

T.C.
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE EKG
SİNYALLERİNDE SOLUNUM TESPİTİ

YÜKSEK LİSANS TEZİ

Sona SEMSARİ PARAPARI

2200006616

Anabilim Dalı: Elektrik - Elektronik Mühendisliği

Program: Elektrik - Elektronik Mühendisliği

Tez Danışmanı: Doç. Dr. Esra SAATÇI

HAZİRAN 2025

T.C.
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE EKG SİNYALLERİNDE
SOLUNUM TESPİTİ

YÜKSEK LİSANS TEZİ

Sona SEMSARİ PARAPARI

2200006616

Anabilim Dalı: Elektrik - Elektronik Mühendisliği

Program: Elektrik - Elektronik Mühendisliği

Tez Danışmanı: Doç. Dr. Esra SAATÇI

Jüri Üyeleri: Prof. Dr. Aydın AKAN

Dr. Öğr. Üyesi Berrak ÖZTÜRK ŞİMŞEK

HAZİRAN 2025

ÖNSÖZ

Bu tez çalışması, lisansüstü eğitimim süresince edindiğim bilgi ve deneyimlerin bir ürünüdür. Bu süreçte katkı sağlayan, destek veren ve ilham kaynağı olan herkese şükranlarımı sunarım.

Öncelikle, tez danışmanım Doç. Dr. Esra SAATÇI'ya; bilimsel bakış açısı kazanmamda, araştırma sürecimi yönlendirmemde ve karşılaştığım zorluklarda yolumu aydınlatmadaki katkıları için en içten teşekkürlerimi sunarım. Kendisiyle çalışmak, akademik anlamda benim için büyük bir kazanç olmuştur.

Hayatım boyunca bana koşulsuz sevgi ve destek veren canım aileme minnettarım. Sabırları ve sevgileriyle her zaman yanımda olan sevgili anneme ve babama; her daim bana inanan ve güç veren sevgili eşime ve kalbimin bir parçası olan canım kardeşlerim Sorur ve Parisa'ya tüm kalbimle teşekkür ederim.

Ayrıca, karşılaştığım her sorunda yardım etmeye çalışan, desteğini hiç esirgemeyen sevgili dayım Rıza'ya da gönülden teşekkür ederim.

Ve son olarak, canım kızım Selin... Minik gülüşünle yorgunluğumu unutturan, varlığınla hayatıma anlam ve renk katan güzel kızım... Senin varlığın bana umut, cesaret ve ilham verdi. İyi ki hayatımdasın, iyi ki senin annenim.

Bu tezin alanına katkı sunmasını dilerim.

Haziran 2025

Sona SEMSARI PARAPARI

İÇİNDEKİLER

KISALTMALAR.....	iv
TABLO LİSTESİ.....	vi
ŞEKİL LİSTESİ	vii
SİMGE LİSTESİ	ix
KISA ÖZET	xii
ABSTRACT	xiii
1. GİRİŞ	1
1.1. Uyku Apnesi	1
1.2. Elektrokardiyogram	5
1.3. Önceki Çalışmalar	8
2. METOT.....	12
2.1. Veri Tabanı:	12
2.1.1. Veri Tabanı Listesi	12
2.1.2. Veri Tabanı Analizi	14
2.2. EKG Sinyallerinde Gürültü ve Artefaktlar.....	15
2.3. Ön İşleme	18
2.3.1. Sinyal Segmentasyonu	18
2.3.2. Veri Temizleme	19
2.3.3. Bant Geçiren Filtre.....	20
2.3.4. Savitzky-Golay Filtresi.....	25
2.4. Tepe tespiti için Pan-Tompkins Algoritması.....	28
2.4.1. Bant Geçiren Filtreleme.....	29
2.4.2. Türevleme (Differentiation).....	30
2.4.3. Kare Alma (Squaring).....	31
2.4.4. Hareketli Ortalama Filtresi (Moving Average Filter - MAF) ..	31
2.4.5. Adaptif Eşikleme ve Karar Verme Mekanizması (Dynamic Thresholding and Decision Logic)	32

2.5. R-R aralıkları	33
2.6. Elektrokardiyogramdan Türetilmiş Solunum (ECG Derived Respiration- EDR).....	35
3. MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE APNEA TESPİTİ.....	40
3.1. Öznitelik Çıkarma	40
3.1.1. Zaman, Frekans ve Doğrusal Olmayan Öznitelikler	40
3.1.2. Zaman-Frekans Alanından Elde Edilen Öznitelikler	45
3.1.3. Zaman-Frekans Alanı Analizi Kullanılarak Kardiyopulmoner Eşleşim (CPC).....	46
3.2. Makine Öğrenmesi.....	49
3.3. Rastgele Ormanlar ile Sınıflandırma	51
4. SONUÇLAR.....	59
4.1. Değerlendirme Metrikleri Sonuçları.....	59
4.2. mRMR ve Random Forest ile Nihai Model Değerlendirmesi.....	59
4.3. Özet ve Çıkarımlar	63
5. TARTIŞMA VE ÖNERİLER	65
5.1. Önceki Çalışmalar ile Kıyaslama	65
5.2. Öneriler ve Gelecek Çalışma.....	66
KAYNAKÇA.....	68
EKLER.....	77

KISALTMALAR

A	: Apnea
AHI	: Apne-Hipopne İndeksi
AI	: Yapay Zeka
ANN	: Yapay Sinir Ağları
ANS	: Otonom sinir sistemi
AUC	: Eğri Altında Kalan Alan
AV	: Atriyoventriküler
BPF	: Bant Geçiren Filtre
CNN	: Evrişimsel Sinir Ağları
CPC	: Kardiyopulmoner Eşleşme
CSA	: Santral Uyku Apnesi
CV	: Çapraz Doğrulama
CWT	: Sürekli Dalgacık Dönüştürücü
DB	: Veri Tabanı
DFA	: Düzeltilmiş Fluktuasyon Analizi
EDR	: EKG Türevli Solunum
EEG	: Elektroensefalogram
EKG	: Elektrokardiyogram
EMG	: Elektromiyogram
EOG	: Elektrookülogram
FFT	: Hızlı Fourier dönüşümü
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
HFC	: Yüksek Frekans Eşleşme
HR	: Kalp Atım Hızı
HRT	: Kalp Hızı Türbülansı
HRV	: Kalp Hızı Değişkenliği
HSAT	: Evde Uyku Apnesi Testleri
IIR	: Sonsuz Dürtü Yanıtlı Filtre
kNN	: k-en yakın komşu

LFC	: Düşük Frekans Eşleşme
LSTM	: Uzun-Kısa Süreli Bellek
MAF	: Hareketli Ortalama Filtresi
MatLab	: Matrix Laboratory
MCC	: Matthews Korelasyon Katsayısı
ML	: Makine Öğrenmesi
mRMR	: Minimum Gereksizlik Maksimum İlgililik
MSA	: Karışık Uyku Apnesi
N	: Normal
ODI	: Oksijen Desatürasyon İndeksi
OSA	: Obstrüktif Uyku Apnesi
PSG	: Polisomnografi
SG	: Savitzky-Golay Filtresi

TABLO LİSTESİ

Tablo 3.1.	EKG, RR Aralıkları ve EDR Sinyallerinden Zaman, Frekans ve Doğrusal Olmayan Özniteliklerden elde edilen özellikler.	43
Tablo 3.2.	Zaman-Frekans Alanı, Sürekli Dalgacık Dönüşümü ve CPC kullanılarak çıkarılmış öznitelikler.....	48
Tablo 4.1.	$TopK = 10$ için çıkarılmış sınıflandırma sonuçları.	61
Tablo 4.2.	$TopK = 15$ için çıkarılmış sınıflandırma sonuçları.	61
Tablo 5.1.	Benzer çalışmalar ve sonuçların karşılaştırılması tablosu.	66
Tablo Ek1.1.	Apne-EKG Veri tabanı kayıtları hakkında ek bilgiler.....	78

ŞEKİL LİSTESİ

Şekil 1.1.	Yapay üretilmiş EKG sinyali.	6
Şekil 2.1.	Ön işleme ve özellik çıkarma yöntemlerine ait blok diyagram.	13
Şekil 2.2.	Örnek bir anotasyon (Apne-Normal) belirtilmesi.	15
Şekil 2.3.	Hareket artefaktları ve elektrot teması gürültüsüne örnek EKG segmenti.	16
Şekil 2.4.	Kas Artefaktları gürültüsüne örnek EKG segmenti.	17
Şekil 2.5.	Kullanılan veri tabanından elde edilmiş baz çizgi kayması gürültüsü.	17
Şekil 2.6.	EKG ölçümü içermeyen segmente örnek.	19
Şekil 2.7.	Büyük oranda EKG morfolojisi bozulmuş segmente örnek.	20
Şekil 2.8.	Tasarlanmış Butterworth bant geçiren filtrenin sıfır-kutup diyagramı. Diyagramda 4 adet kutup ve 4 adet sıfır yer almaktadır. Kutupların bulunduğu noktalar Şekil üzerine yazılmıştır.	24
Şekil 2.9.	Tasarlanmış Butterworth bant geçiren filtrenin (a) genlik cevabı, (b) faz cevabı. Kesim frekansları, dijital açısal frekanstan frekansa (Hz) dönüştürülerek x-ekseninde gösterilmiştir.	24
Şekil 2.10.	Veri temziliği sonrasında sıfır fazlı bant geçiren filtre (a) öncesi EKG sinyali, $x(n)$ ve (b) sonrasındaki EKG sinyali, $y(n)$	26
Şekil 2.11.	EKG sinyal segment örneği (a) SG filtre öncesi, $y(n)$, (c) SG filtre sonrası, $z(n)$	29
Şekil 2.12.	Pan-Tompkins algoritması akış diagramı	29
Şekil 2.13.	Ön işleme çıkışında EKG sinyal segment örneği.	30
Şekil 2.14.	Türevleme sonunda EKG sinyal segmenti.	30
Şekil 2.15.	Kare alma sonunda EKG sinyal segmenti.	31
Şekil 2.16.	Hareketli ortalama filtre (MAF) çıkışı EKG sinyal segmenti.	32
Şekil 2.17.	a01, 10. EKG sinyal segmentinin (a) eşikleme sonrası R-tepeler işaretlenmiş, (b) aynı R-tepelerin sinyal üzerinde gösterilmiş hali.	32
Şekil 2.18.	EKG sinyal segmentinin (a) R-tepelerin sinyal üzerinde gösterilmiş hali, (b) R-R aralıkları zaman serisi.	34
Şekil 2.19.	Genlik modülasyonu yöntemi sonucu bulunan EDR zaman serisi.	36

