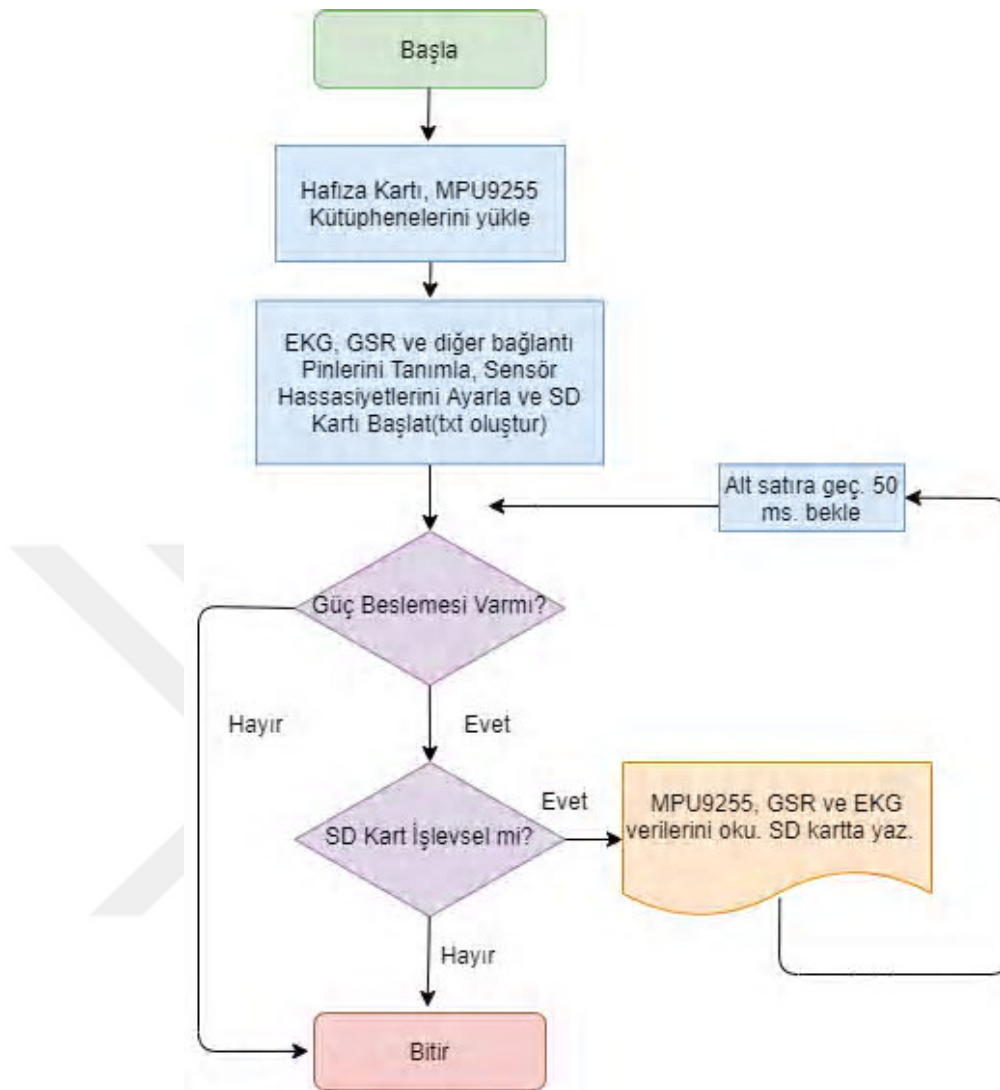
Şekil 2.6’ da karın bölgesine takılan cırt cırtlı kemer görülmektedir. Kemer üzerinde GDC için cilde temas noktaları ve nabız tespitinde kullanılan tek kanal EKG’ nin elektrotlarının (Ag-AgCl) bağlanacağı timsah kablo uçları görülmektedir.

Şekil 2.7’ de kemere takılan kayıt sisteminin cırt cırtlı kumaş haznesi ve elektronik kutusu görülmektedir. Elektronik kutunun üzerinde güç tuşu bulunmaktadır. Elektronik kutusunun sağında 9 V pil ve bağlantısı bulunmaktadır. Güç tuşuna basıldığında sistem kayıt almaya başlamakta ve kapatılana kadar kayıt almaya devam etmektedir.



Şekil 2.8. Hazırlanan kayıt sistemi

Şekil 2.8’ de tüm kayıt sistemi görülmektedir. Karın bölgesine takılan kendi tasarımıımız kemer ve pantolonun kemerine takılan kayıt cihazı, ilgili görselde sunulmuştur. Kayıt sisteminin çalışmasına ait akış diyagramı Şekil 2.9’ da sunulmuştur.



Şekil 2.9. Kayıt sistemine ait akış diyagramı

Akış diyagramından da görüleceği üzere cihaz güç tuşuna basıldıktan itibaren cihaz her 50 milisaniye (ms) de bir tüm verileri bir satıra yazıp alt satıra geçmektedir. Yani verilerin kaydı kapsamında örnekleme frekansı 20 Hz (50 ms’ de 1 kayıt) olarak belirlenmiştir. Nabız, GDC ve hareket verilerinin yapılarına bakıldığında 20 Hz örnekleme frekansının yeterli ve optimal olacağı değerlendirilmiştir.

Kayıt sistemi ile veriler hafıza kartına “.txt” formatında kaydedilmektedir. Şekil 2.10’ da örnek bir kayıt dosyası içeriği görülmektedir. Üç eksenli ivme ölçer verileri X, Y ve Z eksenlerinde AX, AY ve AZ olarak görülmektedir. Üç eksenli jiroskop verileri X, Y ve

Z eksenlerinde GX, GY ve GZ olarak görülmektedir. GDC verisi GSR olarak görülmektedir. Nabız için elde edilen EKG verisi ise son sütunda görülmektedir.

```

AX: -14724 AY: -5592 AZ: 5496 GX: 388 GY: 3090 GZ: -1776 GSR: 513 EKG: 500
AX: -15228 AY: -6712 AZ: 7328 GX: -3414 GY: 678 GZ: -1746 GSR: 512 EKG: 514
AX: -15148 AY: -7608 AZ: 8364 GX: 172 GY: -1328 GZ: -1784 GSR: 513 EKG: 511
AX: -14436 AY: -7740 AZ: 7680 GX: 1802 GY: -3248 GZ: -1968 GSR: 513 EKG: 526
AX: -13040 AY: -6608 AZ: 8508 GX: 84 GY: 1506 GZ: -1650 GSR: 513 EKG: 567
AX: -12516 AY: -6460 AZ: 8792 GX: 636 GY: 122 GZ: -1676 GSR: 514 EKG: 513
AX: -13096 AY: -6744 AZ: 8812 GX: -702 GY: -916 GZ: -1856 GSR: 514 EKG: 507
AX: -13472 AY: -7036 AZ: 7064 GX: -3402 GY: 1816 GZ: -1722 GSR: 515 EKG: 518
AX: -11628 AY: -7052 AZ: 6088 GX: -360 GY: -88 GZ: -1558 GSR: 516 EKG: 508
AX: -12472 AY: -6740 AZ: 7488 GX: -1162 GY: 810 GZ: -1826 GSR: 516 EKG: 512
AX: -13112 AY: -7028 AZ: 7932 GX: 998 GY: -2066 GZ: -1726 GSR: 517 EKG: 292
AX: -13344 AY: -8532 AZ: 7496 GX: 2612 GY: -976 GZ: -1936 GSR: 518 EKG: 523
AX: -12408 AY: -7436 AZ: 7832 GX: 1194 GY: -3366 GZ: -1844 GSR: 518 EKG: 504
AX: -12276 AY: -6928 AZ: 8088 GX: 930 GY: -3350 GZ: -1702 GSR: 519 EKG: 508
AX: -12012 AY: -7456 AZ: 9136 GX: -22 GY: -2616 GZ: -1752 GSR: 520 EKG: 508
AX: -12108 AY: -7664 AZ: 8492 GX: 108 GY: -4544 GZ: -1738 GSR: 520 EKG: 508
AX: -12096 AY: -7836 AZ: 8624 GX: 1266 GY: -5702 GZ: -1766 GSR: 521 EKG: 506
AX: -11364 AY: -6796 AZ: 8668 GX: -40 GY: -4176 GZ: -1882 GSR: 521 EKG: 622
AX: -12652 AY: -7236 AZ: 8508 GX: 46 GY: -6374 GZ: -1752 GSR: 522 EKG: 508
AX: -12228 AY: -6480 AZ: 7852 GX: 234 GY: -6886 GZ: -1816 GSR: 522 EKG: 502
AX: -13448 AY: -6848 AZ: 8440 GX: -250 GY: -5018 GZ: -1504 GSR: 522 EKG: 507
AX: -13276 AY: -7624 AZ: 8288 GX: -386 GY: -3656 GZ: -1918 GSR: 523 EKG: 510
AX: -11640 AY: -6904 AZ: 7896 GX: -128 GY: -4434 GZ: -1800 GSR: 523 EKG: 507
AX: -12152 AY: -7772 AZ: 7628 GX: 998 GY: -2320 GZ: -1734 GSR: 523 EKG: 468
AX: -12508 AY: -7764 AZ: 8804 GX: -44 GY: -3338 GZ: -1976 GSR: 524 EKG: 537
AX: -11468 AY: -7208 AZ: 8556 GX: 2404 GY: -4084 GZ: -1686 GSR: 524 EKG: 509
AX: -10856 AY: -7672 AZ: 8560 GX: 824 GY: -1798 GZ: -1800 GSR: 524 EKG: 504
AX: -10224 AY: -7732 AZ: 8748 GX: 1466 GY: -112 GZ: -1712 GSR: 524 EKG: 508
AX: -10360 AY: -7896 AZ: 8384 GX: 2240 GY: -2790 GZ: -1742 GSR: 524 EKG: 509

```

Şekil 2.10. Kaydedilen veri örneği

2.3. Yöntem

Tez çalışması kapsamında bildiri, makale gibi birçok çalışma gerçekleştirilmiştir. Ayrıca tez konusu çalışma kapsamının neredeyse tamamını kapsayacak şekilde Erciyes Üniversitesi Teknoloji Transfer Ofisi’ nin destekleri ile patent başvurusu yapılmıştır. “Hiperaktivite Bozukluğu Hastalığının Tanısına Yardımcı Olması İçin Bir Bilgisayar Uygulamalı Yöntem ve Sistem” patent adı ile 21.10.2021 tarihinde başvuru gerçekleştirilmiştir. Patent başvurusuna ait başvurusu numarası 2021/016393’ tür. Tez çalışması sürecinde gerçekleştirilen çalışmalar ait yöntemler, teknikler bu bölüm altında

açıklanmıştır. Son olarak da yapılan çalışmalar kapsamındaki değerlendirmeler göz önüne alınarak tez çalışmasında elde edilen verilerin nasıl sonuçlandırıldığına ilişkin yöntem/ yöntemler de bu bölümde belirtilmiştir.

Gerçekleştirdiğimiz bir çalışma kapsamında kontrollü bir şekilde kaydedilmiş 5 erkek ve 5 kadına ait ivmeölçer verilerine göre yürüme, koşma, merdiven çıkma, merdiven inme hareketlerinin tespit edilebilmesi amaçlanmıştır. Veriler bir veri tabanından alınmıştır [159]. Bu kapsamda yerel ortalama ayrışımı (LMD – Local Mean Decomposition) fonksiyonu kullanılmıştır. MATLAB de ilgili fonksiyon kullanılarak elde edilen çıktıdaki ortogonalite parametresine göre hareket tespitine yönelik değerlendirme yapılmıştır [160]. Çalışma kapsamında ivmeölçer veri kayıtlarının her bir eksenine için LMD yöntemi uygulanmış ve elde edilen verilerin ortogonalite değerleri karşılaştırılmıştır. Elde edilen sonuçlar bulgular bölümünde sunulmuştur.

2.3.1. Yerel Ortalama Ayrışımı (Local Mean Decomposition – LMD) ve Ortogonalite Durumu

Fourier dönüşümü zaman bölgesi ve frekans bölgesi analizini birleştirerek sinyallerin analizinde önemli bir araç oluşturmıştır. Ancak Fourier analizi, sinyalin zamanda ve frekansta nasıl değiştiğini tespit edemez. Bu nedenle durağan olmayan sinyaller için uygun değildir. Bu eksikliği gidermek için son zamanlarda zaman-frekans analizi yöntemleri (özellikle de yerel ayrıştırma yöntemleri) daha fazla ilgi görmüştür.

Lineer olmayan ve sabit olmayan sinyaller için önerilen bir sinyal işleme yöntemi olan LMD, Ampirik Mod Ayrışması (EMD) gibi bir sinyal işleme yöntemidir [161].

LMD, EMD den farklı olarak, adaptif bir ayrıştırma yöntemi kullanarak sinyali ayrıştırır. Bu işlem sinyalin temel fonksiyonlarını bilmeksizin yapılır [162]. LMD konuşma sinyali işleme, hata tespiti ve tıbbi sinyal işleme gibi birçok mühendislik alanında yaygın olarak kullanılmaktadır. Ancak teorik temeli ve kapsamının hala bazı eksikliklere sahip olduğu değerlendirilmektedir [163]. LMD'nin karşılaştığı sorunlardan biri mod karıştırma problemi [164]. LMD yönteminin mod karıştırma işlemi, LMD'nin birbirleriyle etkileşime giren ürün fonksiyonlarının eksik ortogonal olmasına dayanır. Yani bu ürün fonksiyonları birbirleriyle tam olarak bağımsız değildir. LMD' nin bir veri kümesine uygulanması işlemi ile ortogonal olmayan bu ürün fonksiyonlarından bir ortogonalite

değeri elde edilir. Bu değer veri setindeki değişimin miktarını gösteren bir bilgi içerir. Yani veri kümesinin içindeki değişimin ne kadarının LMD tarafından ortogonal olarak ifade edilebildiğini belirler [165].


Gerçekleştirmiş olduğumuz başka bir çalışma kapsamında 24 katılımcıya ait altı farklı fiziksel hareketin ivmeölçer ve jiroskop verileri ile sınıflandırılıp tespit edilmesi amaçlanmıştır [166]. Bu hareketler koşma, yürüme, merdiven inme, merdiven çıkma, ayakta durma ve oturma hareketleridir. Veriler bir veri tabanından alınmıştır [159].

2.3.2. Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN)

CNN derin öğrenme yapılarından biri olan ve genellikle görüntü sınıflandırma için yaygın olarak kullanılan bir derin öğrenme mimarisidir. CNN çok katmanlı bir derin sinir ağı yapısını içerir. Öğrenme sürecinde evrişim, havuzlama ve tam bağlantılı katmanlar bulunur [167]. Gerçekleştirilen çalışmada hareket veri setleri bir görüntü matrisi olarak oluşturulmuş ve CNN yapısı kullanılmıştır.

CNN canlı varlıkların doğal görsel algılama mekanizmasından esinlenen geniş çapta bilinen bir derin öğrenme mimarisidir. Literatürde birçok CNN mimarisi olmasına rağmen temel bileşenleri genellikle oldukça benzerdir. Genellikle üç tür katmandan oluşur: evrişim, havuzlama ve tam bağlantı katmanları. Evrişim katmanı girişlerin özelliklerini öğrenmeyi amaçlar. Havuzlama işlemleri iki türde olur: ortalama havuzlama ve maksimum havuzlama. İlk evrişim katmanındaki çekirdek, kenarlar ve eğriler gibi düşük seviye özellikleri tespit etmek için tasarlanırken, daha üst katmanlardaki çekirdekler, daha soyut özellikleri tespit etmeyi öğrenir. Birkaç evrişim ve havuzlama katmanının bir araya gelmesiyle, giderek daha yüksek düzeyde özellikler elde edilebilir. Birkaç evrişim ve havuzlama katmanının ardından yüksek düzeyli çıkarımlar yapmayı amaçlayan bir veya daha fazla tam bağlantılı katman kullanılabilir. Bu katmanlar önceki katmandaki tüm nöronları alır ve bilgi oluşturmak için şu anki katmandaki her bir nöronla bağlantı kurar. CNN'lerin son katmanı ise çıkış katmanıdır. Sınıflandırma görevleri için genellikle softmax operatörü kullanılır [168].

Çalışma kapsamında CNN yapısı kullanılarak hareket tanımlanmasına ilişkin bir sınıflandırma çalışması gerçekleştirilmiştir. Elde edilen sonuçlar bulgular bölümünde sunulmuştur. Tasarlanan derin öğrenme ağ yapısı Şekil 2.11' de görülebilir.



Şekil 2.11. Tasarlanan ağ yapısı

DEHB' in EOG sinyalleri ile tespit edilmesine yönelik gerçekleştirdiğimiz bir çalışmada DEHB olan ve sağlıklı bireylere tarafımızca geliştirilen görsel uyaran takip testi uygulanmış ve eş zamanlı olarak EOG sinyalleri kaydedilmiştir. EOG sinyallerinden çıkarılan öznitelikler ile hasta ve sağlıklı bireylerin sınıflandırma çalışmasında YSA kullanılmıştır [169]. Elde edilen sonuçlar bulgular bölümünde sunulmuştur. Çalışma kapsamında kullanılan yöntemler aşağıda sunulmuştur.

2.3.3. Tekil Spektrum Analizi (Singular Spectrum Analysis - SSA)

SSA tekniği klasik zaman serisi analizi, çok değişkenli istatistik, çok değişkenli geometri, dinamik sistemler ve sinyal işleme unsurlarını içeren güçlü bir zaman serisi analiz yöntemidir. SSA'nın olası uygulama alanları oldukça çeşitlidir. SSA farklı çözünürlükteki trendleri bulma, düzleştirme, küçük ve büyük dönemlere sahip döngülerin eş zamanlı çıkarılması, değişen genliklere sahip periyodisitelerin çıkarılması, karmaşık trendlerin ve periyodisitelerin eş zamanlı çıkarılması, kısa zaman serilerinde yapısal öğelerin bulunması, değişim noktası tespiti, frekans bileşeni filtresi gibi bir çok kullanıma sahiptir [170, 171].


Temel olarak, zaman serisini bağımsız bileşenlere ayırmak ve bu bileşenler aracılığıyla serinin yapısını anlamak amacıyla kullanılır. SSA, gelişmiş bir veri analizi ve spektral yöntem olarak kabul edilir ve çeşitli uygulama alanlarında (mühendislik, ekonomi, meteoroloji, biyomedikal araştırmalarda) kullanılır.

SSA, aşağıdaki temel adımlardan oluşur:

- **Seri Yığma (Embedding):** İlk adım orijinal zaman serisini özel bir matrise dönüştürmektir. Bu işlemde zaman serisi belirli bir boyut (n) ile parçalara bölünür ve bu parçalar matrisin sütunlarını oluşturacak şekilde düzenlenir. Bu süreç, zaman serisinin içerdiği örüntüleri ve yapıları matematiksel olarak temsil edilebilir bir formata dönüştürür.
- **Tekil Değer Ayrışımı (Singular Value Decomposition- SVD):** Matris, SVD yöntemi ile çözülür. SVD matrisin özdeğerlerini ve özvektörlerini hesaplamaya olanak tanır. Tekil değerler matrisin bileşenlerinin önem düzeyini temsil eder. Büyük tekil değerlere sahip olan bileşenler, zaman serisindeki önemli yapıları ifade ederken küçük tekil değerlere sahip olan bileşenler ise gürültü ve rasgele değişimleri temsil eder.
- **Bileşenlerin Seçimi:** SVD sonucunda elde edilen tekil değerler ve özvektörler, zaman serisinin farklı yapılarını temsil eden bileşenlere dönüştürülür. Özellikle büyük tekil değerlere sahip olan bileşenler, önemli örüntüleri içerir ve serideki anlamlı değişiklikleri açığa çıkarırken, küçük tekil değerlere sahip olan bileşenler ise gürültüyü ve rasgele değişimleri içerir.
- **Geri Dönüşüm:** İlgilenilen bileşenler seçildikten sonra, bu bileşenleri birleştirerek zaman serisini tekrar oluşturmak mümkündür. Bu adım, zaman serisindeki farklı bileşenlerin etkilerini anlamak ve analiz etmek için kullanılır.

SSA zaman serisindeki farklı yapıları ve örüntüleri belirlemek için nonparametrik bir yöntem olarak kabul edilir. Yani herhangi bir önceden belirlenmiş model veya varsayım gerektirmez. Bu nedenle SSA parametrik yöntemlerin başarılı bir şekilde ele alamayabileceği karmaşık ve doğrusal olmayan yapıları tanımlama ve çıkarım yapma yeteneği açısından güçlü bir alternatif sunmaktadır.

Çalışma kapsamında EOG sinyalinin gürültüsünün giderilmesi için SSA yöntemi EOG sinyallerine uygulanmıştır. SSA yönteminin EOG sinyallerine uygulanmasıyla bu sinyaller gürültüsüz hale getirilmiş olup göz hareketlerini tespit etmeye uygun bir forma dönüştürülmüştür. Aşağıda Şekil 2.12 de EOG sinyallerine SSA uygulaması öncesi ve sonrası elde edilen sinyal görülmektedir.



