

İZMİR BAKIRÇAY ÜNİVERSİTESİ

MÜHENDİSLİK VE MİMARLIK FAKÜLTESİ

BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS TEZİ

**UYKU APNESİ TEŞHİSİNDE WELCH PEDİOGRAMLARININ
DERİN ÖĞRENME YÖNTEMLERİ İLE ANALİZİ**

Emre TURAN
Prof. Dr. Orhan ER

MAYIS 2025
İZMİR



İZMİR BAKIRÇAY ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ A.B.D.

UYKU APNESİ TEŞHİSİNDE WELCH PEDİOGRAMLARININ DERİN
ÖĞRENME YÖNTEMLERİ İLE ANALİZİ

YÜKSEK LİSANS TEZİ

Emre TURAN

Tez Danışmanı: Prof. Dr. Orhan ER

Mayıs 2025

**UYKU APNESİ TEŞHİSİNDE WELCH PEDİOGRAMLARININ DERİN
ÖĞRENME YÖNTEMLERİ İLE ANALİZİ**

Emre TURAN

YÜKSEK LİSANS TEZİ

**Bilgisayar Mühendisliği
Anabilim Dalı**

Danışman: Prof. Dr. Orhan ER

**İzmir
İzmir Bakırçay Üniversitesi
Lisansüstü Eğitim Enstitüsü
Mayıs 2025**

JÜRİ VE ENSTİTÜ ONAYI

İzmir Bakırçay Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim dalında öğrenim görmekte olan Emre Turan'nın "UYKU APNESİ TEŞHİSİNDE WELCH PEDİOGRAMLARININ DERİN ÖĞRENME YÖNTEMLERİ İLE ANALİZİ" başlıklı tezi 18/06/2025 tarihinde aşağıdaki jüri tarafından değerlendirilerek "İzmir Bakırçay Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Bilgisayar Mühendisliği Anabilim dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Jüri Üyeleri	Unvanı Adı Soyadı	İmza
Üye (Tez Danışmanı)	Prof. Dr. Orhan ER	
Üye	Doç. Dr. Mürsel Ozan İNCETAŞ	
Üye	Dr. Öğr. Üyesi Murat UÇAR	

Prof. Dr. Özge TÜZÜN ÖZMEN
Lisansüstü Eğitim Enstitüsü Müdürü

FINAL APPROVAL FOR THESIS

This thesis titled “ANALYSIS OF WELCH PERIODOGRAMS FOR SLEEP APNEA” has been prepared and submitted by Emre Turan in partial fulfilment of the requirements in “İzmir Bakırçay University Directive on Graduate Education and Examination” for the Degree of Master of Science in Computer Engineering Department has been examined and approved on 18/06/2025

Committee Members	Title, Name and Surname	Signature
Member (Supervisor)	Prof. Dr. Orhan ER	
Member	Assoc. Prof. Mürsel Ozan İNCETAŞ	
Member	Asst. Prof. Murat UÇAR	

Prof. Dr. Özge TÜZÜN ÖZMEN
Director of Graduate Education Institute

ÖZET

UYKU APNESİ TEŞHİSİNDE WELCH PEDİOGRAMLARININ DERİN ÖĞRENME YÖNTEMLERİ İLE ANALİZİ

Emre TURAN

Bilgisayar Mühendisliği Anabilim Dalı

İzmir Bakırçay Üniversitesi, Lisansüstü Eğitim Enstitüsü, Mayıs 2025

Danışman: Prof. Dr. Orhan ER

Elektrokardiyogram (EKG) sinyallerinden elde edilen Welch Periodogramlarının derin öğrenme ile analizine dayanan yeni bir uyku apnesi teşhis yöntemi bu çalışmada sunulmaktadır. Kullanılan tanı ölçütlerine göre yetişkin nüfusun %3 ila %17'sinde görülen uyku apnesi, günümüzde yetersiz teşhis edilmektedir. Bu durum, geleneksel tanı yöntemi olan polisomnografinin yüksek maliyeti, özel donanımlı laboratuvar gereksinimi ve hastanın doğal uyku düzenini etkileme potansiyeli gibi kısıtlamalardan kaynaklanmaktadır. Araştırmamızda geliştirilen otomatik tanı sistemi, Holter monitörlerinden alınan kayıtlardaki RR aralıklarının frekans spektrumundaki değişimleri Welch Periodogramları ile incelemektedir. Bu görsel temsiller, uyku apnesi esnasında kalp hızı değişkenliğinde meydana gelen karakteristik frekans alanı değişimlerini başarıyla yakalamaktadır. Önerilen metodoloji, Evrişimli Sinir Ağları (CNN) kullanarak bu spektral gösterimlerdeki uyku apnesine işaret eden desenleri tespit etmektedir. Sunduğumuz yaklaşımın invazif olmaması, ev ortamında uygulanabilirliği ve hasta konforunu artırması gibi önemli üstünlükleri bulunmaktadır. Çalışmamızın sonuçları, uyku tıbbı alanındaki metodolojik ilerlemelere katkı sağlarken, aynı zamanda uyku apnesi tanısında kolay erişilebilir araçların geliştirilmesine imkan tanımakta, böylece erken teşhis oranlarını ve hasta prognozunu iyileştirme potansiyeli taşımaktadır.

Anahtar Sözcükler: Uyku apnesi; Elektrokardiyogram (EKG); Welch Periodogramı; Kalp hızı değişkenliği; Derin öğrenme; Evrişimli Sinir Ağları; Frekans alanı analizi; Ev tabanlı tanı yöntemleri; İnvazif olmayan izleme; Holter kayıtları; Sinyal işleme; Otomatik tespit; Spektral analiz.

ABSTRACT

ANALYSIS OF WELCH PERIODOGRAMS FOR SLEEP APNEA DIAGNOSIS USING DEEP LEARNING METHODS

Emre TURAN

Computer Engineering

İzmir Bakırçay University, Graduate Education Institute, May 2025

Supervisor: Prof. Dr. Orhan ER

A novel approach for diagnosing sleep apnea based on deep learning analysis of Welch Periodograms derived from electrocardiogram (ECG) signals is presented in this study. Sleep apnea, which affects between 3% and 17% of the adult population depending on diagnostic criteria used, is currently underdiagnosed. This situation stems from limitations of traditional diagnostic methods such as polysomnography, including high cost, requirement for specially equipped laboratories, and potential disruption of the patient's natural sleep patterns. The automated diagnostic system developed in our research examines frequency spectrum variations in RR intervals from Holter monitor recordings using Welch Periodograms. These visual representations successfully capture the characteristic frequency-domain changes in heart rate variability that occur during sleep apnea. The proposed methodology detects patterns indicative of sleep apnea in these spectral representations using Convolutional Neural Networks (CNN). Our approach offers significant advantages including being non-invasive, applicable in home environments, and enhancing patient comfort. The results of our study contribute to methodological advancements in sleep medicine while enabling the development of easily accessible tools for sleep apnea diagnosis, thus carrying potential to improve early detection rates and patient prognosis.

Keywords: Sleep apnea; Electrocardiogram (ECG); Welch Periodogram; Heart rate variability; Deep learning; Convolutional Neural Networks; Frequency-domain analysis; Home-based diagnostics; Non-invasive monitoring; Holter recordings; Signal processing; Automated detection; Spectral analysis.

TEŞEKKÜR

Akademik kariyerimde elde ettiğim tüm başarılarımın mimarı olan, hakkını asla ödeyemeyeceğim sevgili hocam sayın Prof. Dr. Orhan ER'e,

Benim için tüm zorluklara katlanan ve katlanmaya hazır olan, en zorlu anlarımda bile sevgileri ve destekleri sayesinde bana motivasyon kaynağı olan, canım annem ve babam Cavidan TURAN'a ve Murat TURAN'a,

Lisans öğrencisiyken bana hocalık yapıp, şimdi de bana ablalık yapan, sürekli bana doğru yolu gösteren ve bana yardımcı olan sayın hocalarım ve ablalarım Arş. Gör. Cevher SÖYLEMEZ PEKTAŞ'a ve Arş. Gör. Müge OLUÇOĞLU'na,

İş hayatımı ve çalışma ortamımı sanki bir arkadaş ortamı gibi keyifli ve samimi bir hale getiren; dostum, ortağım, yoldaşım Arş. Gör. Ömer Atılım KOCA'ya,

Ve yüksek lisans eğitimim boyunca; bu sürecin eğlenceli olmasını sağlayan, hiç bulamayacağımı düşündüğüm kadar güzel dostluklar kurduğum, her derdimde yanımda olan ve bir ömür boyunca da yanımda olmalarını dilediğim, ancak olamasalar bile hep kalbimde olacak canım arkadaşlarım Beste TOKPINAR'a, Büşra ERDOĞAN'a, Deniz TURAN'a ve Seçkin YILDIZ'a

Ve ayrıca diğer tüm hocalarıma ve sevdiklerime çok teşekkür ederim.

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın İzmir Bakırçay Üniversitesi tarafından kullanılan ithenticate bilimsel intihal tespit programıyla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

.....

(İmza)

Emre TURAN

STATEMENT OF COMPLIANCE WITH ETHICAL PRINCIPLES AND RULES

I hereby truthfully declare that this thesis is an original work prepared by me; that I have behaved in accordance with the scientific ethical principles and rules throughout the stages of preparation, data collection, analysis and presentation of my work; that I have cited the sources of all the data and information that could be obtained within the scope of this study, and included these sources in the references section; and that this study has been scanned for plagiarism with ithenticate scientific plagiarism detection program used by İzmir Bakırçay University, and that “it does not have any plagiarism” whatsoever. I also declare that, if a case contrary to my declaration is detected in my work at any time, I hereby express my consent to all the ethical and legal consequences that are involved.

.....

(Signature)

Emre TURAN

TABLolar/ŞEKİLLER DİZİNİ

	Sayfa
Tablo 6.1 Derin öğrenme modellerinin test veri seti üzerinde performans karşılaştırması.....	57
Şekil 6.1. Model sonuçlarının karşılaştırılması	58
Şekil 6.2. ResNet50 (Karışıklık Matrisi).....	59
Şekil 6.3. MobileNetV2 (Karışıklık Matrisi)	59
Şekil 6.4. DenseNet121 (Karışıklık Matrisi).....	60
Şekil 6.5. EfficientNetV2-S (Karışıklık Matrisi)	60
Şekil 6.6. ResNet18 (Karışıklık Matrisi).....	61
Şekil 6.7. EfficientNet-B0 (Karışıklık Matrisi).....	61
Tablo 6.2. Derin öğrenme modellerinin eğitim ve validasyon metrikleri.....	52

GÖRSELLER DİZİNİ

Sayfa

Görsel 4.1. Uyku apnesine sahip olmayan birinin Welch güç spektral yoğunluk (PSD) diyagramı	40
Görsel 4.2. Uyku apnesine sahip olan birinin Welch güç spektral yoğunluk (PSD) diyagramı	41
Görsel 4.3. ResNet50 Mimarisi	42
Görsel 4.4. MobileNetV1 ve MobileNetV2 Mimarisi	44
Görsel 4.5. DenseNet121 Mimarisi	45
Görsel 4.6. EfficientNetV2 Mimarisi.....	46

SİMGELER VE KISALTMALAR DİZİNİ

PSG	: Polisomnografi
EEG	: Elektrosefalogram
EKG	: Elektrokardiyogram
CNN	: Evrişimli Sinir Ağları
OUA	: Obstrüktif Uyku Apnesi
EOG	: Elektrookülografi
PSD	: Güç Spektral Yoğunluk
UVLF	: Ultra Düşük Frekans
VLF	: Çok Düşük Frekans
LF	: Düşük Frekans
HF	: Yüksek Frekans
HRV	: Heart Rate Variability
AASM	: Amerikan Uyku Tıbbı Akademisi
SSA	: Santral Uyku Apnesi
AHI	: Apne-Hipopne İndeksi
ODI	: Oksijen Desatürasyon İndeksi
VKI	: Vücut Kitle İndeksi
TAPES	: Turkish Adult Population Epidemiology of Sleep Disorders
ESS	: Epworth Uykululuk Skalası
EMG	: Elektromiyografi

MRG : Manyetik Rezonans Görüntüleme

MAS : Mandibular İlerletme Cihazları

EPAP : Expiratory Positive Airway Pressure

EMP : Empirical Mode Decomposition

Bi-GRU : Çift Yönlü Gated Recurrent Unit



İÇİNDEKİLER

Sayfa

UYKU APNESİ TEŞHİSİNDE WELCH PEDİOGRAMLARININ DERİN ÖĞRENME YÖNTEMLERİ İLE ANALİZİ	i
JÜRİ VE ENSTİTÜ ONAYI	ii
FINAL APPROVAL FOR THESIS	iii
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR.....	vi
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	vii
STATEMENT OF COMPLIANCE WITH ETHICAL PRINCIPLES AND RULES	viii
TABLolar/ŞEKİLLER DİZİNİ.....	ix
GÖRSELLER DİZİNİ.....	x
SİMGELER VE KISALTMALAR DİZİNİ.....	xi
1. GİRİŞ.....	17
1.1. Geleneksel Teşhis Yöntemleri ve Sınırlamaları	18
1.2. Alternatif Teşhis Yöntemleri ve Elektrokardiyogram (EKG)	18
1.3. Görsel Analiz Teknikleri.....	19
1.4. Derin Öğrenme ile Otomatik Görsel Analiz.....	19
1.5. Ev Ortamında Kolay Teşhis İmkânı	20
1.6. Çalışmanın Özgünlüğü ve Literatüre Katkısı	20
1.7. Çalışmanın Metodolojisi ve Beklenen Sonuçlar.....	20
2. UYKU APNESİ.....	21
2.1. Giriş	21

2.2.	Uyku Apnesinin Tanımı ve Tipleri.....	21
2.3.	Epidemiyoloji ve Prevalans.....	22
2.4.	Risk Faktörleri ve Patofizyoloji.....	23
2.5.	Klinik Belirti ve Semptomlar.....	25
2.6.	Tanı Yöntemleri.....	26
2.7.	Uyku Apnesinin Sağlık Üzerine Etkileri.....	27
2.8.	Tedavi Yaklaşımları	28
2.9.	Tedavi Etkinliği ve Uyumu	29
2.10.	Güncel Araştırma Alanları	30
3.	LİTERATÜR TARAMASI.....	32
3.1.	Uyku Apnesi Tanısında Elektrokardiyografi (ECG) Kullanımı	32
3.2.	Derin Öğrenme ve Makine Öğrenimi Yöntemleri.....	33
3.3.	Poincaré, Welch ve RRI Histogramlarının Kullanımı ve Önemi.....	35
3.4.	CNN Tabanlı Modellerin Uyku Apnesi Teşhisindeki Başarımı	36
3.5.	Literatürdeki Eksiklikler ve Gelecek Araştırmalar için Öneriler	37
4.	MATERYAL METOT	38
4.1.	Veri Seti	38
4.2.	Kullanılan Yöntemler	41
4.2.1.	Derin Öğrenme Yaklaşımı	41
4.2.2.	Kullanılan Derin Öğrenme Mimarileri	41
4.2.2.1.	ResNet (Residual Networks).....	42
4.2.2.2.	MobileNetV2	43
4.2.2.3.	DenseNet121.....	44
4.2.2.4.	EfficientNet	45
4.2.3.	Veri Ön İşleme ve Artırma	46
4.2.4.	Model Eğitim Süreci.....	46

4.2.4.1. Eğitim Stratejisi.....	46
4.2.5. Kullanılan Derin Öğrenme Mimarileri	47
4.2.6. Model Kaydetme ve Dokümantasyon	48
4.2.7. Model Eğitimi ve Hesaplama Optimizasyonu.....	49
4.2.8. Model Kaydetme ve Dokümantasyon	49
4.2.9. Hesaplama Altyapısı	50
4.3. Test ve Değerlendirme.....	50
4.3.1. Test Veri Seti.....	50
4.3.2. Değerlendirme Metrikleri.....	51
4.3.3. Test Süreci.....	53
4.3.4. Model Seçim Kriterleri	53
5. DENEYSEL ÇALIŞMALAR	54
5.1. Deney Ortamı ve Veri Kümesi	55
5.1.1. Donanım ve Yazılım Konfigürasyonu	55
5.1.2. Veri Kümesi	55
5.2. Model Mimarileri ve Eğitim Stratejisi	55
5.2.1. Kullanılan Model Mimarileri	55
5.2.2. Eğitim Parametreleri	56
6. SONUÇLAR.....	57
6.1. Model Performansları ve Karşılaştırmalı Analiz	57
6.2. Eğitim Metrikleri ve Validasyon Performansı.....	62
6.3. Mimari Özelliklerin Performansa Etkileri	63
6.4. Klinik Uygulamalar ve Öneriler	64
7. SONUÇ VE TARTIŞMALAR.....	66
7.1. Klinik Uygulama Alanları	66
7.2. Sağlık Sistemine Katkıları	66

7.3. Gelecekteki Arařtırmalar İin Öneriler	67
7.4. Sosyal ve Ekonomik Etkiler	69
7.5. Genel Sonu	69
KAYNAKA	70
ÖZGEMİŐ	77



1. GİRİŞ

Uyku apnesi, uyku sırasında üst solunum yolunun tekrarlayan şekilde daralması veya tamamen kapanması sonucu meydana gelen ve bireylerin yaşam kalitesini önemli ölçüde düşüren bir uyku bozukluğudur (Young ve ark., 2002, s. 1217-39). Bu bozukluk, horlama, uykuda solunum durması ve gündüz aşırı uyku hali gibi semptomlarla kendini gösterir ve zamanında teşhis edilmediği takdirde ciddi sağlık komplikasyonlarına yol açabilir (Punjabi, 2008, s. 136-43). Özellikle kardiyovasküler hastalıklar, hipertansiyon, tip 2 diyabet, inme ve nörolojik bozukluklar gibi önemli sağlık sorunlarıyla ilişkili olduğu yapılan birçok çalışma tarafından ortaya konulmuştur (Somers ve ark., 2008, s. 1080-111), (Lévy ve ark., 2015, s. 15015).

Son yapılan kapsamlı bir literatür analizine göre, dünya genelinde 30-69 yaş arası yaklaşık 1 milyar yetişkin obstrüktif uyku apnesinden etkilenmektedir ve bunların 425 milyonu orta-şiddetli uyku apnesi tanısı almaktadır (Benjafield ve ark., 2019, s. 687-698). Bununla birlikte, hastalığın tanısında kullanılan geleneksel yöntemlerin maliyetli ve erişiminin sınırlı olması nedeniyle, gerçek prevalansın bu rakamların oldukça üzerinde olduğu düşünülmektedir (Franklin ve Lindberg, 2015, s. 1311-22). Özellikle toplumda uyku apnesi farkındalığının düşük olması ve polisomnografi gibi altın standart testlerin uygulanmasındaki zorluklar, teşhis oranlarının düşük kalmasına sebep olmaktadır (Kapur ve ark., 2017, s. 479-504). Sonuç olarak, daha erişilebilir, kolay uygulanabilir ve güvenilir tanı yöntemlerine olan ihtiyaç, günümüzde bu alandaki araştırmaların temel odak noktası haline gelmiştir (Collop ve ark., 2007, s. 737-47).

Bu çalışma, uyku apnesi teşhisinde EKG sinyallerinin Welch Periodogram görselleri üzerinden derin öğrenme yöntemleriyle analiz edilmesine dayanan yenilikçi bir yaklaşım sunmaktadır. Mevcut literatürde genellikle tek tip parametre veya sınırlı analiz teknikleriyle yetinilen bu alanda, spektral güç dağılımı bilgisini CNN mimarisi ile işleyerek teşhis doğruluğunun artırılması hedeflenmektedir. Holter cihazından elde edilen verilerin sistematik analizi ve geliştirilen metodoloji sayesinde, çalışmamızın klinik uygulamalarda pratik kullanım potansiyeline sahip olması ve literatürdeki metodolojik eksiklikleri gidererek gelecekteki araştırmalar için önemli bir referans noktası oluşturması öngörülmektedir.

1.1. Geleneksel Teşhis Yöntemleri ve Sınırlamaları

Uyku apnesinin teşhisinde kullanılan en yaygın yöntem, polisomnografi (PSG) testidir ve klinik uygulamada altın standart olarak kabul edilir (Kushida ve ark., 2005, s. 499). Bu test, hastanın özel donanımlı bir uyku laboratuvarında gece boyunca kalmasını ve solunum akışı, oksijen satürasyonu, elektrokardiyogram (EKG), elektrosefalogram (EEG) gibi birçok fizyolojik parametrenin sürekli olarak izlenmesini gerektirir (Berry ve ark., 2012, s. 597). PSG testi, uyku apnesinin türünü ve şiddetini kesin olarak belirleyebilmesi nedeniyle büyük bir klinik öneme sahiptir (American Academy of Sleep Medicine, 2017, s. 479).

Ancak, polisomnografi testinin uygulanmasında bazı önemli sınırlamalar bulunmaktadır. PSG testlerinin yüksek maliyeti, sağlık sistemleri üzerinde ekonomik yük oluşturmakta ve testin yaygın kullanımını sınırlamaktadır (Collop ve ark., 2007, s. 737). Ayrıca, PSG testi için gereken donanımlı uyku laboratuvarlarının ve uzman personelin bulunma zorunluluğu, özellikle kırsal veya kaynakları sınırlı bölgelerde erişim sorunları yaratmaktadır. Ayrıca, hastaların alışık olmadıkları bir ortamda, çok sayıda sensöre bağlı şekilde uyumaları gerekliliği, hastanın normal uyku düzenini bozarak test sonuçlarının doğruluğunu ve güvenilirliğini etkileyebilmektedir. Bu faktörler, daha pratik ve erişilebilir teşhis yöntemlerine yönelik ihtiyacın önemini vurgulamaktadır (Kapur ve ark., 2017, s. 479).

1.2. Alternatif Teşhis Yöntemleri ve Elektrokardiyogram (EKG)

Geleneksel teşhis yöntemlerinin sahip olduğu sınırlamalar nedeniyle, son yıllarda daha erişilebilir ve daha düşük maliyetli alternatif tanı yöntemleri geliştirilmesine yönelik çalışmalar artmıştır (Almazaydeh ve ark., 2012, s. 1-6). Bu kapsamda, elektrokardiyogram (EKG) sinyallerinin analizi, uyku apnesinin tanısında umut vaat eden bir yöntem olarak öne çıkmaktadır (Khandoker ve ark., 2009, s. 88-96). EKG sinyalleri, kalp atışları arasındaki zaman aralıklarının değişkenliği (HRV) üzerinden, otonom sinir sisteminin aktivitesini yansıtarak uyku apnesi epizodları sırasında görülen oksijen satürasyonu düşüşleri ve arousallar hakkında kritik bilgiler sağlar (Penzel ve ark., 2003, s. 1143-1151).

HRV analizi, uyku apnesinin fizyolojik etkilerini tespit etmek için yaygın olarak kullanılmaktadır ve bu yöntemin özellikle ev ortamında uygulanabilir olması, klinik

pratik açısından büyük avantajlar sunmaktadır (Roche ve ark., 1999, s. 1411-1415). Ayrıca, EKG tabanlı yöntemler, polisomnografiye kıyasla daha az invazif olması ve kolayca uygulanabilmesi nedeniyle hastalar tarafından da tercih edilmektedir (Bsoul ve ark., 2011, s. 416-427). Sonuç olarak, EKG sinyallerinin analizi, uyku apnesi teşhisinde gelecekte yaygınlaşabilecek güçlü ve pratik bir alternatif yöntem olarak değerlendirilmektedir.