Şekil 2.20.	QRS eğimi yöntemi sonucu bulunan EDR zaman serisi	37
Şekil 2.21.	QRS alan yöntemi sonucu bulunan EDR zaman serisi.....	38
Şekil 3.1.	Genleşme ve kaydırmaya örnek olarak iki dalgacık, $\psi_{a1,b1}(t)$ ve $\psi_{a2,b2}(t)$ zaman-frekans düzleminde temsili gösterilmiştir.	46
Şekil 3.2.	Öznitelik sayısına karşı eğitim seti çapraz doğruluk (mavi grafik) ve test seti doğruluk (turuncu grafik) değişimleri.	53
Şekil 3.3.	$topK = 15$ için kullanılan öznitelikler ve mRMR skor değerleri.	54
Şekil 4.1.	Tüm özellikleri kullanarak $topK = 15$ için elde edilen hata matrisi. .	60
Şekil 4.2.	Birleşik özelliklerde $topK = 15$ için PR eğrisi.....	63
Şekil 4.3.	Birleşik özelliklerde $topK = 15$ için ROC eğrisi.	64

SİMGE LİSTESİ

$x(n)$	: Bant geçiren filtre giriş sinyali
f_L	: Bant geçiren filtrenin alt kesim frekansı
f_H	: Bant geçiren filtrenin üst kesim frekansı
$H_a(j\Omega)$	: Butterworth filtre frekans cevabı
Ω	: Analog açısal frekans
Ω_c	: Prototif analog filtre kesim frekansı
N	: Prototif analog filtrenin derecesi
G_p	: Prototif analog geçirme bant hata parametresi
G_s	: Prototif analog durdurma bant hata parametresi
δ_p	: Prototif analog geçirme bant hatası
δ_s	: Prototif analog durdurma bant hatası
$H_a(s)$	: Analog alçak geçiren prototif filtre transfer fonksiyonu
Ω_L	: Analog bant geçiren filtre alt kesim frekansı
Ω_H	: Analog bant geçiren filtre üst kesim frekansı
B_Ω	: Analog bant geçiren filtre bant genişliği
Ω_0	: Analog bant geçiren filtre orta frekans
$H_{a_BP}(s)$	: Analog bant geçiren filtre transfer fonksiyonu
$H_{BP}(z)$	: Dijital bant geçiren filtrenin transfer fonksiyonu
$H_{BP}(e^{j\omega})$	: Dijital bant geçiren filtrenin frekans cevabı
$X(e^{j\omega})$	: Sıfır fazlı filtre giriş sinyalinin spektrumu
$V(e^{j\omega})$	: Sıfır fazlı filtre ara sinyalinin spektrumu
$Y(e^{j\omega})$	: Sıfır fazlı bant geçiren filtre çıkış sinyalinin spektrumu
$y(n)$	: Sıfır fazlı bant geçiren filtre çıkış sinyali
L_{sw}	: Savitzky-Golay filtre pencere uzunluğu
N	: Savitzky-Golay filtre polinom derecesi
a_k	: Savitzky-Golay filtre polinom katsayıları
A	: Savitzky-Golay filtre üstel matrisi
a	: Savitzky-Golay filtre polinom katsayı vektörü
Y	: Savitzky-Golay filtre üstel vektörü

$h_0(m)$	: Savitzky-Golay filtre dürtü cevabı
H	: Savitzky-Golay filtre matrisi
$H_{SG}(e^{j\omega})$	: Savitzky-Golay filtre frekans cevabı
f_c	: Savitzky-Golay filtre kesim frekansı
$z(n)$	: Pan-Tompkins algoritması giriş sinyali
$g_1(n)$	: Türevleme adımı giriş sinyali
$g_2(n)$	: Kare alma işlemi çıkış sinyali
$ekg(n)$	: Hareketli Ortalama Filtresi çıkış sinyali
L_{PW}	: Pan-Tompkins algoritması pencere uzunluğu
RR_i	: i. R-R aralıkları
R_i	: i. R-tepe
μ_{RR}	: Bir dakika boyunca hesaplanmış ortalama RR_i
$f_{s,yeni}$	: Yeniden örnekleme frekansı
$EDR_{genlik,i}$	: R-tepeler genliğinden çıkarılan EDR
$EDR_{eğim,i}$	: QRS eğim değişiminden çıkarılan EDR
$EDR_{alan,i}$	: QRS alan değişiminden çıkarılan EDR
$ort(EKG)$	: Ortalama EKG Sinyali
$max(EKG)$	: Maksimum EKG Değeri
$min(EKG)$	: Minimum EKG Değeri
$std(EKG)$	: EKG Standart Sapması
$ort(RR)$	: Ortalama RR Aralığı
$max(RR)$	: Maksimum RR Aralığı
$min(RR)$	: Minimum RR Aralığı
$std(RR)$	: RR Standart Sapması
$ort(HR)$	: Ortalama Kalp Atım Hızı
$P-t-P(RR)$	: Tepe Tepe Değeri
$ort(EDR_{genlik})$	: Ortalama EDR Genliği
$std(EDR_{genlik})$	: EDR Genlik Standart Sapması
$ort(EDR_{eğim})$	: Ortalama EDR Eğimi
$std(EDR_{eğim})$	: EDR Eğim Standart Sapması
$ort(EDR_{alan})$	: Ortalama EDR Alanı

$\text{std}(\text{EDR}_{\text{alan}})$	: EDR Alanı Standart Sapması
$f(\text{EDR}_{\text{alan}})$	: Solunum Frekansı
$\text{std}(\Delta_{\text{RR}})$	: RR Farklarının Standart Sapması
$n(\Delta_{\text{RR}>50})$	: 50ms'yi aşan RR farklarının sayısı
$\%(\Delta_{\text{RR}>50})$	: 50ms'yi aşan RR farklarının tüm RR sayısına
SD1	: Poincaré SD1
SD2	: Poincaré SD2
$\text{oran}(\text{SD1}, \text{SD2})$	: SD1 / SD2 Oranı
VLF(RR)	: Çok Düşük Frekans Gücü (0–0.04 Hz)
LF(RR)	: Düşük Frekans Gücü (0.04–0.15 Hz)
HF(RR)	: Yüksek Frekans Gücü (0.15–0.4 Hz)
$\text{power}(\text{RR})$	: Toplam HRV Gücü (0–0.4 Hz)
$\text{oran}(\text{LF}, \text{HF})$	: LF / HF Oranı
nLF	: Normalize Edilmiş LF
nHF	: Normalize Edilmiş HF
$\text{max}(f_{\text{power}})$	: Maksimum Güçte Frekans
$\text{power}(\text{RR}_{\text{band}})$	: Bant Güç (0.15–0.4 Hz)
H_{RR}	: Pseudo-Entropi
$\text{top}(\text{CPC})$	: Toplam Eşleşme Gücü
LF(CPC)	: Düşük Frekans Eşleşme Gücü
HF(CPC)	: Yüksek Frekans Eşleşme Gücü
$\text{oran}(\text{LF}, \text{HF}) (\text{CPC})$	: LF/HF Eşleşme Güç Oranı
H_{CPC}	: CPC Entropisi
$\text{std}(\text{CPC})$	: CPC Standart Sapması
$\text{max}(\text{CPC})$	: CPC Maksimum Değeri

Enstitüsü	:	Lisansüstü Eğitim Enstitüsü
Dalı	:	Elektrik-Elektronik Mühendisliği
Programı	:	Elektrik-Elektronik Mühendisliği
Tez Danışmanı	:	Doç. Dr. Esra SAATÇI
Tez Türü ve Tarihi	:	Yüksek Lisans – Haziran 2025

KISA ÖZET

Makine Öğrenmesi Yöntemleriyle EKG Sinyallerinde Solunum Tespiti

Sona SEMSARI PARAPARI

Bu tez çalışmasında, "Makine Öğrenmesi Yöntemleriyle EKG Sinyallerinde Solunum Tespiti" başlığı altında, uyku bozukluklarının klinik tanısında yalnızca tek kanallı elektrokardiyogram (EKG) sinyalleri kullanılarak Obstrüktif Uyku Apnesi (OSA) tespit edilmesi amaçlanmıştır.

Çalışmada kullanılan tek kanallı EKG sinyallerin ön işleme sürecinde, gürültü ve artefaktların giderilmesi amacıyla bant geçiren filtre ve Savitzky-Golay filtresi uygulanmıştır. Ardından, Pan-Tompkins algoritması kullanılarak R-tepeleri otomatik olarak tespit edilmiş ve R-R aralık zaman serisi elde edilmiştir. Elde edilen R-tepeleri ve ön işlenmiş EKG sinyalleri kullanılarak EKG Türevli Solunum (EDR) sinyalleri üç farklı formda (QRS Alan Varyasyonu, QRS Eğimi ve R-Tepe Genliği) türetilmiştir. Daha sonra, R-R aralıkları ve EDR sinyalleri kübik spline enterpolasyonu ile 4 Hz örnekleme frekansında yeniden örneklenmiştir.

Hem yeniden örneklenen sinyallerden hem ön işlenmiş EKG'den çeşitli öznitelikler çıkarılmıştır. Bununla birlikte, Sürekli Dalgacık Dönüşümü (CWT) yöntemi ile Kardiyopulmoner Eşleşme (CPC) hesaplanmıştır. Bu bağlamda, CPC matrisinden CWT tabanlı CPC öznitelikleri çıkarılmıştır.

Son aşamada, farklı formlarda elde edilen öznitelikler kullanılarak rastgele ormanlar makine öğrenmesi algoritması ile sınıflandırma işlemi gerçekleştirilmiştir. Öznitelik seçimi mRMR yöntemi kullanarak farklı durumlarda performans değerlendirmeleri yapılmıştır. Bu model, uyku esnasında her bir dakika da apne durumu olup olmadığını tespiti amacıyla uygulanmıştır. En yüksek başarı tüm özniteliklerin birlikte kullanıldığı ve topK = 15 seçiminin uygulandığı durumda elde edilmiştir. Bu durumda, modelin doğruluk değeri %88,99, duyarlılığı 0,88 ve özgüllüğü 0,897 olarak ölçülmüştür.