Şekil 2.12. EOG sinyaline SSA işleme öncesi (yukarıda) ve sonrası (aşağıda) [169]

2.3.4. Yapay Sinir Ağları (YSA)

YSA biyolojik sinir ağlarından etkilenen ve bazı performans özelliklerini paylaşan bir bilgi işleme sistemidir. YSA araştırmaları YSA'nın güçlü desen sınıflandırma ve desen tanıma yeteneklerine sahip olduğunu ve doğrusal olmayan yapıları yönetme, paralel ve seri işlem kapasitesine sahip olma avantajları nedeniyle genellikle veri tahmininde kullanıldığını ortaya koymuştur. İşlem öğelerinin toplam ve aktivasyon fonksiyonları, öğrenme stratejisi, kullanılan öğrenme kuralı ve işlem öğelerinin etkileşiminin bir sonucu olarak topoloji, bir YSA yapısındaki ağı belirler [172,173]. YSA yapay sinir hücrelerinin (nöronlar) bir araya gelmesiyle oluşur. Nöronlar rastgele toplanmazlar. Genellikle hücrelerin her katmanda paralel olarak düzenlendiği üç katmanlı bir ağ oluştururlar. Giriş katmanı, bir veya daha fazla gizli katman ve çıkış katmanından oluşan çok katmanlı algılayıcı (Multi Layer Perceptron- MLP) modeli YSA'nın en yaygın kullanılan versiyonudur. Giriş katmanındaki işlem öğeleri bir tampon görevi görür. Giriş sinyallerini gizli katmandaki işlem öğelerine dağıtır. Bu bileşenlerin her biri, giriş verilerini giriş üzerindeki etkinliği gösteren ağırlık katsayılarıyla çarparak toplam fonksiyona ekler. Daha sonra bu toplam fonksiyonlar bir transfer fonksiyonuna gönderilir ve nöronun çıkış değeri aşağıdaki gibi belirlenir:

$$y_i = f(\sum_i w_{ij}a_i + \theta) \quad (2.1)$$

Burada “j” nöronların sayısını, “i” girişlerin sayısını, giriş sinyalini, ağırlık katsayısını ve önyargı ifadesini (veya eşiği) gösterir.

Bu katmandaki birçok işlemci aynı işlemleri gerçekleştirir. Ağ çıkış değerleri, gizli katman öğeleri gibi çıkış katmanındaki işlem öğeleri kullanılarak belirlenir. Çıkış katmanındaki nöronların çıkışı benzer bir şekilde hesaplanır. İstenen ve gerçek çıkış nöronları değerleri arasındaki kare farkların sayısı E, aşağıdaki denklemle hesaplanabilir:

$$E(w) = \sum (y_{dj} - y_j)^2 \quad (2.2)$$

Burada hedef (gerçek) çıkış değeridir.

Bir YSA modelindeki giriş parametrelerinin ve gizli nöronların sayısı, modelin sınıflandırma etkinliği üzerinde büyük bir etkiye sahiptir.

Çalışma kapsamında YSA' nın mimarisinde gizli katmandaki nöronların sayısı 1-12 arasında alınmış ve modelin optimum mimarisi, eğitim performansının sınıflandırılması için minimum ortalama kare hatayı verme esasına dayanarak hesaplanmıştır. Aşırı uyumu önlemek için gizli katmanların sayısını belirlemek de önemlidir. Bu nedenle yapılan testler sonucunda çalışmada aşırı uyumu önlemek için gizli katmanların sayısı bir olarak ayarlanmıştır.

MLP modelinde bilgi ileri yönde akmaktadır. Bu özellik nedeniyle MLP modeli ayrıca ileri beslemeli YSA olarak da bilinir. Bu modelin avantajlarından biri, çeşitli öğrenme algoritmaları kullanarak ağı eğitebilmesidir. Ağın çıkışı ile hedef çıkış arasındaki hata azalana kadar ağın ağırlıkları, eğitim algoritmasına göre ayarlanır.

YSA' da ağı eğitmek için farklı öğrenme algoritmaları kullanılmaktadır. DEHB ve kontrol grubunun sınıflandırılması için Levenberg Marquardt (LM) öğrenme algoritması kullanılmıştır. Bu algoritma hesaplama hızı açısından etkili bir algoritmadır [174].

EOG sinyallerinin görsel uyaran takip testi ile kaydedilmesi sonucu DEHB' in tespit edilmesine yönelik gerçekleştirdiğimiz bir çalışmada makine öğrenmesi yöntemleri kullanılmıştır. Çalışma kapsamında öncelikle güç analizi yapılmış olup en az kaç katılımcı ile çalışmanın gerçekleştirilebileceği belirlenmiştir. EOG sinyallerinden elde edilen parametreler, Higuchi' nin fraktal boyutu parametresi (Higuchi's fractal dimension-HFD), Hjorth parametreleri kullanılarak hasta ve sağlıklı bireylerin sınıflandırma çalışmasında makine öğrenmesi algoritmaları kullanılmıştır [151]. Elde edilen sonuçlar bulgular bölümünde sunulmuştur. Çalışma kapsamında güç analizine,

parametrelere ve kullanılan makine öğrenmesi algoritmalarına ilişkin yöntemler aşağıda sunulmuştur.

2.3.5. Güç Analizi

Güç analizi bir istatistiksel testin bir etkiyi saptama yeteneğini (yani gücünü) değerlendirmek için kullanılan bir yöntemdir. Özellikle bir çalışmanın belirli bir etki büyüklüğünü saptama olasılığını değerlendirmek için kullanılır. Bu durum bir testin, bir hata yapma olasılığını (Tip-I ve Tip-II hatalar) kontrol altında tutarken, gerçekten var olan bir etkiyi saptama olasılığını en üst düzeye çıkarmak amacıyla yapılır.

Bir güç analizi genellikle aşağıdaki unsurları içerir:

- Örneklem büyüklüğü: Analizdeki örneklem sayısıdır. Genellikle daha büyük bir örneklem, daha büyük bir güç anlamına gelmektedir (yani bir etkiyi tespit etme olasılığı daha yüksektir).
- Etki büyüklüğü: Ölçmek istenilen etkinin boyutudur. Bu genellikle etkinin standartlaştırılmış bir ölçüsüdür ve genellikle istatistiksel analizden elde edilmektedir. Etki büyüklüğü ne kadar büyük olursa, bir etkiyi tespit etme gücü o kadar yüksek olur.
- Tip-I hata oranı (alfa): Bu yokken bir etkinin olduğunu yanlışlıkla tespit etme olasılığıdır (yani bir yanlış pozitif). Alfa genellikle istatistiksel anlamlılık düzeyi olarak belirlenir ve genellikle 0,05 olarak belirlenir.
- Tip-II hata oranı (beta): Bu varken bir etkinin olmadığını yanlışlıkla belirleme olasılığıdır (yani bir yanlış negatif). $1 - \beta$ güç olarak tanımlanır ve genellikle 0,80 veya 0,90 olarak belirlenir.

Güç analizi bu dört bileşeni kullanarak bir testin belirli bir etkiyi saptama yeteneğini değerlendirmektedir. Özellikle bir çalışmanın örneklem büyüklüğünü belirlemek için genellikle bir güç analizi yapılır. Bu durum belirli bir etki büyüklüğünü, belirli bir Tip-I ve Tip-II hata oranı ile tespit etmek için gereken minimum örneklem büyüklüğünü belirler.

Çalışma kapsamında güç analizi gerçekleştirilmiştir. Tip-I hata oranı 0.05 ve Tip-II hata oranı 0.020 olarak güç analizinde belirlenmiştir. Örneklem büyüklüğünü belirlemek için güç analizinde DEHB/sağlıklı sınıflandırmasında en yüksek başarıya sahip parametre değerlendirilmiştir. Güç (1-beta) %80 olarak kabul edildiğinde, her bir grup için gereken minimum örneklem sayısı 19 olarak hesaplanmıştır. Ek olarak diğer parametreler dikkate alındığında, her bir grup için gereken minimum örneklem sayısı 31 olarak hesaplanmıştır.

2.3.6. Higuchi'nin Fraktal Boyutu (Higuchi Fractal Dimension – HFD)

HFD bir zaman serisi verisinin karmaşıklığını, özellikle biyolojik sinyallerin karmaşıklığını ölçmek için kullanılan bir yöntemdir. Fraktal analiz zaman serisi verisinin karmaşıklığını ve düzensizliğini ölçmek için kullanılır. Higuchi' nin fraktal boyutu, özellikle biyolojik ve tıbbi sinyallerin analizi için kullanılır. EEG sinyalleri, kalp ritimleri, nefes alma oranları ve diğer birçok biyolojik zaman serisi verisi üzerinde kullanılabilir.

HFD algoritması, fraktal boyutu (FD) doğrudan zaman serisinden hesaplar. FD zaman serisinin yapısının ne kadar karmaşık olduğunu belirlemek için kullanılır. Yani bir zaman serisi ne kadar düzensiz ve karmaşıksa Higuchi' nin fraktal boyutu o kadar yüksek olacaktır.

Bu ölçüm özellikle nörolojik bozuklukları olan bireylerin beyin dalgalarının analizi gibi durumlarda değerli olabilmektedir. HFD biyolojik sinyallerin analizi için kullanılan doğrusal olmayan bir yöntemdir [175]. Biyolojik sinyallerin karmaşıklığını analiz etmek kullanılabilen HFD [176] çalışma kapsamında sağlıklı bireylerden ve DEHB hastalarından elde edilen EOG sinyallerinin karmaşıklığını tespit etmek için kullanılmıştır.

2.3.7. Hjorth Parametreleri

Hjorth fizyolojik sinyal aktivitesinin sürekli bir analizini gerçekleştirecek nicel bir yöntem geliştirmiştir.

Hjorth parametreleri bir zaman serisi verisinin istatistiksel özelliklerini ölçmek için kullanılan üç özelliktir: aktivite, hareketlilik ve karmaşıklık. Bu parametreler özellikle biyolojik sinyallerin analizi (örneğin EEG, EOG sinyalleri vb.) için kullanılır.

- Aktivite: Bu parametre sinyal gücünü veya bir zaman serisinin varyansını temsil eder. Genel olarak sinyaldeki toplam enerjiyi veya değişkenliği ifade eder.
- Hareketlilik: Sinyalin frekans içeriğini temsil eder. Yani sinyalin ne kadar hızlı değiştiğini gösterir. Bu bir zaman serisinin standart sapmasının oranı veya güç spektrumunun ortalama frekansı olarak ölçülür.
- Karmaşıklık: Bir zaman serisi verisinin ne kadar düzensiz veya karmaşık olduğunu gösterir. Bu genellikle sinyalin frekans değişiminin ne kadar hızlı olduğunu ölçer [177].

Hjorth parametreleri özellikle beyin dalgalarını analiz ederken ve belirli beyin durumlarını veya bozukluklarını tanımlarken çok kullanışlıdır. Çalışmada Hjorth parametreleri sağlıklı bireylerden ve DEHB hastalarından kaydedilen EOG sinyallerinin istatistiksel özelliklerini tespit etmek için kullanılmıştır.

DEHB ve sağlıklı bireyleri sınıflandırmak için parametrelere karar ağacı (Decision Tree-DT), destek vektör makinesi (Support Vector Machine- SVM) ve K-en yakın komşu (K-Nearest Neighbor- K-NN) makine öğrenmesi algoritmaları uygulanmıştır [178].

2.3.8. Karar Ağaçları (Decision Tree – DT)

DT makine öğrenmesi ve veri madenciliği alanlarında sıklıkla kullanılan bir sınıflandırma ve regresyon yöntemidir. DT verileri analiz etmek ve verilere dayalı tahminler yapmak için bir dizi karar kuralına dayanır.

Karar ağacı modeli bir ağaç yapısı kullanır. Her "dal" bir özellik veya öznelik (bir değişkenin belirli bir değeri), her "düğüm" bir karar ve her "yaprak" bir tahminli sonuçtur.

Model karar düğümündeki bir özelliğe bakar ve belirli bir kurala (örneğin bir özellik belirli bir değerden büyük veya küçük mü) dayalı olarak bir sonraki düğüme gitmeye karar vermektedir. Bu süreç model bir yaprak düğümüne (bir sonuç) ulaşana kadar devam eder [179].

Karar ağaçları, çeşitli avantajlara sahiptir. Öncelikle sonuçları anlamak ve yorumlamak nispeten kolaydır. Çünkü ağaç yapısı kararların ve tahminlerin akışını açıkça göstermektedir. İkincisi karar ağaçları kategorik ve sürekli değişkenleri

işleyebilmektedir. Üçüncüsü ise ağaç yapısı, karmaşık etkileşimleri ve ilişkileri yakalayabilmektedir. Ancak, karar ağaçlarının da aşırı uyum ve karar ağacının karmaşıklığı gibi bazı zorlukları bulunmaktadır.

2.3.9. K-En Yakın Komşu (K- Nearest Neighbors - K-NN)

K-NN algoritması bir sınıflandırma ve regresyon yöntemi olan denetimli öğrenmenin basit ve etkili tekniklerinden biridir. Bu algoritma bir örneğin sınıfını belirlemek için, örneğin 'k' en yakın komşusuna bakar. Bu 'k' komşuların çoğunluğu neyse örneğin sınıfı o olmaktadır. K-NN algoritması 'k' parametresine bağlı olarak birkaç şekilde uyarlanabilir. 'k' değeri 1 olduğunda, algoritma sadece en yakın komşuyu dikkate alır. 'k' değeri arttıkça algoritma daha fazla komşuyu dikkate alır. Bu da tahminin daha düşük varyans ancak daha yüksek yanlışlık olasılığı ile sonuçlanır.

K-NN algoritması bir dizi avantaja sahiptir. Özellikle modelin eğitilmesi gerekmez. Bu da onu "tembel" bir öğrenme algoritması yapar. Ayrıca K-NN gürültülü verilere karşı oldukça dirençli olabilir ve çoklu sınıflı durumlarla iyi başa çıkabilmektedir. Ancak K-NN'nin performansı, uygun 'k' değerinin seçilmesine ve uygun bir mesafe metriğinin seçilmesine bağlıdır [180].

2.3.10. Destek Vektör Makinesi (Support Vector Machine – SVM)

SVM ikili sınıflandırma problemlerine uygulanabilen güçlü ve esnek denetimli öğrenme modellerinden biridir. SVM veri noktalarını ayrı bir hiper düzlem oluşturarak sınıflandırır. SVM'nin ana fikri, sınıflar arasında en geniş 'marj' ı bulmaktır; bu marj, hiper düzlem ile en yakın veri noktaları (destek vektörleri) arasındaki mesafedir [181].

SVM ayrıca 'çekirdek hilesi' ne sahiptir. Bu durum verileri daha yüksek boyutlu bir uzaya dönüştürerek doğrusal olmayan sınıflandırma problemlerinin üstesinden gelme yeteneği sağlamaktadır. Bu özellik SVM'nin karmaşık ve doğrusal olarak ayıramayan veri setlerinde bile etkili olmasını sağlamaktadır [182].

Çalışma kapsamında DEHB ve sağlıklı bireylerden elde edilen parametrelerin DT, K-NN ve SVM ile sınıflandırma işlemi gerçekleştirilmiştir.

Hibrit ayrıştırma ve derin öğrenme teknikleri kullanılarak EEG sinyallerinden DEHB tespiti yapılan bir çalışma gerçekleştirilmiştir. Çalışmada çeşitli ayrıştırma teknikleri ve tasarladığımız bir derin öğrenme algoritması kullanılmıştır. Çalışmada EEG sinyalleri ile DEHB için objektif bir tanı aracı geliştirilmesi amaçlanmıştır. EEG sinyalleri ayrıştırma yöntemleri ile alt bantlara ayrılmış olup elde edilen alt bant sinyalleri ile birlikte derin öğrenme algoritmasına giriş yapılmıştır [183]. Elde edilen sonuçlar bulgular bölümünde sunulmuştur. Çalışma kapsamında kullanılan yöntemler aşağıda sunulmuştur.

2.3.11. Değişken Mod Ayrıştırması (Variational Mode Decomposition - VMD)

VMD zamanla değişen ve durağan olmayan sinyalleri işlemek üzere geliştirilmiş bir döngüsüz ayrıştırma algoritmasıdır. VMD zaman serilerini yeniden üretilebilir bant genişliği sınırlı alt modlara ayırabilir [184]. VMD 'f' olarak adlandırılan bir gerçek değerli sinyali, sinyalin spektrumundaki bant genişliği ile belirli seyreklik özelliklerine sahip 'uk' adındaki bir dizi alt sinyale ayırabilir. Her mod merkez frekans (w_k) etrafında yoğunur. Bant genişliği kaydırılmış sinyal VMD'nin 'H1' Gauss düzgünlüğünü kullanarak tahmin edilir [185].

$$\min_{\{u_k\}, \{w_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) x u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (2.3)$$

Burada $\{u_k\} := \{u_1, \dots, u_K\}$ ve $\{w_k\} := \{w_1, \dots, w_K\}$ sırasıyla tüm modların ve merkez frekanslarının kısaltma belirlemeleridir. Aynı şekilde $\sum_k := \sum_{k=1}^K$ tüm modların toplamıdır [186].

Çalışmada EEG sinyaline VMD uygulanarak alt bant sinyalleri elde edildi. Deneyler sonucunda, alt bant sinyallerinin sayısı 3 olarak seçildiğinde derin öğrenme algoritmasının çıktısında en yüksek öğrenme başarısı elde edildi. Bu nedenle, EEG sinyali VMD uygulayarak üç alt banta ayrılmıştır [183].

2.3.12. Güçlü Yerel Ortalama Ayrıştırması (Robust Local Mean Decomposition - RLMD)

LMD 2.3.1 de açıklanmıştır. LMD bir frekans modüle sinyali bir genlik modüle zarf sinyalinden kademeli olarak ayırmaktadır. Bu ayırım orijinal sinyalin düzleştirilmesi,

düzeltilmiş sinyalin orijinal sinyalden çıkarılması ve sonrasında bir zarf tahmini kullanılarak sonucun genlik demodülasyonunun yapılması ile gerçekleştirilir. Zarf tahmini orijinal sinyalin ardışık uçlarının arasındaki hızlandırılmış ağırlıklı hareketli ortalamayı kullanarak elde edilir. Bu ayırım süreci kalan sinyalde osilasyon içermediği duruma kadar devam etmektedir. Özetlemek gerekirse bir sinyalin LMD' si, sinyali hareketli ortalama kullanarak kademeli olarak düzleştirerek elde edilir.

Çalışmada EEG sinyallerine RLMD uygulayarak alt bant sinyallerini elde edilmiştir. RLMD optimizasyon stratejileri ile LMD 'nin sınır koşullarını, zarf tahminini ve durdurma kriterlerini ele alan optimize edilmiş bir yerel ortalama ayrışmasıdır. RLMD bir karma sinyalden birçok tek bileşenli sinyali (ürün fonksiyonları olarak adlandırılır) ve bunlarla ilişkili demodülasyon sinyallerini (yani AM ve FM sinyallerini) aynı anda çıkarabilmektedir. RLMD zaman-frekans analizi için kullanılabilir [187]. Çalışmada RLMD Matlab fonksiyonu kullanılmıştır [188]. Sinyal VMD' deki gibi deneysel olarak belirlenen üç alt banta ayrılmıştır.


2.3.13. Derin Sinir Ağları (DSA)

Bu çalışmada derin sinir ağı mimarilerinden biri olan CNN yapısı kullanıldı. CNN 2.3.2 de açıklandığı üzere örüntü tanıma alanında çığır açan sonuçlara sahiptir. Görüntü işlemeden ses tanımaya kadar birçok kullanım alanı vardır. CNN'lerin en yararlı yönü, YSA'daki parametre sayısını azaltmasıdır. Bu CNN'nin klasik YSA'larla mümkün olmayan karmaşık görevleri çözmek için kullanılmasını sağlamaktadır [189]. CNN öğrenme yoluyla kendilerini optimize eden nöronlardan oluşur. CNN ve YSA arasındaki belirgin fark CNN'lerin görüntüler içindeki örüntüleri tanımada yüksek performans göstermesidir [190-191].

CNN mimarisi temelde şu şekilde çalışır: Evrişim katmanları girişe uygulanan ağırlıkları çarparak girişin yerel bölgelerine bağlı nöron çıktıları belirler. ReLu (düzeltici doğrusal birim) önceki katman tarafından üretilen aktivasyon çıktısına bir aktivasyon fonksiyonu olan sigmoidi uygulamayı amaçlar. Havuzlama katmanları verilen girişin mekansal boyutuna göre örnekleme yapar ve bu aktivasyon içindeki parametre sayısını azaltır. Sınıflandırma sonucuna ulaşmak için tamamen bağlı katmanlar aktivasyonlardan sınıf puanları oluşturmayı amaçlar. Performansı artırmak için katmanlar arasında ReLu kullanılması önerilmektedir [189-191].

Çalışmada tasarlanan CNN yapısı EEG sinyallerine uygulanmıştır. EEG sinyalleri bir görüntü matrisi gibi CNN yapısına giriş verisi olarak uygulanarak sınıflandırma çalışması gerçekleştirilmiştir.

Veri işleme ve derin öğrenme algoritması tasarımı MATLAB R2021b sürümü kullanılarak gerçekleştirilmiştir. Öncelikle EEG sinyalinin her kanalı önışlemden geçirilmiş ardından sinyallerin alt bantları RLMD ve VMD uygulamaları gerçekleştirilerek hesaplanmıştır. Sinyal ve alt bantları derin öğrenme algoritmasına giriş verisi olarak uygulanmıştır. Tasarlanan derin öğrenme algoritması Şekil 2.13' te görülmektedir.