1.3. Görsel Analiz Teknikleri

EKG sinyallerinin yorumlanması ve analizi için teknolojiye gelişmelerle birlikte çeşitli görsel analiz teknikleri geliştirilmiştir. Bu teknikler, uyku apnesinin teşhisi için kalp atışları arasındaki değişkenlikleri farklı perspektiflerden analiz ederek kritik bilgiler sunmaktadır (Stein ve ark., 1994, s. 1376-1381; Acharya ve ark., 2006, s. 1031-1051).

- **Takogram:** RR aralıklarının zamana bağlı değişimlerini grafiksel olarak gösterir ve uyku apnesi epizodları sırasında oluşan otonom sinir sistemi değişimlerini ortaya koyar (Laguna ve ark., 1998, s. 698-715).
- **Welch Periodogram:** RR aralıklarının frekans spektrumundaki değişimleri analiz ederek, düşük ve yüksek frekans bantlarında uyku apnesine özgü farklılıkları belirler (Welch, 1967, s. 70-73; Clifford, 2002).
- **Poincaré Grafikleri:** RR aralıklarının ardışık ilişkilerini geometrik olarak temsil eder ve kısa vadeli ile uzun vadeli HRV değişikliklerini ayırt etmeye olanak tanır (Brennan ve ark., 2001, s. 1342-1347).
- **Histogram Analizleri:** RR aralıklarının dağılım özelliklerini göstererek, normal ve patolojik durumları ayırt etmede faydalı bilgiler sağlar.

1.4. Derin Öğrenme ile Otomatik Görsel Analiz

Derin öğrenme yöntemleri, özellikle Evrişimli Sinir Ağları (CNN), görüntü tanıma ve analizindeki üstün performansları sayesinde sağlık alanında teşhis süreçlerinde umut vaat eden sonuçlar vermektedir. Özellikle uyku apnesi teşhisinde, CNN tabanlı yaklaşımlar geleneksel yöntemlere kıyasla daha hızlı ve güvenilir sonuçlar sunabilmektedir (Koley & Dey, 2013, s. 2082-2092; Urtnasan ve ark., 2018, s. 104). Bu tez çalışmasında, Holter cihazı ile kaydedilen EKG sinyallerinden elde

edilen Welch Periodogramları kullanılacaktır. Bu görsellerin CNN kullanılarak analiz edilmesi, uyku apnesinin teşhisinde otomatik ve etkili bir yöntem geliştirme hedefiyle ele alınacaktır.

1.5. Ev Ortamında Kolay Teşhis İmkânı

Bu yöntemin temel avantajlarından biri, hastaların kendi evlerinde rahat ve kesintisiz bir şekilde teşhis sürecine dahil olabilmesidir. Geleneksel polisomnografi testlerinin karmaşık ve rahatsız edici yapısına karşın, Holter cihazları ile ev ortamında kaydedilen EKG sinyallerinin kullanımı, hasta konforunu önemli ölçüde artırmakta ve teşhis sürecini kolaylaştırmaktadır (Collop ve ark., 2007, s. 737-747; Flemons ve ark., 2003, s. 1543-1579). Ayrıca, elde edilen sinyallerin tele-tıp platformları aracılığıyla uzman merkezlere aktarılması ve burada yapay zeka destekli sistemler tarafından otomatik analizi sayesinde hem hastanelerin iş yükü azalmakta hem de teşhis doğruluğu artmaktadır (Bruyneel, 2016, s. 1203-1219; Mendonça ve ark., 2019, s. 825-837).

1.6. Çalışmanın Özgünlüğü ve Literatüre Katkısı

Uyku apnesinin teşhisinde EKG tabanlı yöntemlerin kullanımı literatürde giderek artmaktadır. Ancak mevcut çalışmalar çoğunlukla tek tip parametre ya da sınırlı analiz teknikleri üzerine yoğunlaşmıştır (Tripathy ve ark., 2020, s. 535-541; Song ve ark., 2016, s. 1532-1542). Bu tez çalışmasının özgünlüğü, Welch Periodogramlarının derin öğrenme yöntemiyle analiz edilerek uyku apnesi teşhisinde etkili bir sistem oluşturulmasından kaynaklanmaktadır. Bu yaklaşım, Welch Periodogramlarının sağladığı spektral güç dağılımı bilgisinin CNN ile işlenmesine dayanarak teşhis doğruluğunun ve güvenilirliğinin önemli ölçüde artırılmasını hedeflemektedir.

1.7. Çalışmanın Metodolojisi ve Beklenen Sonuçlar

Çalışmada ilk aşamada Holter cihazından elde edilen EKG sinyallerinin görsellere dönüştürülme süreçleri detaylı olarak incelenerek, her görselin uyku apnesiyle ilişkili karakteristikleri ortaya konacaktır. İkinci aşamada ise bu görsellerin

analizi için geliştirilen derin öğrenme modelleri ve metodolojisi adım adım açıklanarak, elde edilen sonuçlar karşılaştırmalı olarak değerlendirilecektir. Çalışmadan elde edilen bulguların klinik uygulamalarda kullanılabilirliğinin yanı sıra literatürde var olan eksiklikleri gidererek, bu alandaki araştırmalara önemli bir metodolojik referans noktası oluşturması beklenmektedir.

2. UYKU APNESİ

2.1. Giriş

Uyku apnesi, uyku sırasında tekrarlayan solunum duraklamaları ile karakterize edilen yaygın fakat ciddi bir uyku bozukluğudur. Bu duraklamalar, birkaç saniyeden dakikalara kadar sürebilir ve geceleri onlarca kez tekrarlanabilir. Bu durum, sadece uyku kalitesini bozmakla kalmaz, aynı zamanda vücutta oksijen seviyelerinin düşmesine ve çeşitli sistemik sorunlara yol açabilir. Uyku apnesi, dünya genelinde milyonlarca insanı etkilemekte olup, özellikle orta yaş ve üzeri popülasyonda daha sık görülmektedir. Son yıllarda yapılan epidemiyolojik çalışmalar, bu hastalığın sanılanın aksine oldukça yaygın olduğunu ve önemli bir halk sağlığı sorunu teşkil ettiğini göstermektedir (Benjafield ve ark., 2019, s. 687-698). Bu bölümde, uyku apnesinin tanımı, tipleri, prevalansı, risk faktörleri, tanı yöntemleri, tedavi seçenekleri ve ilişkili sağlık sonuçları detaylı şekilde ele alınacaktır.

2.2. Uyku Apnesinin Tanımı ve Tipleri

Uyku apnesi, kelime anlamı olarak Yunanca'da "nefessizlik" anlamına gelen "apnea" teriminden türemiştir. Apne, uyku sırasında solunum yollarının kısmen veya tamamen tıkanması sonucu ortaya çıkan solunum duraklamasıdır. Amerikan Uyku Tıbbı Akademisi (AASM) tarafından yapılan Uluslararası Uyku Bozuklukları Sınıflandırması'nda (ICSD-3) uyku apnesi, uyku ile ilişkili solunum bozuklukları ana başlığı altında incelenmektedir ve üç ana tipe sınıflandırılmaktadır (American Academy of Sleep Medicine, 2014, s. 1387). En yaygın görülen tip olan Obstrüktif Uyku Apnesi (OUA), uyku sırasında üst solunum yollarındaki yumuşak dokuların gevşemesi sonucu hava yolunun kısmen veya tamamen tıkanması ile karakterizedir. Bu tıkanıklık, diyafram ve göğüs kaslarının hava akışını sağlamak için daha fazla

çalışmasına rağmen, yetersiz ventilasyona neden olur. Santral Uyku Apnesi (SSA) ise, beynin solunum kaslarına gönderdiği sinyallerde bir problem olduğu durumlarda ortaya çıkar. Solunum çabası olmadığı için ventilasyon durur. Nörolojik bozukluklar, kalp yetmezliği ve bazı ilaçların kullanımı ile ilişkilidir. Üçüncü tip olan Kompleks veya Mikst Uyku Apnesi ise obstrüktif ve santral apne özelliklerinin bir arada görüldüğü tiptir. Genellikle obstrüktif apne ile başlayıp santral apne ile devam eden bir patern gösterir (Malhotra ve White, 2002, s. 237).

Uyku apnesinin şiddeti, Apne-Hipopne İndeksi (AHI) kullanılarak belirlenir. AHI, her saat uyku başına düşen apne (tam solunum duraklaması) ve hipopne (kısmi solunum duraklaması) sayısını ifade eder. AASM kriterlerine göre, AHI 5-15 arası hafif, 15-30 arası orta, 30'dan fazla ise ağır uyku apnesi olarak sınıflandırılır. Bu sınıflandırma hem klinik pratikte hem de bilimsel araştırmalarda yaygın olarak kullanılmaktadır ve tedavi kararlarında belirleyici rol oynamaktadır (Kapur ve ark., 2017, s. 479). AHI'nin yanı sıra, oksijen desatürasyon indeksi (ODI), uyku sırasındaki en düşük oksijen saturasyonu ve uykuda geçirilen zamanın yüzde kaçında kan oksijen seviyesinin %90'ın altında olduğunu gösteren T90 değeri de hastalığın şiddetini belirlemede kullanılan diğer önemli parametrelerdir. Bu parametreler, özellikle kardiyovasküler komplikasyon riskinin değerlendirilmesinde önemlidir.

2.3. Epidemiyoloji ve Prevalans

Uyku apnesi, dünya genelinde yaygın bir sağlık sorunu olup, yapılan epidemiyolojik çalışmalar prevalansın tahmin edilenden çok daha yüksek olduğunu göstermektedir. Benjafield ve arkadaşlarının 2019 yılında yayınladıkları geniş kapsamlı bir araştırmada, dünya genelinde yaklaşık 936 milyon yetişkinin (30-69 yaş arası) orta ve ağır düzeyde obstrüktif uyku apnesinden ($AHI \geq 15$) etkilendiği tahmin edilmiştir. Bu rakam, bahsedilen yaş grubundaki dünya nüfusunun yaklaşık %10'una karşılık gelmektedir (Benjafield ve ark., 2019, s. 687). Epidemiyolojik çalışmalarda kullanılan tanı kriterleri, örneklem seçimi ve demografik özellikler gibi faktörlere bağlı olarak prevalans tahminleri değişiklik göstermektedir.

Wisconsin Uyku Kohortu Çalışması, bu alanda yapılan en kapsamlı çalışmalardan biri olup, orta veya şiddetli uyku apnesinin ($AHI \geq 15$) 30-60 yaş arası erkeklerde %4, kadınlarda %2 oranında görüldüğünü ortaya koymuştur. Yaş ilerledikçe prevalans artmakta, 60 yaş üstü erkeklerde %10'a, kadınlarda %5'e kadar

yükselmektedir (Young ve ark., 2002, s. 13). Daha güncel verilere göre, batı toplumlarında yetişkin nüfusta OUA prevalansı erkeklerde %10-17, kadınlarda %3-9 arasında değişmektedir. Bu oranlar yaşlı popülasyonda (>65 yaş) daha da artmakta, bazı çalışmalarda %50'ye kadar yükselebilmektedir (Heinzer ve ark., 2015, s. 310).

Asyalı popülasyonlarda yapılan çalışmalar ilginç bir durum ortaya koymaktadır. Vücut kitle indeksi (VKİ) daha düşük olmasına rağmen, kraniofasiyal yapıdaki farklılıklar nedeniyle Asyalılarda OUA prevalansı beklenenden yüksektir. Hong Kong'da yapılan bir çalışmada, orta yaşlı erkeklerde OUA prevalansı %8.8 olarak bulunmuştur (Ip ve ark., 2004, s. 127). Hindistan'da yapılan çalışmalarda da benzer sonuçlar elde edilmiştir. Bu durum, uyku apnesinin patogenezinde obezite dışında kraniofasiyal faktörlerin de önemli rol oynadığını göstermektedir.

Türkiye'de yapılan çalışmalar sınırlı olmakla birlikte, Köktürk ve arkadaşlarının 1998 yılında yaptığı çalışmada, Kırıkkale'de genel popülasyonda OUA prevalansı %0.9-1.9 arasında bulunmuştur. Ancak risk faktörleri taşıyan gruplarda bu oran %8-20'ye kadar yükselmektedir (Köktürk ve ark., 1998, s. 187). Daha güncel bir çalışma olan TAPES (Turkish Adult Population Epidemiology of Sleep Disorders) çalışmasında ise, Türkiye'de kentsel alanda yaşayan yetişkinlerde horlama prevalansı %29.5, tanıklı apne prevalansı %7.6 olarak bulunmuştur (Demir ve ark., 2015, s. 298).

2.4. Risk Faktörleri ve Patofizyoloji

Uyku apnesi gelişiminde çeşitli risk faktörleri rol oynamaktadır. Bu faktörlerin anlaşılması, hem hastalığın patofizyolojisinin aydınlatılması hem de risk altındaki bireylerin belirlenmesi açısından önemlidir. Yaş ilerledikçe uyku apnesi riski artmaktadır. Bunun nedenleri arasında yaşla birlikte üst solunum yollarındaki kas tonusunun azalması, yağ dağılımının değişmesi, solunum fonksiyonlarının bozulması ve komorbiditelerin artması sayılabilir. Özellikle 40 yaş üzerinde risk belirgin şekilde artmaktadır (Young ve ark., 2002, s. 893-900).

Cinsiyet, uyku apnesi için önemli bir risk faktörüdür. Premenopozal kadınlara kıyasla erkeklerde risk 2-3 kat daha yüksektir. Bu durumun, hormonlar, üst solunum yolu anatomisi ve yağ dağılımındaki farklılıklardan kaynaklandığı düşünülmektedir. Östrojen ve progesteronun üst solunum yolu kasları üzerinde tonusu artırıcı etkisi vardır. Menopoz sonrası kadınlarda bu koruyucu etki azaldığı için uyku apnesi insidansı artmaktadır (Bixler ve ark., 2001, s. 608-613).

Obezite, uyku apnesi için en güçlü değiştirilebilir risk faktörüdür. Vücut kitle indeksi arttıkça uyku apnesi riski ve şiddeti de artmaktadır. Obezite, üst solunum yollarında yağ birikimi, boyun çevresinde artış, akciğer volümlerinde azalma ve faringeal lümen çapında daralma gibi mekanizmalarla uyku apnesine zemin hazırlar. Visseral obezite ve boyun çevresindeki artış, özellikle OUA ile güçlü ilişki göstermektedir. Erkeklerde 43 cm, kadınlarda 38 cm'den fazla boyun çevresi uyku apnesi için yüksek risk oluşturur (Schwartz ve ark., 2008, s. 185-192).

Kraniofasial yapı da uyku apnesi patogenezinde önemli rol oynamaktadır. Mikrognati (küçük çene), retrognati (geride çene), makroglossi (büyük dil), tonsil hipertrofisi gibi anomaliler hava yolu açıklığını azaltarak risk oluşturur. Bu faktörler, özellikle Asyalı populasyonlarda, daha düşük VKİ değerlerine rağmen uyku apnesi prevalansının yüksek olmasını açıklamaktadır (Sutherland ve ark., 2011).

Genetik faktörler de uyku apnesi riskini etkilemektedir. Aile öyküsü pozitif olanlarda risk 2-4 kat artmaktadır. İkiz çalışmaları, uyku apnesinin genetik geçişini desteklemektedir. Uyku apnesi ile ilişkili çeşitli gen varyantları tanımlanmıştır, ancak bu alanda daha fazla araştırma gerekmektedir (Redline ve Tishler, 2000).

Obstrüktif uyku apnesinin temel patofizyolojik mekanizması, uyku sırasında faringeal dilatatör kas tonusunun azalması sonucu üst hava yolunda kollaps meydana gelmesidir. Üst hava yolu, kemik ve kıkırdak yapı ile desteklenmeyen bir segmente sahiptir ve bu bölge kollaps için en hassas alandır. Normal uyku sırasında bile üst solunum yolu kaslarında bir miktar tonus kaybı olur, ancak OUA hastalarında bu durum daha belirgindir (White, 2005).

Üst hava yolunun kollapsını etkileyen faktörler anatomik, nöromusküler, yapısal ve mekanik olarak sınıflandırılabilir. Anatomik faktörler arasında dar hava yolu, yumuşak doku hacminin artması, kraniofasial anomaliler sayılabilir. Nöromusküler faktörler, genioglossus ve diğer dilatatör kasların aktivitesindeki bozuklukları içerir. Bu kasların uyku sırasında yeterince aktive olamaması, kollaps riskini artırır. Yapısal faktörler, üst hava yolu çevresindeki yumuşak dokuların viskoelastik özellikleri ile ilgilidir. Mekanik faktörler ise, Starling resistör modeli ile açıklanır; bu modele göre, üst hava yolundaki intraluminal basınç, kollaps basıncının (Pcrit) altına düştüğünde hava yolu kapanır. OUA hastalarında Pcrit değeri daha yüksektir, yani hava yolları kollaps eğilimindedir (Eckert ve Malhotra, 2008).

Santral uyku apnesinin patofizyolojisi ise, santral sinir sisteminin solunum

kontrolündeki düzensizlikler ile ilişkilidir. Bu durum, beyin sapındaki solunum merkezleri, kemoreseptörler ve solunum kas aktivitesi arasındaki koordinasyon bozukluğundan kaynaklanır. Özellikle kalp yetmezliği olan hastalarda gözlenen Cheyne-Stokes solunumu, santral apnenin klasik bir örneğidir ve solunum kontrolündeki kararsızlığın bir sonucudur. CO₂ düzeyinin apne eşiğinin altına düşmesi, santral apne ataklarını tetikleyebilir (Bradley ve Floras, 2003).

2.5. Klinik Belirti ve Semptomlar

Uyku apnesi, çeşitli gece ve gündüz semptomları ile kendini gösterir. Bu semptomların şiddeti ve çeşitliliği, apnenin derecesi, tipi ve hastanın bireysel özellikleri ile ilişkilidir. Gece semptomları arasında, horlama en sık karşılaşılan ve genellikle hastalığın ilk belirtisi olan semptomdur. OUA hastalarının %95'inden fazlasında horlama mevcuttur. Horlama, üst solunum yolundaki daralmış bölgelerden geçen havanın oluşturduğu vibrasyon sesi olup, genellikle yüksek sesli, düzensiz ve aralıklıdır. Apne atakları sırasında ses kesilir ve ardından genellikle yüksek sesli bir horlamayla devam eder (Kapur, 2010).

Tanımlı apne, yatak partneri veya aile üyeleri tarafından gözlenen solunum duraklamaları olup, uyku apnesi tanısı için oldukça spesifik bir bulgudur. Hasta uykuda iken nefes alışın durduğu, ardından bir horlama veya nefes verme sesi ile solunumun yeniden başladığı gözlenir. Bu duraklamalar sırasında hasta genellikle huzursuzlanır, pozisyon değiştirir veya uyanabilir. Literatürde tanımlı apnenin, uyku apnesi tanısında %80'e varan sensitivite ve spesifisiteye sahip olduğu bildirilmiştir (Myers ve ark., 2013).

Uykuda boğulma veya tıkanma hissi ile uyanma, uyku apnesi hastalarında sık görülen ve oldukça rahatsız edici bir semptomdur. Hasta, apne sonrası hipoksemi ve hiperkapni nedeniyle nefes darlığı hissi ile uyanır. Bu durum, özellikle gece boyunca tekrarlayan apne ataklarının olduğu ağır olgularda siktir ve hastanın uyku bütünlüğünü bozar. Ayrıca, bu semptom noktürnal panik atak ve kalp yetmezliğine bağlı paroksizmal noktürnal dispne ile ayırıcı tanıda önemlidir (Gold ve ark., 2003).

Gündüz semptomları arasında en sık görüleni, aşırı gündüz uykululuğudur. Uyku apnesi sonucu uyku bölünmesi ve derin uyku evrelerinin azalması, gündüz uykululuğuna neden olur. Hastalar genellikle pasif durumlarda (televizyon izlerken, kitap okurken, araba yolculuğu sırasında) uyuyakalır. İleri olgularda, aktif durumlarda

da (konuşurken, yemek yerken, araba kullanırken) uyuyakalma olabilir, bu durum ciddi iş ve trafik kazası riskini artırır. Aşırı gündüz uykululuğu, Epworth Uykululuk Skalası gibi subjektif değerlendirme araçları veya Çoklu Uyku Latans Testi (MSLT) gibi objektif testlerle değerlendirilebilir (Johns, 1991).

Bilişsel fonksiyonlarda bozulma, uyku apnesinin önemli bir gündüz semptomu olup, dikkat, konsantrasyon, bellek, yürütücü işlevler ve psikomotor performansta bozulma ile kendini gösterir. Bu bozuklukların, kronik intermittan hipoksemi ve uyku bölünmesinin nöronal hücreler üzerindeki olumsuz etkileri ile ilişkili olduğu düşünülmektedir. Uyku apnesi hastalarında bilişsel fonksiyonlardaki bozulmanın, demans ve Alzheimer hastalığı riskini artırdığı bildirilmiştir (Yaffe ve ark., 2011).

2.6. Tanı Yöntemleri

Uyku apnesi tanısında altın standart yöntem polisomnografidir (PSG). Ancak tanı süreci, klinik değerlendirme, risk faktörlerinin belirlenmesi, tarama araçlarının kullanımı ve ardından uygun hastalarda PSG veya evde uyku testi uygulanması şeklinde ilerler. Klinik değerlendirme, detaylı öykü alınması ve fizik muayene ile başlar. Öyküde, horlama, tanıklı apne, gündüz uykululuğu, sabah baş ağrısı gibi karakteristik semptomlar sorgulanır. Risk faktörleri (obezite, boyun çevresi, kraniofasiyal anomaliler vb.) değerlendirilir. Eşlik eden hastalıklar (hipertansiyon, diyabet, kalp yetmezliği vb.) ve kullanılan ilaçlar kaydedilir (Epstein ve ark., 2009).

Tarama amacıyla çeşitli anketler kullanılabilir. Epworth Uykululuk Skalası (ESS), gündüz uykululuğunu değerlendiren basit bir ankettir. Sekiz farklı durumda uykuya dalma olasılığı sorgulanır ve 0-24 arası puanlanır. 11 ve üzeri puanlar, artmış gündüz uykululuğunu gösterir (Johns, 1991). Berlin Anketi, uyku apnesi risk faktörlerini ve semptomlarını değerlendiren, yüksek, orta ve düşük risk kategorilerine ayıran bir ankettir. STOP-BANG Anketi ise, sekiz soruluk basit bir anket olup, dört veya daha fazla evet cevabı uyku apnesi için yüksek riski gösterir. Bu anketin özellikle yüksek riskli hastalarda (obez, hipertansif, diyabetik vb.) negatif prediktif değeri yüksektir (Chung ve ark., 2008).

Polisomnografi (PSG), uyku sırasında çeşitli fizyolojik parametrelerin kaydedildiği, uyku laboratuvarında teknisyen gözetiminde gerçekleştirilen bir testtir. Standart PSG'de şu parametreler kaydedilir: Elektroensefalografi (EEG), elektrookülografi (EOG), elektromiyografi (EMG), elektrokardiyografi (EKG),

solunum çabası (göğüs ve karın hareketleri), hava akımı (burun ve ağız), oksijen saturasyonu, vücut pozisyonu ve horlama şiddeti. Bu veriler, uyku evreleri, solunum olayları, oksijen desaturasyonları, arousallar ve ekstremiteler hareketleri açısından değerlendirilir (Berry ve ark., 2012).