Anahtar Kelimeler: Apne, EDR, R-R aralıklar, CWT, Rastgele Ormanlar, Makine Öğrenmesi

Bilim Dalı Sayısal Kodu:

University	:	Istanbul Kültür University
Institute	:	Institute of Graduate Studies
Department	:	Electrical - Electronics Engineering
Programme	:	Electrical - Electronics Engineering
Supervisor	:	Doç. Dr. Esra SAATÇI
Degree Awarded and Date	:	MS – June 2025

ABSTRACT

Respiration Detection in ECG Signals Using Machine Learning Methods

Sona SEMSARI PARAPARI

In this thesis study, titled “Respiration Detection in ECG Signals Using Machine Learning Methods,” the aim was to detect Obstructive Sleep Apnea (OSA) using only single-lead electrocardiogram (ECG) signals for the clinical diagnosis of sleep disorders.

The single-channel ECG signals used in the study were preprocessed by applying a band-pass filter and the Savitzky-Golay filter to eliminate noise and artifacts. Subsequently, R-peaks were automatically detected using the Pan-Tompkins algorithm, and the R-R interval time series was obtained. Based on the detected R-peaks and preprocessed ECG signals, ECG-Derived Respiration (EDR) signals were generated in three forms: QRS area variation, QRS slope, and R-peak amplitude. The R-R intervals and EDR signals were then resampled at 4 Hz using cubic spline interpolation. Various features were extracted both from the resampled signals and the preprocessed ECG signals. Additionally, Cardiopulmonary Coupling (CPC) was computed using the Continuous Wavelet Transform (CWT). In this context, CWT-based CPC features were also derived from the CPC matrix.

In the final stage, classification was performed using the Random Forest machine learning algorithm using different sets of features. Feature selection was conducted using the mRMR method. The model was applied to identify the presence or absence of apnea events on a per-minute basis during sleep. The highest performance was achieved when all features were used together, with topK = 15. In this case, the model achieved an accuracy of 88.99%, a sensitivity of 0.88, and a specificity of 0.897.

Keywords: Obstructive Sleep Apnea, EDR, R-R intervals, CWT, Random Forest, Machine Learning

Science Code:

1. GİRİŞ

Uyku apnesi, uyku esnasında solunumun geçici olarak durması ya da anormal ve yüzeysel solunum epizotlarıyla karakterize edilen bir uyku bozukluğudur. Bu bozukluğun tespiti ve tanısında kullanılan mevcut standart yöntemlerin iyileştirilmesi ve alternatif yaklaşımların geliştirilmesine yönelik birçok çalışma yapılmış olmasına rağmen, henüz klinikte yaygın şekilde kullanılabilecek, altın standart niteliğinde yeni bir yöntem geliştirilememiştir. Bu tez çalışmasında ise yalnızca Elektrokardiyogram (EKG) sinyalleri kullanılarak solunum bozukluklarının tespiti ele alınmakta; bu doğrultuda, sinyal işleme ve makine öğrenmesi temelli bir yaklaşım önerilmektedir.

Tezin bu bölümünde, uyku apnesiyle ilgili temel kavramlara, hastalığın tanı ve tedavi yöntemlerine, özellikle bu çalışmada seçilmiş EKG'nin temellerine ve literatürde bu alanda yapılmış çalışmalara yer verilecektir. Tezin ikinci bölümünde, araştırmada kullanılan sinyal işleme yöntemleri ayrıntılı olarak açıklanmaktadır. Öznitelikler ve makine öğrenmesi adımları tezin üçüncü bölümünde yer alacaktır. Dördüncü bölümde elde edilen bulgular sunulmakta, beşinci ve son bölümde ise bu bulgular literatür ile karşılaştırılarak tartışılmakta ve çeşitli önerilerde bulunmaktadır.

1.1. Uyku Apnesi

Uyku apnesi temel olarak üç ana kategoriye ayrılır: obstrüktif, santral ve karışık uyku apnesi. Obstrüktif uyku apnesi (OSA), kişinin nefes alma çabasına rağmen trakea bileşenlerinin çökmesiyle birlikte burun yoluyla hava akışının azalması veya tamamen durmasıyla ortaya çıkar. Santral uyku apnesi (CSA) ise beynin merkezi solunum kontrol sistemindeki bir işlev bozukluğundan kaynaklanır; yani beyin, solunumdan sorumlu kaslara doğru sinyalleri gönderemez. Bu durum sıklıkla inme geçirmiş veya

beyin sapı hasarı olan hastalarda görülmektedir [1]. Karışık (Mixed) uyku apnesi (MSA), hem obstrüktif hem de santral apne bileşenlerini içeren bir uyku apnesi türüdür ve genellikle yaşlı bireylerde daha sık görülmektedir [2]. Bu türler arasında en yaygın olanı obstrüktif uyku apnesidir.

Obstrüktif Uyku Apnesi (OSA) tıkanmalar, oksijen doygunluğunun azalmasına (desatürasyon) veya uykunun bölünmesine neden olur. Bu durum, kesintili ve dinlendirici olmayan bir uykuya yol açar. Diğer belirtiler arasında yüksek sesli ve rahatsız edici horlama, uyku sırasında gözlenen apne epizodları ve aşırı gündüz uykululuğu yer almaktadır [3]. OSA, ayrıca kardiyovasküler sağlık, davranışsal bozukluklar, yaşam kalitesi ve araç kullanımı güvenliği üzerinde de önemli ölçüde olumsuz etkilere sahiptir [4].

OSA, ciddi olumsuz sonuçlara yol açabilen yaygın bir durumdur. Saatte 5 veya daha fazla olay tanımı kullanıldığında, OSA'nın dünya genelinde yaklaşık 1 milyar kişiyi etkilediği belirtilmektedir [5]. OSA prevalansı yaşla birlikte artar ve 50 yaş ve üzeri bireylerde kadınlar ile erkekler arasında benzer oranlara ulaşır. OSA'nın artan yaygınlığı, %14 ila %55 arasında değişen obezite oranlarıyla ilişkilidir [6].

OSA'nın tespiti ve tanısı için güvenilir ve invaziv olmayan yöntemlerin geliştirilmesi ve araştırılması önemli bir çalışma alanı haline gelmiştir, bu nedenle sonraki bölümlerde uyku apnesinin tespitine yönelik çeşitli yöntemler incelenecektir.

- Polisomnografi (PSG) hastanın uyku süresince çeşitli biyofizyolojik parametrelerinin invaziv olmayan sensör sistemleri aracılığıyla kaydedildiği kapsamlı bir ölçüm prosedürüdür. Bu yöntemle; beyin aktivitesi elektroensefalogram (EEG), göz hareketleri elektrookülogram (EOG), kas aktivitesi ve vücut hareketleri elektromiyogram (EMG), kardiyak aktiviteler (örneğin kalp atım hızı) elektrokardiyogram (EKG), kan oksijen satürasyonu (SpO₂) fotoelektrik pletismografi, nazal hava akımı pneumatograf, solunum eforu vücut pletismografisi ve horlama şiddeti gibi parametreler eş zamanlı olarak kaydedilmektedir. Tüm bu kayıtlar uzmanlarca değerlendirilmekte ve tanı konulmaktadır. PSG, uykuya bağlı solunum bozukluklarının ve OSA tanısında en güvenilir altın standart olarak kabul edilmektedir [7,8].

- Evde Uyku Apnesi Testleri (HSAT – Home Sleep Apnea Tests), OSA şüphesi olan bireylerin evde değerlendirilmesini sağlayan taşınabilir tanı araçlarıdır. Orta ve şiddetli OSA riski yüksek, ek hastalığı olmayan hastalar için uyku laboratuvarında yapılan polisomnografiye (PSG) göre daha pratik ve ekonomik bir alternatiftir. HSAT cihazları genellikle nazal hava akımı, solunum eforu, kan oksijen satürasyonu (SpO₂) ve kalp hızı gibi parametreleri kaydeder; bazı cihazlar vücut pozisyonu ve horlamayı da izler. EEG içermediği için uyku evreleri belirlenemez, bu da apne-hipopne indeksinin düşük tahmin edilmesine neden olabilir. HSAT'ler, orta ve şiddetli OSA tanısında PSG ile yüksek uyum sağlasa da, hafif vakalarda ve arousal ile ilişkili olayların tespitinde daha az duyarlıdır [9].
- Akıllı pijamalar, uyku apnesi gibi uyku bozukluklarını ev ortamında izlemek amacıyla geliştirilen, sensör entegreli giysilerdir ve geleneksel uyku çalışması ekipmanlarına olan ihtiyacı ortadan kaldırmayı hedeflemektedir. Cambridge Üniversitesi'nden araştırmacılar tarafından geliştirilen bu konforlu ve yıkanabilir akıllı pijamalar, uyku durumlarını tespit edebilme kapasitesine sahiptir. Pijamalar, boyun ve göğüs çevresine gevşek bir şekilde giyildiğinde bile, derideki küçük hareketleri algılayarak solunumun izlenmesini sağlayan baskılı kumaş sensörler içermektedir. Bu cihazlar sinyalleri işlemek için derin öğrenme kullanmaktadır. Şu anda akıllı pijamalar prototip aşamasındadır ve ticari olarak piyasada mevcut değildir. Ancak, gelecekte erişilebilir ve konforlu bir ev içi uyku izleme yöntemi sunma potansiyeline sahiptir [10].
- Nabız oksimetri, obstrüktif uyku apnesi (OSA) için uygun maliyetli ve erişilebilir bir tarama aracı olarak günümüzde kullanılmaktadır. Polisomnografi (PSG) kadar kapsamlı veri sunmamakla birlikte, sadece Oksijen Desatürasyon İndeksi (ODI) gibi metriklerle OSA varlığını gösterebilir. Pulse oksimetri, kan oksijen satürasyon düzeylerini ölçer ve uyku sırasında meydana gelen oksijen düşüşlerini tespit edebilir; bu düşüşler, OSA karakteristiğidir. Yapılan çalışmalar, evde gece boyunca gerçekleştirilen pulse oksimetri ölçümlerinin orta ve şiddetli OSA'yı taradığını göstermiştir. Bununla birlikte, pulse oksimetri doğrudan apne olaylarını veya solunum arousal'larını ölçmez; bu nedenle kesin bir tanı için genellikle PSG gibi ileri testler gereklidir [11].