Şekil 2.13. Tasarlanan DSA Algoritması

Tasarlanan algoritmaya göre ön işlemden sonra EEG sinyali bir görüntü matrisiymiş gibi algoritma girişi olarak uygulanır. Ardından Evrişim Katmanı, Yığın Normalleştirme Katmanı ve Relu Katmanı işlemleri uygulanır. Bu işlem üç kez tekrarlanır. Daha sonra, üç Tam Bağlantılı Katman işlemi ile 100-50-2 olarak elde edilen aktivasyon çıktılarından

sınıflandırma sonucuna ulaşılmaya çalışılır. Son olarak derin öğrenme algoritması Softmax Katmanı ile tamamlanmıştır.

Tez sürecinde gerçekleştirdiğimiz bir başka çalışmada DEHB tespiti için göz hareketi tabanlı bir DSA geliştirilmiştir. Bu yeni çalışmada alanda özgün bir uygulama olan DEHB tespiti için EOG sinyallerini kullanan objektif bir tanı aracı geliştirilmiştir. Hem teşhis konan hastalardan hem de sağlıklı katılımcılardan elde edilen EOG sinyalleri, özel olarak tarafımızca tasarlanmış derin öğrenme algoritması EOGtNetV1'in yanı sıra sahada yaygın olarak kullanılan derin öğrenme algoritmaları için de girdi verileri olarak uygulanmıştır. Elde edilen sonuçlar bulgular bölümünde sunulmuştur. Yaygın kullanılan derin öğrenme algoritmaları ve tasarladığımız algoritmaya ilişkin çalışma kapsamında kullanılan yöntemler aşağıda sunulmuştur.

2.3.14. ResNet50

50 katmanlı artıklar ağının (residual networks) kısaltmasıdır. Eğitim setine aşırı uyma (overfitting) sorununu önlemeye yardımcı olan bir yapıya sahiptir [192]. Karmaşık görevlerin çözülmesinde ve tespit doğruluğunun artırılmasında fayda sağlar. Derin CNN'nin eğitim sürecindeki zorlukları ve doğruluk oranının azalmasını önlemek için geliştirilmiştir. Ağ yapısı, evrişim katmanları, bağlantı blokları, kimlik blokları, havuzlama katmanları ve tam bağlantılı katmanları içerir [193]. ResNet50 ağ yapısı giriş katmanında 224x224x3 boyutunda görsellerin girişine izin verir.

2.3.15. MobileNet

Mobil ve gömülü görüntü uygulamalarının tasarım gereksinimlerine uygun, düşük gecikme süreli bir ağ olarak tasarlanmıştır. MobileNet yapısı ilk evrişim katmanı dışında, derinlik bazlı ayrılabilir evrişim katmanlarına dayanmaktadır. Ağ yapısı evrişim katmanı, derinlik bazlı ayrılabilir evrişim katmanı, havuzlama katmanı, tam bağlantılı katmanı, yığın normalleştirme katmanı ve ReLU'yu [194] içerir. MobileNet ağ yapısı giriş katmanında 224x224x3 boyutunda görsellerin girişine izin verir.

2.3.16. SqueezeNet

SqueezeNet'in dağıtık eğitim sırasında sunucular arasında daha az iletişim gereksinimi, daha az bant genişliği gereksinimi ve daha az hafıza gerektiren birimlerde kullanılma

potansiyeli gibi avantajları bulunmaktadır. SqueezeNet, AlexNet seviyesinde doğruluk elde edebilmekte ve model sıkıştırma tekniklerini kullanarak SqueezeNet'i AlexNet'ten 510 kat daha küçük olan 0.5MB'den daha az bir boyuta sıkıştırabilmektedir. Öncelikli olarak CNN mimarisini kullanır. Mimarisinde evrişim katmanları, ateşleme modülleri (fire modules), havuzlama katmanları, tam bağlantılı katmanlar bulunur [195]. SqueezeNet ağ yapısı giriş katmanında $227 \times 227 \times 3$ boyutlu görsellerin girişine izin verir.

2.3.17. AlexNet

AlexNet üstün görüntü sınıflandırma performansına sahiptir. Çıkış zamanında en yüksek sınıflandırma doğruluğuna sahip olduğu gösterilmiştir. AlexNet bir CNN yapısını kullanır. Ağ yapısı evrişim, ReLU, kanal boyunca normalizasyon, maksimum havuzlama, tam bağlantılı katmanları içerir [196, 197]. AlexNet 60 milyon parametre ve 650000 nörona sahip bir sinir ağı modelidir. Eğitimi hızlandırmak için doymamış nöronları kullanır ve GPU ile evrişim işlemini etkin bir şekilde gerçekleştirebilir. Tam bağlantılı katmanlardaki aşırı uyumu azaltmak için "dropout" adı verilen bir düzenleme yöntemi kullanır [197]. AlexNet ağ yapısı giriş katmanında $227 \times 227 \times 3$ boyutlu görsellerin girişine izin verir.


2.3.18. DenseNet

DenseNet ağ yapısı yoğun evrişimli ağ (dense convolutional network) ifadesinin kısaltmasıdır. Bu ağ yapısı ile çıktıya yakın katmanlar ile girişe yakın katmanlar arasında bağlantıları olan evrişim ağlarının daha doğru ve etkin bir şekilde eğitilebileceği vurgulanmaktadır. DenseNet ağ yapısında her katman tüm önceki katmanların özellik haritalarını giriş olarak kullanır. Böylece özellik haritaları tüm sonraki katmanlar için giriş olarak kullanılır. DenseNet kaybolan gradyan problemini azaltır. Özellik yayılımını güçlendirir ve parametre sayısını önemli ölçüde azaltır. Ağ yapısı bir evrişim katmanı, yoğun bloklar, geçiş katmanları, havuzlama katmanları, tam bağlantılı katmanları içerir [198]. DenseNet ağ yapısı giriş katmanında $224 \times 224 \times 3$ boyutlu görsellerin girişine izin verir.

2.3.19. Tasarlanan Ağ Yapısı (EOGtNetV1)

Tasarlanan ağ yapısında evrişim katmanları, yığın normalleştirme katmanları, relu katmanları, maksimum havuzlama katmanları ve tam bağlantı katmanları bulunmaktadır.

Tasarladığımız ağ yapısı Şekil-4'te görülebilir. EOG verileri iki kanallı elektrofizyolojik sinyallerdir. Literatürdeki ağ yapıları genellikle görüntü matrisleri üzerinde çalışmaya odaklanan yapılar olup, her zaman EOG sinyalinde uygulama için uygun olmayabilmektedir. Bu nedenle "EOG Train Net Version 1" kısaltması olarak EOGtNetV1'i geliştirdik.



Yapılan çalışma ile elde edilen sonuçlar bulgular bölümünde sunulmuştur.

2.3.20. Tez Çalışması Verileriyle Yapılan İşlemler ve Tasarlanan Ağ Yapısı

2.2 ve alt başlıklarında ifade edildiği üzere ivmeölçer, jiroskop, nabız, GDC, EOG, EEG verileri elde edildikten sonra veriler üç durum için ayrıştırılmıştır.

- Birimci durum görsel uyaran takip testi öncesi kayıtlardan oluşmaktadır. Burada 8 kanal veri bulunmaktadır. İlk üç kanal ivmeölçer verileri, devamındaki üç kanal jiroskop verileri, devamındaki bir kanal GDC, diğer kanal da nabız sinyaline ait verilerden oluşmaktadır. Verilerin örnekleme frekansı 20 Hz dir. Veri kayıt uzunluğu ise beş dakika olarak belirlenmiştir. Bu kayıtlar tüm katılımcılardan serbest olarak hareketleri sırasında elde edilmiştir. Yani hiçbir hareket kısıtlaması olmaksızın elde edilmiştir.
- İkinci durum görsel uyaran takip testi sırasında bilgisayar başında otururken elde edilen kayıtlardır. Burada da birinci durum da kaydedilen veriler aynı şekilde

kaydedilmiştir. Ancak burada hareket kısıtlaması bulunmaktadır. Katılımcıların kayıtları bilgisayar ekranı başında gerçekleştirilmiştir. Görsel uyaran takip testi ile eş zamanlı olarak kayıt alınmıştır. Burada kayıt uzunluğu test süresi kadardır. Görsel uyaran takip testi 2.2.1 de ifade edildiği üzere üç bölümden oluşmaktadır. Her bir bölüm test-1, test-2, test-3 olarak adlandırılmaktadır. Test bölümlerinin toplam uzunluğu 175 sn dir (test-1 55 sn, test-2 60 sn, test-3 60 sn). Yani ikinci durumda toplam 175 saniye, birinci durumda belirtilen 8 kanal veri kaydı alınmıştır. 8 kanal veriye ek olarak görsel uyaran takip testi sırasında katılımcıların EOG ve EEG sinyalleri de eş zamanlı olarak 2.2 de belirtildiği şekilde kaydedilmiştir. EOG ve EEG sinyal kaydı toplam 5 kanaldan oluşmaktadır. 1. kanal yatay EOG sinyali, 2. kanal EEG T3-T4 sinyali, 3. kanal EEG F7-F8 sinyali, 4. kanal EEG F3-F4 sinyali, 5. kanal ise EEG C3-C4 sinyalidir. 2.2 de belirtilen cihaz ve sistemle elde edilen EOG, EEG sinyallerinin örnekleme frekansı 500 Hz dir. Sinyal uzunlukları ise 175 saniyedir. Veriler üç test bölümünün tamamı için tüm kayıtlar olarak ve her bir test bölümleri olarak ayrı ayrı değerlendirilmiştir. İkinci durumda toplamda 13 kanal veri kaydı elde edilmiştir.

- Üçüncü durum da ise görsel uyaran takip testi ile yapılan çalışmanın tamamlanması akabinde birinci durumda ifade edildiği şekilde tekrar 5 dakikalık 8 kanal veri kaydı alınmıştır. Birinci durumla aynı şekilde üçüncü durumdaki kayıta da hiçbir hareket kısıtlaması bulunmamaktadır.

Birinci ve üçüncü durumda verilerin örnekleme frekansı 20 Hz, kayıt süreleri de 5 dk olduğu için toplam veri uzunlukları $20 \times 5 \times 60$ (sn) den 6000 veriden oluşmaktadır. Yani her bir katılımcı için 6000×8 kanal veri kaydı bulunmaktadır.

İkinci durum için ise veri uzunluğu farklıdır. İkinci durumda 20 Hz örnekleme frekansında 175 sn uzunluğunda 8 kanal veri kaydı bulunmaktadır. 20×175 den 3500×8 kanal veri bulunmaktadır. Ayrıca 5 kanal EOG ve EEG sinyal kaydı bulunmaktadır. Bu sinyallerin örnekleme frekansı 500 Hz dir. Veri uzunluğu ise 175 sn dir. Yani 175×500 den 87500×5 kanal veri bulunmaktadır. Eş zamanlı olarak kaydedilen 3500×8 ve 87500×5 kanal veriyi toplam 13 kanal olarak birleştirmek için düzenleme yapmaya ihtiyaç duyulmuştur. Bu amaçla herhangi bir veri kaybı yaşamaması için verilerin yapılarına

uygun olarak 20 Hz de elde edilen 8 kanal verinin örnekleme frekansının 100 Hz' e çıkarılması, 500 Hz de elde edilen 5 kanal verinin örnekleme frekansının ise 100 Hz' e düşürülmesi çalışması yapılmıştır.

20 Hz verilerin 100 Hz' e çıkarılması için interpolasyon işlemi gerçekleştirilmiştir. İnterpolasyon işlemi bilinen veri noktaları arasında yeni veri noktaları oluşturmak için kullanılan bir matematiksel tekniktir. 20 Hz veriyi 100 Hz' e çıkarmak için 100 Hz, 20 Hz' in beş katı olduğundan, her bir veri noktası arasına dört tane yeni veri noktası eklenmiştir. Aşağıda 20 Hz frekansında $x[n]$ zaman serisinin 100 Hz' e çıkarılmasında bulunacak 4 yeni veri noktasının hesaplanması işlemi formüle edilmiştir (2.4-2.7).

$$x[n+0.2]=x[n]+0.2(x[n+1]-x[n]) \quad (2.4)$$

$$x[n+0.4]=x[n]+0.4(x[n+1]-x[n]) \quad (2.5)$$

$$x[n+0.6]=x[n]+0.6(x[n+1]-x[n]) \quad (2.6)$$

$$x[n+0.8]=x[n]+0.8(x[n+1]-x[n]) \quad (2.7)$$

Genel olarak bu işlem yapılarak 20 Hz verinin örnekleme frekansının 100 Hz' e çıkarılması, yani aynı süredeki veri setinin diğer bir tabirle zaman serisinin veri sayısının 5 katına çıkması sağlanmıştır.

500 Hz de kaydedilen EOG ve EEG verilerinin örnekleme frekansının 100 Hz'e düşürülmesi işlemi gerçekleştirilmiştir. Bunun için örneklem azaltma tekniği uygulanmıştır. Zaman serisindeki sıraları her beş veriden biri alınarak örneklem sayısı beşte birine düşürülmüştür.

Böylece ikinci durum için 175 sn uzunluğunda 100 Hz örnekleme frekansında toplam 13 kanal veri elde edilmiştir. 175×100 den 17500×13 boyutunda her bir katılımcının verisi elde edilmiştir.


Veri boyutlandırma ile ilgili çalışma tamamlandıktan sonra elde edilen tüm verilere genlik normalizasyonu işlemi uygulanmıştır. Verilerin genlik değerleri her bir kanalda farklı ve geniş bir aralıkta dağılım göstermektedir. Veriler derin öğrenme ağ yapısına uygulanacağı için dağınık genlik değerlerinin sistemin çalışma performansını etkileyebileceği değerlendirilmiştir. Bu kapsamda tüm verilerin 0-1 genlik değerleri

arasında dağılım göstermesi istenmiştir. Bu amaçla genlik normalizasyonu işlemi tüm verilere uygulanmıştır.

$$X_{normal}(i, 1) = \frac{X(i,1)-\min(X)}{\max(X)-\min(X)} \quad (2.8)$$

Genlik normalizasyon işlemi formülü 2.8 de görülmektedir. Burada ‘X’ veri setini, ‘i’ veri setinin i. elemanını, ‘min’ ve ‘max’ veri setinin minimum ve maksimum değerlerini ifade etmektedir. Belirtilen genlik normalizasyon işlemi ile tüm veri seti 0-1 genlik değerleri aralığında düzenlenmiştir.

Belirtilen düzenlemeler yapıldıktan sonra veriler derin öğrenme algoritmasında eğitime ve test edilmeye hazır hale gelmiştir. Yapılan çalışmalar sonucunda Şekil 2.15’ te sunulan ağ yapısının tez çalışması kapsamında elde edilen veriler ile çeşitli analizlerde optimal sonucu verdiği ve yüksek başarı ile HB olan ve sağlıklı olan bireyleri ayırt edebildiği tespit edilmiştir.



Şekil 2.15. Derin Öğrenme Ağ Yapısı

Şekil 2.15’ te tüm veriler yukarıda açıklanan ön işleme süreçlerinden sonra CNN tabanlı tek boyutlu bir derin öğrenme algoritmasına giriş verisi olarak uygulanmıştır. Şekilde

görülen evrişim, havuzlama, relu, tam bağlantı katmanları ve sınıflandırma katmanı ile sonuca ulaşılmıştır. Çalışmanın tüm analiz süreçleri Matlab R2021b ortamında gerçekleştirilmiştir.

Eğitim sürecinde aşırı öğrenme yani ezberlemeyi engellemek için derin öğrenme algoritmasının eğitim sürecine “Validation patience” stratejisi eklenmiştir. Literatürde geçen yaygın kullanım adı Türkçe’ye “doğrulama sabrı” olarak çevrilebilir ancak Türkçe’de yaygın kullanımı yoktur. Bu yaklaşım derin öğrenme modeli eğitilirken erken durdurma stratejisinin bir parçasıdır. Erken durdurma, modelin eğitim sürecini izler ve belirli bir süre boyunca (belirlenen süre kadar) modelin doğrulama seti üzerindeki performansında bir iyileşme olmadığında eğitimi durdurur. Bu yaklaşım aşırı öğrenme veya ezberlemeyi önlemeye yardımcı olmaktadır. Çalışmada validation_patience = 5 olarak seçilmiş olup bu durum modelin doğrulama seti üzerindeki performansı 5 tekrar boyunca iyileşmezse eğitimin durdurulacağı anlamına gelmektedir.

Eğitim ve test sürecinde literatürde K-fold cross validation olarak adlandırılan Türkçe kullanımı ise K-katlı çapraz doğrulama olan teknik kullanılmıştır. K-katlı çapraz doğrulama, bir modelin performansını değerlendirmek için kullanılan bir tekniktir. Çalışma kapsamında elde edilen veri seti derin öğrenme algoritma yapısında eğitim ve test setlerine ayrılarak eğitilmiş ve test edilerek model performansı değerlendirilmiştir.

K-katlı çapraz doğrulamada veri seti 'K' adet alt sete ayrılır. Sonra 'K' adet farklı eğitim ve test süreci gerçekleştirilir. Her bir süreçte 'K-1' adet alt set, eğitim seti olarak; kalan 1 adet alt set ise test seti olarak kullanılır. Bu işlem her bir alt setin bir kez test seti olarak kullanılmasıyla 'K' kez tekrarlanır. Daha sonra bu 'K' adet eğitim ve test sürecinin sonuçları alınır ve ortalaması alınarak modelin nihai performansı belirlenir.

Tez çalışması kapsamında da K=5 seçilerek model performansı değerlendirilmiştir. Elde edilen sonuçlardan literatürde confusion matrisi olarak ifade edilen Türkçesi karışıklık-karmaşıklık matrisi olarak da kullanılan matris tablosu oluşturulmuştur. Karmaşıklık matrisi sınıflandırma problemlerinde modelin performansını değerlendirmek için kullanılan bir tablodur. Bu matris, modelin tahminlerini ve gerçek değerleri karşılaştırarak, modelin doğru ve yanlış tahminlerini gösterir. Karmaşıklık matrisi genellikle iki sınıflı (binary) sınıflandırma problemleri için kullanılmaktadır. 2x2 boyutunda bir matristir. Şekil 2.16 da karmaşıklık matrisi görseli sunulmuştur.

		Tahmin Edilen	
		1	0
Gerçek	1	DP	YP
	0	YN	DN

Şekil 2.16. Karmaşıklık Matrisi

Bu matrisin hücrelerine şu değerler bulunur:

- Doğru Pozitif (DP): Gerçek değeri pozitif olan ve modelin pozitif olarak doğru tahmin ettiği veri noktalarının sayısı.
- Doğru Negatif (DN): Gerçek değeri negatif olan ve modelin negatif olarak doğru tahmin ettiği veri noktalarının sayısı.
- Yanlış Pozitif (YP): Gerçek değeri negatif olan ve modelin yanlışlıkla pozitif olarak tahmin ettiği veri noktalarının sayısı.
- Yanlış Negatif (YN): Gerçek değeri pozitif olan ve modelin yanlışlıkla negatif olarak tahmin ettiği veri noktalarının sayısı.

Karmaşıklık matrisinden elde edilen bazı önemli parametreler şunlardır:

- Doğruluk: Bu parametre modelin doğru tahminlerinin toplam veri noktalarına oranıdır. Yani modelin hem pozitif hem de negatif sınıfları ne kadar doğru tahmin ettiğini gösterir. Formülü 2.9 da görülmektedir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YN+YP} \quad (2.9)$$

- Hassaslık/Duyarlılık: Bu parametre gerçek değeri pozitif olan veri noktalarından kaç tanesinin model tarafından doğru olarak pozitif olarak tahmin edildiğini

gösterir. Yani, modelin tüm pozitif veri noktalarını ne kadar doğru tahmin ettiğini gösterir.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (2.10)$$

- **Özgüllük:** Bu parametre gerçek değeri negatif olan veri noktalarından kaç tanesinin model tarafından doğru olarak negatif tahmin edildiğini gösterir. Yani, modelin tüm negatif veri noktalarını ne kadar doğru tahmin ettiğini gösterir.

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (2.11)$$

Bu parametreler modelin performansını değerlendirmek için kullanılır ve genellikle bir model seçerken veya modelin performansını iyileştirirken dikkate alınır.

Karmaşıklık matrisi kullanılarak doğruluk, özgüllük, hassasiyet parametreleri ve doğruluk oranlarının standart sapması gibi değerler hesaplanmıştır.

Doğruluk oranlarının standart sapması bir modelin farklı test setlerindeki performansının ne kadar değişken olduğunu göstermektedir. Eğer bir modelin doğruluk değerlerinin standart sapması düşükse, bu modelin farklı test setlerinde benzer performans gösterdiği anlamına gelmektedir. Eğer standart sapma yüksekse, bu modelin farklı test setlerindeki performansının değişken olduğu anlamına gelmektedir. Bu kapsamda k-katlı çapraz doğrulama sonucunda elde edilen doğruluk oranlarının standart sapması (Formül 2.12) hesaplanmıştır.

$$\sqrt{\frac{\sum (x - \bar{x})^2}{N-1}} \quad (2.12)$$

Burada ‘ x ’ her bir doğruluk oranını ifade ederken ‘ $\bar{x}$ ’ doğruluk oranlarının ortalamasını ifade etmektedir. ‘ N ’ ise eleman sayısını yani doğruluk sayısını ifade etmektedir.