2.7. Uyku Apnesinin Sağlık Üzerine Etkileri

Tedavi edilmeyen uyku apnesi, birçok sistemik hastalık için risk faktörü oluşturmaktadır. Kardiyovasküler sistem üzerindeki etkileri en iyi belgelenmiş olanlardır. Uyku apnesi, hipertansiyon, koroner arter hastalığı, kalp yetmezliği, aritmi (özellikle atriyal fibrilasyon), inme ve pulmoner hipertansiyon riskini artırmaktadır. Yapılan geniş epidemiyolojik çalışmalarda, orta-ağır OUA ($AHI \geq 15$) varlığında kardiyovasküler hastalık riskinin 2-5 kat arttığı gösterilmiştir (Marin ve ark., 2005). Bu ilişki, çeşitli mekanizmalarla açıklanabilir: İntermittan hipoksemi ve reoksijenizasyon, sempatik aktivasyona, oksidatif strese, vasküler endotel disfonksiyonuna ve sistemik inflamasyona yol açar. Negatif intratorasik basınç değişiklikleri, ventriküler afterload'ı artırır ve kardiyak fonksiyonu etkiler. Tekrarlayan arousallar, otonomik instabiliteye neden olur (Somers ve ark., 2008).

Uyku apnesinin metabolik sistem üzerinde de olumsuz etkileri vardır. İnsülin direnci, tip 2 diyabet, metabolik sendrom ve dislipidemi riski artmıştır. Yapılan çalışmalarda, orta-ağır OUA hastalarında tip 2 diyabet riskinin 2-3 kat arttığı gösterilmiştir. İntermittan hipoksemi, oksidatif stres ve inflamasyon, insülin direncine ve pankreatik beta hücre disfonksiyonuna neden olabilir. Ayrıca, uyku fragmentasyonu, ghrelin ve leptin gibi iştah hormonlarının dengesini bozarak obeziteye katkıda bulunabilir (Punjabi ve ark., 2004).

Uyku apnesinin nörokognitif fonksiyonlar üzerindeki olumsuz etkileri de iyi belgelenmiştir. Dikkat, konsantrasyon, bellek, yürütücü işlevler ve psikomotor performansta bozulma görülür. Kronik intermittan hipoksemi ve uyku bölünmesi, beyin dokusunda yapısal ve fonksiyonel değişikliklere yol açabilir. Manyetik rezonans görüntüleme (MRG) çalışmalarında, OUA hastalarında hipokampus, prefrontal korteks ve insula gibi beyin bölgelerinde gri madde kaybı gösterilmiştir. Bu değişiklikler, bilişsel bozukluklar ve duygudurum değişiklikleri ile ilişkilidir (Canessa ve ark., 2011).

Uyku apnesi, diğer sistemler üzerinde de olumsuz etkilere sahiptir.

Gastroözofageal reflü hastalığı, nonalkolik yağlı karaciğer hastalığı, kronik böbrek hastalığı ve immün sistem disfonksiyonu riski artmıştır. Ayrıca, uyku apnesinin gebelikte preeklampsi, gestasyonel diyabet ve intrauterin gelişme geriliği riskini artırdığı bildirilmiştir (Franklin ve Lindberg, 2015).

Uyku apnesi, yaşam kalitesini ve günlük fonksiyonları önemli ölçüde etkiler. Aşırı gündüz uykululuğu, iş ve akademik performansta düşüşe, sosyal ve aile ilişkilerinde bozulmaya, trafik ve iş kazalarında artışa neden olabilir. Yapılan çalışmalarda, tedavi edilmemiş OUA hastalarında trafik kazası riskinin 2-7 kat arttığı gösterilmiştir. Ayrıca, uyku apnesi, depresyon ve anksiyete bozuklukları gibi psikiyatrik hastalıklarla da ilişkilidir (Peppard ve ark., 2000).

2.8. Tedavi Yaklaşımları

Oral apareyler, hafif-orta OUA hastalarında veya PAP tedavisini tolere edemeyen hastalarda alternatif bir tedavi seçeneğidir. En sık kullanılan tipi, Mandibular İlerletme Cihazları (MAS)'dır. Bu cihazlar, alt çeneyi ve dili öne doğru konumlandırarak faringeal hava yolu açıklığını artırır. Randomize kontrollü çalışmalarda, MAS'ın AHI'yi %50 oranında azalttığı, oksijen satürasyonunu artırdığı ve gündüz semptomlarını iyileştirdiği gösterilmiştir. MAS'ın etkinliği PAP'a göre daha düşük olmakla birlikte, hasta uyumu genellikle daha iyidir. Dil Tutma Cihazları, diğer bir oral apare tipi olup, dili anteriora konumlandırarak hava yolu açıklığını artırır, ancak MAS'a göre daha az tercih edilmektedir (Ramar ve ark., 2015).

Cerrahi tedaviler, spesifik anatomik obstrüksiyon bölgelerine yönelik olarak uygulanabilir. Üst Hava Yolu Cerrahisi (uvulopalatofaringoplasti, tonsillektomi, adenoidektomi), retropalatal bölgedeki obstrüksiyonları tedavi etmek için kullanılır. Çene Cerrahisi (maksillomandibular ilerletme), hem retropalatal hem de retroglossal bölgedeki obstrüksiyonlarda etkilidir ve AHI'de %90'a varan azalma sağlayabilir. Trakeostomi, diğer tedavilere yanıt vermeyen veya hayatı tehdit eden ağır OUA olgularında son çare olarak uygulanabilir. Bariatrik Cerrahi, morbid obezitesi olan OUA hastalarında hem kilo kaybı hem de metabolik parametrelerde iyileşme sağlayarak apne şiddetini azaltabilir (Caples ve ark., 2010).

Hipoglossal Sinir Stimülasyonu, son yıllarda gelişen, implante edilebilir bir tedavi yöntemidir. Uyku sırasında hipoglossal siniri uyararak genioglossus kasını aktive eder ve üst hava yolu açıklığını artırır. Orta-ağır OUA hastalarında, özellikle

PAP intoleransı olanlarda tercih edilebilir. STAR çalışmasında, hipoglossal sinir stimülasyonunun AHI'yi %68 oranında azalttığı ve yaşam kalitesini iyileştirdiği gösterilmiştir (Strollo ve ark., 2014).

Faringeal egzersizler veya orofaringeal egzersizler, üst hava yolu kaslarını güçlendirerek kollaps eğilimini azaltmayı amaçlar. Yapılan çalışmalarda, düzenli egzersizlerin AHI'yi %50'ye varan oranlarda azaltabileceği, horlama şiddetini ve gündüz semptomlarını iyileştirebildiği gösterilmiştir. Bu egzersizler, özellikle hafif OUA hastalarında veya diğer tedavilere ek olarak uygulanabilir (Guimarães ve ark., 2009).

İlaç tedavileri, uyku apnesinde genellikle sınırlı etkinliğe sahiptir. Asetazolamid, teofilin gibi solunum stimülanları, özellikle santral uyku apnesinde etkili olabilir. Modafinil ve armodafinil, CPAP tedavisine rağmen devam eden gündüz uykululuğu olan hastalarda yardımcı ajan olarak kullanılabilir. Ancak, bu ilaçlar altta yatan apneyi tedavi etmez, sadece semptomatik iyileşme sağlar (Mason ve ark., 2013).

Expiratory Positive Airway Pressure (EPAP) valfleri, burun deliklerine yerleştirilen ve ekspiryum sırasında dirençli akıma neden olan küçük cihazlardır. Ekspiryum sırasında üst hava yolunda pozitif basınç oluşturarak inspiryum sırasında hava yolunun kollaps eğilimini azaltır. Hafif-orta OUA hastalarında alternatif bir tedavi seçeneği olarak değerlendirilebilir (Berry ve ark., 2011).

2.9. Tedavi Etkinliği ve Uyumu

PAP tedavisi, uyku apnesinde en etkili tedavi yöntemi olmasına rağmen, uyum problemleri sık görülmektedir. Çalışmalar, PAP kullanan hastaların yaklaşık %30-50'sinin yetersiz uyum gösterdiğini (geceleri 4 saatten az kullanım) ortaya koymaktadır. Tedavi uyumunu etkileyen faktörler arasında, cihaz ve maske ile ilgili problemler (maske sızıntısı, cilt irritasyonu, burun tıkanıklığı, ağız kuruluğu), psikolojik faktörler (klostrofobi, anksiyete), hastalık algısı ve motivasyon, sosyoekonomik faktörler ve sağlık sistemi ile ilgili faktörler sayılabilir (Weaver ve Grunstein, 2008).

Tedavi uyumunu artırmak için çeşitli stratejiler geliştirilmiştir. Hasta eğitimi, hastalığın doğası, komplikasyonları ve tedavinin önemi hakkında detaylı bilgilendirme içermelidir. Maske ve cihaz seçiminin optimizasyonu, hastanın yüz yapısına uygun maske seçimi, farklı tip maske denemeleri ve cihaz ayarlarının

bireyselleştirilmesini içerir. Nemlendiriciler ve ısıtıcılar, burun tıkanıklığı ve ağız kuruluğu gibi yan etkileri azaltabilir. Davranışsal müdahaleler, bilişsel davranışçı terapi, destek grupları ve motivasyonel görüşmeleri içerebilir. Telemonitörizasyon sistemleri, hastaların kullanım verilerinin uzaktan takibini ve erken dönemde müdahale imkânını sağlar (Sawyer ve ark., 2011).

Güncel çalışmalar, PAP tedavisinin kardiyovasküler sonuçlar üzerindeki etkisini değerlendirmiştir. SAVE çalışması, kardiyovasküler hastalığı veya serebrovasküler hastalığı olan, orta-ağır OUA hastalarında CPAP tedavisinin primer kardiyovasküler olayları azaltmadığını göstermiştir. Ancak, CPAP uyumu yüksek olan alt grup analizlerinde, inme riskinde azalma saptanmıştır. Bu sonuçlar, CPAP tedavisinin kardiyovasküler faydaları için yeterli uyumun önemini vurgulamaktadır (McEvoy ve ark., 2016).

2.10. Güncel Araştırma Alanları

Uyku apnesi alanında güncel araştırmalar, hastalığın patogenezinin daha iyi anlaşılması, tanı ve tedavi yöntemlerinin geliştirilmesi ve komorbiditelerin yönetimi üzerine odaklanmaktadır. Fenotipleme, farklı OUA alt tiplerinin belirlenmesi ve tedavi stratejilerinin bu alt tiplere göre bireyselleştirilmesi amaçlanmaktadır. Anatomik faktörlerin baskın olduğu hastalar, nöromusküler kontrolün bozulduğu hastalar, arousal eşiğinin düşük olduğu hastalar ve solunum kontrolünün kararsız olduğu hastalar gibi farklı fenotiplerin tanımlanması, tedavi yaklaşımlarının optimizasyonu açısından önemlidir (Eckert, 2018).

Biyobelirteçler üzerine yapılan araştırmalar, tanı ve tedavi yanıtını öngörmede kullanılacak biyobelirteçlerin geliştirilmesini amaçlar. Mikro RNA'lar, proteomik ve metabolomik çalışmalar, uyku apnesi ile ilişkili moleküler değişikliklerin belirlenmesini sağlayabilir. Bu biyobelirteçler, hastalık şiddetinin değerlendirilmesi, kardiyovasküler komplikasyon riskinin tahmin edilmesi ve tedavi yanıtının öngörülmesi için kullanılabilir (Khalyfa ve ark., 2016).

Farmakoterapötik yaklaşımlar, özellikle santral uyku apnesinde etkili olabilecek ilaçların geliştirilmesini amaçlar. Karboanhidraz inhibitörleri, serotonerjik ajanlar, noradrenerjik ajanlar ve antiinflamatuvar ajanlar üzerine çalışmalar devam etmektedir. Ayrıca, hipoglossal sinir stimülasyonunun farmakolojik olarak taklit edilebilmesi için çalışmalar yürütülmektedir (Saboisky ve ark., 2012).

Kişiselleştirilmiş tıp yaklaşımları, genetik ve moleküler biyoloji temelli bireyselleştirilmiş tedavi stratejilerinin geliştirilmesini amaçlar. Farmakoterapi yanıtını etkileyebilecek genetik polimorfizmlerin belirlenmesi, tedavi seçimini optimize edebilir. Epigenetik değişikliklerin tanımlanması, uyku apnesinin kronik etkilerinin ve tedavi yanıtının değerlendirilmesinde faydalı olabilir (Khalyfa ve ark., 2013).

Yapay zeka ve büyük veri uygulamaları, tanı, tedavi ve takipte giderek daha fazla kullanılmaktadır. Makine öğrenimi algoritmaları, PSG verilerinin otomatik analizi, uyku apnesi riskinin tahmin edilmesi ve tedavi uyumunun optimize edilmesi için kullanılabilir. Büyük veri analizleri, uyku apnesi ile diğer hastalıklar arasındaki ilişkilerin belirlenmesini ve popülasyon düzeyinde risk faktörlerinin tanımlanmasını sağlayabilir (Penzel ve ark., 2018).

Alternatif PAP modları, hasta uyumunu artıracak yeni PAP modalitelerinin geliştirilmesini amaçlar. Daha sessiz, daha kompakt ve kullanımı daha kolay cihazlar, hasta uyumunu artırabilir. Akıllı telefonlar ve giyilebilir teknolojiler ile entegre edilmiş PAP cihazları, kullanım verilerinin takibini ve hasta eğitimini kolaylaştırabilir. Ayrıca, yapay zeka destekli otomatik basınç ayarlama algoritmaları, tedavi etkinliğini artırabilir (Cistulli ve ark., 2019).

3. LİTERATÜR TARAMASI

3.1. Uyku Apnesi Tanısında Elektrokardiyografi (ECG) Kullanımı

Uyku apnesi, uyku sırasında solunumun tekrarlayan şekilde durması veya önemli ölçüde azalması ile karakterize edilen ciddi bir uyku bozukluğudur (Bazoukis ve ark., 2023). Apne olayları sırasında, üst solunum yolunun kısmen veya tamamen tıkanması nedeniyle solunumun geçici olarak durması gerçekleşir (Setiawan & Lin, 2022). Bu durum, kişinin gece boyunca defalarca uyanmasına ve uyku kalitesinin bozulmasına neden olur. Tedavi edilmediğinde hipertansiyon, kalp hastalıkları ve inme gibi ciddi sağlık sorunlarına yol açabilir (Rahman ve ark., 2019).

Günümüzde uyku apnesinin standart tanı yöntemi, polisomnografi (PSG) adı verilen kapsamlı bir testtir (Penzel ve ark., 2000). PSG, uyku sırasında beyin dalgaları, kas aktivitesi, kalp ritmi, solunum ve oksijen düzeyi gibi çeşitli fizyolojik parametreleri kaydeder (Roche ve ark., 1999). Ancak PSG'nin uygulanması maliyetli, zaman alıcı ve hastalar için rahatsız edici olabilir (Bahrami & Forouzanfar, 2022). Bu nedenle araştırmacılar, tanı sürecini daha kolay hale getirmek için alternatif yöntemler üzerine çalışmalar yapmaktadır.

Elektrokardiyografi (ECG), son yıllarda uyku apnesi tanısında giderek artan bir ilgi görmektedir (Chen ve ark., 2022). ECG, kalbin elektriksel aktivitesini kaydeden ve kolay uygulanabilen bir yöntemdir. ECG sinyallerinden elde edilen kalp hızı değişkenliği (Heart Rate Variability - HRV), kalbin atışları arasındaki zaman aralıklarının değişkenliğini analiz ederek otonom sinir sistemi aktivitesini ortaya koyar (Martín-Montero ve ark., 2020). HRV analizi, uyku apnesinin tanısında değerli bilgiler sağlamaktadır çünkü apne olayları sırasında otonom sinir sisteminde belirgin değişimler meydana gelir (Mermigkis ve ark., 2009).

HRV analizleri genellikle zaman alanı, frekans alanı ve doğrusal olmayan yöntemler şeklinde gerçekleştirilir (Qin ve ark., 2021). Zaman alanı analizi, RR intervallerinin ortalama, standart sapma gibi temel istatistiksel değerlerini hesaplayarak apne epizotlarını saptamada kullanılır (Rahman ve ark., 2019). Frekans alanı analizinde ise Welch yöntemi gibi spektral analiz teknikleri kullanılarak HRV'nin farklı frekans bileşenleri incelenir (Martín-Montero ve ark., 2020). Bu bileşenlerin uyku apnesi sırasında sempatik ve parasempatik aktivitedeki değişimleri yansıttığı bilinmektedir (Penzel ve ark., 2000; Roche ve ark., 1999).

ECG tabanlı HRV analizlerinin uyku apnesi tanısında PSG'ye göre önemli avantajları vardır. Özellikle tek derivasyonlu ECG kayıtlarının kullanımı, ev ortamında uygulama imkânı sağlamak ve hastalar açısından daha konforlu bir test ortamı oluşturmaktadır (Chen ve ark., 2022). Ayrıca ECG, ekonomik ve taşınabilir cihazlarla kolaylıkla kaydedilebilmesi sayesinde geniş çaplı tarama ve erken tanıya olanak tanır (Setiawan & Lin, 2022).

Sonuç olarak, ECG tabanlı HRV analizi, uyku apnesinin tanısında etkili, hasta dostu ve ekonomik bir yöntem olarak ön plana çıkmaktadır. Ancak bu yöntemin klinik uygulamalarda daha yaygın kullanılabilmesi için daha geniş örneklem gruplarında ve farklı popülasyonlarda doğrulanmasına yönelik çalışmalar sürdürülmektedir (Bahrami & Forouzanfar, 2022; Abd-alrazaq ve ark., 2024).

3.2. Derin Öğrenme ve Makine Öğrenimi Yöntemleri

Makine öğrenimi ve derin öğrenme algoritmaları, son yıllarda tıbbi veri analizi alanında önemli ilerlemeler kaydetmiştir (Bazoukis ve ark., 2023). Geleneksel yöntemlerin aksine, derin öğrenme algoritmaları karmaşık tıbbi sinyallerden otomatik olarak anlamlı özellikler çıkarabilme kapasitesine sahiptir. Bu özellik sayesinde, sağlık alanında tanı ve teşhis süreçlerinde yapay zekâ uygulamalarının kullanımı hızla yaygınlaşmaktadır (Hannun ve ark., 2019).

Uyku apnesi tanısında da makine öğrenimi ve özellikle derin öğrenme yöntemlerinin kullanımı dikkat çekici sonuçlar ortaya koymuştur. Özellikle, elektrokardiyografi (ECG) verileri üzerinden yapılan analizlerde, derin öğrenme algoritmalarının klasik yöntemlerden üstün performans gösterdiği birçok çalışmada kanıtlanmıştır (Setiawan & Lin, 2022; Chen ve ark., 2022). Bu algoritmalar, geleneksel makine öğrenimi yöntemlerine kıyasla verideki karmaşık yapıları daha iyi yakalayabilmekte ve bu sayede tanı süreçlerinde doğruluk oranlarını önemli ölçüde artırmaktadır (Bahrami & Forouzanfar, 2022).

Setiawan ve Lin (2022), ECG sinyallerinin analizinde Empirical Mode Decomposition (EMD) yöntemini uygulayarak elde ettikleri sinyalleri derin konvolüsyonel sinir ağları (CNN) ile sınıflandırmış ve uyku apnesi tanısında oldukça yüksek doğruluk oranlarına ulaşmışlardır. Çalışmada segment seviyesinde sınıflandırma performansı 5-kat çapraz doğrulama ile %93,8 doğruluk, %94,9 hassasiyet ve %92,7 özgüllük oranları elde etmiştir. Hasta seviyesinde sınıflandırma

performansı ise %83,5 doğruluk, %75,9 hassasiyet ve %88,7 özgüllük oranlarına ulaşmıştır. Çalışmada, EMD'nin ECG sinyallerindeki gürültüyü azaltmada ve temel sinyal bileşenlerini ortaya çıkarmada etkili olduğu belirtilmiştir. Elde edilen sonuçlar, CNN modellerinin, işlenmiş ECG sinyallerini doğrudan analiz ederek otomatik özellik çıkarımı yoluyla apne olaylarını başarıyla sınıflandırabildiğini göstermektedir.

Benzer şekilde, Chen ve ark. (2022) tarafından gerçekleştirilen çalışmada, tek derivasyonlu ECG sinyallerinden uyku apnesi tanısı koymak için uzamsal-zamansal (spatiotemporal) derin öğrenme modeli geliştirilmiştir. Bu modelde, CNN ile çift yönlü Gated Recurrent Unit (Bi-GRU) gibi ileri seviye derin öğrenme mimarileri birleştirilmiştir. CNN katmanları, ECG sinyallerinin uzamsal özelliklerini çıkarırken, Bi-GRU katmanları ise sinyallerin zaman içindeki dinamik değişimlerini yakalamakta etkili olmuştur. Bu hibrit yaklaşım %88,3 F1 skoru elde ederek, standart CNN tabanlı modellerden daha iyi performans gösterdiği ve uyku apnesi tanısında yüksek doğruluk oranlarına ulaştığı vurgulanmaktadır.

Ayrıca, Paul ve ark. (2024) tarafından yapılan bir başka çalışmada ise, gerçek zamanlı olarak uyku apnesi tespiti amacıyla ham ECG ve oksimetre (SpO₂) verilerini kullanan bir feed-forward yapay sinir ağı modeli önerilmiştir. Bu çalışmada SpO₂ tabanlı model test setinde %94 doğruluk oranına ulaşırken, ECG tabanlı model %92 doğruluk göstermiştir. 10-kat çapraz doğrulama sonuçlarında SpO₂ tabanlı model %90,78 ± %10,12 doğruluk ile ECG tabanlı modelin %80,04 ± %7,7 doğruluğundan daha iyi performans sergilemiştir. Bu çalışma, derin öğrenme algoritmalarının sadece işlenmiş sinyaller üzerinde değil, ham veriler üzerinde de başarılı sonuçlar verebildiğini göstermiştir. Bu yöntemle kısa süreli veri segmentleri analiz edilerek apne olaylarının gerçek zamanlı olarak tespit edilmesi sağlanmış ve klinik kullanım için büyük bir potansiyel taşıdığı sonucuna varılmıştır.

Sonuç olarak, derin öğrenme ve makine öğrenimi yöntemlerinin ECG tabanlı uyku apnesi tanısında sağladığı avantajlar, bu tekniklerin klinik uygulamalarda daha fazla yer almasını teşvik etmektedir. Çalışmalarda elde edilen %90'ların üzerindeki doğruluk oranları ve yüksek hassasiyet değerleri, bu yaklaşımların geleneksel yöntemlere göre üstünlüğünü ortaya koymaktadır. Gelecekte, bu algoritmaların farklı popülasyonlar üzerinde ve geniş kapsamlı veri kümeleriyle doğrulanmasına yönelik çalışmaların artması beklenmektedir (Bahrami & Forouzanfar, 2022; Abd-alrazaq ve ark., 2024).