- EKG sinyalleriyle otomatik apne teşhisi: Yukarıda bahsedilen yöntemlerin yüksek maliyetli olması ve herkes için ulaşılabilir olmaması sorunlarını aşmak amacıyla, Guillemineault ve arkadaşları 1984 yılında uyku apnesinin elektrokardiyogram (EKG) sinyalleri kullanılarak tespitini önermiştir [12] ve son 40 yılda EKG sinyalleri kullanarak, değişik sinyal işleme, Makine Öğrenmesi ve Derin öğrenme yöntemleriyle apne teşhis edilmesine çalışılmıştır ve zamanla daha yüksek performanslarla sonuçlar alınmıştır.

Obstrüktif Uyku Apnesi (OSA) başta olmak üzere uyku apnesinin ciddi sağlık sonuçları göz önünde bulundurulduğunda, bu tezde tek kanallı elektrokardiyografi (EKG) kullanılarak uyku apnesinin tespiti önerilmektedir. Bu yaklaşım, çeşitli pratik ve klinik avantajlara dayanmaktadır:

- EKG, klinik ve ev ortamlarında yaygın olarak kullanılan, standart ve invaziv olmayan bir yöntemdir. Ayrıca ek sensörlere ihtiyaç duymaması, uyku sırasında hastaya konfor sağlamaktadır.[13]
- Dünyada daha çok kişi için erişilirdir. [14]
- Evde EKG ile izleme, sınırlı yatak ve personel sayısına sahip uyku klinikleri ve hastanelerde kalma zorunluluğunu ortadan kaldırarak önemli bir avantaj sunmaktadır.
- Uyku çalışmaları için uzun bekleme sürelerini azaltma imkânı sağlamaktadır [15].
- Tek kanallı EKG cihazları, örneğin giyilebilir saatler, kompakt ve taşınabilir olmaları sayesinde uzun süreli evde izlemeye uygundur.
- EKG sinyalleri gerçek zamanlı olarak işlenebilir, bu da apne olaylarının kesintisiz tespiti açısından önemlidir ve giyilebilir teknolojilere veya mobil sağlık uygulamalarına entegre edilmelerini mümkün kılar. [16]
- Otomatik olarak sonuçlanıyor ve Makine öğrenmesi ve Derin öğrenme yöntemlerini kullanarak yukarı performansla apne ve çeşidini belirlenebilir. [17]
- Hasta için çok az maliyetli bir yöntemdir. [14].

1.2. Elektrokardiyogram

Obstrüktif Uyku Apnesi (OSA) tanısında kullanılabilecek biyofizyolojik sinyallerden biri olan elektrokardiyografi (EKG), kalbin elektriksel aktivitesini zaman içerisinde ölçen önemli bir tanı aracıdır. Kalp kasının kasılmasını sağlayan elektriksel uyarıların vücut yüzeyine iletilmesiyle elde edilen EKG sinyali, kardiyak fonksiyonların değerlendirilmesinde yaygın olarak kullanılmakta ve son yıllarda OSA gibi uyku bozukluklarının tespitinde de giderek artan bir öneme sahip olmaktadır.


Bu bölümde, EKG sinyalinin temel özellikleri, fizyolojik kaynakları ve karakteristik dalga formu bileşenleri ayrıntılı olarak ele alınacaktır. Ayrıca EKG sinyali üzerinden elde edilen ve OSA tespiti açısından önemli bilgiler sağlayan parametreler tanıtılacaktır. Bu kapsamda, RR aralıkları, Kalp Hızı Değişkenliği (Heart Rate Variability- HRV) ve EKG Türevli Solunum (Electrocardiogram-Derived Respiration- EDR) kavramlarına genel bir bakış sunulacaktır.

Söz konusu parametrelerin teorik temelleri, hesaplama yöntemleri ve uygulama süreçleri ise sırasıyla Bölüm 2.4, Bölüm 2.5 ve Bölüm 2.6’da ayrıntılı biçimde açıklanacaktır.

Kalbin elektriksel iletim sistemi, sinoatriyal (SA) düğüm, atriyoventriküler (AV) düğüm, His demeti ve Purkinje liflerinden oluşmakta olup, kalp kas dokusunun ritmik kasılmasını kontrol etmektedir [18]. SA düğümünde başlatılan elektriksel dürtüler bu iletim yolundan geçerek atriyum ve ventriküllerin depolarizasyon ve repolarizasyonuna neden olmaktadır. Bu elektriksel aktivite, vücut yüzeyine yerleştirilen elektrotlar aracılığıyla EKG sinyali şeklinde kaydedilmektedir. Şekil 1.1’de gösterilen EKG dalga formu; P dalgası, QRS kompleksi, T dalgası ve U dalgası olmak üzere dört temel bileşenden oluşmaktadır [19]. Her bir bileşen, belirli fizyolojik olayları temsil etmektedir:

- P dalgası: Atrial depolarizasyonu temsil eder.
- QRS kompleksi: Ventriküler depolarizasyonu gösterir.
- T dalgası: Ventriküler repolarizasyonu ifade eder.

- U dalgası: Purkinje liflerindeki repolarizasyonu ifade eder.



Şekil 1.1. Yapay üretilmiş EKG sinyali.

Ayrıca, PR aralığı, ST segmenti ve QT aralığı gibi parametreler, elektriksel iletim ve toparlanma evrelerinin zamanlamasını karakterize etmek için kullanılmaktadır.

EKG sinyalinin en önemli yapısal bileşeni olan QRS kompleksi sadece kalbin ventriküler aktivitesini temsil etmekle kalmayıp, aynı zamanda solunum ve otonom sinir sistemi işlevlerine dair ikincil sinyallerin çıkarımı açısından da kritik bir role sahiptir. Bu açıdan, EKG'den elde edilen parametreler ve yaklaşımlar aşağıda sıralanmıştır:

- QRS Kompleksi: QRS kompleksi, sağ ve sol ventriküllerin hızlı depolarizasyonunu temsil eder ve kalbin sistemik ve pulmoner dolaşıma kan pompalamasını sağlar. Bu kompleks, EKG dalga formunun en belirgin bölümü olup aşağıdaki üç ana bileşenden oluşur:
 - Q dalgası: Septumun depolarizasyonunu temsil eden ilk negatif sapma.
 - R dalgası: Ventrikül miyokardının büyük kısmının depolarizasyonunu gösteren pozitif sapma.
 - S dalgası: R dalgasını takiben gelen ve ventriküler depolarizasyonu tamamlayan negatif sapma.

QRS kompleksinin süresi, genliği ve morfolojisi, kalbin elektriksel iletimi ve yapısal bütünlüğü hakkında önemli bilgiler sunar. Normal QRS süresi 0.06~0.1 saniye arasında olup, bu değerin üzerindeki uzamalar intraventriküler ileti gecikmesi veya ventriküler hipertrofi gibi patolojilere işaret edebilir.

- RR Aralıkları (RR) ve Kalp Atım Hızı (HR): QRS kompleksinde yer alan ardışık R-dalgaları arasındaki süre, RR aralığı olarak tanımlanır ve kardiyak döngünün

düzenliliğini değerlendirmede temel ölçüttür. Aynı zamanda anlık kalp atım hızının hesaplanmasında kullanılır.

- Kalp Hızı Değişkenliği (HRV): HRV, RR aralıklarındaki fizyolojik varyasyonu nicel olarak ifade eden ve otonom sinir sistemi (ANS) aktivitesini değerlendirmede yaygın olarak kullanılan bir metriktir. Düşük HRV düzeyi, stres, kardiyovasküler hastalıklar ve özellikle OSA gibi bozukluklarla ilişkilendirilmektedir [20].
- EKG Türevli Solunum (EDR): QRS kompleksinin genlik ve şekil değişimleri, torasik empedanstaki dalgalanmalar ve ANS modülasyonuna bağlı olarak solunum döngüsüyle senkronize şekilde değişkenlik gösterebilir. Bu varyasyonlar kullanılarak EDR sinyali elde edilir. EDR, doğrudan solunum sensörü kullanılmadan, EKG üzerinden dolaylı olarak solunum izlenmesine olanak sağlar [20].
- Kardiyopulmoner eşleşme (CPC): CPC hem R-R aralıkları zaman serisi hem de EKG-türetilmiş solunum (EDR) zaman serisinden elde edilen bilgilerin bütünleştirilmesiyle elde edilir; böylece uykunun nicel kalitesinin değerlendirilmesi ve uyku sırasında solunum bozukluklarının tespiti mümkün hâle getirilmektedir. Ayrıca CPC, yalnızca kalp atım aralıkları (HRV) ya da yalnızca EDR sinyali üzerinden yürütülen tek değişkenli analizlerin yetersizliklerini gidermek amacıyla çift değişkenli bir zaman serisi analiz yöntemi olarak işlev görmektedir. Başka bir deyişle, HRV düzeyleri düşük olan bireylerde dahi EDR sinyali ile R-dalgası genliği arasındaki modülasyon korunmakta ve bu etkileşim CPC metriği aracılığıyla nicel olarak ifade edilerek obstrüktif uyku apnesi (OSA) tespiti için kullanılabilir. [21]

Ek olarak, EKG sinyali üzerinden Kalp Hızı Türbülansı (Heart Rate Turbulance - HRT), Poincare Grafiği Analizi ve Düzeltilmiş Fluktuasyon Analizi (Detrended Fluctuation Analysis - DFA) [22] gibi sinyalin zamansal ve yapısal karakteristiklerini inceleyerek OSA'nın tespitine ışık tutacak bilgiler sunan parametre ve ileri analiz yaklaşımları da bulunmaktadır.

1.3. Önceki Çalışmalar

Guilleminault ve arkadaşları 1984 yılında uyku apnesi sendromu ile ilişkili kalp hızı değişikliklerini gözlemlemişler ve 24 saatlik EKG izlemini tarama yöntemi olarak önermişlerdir. Bu öncü çalışma, sonrasında EKG tabanlı uyku apnesi tespiti yöntemlerini araştıran çalışmalara temel oluşturmuştur [12]. Bunu takiben, 1985 yılında Moody ve arkadaşları, [23] yüzeysel EKG kayıtlarından solunum sinyallerinin çıkarılabileceğini göstererek, EKG Türevli Solunum (EDR) kavramını ortaya koymuştur. Bu teknik, solunum paternlerinin invaziv olmayan bir şekilde değerlendirilmesini sağlamış ve EKG'nin uyku apnesi tespiti potansiyelini desteklemiştir [24]. Bu öncü iki çalışma, EKG tabanlı tanı araçlarının geliştirilmesinde önemli rol oynamış ve hem araştırma hem de klinik uygulamalarda önemli ilerlemelere katkı sağlamıştır.