Bulgular bölümünde Şekil 2.15’te sunulan ağ yapısı çıkışında elde edilen k-katlı çapraz doğrulamanın her bir katında elde edilen başarı oranları ve bu oranların standart sapma değerleri sunulmuştur.

3. BÖLÜM

BULGULAR

Tez çalışması kapsamında gerçekleştirilen çalışmalara ait bulgular bu bölümde sunulmuştur. İkinci bölüm olan Materyal ve Yöntem bölümünde detayları ayrı ayrı ifade edilen çalışmaların bulguları alt başlıklar halinde bu bölümde ortaya konacaktır.

3.1. İvmeölçer Verilerine LMD Uygulaması Bulguları

LMD uygulaması yapılarak gerçekleştirilen çalışmanın bulguları aşağıda sunulmuştur. Yapılan işlemlerin ve kullanılan yöntemlerin detayları 2.3 ve 2.3.1 başlıkları altında ifade edilmiş olan çalışma kapsamında kontrollü hareketler sırasında kaydedilmiş 5 erkek ve 5 kadın katılımcıya ait ivmeölçer verilerinden yürüme, koşma, merdiven çıkma, merdiven inme hareketlerinin tespit edilmesi amaçlanmıştır.

Bu kapsamda LMD fonksiyonu kullanılmıştır. MATLAB de ilgili fonksiyon kullanılarak elde edilen çıktıdaki ortogonalite parametresine göre hareket tespitine yönelik değerlendirme yapılmıştır [160]. İvmeölçer veri kayıtlarının her bir eksen için LMD yöntemi uygulanmış ve elde edilen verilerin ortogonalite değerleri karşılaştırılmıştır. Elde edilen sonuçlar aşağıda tablolar halinde sunulmuştur.

Tablo 3.1. Merdiven inme ortogonallik deęerleri

MERDİVEN İNME	x	y	z	e/k
1	0,0479	0,0393	0,0959	e
2	0,0806	0,0372	0,1258	k
3	0,0554	0,1131	0,0642	e
4	0,0698	0,0568	0,1257	k
5	0,0496	0,0622	0,0933	k
6	0,0345	0,0947	0,0664	e
7	0,1594	0,0975	0,0361	k
8	0,0646	0,0675	0,0921	k
9	0,0336	0,0768	0,0543	e
10	0,0914	0,139	0,0597	e
Ortalama	0,06868	0,07841	0,08135	

Tablo 3.1’ de merdiven inme aktivitesi sırasında ivmeölçerin z eksenine ait ortalama ortogonallik deęerinin x ve y eksenlerine göre daha yüksek olduęu görölmektedir.

Tablo 3.2. Merdiven çıkma ortogonallik değerleri

Merdiven Çıkma	x	y	z	e/k
1	0,0492	0,0713	0,1098	e
2	0,0696	0,0366	0,1505	k
3	0,0577	0,0775	0,1218	e
4	0,0711	0,0426	0,1253	k
5	0,025	0,0401	0,1444	k
6	0,0575	0,0567	0,0562	e
7	0,1596	0,0427	0,096	k
8	0,1024	0,0376	0,1551	k
9	0,0404	0,1405	0,1783	e
10	0,071	0,1004	0,1419	e
Ortalama	0,07035	0,0646	0,12793	

Tablo 3.2’ de merdiven çıkma aktivitesi sırasında ivmeölçer sensörünün z eksenine ait ortalama ortogonallik değerinin x ve y eksenlerine göre daha yüksek olduğu görülmektedir.

Tablo 3.3. Koşu aktivitesi ortogonallik değerleri

KOŞU	x	y	z	e/k
1	0,1256	0,0674	0,0415	e
2	0,1195	0,243	0,0809	k
3	0,0606	0,1874	0,0912	e
4	0,0609	0,123	0,0924	k
5	0,088	0,109	0,1091	k
6	0,0548	0,1417	0,0543	e
7	0,2711	0,0748	0,1041	k
8	0,0324	0,2242	0,0617	k
9	0,0332	2,6664	0,0295	e
10	0,0477	0,0704	0,0465	e
Ortalama	0,08938	0,39073	0,07112	

Tablo 3.3’ te koşma aktivitesi sırasında ivmeölçerin y eksenine ait ortalama ortogonallik değerinin x ve z eksenlerine göre daha yüksek olduğu görülmektedir.

Tablo 3.4. Yürüme aktivitesi ortogonallik değerleri

YÜRÜME	x	y	z	e/k
1	0,1016	0,0525	0,201	e
2	0,1075	0,0406	0,1125	k
3	0,0775	0,0788	0,0949	e
4	0,0993	0,0686	0,1517	k
5	0,0502	0,0371	0,1466	k
6	0,0349	0,1244	0,0797	e
7	0,2907	0,0558	0,2222	k
8	0,0221	0,0369	0,09	k
9	0,1312	0,1184	0,0634	e
10	0,246	0,0818	0,0561	e
Ortalama	0,1161	0,06949	0,12181	

Tablo 3.4’ te yürüme aktivitesi sırasında ivmeölçerin z eksenine ait ortalama ortogonallik değerinin x ve y eksenlerine göre daha yüksek olduğu görülmüştür.

Tablo 3.1, 3.2, 3.3 ve 3.4’ ten elde edilen bulgulara göre sadece ivmeölçer sensörü ile kontrollü hareketin yüksek doğrulukla tahmin edilebileceği görülmektedir. Çalışma bulgularının detaylı değerlendirilmesi “Tartışma-Sonuç ve Öneriler” bölümünde ifade edilmiştir.

3.2. Derin Sinir Ağıyla Aktivite Tanımlama Uygulaması Bulguları

Derin sinir ağı ile insan aktivitesinin tanımlanabileceği yaklaşımla gerçekleştirilen çalışmaya ait bulgular bu başlık altında sunulmuştur. Çalışma kapsamında 24 katılımcıya ait altı farklı fiziksel hareketin ivmeölçer ve jiroskop verileri ile sınıflandırılıp tespit edilmesi amaçlanmıştır [166]. 24 katılımcının birden fazla kayıtları veri tabanından alınarak çalışma gerçekleştirilmiştir [159]. Koşma, yürüme, merdiven inme, merdiven çıkma, ayakta durma ve oturma aktiviteleri sırasında kaydedilen 3 eksen ivmeölçer ve 3 eksen jiroskopa ait veriler 2.3.2 başlığı altında tasarımına ait detaylar bulunan derin öğrenme ağ yapısıyla eğitilmiş ve test edilmiştir. Elde edilen bulgular aşağıda sunulmuştur.

Jiroskop, ivmeölçer ve jiroskop+ivmeölçer sensörlerinden 30 saniye ve 20 saniye boyunca elde edilen veriler kullanılarak sınıflandırma çalışması gerçekleştirilmiş ve elde edilen ortalama sınıflandırma başarı oranları aşağıda Tablo 3.5’te sunulmuştur. Altı farklı hareket ikili gruplar halinde sınıflandırma çalışmasına dahil edilmiştir. Tabloda hareket tipleri kısaltılarak tanımlanmıştır. Merdiven inme (Mi), merdiven çıkma (Mç), koşma (Ko), yürüme (Yü), oturma (Ot), ayakta durma (Ad). Veri uzunluğu, 1500 veri olanlar 30 sn’lik çalışmanın bulgularını 1000 veri olanlar ise 20 sn’ lik çalışmanın bulgularını ifade etmektedir. 1000 veri olan çalışmada birim veri uzunluğu az olmasına rağmen daha fazla katılımcı bulunmaktadır. 1500 veri olan çalışmada ise birim veri uzunluğu daha fazladır ancak daha az katılımcı bulunmaktadır. Katılımcı sayısının ve veri uzunluğunun elde edilen sonuca etkisi değerlendirilmek için böyle bir yaklaşım sergilenmiştir.

Tablo 3.5. Hareket grupları sınıflandırma başarıları

Sayı	Hareket Tipi	Veri Uzunluğu	Jiroskop Ortalama Başarı	İvme Ölçer Ortalama Başarı	Jiroskop+İvme Ölçer Ortalama Başarı
1	Mi-Ko	1500	72,02	67,98	70,68
		1000	85	72,42	79,64
2	Mi-Ot	1500	96,84	96,82	96,82
		1000	98,1	95,38	99,06
3	Mi-Ad	1500	97,88	93,68	95,28
		1000	98,08	94,4	98,58
4	Mi-Mç	1500	95,7	66,32	68,84
		1000	96,8	53,04	72,5
5	Mi-Yü	1500	86,42	52,44	62,7
		1000	90,04	53,48	61,34
6	Ko-Ot	1500	100	97,32	97,34
		1000	98,88	95,56	99,44
7	Ko-Ad	1500	94,66	94,76	89,58
		1000	95,54	97,82	99,44
8	Ko-Mç	1500	74,68	77,44	81,54
		1000	86,12	90,92	84
9	Ko-Yü	1500	71,9	74,9	73,28
		1000	68,34	82,62	75,1
10	Ot-Ad	1500	88,52	96,84	93,24
		1000	80,24	98,94	91,68
11	Ot-Mç	1500	100	96,88	95,26
		1000	99,14	96,54	98,26
12	Ot-Yü	1500	100	98,26	99,16
		1000	100	97,5	99,58
13	Ad-Mç	1500	94,72	93,66	87,1
		1000	99,14	91,32	96,08
14	Ad-Yü	1500	99,16	95,82	97,9
		1000	97,5	94,18	96,24
15	Mç-Yü	1500	82,82	66,32	72,52
		1000	86,26	61,02	65,12

Bulguların değerlendirilmesi dördüncü bölümde gerçekleştirilmiştir.

3.3. EOG Sinyalleriyle YSA Kullanarak DEHB Tespiti Uygulaması Bulguları

EOG sinyalleriyle YSA kullanarak DEHB tespit etmek üzere gerçekleştirilen çalışmaya ait bulgular bu başlık altında sunulmuştur. Görsel uyaran takip testi sırasında kaydedilen DEHB ve sağlıklılara ait EOG sinyalleri kullanılmıştır. Sinyallerden çeşitli öznitelikler elde edilmiştir. Elde edilen öznitelikler YSA kullanılarak sınıflandırma çalışmasında kullanılmıştır [169].

Çalışmada görsel uyaran takip testi ile kaydedilen EOG sinyalinden elde edilen öznitelikler şunlardır:

- Toplam hareket sayısı: Sağlıklı ve DEHB olan katılımcıların görsel uyaran takip testinin üç bölümü için de ayrı ayrı hesaplanan toplam göz hareketi sayısıdır.
- Görsel çeldirici takip sayısı: Sağlıklı ve DEHB olan katılımcıların görsel uyaran takip testindeki görsel çeldiricileri takip ettikleri toplam sayıdır.
- Görsel uyaran tespiti: Görsel uyaran takip testinde, uyaranlar ekranda belirli bir periyotta ve yönde hareket etmektedir. Katılımcılardan görsel uyaran hareketini tarif etmeleri istenmiştir. Verdikleri cevap uyaranları tanımlayabiliyorsa "başarılı", tanımlayamıyorsa "başarısız" olarak değerlendirilmiştir.
- İşitsel uyaran tespiti: Görsel uyaran takip testinin üçüncü aşamasında işitsel uyaranlar bulunmaktadır. Bu uyaranlar ambulans sireni sesi ve okuldaki çocuk seslerinden oluşmaktadır. Testin uygulandığı kişilere hangi sesleri duydukları sorulmuştur. Katılımcı bu soruyu "çocuk sesi" ve "ambulans/siren sesi" şeklinde cevaplıyorsa "başarılı", eksik bir açıklamada ise "başarısız" olarak değerlendirilmiştir.

Görsel uyaran takip testinin üç bölümü için (çeldirici olmayan, görsel çeldirici olan, işitsel çeldirici olan bölümler) yönler göre göz hareket sayılarının başarı oranları Tablo 3.6' da sunulmuştur.

Tablo 3.6. Yönlere göre toplam hareket sayısının doğruluk oranları

Yönler	DEHB - İlk Kayıt	DEHB - Tedavi Sonrası Kayıt	Sağlıklı Kayıt
Sol-1	95,52%	92,56%	96,99%
Sol-2	97,41%	97,63%	94,04%
Sol-3	94,76%	95,83%	97,65%
Sağ-1	88,58%	85,13%	97,50%
Sağ-2	83,49%	82,76%	90,59%
Sağ-3	79,86%	79,10%	88,31%
Yukarı-1	97,42%	90,60%	97,45%
Yukarı-2	77,48%	86,15%	62,55%
Yukarı-3	83,27%	93,16%	72,94%
Aşağı-1	97,30%	97,52%	93,04%
Aşağı-2	77,61%	81,71%	61,76%
Aşağı-3	77,67%	85,56%	74,51%

Sağlıklı ve DEHB olan katılımcıların görsel uyaran takip testindeki görsel çeldirici olan bölümde uyaranları doğru takibi açısından elde edilen başarı oranları Tablo 3.7’ de sunulmuştur. Görsel çeldirici görsel uyaran takip testinin ikinci ve üçüncü test bölümlerinde bulunmaktadır. Üçüncü test bölümünde ayrıca işitsel çeldirici de bulunmaktadır.

Tablo 3.7. Görsel çeldirici durumunda doğruluk oranları

Test-2 Görsel Çeldiricili Bölüm				Test-3 Görsel+İşitsel Çeldiricili Bölüm		
Görsel Çeldirici	DEHB - İlk Kayıt	DEHB - Tedavi Sonrası Kayıt	Sağlıklı Kayıt	DEHB - İlk Kayıt	DEHB - Tedavi Sonrası Kayıt	Sağlıklı Kayıt
Kedi	65,66%	66,15%	67,78%	71,51%	68,21%	65,28%
Köpek	75,66%	78,21%	82,22%	73,40%	68,46%	71,11%
Ortalama	70,66%	72,18%	75,00%	72,45%	68,33%	68,19%

Görsel uyaran takip testinde uyaranlar ekranın köşe bölümlerinde ‘kare’ ve ‘z’ şeklini oluşturacak biçimde düzenli olarak hareket etmektedir. Testin uygulandığı katılımcılara görsel uyaran hareketini algılayıp algılayamadıkları sorulmuştur. ‘kare’ ve ‘z’ örüntüsünü doru tespit etme durumlarına göre doğruluk oranları Tablo 3.8’ de sunulmuştur.

Tablo 3.8. Görsel uyaran tespiti doğruluk oranları

DEHB - İlk Kayıt	DEHB - Tedavi Sonrası Kayıt	Sağlıklı Kayıt
33,85%	50,00%	75,61%

Görsel uyaran takip testinin üçüncü test bölümünde işitsel uyaran çeldiriciler bulunmaktadır. Bu işitsel çeldiriciler ambulans/alarm sesi ve okuldaki çocuk gürültüsü sesleridir. Katılımcılara test sonrasında hangi sesleri duyduğu soruldu. Sorulara cevapları içeren performans değerlendirmesi Tablo 3.9’ da sunulmuştur.

Tablo 3.9. İşitsel uyaran tespiti doğruluk oranları

DEHB - İlk Kayıt	DEHB - Tedavi Sonrası Kayıt	Sağlıklı Kayıt
63,07%	60,00%	90,24%

Elde edilen sonuçlar değerlendirildiğinde bazı performans parametrelerinin DEHB ve sağlıklı bireyler için ayırt edici olduğu görülmektedir. Toplam hareket sayısından Sağ-1, Sağ-2, Sağ-3 özelliklerinin ve görsel çeldirici durumunda doğruluk oranlarından köpek görselinin hasta ve sağlıklı gruplar için ayırt edici olduğu tablolardan görülmektedir. Görsel uyaran ve işitsel uyaran tespiti parametrelerinin hasta/sağlıklı ayrımı tespitinde yüksek başarı oranına sahip olduğu görülmektedir.

Sınıflandırma analizi Tablo 3.6’ dan Sağ-1, Sağ-2, Sağ-3 parametrelerinin, Tablo 3.7’ den köpek görseli tespiti parametresinin, Tablo 3.8 ve Tablo 3.9 da bulunan parametrelerin kullanılmasıyla (toplam 6 parametre) gerçekleştirilmiştir. Çalışmada DEHB ilk kayıt, DEHB tedavi sonrası kayıt ve sağlıklı olmak üzere 3 grup sınıflandırma işlemi yapılmıştır. Verilerin %70’i eğitim seti geri kalan %30’u ise test seti olarak belirlenmiştir. YSA sonucu elde edilen sınıflandırma başarı oranı Tablo 3.10’ da sunulmuştur.

Tablo 3.10. YSA sonucu sınıflandırma başarı oranları

DEHB - İlk Kayıt	DEHB - Tedavi Sonrası Kayıt	Sağlıklı Kayıt
62,54%	75,78%	81,76%

3.4. EOG Sinyalleriyle Makine Öğrenmesi Kullanarak DEHB Tespiti Uygulaması Bulguları

EOG sinyalleriyle makine öğrenmesi algoritmaları kullanarak DEHB tespit etmek üzere gerçekleştirilen çalışmaya ait bulgular bu başlık altında sunulmuştur. Çalışma kapsamında EOG sinyallerinden elde edilen parametreler, HFD parametresi ve Hjorth parametreleri (aktivite, hareketlilik, karmaşıklık) kullanılarak hasta ve sağlıklı bireylerin sınıflandırma çalışmasında makine öğrenmesi algoritmaları kullanılmıştır [151]. Çalışmada görsel uyaran takip testi sırasında kaydedilen EOG sinyalleri kullanılmıştır. İlgili parametrelerden elde edilen bulgular Tablo 3.11 ve 3.12’ de sunulmuştur. EOG sinyalinden görsel uyaran takip testi ile ilişkili elde edilen parametreler şunlardır:

- Referans uyaran birebir takip sayısı (RUBTS): Sağlıklı ve DEHB olan katılımcıların görsel uyaran takip testinde ekranda görünen uyaranları birebir takip edip etmedikleri, hangi oranda takip ettikleri tespit edilmiştir.
- Renk oyunu tespiti (ROT): Görsel uyaran takip testinde ekranda periyodik olarak hareket eden görselle zemin rengi arasında bir ilişki bulunmaktadır. Tekrarlanan testlerde arka plan rengi, bir sonraki periyotta uyaranın rengi olmaktadır. Bu durumun tespit durumu katılımcılara sorulmuştur.

Tablo 3.11. Yönlere göre referans uyaran birebir takip sayısı ve renk oyunu tespiti ortalama başarı oranları

Parametre	DEHB - İlk Kayıt	DEHB - Tedavi Sonrası Kayıt	Sağlıklı Kayıt
RUBTS	28,07%	29,02%	32,41%
ROT	4,62%	45,00%	39,02%

Tablo 3.12. HFD ve Hjorth parametreleri tüm test bölümleri parametre ortalamaları

	HFD	Aktivite	Hareketlilik	Karmaşıklık
DEHB - İlk Kayıt	1,054	0,087	0,014	0,441
DEHB - Tedavi Sonrası Kayıt	1,051	0,102	0,014	0,414
Sağlıklı Kayıt	1,05	0,134	0,015	0,42

Aşağıda Tablo 3.13’ te ilgili parametreler kullanılarak makine öğrenmesi algoritmaları ile yapılan sınıflandırma çalışmasına ait başarı oranları görülmektedir.

Tablo 3.13. Makine öğrenmesi sınıflandırma başarı oranları

	Makine Öğrenmesi Algoritması	5 Katlı Çapraz Doğrulama	10 Katlı Çapraz Doğrulama	Çapraz Doğrulamasız
DEHB İlk Kayıt / Sağlıklı Kayıt Sınıflandırma Başarı Oranları	DT	66,27%	62,50%	89,13%
	SVM	59,02%	56,25%	86,90%
	K-NN	55,07%	50,00%	73,97%
	Makine Öğrenmesi Algoritması	5 Katlı Çapraz Doğrulama	10 Katlı Çapraz Doğrulama	Çapraz Doğrulamasız
DEHB İlk Kayıt / DEHB - Tedavi Sonrası Kayıt / Sağlıklı Kayıt Sınıflandırma Başarı Oranları	DT	43,77%	58,37%	80,47%
	SVM	43,22%	58,33%	80,07%
	K-NN	35,30%	30,55%	66,13%

3.5. EEG Sinyallerinin Derin Öğrenme Algoritmalarında Kullanılmasıyla DEHB Tespiti Uygulaması Bulguları

Hibrit ayrıştırma (RLMD ve VMD) ve derin öğrenme teknikleri kullanılarak EEG sinyallerinden DEHB tespiti yapılan bir çalışma gerçekleştirilmiş olup bulguları bu başlık altında sunulmuştur. Çalışmada yöntem bölümünde sunulan ayrıştırma teknikleri olan RLMD ve VMD ile birlikte tasarladığımız derin öğrenme algoritması kullanılmıştır

[183]. Çalışmada 19 kanal EEG sinyali kullanılmış olup aşağıda Tablo 3.14' te 19 kanal EEG sinyalinin derin öğrenme algoritmasına uygulanması sonucu elde edilen DEHB/Sağlıklı sınıflandırmasına ait bulgular sunulmuştur. Burada yapılan uygulamada EEG sinyallerine ön işleme yapılmış olup akabinde doğrudan her bir kanal derin öğrenme algoritmasına giriş olarak uygulanmıştır. Burada EEG kanallarının DEHB tespitinde en iyi performansı gösteren kanalı tespit edilmiştir. Bu tespit üzerine en başarılı kanal üzerinde RLMD ve VMD uygulanarak sınıflandırma başarısının yükseltilmesine yönelik çalışma yapılmıştır.