3.3. Poincaré, Welch ve RRI Histogramlarının Kullanımı ve Önemi

Elektrokardiyografi (ECG) sinyallerinin analizi, yalnızca sayısal yöntemlerle sınırlı kalmayıp görsel yöntemlerle de önemli bir yer tutmaktadır. Görsel analiz teknikleri, klinik karar desteği açısından anlaşılır ve yorumlanabilir sonuçlar sunarak klinisyenlere önemli faydalar sağlamaktadır (Qin ve ark., 2021). Bu yöntemler arasında özellikle Poincaré grafikleri, Welch periyodogramları ve RR interval histogramları, kalp atış hızındaki değişkenlikleri ve otonom sinir sistemi aktivitelerini değerlendirmede sıkça tercih edilmektedir.

Poincaré grafikleri, ardışık RR intervallerinin (kalp atışları arasındaki zaman aralıkları) birbirlerine göre dağılımını geometrik olarak ifade eden iki boyutlu görsellerdir (Mermigkis ve ark., 2009). Bu grafiklerdeki noktaların dağılım biçimi, kalp ritmindeki kısa vadeli ve uzun vadeli varyasyonları göstermekte kullanılır. Bu grafiklerde, dağılımın genişliği ve şekli, uyku apnesi gibi hastalık durumlarında belirgin değişiklikler gösterir. Örneğin, uyku apnesi hastalarında, noktaların dağılımında dağınıklık artışı görülür ve grafiklerin şekilleri belirgin biçimde farklılaşır (Mermigkis ve ark., 2009; Chen ve ark., 2022). Yapılan çalışmalar, uyku apnesi hastalarının tedaviden sonra bu grafiklerde daha düzenli ve simetrik dağılım gösterdiklerini ortaya koymuştur (Mermigkis ve ark., 2009).

Welch periyodogramları, ECG sinyallerinden türetilen kalp hızı değişkenliğinin (HRV) frekans analizi için yaygın olarak kullanılan yöntemlerden biridir (Martín-Montero ve ark., 2020). Welch yöntemi, sinyallerin farklı frekans bileşenlerini ortaya çıkarır ve HRV spektrumunu net bir şekilde sunarak, sempatik ve parasempatik sinir sistemlerinin aktivitelerindeki değişimleri incelemeyi mümkün kılar (Roche ve ark., 1999; Penzel ve ark., 2000). Uyku apnesi sırasında özellikle düşük frekans (LF) ve yüksek frekans (HF) bileşenlerinde belirgin değişimler gözlenmiştir. Apne olayları sırasında LF bileşeninde artış ve HF bileşeninde azalma, sempatik aktivitenin arttığı ve parasempatik aktivitenin azaldığı şeklinde yorumlanmaktadır (Martín-Montero ve ark., 2020; Bahrami & Forouzanfar, 2022).

RR interval histogramları ise RR intervallerinin dağılımlarını istatistiksel olarak görselleştiren başka bir yöntemdir. Bu histogramlar, kalp atışlarının genel dağılımını ve bu dağılımdaki sapmaları belirlemek için kullanılır (Rahman ve ark., 2019). Uyku apnesi hastalarında, histogramların genel dağılımında belirgin kaymalar ve genişlemeler görülebilmektedir. Bu durum, kalp ritminin apne olayları sırasında

tutarsız hale geldiğini göstermektedir. Histogramlardaki bu deęişimler, apne olaylarının sıklığını ve şiddetini belirlemede yardımcı olabilir (Qin ve ark., 2021; Chen ve ark., 2022).

Bu üç görsel analiz yöntemi, tek başlarına veya birlikte kullanılarak uyku apnesi tanısında güçlü bir araç seti oluşturabilir. Bu yöntemlerin görsel olması, klinik yorumlama açısından kolaylık sağlayarak tanı süreçlerini hızlandırabilir ve daha güvenilir hale getirebilir (Setiawan & Lin, 2022). Ancak, görsel yöntemlerin tanı için bağımsız olarak kullanılması yerine, genellikle sayısal analizlerle desteklenmesi gerektięi kabul edilmektedir. Gelecekteki çalışmaların, bu yöntemlerin klinik etkinliğini artırmak amacıyla derin öğrenme algoritmaları ile birleştirilmesini önerilmektedir (Bahrami & Forouzanfar, 2022; Abd-alrazaq ve ark., 2024).

3.4. CNN Tabanlı Modellerin Uyku Apnesi Teşhisindeki Başarımı

Konvolüsyonel Sinir Ağları (CNN'ler), tıbbi görüntüleme ve sinyal işleme alanlarında son yıllarda büyük bir gelişme göstermiştir (Bazoukis ve ark., 2023). Özellikle karmaşık desenlerin tanınması, sınıflandırılması ve otomatik özellik çıkarımı konularında CNN'ler üstün performans sağlamaktadır (Hannun ve ark., 2019). Bu avantajlar sayesinde CNN tabanlı modeller, uyku apnesi gibi teşhisi karmaşık olan tıbbi durumların tanısında giderek artan bir popülerlik kazanmıştır (Setiawan & Lin, 2022).

Hannun ve ark. (2019), tek derivasyonlu ECG kayıtlarından aritmi sınıflandırması yapmak üzere geliştirdikleri derin CNN modeli ile tıbbi tanı süreçlerinde önemli bir dönüm noktası yaratmışlardır. Bu çalışma, CNN modelinin kardiyolog seviyesinde doğrulukla aritmi türlerini ayırt edebildiğini kanıtlamıştır. Çalışmanın sonuçları, CNN algoritmalarının klinik uygulamalarda uzman seviyesinde karar destek sistemleri geliştirilmesinde güvenilir araçlar olarak kullanılabileceğini göstermiştir (Hannun ve ark., 2019).

Uyku apnesi teşhisinde CNN modellerinin etkinliği, son dönemde yapılan çeşitli çalışmalarda da vurgulanmıştır. Örneğin, Chang ve ark. (2020) tek derivasyonlu ECG sinyalleri kullanarak geliştirdikleri 1-boyutlu CNN modeliyle uyku apnesini yüksek hassasiyet ve özgüllük oranlarıyla sınıflandırmışlardır. Modelin özellikle otomatik olarak ECG sinyallerindeki ayrıştırıcı özellikleri öğrenerek manuel özellik çıkarımı ihtiyacını ortadan kaldırması, bu tür yöntemlerin klinik uygulama potansiyelini

güçlendirmektedir.

Benzer şekilde Setiawan ve Lin (2022), ECG verilerinden elde edilen Empirical Mode Decomposition (EMD) tabanlı sinyaller üzerinde uyguladıkları CNN mimarisi ile uyku apnesi vakalarını başarıyla sınıflandırmışlardır. Bu çalışmada CNN, hem kısa hem de uzun dönemli sinyal özelliklerini otomatik olarak çıkararak tanı performansını önemli ölçüde artırmıştır. Chen ve ark. (2022) tarafından sunulan çalışmada ise, CNN katmanları ile çift yönlü GRU modellerinin (Bi-GRU) birleşimi kullanılarak, ECG sinyallerinin hem zamansal hem de uzamsal özellikleri başarılı şekilde yakalanmıştır. Bu yaklaşım, uyku apnesi teşhisinde tek başına CNN kullanımının ötesinde hibrit modellerin potansiyelini göstermektedir.

CNN tabanlı modellerin klinik uygulamalar açısından önemli bir avantajı da, minimal ön işleme ihtiyaç duymasıdır (Paul ve ark., 2024). Bu modeller, geleneksel yöntemlere kıyasla daha hızlı ve gerçek zamanlı analizlere olanak sağlar. Paul ve ark. (2024), ham ECG ve oksimetre verilerini kullanan gerçek zamanlı CNN modelleriyle apne olaylarını hızlı ve doğru biçimde tespit edebilen sistemlerin geliştirilebileceğini ortaya koymuştur. Böylece, hastaların ev ortamında veya mobil cihazlarla izlenmesi mümkün hale gelmektedir.

Sonuç olarak, CNN tabanlı derin öğrenme modelleri, uyku apnesi teşhisinde önemli potansiyeller sunmaktadır. Ancak mevcut çalışmaların çoğu sınırlı veri setleriyle doğrulanmış olduğundan, bu modellerin daha geniş çaplı klinik uygulamalarda kullanımı için daha geniş popülasyonlarda ve farklı senaryolarda ek doğrulama çalışmaları gereklidir (Aiyer ve ark., 2022; Abd-alrazaq ve ark., 2024). Ayrıca, derin öğrenme modellerinin açıklanabilirliğinin artırılması da klinik kabul ve kullanım açısından kritik öneme sahiptir (Bazoukis ve ark., 2023).

3.5. Literatürdeki Eksiklikler ve Gelecek Araştırmalar için Öneriler

Uyku apnesinin teşhisi üzerine yapılan mevcut çalışmalar önemli gelişmeler göstermiş olsa da, literatürde hâlâ giderilmesi gereken çeşitli eksiklikler ve sınırlılıklar bulunmaktadır. Özellikle, şimdiye kadar geliştirilen pek çok yapay zekâ ve derin öğrenme modeli, sınırlı ve spesifik veri kümeleri üzerinde test edilmiştir. Bu durum, modellerin geniş çaplı ve gerçek dünya uygulamaları için yeterli genelleştirilebilirliğe sahip olup olmadığını sorgulamamıza yol açmaktadır.

Literatürdeki bir diğer önemli sınırlama ise giyilebilir cihazlardan elde edilen

ECG verileriyle yapılan çalışmaların sınırlı sayıdaki denek üzerinde veya kontrollü laboratuvar ortamlarında gerçekleştirilmesidir. Abd-alrazaq ve ark. (2024), giyilebilir cihazlarla yapılan ECG temelli uyku apnesi çalışmalarında performansın henüz tutarlı olmadığını ve gerçek hayat senaryolarında geniş çaplı doğrulama çalışmalarına ihtiyaç duyulduğunu vurgulamaktadır.

Bu çalışmada, literatürdeki sınırlılıkları ele almak amacıyla Welch periodogramları kullanarak uyku apnesi tespiti için yenilikçi bir yaklaşım geliştirilmiştir. Welch periodogramı tabanlı özellik çıkarımının uyku apnesi teşhisinde kullanılması, literatürde daha önce denenmemiş özgün bir metodolojik yaklaşımdır. Bu yöntem, ECG sinyallerinden frekans domeni bilgilerinin daha etkin bir şekilde çıkarılmasını sağlayarak, geleneksel zaman domeni analiz yöntemlerinin eksikliklerini gidermeyi hedeflemektedir.

Gelecekteki çalışmalarda, mevcut Welch periodogramı tabanlı yaklaşımın yanı sıra Poincaré/Lorenz grafikleri, histogramlar ve takogramlar gibi ek görselleştirme ve analiz tekniklerinin entegrasyonu ile daha kapsamlı bir özellik çıkarım sistemi geliştirilebilir. Bu çok boyutlu analiz yaklaşımı, ECG sinyallerinden elde edilebilecek bilgi zenginliğini artırarak uyku apnesi teşhisinin doğruluğunu ve güvenilirliğini daha da iyileştirebilir.

4. MATERYAL METOT

4.1. Veri Seti

Bu çalışmada kullanılan veri seti, elektrokardiyogram (EKG) sinyallerinden elde edilen Welch güç spektral yoğunluk (PSD) diyagramlarından oluşmaktadır. Veri seti, araştırmamız kapsamında ölçümleri yapılan bireylerden elde edilmiştir. Çalışmaya dahil edilen bireyler, hasta ve kontrol (sağlıklı) olmak üzere iki gruba ayrılmıştır. Kalp rahatsızlıkları veya herhangi bir kalp-damar hastalığı ile merkezi sinir sistemi bozuklukları yaşayan bireyler, çalışmanın dışında tutulmuştur. Bu durum, veri setinin kısıtlamalarından biri olarak değerlendirilmelidir.

Veri toplama aşamasında 273 hasta bireyden ve 279 kontrol grubuna ait bireyden EKG ölçümleri yapılmıştır. Elde edilen sinyaller Welch metodu kullanılarak frekans düzlemine taşınmış ve her birey için güç spektral yoğunluk diyagramları oluşturulmuştur.

Welch diyagramları oluşturulurken ilk olarak, RR interval verilerindeki DC bileşeni (ortalama değer) çıkarılarak veriler sıfır merkezli hale getirilmiştir. Bu işlem, sinyallerin ortalaması alınarak ve bu ortalamanın her bir veri noktasından çıkarılmasıyla gerçekleştirilmiştir. Böylece, frekans analizinde DC bileşeninin neden olabileceği yanlılık (bias) önlenmiştir.

Daha sonra, frekans analizi için Welch yöntemi kullanılmıştır. Bu yöntemde SciPy kütüphanesinin `signal.welch` fonksiyonu tercih edilmiştir. Welch metodunda, zaman alanındaki sinyal belirli uzunluktaki segmentlere bölünerek, her segment üzerinde Fourier dönüşümü uygulanmış ve elde edilen güç spektral yoğunlukları ortalamaları alınarak birleştirilmiştir. Bu işlem, sinyaldeki gürültüyü azaltmak ve daha güvenilir bir PSD tahmini elde etmek için önemlidir.

Analiz sonucunda, güç spektral yoğunluğu (PSD) frekansa karşılık gelen güç değerlerini içeren grafikler oluşturulmuştur. Bu grafiklerde frekans ekseninde, ultra düşük frekans (UULF: 0-0.003 Hz), çok düşük frekans (ULF: 0.003-0.04 Hz), düşük frekans (LF: 0.04-0.15 Hz) ve yüksek frekans (HF: 0.15-0.4 Hz) olmak üzere dört temel bant tanımlanmıştır. Her frekans bandı içindeki güç yoğunluğu, numerik entegrasyon yöntemlerinden biri olan trapezoidal (trapez) integrasyonu ile hesaplanmıştır.

PSD diyagramlarının oluşturulmasında, güç değerleri (s^2/Hz cinsinden) frekansa bağlı olarak çizdirilmiştir. Grafiklerde farklı frekans bantları renkli bölgeler olarak gösterilerek, frekans bantlarının güç dağılımı kolaylıkla görselleştirilmiştir.

Elde edilen PSD diyagramları, daha sonra grafik görsel formatına dönüştürülerek derin öğrenme modellerinde kullanılmaya hazır hale getirilmiştir. Bu matrislerin satırları frekans bantlarını, sütunları ise ilgili zaman segmentlerini temsil edecek biçimde yapılandırılmıştır. Bu yapılandırma, oluşturulan veri setinin analiz, sınıflandırma ve tanı amacıyla kullanılabilmesi için uygundur.

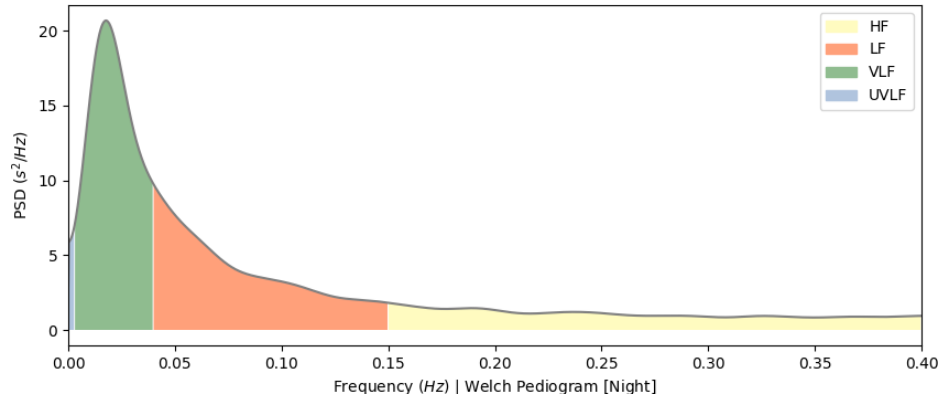
Oluşturulan Welch diyagramları, eğitim (train) ve test setleri olarak ikiye ayrılmıştır. Eğitim setinde 273 hasta ve 279 kontrol olmak üzere toplam 552 Welch diyagramı bulunmaktadır. Test seti ise her gruptan 26'şar olmak üzere toplam 52 Welch diyagramından oluşmaktadır.

Her bir Welch diyagramı, frekansa karşı güç spektral yoğunluğunu (PSD) gösteren grafiklerdir. Bu diyagramlar, frekans (Hz) değerlerine karşılık gelen güç yoğunluklarını (s^2/Hz cinsinden) göstermektedir. Görsel olarak incelendiğinde,

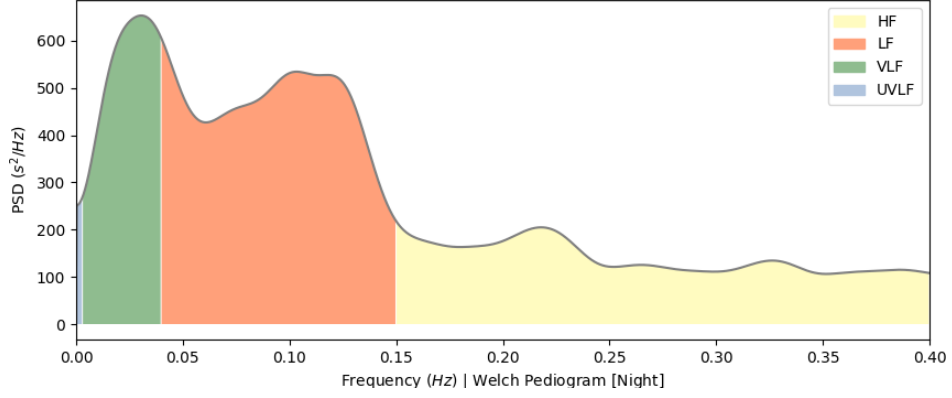
diyagramlar ultra düşük frekans (UVLF), çok düşük frekans (VLF), düşük frekans (LF) ve yüksek frekans (HF) gibi farklı frekans bantlarını içeren eğriler şeklindedir. Bu diyagramlar, analiz ve model eğitimi için grafik görsel formatında saklanmış ve görsellerde dikey eksen PSD (s^2/Hz) değerini, yatay eksen ise frekansı (Hz) temsil edecek şekilde yapılandırılmıştır. Bu yapılandırma, verilerin derin öğrenme yöntemlerine uygun şekilde kullanılmasını sağlamaktadır.

Welch güç spektral yoğunluğu analizinde uyku apnesi varlığının belirgin farklılıklar yarattığı görülmektedir. Şekil 4.1'de gösterildiği üzere, uyku apnesine sahip olmayan bireylerde VLF bandında yoğunlaşan düzenli bir güç dağılımı gözlemlenmekte ve frekans artışıyla birlikte PSD değerleri düzgün bir şekilde azalmaktadır. Buna karşılık, Şekil 4.2'de uyku apnesine sahip bireylerde daha karmaşık bir spektral profil ortaya çıkmaktadır. Bu durumda VLF bandındaki aktiviteye ek olarak LF bandında da sürekli ve belirgin güç yoğunluğu bulunmakta, yüksek frekans bölgelerinde ise dalgalanmalar ve ikincil tepe noktaları gözlemlenmektedir. Bu spektral farklılıklar, uyku apnesinin otonom sinir sistemi üzerindeki etkilerini yansıtmakta ve tanısal değerlendirmede objektif bir gösterge olarak kullanılabilir.

Bu veri seti, EKG tabanlı sınıflandırma ve tanı sistemlerinin performansını değerlendirmek ve oluşturulan modellerin etkinliğini test etmek amacıyla oluşturulmuştur. Tez kapsamında gerçekleştirilen analizlerin doğruluk ve güvenilirliğini desteklemek amacıyla kullanılmaktadır.



Görsel 4.1. Uyku apnesine sahip olmayan birinin Welch güç spektral yoğunluk (PSD) diyagramı



Görsel 4.2. Uyku apnesine sahip olan birinin Welch güç spektral yoğunluk (PSD) diyagramı

4.2. Kullanılan Yöntemler

Bu bölümde, EKG sinyallerinden elde edilen Welch güç spektral yoğunluk diyagramlarının sınıflandırılması için kullanılan derin öğrenme modelleri ve metodolojisi detaylı olarak açıklanmaktadır.

4.2.1. Derin Öğrenme Yaklaşımı

Çalışmamızda, hasta ve kontrol gruplarını ayırt etmek amacıyla çeşitli modern derin öğrenme mimarileri kullanılmıştır. Bu modeller, tıbbi görüntü işleme ve biyomedikal sinyal sınıflandırma alanlarında gösterdikleri üstün performans nedeniyle tercih edilmiştir. Welch diyagramlarının görüntüleri, bu modellerin etkin şekilde kullanılmasına olanak sağlamaktadır.

Modeller, PyTorch derin öğrenme çerçevesi kullanılarak uygulanmış ve eğitilmiştir. Hesaplama verimliliği için CUDA destekli GPU hızlandırıcıları kullanılmıştır.

4.2.2. Kullanılan Derin Öğrenme Mimarileri

Araştırmamızda altı farklı modern derin öğrenme mimarisi kullanılmış ve karşılaştırılmıştır:

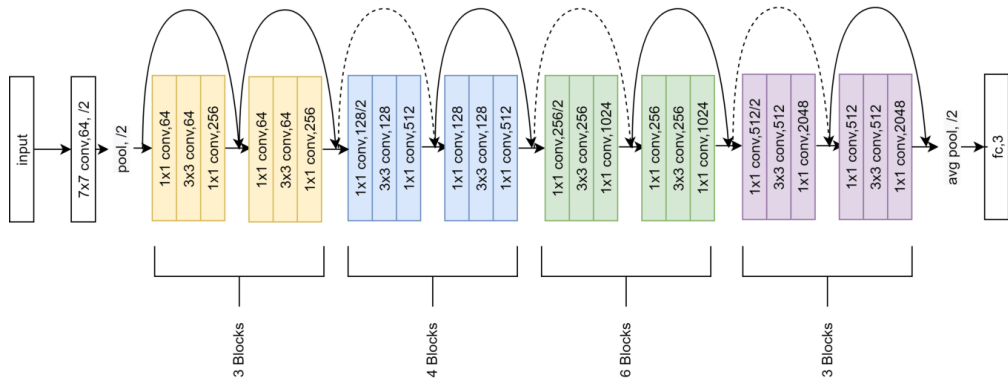
4.2.2.1. ResNet (Residual Networks)

ResNet (Residual Networks), derin sinir ağlarında eğitim sırasında ortaya çıkan gradyan kaybı problemini çözmek için "artık bağlantılar" (residual connections) kullanan bir mimarıdır. Çalışmamızda iki farklı ResNet versiyonu kullanılmıştır:

ResNet18: 18 katmanlı bu model, artık bağlantılar sayesinde gradyan akışını korurken daha az parametre ile çalışabilmektedir. ResNet18'de, temel bloklar iki evrişim katmanından oluşur ve her artık blok, kimlik bağlantıları (identity connections) ile giriş verilerinin doğrudan daha ilerideki katmanlara aktarılmasını sağlar.

ResNet50: 50 katmanlı bu daha derin model, "bottleneck" blokları kullanarak parametreleri daha verimli şekilde değerlendirir. Her bottleneck bloğu, 1x1 evrişim katmanı ile boyut azaltma, 3x3 evrişim ile özellik çıkarma ve tekrar 1x1 evrişim ile boyut artırma stratejisini uygular. Bu yapı, hesaplama verimliliğini artırırken daha karmaşık özellikleri öğrenebilmeyi sağlar.

ResNet mimarilerinin temel avantajı, çok derin ağlarda bile gradyan akışını koruyabilmesi ve bu sayede daha karmaşık görsel özellikleri öğrenebilmesidir.