Guilleminault ve arkadaşları çalışmanın sonuçlarının cesaretlendirmesiyle, [12] yüzey elektrokardiyogramlarından (EKG) elde edilen kardiyak interbeat aralıklarına (R-R aralıkları) dayalı olarak uykuya bağlı solunum olaylarını tespit etmeye yönelik çeşitli yöntemler önerilmiştir. Başlangıçta bu amaçla yalnızca sinyal işleme teknikleri kullanılmış; Fourier Analizi [25], Hilbert Dönüşümü [26] ve dalgacık ayrıştırılmış bantların entropisinin hızlı ve yaklaşık kestirimi [27] gibi yöntemler uygulanmıştır. Bu alandaki en erken sistematik araştırmalardan biri 2002 yılında gerçekleştirilmiş ve çeşitli algoritmaların EKG sinyallerinden apne olaylarını tespit etmedeki başarısı değerlendirilmiştir [28]. Bu çalışmada, R-R aralıklarındaki değişimlerin apneli ve apnesiz dönemleri etkili bir şekilde ayırt edebildiği gösterilmiştir.

İlerleyen yıllarda, makine öğrenmesi tekniklerinin apne sınıflandırmasında kullanılmıştır. 2009 yılında, R-R aralıklarından elde edilen zaman domen, frekans domen ve doğrusal olmayan özellikler kullanılarak destek vektör makineleri (SVM) ile sınıflandırma yapılmıştır [29]. Bu çalışmada yüksek sınıflandırma doğruluğu rapor edilmiş, bu da kalp atım değişkenliği (HRV) özelliklerinin ayırt edici gücünü göstermiştir.

2010 yılında, R-R aralığına dayalı özellik seçiminin optimize edilmesiyle SVM ve KNN tabanlı sınıflandırıcılar kullanarak %89 doğruluk elde edilmiştir [30].

2018 yılında ise R-R aralıklarının frekans domeni karakteristikleri hızlı Fourier dönüşümü (FFT) ile incelenmiş ve bu özelliklerle yapay sinir ağları (YSA) gibi sınıflayıcılar eğitilmiştir [31]. Önceki çalışmalara kıyasla sınıflandırma doğruluğu biraz daha düşük rapor edilmiş olsa da, duyarlılık oldukça yüksek bulunmuş ve bu durum, frekans temelli analizlerin tarama amaçlı kullanımda potansiyele sahip olduğunu göstermiştir.

Son yıllarda derin öğrenme teknikleri sayesinde fizyolojik zaman serilerindeki uzun dönemli bağımlılıkların modellenmesi mümkün hale gelmiştir. 2021 yılında, uzun-kısa süreli bellek (LSTM) ağları doğrudan R-R aralık dizilerine uygulanmış ve orta-şiddetli obstrüktif uyku apnesi (OSA) hastalarının tespitinde %100 duyarlılık ve özgüllük sağlanmıştır [32]. Bu, zaman serisi modellemesinin uyku apnesi tespitinde etkinliğini ortaya koymuştur.

Benzer bir yaklaşım 2022 yılında çok daha büyük bir klinik veri kümesinde doğrulanmıştır. Bu çalışmada, LSTM tabanlı modeller yalnızca R-R aralıkları kullanılarak şiddetli OSA taraması amacıyla eğitilmiş ve ROC eğrisi altında kalan alan (AUC) değeri 0.92 olarak elde edilmiştir [33]. Bu sonuç, derin öğrenme tekniklerinin bu alanda ölçeklenebilirliğini bir kez daha ortaya koymuştur.

2024 yılında ise çok görevli öğrenme (multi-task learning) çerçevesinde hem R-R aralıkları hem de solunum efor sinyallerinin kullanıldığı bir model önerilmiştir. Bu model, aynı anda apne-hipopne indeksi (AHİ) ve uyku evrelerini tahmin etmiş ve manuel olarak skorlanan AHİ değerleriyle yüksek korelasyon göstermiştir [34]. Elde edilen bulgular, birden fazla fizyolojik sinyalin bir arada kullanılmasının tespit doğruluğunu artırabileceğini göstermektedir.

EDR tanımının sunulduğunun ardından, 2009 yılında gerçekleştirilen bir çalışmada, EDR sinyallerinin spektral analizi kullanılarak uyku apnesi tespiti yapılmıştır. Bu çalışmada, R dalgası alanına dayalı EDR sinyalinin, apne epizotlarını tespit etmede yüksek özgüllük ve duyarlılık sağladığı rapor edilmiştir [35]. Başka bir çalışmada,

EDR'nin PSG ile karşılaştırıldığında uyku apnesi-hipopne sendromu (SAHS) tanısında yüksek bir uyum oranı sağladığı bulunmuştur. Bu çalışmada, EDR ile hesaplanan apne-hipopne indeksinin (AHI), PSG ile hesaplanan AHI ile yüksek korelasyon gösterdiği rapor edilmiştir [36]. Daha sonra tek kanallı EKG sinyalleri kullanılarak geliştirilen bir derin öğrenme modeli ile EDR ve HRV özellikleri birleştirilerek uyku apnesi tespiti yapılmıştır. Bu yöntemin, mevcut yöntemlere göre daha yüksek doğruluk sağladığı belirtilmiştir [37]. 2023 yılında yapılan bir çalışmada ise, EDR yerine doğrudan solunum eforu sinyallerinin kullanılmasıyla uyku bozukluklarının tespitinde daha yüksek performans elde edildiği rapor edilmiştir. Bu bulgu, EDR'nin solunum sinyallerinin yerini tam olarak alamayabileceğini göstermektedir [38]. Sonuç olarak, EDR sinyalleri, uyku apnesi tespitinde umut verici bir araç olarak değerlendirilmiştir. Ancak, EDR'nin doğrudan solunum sinyallerinin yerini alıp alamayacağı konusunda daha fazla araştırmaya ihtiyaç duyulmaktadır.

R-R aralık ve EDR'nin her birinin ayrı ayrı kullanmak apne tespitinin sınırlamalarına göze alarak, yeni araştırmalarda kardiyopulmoner eşleşme (CPC) analizi önerilmiştir. CPC analizi, kalp atım hızı değişkenliği (HRV) ve solunum sinyalleri arasındaki etkileşimi değerlendirerek, uyku sırasında meydana gelen solunum bozukluklarını tespit etmeyi amaçlamaktadır. Bu yöntem, özellikle elektrokardiyogram (EKG) sinyallerinden türetilen solunum (EDR) sinyalleri ile birlikte kullanıldığında, uyku apnesi tespitinde umut verici sonuçlar vermiştir.

2007 yılında gerçekleştirilen bir çalışmada, HRV özelliklerini knn makine öğrenmesi sınıflandırma yöntemi kullanarak yüzde 85 oranında doğruluk elde etmiştir [39].

EDR ve kalp atım hızı değişkenliği (HRV) yöntemleri birleştirilerek uyku bozukluklarının tespitini amaçlayan bir başka çalışma, bu kombinasyonun, uyku bozukluklarının taranmasında etkili bir araç olabileceği belirtilmiştir [40].

Tuncer ise Dalgacık Dönüştürücüden elde edilen öznitelikler için Rasgele Ormanlar (Random Forest) modeli kullanmıştır. [41].

Kardiyopulmoner eşleşme (CPC), hem R-R aralıkları zaman serisi hem de EKG-türetilmiş solunum (EDR) zaman serisinden elde edilen bilgilerin bütünleştirilmesiyle elde edilmekte; böylece uykunun nicel kalitesinin değerlendirilmesi ve uyku sırasında

solunum bozukluklarının tespiti mümkün hâle getirilmektedir. Geleneksel polisomnografi (PSG) yöntemine kıyasla, CPC yöntemi uygulanabilirlik açısından daha pratik bir alternatif sunmaktadır. Ayrıca CPC, yalnızca kalp atım aralıkları (HRV) ya da yalnızca EDR sinyali üzerinden yürütülen tek değişkenli analizlerin yetersizliklerini gidermek amacıyla çift değişkenli bir zaman serisi analiz yöntemi olarak işlev görmektedir. Başka bir deyişle, HRV düzeyleri düşük olan bireylerde dahi EDR sinyali ile R-dalgası genliği arasındaki modülasyon korunmakta ve bu etkileşim CPC metriği aracılığıyla nicel olarak ifade edilerek obstrüktif uyku apnesi (OSA) saptanabilmektedir. Bu kavramdan yola çıkılarak Wang ve arkadaşları tarafından SST-CPC adı verilen yeni bir yöntem önerilmiş; bu yöntemle elde edilen özellikler üzerinden çeşitli makine öğrenmesi sınıflandırma algoritmaları kullanılarak apne tespiti gerçekleştirilmiştir [42].

2. METOT

Bu bölüm altında, çalışmada kullanılan veri tabanı ve sinyal işleme yöntemleri olan R-tepe tespiti, RR aralığı ve EDR detaylı anlatılacaktır. Şekil 2.1’de ön işleme ve özellik çıkarma adımları akış diyagramı şeklinde özetlenmiştir. Makine öğrenmesi ile ilgili yöntem adımları bir sonraki bölümde yer alacaktır.

2.1. Veri Tabanı:

Çalışmanın ilk adımı amaca uygun, güvenilir ve kapsamlı bir veri tabanının seçilmesidir. Bu doğrultuda, ilgili literatürde yaygın olarak kullanılan EKG-Apnea veri tabanları değerlendirilmiş ve bu tez kapsamında analiz edilen veri kümesi ayrıntılı biçimde tanıtılmıştır.


2.1.1. Veri Tabanı Listesi

Literatürde, EKG ve OSA arasındaki ilişkiyi tespit için kullanılabilecek üç veri tabanı yayımlanmıştır: MIT-BIH Polysomnographic Veri tabanı [43], University College Dublin Uyku Apne Veri tabanı (UCD-DB) [44] ve PhysioNet Apne-EKG Veri tabanı [45].

A. MIT-BIH Polysomnographic Veri tabanı [43]

Bu veri seti, MIT'nin Beth Israil Hastanesi'nde Boston'da toplanmış olup, 32 ile 56 yaşları arasında 16 erkekten alınan 18 PSG kaydını içermektedir [46]. EKG sinyali, 250 Hz örnekleme hızıyla 12 bitlik çözünürlükle taşınabilir bir holter cihazı kullanılarak kaydedilmiştir. Uzman anotasyonları, her biri 30 saniye süren segmentlerde standartlaştırılmış kriterlere göre sağlanmıştır. Anotasyonlar, obstrüktif,

merkezi ve karışık olaylar gibi farklı apne türlerini ayrıntılı bir şekilde kategorize etmektedir.