Tablo 3.14. 19 Kanal EEG sinyaliyle elde edilen başarı oranları

Kanallar	Başarı Oranı (%)	Hassaslık	Özgüllük	Standart Sapma (%)
Fp1	65,82	65%	65%	8,07
Fz	64,16	78%	64%	11,98
F3	60,82	62%	63%	6,76
F8	60,00	67%	58%	3,33
Pz	59,16	79%	58%	3,11
C3	58,34	79%	57%	7,47
Fp2	57,50	59%	56%	6,68
P8	56,66	56%	60%	7,71
O1	54,98	58%	63%	16,33
F4	53,32	59%	54%	8,89
P4	53,32	53%	59%	10,32
Cz	53,32	-	61%	4,86
F7	50,02	52%	44%	6,96
P7	49,98	70%	48%	7,90
C4	49,16	39%	51%	3,14
T7	48,34	56%	41%	17,59
T8	47,50	57%	48%	8,58
P3	45,84	60%	-	14,20
O2	40,82	41%	-	4,86

EEG' nin tüm kanallarının aynı anda kullanılmasıyla elde edilen başarı oranları ve çeşitli beyin bölgelerinden (frontal, parietal, central, occipital, temporal) alınan sinyallerin kullanılması ile elde edilen başarı oranları ise Tablo 3.15' te sunulmuştur.

Tablo 3.15. Tüm kanallar ve beyin bölgelerinden elde edilen başarı oranları

Kanallar	Başarı Oranı (%)	Hassaslık	Özgüllük	Standart Sapma (%)
19 Kanal (tüm kanallar)	95,24	97%	94%	1,78
Frontal (Fp1, Fp2, F3, F4, F7, F8, Fz)	94,76	96%	94%	2,81
Parietal (P3, P4, P7, P8, Pz)	93,00	96%	90%	2,96
Central (C3, C4, Cz)	88,88	92%	86%	3,72
Occipital(O1, O2)	69,18	74%	77%	11,22
Temporal (T7, T8)	68,74	75%	70%	9,60

Tek bir kanal kullanılarak yüksek başarı elde edilmesi amaçlanan çalışmada Tablo 3.14’ te en yüksek başarının elde edildiği Fp1 kanalı üzerine yoğunlaşmıştır. Bu kapsamda ilgili kanal üzerinde RLMD ve VMD uygulamaları gerçekleştirilmiştir. Elde edilen bulgular Tablo 3.16’ da sunulmuştur.

Tablo 3.16. Fp1 Kanalına RLMD ve VMD uygulaması sonucu başarı oranları

Sıra No	Kanal Adı ve Uygulama	Başarı Oranı (%)	Hassaslık	Özgüllük	Standart Sapma (%)
1	Fp1+RLmd+Vmd	87,38	95%	83%	1,99
2	Fp1+RLmd	80,00	82%	82%	4,85
3	Fp1→ RLmd	66,94	71%	65%	6,5
4	Fp1+Vmd	77,08	79%	80%	4,21
5	Fp1→ Vmd	63,34	62%	67%	4,3
6	Fp1	65,82	65%	65%	8,07

Kısaca açıklamak gerekirse derin öğrenme algoritmasına giriş yapılırken Tablo 3.16’ da birinci sırada Fp1 kanalıyla birlikte RLMD ve VMD uygulaması yapılarak elde edilen alt bant sinyalleri (iki uygulamadan da üçer alt bant elde edilmiştir) birlikte giriş yapılmıştır. İkinci sırada Fp1 ile birlikte RLMD alt bant sinyalleri giriş olarak uygulanmıştır. Üçüncüde Fp1 dahil edilmemiş olup sadece Fp1 den elde edilen RLMD alt bant sinyalleri kullanılmıştır. Dördüncüde Fp1 ile birlikte VMD alt bant sinyalleri giriş olarak

uygulanmıştır. Beşincide Fp1 dahil edilmemiş olup sadece Fp1 den elde edilen VMD alt bant sinyalleri kullanılmıştır. Altıncıda ise sadece Fp1 ile elde edilen sonuç görülmektedir. Çalışma kapsamında yüksek başarılı sonuçlar elde edilmiş olup sonuçlara ilişkin değerlendirme ve yorumlar Tartışma-Sonuç ve Öneriler bölümünde sunulmuştur.

3.6. Göz Hareketlerine Dayalı EOG Sinyalleri Üzerinde Derin Öğrenme Algoritmaları Kullanılmasıyla DEHB Tespiti Uygulaması Bulguları

Gerçekleştirilen çalışma kapsamında 53 DEHB ve 36 sağlıklı çocuktan elde edilen EOG sinyalleri üzerinde çalışılmıştır. Sinyaller görsel uyaran takip testi eşliğinde kaydedilmiştir. Sinyaller Şekil 2.14’ te sunulan tarafımızca geliştirilmiş EOGtNetV1 ağ yapısıyla eğitilmiş ve test edilmiştir. Ayrıca EOG sinyalleri literatürde yaygın olarak kullanılan ağ yapıları kullanılarak da öğrenme ve test süreçlerine tabi tutulmuştur. Tablo 3.17’ de görsel uyaran takip testinin birinci bölümü olan Test-1 uygulama sürecinde elde edilen EOG sinyalleri kullanıldığında ortaya çıkan derin öğrenme algoritmalarına ait başarı oranları görülmektedir.

Tablo 3.17. EOG sinyali (Test-1) derin öğrenme algoritmaları – test başarı oranları

Fonksiyon Adı	EOGtNetV1	DenseNet	MobileNet	ResNet50	Squeeze Net	AlexNet
Başarı Oranı	88,89%	77,78%	77,78%	66,67%	77,78%	72,22%
Özgüllük	100,00%	85,71%	100,00%	50,00%	100,00 %	100,00 %
Hassaslık	83,33%	72,72%	42,85%	80,00%	0,00%	0,00%
Standart Sapma	8%	12%	9%	11%	0%	0%

Aşağıda Tablo 3.18’ de ise görsel uyaran takip testinin ikinci bölümü olan Test-2 uygulaması sürecinde elde edilen EOG sinyallerinin derin öğrenme algoritmalarına giriş olarak uygulanması sonucu elde edilen başarı oranları görülmektedir.

Tablo 3.18. EOG sinyali (Test-2) derin öğrenme algoritmaları – test başarı oranları

Fonksiyon Adı	EOGtNetV1	DenseNet	MobileNet	ResNet50	Squeeze Net	AlexNet
Başarı Oranı	72,22%	77,78%	77,78%	72,22%	72,22%	61,11%
Özgüllük	71,42%	83,33%	75,00%	71,42%	100,00 %	100,00 %
Hassaslık	72,72%	66,67%	83,33%	75,00%	0,00%	0,00%
Standart Sapma	11%	11%	12%	12%	0%	0%

Aşağıda Tablo 3.19’ da ise görsel uyaran takip testinin üçüncü bölümü olan Test-3 uygulaması sürecinde elde edilen EOG sinyallerinin derin öğrenme algoritmalarına giriş olarak uygulanması sonucu elde edilen başarı oranları görülmektedir.

Tablo 3.19. EOG sinyali (Test-3) derin öğrenme algoritmaları – test başarı oranları

Fonksiyon Adı	EOGtNetV1	DenseNet	MobileNet	ResNet50	Squeeze Net	AlexNet
Başarı Oranı	72,22%	72,22%	66,67%	66,67%	66,67%	66,67%
Özgüllük	62,50%	66,67%	100,00%	71,42%	100,00 %	100,00 %
Hassaslık	80,00%	83,33%	33,33%	50,00%	0,00%	0,00%
Standart Sapma	11%	12%	9%	11%	0%	0%

Bulguların değerlendirmesi Tartışma-Sonuç ve Öneriler bölümünde sunulmuştur.

3.7. Tez Çalışması Verileriyle Yapılan İşlemlerden Elde Edilen Bulgular

Tez çalışması sürecinde mevcut tez yöntemine altyapı oluşturulması, bulguların ortaya konulması ve desteklenmesi amacıyla doğrudan ve dolaylı olarak tez konusu ile ilgili birçok çalışma gerçekleştirilmiş olup bulguları sunulmuştur.

Aşağıda DEHB tanısı olan bireylerde HB tespiti için non-invazif hareket analizi çalışması kapsamında elde edilen DEHB ve HB tanılı katılımcılara ve sağlıklı katılımcılara ait veriler kullanılarak gerçekleştirilen çalışmaya ait bulgular görülmektedir. Bu bulgulara ait yöntemler, yapılan işlemler ve tasarlanan ağ yapısı ile ilgili hususlar 2.3.5 başlığı altında sunulmuştur.


Çalışma üç aşamada gerçekleştirilmiştir. Görsel uyaran takip testi uygulaması yapılmadan önce hareket verileri, GDC ve nabız verileri beş dakika süre ile kaydedilmiştir. Bu veriler katılımcıların serbest hareketlilikleri sürecinde kaydedilmiştir. K-Katlı çapraz doğrulama işlemi gerçekleştirilmiş olup her bir katta elde edilen başarı oranları, ortalama başarı oranları ve standart sapmaları içeren bulgular Tablo 3.20’ de sunulmuştur.

Tablo 3.20 de ilk satırda görülen bulgular sekiz kanal veri ile elde edilen çalışmanın bulgularıdır. 3 kanal ivmeölçer, 3 kanal jiroskop, 1 kanal nabız ve 1 kanal GDC verisiyle elde edilen bulgular tablonun birinci satırındadır. Tablo ortalama başarı oranlarına göre büyükten küçüğe doğru sıralanarak oluşturulmuştur. Diğer satırlar da ise her bir parametreye ait veriler kullanılarak elde edilen sonuçlar görülmektedir. Yani ikinci satır jiroskopun üç kanalı, üçüncü satır GDC’ nin tek kanalı, dördüncü satır nabızın tek kanalı ve beşinci satır jiroskopun üç kanalından elde edilen bulgulardır.

Tablo 3.20. Birinci durum, değerlendirme bulguları

Kullanılan Veriler	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
İvmeölçer, Jiroskop, Nabız, GDC	100,00%	75,00%	85,71%	85,71%	100,00%	89,29%	9,58%
Jiroskop	85,71%	75,00%	85,71%	85,71%	100,00%	86,43%	7,95%
GDC	85,71%	75,00%	85,71%	71,43%	85,71%	80,71%	6,23%
Nabız	85,71%	75,00%	85,71%	71,43%	85,71%	80,71%	6,23%
İvmeölçer	85,71%	62,50%	85,71%	85,71%	71,43%	78,21%	9,61%

Birinci durumdan elde edilen başarı oranlarını özet olarak gösteren grafik ise Şekil 3.1' de sunulmuştur.



Şekil 3.1. Birinci durum, ortalama başarı yüzdeleri

İkinci durumda birinci durumdaki kaydedilen verilerle eş zamanlı olarak görsel uyaran takip testi uygulaması gerçekleştirilmiştir. Görsel uyaran takip testi sırasında birinci durumdaki veriler de kaydedilmiştir. Ayrıca bir kanal yatay EOG ve dört kanal EEG (T3-T4, F7-F8, F3-F4, C3-C4,) sinyali kaydedilmiştir. Yani toplamda sekiz kanal ilk durumda kaydedilen veriye ek olarak toplam beş kanal da EOG ve EEG' ye ait sinyaller kaydedilmiştir. Toplam 13 kanal sinyal görsel uyaran takip testi sürecinde ekran başında kaydedilmiştir. Kayıt süresi toplam 2 dakika 55 saniyedir. Yani toplam 175 saniyedir. Aşağıdaki tablolarda tüm test bölümlerinin aynı anda derin öğrenme algoritmasına uygulanması sonucu elde edilen bulgularla Test-1, Test-2, Test-3 bölümlerinin ayrı ayrı uygulanması sonucu elde edilen bulgular tablolarda sunulmuştur.

İkinci durumda 13 kanal veriyle elde edilen başarı oranları aşağıdaki Tablo 3.21' de sunulmuştur.

Tablo 3.21. İkinci durum, 13 kanal tüm veriler değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	83,33%	57,14%	85,71%	83,33%	100,00%	81,90%	13,85%
Test-1	100,00%	71,43%	71,43%	83,33%	83,33%	81,90%	10,50%
Test-2	66,67%	71,43%	71,43%	100,00%	83,33%	78,57%	12,05%
Test-3	83,33%	71,43%	71,43%	83,33%	66,67%	75,24%	6,83%

İkinci durumda 8 kanal (jiroskop, ivmeölçer, nabız, GDC) veri ile elde edilen başarı oranları Tablo 3.22’ de sunulmuştur.

Tablo 3.22. İkinci durum, 8 kanal sinyal değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	85,71%	85,71%	85,71%	85,71%	71,43%	82,86%	5,71%
Test-1	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%
Test-2	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%
Test-3	71,43%	83,33%	85,71%	85,71%	71,43%	79,52%	6,67%

İkinci durumda ivmeölçer verileri kullanılarak elde edilen başarı oranları Tablo 3.23’ te sunulmuştur.

Tablo 3.23. İkinci durum ivmeölçer verileri değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	57,14%	85,71%	85,71%	85,71%	71,43%	77,14%	11,43%
Test-1	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%
Test-2	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%
Test-3	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%

İkinci durumda jiroskop verileri kullanılarak elde edilen başarı oranları Tablo 3.24’ te sunulmuştur.

Tablo 3.24. İkinci durum, jiroskop verileri değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%
Test-1	71,43%	85,71%	71,43%	85,71%	71,43%	77,14%	7,00%
Test-2	85,71%	85,71%	85,71%	85,71%	71,43%	82,86%	5,71%
Test-3	71,43%	85,71%	100,00%	85,71%	85,71%	85,71%	9,04%

İkinci durumda sadece GDC sinyalleri kullanılarak elde edilen başarı oranları Tablo 3.25’te sunulmuştur.

Tablo 3.25. İkinci durum, GDC sinyalleri değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	71,43%	85,71%	85,71%	71,43%	71,43%	77,14%	7,00%
Test-1	71,43%	85,71%	71,43%	85,71%	71,43%	77,14%	7,00%
Test-2	85,71%	85,71%	85,71%	71,43%	71,43%	80,00%	7,00%
Test-3	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%

İkinci durumda sadece nabız sinyalleri kullanılarak elde edilen başarı oranları Tablo 3.26’te sunulmuştur.

Tablo 3.26. İkinci durum, nabız sinyalleri değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%
Test-1	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%
Test-2	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%
Test-3	71,43%	85,71%	85,71%	85,71%	71,43%	80,00%	7,00%

İkinci durumda EOG ve EEG sinyalleri kullanılarak toplam 5 kanal veri ile elde edilen başarı oranları Tablo 3.27’te sunulmuştur.

Tablo 3.27. İkinci durum, 5 kanal EOG ve EEG sinyalleri değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	77,78%	80,00%	77,78%	66,67%	66,67%	73,78%	5,86%
Test-1	66,67%	80,00%	77,78%	77,78%	77,78%	76,00%	4,75%
Test-2	77,78%	80,00%	77,78%	77,78%	66,67%	76,00%	4,75%
Test-3	55,56%	90,00%	77,78%	66,67%	77,78%	73,56%	11,64%

İkinci durumda yatay EOG sinyalleri kullanılarak elde edilen başarı oranları Tablo 3.28’ de sunulmuştur.

Tablo 3.28. İkinci durum, yatay EOG sinyalleri değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-1	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-2	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-3	55,56%	80,00%	77,78%	77,78%	77,78%	73,78%	9,15%

İkinci durumda EEG (T3-T4) kanalı sinyalleri kullanılarak elde edilen başarı oranları Tablo 3.29’ da sunulmuştur.

Tablo 3.29. İkinci durum, EEG (T3-T4) sinyali değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	77,78%	80,00%	77,78%	66,67%	77,78%	76,00%	4,75%
Test-1	66,67%	80,00%	77,78%	77,78%	77,78%	76,00%	4,75%
Test-2	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-3	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%

İkinci durumda EEG (F7-F8) kanalı sinyalleri kullanılarak elde edilen başarı oranları Tablo 3.30’ da sunulmuştur.

Tablo 3.30. İkinci durum, EEG (F7-F8) sinyali değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	77,78%	70,00%	66,67%	77,78%	77,78%	74,00%	4,75%
Test-1	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-2	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-3	77,78%	70,00%	77,78%	77,78%	88,89%	78,44%	6,03%

İkinci durumda EEG (F3-F4) kanalı sinyalleri kullanılarak elde edilen başarı oranları Tablo 3.31’ de sunulmuştur.

Tablo 3.31. İkinci durum, EEG (F3-F4) sinyali değerlendirme bulguları


Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-1	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-2	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-3	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%

İkinci durumda EEG (C3-C4) kanalı sinyalleri kullanılarak elde edilen başarı oranları Tablo 3.32’ de sunulmuştur.

Tablo 3.32. İkinci durum, GDC verileri değerlendirme bulguları

Test Bölümü	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
Tüm Testler	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-1	77,78%	70,00%	77,78%	77,78%	77,78%	76,22%	3,11%
Test-2	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%
Test-3	77,78%	80,00%	77,78%	77,78%	77,78%	78,22%	0,89%

İkinci durumdan elde edilen ortalama en yüksek başarılı sonuçların özet olarak grafik gösterimi Şekil 3.2’ de sunulmuştur.




Şekil 3.2. İkinci durum, ortalama en yüksek başarı yüzdeleri

Üçüncü durumda görsel uyarın takip testi uygulaması tamamlandıktan sonra katılımcılar birinci durumdakine benzer şekilde serbest olarak 5 dakika hareket etmişlerdir. Bu sırada birinci durumdaki gibi 8 kanal (ivmeölçer, jiroskop, nabız, GDC) veri kaydı gerçekleştirilmiştir. Elde edilen veriler derin öğrenme algoritmasında eğitilmiş ve test edilmiştir. Elde edilen bulgular aşağıda Tablo 3.33’ te sunulmuştur.

Tablo 3.33. Üçüncü durum, değerlendirme bulguları

Kullanılan Veriler	Kat-1	Kat-2	Kat-3	Kat-4	Kat-5	Ortalama	Standart Sapma
İvmeölçer, Jiroskop, Nabız, GDC	85,71%	85,71%	85,71%	85,71%	71,43%	82,86%	5,71%
Jiroskop	71,43%	85,71%	85,71%	85,71%	85,71%	82,86%	5,71%
Nabız	71,43%	71,43%	85,71%	85,71%	85,71%	80,00%	7,00%
İvmeölçer	57,14%	85,71%	71,43%	100,00%	71,43%	77,14%	14,57%
GDC	71,43%	71,43%	71,43%	85,71%	71,43%	74,29%	5,71%

Üçüncü durumdan elde edilen başarı oranlarını özet olarak gösteren grafik ise Şekil 3.3’te sunulmuştur.



Şekil 3.3. Üçüncü durum, ortalama başarı yüzdeleri

Çalışma kapsamında elde edilen tüm bulgulara bu bölüm içeriğinde yer verilmiştir. Elde edilen bulgular hakkında tartışma ve öneriler, dördüncü bölüm olan Tartışma-Sonuç ve Öneriler başlığı altında sunulmuştur.

4. BÖLÜM

TARTIŞMA-SONUÇ VE ÖNERİLER

Bu bölümde tez çalışması kapsamında gerçekleştirilen çalışmalar ve elde edilen bulgular üzerinde tartışma yapılmış olup bulgular değerlendirilmiştir. Daha sonra bulgulara dayalı olarak sonuç ve öneriler sunulmuştur.

4.1.Tartışma

Bulgular bölümünde 3.1 başlığı altında ivmeölçer verilerine LMD uygulaması sonucunda elde edilen çalışmanın sonuçları ortaya konulmuştur. Burada Tablo 3.1, 3.2, 3.3, 3.4 detaylı olarak değerlendirildiğinde;

- Merdiven inme ve çıkma aktivitelerinin ivmeölçer sensörünün z eksenine ait ortogonallik değerinin işlevsel olarak hareketi tanımlayabildiği tespit edilmiştir.
- Merdiven çıkma aktivitesinin merdiven inme aktivitesine göre z ekseninde genel anlamda daha yüksek ortalama ortogonallik değeri verdiği tespit edilmiştir.
- Koşma aktivitesinin ivmeölçer sensörünün y eksenine ait ortogonallik değerinin belirgin olduğu değerlendirilmiştir.
- Yürüme aktivitesinde ivmeölçer sensörünün hareketin eksenlerinde ortogonallik değerine ait anlamlı bir bulgu vermediği değerlendirilmiştir.

LMD' den elde edilen ortogonallik değerine göre merdiven inme, merdiven çıkma, koşma ve yürüme aktivitelerinde genel olarak ortogonallik değerinin işlevsel olabileceği ancak doğrudan hareketi tanımlama ve sınıflandırmada sadece bu değer ile uygulama yapılmasının yetersiz olduğu değerlendirilmiştir.