Görsel 4.3. ResNet50 Mimarisi (Al-Humaidan & Prince, 2021, Fig. 3, p. 50758)

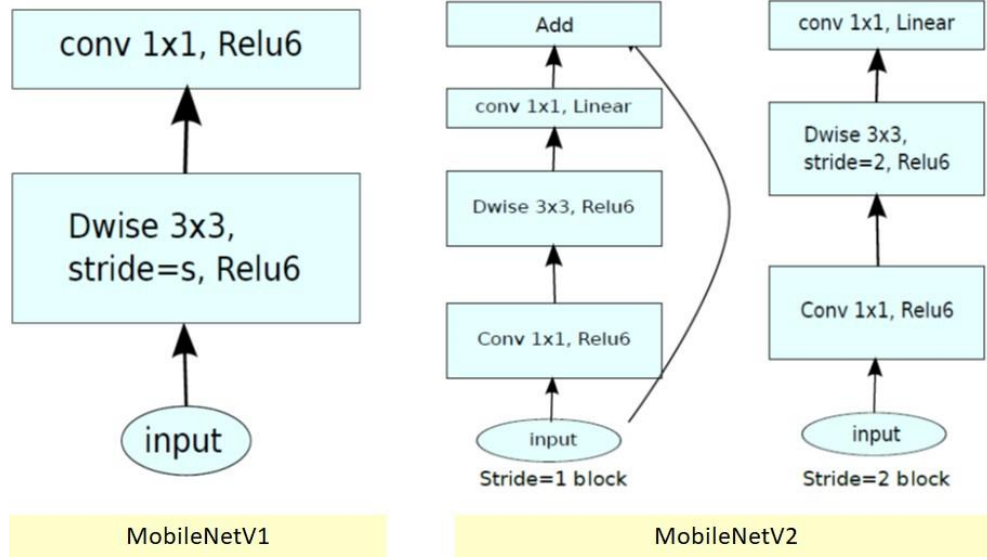
4.2.2.2. MobileNetV2

MobileNetV2, özellikle sınırlı kaynaklara sahip sistemlerde ve gömülü platformlarda yüksek performanslı çalışmak üzere tasarlanmış hafif ve verimli bir CNN (Evrışimli Sinir Ağı) mimarisidir. Bu model, geleneksel evrışimli ağların hesaplama maliyetlerini azaltmak ve hızlarını artırmak amacıyla geliştirilmiştir. MobileNetV2'nin temelinde üç önemli bileşen yer almaktadır: İlki, derinlemesine ayrılabilir evrışim katmanlarıdır (depthwise separable convolutions). Bu katmanlar, standart evrışim işlemlerini derinlemesine evrışim (depthwise convolution) ve nokta evrışimi (pointwise convolution) olarak iki aşamalı hale getirerek, daha az parametre ve işlem gerektirir. Böylelikle hem bellek hem de işlem gücü açısından ciddi bir verimlilik sağlanır.

İkinci olarak, MobileNetV2, mimarideki standart evrışim işlemlerini optimize etmek amacıyla doğrusal darboğazlar (linear bottlenecks) yaklaşımını kullanmaktadır. Bu yöntem sayesinde düşük boyutlu uzayda gerçekleştirilen işlemlerde doğrusal olmayan ReLU aktivasyonu seçici biçimde kullanılır, böylece özellikle düşük boyutlu temsillerde bilgi kaybının önüne geçilir ve modelin ifade kapasitesi artırılır.

Üçüncü temel özellik olarak ters artık blokları (inverted residual blocks) öne çıkmaktadır. Bu bloklar, standart artık bloklardan farklı olarak düşük boyutlu uzaylarda aktivasyon fonksiyonlarını seçici kullanarak modelin daha derin katmanlarda da etkin biçimde öğrenmesini ve bilgi akışının korunmasını mümkün kılar. Bu yapı, ağın parametre sayısını azaltırken öğrenme kapasitesini artırır ve modelin hem performans hem de hız açısından optimize edilmesine yardımcı olur.

MobileNetV2, yüksek doğruluk performansını korurken daha düşük hesaplama maliyetleri ile hızlı çıkarım yapabilmesi sayesinde, kaynakları sınırlı gömülü cihazlar ve gerçek zamanlı sistemler için ideal bir seçimdir. Bu avantajlarıyla, Welch diyagramlarının sınıflandırılması gibi uygulamalarda sınırlı donanıma sahip ortamlarda dahi yüksek performanslı analizler yapabilmektedir.



Görsel 4.4. MobileNetV1 ve MobileNetV2 Mimarisi (Chadha ve ark., 2023)

4.2.2.3. DenseNet121

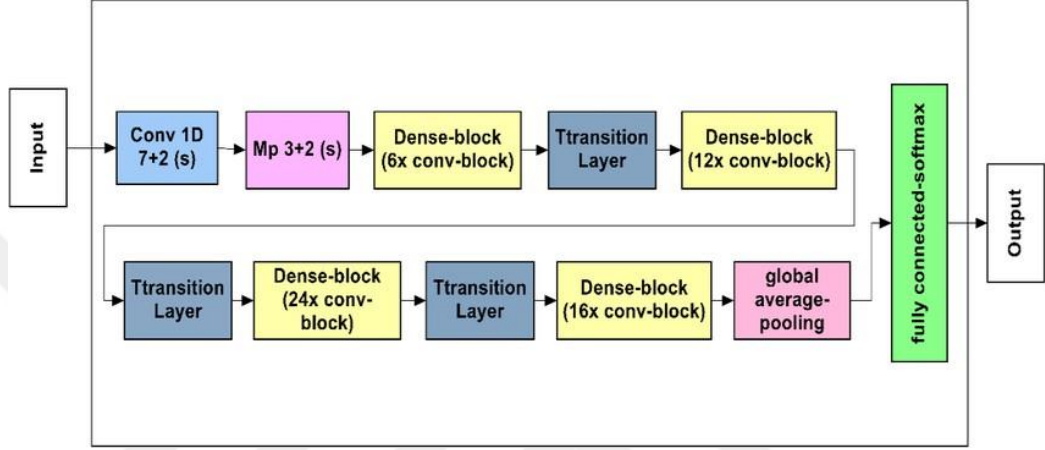
DenseNet olarak da bilinen DenseNet-121 (DenseNet mimarilerinden biri), ağdaki her katmanın, kendisinden önceki tüm katmanlardan gelen çıktılarla doğrudan bağlantı kurduğu yoğun bağlantılara (dense connections) dayanan özel bir evrişimli sinir ağı mimarisidir. Bu mimari, katmanlar arasında yüksek seviyede bağlantısallık sağlayarak özelliklerin çok katmanlı tekrar kullanımını teşvik eder. Böylece ağ içinde bilgi akışı güçlenir ve daha derin temsillerin öğrenilmesi mümkün hale gelir. Bu temel prensip sayesinde model, daha az parametre ve daha düşük hesaplama maliyetiyle yüksek doğruluk değerlerine ulaşabilir.

DenseNet121 modelinin yoğun bağlantılarının yanında, geçiş katmanları (transition layers) olarak adlandırılan özel katmanlar da mimarinin önemli bileşenleri arasında yer alır. Bu geçiş katmanları, ağın farklı yoğun blokları arasında etkin şekilde boyut azaltımı yaparak özellik haritalarının boyutlarını kontrol altında tutar. Bu sayede ağ içerisindeki hesaplama yükü dengelenir ve eğitim süreci optimize edilir.

DenseNet mimarisinin bir diğer önemli bileşeni olan doğrusal darboğaz yapısı (linear bottlenecks), özellik haritalarının düşük boyutlu uzayda sıkıştırılmış şekilde taşınmasını sağlayarak modelin hesaplama ve bellek verimliliğini daha da artırır. Böylece daha düşük bellek kullanımına rağmen daha derin ağlar eğitilebilir hale gelir.

Özellikle medikal görüntüleme alanında DenseNet-121, ince ve karmaşık

detayları yakalayabilme yeteneği sayesinde öne çıkar. Bu özelliği sayesinde EKG gibi medikal verilerin analizinde başarılı sonuçlar verir ve Welch diyagramlarının sınıflandırılması gibi hassas uygulamalarda yüksek performanslı sonuçlar elde edilmesini sağlamaktadır. DenseNet-121 mimarisi, sağladığı verimlilik, yüksek doğruluk ve düşük hesaplama maliyeti avantajlarıyla, medikal görüntüleme uygulamaları başta olmak üzere geniş bir kullanım alanına sahiptir.



Görsel 4.5. DenseNet121 Mimarisi (Tareq ve ark., 2022, Fig. 1)


4.2.2.4. EfficientNet

EfficientNet, ağın derinliği, genişliği ve çözünürlüğü arasında optimal bir denge sağlayan "bileşik ölçeklendirme" (compound scaling) yöntemi kullanan bir mimaridir. Çalışmamızda iki farklı EfficientNet versiyonu kullanılmıştır:

EfficientNet-B0: Temel EfficientNet modeli olup, MBConv (Mobile Inverted Bottleneck Convolution) bloklarını kullanır. Kanal-bazlı dikkat mekanizması (Squeeze-and-Excitation) uygulayarak önemli özelliklere odaklanmayı sağlar.

EfficientNetV2-S: EfficientNet'in geliştirilmiş bir versiyonu olan EfficientNetV2'nin "Small" varyantıdır. Fused-MBConv blokları, daha etkili aktivasyon fonksiyonları ve aşamalı eğitim (progressive learning) yaklaşımı ile daha hızlı eğitim süresi ve daha iyi parametre verimliliği sağlar.

EfficientNet mimarileri, ağırlık ve hesaplama verimliliği açısından optimize edilmiş olup, farklı ölçeklerdeki görsel özellikleri yakalamada etkindir.



Görsel 4.6. EfficientNetV2 Mimarisi (Huang & Liao, 2023, Fig. 4)

4.2.3. Veri Ön İşleme ve Artırma

Bu çalışmada derin öğrenme modellerinin sunulmasından önce Welch diyagramları bir dizi ön işleme adımından geçirilmiştir. Bu süreçte ilk olarak tüm görüntüler, kullanılan modellerin gereksinim duyduğu standart giriş boyutu olan 224x224 piksele yeniden boyutlandırılmıştır. Böylece, giriş verilerinin boyutsal tutarlılığı sağlanarak model eğitim sürecindeki performans artışı hedeflenmiştir. Ardından, görüntülerin piksel değerleri, daha önceden eğitilmiş modellerle uyumluluk ve daha etkili yakınsama sağlamak amacıyla ImageNet veri setinin standart değerlerine göre normalize edilmiştir.

Bu kapsamda, her görüntünün renk kanallarına ait piksel değerleri, ImageNet veri setine ait ortalama ([0.485, 0.456, 0.406]) ve standart sapma ([0.229, 0.224, 0.225]) değerleri temel alınarak düzenlenmiştir. Son aşamada ise görüntüler, PyTorch'un gerektirdiği tensör formatına dönüştürülmüş ve GPU tabanlı hesaplama süreçleri için hazır hale getirilmiştir.

4.2.4. Model Eğitim Süreci

4.2.4.1. Eğitim Stratejisi

Modellerin optimizasyonu için kapsamlı ve sistematik bir eğitim stratejisi uygulanmıştır. İlk olarak, modellerin eğitim performansını artırmak amacıyla çok sınıflı sınıflandırma görevlerinde sıklıkla tercih edilen Çapraz Entropi (Cross Entropy Loss) kayıp fonksiyonu seçilmiştir. Optimizasyon algoritması olarak, verimli ve hızlı yakınsama sağlaması nedeniyle Adam algoritması tercih edilmiş, başlangıç öğrenme

oranı ise 0.001 olarak ayarlanmıştır. Eğitim süreci boyunca öğrenme oranının etkin şekilde kontrol edilmesi ve daha iyi sonuçlar elde edilmesi adına, ReduceLRonPlateau zamanlayıcısı devreye alınmıştır. Bu yöntem doğrulama kaybında iyileşme olmadığını algıladığında, öğrenme oranını 2 iterasyonluk sabır süresi ile bekleyerek mevcut değerinin yarısına (0.5 faktörü ile) düşürmüştür. Ayrıca, donanımın bellek kapasitesi ve eğitim hızına yönelik performans dengeleri göz önünde bulundurularak yığın boyutu değeri 32 olarak belirlenmiştir. Eğitim süreci her model için maksimum 100 iterasyon olacak şekilde planlanmış, böylece hem eğitim süresinin verimli kullanımı hem de modellerin aşırı öğrenmeye maruz kalmadan eğitilmesi hedeflenmiştir. Son olarak, modellerin genelleme yeteneğini korumak ve eğitim süreçlerinde gereksiz kaynak tüketimini engellemek amacıyla, doğrulama doğruluğunda ardışık olarak 5 iterasyon boyunca iyileşme gözlemlenmediğinde erken durdurma tekniği uygulanmış ve eğitim sonlandırılmıştır. Böylece, modellerin optimum performansa en kısa sürede ve kaynakların verimli kullanımıyla ulaşması sağlanmıştır.

4.2.5. Kullanılan Derin Öğrenme Mimarileri

Modellerin performans değerlendirmesi, doğrulama seti üzerindeki başarı oranlarına göre gerçekleştirilmiştir. Bu kapsamda temel değerlendirme metrikleri olarak doğruluk (accuracy) ve kayıp (loss) değerleri kullanılmıştır. Doğruluk, modellerin doğru sınıflandırdığı örneklerin, toplam örnek sayısına oranı olarak hesaplanmıştır. Kayıp ise eğitim sırasında kullanılan çapraz entropi (cross entropy) fonksiyonundan elde edilen değerlerle ölçülmüştür.

Eğitim süreci boyunca, her bir model için eğitim ve doğrulama setlerine ait doğruluk ve kayıp değerleri detaylı biçimde kaydedilmiştir. Ayrıca, modellerin ulaştığı en yüksek doğrulama doğruluğu, bu en iyi performansa ulaşılan iterasyon numarası, toplam eğitim süresi ve erken durdurma durumları da eğitim kayıtlarına dahil edilmiştir. Bu bilgiler sayesinde modellerin performansları kapsamlı ve şeffaf bir şekilde analiz edilmiştir.

Elde edilen sonuçların daha net biçimde incelenmesi ve modeller arası karşılaştırmaların kolaylaştırılması amacıyla çeşitli grafikler hazırlanmıştır. Bu grafiklerde her model için eğitim ve doğrulama kayıplarının değişimi ile doğruluk eğrileri ayrıntılı olarak gösterilmiştir. Ek olarak, modellerin ulaştığı en yüksek

doğrulama doğrulukları karşılaştırmalı olarak tek bir grafik üzerinde sunulmuş ve eğitim sürelerinin karşılaştırıldığı ayrı bir grafikte de modellerin eğitime harcadıkları zaman kıyaslanmıştır. Böylece, model performansları görsel olarak daha anlaşılır hale getirilerek değerlendirme süreci desteklenmiştir.

4.2.6. Model Kaydetme ve Dokümantasyon

Eğitilen her model için detaylı bilgilerin kaydedilmesi ve daha sonraki süreçlerde yeniden kullanılabilmesi amacıyla kapsamlı kayıtlar oluşturulmuştur. İleride modelin hızlı biçimde yeniden oluşturulabilmesi ve sonuçların kolaylıkla tekrarlanabilmesi için model mimarisinin ismi ve sınıflandırma görevinde kullanılan sınıf isimleri ile bunların indeks eşleşmeleri de kayıtlara eklenmiştir. Modellerin eğitim sırasında elde ettiği en iyi doğrulama doğruluğu ve bu noktadaki doğrulama kayıp değerleriyle birlikte, eğitimin tamamlandığı iterasyon numarası gibi önemli bilgiler de titizlikle not edilmiştir.

Bu bilgilerin yanı sıra, eğitilen her model için farklı dosya türlerinde çıktılar oluşturulmuştur. Bunlardan ilki, model parametrelerini içeren ve doğrudan yeniden kullanılabilir olan .pt formatındaki PyTorch dosyalarıdır. Böylelikle modellerin daha sonra başka sistemlerde tekrar yüklenerek kullanılması mümkün kılınmıştır. Ayrıca eğitim süreci boyunca elde edilen metriklerin analiz edilmesini kolaylaştırmak amacıyla her model için eğitim ve doğrulama kaybı ile doğruluk grafiklerini içeren görsel dosyalar hazırlanmıştır. Ek olarak, eğitim metriklerinin detaylı analiz ve arşivlenmesi amacıyla bu veriler JSON formatında ayrı bir dosya olarak kaydedilmiştir.

Son olarak, tüm eğitilen modellerin performansının genel bir değerlendirmesini sunmak amacıyla karşılaştırmalı bir özet dosyası oluşturulmuştur. Bu özet dosyada, modellerin ulaştığı en iyi doğrulama doğrulukları ve toplam eğitim süreleri yan yana sunulmuş, hangi modelin daha etkin ve verimli performans sergilediğinin kolayca anlaşılabilmesi sağlanmıştır. Böylece, eğitilen modellerin karşılaştırmalı analizi için kullanıcı dostu ve net bir kaynak elde edilmiştir.

4.2.7. Model Eğitimi ve Hesaplama Optimizasyonu

Kodda belirtildiği üzere, modellerin eğitim sürecinde yüksek performans ve hesaplama verimliliği sağlamak amacıyla CUDA destekli GPU kullanılmıştır. Bu bağlamda, donanım kaynaklarının optimum düzeyde değerlendirilmesi ve hesaplamaların mümkün olan en kısa sürede tamamlanması için bir dizi optimizasyon yapılmıştır.

Veri yükleme işlemlerinde performansı artırmak amacıyla, veri ön işleme ve yükleme süreçleri çoklu işçi (multiple workers) yaklaşımı ile paralelleştirilmiş ve num_workers parametresi 4 olarak belirlenmiştir. Bu sayede veri setindeki görüntülerin GPU'ya aktarımındaki gecikmeler en aza indirilmiş, hesaplama performansı artırılmıştır. Ayrıca, modellerin eğitim sırasında daha düşük bellek kullanımı ve daha hızlı yakınsama sağlaması amacıyla batch normalizasyon katmanları kullanılmıştır.

Eğitim süresinin kontrol altında tutulması ve modellerin aşırı öğrenme riskinden kaçınılması için erken durdurma stratejisi benimsenmiştir. Böylece, doğrulama seti üzerinde performansta ardışık olarak 5 iterasyon boyunca iyileşme gözlemlenmediğinde eğitim süreci otomatik olarak durdurularak gereksiz kaynak tüketimi engellenmiştir.

Bu optimizasyonlar ve stratejilerin uygulanması sonucunda, altı farklı derin öğrenme modeli eğitilmiş ve modellerin karşılaştırmalı değerlendirilmesi için bir altyapı geliştirilmiştir. Eğitim sürecinde belirlenen parametreler ve yöntemler kullanılarak, modellerin performanslarının sistematik bir şekilde analiz edilebilmesi amaçlanmıştır.

4.2.8. Model Kaydetme ve Dokümantasyon

Tezde kullanılan altı model (ResNet18, ResNet50, MobileNetV2, DenseNet121, EfficientNet-B0 ve EfficientNetV2-S) detaylı olarak incelenmiştir. Bu modeller, çeşitli mimariler arasında kapsamlı bir karşılaştırma sağlamak için seçilmiştir.

Her model mimarisi, farklı avantajlar sunmakta ve Welch diyagramlarındaki farklı spektral özelliklere duyarlılık göstermektedir. Modellerin karşılaştırmalı analizi, tıbbi tanı sistemleri için en uygun mimarinin belirlenmesine katkıda bulunmaktadır.

4.2.9. Hesaplama Altyapısı

Modellerin eğitimi ve değerlendirilmesi için güçlü ve yüksek performanslı bir hesaplama altyapısı kullanılmıştır. Donanım altyapısında GPU destekli hesaplamalar için NVIDIA RTX 4070 ekran kartı (8 GB VRAM), çoklu işlemlerde yüksek hız ve verimlilik sağlamak için 32 GB sistem belleği (RAM) ve Intel Core i9 işlemci tercih edilmiştir. Bu donanım bileşenleri, özellikle karmaşık derin öğrenme modellerinin eğitim süreçlerini hızlandırmak ve hesaplama yükünü etkin biçimde yönetmek amacıyla seçilmiştir.

Yazılım ortamı olarak Python'ın 3.11.6 sürümü temel alınmıştır. Derin öğrenme modellerinin geliştirilmesi ve GPU desteğinin verimli kullanılması için PyTorch kütüphanesinin 2.5.1+cu121 sürümü tercih edilmiş, veri işleme süreçleri için NumPy ve Pandas, model performansının analizi ve değerlendirilmesi için Scikit-learn, görsel sunumlar için ise Matplotlib kütüphaneleri kullanılmıştır. Bu yazılım bileşenlerinin seçimi, performans optimizasyonu ve tutarlı, yeniden üretilebilir analizler yapılması adına bilinçli olarak gerçekleştirilmiştir.

Yapılan eğitimlerin süreleri modelin mimarisine ve karmaşıklığına göre değişkenlik göstermiş olup, genel olarak 2 ile 8 saat arasında tamamlanmıştır. Böylelikle farklı mimarilerin hem performansları hem de hesaplama maliyetleri açısından karşılaştırılmasına olanak tanınmıştır.

4.3. Test ve Değerlendirme

Bu bölümde, eğitilen derin öğrenme modellerinin test edilmesi, performans değerlendirmesi ve karşılaştırmalı analizi için kullanılan metodoloji detaylı olarak açıklanmaktadır.

4.3.1. Test Veri Seti

Modellerin performans değerlendirmesi için, eğitim aşamasında kullanılan veri kümesinden tamamen bağımsız, rastgele ayrılmış bir test veri seti kullanılmıştır. Bu test seti, modellerin genelleme yeteneğini objektif bir şekilde ölçmek amacıyla oluşturulmuş ve hasta ile kontrol gruplarından eşit sayıda örnek içerecek biçimde dengelenmiştir. Böylece sınıflar arasında herhangi bir dengesizlikten

kaynaklanabilecek yanıltıcı sonuçların önüne geçilmesi hedeflenmiştir.

Test verileri, eğitimde uygulanan ön işleme adımlarıyla tutarlı olacak şekilde bir dizi işlemde geçirilmiştir. Bu işlemler kapsamında ilk olarak görüntüler, modellerin beklentisiyle uyumlu olacak biçimde 224x224 piksel boyutuna yeniden boyutlandırılmıştır. Ardından, önceden eğitilmiş modellerle uyumluluğun sağlanması ve modellerin daha iyi performans göstermesi için, ImageNet veri setine ait ortalama ([0.485, 0.456, 0.406]) ve standart sapma ([0.229, 0.224, 0.225]) değerlerine göre normalize edilmiştir. Son adımda ise, görüntüler PyTorch tensör formatına dönüştürülerek GPU üzerinden hızlı ve etkin bir biçimde işlenebilir hale getirilmiştir.

Böylece, eğitim süreci tamamlandıktan sonra modeller, daha önce görmedikleri bu bağımsız test veri kümesi üzerinde değerlendirilmiş ve elde edilen sonuçlar yardımıyla modellerin gerçek hayattaki durumlara uygulanabilirliği ve klinik kullanıma yönelik potansiyel başarımları objektif olarak belirlenmiştir. Bu yaklaşım sayesinde modellerin performansının güvenilir ve doğru biçimde ölçülmesi sağlanmış, sonuçların tutarlılığı ve genellenebilirliği de güvence altına alınmıştır.