Şekil 2.1. Ön işleme ve özellik çıkarma yöntemlerine ait blok diyagram.

B. University College Dublin Uyku Apne Veri tabanı [44]

Bu veri seti, St. Vincent Üniversitesi Hastanesi'nden alınmış olup, 28 ile 68 yaşları arasında 21 erkek ve 4 kadından alınan 25 PSG kaydını içermektedir [47]. EKG

sinyali, 125 Hz. örnekleme hızında kaydedilmiş, ancak niceliksel parametreler açıkça belirtilmemiştir. Her kayıt 6 ila 8 saat arasında değişen bir süreye sahiptir.

C. PhysioNet Apne-EKG Veri tabanı [45]

Bu veri seti, 27. Uluslararası Bilgisayar Kardiyoloji Konferansı 2000'de ilk kez yayımlanmış olup, tek kanallı EKG'den uyku apnesi tespiti için sunulmuştur [48]. Bu veri seti, alanındaki en çok başvurulmuş veri setlerinden biri olarak geniş çapta kabul görmüştür [49]. Toplamda 30 farklı kişiden alınan 70 EKG kaydını içermektedir, her bir kayıt 7 ila 10 saat arasında değişen sürelerdedir ve 25 erkek ile 5 kadından alınmıştır. EKG kayıtları 100 Hz. örnekleme hızıyla kaydedilmiş ve 200 A/D birimi/mV olarak ölçülmüştür.

Bu tez çalışmasında, daha geniş ve kapsamlı bir veri içeriğine sahip olması ve literatürde birçok bilimsel çalışmada yaygın olarak tercih edilmesi nedeniyle, Obstrüktif Uyku Apnesi (OSA) tespitinde PhysioNet Apnea-EKG veri tabanı kullanılmıştır.

2.1.2. Veri Tabanı Analizi

Veri tabanı, 35 kayıtlık bir eğitim seti (a01-a20, b01-b05 ve c01-c10) ve 35 kayıtlık bir test seti (x01-x35) olmak üzere toplam 70 kayıttan oluşmaktadır. Kayıtlar, her biri yaklaşık 7 saat ile 10 saat arasında değişen uzunluklara sahiptir. Her kayıt, bir EKG sinyali ve bir dizi apne anotasyonu içerir. Apne anotasyonları aynı anda kaydedilen solunum ve ilişkili sinyallere dayalı olarak uzmanlar tarafından türetilmiş bilgilerdir. Ayrıca, sekiz kayıt (a0, a02, a03, a04, b01, c01, c02 ve c03) dört ek sinyal ile sunulmuştur. Bu sinyaller indüktans piletismografisi kullanılarak elde edilen göğüs ve karın solunum sinyalleri, nazal termistörlerle ölçülen oronazal hava akımı ve oksijen saturasyonudur (SpO2). Veri tabanında yer alan tüm sinyaller 16 bit analog-dijital dönüştürücü kullanılarak, 100 Hz. frekans ile örneklenmiştir.

Veri tabanına erişmek ve kullanmak için PhysioNet WFDB (WaveForm DataBase) Yazılım Paketi kullanılmaktadır. “WFDB Toolbox for MATLAB and Octave”, PhysioBank veri tabanlarında kullanılan formatlarda fizyolojik sinyalleri ve zaman serilerini okumak, yazmak ve işlemek için bir dizi fonksiyon içeren bir koleksiyondur.

Apne anotasyon dosyası (aynı anda kaydedilen solunum ve ilişkili sinyallere dayalı olarak uzmanlar tarafından türetilen) apne olaylarını belirlemek için kullanılmaktadır. Bu dosyalarda, ilk anotasyon 0 saniyeye yerleştirilir ve bir sonraki bir dakikalık aralıklara ilişkilendirilir (yani kaydın başlangıcından itibaren 0~59.99 saniye). İkinci anotasyon 60 saniyeye yerleştirilir ve bir sonraki bir dakikalık aralıkla ilişkilendirilir (60-119,99 saniye), vb. Her "A" anotasyonu, ilgili dakikanın başında apnenin başladığını gösterir; her "N" anotasyonu, ilgili dakikanın başında apnenin olmadığını belirtir. Şekil 2.2’de örnek bir anotasyon belirtilmesi gösterilmiştir. Bu şekilde geçen zaman, sol kenardan olan uzaklıkla temsil edilmektedir. “*” karakterleri apne dönemlerini, ‘|’ karakterleri ise. apn anotasyonlarının zamanlarını, “N” harfleri apne olmayan (normal) segmenti, “A” harfi ise apne tespit edilen segmenti ifade etmektedir. Zaman, 0’inci dakikadan 8’ inci dakikaya kadar gösterilmektedir.



Şekil 2.2. Örnek bir anotasyon (Apne-Normal) belirtilmesi.


Bu çalışmada kullanılan anotasyonlar ile ilgili ek bilgiler Ek1 de bulunan Tablo Ek1.1 da sunulmuştur.

2.2. EKG Sinyallerinde Gürültü ve Artefaktlar

Elektrokardiyogram (EKG) sinyalleri, sinyal kalitesini düşüren ve hem klinik yorumlamayı hem de R-dalgası tespiti veya uyku apnesi sınıflandırması gibi otomatik analizleri olumsuz etkileyen çeşitli gürültü ve artefaktlar içerir. Bu bozulmalar; fizyolojik süreçlerden, çevresel etkenlerden veya veri toplama sisteminin teknik sınırlamalarından kaynaklanabilir. EKG kayıtlarında karşılaşılan başlıca gürültü kaynakları aşağıda yer almaktadır.

- **Hareket Artefaktları ve Elektrot Teması**

Hareket nedeniyle elektrotların yer değıştirmesi, deriyle zayıf teması, kuruyan iletken jel veya gevşek elektrotlar sinyalde kesilmelere, ani sıçramalara, sivri uçlu darbelere (spikes) veya büyük ölçüde bozulmalara neden olabilir. [50], [51]. EKG sinyalinin morfolojisini bozan bu artefaktlar, dijital filtreleme yöntemleriyle tam olarak temizlenemez; bu nedenle, artefakt içeren bölümlerin sinyalden ayıklanması gerekebilir. Şekil 2.3’de veri tabanından elde edilmiş bu çeşit bir gürültüye örnek gösterilmiştir.




Şekil 2.3. Hareket artefaktları ve elektrot teması gürültüsüne örnek EKG segmenti.

- **Kas Artefaktları (EMG Gürültüsü)**

Konuşma, istemsiz kas kasılmaları ve titreme gibi iskelet kası aktivitelerine bağlı olarak oluşan bu tür artefaktlar, genellikle EKG sinyalinin frekans içeriğinin dışında kalan yüksek frekans bantlarında ortaya çıkar [52]. Şekil 2.4’te veri tabanından elde edilmiş bu çeşit bir gürültüye örnek gösterilmiştir.

- **Cihaz Kaynaklı Gürültü**


EKG amplifikatörü veya analog-dijital dönüştürücülerden kaynaklanan gürültü yüksek frekans bölgesinde yer almaktadır ve dijital filtreler ile temizlenebilir [51].



Şekil 2.4. Kas Artefaktları gürültüsüne örnek EKG segmenti.

- **Baz Çizgi Kayması (Baseline Wander)**

Solunum, hareket ya da elektrot-deri empedansındaki değişikliklerden kaynaklanan bu artefaktlar, genellikle 0.5 Hz'in altındaki düşük frekanslı dalgalanmalardır ve ST segmenti ile T dalgası gibi önemli bileşenleri bozabilir [52]. Dijital filtreler yardımıyla temizlenebilen bu gürültüye örnek Şekil 2.5'te verilmiştir. Bu şekilde sinyalin şeklinin bozulmadan düşük frekanslı dalga ile salınım yaptığı gözlemlenebilir.



Şekil 2.5. Kullanılan veri tabanından elde edilmiş baz çizgi kayması gürültüsü.

- **Şebeke Paraziti**

Çevredeki alternatif akım kaynaklarının oluşturduğu elektromanyetik alanlardan kaynaklanan bu gürültü, genellikle 50 veya 60 Hz. frekans bandında yer alır ve dijital filtreler ile temizlenebilir [50].

2.3. Ön İşleme

Sinyal bütünlüğünü sağlamak, gürültü ve artefaktların etkilerini azaltmak ve özellik çıkarımının güvenilirliğini artırmak amacıyla tüm EKG kayıtlarına çeşitli ön işleme adımları uygulanmıştır.

2.3.1. Sinyal Segmentasyonu

Apne anotasyonlarının dakikalık doğası göz önünde bulundurularak, EKG sinyalleri bir dakikalık örtüşmeyen segmentlere ayrılmıştır. Bu işlem, EKG sinyallerinin incelenmesinde aşağıdaki maddelerde yer alan avantajları sağlar:

- Bir dakikalık segmentler, genellikle kısa süreli dalgalanmalar gösteren kısa vadeli kalp hızı değişkenliği (HRV) ve solunum hızının hesaplanmasına olanak tanır [20].
- Tüm EKG'yi aynı anda işlemek yüksek bellek ve hesaplama gerektirir. Sinyali daha küçük parçalara ayırmak, gerçek zamanlı veya toplu işlem yapmayı sağlar, bu da özellik çıkarımı (R-dalgaları, RR aralıkları, EDR) için daha verimlidir [53].
- EKG sinyalleri istatistiksel olmayan bir yapıya sahiptir, yani kalp hızı, genlik gibi özellikleri, çeşitli fizyolojik faktörlere bağlı olarak zaman içinde değişir. Sinyali daha kısa, sabit uzunluktaki aralıklara ayırmak, her segment içinde yerel istatistiksel denge varsayımını yapmayı kolaylaştırır. Bu varsayım, ön işleme tekniklerinin ve özellik çıkarım yöntemlerinin uygulanmasını basitleştirir ve daha güvenilir analizler sağlar [54].
- Bir dakikalık segmentler, yeterli bilgi toplamak ile hesaplama verimliliğini sağlamak arasında bir denge sağlar. Bu segmentler, birden fazla kalp döngüsünü kapsayacak kadar uzundur ve kalp hızı değişkenliği, QRS kompleks morfolojisi ve frekans düzlemi özellikleri gibi anlamlı özelliklerin çıkarılmasına olanak tanır. Bu tür özellikler, kardiyak olayların sınıflandırılması veya anormalliklerin tespiti amacıyla derin öğrenme modelleri için kritik girdilerdir [55].
- Makine öğrenmesi algoritmaları için mevcut eğitim örneklerinin sayısını artırır. Bu artış, derin öğrenme modellerini eğitmek için faydalıdır çünkü büyük veri


setleri, modellerin etkin bir şekilde genelleme yapabilmesi için gereklidir. Ayrıca, uniform segment uzunlukları, toplu işleme ve model mimarisi tasarımını basitleştirir [56].