Bu kapsamda ivmeölçer ve jiroskop sensörleri kullanılarak daha detaylı parametrelerin tespit edilebilmesi, tek bir parametreye bağlı kalınmaması amacıyla bulguları 3.2 başlığı altında Tablo 3.5’ te sunulan derin sinir ağı kullanılarak aktivite tanımlama çalışması gerçekleştirilmiştir.

Tablo 3.5’ te sunulan bulgular değerlendirildiğinde altı farklı hareket tipinin ikili gruplar halinde derin sinir ağıyla sınıflandırılması sonucunda yüksek doğruluk oranlarına ulaşılabildiği gösterilmiştir. Özetle;

- İvmeölçer ve jiroskop sensörlerinden elde edilen verilere dayanarak hareket tanımlamanın yüksek doğrulukla yapılabileceği gösterilmiştir.
- Jiroskobun hareket tanımlamada ivmeölçere göre daha etikili olduğu, jiroskop verilerinden hareket tanımlamanın başarı oranının daha yüksek olduğu ortaya konulmuştur.
- Veri uzunluğundan ziyade katılımcı sayısının artmasının sınıflandırma başarısını olumlu yönde etkilediği görülmüştür.
- Kullanılan verilerin kontrollü kaydedilmiş verilerden oluşması sebebiyle günlük yaşam aktivitesi sırasında aynı doğruluk oranlarının sağlanamayacağı ancak bu sonuçların yakınsanabileceği değerlendirilmektedir.

Bulgular bölümünde 3.3 başlığı altında EOG sinyalleriyle YSA kullanılarak DEHB tespiti uygulamasının sonuçları değerlendirilmiştir.

Hastalar ve sağlıklı kişiler için; yönlere göre toplam hareket sayısı, görsel çeldirici durumunda doğruluk oranları, görsel uyaran tespiti ve işitsel uyaran tespiti parametreleri değerlendirilmiştir. Sağlıklı katılımcıların DEHB'li katılımcılara göre daha yüksek başarı oranına sahip olduğu genel olarak görülmektedir. Ayrıca ilaç tedavisi gören DEHB’ li katılımcıların test performanslarında genel olarak olumlu yönde değişim olduğu gözlenmiş olup bu durumun ilaç tedavisinin test performansını iyileştirdiği yönünde değerlendirilmiştir. YSA sonucu elde edilen bulgular EOG’ nin DEHB konusunda kullanılabileceği doğrultusunda anlamlı bulgular vermektedir. Ancak elde edilen bu sonuçların hastalık tespiti için yeterli olmadığı değerlendirilmektedir.

EOG sinyalleriyle makine öğrenmesi algoritmaları kullanılarak DEHB tespiti yapılmak üzere gerçekleştirilen 3.4 başlığı altında sunulan çalışmanın bulguları değerlendirilmiştir. EOG sinyallerinden HFD parametresi, Hjorth parametreleri, RUBTS ve ROT parametreleri ile elde edilen bulgulara göre DT algoritmasıyla yüksek doğrulukta sınıflandırma işleminin yapılabileceği ortaya konulmuştur. Konu hakkında literatürde yapılan çalışmalar incelendiğinde görsel uyaran takip testi benzeri bir uygulamayla DEHB tespitine yönelik bir çalışma ile karşılaşılmamıştır. Literatürdeki bazı çalışmalarda göz hareketlerinin tespitine odaklanılmış ve göz izleme prensibine dayanan görüntü işleme yöntemleri kullanılmıştır [140-143]. Çalışmalar ayrıca göz izleme ilkesine dayalı olarak hasta/sağlıklı ayırımına da odaklanmıştır. Bu çalışmalarda bireylerin farklı durumlardaki göz hareketleri analiz edilmiştir [144-147]. Literatürdeki çalışmalar incelendiğinde elde edilen bulguları destekleyici nitelikte göz hareketlerine dayalı olarak DEHB tespiti yapılabileceği değerlendirilmiştir.

EEG sinyallerinin derin öğrenme algoritmalarında kullanılmasıyla DEHB tespiti gerçekleştirilmesi üzerine yapılan çalışma kapsamında Tablo 3.14, 3.15 ve 3.16 incelenmiştir.

Tablo 3.14 incelendiğinde tek kanal çalışmada en yüksek başarının Fp1 kanalında elde edildiği görülmektedir. Literatürde yapılan çalışmalar incelendiğinde DEHB tespitinde Fp1 ve Fp7 kanalının yüksek başarılı sınıflandırma performansı gösterdiği görülmektedir [135]. Bu kapsamda çalışma literatürle uyumludur.

Tablo 3.15 incelendiğinde tüm kanallar aynı anda kullanıldığında en yüksek başarının tespit edildiği görülmektedir. Devamında başarı sıralaması frontal, parietal, central, occipital ve temporal bölümlerden alınan EEG sinyal kanalları olarak tespit edilmiştir.

Tablo 3.16' da sunulan bulgular değerlendirildiğinde;

- RLMD' nin sınıflandırma başarısı üzerindeki etkisinin VMD' ye göre daha yüksek olduğu tespit edilmiştir.
- RLMD ve VMD uygulamalarında sadece alt bant sinyalleri kullanıldığında elde edilen başarı, alt bant sinyallerinin sinyalde birlikte kullanılması durumunda elde edilen başarıdan daha düşüktür.

- RLMD ve VMD tek bir EEG kanalına (Fp1) uygulandığında %87'nin üzerinde sınıflandırma başarı oranı elde edilmiştir. Bu literatürde tek kanalla elde edilen en yüksek sınıflandırma başarısıdır. Ayrıca literatürde DEHB'nin tek kanalla tespitine yönelik bir sınıflandırma çalışmasına rastlanmamıştır. Bu bağlamda çalışma literatüre katkı sağlamaktadır.
- Bulgulara göre DEHB' in EEG sinyallerini etkilediği açıkça görülmektedir. EEG sinyali bir görüntü matrisi olarak değerlendirildiğinde matris üzerinde DEHB ile ilişkilendirilen örüntünün CNN ile yüksek başarıyla tanımlanabileceği ortaya konulmuştur.

Göz hareketlerine dayalı EOG sinyalleri ile derin öğrenme algoritmalarıyla DEHB tespiti çalışmasının bulguları Tablo 3.17, 3.18 ve 3.19' da sunulmuştur. Sunulan bulgular değerlendirildiğinde tarafımızca tasarlanan EOGtNetV1 ağ yapısıyla 88,89% oranında hasta/sağlıklı sınıflandırması gerçekleştirilmiştir. Bu sonuç EOG ile DEHB tanısında literatürde özgün bir sonuç olarak değerlendirilebilir. Literatürde çok az sayıda çalışma bulunmakta olup ilgili çalışmalarda çok daha düşük sınıflandırma başarıları elde edilmiştir [148,149]. Algoritmanın performansı görsel uyaran takip testinin üç bölümü içinde literatürde yaygın olarak kullanılan ağ yapıları ile karşılaştırılmıştır. Görsel uyaran takip testinin birinci bölümünde en yüksek başarı oranı elde edilmiştir. Burada tablolardan görüleceği üzere EOGtNetV1 diğer ağ yapılarına göre üstün performansı ile dikkat çekmektedir. Bu sonuç EOG sinyallerine özgü tasarlanan yapının genel ağ yapılarına kıyasla etkisini ortaya koymaktadır.

Tez sürecinde gerçekleştirilen yukarıda tartışılarak ifade edilen çalışmaların devamında tez çalışması kapsamında bulguları 3.7 başlığı altında sunulan sonuçlar değerlendirilmiştir.

Yapılan değerlendirmede birinci durumda yani ilk olarak HB ve sağlıklı bireylerden alınan jiroskop, ivmeölçer, nabız ve GDC verileri ile (toplam 8 kanal veri) gerçekleştirilen derin öğrenme çalışmasında 89,29% oranında test başarısı elde edilmiştir. İkinci durumda 13 kanal veriyle çalışma gerçekleştirilmiş olup her bir kanaldan elde edilen başarı oranları ayrı ayrı değerlendirilmiştir. Gerçekleştirilen çalışmada en yüksek başarı göz önüne alındığında Test-3' te jiroskop verileri ile gerçekleştirilen derin öğrenme çalışmasında 85,71% oranında test başarısı elde edilmiştir. Üçüncü durumda yani son olarak görsel

uyaran takip testi uygulaması gerçekleştirildikten sonra HB ve sağlıklı bireylerden alınan jiroskop, ivmeölçer, nabız ve GDC verileri ile gerçekleştirilen derin öğrenme çalışmasında ise 82,86% oranında test başarısı elde edilmiştir.

Elde edilen başarı oranları değerlendirildiğinde birinci durumda elde edilen sonuçların hasta / sağlıklı ayırımında en etkili sonucu verdiği görülmüştür. Benzer şekilde EOGtNetV1 ile gerçekleştirilen çalışmada da en yüksek başarı Test-1 de elde edilmiştir. Elde edilen bulgular literatürde olmayan özgün sonuçları ortaya koymaktadır.

4.2.Sonuç ve Öneriler

Tez sürecinde gerçekleştirilen çalışmaları kısaca özetlemek gerekirse öncelikle 10 katılımcıya ait ivmeölçer verileri kullanılarak hareket tanımlaması çalışması gerçekleştirilmiştir. Çalışmada LMD fonksiyonu ve ortogonallik parametresi kullanılmıştır. Hareket tanımlama için anlamlı bulgular elde edilmiş olup harekete dair daha fazla veri (örneğin jiroskop) ile daha başarılı sonuçlar elde edilebileceği değerlendirilmiştir.

Bu doğrultuda 24 katılımcıya ait jiroskop ve ivmeölçer verileri derin sinir ağı yapısıyla değerlendirildiğinde kontrollü olarak kaydedilmiş hareket verilerinden aktivitelerin 100%' e varan doğruluk oranları ile tespit edilebileceği ortaya konulmuştur. Jiroskopun hareket tanımlamada ivmeölçere göre çok daha etkili olduğu tespit edilmiştir. Aktivite tanımlama çalışması kapsamında daha uzun süreli veriler içeren daha az katılımcıyla yapılan çalışmanın ortalama başarı oranları ile daha kısa süreli veriler içeren daha fazla katılımcıyla yapılan çalışmanın ortalama başarı oranları karşılaştırılmıştır. Katılımcı sayısı arttığında veri uzunlukları daha kısa olsa da hareket tanımlama başarı oranının genel olarak yükseldiği tespit edilmiştir.

EOG sinyalleriyle YSA kullanılarak DEHB tespiti çalışması gerçekleştirilmiş olup bu kapsamda sinyale ve sinyalin kayıt protokolüne uygun parametreler elde edilmiştir. Bu kapsamda 53 DEHB' li, 36 sağlıklı, 39 kişi ise DEHB tanısı olup 6 ay tedavi gördükten sonra çalışmaya dahil edilen katılımcılardan oluşmaktadır. Elde edilen parametreler YSA' da sınıflandırıldığında hasta ve sağlıklı grupların tespit edilebileceği sonucuna ulaşılmıştır. Elde edilen bulgulara göre çok yüksek başarı oranları elde edilememiş ancak belirtilen sınıflandırmanın yapılabilceği ortaya konulmuştur.

Bu kapsamda EOG sinyallerinin makine öğrenmesi algoritmaları ile benzer şekilde sınıflandırılabilmesi amacıyla bir çalışma gerçekleştirilmiştir. Çalışmada aynı veriler (53 DEHB, 36 sağlıklı, 39 tedavi görmüş DEHB) kullanılmıştır. Gerçekleştirilen çalışmada DT algoritması kullanıldığında DEHB / Sağlıklı ayrımının 89,13% başarı oranı ile elde edilebileceği gösterilmiştir.

EEG sinyallerinin derin öğrenme algoritmalarında kullanılmasıyla DEHB tespit edilmesi çalışması gerçekleştirilmiştir. Burada en başarılı test performansının sağlandığı EEG kanalının Fp1 kanalı olduğu tespit edilmiştir. Fp1 kanalına RLMD ve VMD işlemleri gerçekleştirilerek elde edilen veriler derin öğrenme algoritmasına uygulandığında 87,38% oranında bir başarı oranı elde edilmiştir. Bu başarı oranı literatürde tek bir kanaldan DEHB tespiti üzerine elde edilen en yüksek başarı oranıdır. Ayrıca aynı çalışmada çoklu EEG kanalları ile 95% üzerinde başarı oranları elde edilmiştir. Gerçekleştirilen yöntemin ve geliştirilen derin öğrenme algoritmasının üstün başarısı ortaya konulmuştur.

Derin öğrenme algoritmalarında elde edilen üstün başarılarından yola çıkarak EOG sinyalleri ile daha önce elde edilen veriler üzerinde bir çalışma gerçekleştirilmiştir. Çalışmada aynı veriler (53 DEHB, 36 sağlıklı) kullanılmıştır. Görsel uyaran takip testinin birinci bölümü olan Test-1 kısmında elde edilen EOG sinyalinin tasarlanan EOGtNetV1 derin öğrenme ağ yapısına uygulanması sonucunda 88,89% başarı oranı elde edilmiştir. Bu sonuç literatürle karşılaştırıldığında EOG ile DEHB tespitinde özgün bir başarı oranıdır.

Tez çalışması kapsamında yapılan çalışmalardan elde edilen bulgular hem hareket verilerinin hem EOG ve EEG sinyallerinin derin öğrenme algoritmaları kullanıldığında hasta / sağlıklı ayrımını yüksek başarılı bir şekilde gerçekleştirebildiğini ortaya koymaktadır.

Bu kapsamda DEHB tanısı olan bireylerde HB tespiti için non-invazif hareket analizi ve fizyolojik sinyallerin kullanılması kapsamında gerçekleştirilen çalışmada 30 HB olan katılımcı ve 10 sağlıklı katılımcıdan ivmeölçer, jiroskop, nabız, GDC, EEG, EOG sinyalleri kaydedilmiştir. Veriler öncelikle 5 dakika boyunca serbest hareket durumunda kaydedilmiştir. Serbest hareket durumunda kaydedilen veriler ivmeölçer, jiroskop, nabız

ve GDC verileridir. Daha sonra görsel uyaran takip testi eşliğinde tüm veriler kaydedilmiştir. Görsel uyaran eşliğinde kaydedilen verilerin süresi 175 saniyedir. Son olarak üçüncü durumda, ilk durumdaki 5 dakikalık kayıt tekrar alınmıştır. Tüm veriler ayrı ayrı ve bir arada analiz edilmiştir. Elde edilen bulgulara göre birinci durumda tüm verilerin derin öğrenme algoritmasına uygulanması sonucunda 89,29% başarı oranı ile HB/sağlıklı sınıflandırması gerçekleştirilmiştir.

Elde ettiğimiz tüm bulgular birlikte değerlendirildiğinde DEHB ve HB veri yapısına uygun derin öğrenme algoritmaları ile yüksek doğrulukta tanımlanabilmektedir. DEHB ve HB tespiti üzerine yaptığımız çalışmalara göre sağlıklı / hasta ayırımında genel olarak uygulanan testlerin ilk bölümleri yüksek ayırt edicilikte olmaktadır. HB tespiti için gerçekleştirilen çalışmada birinci durum kayıtları ile 89,29% başarı oranı elde edilmiş ve EOGtNetV1 ile gerçekleştirilen çalışmada Test-1 de 88,89% en yüksek başarı oranı elde edilmiştir.

Klinikte HB tespiti için fizyolojik sinyallerin ve hareket verilerinin efektif bir şekilde kullanılabileceği değerlendirilmektedir. Bunun için klinisyenlerle birlikte tanıyı destekleyecek test protokollerinin geliştirilmesi ve çalışmalar için katılımcı sayılarının artırılması gerekmektedir. Yüksek başarılı sonuçların standart hale getirilmesi için çalışma kapsamında bu hususlar önerilmektedir.

Tez çalışması kapsamında elde edilen bulgular DEHB ve HB' nin objektif değerlendirme araçları ile yüksek başarılı bir şekilde tespit edilebileceğini ortaya koymaktadır. Çalışma kapsamında katılımcı sayılarının artırılması ile başarı oranlarının daha fazla yükseltilebileceği değerlendirilmektedir. Tez çalışmasından elde edilen bulgular literatüre katkı sağlayacak özgün sonuçlar içermektedir. DEHB ve HB hastalığının tanı sürecine katkı sağlayacak önemli bilimsel bulgular ortaya konulmuştur.

KAYNAKÇA

1. Barkley, R.A., 2006. Attention-Deficit Hyperactivity Disorder: A handbook for Diagnosis and Treatment. Guilford Press (3. Basım), New York.
2. Spencer, T.J., Biederman, J., Mick, E., 2007. Attention deficit/ hyperactivity disorder: Diagnosis, lifespan, comorbidities, and neurobiology, **Ambulatory Pediatrics**, **7**:73-81.
3. Sonuga-Barke, E. J., Halperin, J. M., 2010. Developmental phenotypes and causal pathways in attention deficit/hyperactivity disorder: potential targets for early intervention?. **Journal of Child Psychology and Psychiatry**, **51**(4), 368-389.
4. American Psychiatric Association, D., & American Psychiatric Association. 2013. Diagnostic and Statistical Manual of Mental Disorders: DSM-5 (Vol. 5, No. 5). American Psychiatric Association, Washington, DC.
5. Willcutt, E.G., 2012. The prevalence of DSM-IV attention deficit/hyperactivity disorder: a meta analytic review. **Neurotherapeutics**, **9**: 490-499.
6. Polanczyk, G.V., Willcutt, E.G., Salum, G.A., Kieling, C., Rohde, L.A., 2014. ADHD prevalence estimates across three decades: an updated systematic review and meta-regression analysis. **International Journal of Epidemiology**, **43**: 434-442.
7. Fayyad, J, Sampson, N.A., Hwang, I., Adamowski, T., Aguilar, S., et al, 2017. The descriptive epidemiology of DSM-IV Adult ADHD in the World Health Organization World Mental Health Surveys. **ADHD Attention Deficit and Hyperactivity Disorders**, **9**: 47-65.
8. Kieling, R., Rohde, L. A., 2012. ADHD in children and adults: diagnosis and prognosis. **Behavioral neuroscience of attention deficit hyperactivity disorder and its treatment**, **9**:1-16.
9. Nigg, J.T., 2000. On inhibition/disinhibition in developmental psychopathology:

Views from cognitive and personality psychology and a working inhibition taxonomy, **Psychological Bulletin**, **126**,220–246.

10. Faraone, S. V., Larsson, H., 2019. Genetics of attention deficit hyperactivity disorder. **Molecular Psychiatry**, **24**(4), 562-575.
11. Sayal, K., Prasad, V., Daley, D., Ford, T., Coghill, D., 2018. ADHD in children and young people: prevalence, care pathways, and service provision. **The Lancet Psychiatry**, **5**(2), 175-186.
12. Conners, C.K., Sitarenios, G., Parker, J.D.A., Epstein, J.N., 1998. The Revised Conners Parent Rating Scale (CPRS-R): Factor structure, reliability, and criterion validity. **Journal of Abnormal Child Psychology**, **26**(4): 257-268.
13. Conners, C.K., Sitarenios, G., Parker, J.D.A., Epstein, J.N., 1998. Revision and restandardization of the Conners Teacher Rating Scale (CTRS-R): Factor structure, reliability, and criterion validity. **Journal of Abnormal Child Psychology**, **26**(4): 279-291.
14. Guy, W., 1976. Clinical Global Impressions: In ECDEU Assessment Manual for Psychopharmacology, Revised DHEWPub. (ADM). Rockville, MD: National Institute for Mental Health, pp. 218-222.
15. Kedem, B., 1986. **Spectral analysis and discrimination by zerocrossings. Proceedings of the IEEE**, **74**(11): 1477-1493.
16. Pliszka, S., 2007. AACAP Work Group on Quality Issues. Practice parameter for the assessment and treatment of children and adolescents with attention-deficit/hyperactivity disorder. **Journal of the American Academy of Child and Adolescent Psychiatry**, **46**: 894-921.
17. Faraone, S. V., Asherson, P., Banaschewski, T., Biederman, J., Buitelaar, J. K., Ramos-Quiroga, J. A., Rohde, L. A., Sonuga-Barke, E. J. S., Tannock, R., Franke, B., 2015. Attention-deficit/hyperactivity disorder. **Nature Reviews Disease Primers**, **1**, 15020.
18. Rucklidge, J.J., 2010. Gender differences in attention-deficit/hyperactivity

disorder. **Psychiatric Clinics**, **33**(2), 357-373.