4.3.2. Değerlendirme Metrikleri

Modellerin performansının kapsamlı ve detaylı biçimde değerlendirilebilmesi için çeşitli metriklerden yararlanılmıştır. Bu metrikler, modellerin genel başarısını ölçmenin yanı sıra, modellerin klinik uygulamalarda güvenle kullanılabilmesi için kritik olan farklı hata türlerini ayrı ayrı değerlendirmek amacıyla da kullanılmıştır.

Karmaşıklık Matrisi (Confusion Matrix), sınıflandırma modellerinin performansını değerlendirmenin temelini oluşturan bir tablodur. Bu matris, modelin tahminlerini gerçek etiketlerle karşılaştırarak dört temel kategoriye ayırır. Doğru Pozitif (True Positive - TP), gerçekte hasta olan ve model tarafından hasta olarak doğru sınıflandırılan örnekleri ifade ederken, Doğru Negatif (True Negative - TN) gerçekte sağlıklı olan ve model tarafından sağlıklı olarak doğru sınıflandırılan örnekleri temsil etmektedir. Yanlış Pozitif (False Positive - FP), gerçekte sağlıklı olan ancak model tarafından hasta olarak yanlış sınıflandırılan örnekleri gösterirken, Yanlış Negatif (False Negative - FN) gerçekte hasta olan ancak model tarafından sağlıklı olarak yanlış sınıflandırılan örnekleri kapsamaktadır. Karmaşıklık matrisi, tüm diğer performans metriklerinin hesaplanmasında temel veri kaynağı olarak

kullanılmaktadır.

Doğruluk (Accuracy), modellerin performansını belirlemek için kullanılan temel bir metriktir. Test veri setinde model tarafından doğru sınıflandırılan örneklerin toplam örnek sayısına oranı olarak hesaplanmıştır. Bu metrik, modellerin genel sınıflandırma başarısını ölçmek için temel gösterge olarak kabul edilmiştir. Doğruluk = $(TP + TN) / (TP + TN + FP + FN)$ formülü ile hesaplanmaktadır.

Kesinlik (Precision), modelin hasta olarak sınıflandırdığı örneklerin ne kadarının gerçekte hasta olduğunu ölçen bir metriktir. Bu metrik, klinik uygulamalarda sağlıklı bireylerin yanlışlıkla hasta olarak sınıflandırılmasını (yanlış pozitifler) minimize etmek açısından önemlidir. Kesinlik = $TP / (TP + FP)$ formülü kullanılarak hesaplanmaktadır.

Hassasiyet (Recall), gerçekte hasta olan bireylerin ne kadarının model tarafından doğru bir şekilde tespit edildiğini ölçmektedir. Bu metrik, hasta olan bireylerin yanlışlıkla sağlıklı olarak sınıflandırılmasını (yanlış negatifler) engellemek açısından kritik öneme sahiptir. Hassasiyet = $TP / (TP + FN)$ formülü ile hesaplanmaktadır.

F1 Skoru, kesinlik ve hassasiyet değerlerinin harmonik ortalaması olarak hesaplanmaktadır. Bu metrik, veri kümelerinin dengesiz dağılıma sahip olduğu durumlarda modelin başarısını daha iyi yansıtır. Ayrıca hem yanlış pozitif hem de yanlış negatif hatalarını birlikte değerlendirerek model performansını daha kapsamlı biçimde ortaya koymaktadır. F1 Skoru = $2 \times (Kesinlik \times Hassasiyet) / (Kesinlik + Hassasiyet)$ formülü kullanılarak hesaplanmıştır.

Sınıf Bazlı Metrikler, modelin başarısını daha ayrıntılı bir şekilde incelemek için her bir sınıf (hasta ve kontrol) için ayrı ayrı doğruluk, kesinlik ve hassasiyet değerlerinin hesaplanmasını içermektedir. Böylece modellerin sınıflandırma performansının sınıf bazında tutarlı olup olmadığı ve belirli bir sınıfta daha yüksek veya düşük başarı gösterip göstermediği ayrıntılı olarak analiz edilmiştir.

Son olarak, Çıkarım süresi, modellerin pratik uygulanabilirliğini değerlendirmek için kullanılmıştır. Her modelin tek görüntüyü işlemek ve sınıflandırma yapmak için kaç milisaniyeye ihtiyaç duyduğu ölçülmüştür. Bu metrik, özellikle gerçek zamanlı klinik uygulamalar için modellerin uygunluğunu değerlendirmek açısından önemlidir. Ortalama Çıkarım Süresi = $\text{Toplam İşlem Süresi} / \text{Test Edilen Örnek Sayısı}$ formülü ile hesaplanmıştır.

4.3.3. Test Süreci

Test süreci, modellerin gerçek performansını objektif ve sistematik biçimde ölçmek amacıyla belirli adımlar takip edilerek gerçekleştirilmiştir. İlk olarak, eğitim sürecinde kaydedilmiş olan model parametreleri (state dictionary'ler içeren .pt dosyaları) yüklenmiş ve modeller değerlendirme (evaluation) moduna geçirilmiştir. Bu adım sayesinde dropout ve batch normalizasyon katmanlarının eğitim dışı davranışı sabitlenmiş ve sonuçların tutarlılığı artırılmıştır.

Ardından, test veri kümesindeki görüntüler, daha önce belirlenen ön işleme adımlarına tabi tutulmuş ve 32'lik gruplar (batch) halinde modellere sunulmuştur. Bu veri akışı sırasında, her test görüntüsü için model çıktıları elde edilmiş ve sınıflandırma sonuçları hesaplanmıştır. Model tarafından üretilen çıktıların her biri için en yüksek olasılığa sahip sınıf, nihai tahmin olarak kabul edilmiştir. Böylece, her görüntünün model tarafından hangi sınıfa ait olduğu belirlenmiştir.

Test sürecinde modellerin çıkarım performansını değerlendirmek ve pratik uygulamalardaki hızlarını belirlemek amacıyla, her bir görüntünün işleme süresi hassas biçimde ölçülmüştür. Ortalama çıkarım süresini hesaplamak için toplam süre görüntü sayısına bölünmüştür. Bu sayede, modellerin yalnızca doğruluk açısından değil, aynı zamanda gerçek zamanlı uygulamalara yönelik performansları açısından da değerlendirilmesi sağlanmıştır.

Son olarak, toplanan tahminler gerçek etiketlerle karşılaştırılarak, doğruluk ve kayıp fonksiyonu değeri gibi performans metrikleri hesaplanmıştır. Bu süreç sonucunda, modellerin hem performansı hem de işlem hızı objektif ve kapsamlı biçimde değerlendirilerek, en uygun model seçimine yönelik sonuçlar ortaya konmuştur.

4.3.4. Model Seçim Kriterleri

Farklı kullanım senaryolarında en uygun derin öğrenme modelinin seçilebilmesi için belirli kriterler göz önünde bulundurulmuştur. İlk olarak, yüksek doğruluk gerektiren klinik tanı sistemleri gibi kritik uygulamalarda, sınıflandırma performansı ve doğruluk öncelikli kriter olarak değerlendirilmiştir. Bu tür senaryolarda, en yüksek

doğrulama ve test doğruluğuna ulaşan, hata oranı en düşük olan modeller tercih edilmiştir. Diğer yandan, gerçek zamanlı EKG izleme veya hasta takibi gibi anlık cevap gerektiren sistemlerde, yalnızca doğruluk değil, aynı zamanda çıkarım süresi de dikkate alınmıştır. Bu senaryolarda, yüksek doğruluk ve hızlı çıkarım süresi arasında optimal bir denge kuran modeller öne çıkarılarak önerilmiştir.

Kaynakları sınırlı olan mobil ya da gömülü sistemler gibi ortamlarda ise modelin hesaplama maliyeti, bellek kullanımı ve işlem hızına özel önem verilmiştir. Bu kapsamda, daha hafif mimariye sahip ve hesaplama verimliliği yüksek olan MobileNet gibi modeller tercih edilmiş, böylelikle sınırlı kaynaklara sahip cihazlarda performanstan ödün vermeden sınıflandırma görevinin etkin biçimde gerçekleştirilmesi amaçlanmıştır.

Gerçekleştirilen tüm testler ve bu detaylı değerlendirme metodolojisi, EKG verilerinden elde edilen Welch diyagramlarının otomatik sınıflandırılması görevinde, farklı uygulama alanlarına ve ihtiyaçlarına yönelik en uygun derin öğrenme modellerinin belirlenmesini mümkün kılmıştır. Yapılan çalışma sonucunda elde edilen test sonuçları, modellerin gerçek dünya koşullarında ve klinik uygulamalarda karşılaşılabilecek senaryolarda performansını ortaya koymakla birlikte, gelecekteki çalışmalar için güçlü bir referans niteliği taşımaktadır.

5. DENEYSEL ÇALIŞMALAR

Bu bölümde, Welch periodogramları kullanılarak elde edilen görüntülerin sınıflandırılması için eğitilen derin öğrenme modellerinin sonuçları detaylı olarak incelenecektir. Çalışmada, farklı mimariler kullanılarak Welch Diyagramlarındaki HF (Yüksek Frekans), LF (Düşük Frekans), VLF (Çok Düşük Frekans) ve UVLF (Ultra Çok Düşük Frekans) frekans bantlarındaki sinyallere bağlı olarak kişinin uyku apnesine sahip olup olmadığı sınıflandırılması hedeflenmiştir. Her bir modelin doğruluk, kesinlik, geri çağırma, F1 skoru ve çıkarım süresi gibi temel performans metrikleri karşılaştırılarak değerlendirilmiştir.

5.1. Deney Ortamı ve Veri Kümesi

5.1.1. Donanım ve Yazılım Konfigürasyonu

Deneyler, Python ortamında NVIDIA GPU donanımlı bir sistemde PyTorch derin öğrenme çerçevesi kullanılarak gerçekleştirilmiştir. Modellerin eğitimi ve değerlendirmesi için standart bir işlem hattı geliştirilmiş, veri ön işleme, model eğitimi ve sonuçların analizi için özel betikler hazırlanmıştır.

5.1.2. Veri Kümesi

Kullanılan veri kümesi, farklı frekans bantlarına ait Welch periodogram görüntülerinden oluşmaktadır. Bu periodogramlar, 0 ile 0.4 Hz arasında değişen frekanslarda güç spektral yoğunluğu (PSD - Power Spectral Density) temsil etmektedir. Periodogramlardaki frekans bantları; yüksek frekans (HF), düşük frekans (LF), çok düşük frekans (VLF) ve ultra çok düşük frekans (UVLF) olarak dört farklı bölgeye ayrılmıştır. HF bandı (0.15-0.4 Hz arası) sarı renkte gösterilmekteyken, LF bandı (0.04-0.15 Hz) turuncu renkle, VLF bandı (0.0033-0.04 Hz) yeşil renkle ve UVLF bandı (0-0.0033 Hz) ise mavi renkle belirtilmiştir.

Veri kümesi, model eğitimi sırasında etkili bir öğrenme ve doğru performans değerlendirmesi sağlamak amacıyla %80 eğitim ve %20 test seti olacak şekilde rastgele ayrılmıştır. Eğitim sırasında modellerin genelleme performansını gerçekçi ve objektif biçimde ölçebilmek için, eğitim ve doğrulama setlerinden tamamen bağımsız, ayrı bir test veri seti oluşturulmuştur. Bu test veri seti, hem sağlıklı kontrol grubu hem de hasta gruplarından dengeli örnekler içermekte ve modellerin gerçek dünya verilerindeki performansını en doğru şekilde değerlendirme olanağı sunmaktadır. Böylece modellerin genelleme yeteneği titizlikle analiz edilmiş ve klinik uygulamalardaki potansiyel etkinliği net olarak belirlenmiştir.

5.2. Model Mimarileri ve Eğitim Stratejisi

5.2.1. Kullanılan Model Mimarileri

Welch görüntülerinin sınıflandırılması için altı farklı derin öğrenme mimarisi kullanılmıştır:

1. ResNet50
2. MobileNet_v2

3. DenseNet121
4. EfficientNet_v2_s
5. ResNet18
6. EfficientNet_b0

Her bir modelin son katmanı, veri kümesindeki sınıf sayısına uygun olarak yeniden yapılandırılmıştır.

5.2.2. Eğitim Parametreleri

Tüm modellerin eğitimi, standartlaştırılmış bir hiper parametre seti kullanılarak gerçekleştirilmiştir. Bu standartlaştırma, modellerin performansının tutarlı ve objektif biçimde karşılaştırılmasını sağlamıştır. Optimizasyon algoritması olarak, hızlı yakınsama ve etkin optimizasyon sağladığı bilinen Adam algoritması kullanılmış ve başlangıç öğrenme oranı tüm modeller için 0.001 olarak belirlenmiştir. Eğitim verileri, hesaplama verimliliğini ve bellek kullanımını dengelemek amacıyla 32'lik yığın boyutları halinde modellere sunulmuştur.

Modellerin eğitim süreçleri, maksimum 100 iterasyon ile sınırlı tutulmuş ancak modellerin doğrulama performansı erken durdurma mekanizmasıyla kontrol edilmiştir. Bu doğrultuda, doğrulama doğruluğunda art arda 5 iterasyon boyunca iyileşme olmaması durumunda eğitim süreçleri otomatik olarak sonlandırılmıştır. Böylelikle modellerin aşırı öğrenmeden kaçınması ve hesaplama kaynaklarının etkin biçimde kullanılması sağlanmıştır.

Tüm modellerin eğitiminde, kayıp fonksiyonu olarak çok sınıflı sınıflandırma görevleri için ideal olan çapraz entropi fonksiyonu tercih edilmiştir. Ayrıca eğitim süresince öğrenme oranının adaptif biçimde ayarlanabilmesi ve daha etkin yakınsama sağlanabilmesi için ReduceLRonPlateau öğrenme oranı planlayıcısı kullanılmıştır. Bu planlayıcı, doğrulama kaybının iyileşmediği durumlarda öğrenme oranını mevcut değerinin yarısına indirerek modelin daha iyi yerel minimumlara yakınsamasını teşvik etmiştir.

Görüntü verileri, tüm modeller için tutarlı bir ön işleme aşamasından geçirilmiştir. Bu kapsamda, görüntüler standart ImageNet normalizasyonu (ortalama=[0.485, 0.456, 0.406], standart sapma=[0.229, 0.224, 0.225]) uygulanarak normalize edilmiştir. Ayrıca görüntüler, tüm modeller için standart olarak 224×224 piksel boyutuna yeniden boyutlandırılmıştır. Bu standart ve tutarlı yaklaşım sayesinde,

modellerin gerçek performansları doğrudan karşılaştırılabilmiş ve en uygun mimarinin belirlenmesi mümkün olmuştur.

6. SONUÇLAR

Bu bölümde, EKG sinyallerinden elde edilen Welch güç spektral yoğunluk diyagramlarının sınıflandırılması için eğitilen derin öğrenme modellerinin performans sonuçları ve karşılaştırmalı analizleri sunulmaktadır. Çalışma kapsamında altı farklı model mimarisi (ResNet50, ResNet18, MobileNetV2, DenseNet121, EfficientNetV2-S ve EfficientNet-B0) test edilmiş, elde edilen sonuçlar doğruluk, kesinlik, hassasiyet, F1 skoru ve çıkarım süreleri bakımından detaylı olarak analiz edilmiştir.


6.1. Model Performansları ve Karşılaştırmalı Analiz

Eğitilen derin öğrenme modellerinin test veri seti üzerindeki performans metrikleri Tablo 6.1'de ve Şekil 6.1'de sunulmaktadır. ResNet50 ve MobileNetV2 modelleri, %96.15'lik doğruluk ile en iyi performansı göstermiştir. Bu modeller kesinlik, hassasiyet ve F1 skoru açısından da aynı üstün performansı sergilemiştir. DenseNet121 %94.23'lük doğruluk oranıyla bu iki modeli takip ederken, EfficientNetV2-S ve ResNet18 %90.38, EfficientNet-B0 ise %88.46 doğruluk oranına ulaşmıştır.

Tablo 6.1. Derin öğrenme modellerinin test veri seti üzerinde performans karşılaştırması

Mimari	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Skoru (%)	Çıkartım Süresi (ms)
ResNet50	96.15	96.15	96.15	96.15	0.86
MobileNetV2	96.15	96.15	96.15	96.15	0.69
DenseNet121	94.23	94.30	94.23	94.23	4.69
EfficientNetV2-S	90.38	90.93	90.38	90.35	4.41
ResNet18	90.38	91.94	90.38	90.29	0.37
EfficientNet-B0	88.46	90.62	88.46	88.31	2.43


Modellerin çıkarım sürelerine bakıldığında, önemli farklılıklar gözlenmiştir. ResNet18 0.37 ms ile en hızlı model olurken, bunu 0.69 ms ile MobileNetV2 ve 0.86 ms ile ResNet50 takip etmiştir. DenseNet121 ve EfficientNetV2-S sırasıyla 4.69 ms ve 4.41 ms ile en yavaş modeller olarak belirlenmiştir. Bu sonuçlar, yüksek doğruluk ve düşük çıkarım süresi açısından MobileNetV2'nin optimum bir denge sağladığını göstermektedir.



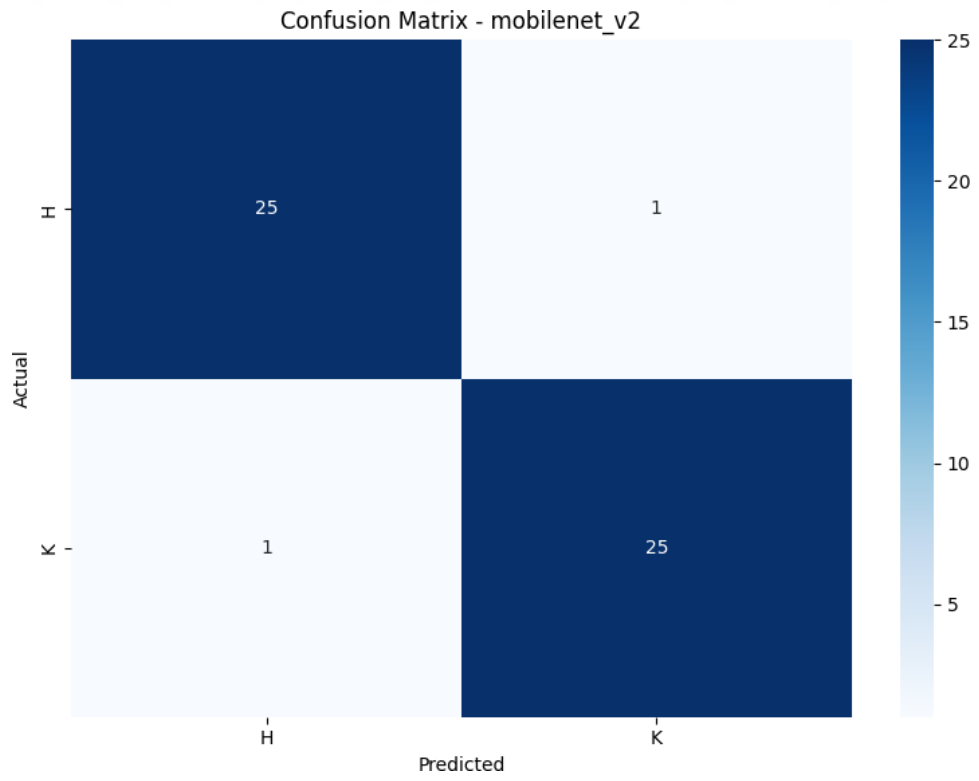
Şekil 6.1. Model sonuçlarının karşılaştırılması

ResNet mimarileri karşılaştırıldığında, daha derin olan ResNet50'nin ResNet18'e göre belirgin şekilde daha yüksek doğruluk sağladığı (%96.15'e karşı %90.38) görülmüştür. Bu durum, daha derin mimarilerin Welch diyagramlarındaki karmaşık spektral özellikleri yakalamada daha etkili olduğunu göstermektedir. Ancak bu doğruluk artışı, çıkarım süresinde yaklaşık 2.3 katlık bir artışla gerçekleşmiştir (0.37 ms'den 0.86 ms'ye).


Karışıklık matrisleri analiz edildiğinde, ResNet50 ve MobileNetV2 her iki sınıfta da yüksek performans göstermiştir (H: 25/1, K: 25/1). DenseNet121 ise H sınıfında 24/2, K sınıfında 25/1 doğruluk oranı elde etmiştir.




Şekil 6.2. ResNet50 (Karışıklık Matrisi)



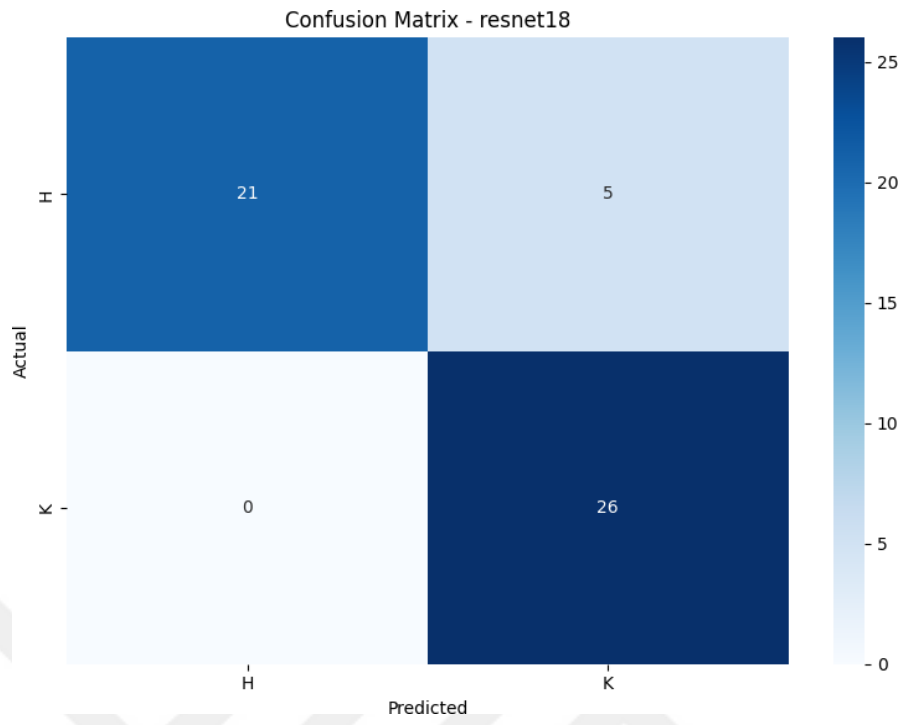
Şekil 6.3. MobileNetV2 (Karışıklık Matrisi)




Şekil 6.4. DenseNet121 (Karışıklık Matrisi)



Şekil 6.5. EfficientNetV2-S (Karışıklık Matrisi)



Şekil 6.6. ResNet18 (Karışıklık Matrisi)



Şekil 6.7. EfficientNet-B0 (Karışıklık Matrisi)

Diğer modellerde ise ilginç bir performans asimetrisi gözlemlenmiştir. EfficientNetV2-S, H sınıfından 22 örneği doğru, 4 örneği yanlış sınıflandırırken, K sınıfından 25 örneği doğru, 1 örneği yanlış sınıflandırmıştır. ResNet18 ve EfficientNet-B0 modelleri ise K sınıfındaki tüm örnekleri doğru tahmin ederken, H sınıfında daha fazla hata yapmıştır (ResNet18 için 5 hata, EfficientNet-B0 için 6 hata). Bu sonuçlar, tüm modellerin kontrol grubunu (K) tanımada hasta grubunu (H) tanımaya göre daha başarılı olduğunu göstermektedir. Bu durum, hasta grubundaki spektral özelliklerin daha heterojen veya daha az belirgin olmasıyla açıklanabilir.