Bu çalışmada, 35'i eğitim ve 35'i test olmak üzere toplam 70 EKG sinyali, her biri 1 dakika (60 saniye) uzunluğunda ve 6000 örnekten oluşan örtüşmeyen segmentlere ayrılmıştır. Her bir veri setinde, adetleri 100 ile 130 arasında değişen ve $x(n)$, $1 \leq n \leq 6000$ şeklinde gösterilen segment sinyal kümeleri bir sonraki adımda kullanılmak üzere hazırlanmıştır.


2.3.2. Veri Temizleme

Veri temizleme büyük veri tabanlarının işlenmesinde en önemli adımdır. Bu çalışmada veri temizliği iki aşamada gerçekleştirilmiştir. İlk aşamada, örnekleri Şekil 2.6 ve 2.7'de yer alan, ölçüm içermeyen veya ölçüm içerdiği halde büyük oranda morfolojik bozulmaların yer aldığı segmentlerin sinyal kümelerinden çıkarılması ele alınmıştır.

Büyük oranda ölçümlerin başladığı ilk dakikalar ile bittiği son dakikalar arasında yer alan bu bozuklukların atılmasıyla, orta bölümde yer alan 5 saatlik temiz bölüm seçilmiş ve bu segmentler üzerinde çalışılmıştır.



Şekil 2.6. EKG ölçümü içermeyen segmente örnek.



Şekil 2.7. Büyük oranda EKG morfolojisi bozulmuş segmente örnek.

İkinci aşamada, EKG sinyallerinde ani sıçramalar ve sivri uçlu darbelere (spikes) olarak görülen gürültülü kısımların temizlenmesi ele alınmıştır. Genel olarak literatürde Dalgacık Dönüşümü Yöntemleri (Wavelet Transform Method) [57] ve Uyarlamalı Filtreleme (Adaptive Filtering) [58] yöntemleriyle EKG sinyallerinden bu tip gürültü temizliği yapılmıştır. Fakat bu çalışmada genlik eşiği yöntemi kullanılmıştır. Fizyolojik olarak QRS kompleksinin genellikle 3 mV değerini aşmadığı kabulüne dayanılarak, eşik değeri iki katı olacak şekilde 6 mV seçilmiştir. [50][51].

Bu adımlar sonrasında, apne anotasyonları da temizlenmiş segmentlerle eşleştirilerek güncellenmiştir. Bu süreç sonucunda, yüksek kaliteli ve analiz için uygun bir EKG veri seti elde edilmiştir.

2.3.3. Bant Geçiren Filtre

EKG segmentlerinin, genlik eşiği yöntemiyle büyük genlikli ve EKG morfolojisini bozan gürültülerden temizlenmesinin ardından, düşük ve yüksek frekanslardaki bozucu etkilerin giderilmesi amacıyla sıfır fazlı bant geçiren filtre uygulanmıştır. Bu çalışmada, bant geçiren filtrenin alt ve üst kesim frekansları sırasıyla $f_L = 0.5 \text{ Hz}$ ve $f_H = 30 \text{ Hz}$ olarak seçilmiştir. Alt kesim frekansı, baz çizgisi kayması gibi düşük frekanslı gürültüleri baskılamayı; üst kesim frekansı ise kas artefaktları ve şebeke gürültüsü gibi yüksek frekanslı parazitleri elemeyi hedeflemektedir. Makine öğrenmesi aşamasında kullanılacak sinyallerin, EKG'nin QRS kompleksine dayanması nedeniyle, QRS kompleksinin tüm frekans bileşenleriyle birlikte gürültüsüz bir şekilde elde edilmesi gereklidir. Bu bağlamda seçilen $0.5 - 30 \text{ Hz}$ aralığı, QRS kompleksinin korunmasını sağlamaktadır.

- **Bant Geçiren Filtre Tasarımı**

Bu çalışmada MATLAB ortamında Butterworth tabanlı bir bant geçiren filtre tasarlanmış ve ileri-geri filtreleme (zero-phase filtering) yöntemiyle sıfır fazlı bir filtreleme gerçekleştirilmiştir. Butterworth filtre, Sonsuz Dürtü Yanıtlı (IIR) ve geçirme ile durdurma bantlarında monoton azalan karakteristiğe sahip bir analog filtredir [59]. Klasik tasarımda, N . dereceden Butterworth alçak geçiren filtrenin frekans cevabı aşağıdaki gibidir:

$$|H_a(j\Omega)|^2 = \frac{1}{1 + \left(\frac{\Omega}{\Omega_c}\right)^{2N}} \quad (2.1)$$

$$H_a(s)H_a(-s) = \frac{1}{1 + \left(\frac{s}{j\Omega_c}\right)^{2N}} \quad (2.2)$$

Burada Ω , analog açısal frekans (rad/s), Ω_c filtrenin genlik cevabının $1/\sqrt{2}$ 'ye düştüğü 3-dB kesim frekansı (rad/s) ve N filtrenin derecesidir. Butterworth alçak geçiren filtrenin karakteristikleri şu şekildedir [59]:

- $|H_a(j\Omega = 0)|^2 = 1$: Geçirme bandında düz frekans cevabı,
- $|H_a(j\Omega = \Omega_c)|^2 = 1/2$,
- $|H_a(j\Omega)|^2$ monoton şekilde azalır,
- N arttıkça ideal alçak geçiren filtreye yakınsar,
- $H_a(s)H_a(-s)$, $2N$ adet s -düzleminde:

$$p_k = \Omega_c e^{j\frac{\pi}{2N}(2k+N+1)}, k = 0, 1, \dots, 2N - 1 \quad (2.3)$$

noktalarında Ω_c yarıçapında bir çember üzerinde eşit aralıklarla sıralanmış kutuplara sahiptir.

Geçirme ve durdurma bantlarındaki hata parametrelerine göre filtre derecesi ve kesim frekansı aşağıdaki gibi hesaplanabilir:

$$N = \frac{1}{2} \frac{\log \frac{G_p}{G_s}}{\log \frac{\Omega_p}{\Omega_s}} \quad (2.4)$$

$$\Omega_c = \frac{\Omega_p}{(G_p)^{1/2N}} \quad (2.5)$$

Burada $G_p = \left(1/(1 - \delta_p)^2\right) - 1$ ve $G_s = \frac{1}{(\delta_s)^2} - 1$ sırasıyla geçirme ve durdurma bandları hataları parametreleridir.

Bu durumda, kararlı ve nedensel analog alçak geçiren prototip filtre $H_a(s)$ aşağıdaki şekilde ifade edilir:

$$H_a(s) = \frac{\Omega_c^N}{\prod_{LHP \text{ poles}} (s - p_k)} \quad (2.6)$$

Burada kutuplar sol yarım düzlemde seçilen kutuplardır.

Bu çalışmada MATLAB'in *butter* fonksiyonu kullanılmış ve bu sayede analog prototip filtre yerine doğrudan dijital bant geçiren filtre tasarımı yapılmıştır. Bu yöntem, doğrudan bant geçiren filtre dönüşümü ile gerçekleştirilir.

İlk olarak, ileri-geri filtreleme de göz önünde bulundurularak filter derecesi $N = 2$ olarak belirlenmiştir. Bu durumda, analog alçak geçiren prototip filtrenin sol yarım düzlemdeki kutupları (2.3) kullanılarak $p_0 = \Omega_c(-0.707 + j0.707)$ ve $p_1 = \Omega_c(-0.707 - j0.707)$ olarak bulunur. Analog alçak geçiren prototip filtrenin transfer fonksiyonu:

$$H_{a_LP}(s) = \frac{1}{(s + 0.7071 - j0.7071)(s + 0.7071 + j0.7071)} \quad (2.7)$$

Olarak bulunur. Burada 3-dB kesim frekansı $\Omega_c = 1 \text{ rad/s}$ olarak alınmıştır. Bir sonraki adım frekans dönüşümüyle alçak geçiren filtreden bant geçiren filtreye s-düzleminde dönüşümle ulaşılabilir [60]

$$s \rightarrow Q \frac{\hat{s}^2 + 1}{\hat{s}} \quad (2.8)$$

Burada $\hat{s} = s/\Omega_o$ orta frekans dönüşümünü sağlar ve $Q = \Omega_o/(\Omega_H - \Omega_L)$ analog filtrelerdeki kalite parametresidir.

Yukarıda açıklanan nedenlerle bant geçiren filtrenin, alt kesim frekansı $\Omega_L = 2\pi 0.5 \text{ rad/s}$ ve üst kesim frekansı $\Omega_H = 2\pi 30 \text{ rad/s}$ 'dır. Bant geçiren filtrenin bant genişliği $B_\Omega = \Omega_H - \Omega_L$ ile ve orta frekans Ω_o , alt ve üst kesim frekanslarının geometrik ortalaması alınarak hesaplanır. Bu durumda bant geçiren filtre parametrelerimiz aşağıdaki şekilde bulunmuş olur:

$$\begin{aligned} B_\Omega &= 59\pi \text{ rad/s} \\ \Omega_o &= 2\pi 1.9375 \text{ rad/s} \end{aligned} \quad (2.9)$$

Bu aşamada MATLAB'de analog frekansların f_s ile normalize edilerek filtre tasarım fonksiyonlarında kullanıldığını belirtmek isteriz. Diğer bir işlem de analog-dijital dönüşümünden önce alt ve üst kesim frekanslarının, Ω_L ve Ω_H ön çarpıtma (pre-wrapping) ile dönüştürülmesidir. Bu durumda, analog bant geçiren filtrenin transfer fonksiyonu aşağıdaki şekilde elde edilir:

$$H_{a_BP}(s) = \frac{29.62s^2}{(s + 3.8041 - j3.8935)(s + 3.8041 + j3.8935)(s + 0.0444 - j0.0455)(s + 0.0444 + j0.0455)} \quad (2.10)$$

Burada analog bant geçiren filtrenin derecesinin $N = 4$ 'e çıktığı görülür.