19. Demontis, D., Walters, R. K., Martin, J., Mattheisen, M., Als, T. D., Agerbo, E., Belliveau, R., Bybjerg-Grauholm, J., et al, 2019. Discovery of the first genome-wide significant risk loci for attention deficit/hyperactivity disorder. **Nature Genetics**, **51**(1), 63-75.
20. Catalá-López, F., Hutton, B., Núñez-Beltrán, A., Page, M. J., Ridao, M., Macías Saint-Gerons, D., Catalá, M. A., Tabarés-Seisdedos, R., & Moher, D., 2017. The pharmacological and non-pharmacological treatment of attention deficit hyperactivity disorder in children and adolescents: A systematic review with network meta-analyses of randomised trials. **PLoS ONE**, **12**(7), e0180355.
21. Banaschewski, T., Coghill, D., Santosh, P. et al., 2006. Long-acting medications for the hyperkinetic disorders. **European Child and Adolescent Psychiatry**, **15**, 476–495.
22. Daley, D., Van Der Oord, S., Ferrin, M., Danckaerts, M., Doepfner, M., Cortese, S., & Sonuga-Barke, E. J., 2014. Behavioral interventions in attention-deficit/hyperactivity disorder: a meta-analysis of randomized controlled trials across multiple outcome domains. **Journal of the American Academy of Child & Adolescent Psychiatry**, **53**(8), 835-847.
23. Cortese, S., Adamo, N., Del Giovane, C., Mohr-Jensen, C., Hayes, A. J., Carucci, S., Atkinson, L. Z., Tessari, L., et al, 2018. Comparative efficacy and tolerability of medications for attention-deficit hyperactivity disorder in children, adolescents, and adults: a systematic review and network meta-analysis. **The Lancet Psychiatry**, **5**(9), 727-738.
24. Sciberras, E., Mulraney, M., Silva, D., Coghill, D., 2017. Prenatal Risk Factors and the Etiology of ADHD—Review of Existing Evidence. **Current Psychiatry Reports**, **19**(1), 1.
25. Polanczyk, G. V., Salum, G. A., Sugaya, L. S., Caye, A., Rohde, L. A., 2015. Annual Research Review: A meta-analysis of the worldwide prevalence of mental disorders in children and adolescents. **Journal of Child Psychology and**

Psychiatry, **56**(3), 345-365.

26. Thomas, R., Sanders, S., Doust, J., Beller, E., Glasziou, P., 2015. Prevalence of Attention-Deficit/Hyperactivity Disorder: A Systematic Review and Meta-analysis. **Pediatrics**, **135**(4).
27. Patel, S., Park, H., Bonato, P., Chan, L., Rodgers, M., 2012. A review of wearable sensors and systems with application in rehabilitation. **Journal of neuroengineering and rehabilitation**, **9**(1), 21.
28. Bouten, C. V., Koekkoek, K. T., Verduin, M., Kodde, R., Janssen, J. D., 1997. A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity. **IEEE Transactions on Biomedical Engineering**, **44**(3), 136-147.
29. Aminian, K., Najafi, B., 2004. Capturing human motion using body-fixed sensors: outdoor measurement and clinical applications. **Computer Animation and Virtual Worlds**, **15**(2), 79-94.
30. Najafi, B., Aminian, K., Paraschiv-Ionescu, A., Loew, F., Bula, C. J., Robert, P., 2003. Ambulatory system for human motion analysis using a kinematic sensor: monitoring of daily physical activity in the elderly. **IEEE Transactions on Biomedical Engineering**, **50**(6), 711-723.
31. Lord, S. R., Menz, H. B., Tiedemann, A., 2003. A physiological profile approach to falls risk assessment and prevention. **Physical therapy**, **83**(3), 237-252.
32. Bamberg, S. J. M., Benbasat, A. Y., Scarborough, D. M., Krebs, D. E., Paradiso, J. A., 2008. Gait analysis using a shoe-integrated wireless sensor system. **IEEE Transactions on Information Technology in Biomedicine**, **12**(4), 413-423.
33. Lees, A., 2002. Technique analysis in sports: a critical review. **Journal of sports sciences**, **20**(10), 813-828.
34. Kavanagh, J. J., Menz, H. B., 2008. Accelerometry: a technique for quantifying movement patterns during walking. **Gait & posture**, **28**(1), 1-15.

35. Del Rosario, M.B., Redmond, S.J., Lovell, N.H., 2015. Tracking the evolution of smartphone sensing for monitoring human movement. **Sensors**, **15**(8), 18901-18933.
36. Seshadri, D.R., Li, R.T., Voos, J.E. et al., 2019. Wearable sensors for monitoring the physiological and biochemical profile of the athlete. **Npj Digital Medicine**, **2**, 72.
37. El-Sheimy, N., Hou, H., Niu, X., 2008. Analysis and modeling of inertial sensors using allan variance. **IEEE Transactions on Instrumentation and Measurement**, **57**(1), 140–149.
38. Jekeli, C., 2001. Inertial Navigation Systems with Geodetic Applications. De Gruyter, Berlin, Boston.
39. Madou, M. J., 2011. Manufacturing techniques for microfabrication and nanotechnology. CRC press.
40. Zhao, S., Liu, Q., Liu, Y., Ma, H., He, Z., 2022. Navigation-grade resonant fiber-optic gyroscope using ultra-simple white-light multibeam interferometry. **Photonics Research**, **10**(2), 542-549.
41. Woodman, O. J., 2007. An introduction to inertial navigation (No. UCAM-CL-TR-696). University of Cambridge, Computer Laboratory.
42. Xie, H., Fedder, G.K., 2003. Fabrication, characterization, and analysis of a DRIE CMOS-MEMS gyroscope. **IEEE Sensors Journal**, **3**(5), 622-631.
43. Zhai, Y., Li, D., Wu, C., Wu, H., 2021. Urban park facility use and intensity of seniors' physical activity—An examination combining accelerometer and GPS tracking. **Landscape and Urban Planning**, **205**, 103950.
44. Varanis, M., Silva, A., Mereles, A., Pederiva, R., 2018. MEMS accelerometers for mechanical vibrations analysis: A comprehensive review with applications. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, **40**, 1-18.

45. Cascone, V., Boaga, J., Cassiani, G., 2021. Small Local Earthquake Detection Using Low-Cost MEMS Accelerometers: Examples in Northern and Central Italy. **The Seismic Record**, **1**(1), 20-26.
46. Taraldsen, K., Chastin, S. F., Riphagen, I. I., Vereijken, B., Helbostad, J. L., 2012. Physical activity monitoring by use of accelerometer-based body-worn sensors in older adults: a systematic literature review of current knowledge and applications. **Maturitas**, **71**(1), 13-19.
47. Tundo, M.D., Lemaire, E., Baddour, N., 2013. Correcting Smartphone orientation for accelerometer-based analysis. In *2013 IEEE international symposium on medical measurements and applications (memea)*, pp. 58-62.
48. Lang, C.E., Waddell, K.J., Klaesner, J.W., Bland, M.D., 2017. A method for quantifying upper limb performance in daily life using accelerometers. **JoVE (Journal of Visualized Experiments)**, **(122)**, e55673.
49. Caruso, M.J., 2000. Applications of magnetic sensors for low cost compass systems. *IEEE Position location and navigation symposium, (Cat. No. 00CH37062)* pp. 177-184.
50. Ripka, P., 2001. Magnetic Sensors and Magnetometers, Artech House. Inc., Northwood, MA.
51. Lenz, J., Edelstein, S., 2006. Magnetic sensors and their applications, in **IEEE Sensors Journal**, vol. 6, no. 3, pp. 631-649,
52. Härmäläinen, M., Hari, R., Ilmoniemi, R.J., Knuutila, J., Lounasmaa, O.V., 1993. Magnetoencephalography theory, instrumentation, and applications to noninvasive studies of the working human brain. **Reviews of modern Physics**, **65**(2), 413.
53. Kim, J., Jun, H., 2008. Vision-based location positioning using augmented reality for indoor navigation. **IEEE Transactions on Consumer Electronics**, **54**(3), 954-962.
54. Webster, J.G. (Ed.), 2009. Medical Instrumentation: Application and Design.

John Wiley & Sons.

55. Semmlow, J., 2017. *Circuits, Signals, and Systems for Bioengineers: a MatLab-Based Introduction*. Academic Press.
56. Sörnmo, L., & Laguna, P., 2005. *Bioelectrical Signal Processing in Cardiac and Neurological Applications (Vol. 8)*. Academic Press.
57. Kligfield, P., Gettes, L. S., Bailey, J.J., Childers, R., Deal, B.J., Hancock, E. W., et al, 2007. Recommendations for the standardization and interpretation of the electrocardiogram: part I: the electrocardiogram and its technology: a scientific statement from the American Heart Association Electrocardiography and Arrhythmias Committee, Council on Clinical Cardiology; the American College of Cardiology Foundation; and the Heart Rhythm Society endorsed by the International Society for Computerized Electrocardiology. **Circulation**, **115**(10), 1306-1324.
58. Lyon, A., Mincholé, A., Martínez, J. P., Laguna, P., Rodriguez, B., 2018. Computational techniques for ECG analysis and interpretation in light of their contribution to medical advances. **Journal of The Royal Society Interface**, **15**(138), 20170821.
59. Hampton, J., Hampton, J., 2019. *The ECG Made Easy e-book*. Elsevier Health Sciences.
60. Surawicz, B., Knilans, T., 2008. *Chou's Electrocardiography in Clinical Practice: Adult and Pediatric*. Elsevier Health Sciences.
61. Epstein, A.E., DiMarco, J.P., Ellenbogen, K.A., Estes III, N.M., Freedman, R.A., Gettes, L.S., et al, 2013. 2012 ACCF/AHA/HRS focused update incorporated into the ACCF/AHA/HRS 2008 guidelines for device-based therapy of cardiac rhythm abnormalities: a report of the American College of Cardiology Foundation/American Heart Association Task Force on Practice Guidelines and the Heart Rhythm Society. **Circulation**, **127**(3), e283-e352.
62. Goff, Jr, D.C., Lloyd-Jones, D.M., Bennett, G., Coady, S., D'agostino, R.B.,

- Gibbons, R., et al, 2014. 2013 ACC/AHA guideline on the assessment of cardiovascular risk: a report of the American College of Cardiology/American Heart Association Task Force on Practice Guidelines. **Circulation**, **129**(25_suppl_2), pp 49-73.
63. O'gara, P. T., Kushner, F. G., Ascheim, D. D., Casey, D. E., Chung, M. K., De Lemos, J. A., et al, 2013. 2013 ACCF/AHA guideline for the management of ST-elevation myocardial infarction: a report of the American College of Cardiology Foundation/American Heart Association Task Force on Practice Guidelines. **Journal of the American college of cardiology**, **61**(4), e78-e140.
64. Ali, N.S., Alyasseri, Z.A.A., Abdulmohson, A., 2018. Real-time heart pulse monitoring technique using wireless sensor network and mobile application. **International Journal of Electrical and Computer Engineering**, **8**(6), 5118.
65. Mratbaevna, W.N., Farrux, S., 2022. The structure of the heart and its physiology in regular athletes. **Eurasian Scientific Herald**, **8**, 102-105.
66. Goldberger, A.L., Goldberger, Z.D., Shvilkin, A., 2017. Clinical electrocardiography: a simplified approach e-book. Elsevier Health Sciences.
67. Moody, G.B., Mark, R.G., Zoccola, A., Mantero, S., 1985. Derivation of respiratory signals from multi-lead ECGs. **Computers in cardiology**, **12**(1985), 113-116.
68. Janse, M.J., 2004. Electrophysiological changes in heart failure and their relationship to arrhythmogenesis. **Cardiovascular research**, **61**(2), 208-217.
69. O'Rourke, M.F., Yaginuma, T., 1984. Wave reflections and the arterial pulse. **Archives of internal medicine**, **144**(2), 366-371.
70. Goldberger, Z., Lampert, R., 2006. **Implantable cardioverter-defibrillators: expanding indications and technologies**. **Jama**, **295**(7), 809-818.
71. Shi, Y., Ruiz, N., Taib, R., Choi, E., Chen, F., 2007. *Galvanic skin response (GSR) as an index of cognitive load. In CHI'07 extended abstracts on Human factors in computing systems*, pp. 2651-2656.

72. Boucsein, W., 2012. Electrodermal activity. Springer Science & Business Media.
73. Montagna, W., 2012. The structure and function of skin. Elsevier.
74. Dawson, M.E., Schell, A.M., Filion, D. L., 2007. The electrodermal system. Handbook of psychophysiology, 2, 200-223.
75. Lykken, D.T., 1998. A tremor in the blood: Uses and abuses of the lie detector. Plenum Press.
76. Critchley, H.D., 2002. Electrodermal responses: what happens in the brain. **The Neuroscientist**, **8**(2), 132-142.
77. Duchowski, A.T., 2003. Eye Tracking Methodology: Theory and Practice.
78. Banerjee, A., Datta, S., Pal, M., Konar, A., Tibarewala, D. N., Janarthanan, R., 2013. Classifying electrooculogram to detect directional eye movements. **Procedia Technology**, **10**, 67-75.
79. Barea, R., Boquete, L., Mazo, M., López, E., 2002. System for assisted mobility using eye movements based on electrooculography. **IEEE transactions on neural systems and rehabilitation engineering**, **10**(4), 209-218.
80. Webster, J. G., 1998. The measurement, instrumentation and sensors handbook (Vol. 14). CRC press.
81. Sahayadhas, A., Sundaraj, K., Murugappan, M., 2012. Detecting driver drowsiness based on sensors: a review. **Sensors**, **12**(12), 16937-16953.
82. Barea, R., Boquete, L., Mazo, M., López, E., 2002. Wheelchair guidance strategies using EOG. **Journal of intelligent and robotic systems**, **34**, 279-299.
83. Tzimourta, K.D., Tsilimbaris, A., Tzioukalia, K., Tzallas, A.T., Tsipouras, M.G., Astrakas, L.G., Giannakeas, N., 2018. EEG-based automatic sleep stage classification. **Biomedical Journal**, **1**(6).
84. Craik, A., He, Y., Contreras-Vidal, J. L., 2019. Deep learning for electroencephalogram (EEG) classification tasks: a review. **Journal of neural**

engineering, **16**(3), 031001.

85. Nuwer, M., 1997. Assessment of digital EEG, quantitative EEG, and EEG brain mapping: Report of the American Academy of Neurology and the American Clinical Neurophysiology Society, **Neurology**, **49**(1), 277-292.
86. Abo-Zahhad, M., Ahmed, S.M., Abbas, S.N., 2015. A new EEG acquisition protocol for biometric identification using eye blinking signals. **International Journal of Intelligent Systems and Applications**, **7**(6), 48.
87. Başar, E., 2012. Brain function and oscillations: volume ii: integrative brain function. Neurophysiology and cognitive processes. Springer Science & Business Media.
88. Adeli, H., Zhou, Z., Dadmehr, N., 2003. Analysis of EEG records in an epileptic patient using wavelet transform. **Journal of neuroscience methods**, **123**(1), 69-87.
89. Klem, G.H., Lüders, H.O., Jasper, H.H., Elger, C., 1999. The ten-twenty electrode system of the International Federation. The International Federation of Clinical Neurophysiology. **Electroencephalography and Clinical Neurophysiology**. **52**:3-6. PMID: 10590970.
90. Oostenveld, R., Praamstra, P., 2001. The five percent electrode system for high-resolution EEG and ERP measurements. **Clinical neurophysiology**, **112**(4), 713-719.
91. Kwak, Y.H., Kim, W., Park, K.B., Kim, K., Seo, S., 2017 Flexible heartbeat sensor for wearable device, **Biosensors and Bioelectronics**, **94**:250–255.
92. Yin, Y., Cui, Y., Xing, Y., Li, M., 2018. Thermal management of flexible wearable electronic devices integrated with human skin considering clothing effect, **Applied Thermal Engineering**, **144**: 504–511.
93. Huang, S., Li, J., Zhang, P., Zhang, W., 2018. Detection of mental fatigue state with wearable ECG devices, **International Journal of Medical Informatics**, **119**:39–46.

94. Szttyler, T., Stuckenschmidt, H., Petrich, W., 2017. Position-aware activity recognition with wearable devices, **Pervasive and Mobile Computing**, **38**:281–295.
95. Akagi, T., Dohta, S., Matsushita, H., Yoneda, M., 2012. Development of low-cost intelligent wearable motion sensing device using embedded controller, **Procedia Engineering**, **41**:143 – 149.
96. Mencarini, E., Leonardi, C., Cappelletti, A., Giovanelli, D., Angeli, A. D., Zancanaro, M., 2019. Co-designing wearable devices for sports: The case study of sport climbing, **International Journal of Human-Computer Studies**, **124**:26–43.
97. Zhang, J., Cao, Y., Qiao, M., Ai, L., Sun, K., Mi, Q., Zang, S., Zuo, Y., Yuan, X., Wang, Q., 2018. Human motion monitoring in sports using wearable graphene-coated fiber sensors, **Sensors and Actuators, A** **274**:132–140.
98. Benson, L.C., Clermont, C.A., Bošnjak, E., Ferber, R., 2018. The use of wearable devices for walking and running gait analysis outside of the lab: A systematic review, **Gait & Posture**, **63**:124–138.
99. Sano, A., Picard, R.W., Stickgold, R., 2014. Quantitative analysis of wrist electrodermal activity during sleep, **International Journal of Psychophysiology**, **94**,382–389.
100. Liu, Y., Du, S., 2018. Psychological stress level detection based on electrodermal activity, **Behavioural Brain Research**, **341**,50–53.
101. Satterfield, J.H., Dawson, M.E., 1971. Electrodermal correlates of hyperactivity in children. **Psychophysiology**, **8**(2), 191-197.
102. Dupuy, F.E., Clarke, A.R., Barry, R.J., Selikowitz, M., Mc Carthy, R., 2014. EEG and electrodermal activity in girls with Attention-Deficit/Hyperactivity Disorder, **Clinical Neurophysiology**, **125**,491–499.
103. Guo, Q., Liu, B., Chen, C.W., 2016. A two-layer and multi-strategy framework for human activity recognition using smartphone. *In 2016 IEEE International*

Conference on Communications, (Icc) pp. 1-6.

104. Shoaib, M., Scholten, H., Havinga, P.J., 2013. Towards physical activity recognition using smartphone sensors. *In 2013 IEEE 10th international conference on ubiquitous intelligence and computing and 2013 IEEE 10th international conference on autonomic and trusted computing*, pp. 80-87.
105. Pires, I.M., Garcia, N.M., Pombo, N., Flórez-Revuelta, F., Spinsante, S., Teixeira, M.C., 2018. Identification of activities of daily living through data fusion on motion and magnetic sensors embedded on mobile devices. **Pervasive and Mobile Computing**, **47**, 78-93.
106. Ronao, C.A., Cho, S.B., 2014. Human activity recognition using smartphone sensors with two-stage continuous hidden Markov models. *In 2014 10th IEEE international conference on natural computation (ICNC)* pp. 681-686.
107. Hung, W.C., Shen, F., Wu, Y.L., Hor, M.K., Tang, C.Y., 2014. Activity recognition with sensors on mobile devices. *In 2014 IEEE International Conference on Machine Learning and Cybernetics, Vol. 2*, pp. 449-454.
108. Baerg, S., Cairney, J., Hay, J., Rempel, L., Mahlberg, N., Faught, B.E., 2011. Evaluating physical activity using accelerometry in children at risk of developmental coordination disorder in the presence of attention deficit hyperactivity disorder, **Research in Developmental Disabilities**, **32**, 1343–1350.
109. Malekzadeh, M., Clegg, R.G., Cavallaro, A., Haddadi, H., 2019. Mobile sensor data anonymization. *In Proceedings of the International Conference on Internet of Things Design and Implementation (IoTDI '19)*. Association for Computing Machinery, New York, NY, USA, 49–58.
110. Ngoh, K.J., Gouwanda, D., Gopalai, A.A., Chong, Y.Z., 2018. Estimation of vertical ground reaction force during running using neural network model and uniaxial accelerometer. **Journal of Biomechanics. Volume 76**, 269-273.
111. Ignatov, A., 2018. Real-time human activity recognition from accelerometer data using Convolutional Neural Networks. **Applied Soft Computing. Volume:**

62, 915-922.

112. Jeantet, L., Vigon, V., Geiger, S., Chevallier, D., 2021. Fully Convolutional Neural Network: A solution to infer animal behaviours from multi-sensor data. **Ecological Modelling. Volume 450**.
113. Cescon, M., Choudhary, D., Pinsker, J.E., Dadlani, V., Church, M.M., Kudva, Y.C., Doyle, F.J., Dassau, E., 2021. Activity Detection and Classification from Wristband Accelerometer Data Collected on People with Type 1 Diabetes in Free-Living Conditions. **Computers in Biology and Medicine, 104633**.
114. Boukhechba, M., Cai, L., Wu, C., Barnes, L.E., 2019. ActiPPG: Using deep neural networks for activity recognition from wrist-worn photoplethysmography (PPG) sensors, **Smart Health, Volume 14**.
115. Kropotov, J.D., Pronina, M.V., Ponomarev, V.A., Poliakov, Y.I., Plotnikova, I.V., Mueller, A., 2019. Latent ERP components of cognitive dysfunctions in ADHD and schizophrenia. **Clinical Neurophysiology, 130**(4), 445-453.
116. Yu, C.L., Chueh, T.Y., Hsieh, S.S., Tsai, Y.J., Hung, C.L., Huang, C.J., et al, 2019. Motor competence moderates relationship between moderate to vigorous physical activity and resting EEG in children with ADHD. **Mental Health and Physical Activity, 17**, 100302.
117. Marcano, J.L., Bell, M.A., Beex, A.L., 2018. Classification of ADHD and non-ADHD subjects using a universal background model. **Biomedical signal processing and control, 39**, 204-212.
118. Öztoprak, H., Toyçan, M., Alp, Y.K., Arıkan, O., Doğutepe, E., Karakaş, S., 2017. Machine-based classification of ADHD and nonADHD participants using time/frequency features of event-related neuroelectric activity. **Clinical Neurophysiology, 128**(12), 2400-2410.
119. González, J.J., Méndez, L.D., Mañas, S., Duque, M.R., Pereda, E., De Vera, L., 2013. Performance analysis of univariate and multivariate EEG measurements in the diagnosis of ADHD. **Clinical Neurophysiology, 124**(6), 1139-1150.