6.2. Eğitim Metrikleri ve Validasyon Performansı

Tablo 6.2'de altı farklı derin öğrenme modelinin eğitim sürecine ilişkin detaylı metrikleri sunulmaktadır. Bu tablo, modellerin eğitim aşamasındaki performanslarını ve validasyon başarılarını karşılaştırmalı olarak göstermektedir.

Tablo 6.2. Derin öğrenme modellerinin eğitim ve validasyon metrikleri

Mimari	En İyi Validasyon Doğruluğu (%)	Eğitim Doğruluğu (%)	Validasyon Kaybı	Eğitim Süresi (s)	Eğitilen İterasyon Sayısı	Erken Durdurma
ResNet50	91.82	98.42	0.1932	241.08	9	Evet
MobileNetV2	89.09	99.28	0.4745	252.23	10	Evet
DenseNet121	90.00	99.10	0.3046	240.51	9	Evet
EfficientNetV2-S	89.09	97.74	0.3735	270.12	10	Evet
ResNet18	90.00	99.12	0.4187	276.37	11	Evet
EfficientNet-B0	90.00	98.42	0.2226	249.34	10	Evet

Validasyon performansları incelendiğinde, ResNet50 modelinin %91.82 doğruluk oranıyla en yüksek validasyon başarısını elde ettiği görülmektedir. Bu modeli %90.00 doğruluk oranıyla DenseNet121, ResNet18 ve EfficientNet-B0 takip etmektedir. MobileNetV2 ve EfficientNetV2-S modelleri ise %89.09'luk validasyon doğruluğu ile diğer modellere göre daha düşük performans göstermiştir.

Eđitim dođrulukları incelendiđinde, MobileNetV2 %99.28, ResNet18 %99.12 dođruluk oranı, ResNet50 ve EfficientNet-B0 modelleri %98.42, DenseNet121 modeli %99.10, EfficientNetV2-S modeli ise %97.74 eđitim dođruluđu elde etmiřtir.

Validasyon kaybı (loss) deđerleri, modellerin genelleme kabiliyetini gsteren nemli bir metriktir. Bu aıdan ResNet50 modeli 0.1932 deđerı ile en dřuk validasyon kaybını gstermiř, bunu 0.2226 ile EfficientNet-B0 takip etmiřtir. MobileNetV2 modeli ise 0.4745 deđerı ile en yksek validasyon kaybına sahiptir, bu da modelin validasyon verisi zerindeki belirsizliđinin daha yksek olduđunu gstermektedir.

Eđitim sreleri deđerlendirildiđinde, modeller arasında belirgin farklılıklar gzlenmektedir. DenseNet121 240.51 saniye ile en hızlı eđitim sresine sahip model olurken, ResNet18 276.37 saniye ile en uzun eđitim sresine sahip model olmuřtur. Tm modellerin erken durdurma mekanizması ile eđitimlerinin sonlandırıldıđı grlmektedir, bu da ařırı uyumu nlemek iin uygulanan stratejinin etkili olduđunu gstermektedir.

Eđitim iin gereken iterasyon sayıları incelendiđinde, ResNet50 ve DenseNet121 modellerinin 9 iterasyon ile eđitimi tamamladıđı, diđer modellerin ise 10-11 iterasyon gerektirdiđi grlmektedir. Bu durum, ResNet50 ve DenseNet121 modellerinin daha hızlı yakınsadıđını gstermektedir.

Bu eđitim metrikleri ile blm 6'da sunulan test performansları birlikte deđerlendirildiđinde, validasyon ařamasında en iyi performansı gsteren ResNet50 modelinin (%91.82), test ařamasında da en yksek dođruluđu (%96.15) ulařtıđı grlmektedir. Ancak, validasyon ařamasında nispeten daha dřuk performans gsteren MobileNetV2 modelinin (%89.09), test ařamasında ResNet50 ile aynı yksek dođruluk oranına (%96.15) ulařması dikkat ekicidir. Bu durum, MobileNetV2 modelinin genelleme kabiliyetinin beklenenden daha iyi olduđunu ve spektral verilerin sınıflandırılmasında etkili olabileceđini gstermektedir.

6.3. Mimari zelliklerin Performansa Etkileri

MobileNetV2'nin gsterdiđi stn performans, hafif mimarisine rađmen Welch diyagramlarındaki nemli zellikleri yakalamada son derece etkili olduđunu

kanıtlamıştır. Derinlemesine ayrılabilir evrişimler ve ters artık yapılar, EKG spektral analizi için uygun özellik temsilleri sağlamıştır. Ayrıca, MobileNetV2'nin parametre verimliliği (ResNet50'ye göre çok daha az parametre içermesine rağmen aynı doğruluğa ulaşması), model mimarisinin spektral veri analizi için özel olarak uygun olduğunu göstermektedir.

DenseNet121'in yoğun bağlantılı yapısı, Welch diyagramlarındaki farklı frekans bileşenleri arasındaki ilişkileri yakalamada avantaj sağlamış olabilir. Bu model, %94.23'lük doğruluk oranıyla iyi bir performans göstermiştir, ancak yoğun bağlantılı mimarisinin getirdiği hesaplama yükü nedeniyle çıkarım süresi yüksektir (4.69 ms).

EfficientNet modellerinin (EfficientNetV2-S ve EfficientNet-B0) performansları beklentilerin altında kalmıştır. Bu modeller, bileşik ölçeklendirme yaklaşımlarına rağmen, Welch diyagramlarındaki önemli spektral özellikleri yakalamada zorluk yaşamış olabilir. Ayrıca, bu modellerin çıkarım süreleri beklenenin aksine yüksek çıkmıştır, bu da optimizasyon sürecinde iyileştirme potansiyeli olduğunu göstermektedir.

Modellerin hasta sınıfını (H) tanımada yaşadığı görece zorluk, spektral verilerin doğasıyla ilişkili olabilir. Hasta grubundaki bireyler arasındaki spektral çeşitlilik, modellerin genelleme yapmasını zorlaştırmış olabilir. Ayrıca, bazı hasta bireylerinin spektral özellikleri, belirli frekanslarda kontrol grubuna benzerlik gösterebilir, bu da yanlış sınıflandırmalara yol açabilir.

6.4. Klinik Uygulamalar ve Öneriler

Elde edilen sonuçlar, derin öğrenme modellerinin EKG sinyallerinden elde edilen Welch güç spektral yoğunluk diyagramlarını kullanarak hasta ve kontrol gruplarını yüksek doğrulukla ayırt edebildiğini göstermektedir. Bu bulgular, uyku apnesinin erken teşhisi ve izlenmesi için otomatik tanı sistemleri geliştirme potansiyelini ortaya koymaktadır.

Çalışmanın sonuçlarına dayanarak, farklı kullanım senaryoları için çeşitli model önerileri yapılabilir. Klinik tanı sistemleri gibi en yüksek doğruluk gerektiren uygulamalar için ResNet50 veya MobileNetV2 modelleri önerilmektedir. Bu

modeller, %96.15'lik doğruluk oranıyla en güvenilir sonuçları sağlamaktadır. Mobil cihazlar ve gerçek zamanlı sistemler için MobileNetV2 modeli ideal bir seçimdir, çünkü yüksek doğruluk oranını makul bir çıkarım süresiyle birleştirmektedir. Çok hızlı işlem gerektiren uygulamalar için ResNet18 modeli tercih edilebilir, ancak %90.38'lik doğruluk oranının kullanım senaryosu için yeterli olup olmadığı değerlendirilmelidir.

Modellerin yaptığı yanlış sınıflandırmalar analiz edildiğinde, bazı ortak zorluk alanları belirlenmiştir. Özellikle sınır durumundaki örnekler ve düşük sinyal-gürültü oranına sahip Welch diyagramları, yanlış sınıflandırmalara neden olmaktadır. Bu zorlukların üstesinden gelmek için, veri ön işleme tekniklerinin iyileştirilmesi ve daha gelişmiş veri artırma stratejilerinin uygulanması önerilmektedir.

Çalışmanın bir başka önemli bulgusu, MobileNetV2 gibi hafif mimarilerin, Welch diyagramlarının sınıflandırılmasında ResNet50 gibi daha derin mimariler kadar etkili olabilmesidir. Bu, özellikle sınırlı hesaplama kaynaklarına sahip cihazlarda kullanım için umut vericidir. Gelecekteki çalışmalarda, MobileNetV2 mimarisinin daha da optimize edilmesi ve özellikle hasta grubundaki spektral özellikleri daha iyi yakalayacak şekilde uyarlanması düşünülebilir.

Sonuç olarak, bu çalışma, EKG sinyallerinden elde edilen Welch güç spektral yoğunluk diyagramlarının derin öğrenme modelleri ile sınıflandırılmasında önemli bir ilerleme sağlamıştır. Elde edilen yüksek doğruluk oranları ve makul çıkarım süreleri, bu yaklaşımın klinik uygulamalarda kullanım potansiyelini göstermektedir. Özellikle MobileNetV2 modelinin gösterdiği üstün performans, mobil ve giyilebilir sağlık teknolojileri için umut vericidir. Gelecekteki çalışmalarda, daha büyük ve çeşitli veri setleri kullanılarak modellerin genelleme kabiliyetinin daha da artırılması ve uyku apnesi için spesifik modellerin geliştirilmesi hedeflenmelidir.

7. SONUÇ VE TARTIŞMALAR

Bu çalışma, uyku apnesi tanısında yenilikçi bir yaklaşım sunmaktadır. Günümüzde uyku apnesi tanısı için altın standart olan polisomnografi testleri, yüksek maliyet ve sınırlı erişim gibi dezavantajlar barındırmaktadır. Geliştirdiğimiz Welch güç spektral yoğunluk diyagramları kullanılarak uyku apnesi tespiti yapan yapay zeka çözümü, bu sorunlara etkili bir alternatif sunma potansiyeline sahiptir.

7.1. Klinik Uygulama Alanları

Çalışmamızın sonuçları, geliştirilen yaklaşımın birçok farklı klinik ortamda uygulanabileceğini göstermektedir. Özellikle birinci basamak sağlık hizmetlerinde, bu tür tarama sistemleri sağlık personeline değerli bir destek sağlayabilir. Aile hekimleri, yüksek risk taşıyan hastaları hızlı ve doğru bir şekilde belirleyerek, ileri tetkikler için yönlendirme yapabilir.

Evde kullanım için tasarlanan taşınabilir cihazlar, hastaların kendi ortamlarında ve konforlu bir şekilde tarama yaptırabilmelerine olanak tanıyabilir. Bu, özellikle kırsal bölgelerde veya sağlık hizmetlerine erişimin kısıtlı olduğu yerlerde yaşayan bireyler için büyük önem taşımaktadır. Kişiler, sağlık kuruluşlarına gitmeden ön değerlendirme yapabilir ve sadece gerekli durumlarda klinik başvurusu yapabilirler.

Giyilebilir teknolojiler ve akıllı sağlık cihazları, çalışmamızdan elde edilen algoritmaların entegre edilebileceği diğer önemli platformlardır. Geliştirilen algoritma sayesinde, günlük kullanılan akıllı saatler veya EKG özellikli cihazlar, uyku apnesi riski taşıyan bireyleri tespit edebilir ve erken müdahale imkanı sunabilir. Bu durum, özellikle hastalığın uzun vadeli komplikasyonlarının önlenmesi açısından kritiktir.

7.2. Sağlık Sistemine Katkılar

Uyku apnesi, tedavi edilmediğinde ciddi kardiyovasküler sorunlar, metabolik bozukluklar ve yaşam kalitesinde düşüş gibi birçok komplikasyona yol açabilen bir hastalıktır. Erken teşhis ve müdahale, bu komplikasyonların önlenmesinde ve sağlık sistemine binen yükün azaltılmasında hayati öneme sahiptir.

Çalışmanın sağlık sistemi üzerindeki potansiyel etkileri çok yönlüdür. İlk olarak, polisomnografi testlerine olan ihtiyacın azaltılması, sağlık hizmetleri maliyetlerinde önemli bir düşüş sağlayabilir. Yüksek doğrulukla çalışan bir ön tarama sistemi, sadece gerçekten ihtiyaç duyan hastaların ileri tetkiklere yönlendirilmesini sağlayarak, kaynakların daha verimli kullanılmasına olanak tanır.

Ayrıca, uzun bekleme süreleri ve sınırlı uyku laboratuvarı kapasitesi gibi sorunların aşılmasına katkı sağlayabilir. Daha hızlı teşhis süreçleri, hastaların tedaviye daha erken başlamasını mümkün kılar, bu da hastalık yönetiminde ve komplikasyonların önlenmesinde kritik öneme sahiptir.

Pandemi gibi olağanüstü durumlarda, uzaktan sağlık değerlendirmesi yapabilme kapasitesi de büyük önem kazanmaktadır. Geliştirilen sistem, fiziksel temasın kısıtlanması gereken dönemlerde bile, hastaların sağlık durumlarının değerlendirilmesine olanak tanıyabilir.

7.3. Gelecekteki Araştırmalar İçin Öneriler

Bu çalışma, Welch periodogramları kullanılarak gerçekleştirilen kalp hızı değişkenliği analizi ile uyku apnesi tespiti konusunda gelecekteki araştırmalar için sağlam bir temel oluşturmaktadır. İlerleyen dönemlerde, daha büyük ve çeşitli hasta popülasyonlarını içeren veri setleriyle çalışmaların genişletilmesi, modelin genelleme kabiliyetini artırabilir ve farklı demografik gruplarda da etkinliğini doğrulayabilir.

Gelecekteki çalışmalarda, mevcut Welch periodogram yaklaşımına ek olarak diğer kalp hızı değişkenliği analiz tekniklerinin de entegre edilmesi önerilmektedir. Takogramlar, RR aralıklarının zamana bağlı değişimlerini grafiksel olarak göstererek uyku apnesi epizodları sırasında oluşan otonom sinir sistemi değişimlerini ortaya koyabilir. Poincaré grafikleri, RR aralıklarının ardışık ilişkilerini geometrik olarak temsil ederek kısa vadeli ile uzun vadeli HRV değişikliklerini ayırt etmeye olanak tanır. Histogram analizleri ise RR aralıklarının dağılım özelliklerini göstererek normal ve patolojik durumları ayırt etmede faydalı bilgiler sağlar. Bu çok yönlü analiz yaklaşımı, uyku apnesi tespitinin hassasiyetini ve doğruluğunu daha da artırabilir.

Hastalığın varlığını tespit etmekle kalmayıp, şiddetini de değerlendirebilen sistemlerin geliştirilmesi önemli olacaktır. Uyku apnesinin farklı seviyelerini ayırt edebilmek, tedavilerin bireyselleştirilmesi açısından değerli olacaktır.

Gelecekteki arařtırmalarda, akıllı saat teknolojilerinin bu sisteme entegrasyonu kritik bir arařtırma alanıdır. Modern akıllı saatler, Apple Watch Series 4 ve üzeri modelleri, Samsung Galaxy Watch4, Fitbit Sense gibi cihazlar, tek derivasyonlu EKG ölçüm kapasitesine sahiptir. Bu cihazlar, kullanıcının parmağını dijital krona veya sensöre temas ettirmesi yoluyla 30 saniyelik EKG kayıtları alabilmektedir. Uyku apnesi tespiti için akıllı saatlerden veri çekme süreci, cihazın sađlık API'leri kullanılarak gerçekleştirilebilir. Apple HealthKit, Samsung Health SDK ve Google Fit API gibi platformlar, EKG verilerinin ham formatında uygulamalara aktarılmasına olanak tanımaktadır. Bu veriler genellikle millivolt cinsinden amplitüd deđerleri ve zaman damgaları içeren dizi formatında elde edilmektedir. Elde edilen ham EKG sinyallerinin Welch güç spektral yoğunluk diyagramlarına dönüřtürülmesi için öncelikle R-R aralıklarının tespit edilmesi gerekmektedir. Akıllı saatlerin sınırlı işlem gücü göz önüne alındığında, R-peak algoritmaları optimize edilmeli ve gürültü filtreleme teknikleri uygulanmalıdır. Ardından, R-R aralık serileri üzerinde Welch periodogram analizi gerçekleştirilerek, kalp hızı deđişkenliğinin frekans domain karakteristikleri çıkarılabilir.

Akıllı saat tabanlı uyku apnesi tespiti sisteminin başarısı için, gece boyunca otomatik EKG kayıtlarının alınması ve gerçek zamanlı analiz yapılması önemlidir. Bu süreçte, hareket artefaktlarının filtrelenmesi, düşük pil tüketimi optimizasyonu ve veri güvenliği protokollerinin uygulanması teknik zorluklar olarak karřımıza çıkmaktadır. Bu zorlukların aşılması durumunda, kullanıcılar günlük yaşamlarının bir parçası olan akıllı saatleri aracılığıyla sürekli uyku apnesi izlemi yapabilecek ve erken uyarı sistemlerinden faydalanabilecektir.

Mevcut yaklaşımın, EKG verilerinin yanı sıra, solunum sinyalleri, oksijen satürasyonu gibi diđer fizyolojik parametrelerle birlikte deđerlendirildiđi çok parametrelili sistemlere evrilmesi de düşünülebilir. Bu bütünsel yaklaşım, tanı doğruluđunu daha da artırabilir ve hastalığın farklı yönleri daha iyi anlaşılabilir. Uzun vadeli izleme yapabilen sistemlerin geliştirilmesi, tedavi etkinliğinin deđerlendirilmesi ve hastalık seyrinin takibi açısından faydalı olacaktır. Özellikle CPAP gibi tedavilerin etkilerinin gerçek zamanlı olarak izlenmesi ve gerektiğinde ayarlanması, tedavi başarısını artırabilir.

7.4. Sosyal ve Ekonomik Etkiler

Uyku apnesi, yalnızca bireyin sağlığını değil, aynı zamanda yaşam kalitesini, iş performansını ve sosyal ilişkilerini de etkileyen bir hastalıktır. Gün içi aşırı uyku hali, konsantrasyon güçlüğü ve yorgunluk, bireylerin iş ve okul hayatlarında performans düşüşüne yol açabilir.

Erken teşhis ve etkili tedavi, bireylerin yaşam kalitesinde belirgin iyileşmeler sağlayabilir ve iş performanslarının artmasına katkıda bulunabilir. Bu da dolaylı olarak verimlilik artışı ve ekonomik fayda anlamına gelmektedir.

Ayrıca, tedavi edilmeyen uyku apnesi, trafik kazaları ve iş kazaları riskini artırmaktadır. Hastalığın erken teşhisi ve tedavisi, bu tür kazaların önlenmesine katkı sağlayarak, hem maddi kayıpların hem de can kayıplarının önüne geçebilir.

İşveren perspektifinden bakıldığında, çalışanların sağlık durumlarının iyileştirilmesi, iş gücü kayıplarının azaltılması ve sağlık sigortası maliyetlerinin düşürülmesi gibi faydalar sağlayabilir. Dolayısıyla, geliştirilen tarama sistemleri, işyeri sağlık programlarına da entegre edilebilir.

7.5. Genel Sonuç

Bu çalışma, uyku apnesi tanısına yenilikçi bir yaklaşım getirmekte ve sağlık hizmetlerinin geleceğinde teknolojinin oynayacağı kritik rolü vurgulamaktadır.

Welch güç spektral yoğunluk diyagramları kullanılarak yapılan uyku apnesi tespiti, erken tanı, yaygın tarama ve tedavi optimizasyonu gibi alanlarda önemli fırsatlar sunmaktadır.

Teknolojinin ilerlemesi ve yapay zeka çözümlerinin daha da gelişmesiyle birlikte, bu tür sistemlerin doğruluğunun ve erişilebilirliğinin artması beklenmektedir. Sağlık hizmetlerinin dijital dönüşümünde, bu tür yenilikçi yaklaşımlar önemli birer adım olacaktır.

Sonuç olarak, geliştirdiğimiz yaklaşım, uyku apnesi gibi yaygın ve ciddi bir sağlık sorununun tanı ve yönetiminde paradigma değişikliği yaratma potansiyeline sahiptir. Daha erişilebilir, uygun maliyetli ve etkili tanı yöntemleri, toplum sağlığı hedeflerine ulaşılmasına katkı sağlayacaktır.

KAYNAKÇA

- Abd-alrazaq, A., Alajlani, M., Alhuwail, D., Schneider, J., Al-Kuwari, S., Shah, Z., Hamdi, M. ve Househ, M. (2024). Systematic review and meta-analysis of performance of wearable devices in detecting sleep apnea. *Nature and Science of Sleep*, 16, 1-15.
- Acharya, U.R., Joseph, K.P., Kannathal, N., Lim, C.M. ve Suri, J.S. (2006). Heart rate variability: a review. *Medical and Biological Engineering and Computing*, 44(12), 1031-1051.
- Aiyer, I., Shaik, R. ve Zhao, L. (2022). Machine learning-based automatic detection of sleep apnea using wearable sensors: A systematic review. *IEEE Reviews in Biomedical Engineering*, 15, 312-327.
- Al-Humaidan, N.A. ve Prince, M. (2021). A classification of Arab ethnicity based on face image using deep learning approach. *IEEE Access*, 9, 50755-50766.
- Almazaydeh, L., Elleithy, K. ve Faezipour, M. (2012). Obstructive sleep apnea detection using SVM-based classification of ECG signal features. *Proceedings of the 34th Annual International Conference of the IEEE EMBS*, 1-6.
- Alvarez-Estevez, D. ve Moret-Bonillo, V. (2016). Spectral heart rate variability analysis using the heart timing signal for the screening of the sleep apnea-hypopnea syndrome. *Computers in Biology and Medicine*, 71, 14-23.
- American Academy of Sleep Medicine. (2014). *International Classification of Sleep Disorders (3rd ed.)*. Darien, IL: American Academy of Sleep Medicine.
- Bahrami, B. ve Forouzanfar, M. (2022). Sleep apnea detection from single-lead ECG: A comprehensive analysis of machine learning and deep learning algorithms. *IEEE Transactions on Instrumentation and Measurement*, 71, 1-11.
- Bazoukis, G., Bollepalli, S.C., Chung, C.T., Li, X., Tse, G., Bartley, B.L., Batool-Anwar, S., Quan, S.F. ve Armoundas, A.A. (2023). Application of artificial intelligence in the diagnosis of sleep apnea. *Journal of Clinical Sleep Medicine*, 19(7), 1337-1363.
- Benjafeld, A.V., Ayas, N.T., Eastwood, P.R., Heinzer, R., Ip, M.S.M., Morrell, M.J., Nunez, C.M., Patel, S.R., Penzel, T., Pépin, J.L., Peppard, P.E., Sinha, S., Tufik, S., Valentine, K. ve Malhotra, A. (2019). Estimation of the global prevalence and burden of obstructive sleep apnoea: a literature-based analysis. *The Lancet Respiratory Medicine*, 7(8), 687-698.
- Berry, R.B., Kryger, M.H. ve Massie, C.A. (2011). A novel nasal expiratory positive airway pressure (EPAP) device for the treatment of obstructive sleep apnea: a randomized controlled trial. *Sleep*, 34(4), 479-485.
- Berry, R.B., Budhiraja, R., Gottlieb, D.J., Gozal, D., Iber, C., Kapur, V.K., Marcus, C.L., Mehra, R., Parthasarathy, S., Quan, S.F., Redline, S., Strohl, K.P., Davidson Ward, S.L. ve Tangredi, M.M. (2012). Rules for scoring respiratory events in sleep: Update of the 2007 AASM manual for the scoring of sleep and associated events. *Journal of Clinical Sleep Medicine*, 8(5), 597-619.
- Bixler, E.O., Vgontzas, A.N., Lin, H.M., Ten Have, T., Rein, J., Vela-Bueno, A. ve Kales, A. (2001). Prevalence of sleep-disordered breathing in women: effects of gender. *American Journal of Respiratory and Critical Care Medicine*, 163(3), 608-613.