120. Hermens, D.F., Kohn, M.R., Clarke, S.D., Gordon, E., Williams, L.M., 2005. Sex differences in adolescent ADHD: findings from concurrent EEG and EDA. **Clinical neurophysiology**, **116**(6), 1455-1463.
121. Kollins, S.H., DeLoss, D.J., Cañadas, E., Lutz, J., Findling, R.L., Keefe, R. S., et al, 2020. A novel digital intervention for actively reducing severity of paediatric ADHD (STARS-ADHD): a randomised controlled trial. **The Lancet Digital Health**, **2**(4), e168-e178.
122. Adamou, M., Fullen, T., Jones, S.L., 2020. EEG for diagnosis of adult ADHD: a systematic review with narrative analysis. **Frontiers in Psychiatry**, **11**, 871.
123. Moghaddari, M., Lighvan, M.Z., Danishvar, S., 2020. Diagnose ADHD disorder in children using convolutional neural network based on continuous mental task EEG. **Computer Methods and Programs in Biomedicine**, **197**, 105738.
124. Gloss, D., Varma, J.K., Pringsheim, T., Nuwer, M.R., 2016. Practice advisory: The utility of EEG theta/beta power ratio in ADHD diagnosis: Report of the Guideline Development, Dissemination, and Implementation Subcommittee of the American Academy of Neurology. **Neurology**, **87**(22), 2375-2379.
125. Tanko, D., Barua, P.D., Dogan, S., Tuncer, T., Palmer, E., Ciaccio, E.J., Acharya, U.R., 2022. EPSPatNet86: eight-pointed star pattern learning network for detection ADHD disorder using EEG signals. **Physiological Measurement**, **43**(3), 035002.
126. Vahid, A., Bluschke, A., Roessner, V., Stober, S., Beste, C., 2019. Deep learning based on event-related EEG differentiates children with ADHD from healthy controls. **Journal of clinical medicine**, **8**(7), 1055.
127. Slater, J., Joobar, R., Koborsy, B.L., Mitchell, S., Sahlas, E., Palmer, C., 2022. Can electroencephalography (EEG) identify ADHD subtypes? A systematic review. **medRxiv**.
128. Quintana, H., Snyder, S.M., Purnell, W., Aponte, C., Sita, J., 2007. Comparison of a standard psychiatric evaluation to rating scales and EEG in the differential

- diagnosis of attention-deficit/hyperactivity disorder. **Psychiatry research**, **152**(2-3), 211-222.
129. Clarke, A.R., Barry, R.J., Johnstone, S.J., McCarthy, R., Selikowitz, M., 2019. EEG development in attention deficit hyperactivity disorder: from child to adult. **Clinical Neurophysiology**, **130**(8), 1256-1262.
 130. Chen, H., Song, Y., Li, X., 2019. A deep learning framework for identifying children with ADHD using an EEG-based brain network. **Neurocomputing**, **356**, 83-96.
 131. Dubreuil-Vall, L., Ruffini, G., Camprodon, J.A., 2020. Deep learning convolutional neural networks discriminate adult ADHD from healthy individuals on the basis of event-related spectral EEG. **Frontiers in neuroscience**, **14**, 251.
 132. Chen, H., Song, Y., Li, X., 2019. Use of deep learning to detect personalized spatial-frequency abnormalities in EEGs of children with ADHD. **Journal of neural engineering**, **16**(6), 066046.
 133. Moghaddari, M., Lighvan, M.Z., Danishvar, S., 2020. Diagnose ADHD disorder in children using convolutional neural network based on continuous mental task EEG. **Computer Methods and Programs in Biomedicine**, **197**, 105738.
 134. Lenartowicz, A., Loo, S. K., 2014. Use of EEG to diagnose ADHD. **Current psychiatry reports**, **16**(11), 1-11.
 135. Tosun, M., 2021. Effects of spectral features of EEG signals recorded with different channels and recording statuses on ADHD classification with deep learning. **Physical and Engineering Sciences in Medicine**, **44**(3), 693-702.
 136. Ekhlas, A., Nasrabadi, A. M., Mohammadi, M. R., 2021. Direction of information flow between brain regions in ADHD and healthy children based on EEG by using directed phase transfer entropy. **Cognitive Neurodynamics**, **15**(6), 975-986.
 137. Kanematsu, H., Barry, D.M., Ogawa, N., Nakahira, K.T., Yoshitake, M., Shirai, et al, 2018. Some Psychological Responses Measured by a Commercial

- Electrooculography Sensor and Its Applicability. **Procedia Computer Science**, **126**, 1014-1022.
138. Rahman, M.M., Bhuiyan, M.I.H., Hassan, A.R., 2018. Sleep stage classification using single-channel EOG. **Computers in biology and medicine**, **102**, 211-220.
 139. Erkeymaz, H., Ozer, M., Orak, İ. M., 2015. Detection of directional eye movements based on the electrooculogram signals through an artificial neural network. **Chaos, Solitons & Fractals**, **77**, 225-229.
 140. Al-Rahayfeh, A., Faezipour, M., 2013. Enhanced frame rate for real-time eye tracking using circular hough transform. *In 2013 IEEE Long Island Systems, Applications and Technology Conference (LISAT)* pp. 1-6.
 141. Kashani, M.A.A., Arani, M.M., Fini, M.R.R., 2011. Eye detection and tracking in images with using bag of pixels. *In 2011 IEEE 3rd International Conference on Communication Software and Networks* pp. 64-68.
 142. Liang, Z., Tan, F., Chi, Z., 2012. Video-based biometric identification using eye-tracking technique. *In: 2012 IEEE International Conference on Signal Processing, Communication and Computing (ICSPCC 2012)* pp. 728-733.
 143. Hansen, D.W., Hammoud, R. I., 2007. An improved likelihood model for eye tracking. **Computer Vision and Image Understanding**, **106**(2-3), 220-230.
 144. Lee, Y.J., Lee, S., Chang, M., Kwak, H.W., 2015. Saccadic movement deficiencies in adults with ADHD tendencies. **ADHD Attention Deficit Hyperactivity Disorder**, **7**:271-280.
 145. Tsang, V., Chu, P.C.K., 2018. Comparing eye-tracking data of children with high-functioning ASD, comorbid ADHD, and of a control watching social videos. **JoVE (Journal of Visualized Experiments)**, **(142)**, e58694.
 146. Marotta, A., Pasini, A., Menotti, E., Pasquini, A., Pitzianti, M.B., et al, 2017. Controlling attention to gaze and arrows in attention deficit hyperactivity disorder. **Psychiatry Research**, **251**: 148-154.

147. Rojas-Libano, D., Wainstein, G., Carrasco, X., Aboitiz, F., Crossley, N., Ossandón, T., 2019. A pupil size, eye-tracking and neuropsychological dataset from ADHD children during a cognitive task. **Scientific data**, **6**(1), 25.
148. Shoouri, N., 2022. Detection of ADHD from EOG signals using approximate entropy and petrosain's fractal dimension. **Journal of Medical Signals and Sensors**, **12**(3), 254-262.
149. Shoouri, N., 2022. EOG biofeedback protocol based on selecting distinctive features to treat or reduce ADHD symp-toms. **Biomedical Signal Processing and Control**, **71**, 102748.
150. Latifoğlu, F., Esas, M. Y., Demirci, E., 2020. Diagnosis of attention-deficit hyperactivity disorder using EOG signals: a new approach. **Biomedical Engineering/Biomedizinische Technik**, **65**(2), 149-164.
151. Latifoğlu, F., Esas, M. Y., İleri, R., Özmen, S., Demirci, E., 2022. Using electrooculography with visual stimulus tracking test in diagnosing of ADHD: findings from machine learning algorithms. **Turkish Journal of Medical Sciences**, **52**(5), 1616-1626.
152. InvenSense Inc., 2014. MPU-9255 Product Specification, <https://stanford.edu/class/ee267/misc/MPU-9255-Datasheet.pdf> (Erişim tarihi: Temmuz 2023).
153. Arduino Nano., 2008. <https://www.arduino.cc/en/uploads/Main/ArduinoNanoManual23.pdf> (Erişim tarihi: Temmuz 2023).
154. Arduino, 2021. <https://www.arduino.cc/en/Reference/SDCardNotes> (Erişim tarihi: Temmuz 2023).
155. Farnell, 2023. <http://www.farnell.com/datasheets/1842389.pdf> (Erişim tarihi: Temmuz 2023).
156. Grove, 2015. https://www.mouser.com/catalog/specsheets/Seed_101020052.pdf (Erişim

tarihi: Ağustos 2023).

157. Analog Devices, 2011. <https://eu.mouser.com/datasheet/2/609/AD620-877253.pdf> (Erişim tarihi: Ağustos 2023).
158. Texas Instruments, 2022. <https://www.ti.com/lit/ds/symlink/lm158-n.pdf> (Erişim tarihi: Ağustos 2023).
159. Malekzadeh, M., Clegg, R.G., Cavallaro, A., Haddadi, H., 2019. Mobile sensor data anonymization. *In Proceedings of the international conference on internet of things design and implementation*, pp. 49-58.
160. Esas, M.Y., Latifoğlu, F., 2019. Motion Type Verification Studies Using Accelerometer Sensor Data With Local Mean Decomposition. **Academic Perspective Procedia**, **2**(3), 1051-1057.
161. Smith, J.S., 2005. The local mean decomposition and its application to EEG perception data. **Journal of the Royal Society Interface**, **2**(5), 443-454.
162. Cheng, Y., Wang, Z., Chen, B., Zhang, W., Huang, G., 2019. An improved complementary ensemble empirical mode decomposition with adaptive noise and its application to rolling element bearing fault diagnosis. **ISA transactions**, **91**, 218-234.
163. Darong, H., Lanyan, K., Bo, M., Ling, Z., Guoxi, S., 2018. A new incipient fault diagnosis method combining improved RLS and LMD algorithm for rolling bearings with strong background noise. **IEEE Access**, **6**, 26001-26010.
164. Zhang, L., Wang, Z., Quan, L., 2018. Research on weak fault extraction method for alleviating the mode mixing of LMD. **Entropy**, **20**(5), 387.
165. Xiao, Y., Dong, Y.H., 2016. Local mean decomposition algorithm improved by de-correlation. In 2016 9th IEEE International Congress on Image and Signal Processing, *BioMedical Engineering and Informatics (CISP-BMEI)* pp. 1206-1210.
166. Esas, M.Y., Latifoğlu, F., 2021. Controlled Human Activity Recognition Using

Deep Neural Networks. *VII. INSAC International Congress on Natural and Engineering Sciences*, 109-117.

167. Momeny, M., Latif, A.M., Sarram, M.A., Sheikhpour, R., Zhang, Y.D., 2021. A noise robust convolutional neural network for image classification. **Results in Engineering**, **10**, 100225.
168. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahrudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., Chen, T., 2018. Recent advances in convolutional neural networks, **Pattern Recognition**, **Volume 77**, Pages 354-377.
169. Demirci, E., Esas, M.Y., Altıntop, Ç., Taştepe, N., Latifoğlu, F., 2023. Diagnostic support system for the detection of attention deficit hyperactivity disorder using eeg signals. **Journal of Psychiatry and Psychiatric Disorders**. **7** (2023): 118-127.
170. Hassani, H., 2007. Singular spectrum analysis: methodology and comparison, **Journal of Data Science**, **5**, 239-257.
171. Mert, C., Milnikov, A., 2011. Singular Spectrum Analysis Method as a universal filter. *In 2011 5th IEEE International Conference on Application of Information and Communication Technologies (AICT)* pp. 1-5.
172. Hagan M.T., Demuth H.B., Beale M.H., 1996. *Neural Network Design*. Boston. MA: PWS Publishing.
173. Haykin, S., 1998. *Neural networks: a comprehensive foundation*. Prentice Hall PTR.
174. Marquardt, D.W., 1963. An algorithm for least-squares estimation of nonlinear parameters, **Journal of the society for Industrial and Applied Mathematics**. **11**: 431-441.
175. Kesic, S., Spasic, S.Z., 2016. Application of Higuchi's fractal dimension from basic to clinical neurophysiology: A review. **Computer Methods and Programs in Biomedicine**, **133**: 55-70.

176. Gomez, C., Mediavilla, A., Hornero, R., Abasolo, D., Fernandez, A., 2009. Use of the Higuchi's fractal dimension for the analysis of MEG recordings from Alzheimer's disease patients. **Medical Engineering and Physics**, **31**(3): 306-313.
177. Mouzé-Amady, M., Horwat, F., 1996. Evaluation of Hjorth parameters in forearm surface EMG analysis during an occupational repetitive task. **Electroencephalography and Clinical Neurophysiology/Electromyography and Motor Control**, **101**(2), 181-183.
178. Mohammed, M., Khan, M.B., Bashier, E.B.M., 2016. Machine learning: algorithms and applications. Crc Press.
179. Quinlan, J.R., 1986. Induction of decision trees. **Machine learning**, **1**, 81-106.
180. Cover, T., Hart, P., 1967. Nearest neighbor pattern classification. **IEEE transactions on information theory**, **13**(1), 21-27.
181. Cortes, C., Vapnik, V., 1995. Support-vector networks. **Machine learning**, **20**, 273-297.
182. Vapnik, V., 1999. The nature of statistical learning theory. Springer science & business media.
183. Esas, M. Y., Latifoğlu, F., 2023. Detection of ADHD from EEG signals using new hybrid decomposition and deep learning techniques. **Journal of Neural Engineering**, **20**, 036028.
184. Wang, R., Li, C., Fu, W., Tang, G., 2019. Deep learning method based on gated recurrent unit and variational mode decomposition for short-term wind power interval prediction. **IEEE transactions on neural networks and learning systems**, **31**(10), 3814-3827.
185. Wang, Y., Markert, R., Xiang, J., Zheng, W., 2015. Research on variational mode decomposition and its application in detecting rub-impact fault of the rotor system. **Mechanical Systems and Signal Processing**, **60**, 243-251.
186. Dragomiretskiy, K., Zosso, D., 2013. Variational mode decomposition. **IEEE**

- transactions on signal processing**, **62**(3), 531-544.
187. Liu, Z., Jin, Y., Zuo, M.J., Feng, Z., 2017. Time-frequency representation based on robust local mean decomposition for multicomponent AM-FM signal analysis. **Mechanical systems and signal processing**, **95**, 468-487.
 188. Zhiliang, L., 2022. Robust local mean decomposition (RLMD). <https://www.mathworks.com/matlabcentral/fileexchange/66935-robust-local-mean-decomposition-rlmd>, (Eriřim tarihi: Ağustos 2022).
 189. Albawi, S., Mohammed, T.A., Al-Zawi, S., 2017. Understanding of a convolutional neural network. In *2017 IEEE international conference on engineering and technology (ICET)* pp. 1-6.
 190. O'Shea, K., Nash, R., 2015. An introduction to convolutional neural networks. **arXiv** preprint arXiv:1511.08458.
 191. LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. **nature**, **521**(7553), 436-444.
 192. Theckedath, D., Sedamkar, R.R., 2020. Detecting affect states using VGG16, ResNet50 and SE-ResNet50 networks. **SN Computer Science**, **1**, 1-7.
 193. Mukti, I.Z., Biswas, D., 2019. Transfer learning based plant diseases detection using ResNet50. In *2019 4th IEEE International conference on electrical information and communication technology (EICT)* pp. 1-6.
 194. Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., et al, 2017. Mobilenets: Efficient convolutional neural networks for mobile vision applications. **arXiv** preprint arXiv:1704.04861.
 195. Iandola, F.N., Han, S., Moskewicz, M.W., Ashraf, K., Dally, W. J., Keutzer, K., 2016. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. **arXiv** preprint arXiv:1602.07360.
 196. Lu, S., Lu, Z., Zhang, Y.D., 2019. Pathological brain detection based on AlexNet and transfer learning. **Journal of computational science**, **30**, 41-47.

197. Krizhevsky, A., Sutskever, I., Hinton, G.E., 2017. Imagenet classification with deep convolutional neural networks. **Communications of the ACM**, **60**(6), 84-90.
198. Huang, G., Liu, Z., VanDerMaaten, L., Weinberger, K.Q., 2017. Densely connected convolutional networks. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4700-4708.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Mustafa Yasin ESAS

Uyruğu: Türkiye (T.C)

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı	2017
Lisans	Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü	2014
Lisans (Çift Anadal)	Erciyes Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü	2014
Lise	Mürşide Ermumcu Anadolu Öğretmen Lisesi, Isparta	2009

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2022-Halen	Türkiye İlaç ve Tıbbi Cihaz Kurumu	Klinik Mühendislik Uzmanı
2018-2022	Hatay İl Sağlık Müdürlüğü	Biyomedikal Yüksek Mühendisi
01.2018-09.2018	Denizli İl Sağlık Müdürlüğü	Çözümleyici Uzman
2015-2018	Denizli Kamu Hastaneleri Birliği Genel Sekreterliği	Klinik Mühendislik Sorumlusu
2014-2015	Denizli Devlet Hastanesi	Biyomedikal Mühendisi

YABANCI DİL

İngilizce

PROJELERDE YAPTIĞI GÖREVLER:

Üniversite Projeleri

1. Araştırmacı, Genel Araştırma Projesi, “Hiperaktivite Bozukluğu Tespiti İçin Non İnvazif Hareket Analizi”, FBA-2022-11213, 2022-Devam Ediyor.

Üniversite Dışı Projeler

1. Proje Yürütücüsü, “Bilgisayar Tabanlı Elektrofizyolojik Çoklu Ölçüm Sistemi”, Bilim, Sanayi ve Teknoloji Bakanlığı, Teknogirişim Sermaye Desteği, Proje No: 0336.TGSD.2014 (12 ay)
2. Bursiyer, “Dikkat Eksikliği Ve Hiperaktivite Bozukluğu Olan Çocuk ve Ergenlerde Tanı ve Tedavi Takibinde Göz İzleme Prensipleri ile EOG Sinyallerinin Kullanımı: Yeni Bir Yaklaşım”, TÜBİTAK 3001 Projesi, Proje No: 116E614, 2017-2019.

YAYINLAR

- 1- Esas, M. Y., & Latifoğlu, F. (2023). Detection of ADHD from EEG signals using new hybrid decomposition and deep learning techniques. Journal of Neural Engineering. DOI: 10.1088/1741-2552/acc902 (SCI)
- 2- Demirci, E., Esas, M.Y., Altıntop, Ç.G., Taştape, N., Latifoğlu, F. (2023). Diagnostic Support System for the Detection of Attention Deficit Hyperactivity Disorder using EOG signals. Journal of Psychiatry and Psychiatric Disorders. 7 (2023): 118-127. (Uluslararası Alan İndeksli Dergi)
- 3- Latifoğlu, F., Esas, M. Y., İleri, R., Özmen, S., & Demirci, E. (2022). Using electrooculography with visual stimulus tracking test in diagnosing of ADHD: findings from machine learning algorithms. Turkish Journal of Medical Sciences, 52(5), 1616-1626. (SCI-Expanded)
- 4- Esas, M.Y., Latifoğlu, F. (2021). Controlled Human Activity Recognition Using Deep Neural Networks. VII. INSAC International Congress on Natural and Engineering Sciences (ICNES-2021), pp:109-117, Konya/Turkey (Bildiri)
- 5- Latifoğlu, F., Esas, M.Y., Demirci, E. (2020). Diagnosis of attention-deficit hyperactivity disorder using EOG signals: a new approach. Biomedical Engineering /

Biomedizinische Technik, 65(2), 149-164. <https://doi.org/10.1515/bmt-2019-0027> (SCI-Expanded)

6-Esas, M.Y. , Latifoğlu, F. (2019). Motion Type Verification Studies Using Accelerometer Sensor Data With Local Mean Decomposition. Academic Perspective Procedia, 2 (3), 1051-1057. doi: 10.33793/acperpro.02.03.117 (Bildiri)

7-Demirci, E., Latifoğlu, F., Esas, M. Y. , İleri, R., Taştepe, N., Özmen, S., Altıntop, Ç. G. (2019). Use of EOG (electrooculogram) signals in children with ADHD: a preliminary study . Child and Adolescent Mental Health and Diseases Congress (pp.175). Istanbul, Turkey (Bildiri)

8-Esas, M. Y. (2017). EOG testi ile dikkat eksikliğinin tanısı (Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü).

9-Esas, M. Y., Latifoğlu, F.,Demirci, E.,Altıntop, Ç.G. "Determination of attention deficit hyperactivity disorder by electrooculogram test," 2017 Medical Technologies National Congress (TIPTEKNO), Trabzon, 2017, pp. 1-4, doi: 10.1109/TIPTEKNO.2017.8238051. (Bildiri)

10-Altıntop,Ç. G.,Latifoğlu, F.,Esas, M.Y. "Analysis of electrooculogram signals from students before and after exam," 2016 Medical Technologies National Congress (TIPTEKNO), Antalya, 2016, pp. 1-4, doi: 10.1109/TIPTEKNO.2016.7863085. (Bildiri)

11-Esas, M.Y., Latifoğlu, F. "Computer-Based design with dual channel device electrooculography and eye movement tracking," 2015 Medical Technologies National Conference (TIPTEKNO), Bodrum, 2015, pp. 1-4, doi: 10.1109/TIPTEKNO.2015.7374593. (Bildiri)