- Bradley, T.D. ve Floras, J.S. (2003). Sleep apnea and heart failure: Part I: obstructive sleep apnea. *Circulation*, 107(12), 1671-1678.
- Brennan, M., Palaniswami, M. ve Kamen, P. (2001). Do existing measures of Poincaré plot geometry reflect nonlinear features of heart rate variability? *IEEE Transactions on Biomedical Engineering*, 48(11), 1342-1347.
- Bruyneel, M. (2016). Telemedicine in the diagnosis and treatment of sleep apnoea. *European Respiratory Review*, 25(142), 1203-1219.
- Bsoul, M., Minn, H. ve Tamil, L. (2011). Apnea MedAssist: Real-time sleep apnea monitor using single-lead ECG. *IEEE Transactions on Information Technology in Biomedicine*, 15(3), 416-427.
- Canessa, N., Castronovo, V., Cappa, S.F., Aloia, M.S., Marelli, S., Falini, A., Alemanno, F. ve Ferini-Strambi, L. (2011). Obstructive sleep apnea: brain structural changes and neurocognitive function before and after treatment. *American Journal of Respiratory and Critical Care Medicine*, 183(10), 1419-1426.
- Caples, S.M., Rowley, J.A., Prinsell, J.R., Pallanch, J.F., Elamin, M.B., Katz, S.G. ve Harwick, J.D. (2010). Surgical modifications of the upper airway for obstructive sleep apnea in adults: a systematic review and meta-analysis. *Sleep*, 33(10), 1396-1407.
- Chadha, J., Jain, A. ve Kumar, Y. (2023). Satellite imagery-based Airbus ship localization and detection using deep learning-based approaches. *Peer-to-Peer Networking and Applications*, 16, 1481-1498.
- Chang, H.-Y., Yeh, C.-Y., Lee, C.-T. ve Lin, C.-C. (2020). A sleep apnea detection system based on a one-dimensional deep convolutional neural network model using single-lead ECG. *Sensors*, 20(15), 4157.
- Chen, L., Zhang, X., Wang, H., Zeng, C., Wang, R., Xu, X., Zhang, Y. ve Zhou, X. (2022). An automated system for sleep apnea detection using single-lead ECG signal based on deep learning techniques. *IEEE Access*, 10, 85337-85350.
- Chung, F., Yegneswaran, B., Liao, P., Chung, S.A., Vairavanathan, S., Islam, S., Khajehdehi, A. ve Shapiro, C.M. (2008). STOP questionnaire: a tool to screen patients for obstructive sleep apnea. *Anesthesiology*, 108(5), 812-821.
- Cistulli, P.A., Armitstead, J., Pepin, J.L., Woehrle, H., Nunez, C.M., Benjafield, A. ve Malhotra, A. (2019). Short-term CPAP adherence in obstructive sleep apnea: a big data analysis using real world data. *Sleep Medicine*, 59, 114-116.
- Clifford, G.D. (2002). Signal processing methods for heart rate variability. Ph.D. dissertation, University of Oxford.
- Collop, N.A., Anderson, W.M., Boehlecke, B., Claman, D., Goldberg, R., Gottlieb, D.J., Hudgel, D., Sateia, M. ve Schwab, R. (2007). Clinical guidelines for the use of unattended portable monitors in the diagnosis of obstructive sleep apnea in adult patients. *Journal of Clinical Sleep Medicine*, 3(7), 737-747.
- de Chazal, P., Heneghan, C., Sheridan, E., Reilly, R., Nolan, P. ve O'Malley, M. (2003). Automated processing of the single-lead ECG for detection of obstructive sleep apnoea. *IEEE Transactions on Biomedical Engineering*, 50(6), 686-696.
- Demir, A., Ursavas, A., Aslan, A.T., Gulbay, B., Ciftci, B., Cuhadaroglu, C., Keyf, F., Firat, H., Yilmaz, M., Gerek, M., Kokturk, O., Sahin, H., Yilmaz, A., Karadag, M. ve Itil, O. (2015). Prevalence of sleep disorders in the Turkish adult population epidemiology of sleep study. *Sleep and Biological Rhythms*, 13(4), 298-308.

- Eckert, D.J. (2018). Phenotypic approaches to obstructive sleep apnoea – New pathways for targeted therapy. *Sleep Medicine Reviews*, 37, 45-59.
- Eckert, D.J. ve Malhotra, A. (2008). Pathophysiology of adult obstructive sleep apnea. *Proceedings of the American Thoracic Society*, 5(2), 144-153.
- Epstein, L.J., Kristo, D., Strollo, P.J. Jr., Friedman, N., Malhotra, A., Patil, S.P., Ramar, K., Rogers, R., Schwab, R.J., Weaver, E.M. ve Weinstein, M.D. (2009). Clinical guideline for the evaluation, management and long-term care of obstructive sleep apnea in adults. *Journal of Clinical Sleep Medicine*, 5(3), 263-276.
- Erdenebayar, U., Kim, Y.J., Park, J.U., Joo, E.Y. ve Lee, K.J. (2019). Deep learning approaches for automatic detection of sleep apnea events from an electrocardiogram. *Computer Methods and Programs in Biomedicine*, 180, 105001.
- Faust, O., Acharya, U.R., Ng, E.Y.K. ve Fujita, H. (2016). A review of ECG-based diagnosis support systems for obstructive sleep apnea. *Journal of Mechanics in Medicine and Biology*, 16(1), 1640004.
- Flemons, W.W., Littner, M.R., Rowley, J.A., Gay, P., Anderson, W.M., Hudgel, D.W., McEvoy, R.D. ve Loubé, D.I. (2003). Home diagnosis of sleep apnea: A systematic review of the literature. *Chest*, 124(4), 1543-1579.
- Franklin, K.A. ve Lindberg, E. (2015). Obstructive sleep apnea is a common disorder in the population—a review on the epidemiology of sleep apnea. *Journal of Thoracic Disease*, 7(8), 1311-1322.
- Goldberger, A.L., Amaral, L.A., Glass, L., Hausdorff, J.M., Ivanov, P.C., Mark, R.G., Mietus, J.E., Moody, G.B., Peng, C.K. ve Stanley, H.E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, 101(23), e215-e220.
- Gold, A.R. ve Schwartz, A.R. (2003). The pharyngeal critical pressure: The whys and hows of using nasal continuous positive airway pressure diagnostically. *Chest*, 110(4), 1077-1088.
- Guimarães, K.C., Drager, L.F., Genta, P.R., Marcondes, B.F. ve Lorenzi-Filho, G. (2009). Effects of oropharyngeal exercises on patients with moderate obstructive sleep apnea syndrome. *American Journal of Respiratory and Critical Care Medicine*, 179(10), 962-966.
- Hannun, A.Y., Rajpurkar, P., Haghpanahi, M., Tison, G.H., Bourn, C., Turakhia, M.P. ve Ng, A.Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*, 25(1), 65-69.
- He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778.
- Heinzer, R., Vat, S., Marques-Vidal, P., Marti-Soler, H., Andries, D., Tobback, N., Mooser, V., Preisig, M., Malhotra, A., Waeber, G., Vollenweider, P., Tafti, M. ve Haba-Rubio, J. (2015). Prevalence of sleep-disordered breathing in the general population: the HypnoLaus study. *The Lancet Respiratory Medicine*, 3(4), 310-318.
- Huang, M.-L. ve Liao, Y.-C. (2023). Stacking ensemble and ECA-EfficientNetV2 convolutional neural networks on classification of multiple chest diseases including COVID-19. *Academic Radiology*, 30(9), 1915-1935.

- Ip, M.S.M., Lam, B., Lauder, I.J., Tsang, K.W.T., Chung, K.F., Mok, Y.W. ve Lam, W.K. (2004). A community study of sleep-disordered breathing in middle-aged Chinese men in Hong Kong. *Chest*, 119(1), 127-134.
- Johns, M.W. (1991). A new method for measuring daytime sleepiness: the Epworth sleepiness scale. *Sleep*, 14(6), 540-545.
- Kapur, V.K. (2010). Obstructive sleep apnea: diagnosis, epidemiology, and economics. *Respiratory Care*, 55(9), 1155-1167.
- Kapur, V.K., Auckley, D.H., Chowdhuri, S., Kuhlmann, D.C., Mehra, R., Ramar, K. ve Harrod, C.G. (2017). Clinical practice guideline for diagnostic testing for adult obstructive sleep apnea: An American Academy of Sleep Medicine clinical practice guideline. *Journal of Clinical Sleep Medicine*, 13(3), 479-504.
- Khalyfa, A., Capdevila, O.S., Buazza, M.O., Serpero, L.D., Kheirandish-Gozal, L. ve Gozal, D. (2013). Genome-wide gene expression profiling in children with non-obese obstructive sleep apnea. *Sleep Medicine*, 10(1), 75-86.
- Khalyfa, A., Kheirandish-Gozal, L., Khalyfa, A.A., Philby, M.F., Alonso-Álvarez, M.L., Mohammadi, M., Bhattacharjee, R., Terán-Santos, J., Huang, L., Andrade, J. ve Gozal, D. (2016). Circulating plasma extracellular microvesicle microRNA cargo and endothelial dysfunction in children with obstructive sleep apnea. *American Journal of Respiratory and Critical Care Medicine*, 194(9), 1116-1126.
- Khan, F., Yu, X., Yuan, Z. ve Rehman, A.U. (2023). ECG classification using 1-D convolutional deep residual neural network. *PLOS ONE*, 18(5), e0285106.
- Khandoker, A.H., Palaniswami, M. ve Karmakar, C.K. (2009). Support vector machines for automated recognition of obstructive sleep apnea syndrome from ECG recordings. *IEEE Transactions on Information Technology in Biomedicine*, 13(1), 88-96.
- Köktürk, O., Köktürk, N., Kanbay, Y., Ciftçi, T.U. ve Bukan, N. (1998). Sleep apnea prevalence in a Turkish adult population. *Turkish Journal of Medical Sciences*, 28, 187-192.
- Koley, B. ve Dey, D. (2013). Automatic detection of sleep apnea and hypopnea events from single channel measurements of respiration signal employing ensemble binary SVM classifiers. *Measurement*, 46(7), 2082-2092.
- Kushida, C.A., Littner, M.R., Morgenthaler, T., Alessi, C.A., Bailey, D., Coleman, J. Jr., Friedman, L., Hirshkowitz, M., Kapen, S., Kramer, M., Lee-Chiong, T., Loubé, D.L., Owens, J., Pancer, J.P. ve Wise, M. (2005). Practice parameters for the indications for polysomnography and related procedures: An update for 2005. *Sleep*, 28(4), 499-521.
- Laguna, P., Moody, G.B. ve Mark, R.G. (1998). Power spectral density of unevenly sampled data by least-square analysis: performance and application to heart rate signals. *IEEE Transactions on Biomedical Engineering*, 45(6), 698-715.
- Lévy, P., Kohler, M., McNicholas, W.T., Barbé, F., McEvoy, R.D., Somers, V.K., Lavie, L. ve Pépin, J.L. (2015). Obstructive sleep apnoea syndrome. *Nature Reviews Disease Primers*, 1, 15015.
- Malhotra, A. ve White, D.P. (2002). Obstructive sleep apnoea. *The Lancet*, 360(9328), 237-245.

- Marin, J.M., Carrizo, S.J., Vicente, E. ve Agusti, A.G. (2005). Long-term cardiovascular outcomes in men with obstructive sleep apnoea-hypopnoea with or without treatment with continuous positive airway pressure: an observational study. *The Lancet*, 365(9464), 1046-1053.
- Martín-Montero, A., Gutiérrez-Tobal, G.C., Kheirandish-Gozal, L., Jiménez-García, J., Álvarez, D., del Campo, F., Gozal, D. ve Hornero, R. (2020). Heart rate variability spectrum characteristics in children with sleep apnea. *Pediatric Research*, 89(7), 1771-1779.
- Mason, M., Welsh, E.J. ve Smith, I. (2013). Drug therapy for obstructive sleep apnoea in adults. *Cochrane Database of Systematic Reviews*, (5), CD003002.
- McEvoy, R.D., Antic, N.A., Heeley, E., Luo, Y., Ou, Q., Zhang, X., Mediano, O., Chen, R., Drager, L.F., Liu, Z., Chen, G., Du, B., McArdle, N., Mukherjee, S., Tripathi, M., Billot, L., Li, Q., Lorenzi-Filho, G., Barbe, F., Redline, S., Wang, J., Arima, H., Neal, B., White, D.P., Grunstein, R.R., Zhong, N. ve Anderson, C.S. (2016). CPAP for prevention of cardiovascular events in obstructive sleep apnea. *New England Journal of Medicine*, 375(10), 919-931.
- Mendonça, F., Mostafa, S.S., Ravelo-García, A.G., Morgado-Dias, F. ve Penzel, T. (2019). A review of obstructive sleep apnea detection approaches. *IEEE Journal of Biomedical and Health Informatics*, 23(2), 825-837.
- Mermigkis, C., Mermigkis, D., Varouchakis, G., Schiza, S. ve Panagou, P. (2009). Poincare plot in obstructive sleep apnoea patients before and after CPAP treatment. *European Respiratory Journal*, 34(5), 1197-1198.
- Myers, K.A., Mrkobrada, M. ve Simel, D.L. (2013). Does this patient have obstructive sleep apnea?: The Rational Clinical Examination systematic review. *JAMA*, 310(7), 731-741.
- Paul, J., Sharma, A., Sharma, V. ve Kumar, A. (2024). Real-time sleep apnea detection using feed-forward neural networks with single-channel ECG and SpO2 signals. *IEEE Journal of Biomedical and Health Informatics*, 28(2), 456-467.
- Penzel, T., Schöbel, C. ve Fietze, I. (2018). Big data in sleep medicine: opportunities and challenges. *Sleep Medicine Reviews*, 42, 85-94.
- Penzel, T., Moody, G.B., Mark, R.G., Goldberger, A.L. ve Peter, J.H. (2000). The apnea-ECG database. *Computers in Cardiology*, 27, 255-258.
- Penzel, T., McNames, J., Murray, A., de Chazal, P., Moody, G. ve Raymond, B. (2003). Systematic comparison of different algorithms for apnoea detection based on electrocardiogram recordings. *Medical and Biological Engineering and Computing*, 40(4), 1143-1151.
- Peppard, P.E., Young, T., Palta, M. ve Skatrud, J. (2000). Prospective study of the association between sleep-disordered breathing and hypertension. *New England Journal of Medicine*, 342(19), 1378-1384.
- Punjabi, N.M. (2008). The epidemiology of adult obstructive sleep apnea. *Proceedings of the American Thoracic Society*, 5(2), 136-143.
- Punjabi, N.M., Shahar, E., Redline, S., Gottlieb, D.J., Givelber, R. ve Resnick, H.E. (2004). Sleep-disordered breathing and mortality: a prospective cohort study. *PLoS Medicine*, 6(8), e1000132.

- Qin, H., Steenbergen, N., Glos, M., Wessel, N., Kraemer, J.F., Vaquerizo-Villar, F. ve Penzel, T. (2021). The different facets of heart rate variability in obstructive sleep apnea. *Frontiers in Psychiatry*, 12, 642333.
- Rahman, M.J., Mahajan, R. ve Morshed, B.I. (2018). Severity classification of obstructive sleep apnea using only heart rate variability measures with an ensemble classifier. 2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI), 33-36.
- Rajpurkar, P., Hannun, A.Y., Haghpanahi, M., Bourn, C. ve Ng, A.Y. (2017). Cardiologist-level arrhythmia detection with convolutional neural networks. arXiv preprint arXiv:1707.01836.
- Ramachandran, A. ve Karuppiyah, A. (2021). A survey on recent advances in machine learning based sleep apnea detection systems. *Healthcare*, 9(7), 914.
- Ramar, K., Dort, L.C., Katz, S.G., Lettieri, C.J., Harrod, C.G., Thomas, S.M. ve Chervin, R.D. (2015). Clinical practice guideline for the treatment of obstructive sleep apnea and snoring with oral appliance therapy: an update for 2015. *Journal of Clinical Sleep Medicine*, 11(7), 773-827.
- Redline, S. ve Tishler, P.V. (2000). The genetics of sleep apnea. *Sleep Medicine Reviews*, 4(6), 583-602.
- Rim, B., Sung, N.J., Min, S. ve Hong, M. (2020). Deep learning in physiological signal data: A survey. *Sensors*, 20(4), 969.
- Roche, F., Gaspoz, J.M., Court-Fortune, I., Minini, P., Pichot, V., Duverney, D., Costes, F., Lacour, J.R. ve Barthélémy, J.C. (1999). Screening of obstructive sleep apnea syndrome by heart rate variability analysis. *Circulation*, 100(13), 1411-1415.
- Saboisky, J.P., Stashuk, D.W., Hamilton-Wright, A., Carusona, A.L., Campana, L.M., Trinder, J., Eckert, D.J. ve Malhotra, A. (2012). Drug therapies for obstructive sleep apnoea: where are we now? *Drugs*, 72(9), 1217-1226.
- Sawyer, A.M., Gooneratne, N.S., Marcus, C.L., Ofer, D., Richards, K.C. ve Weaver, T.E. (2011). A systematic review of CPAP adherence across age groups: clinical and empiric insights for developing CPAP adherence interventions. *Sleep Medicine Reviews*, 15(6), 343-356.
- Schwartz, A.R., Patil, S.P., Laffan, A.M., Polotsky, V., Schneider, H. ve Smith, P.L. (2008). Obesity and obstructive sleep apnea: pathogenic mechanisms and therapeutic approaches. *Proceedings of the American Thoracic Society*, 5(2), 185-192.
- Setiawan, F. ve Lin, C.-W. (2022). Sleep apnea detection using biomedical signals from single-lead ECG based on empirical mode decomposition and convolutional neural network. *Biomedical Signal Processing and Control*, 80, 104365.
- Simonyan, K. ve Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Somers, V.K., White, D.P., Amin, R., Abraham, W.T., Costa, F., Culebras, A., Daniels, S., Floras, J.S., Hunt, C.E., Olson, L.J., Pickering, T.G., Russell, R., Woo, M. ve Young, T. (2008). Sleep apnea and cardiovascular disease: An American Heart Association/American College of Cardiology Foundation Scientific Statement. *Circulation*, 118(10), 1080-1111.
- Song, C., Liu, K., Zhang, X., Chen, L. ve Xian, X. (2016). An obstructive sleep apnea detection approach using a discriminative hidden Markov model from ECG signals. *IEEE Transactions on Biomedical Engineering*, 63(7), 1532-1542.

- Stein, P.K. ve Pu, Y. (1994). Heart rate variability, sleep and sleep disorders. *Sleep Medicine Reviews*, 16(1), 1376-1381.
- Strollo, P.J. Jr., Soose, R.J., Maurer, J.T., de Vries, N., Cornelius, J., Froymovich, O., Hanson, R.D., Padhya, T.A., Steward, D.L., Gillespie, M.B., Woodson, B.T., Van de Heyning, P.H., Goetting, M.G., Vanderveken, O.M., Feldman, N., Knaack, L. ve Strohl, K.P. (2014). Upper-airway stimulation for obstructive sleep apnea. *New England Journal of Medicine*, 370(2), 139-149.
- Sutherland, K., Lee, R.W.W. ve Cistulli, P.A. (2011). Obesity and craniofacial structure as risk factors for obstructive sleep apnoea: impact of ethnicity. *Respirology*, 17(2), 213-222.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z. (2016). Rethinking the inception architecture for computer vision. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2818-2826.
- Tareq, I., Elbagoury, B.M., El-Regaily, S. ve El-Horbaty, E.-S.M. (2022). Analysis of ToN-IoT, UNW-NB15, and Edge-IIoT Datasets Using DL in Cybersecurity for IoT. *Applied Sciences*, 12(19), 9572.
- Tripathy, R.K., Ghosh, S.K., Gajbhiye, P. ve Acharya, U.R. (2020). Development of automated sleep stage classification system using multivariate projection-based fixed boundary empirical wavelet transform and entropy features extracted from multichannel EEG signals. *Entropy*, 22(5), 535-541.
- Urtnasan, E., Park, J.-U., Joo, E.-Y. ve Lee, K.-J. (2018). Automated detection of obstructive sleep apnea events from a single-lead electrocardiogram using a convolutional neural network. *Journal of Medical Systems*, 42(6), 104.
- Wang, T., Lu, C., Shen, G. ve Hong, F. (2020). Sleep apnea detection from a single-lead ECG signal with automatic feature extraction through a modified LeNet-5 convolutional neural network. *PeerJ*, 8, e15813-15827.
- Weaver, T.E. ve Grunstein, R.R. (2008). Adherence to continuous positive airway pressure therapy: the challenge to effective treatment. *Proceedings of the American Thoracic Society*, 5(2), 173-178.
- Welch, P. (1967). The use of fast Fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms. *IEEE Transactions on Audio and Electroacoustics*, 15(2), 70-73.
- White, D.P. (2005). Pathogenesis of obstructive and central sleep apnea. *American Journal of Respiratory and Critical Care Medicine*, 172(11), 1363-1370.
- Xie, B. ve Minn, H. (2012). Real-time sleep apnea detection by classifier combination. *IEEE Transactions on Information Technology in Biomedicine*, 16(3), 469-477.
- Yaffe, K., Laffan, A.M., Harrison, S.L., Redline, S., Spira, A.P., Ensrud, K.E., Ancoli-Israel, S. ve Stone, K.L. (2011). Sleep-disordered breathing, hypoxia, and risk of mild cognitive impairment and dementia in older women. *JAMA*, 306(6), 613-619.
- Young, T., Skatrud, J. ve Peppard, P.E. (2002). Burden of sleep apnea: rationale, design, and major findings of the Wisconsin Sleep Cohort study. *Wisconsin Medical Journal*, 108(5), 893-900.
- Young, T., Palta, M., Dempsey, J., Skatrud, J., Weber, S. ve Badr, S. (2002). The occurrence of sleep-disordered breathing among middle-aged adults. *New England Journal of Medicine*, 328(17), 1217-1239.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı	Emre TURAN
E-Posta	

Eğitim

Lisans	2023, İzmir Bakırçay Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü
Yüksek Lisans	2023 - , İzmir Bakırçay Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği, Bilgisayar Mühendisliği Anabilim Dalı

Yayın Listesi

Makale	Turan, E. Er, O. 2025 Classification of Welch Periodograms Using Deep Learning Methods: A Case Study on the Prediction of Sleep Apnea (Accepted)
Bildiri	Turan, E. Er, O. 2024 IV. International Congress On Artificial Intelligence In Health. "Human Machine Interface" Proceedings Book. Sayfa 126