Analog bant geçiren filtrenin dijital bant geçiren filtreye dönüştürülmesinde bilinear dönüşüm uygulanmaktadır. Bu doğrusal olmayan dönüşüm $H_{a_LP}(s)$ 'de aşağıdaki değişim ile ulaşılabilir [59].

$$s \rightarrow 2f_s \frac{1 - z^{-1}}{1 + z^{-1}} \quad (2.11)$$


Sonuçta elde edilen dijital bant geçiren filtrenin transfer fonksiyonu:

$$H_{BP}(z) = \frac{0.3809z^4 - 0.7617z^2 + 0.3809}{z^4 - 1.597z^3 + 0.4553z^2 - 0.04789z + 0.1912} \quad (2.12)$$

Tasarlanmış filtrenin sıfırları her biri ikinci dereceden olacak şekilde $z = 1$ ($\omega = 0$) ve $z = -1$ ($\omega = \pi$) noktalarında, kutupları ise $z = 0.9781e^{j0.0076\pi}$ ve $z = 0.4471e^{j0.6313\pi}$ ile bunların eşleniklerinde yer almaktadır. Tasarlanan digital bant geçiren filtrenin sıfır-kutup diyagramı Şekil 2.8’de ve frekans cevabı ise Şekil 2.9’da çizdirilmiştir.



Şekil 2.8. Tasarlanmış Butterworth bant geçiren filtrenin sıfır-kutup diyagramı. Diyagramda 4 adet kutup ve 4 adet sıfır yer almaktadır. Kutupların bulunduğu noktalar Şekil üzerine yazılmıştır.



Şekil 2.9. Tasarlanmış Butterworth bant geçiren filtrenin (a) genlik cevabı, (b) faz cevabı. Kesim frekansları, dijital açısal frekanstan frekansa (Hz) dönüştürülerek x-ekseninde gösterilmiştir.

• Sıfır Fazlı Filtre Tasarımı

Tasarlanan IIR filtrenin, Şekil 2.9b’de görüldüğü gibi, faz cevabının bulunması EKG segmentlerinin morfolojisinde bozulmalara yol açmaktadır. Bu durum, QRS kompleksinin bozulmasına, kalp atımlarının zamanlamasının kaymasına ve R-peak

tespiti gibi özellik çıkarımlarının doğruluğunun azalmasına neden olduğu çeşitli çalışmalarda tespit edilmiştir. Bu problemi ortadan kaldırmak için sıfır fazlı filtreleme uygulanmaktadır [50].

Sıfır fazlı filtre, tasarlanmış filtrenin giriş sinyaline ileri-geri filtreleme uygulanarak gerçekleştirilir. Segmentasyon ve veri temizliği sonrasında bir segmentin $x(n)$, $1 \leq n \leq 6000$ şeklinde verildiğini varsayarsak, ileri filtre çıkışı $v(n)$ 'nin spektrumu (2.12)'de verilen bant geçiren filtrenin frekans cevabı, $H_{BP}(e^{j\omega})$ ile aşağıdaki şekilde ifade edilir:

$$V(e^{j\omega}) = H_{BP}(e^{j\omega})X(e^{j\omega}) \quad (2.13)$$

Filtre çıkışı zamanda ters çevrilerek ($v(-n)$) yine aynı $H_{BP}(e^{j\omega})$ filtresi ile filtrelenir ve çıkış sinyali $y(n)$, $1 \leq n \leq 6000$ elde edilir. Çıkış sinyalinin spektrumun

$$Y(e^{j\omega}) = |H_{BP}(e^{j\omega})|^2 X(e^{j\omega}) \quad (2.14)$$

Şeklinde olduğu kolayca gösterilebilir.

Şekil 2.10'da, sıfır fazlı bant geçiren filtre uygulanmadan önce ve sonra elde edilen sinyal segmentine ait bir örnek verilmiştir. Şekilden de görülebileceği üzere, düşük frekans bandındaki salınımlar başarılı bir şekilde bastırılmış, yüksek frekans bandındaki gürültüde ise belirgin bir iyileşme sağlanmıştır. Ancak bu iyileşme, RR aralığı ve QRS kompleksi tespitinde kullanılan algoritmalar için yeterli düzeyde değildir. Bu nedenle, bir sonraki aşamada EKG sinyalinin morfolojisinde minimum bozulma oluşturacak şekilde bir Savitzky-Golay filtresi tasarlanmış ve $y(n)$ sinyaline uygulanmıştır.


2.3.4. Savitzky-Golay Filtresi

Savitzky-Golay (SG) filtresi [61], EKG sinyallerinde RR aralığı ve QRS kompleksinin


doğru şekilde tespit edilebilmesi için gerekli olan sinyal yumuşatmasını sağlayan etkili bir yöntemdir. Bu yumuşatma işlemi, özellikle QRS kompleksi çevresindeki yüksek frekans bileşenlerinin bir sonraki adımda kullanılan Pan-Tompkins algoritmasındaki türev alma aşamasında aşırı büyümesini engellemek açısından kritiktir.

- **Satitzky-Golay Filtre Tasarımı**

SG filtresi, sıfır ortalamalı $L = 6000$ uzunluğunda giriş sinyaline $(y(n))$ uygulanmaktadır. Filtrenin temel amacı, her $m = 0$ noktasında, $p(m) = \sum_{k=0}^N a_k m^k$ şeklinde tanımlanan N . dereceden bir polinomun sinyale en iyi uyacak şekilde katsayılarını (a_k) bulmaktır.



(a)



(b)

Şekil 2.10. Veri temizliği sonrasında sıfır fazlı bant geçiren filtre (a) öncesi EKG sinyali, $x(n)$ ve (b) sonrasındaki EKG sinyali, $y(n)$.

Filtreleme işlemi, $L_{sw} = 2M + 1$ uzunluğundaki pencere içerisinde gerçekleştirilir. Bu işlem, polinom katsayılarını bulmak için aşağıdaki optimizasyon probleminin çözülmesini gerektirir.

$$\min_{\mathbf{a}} \|\mathbf{A}\mathbf{a} - \mathbf{Y}\|_2 \quad (2.15)$$

Burada yer alan matrisler:

$$\begin{aligned} \mathbf{A} &= \begin{bmatrix} (-M)^0 & \dots & (-M)^N \\ \vdots & \ddots & \vdots \\ (M)^0 & \dots & (M)^N \end{bmatrix} \\ \mathbf{a} &= [a_0 \quad \dots \quad a_N]^T \\ \mathbf{Y} &= [y(-M) \quad \dots \quad y(M)]^T \end{aligned} \quad (2.16)$$

şeklindedir ve çözüm

$$\mathbf{a} = \mathbf{H}\mathbf{Y} \quad (2.17)$$

olarak bulunur. Burada $\mathbf{H} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$ ifadesi sadece derece (N) ve pencere uzunluğuna ($2M + 1$) bağlı olarak sabit bir matristir. Boyutu $N + 1 \times 2M + 1$ 'dur. Eşitlik (2.17) aynı zamanda SG filtrenin çıkışıdır. Çıkışın sadece $m = 0$ noktasındaki polinom değerini dikkate alacak şekilde

$$z(0) = \sum_{m=-M}^M h_0(m)y(m) \quad (2.18)$$

ifade edilir. Burada $h_0(m)$ SG filtrenin dürtü cevabıdır ve uzunluğu pencere uzunluğuyla aynıdır. Aynı zamanda $h_0(m)$ yukarıdaki $\mathbf{H}$ matrisinin ilk satırıdır.

SG filtresinin birçok önemli özellikleri bulunmaktadır. Bunlar aşağıda özetlenmiştir [62]:

- $h_0(m)$ polinom yapıya sahiptir ve polinom derecesinin tek sayı olduğu noktalarda sıfıra eşit olması hesaplamalarda kolaylık sağlamaktadır,
- SG filtre derecesi $N = 0$ seçildiği durumda, SG filtresi hareketli ortalama (moving average) filtreye dönüşür,
- $h_0(m)$ 'in simetriktir, buda SG filtresinin doğrusal fazlı olmasını sağlar,
- $H_{SG}(z)$ 'in sıfırları birim çember üzerinde yer almaktadır,
- $H_{SG}(e^{j\omega})$ geçiş bandı Butterworth filtresine benzer şekilde düzdür,

- Kesim frekansları [62] da yer alan deneysel bulunmuş şekliyle $f_c = \frac{N+1}{3.2M-4.6}$ eşitliği kullanılarak hesaplanabilir,
- SG filtre derecesi N 'in 2,3 gibi küçük değerlerinde, durdurma bandı seviyesi $R_S \approx -11 \text{ dB}$ 'dir.

EKG sinyalindeki hızlı değişimlerin tespit edilebilmesi için pencere uzunluğu 100 ms olarak belirlenmiştir. Örnekleme frekansı kullanılarak ve pencere uzunluğunun tek sayılardan seçilmesi gerekliliği göz önünde bulundurularak pencerenin $L_{sw} = (0.1 \times 100) + 1 = 11$ örnek uzunluğunda olduğu bulunur. Polinom derecesi $N = 3$ olarak seçilmiş ve kesim frekansı $f_c \approx 17.4 \text{ Hz}$ olarak hesaplanmıştır.


Şekil 2.11a'de, SG filtresi uygulanmadan önceki sinyal olan $y(n)$, Şekil 2.10b'de sunulan sinyalin 134.1–134.2 dakikaları arasındaki bir bölümü büyütülerek gösterilmiştir. Aynı zaman aralığında SG filtresi uygulandıktan sonra elde edilen çıkış sinyali $z(n)$ ise Şekil 2.11b'de sunulmaktadır. Şekiller karşılaştırıldığında, SG filtresinin sinyalin şekil ve zamanlama bilgilerini koruduğu, ancak yüksek frekanslı bileşenleri başarılı bir şekilde bastırarak sinyali yumuşattığı açıkça görülmektedir. Ek olarak, SG filtresi uygulaması sonrasında, filtreleme işlemi nedeniyle oluşabilecek olası DC bileşenlerin giderilmesi amacıyla sinyalin ortalaması çıkartılmış ve böylece baz çizgisi düzeltilmesi gerçekleştirilmiştir.

2.4. Tepe tespiti için Pan-Tompkins Algoritması


Elektrokardiyogram (EKG) sinyalinde, her bir kalp atımı karakteristik bir QRS kompleksi ile temsil edilir. Kalp ritminin izlenmesi ve EKG sinyalinden türetilen özelliklerin hesaplanması için, QRS komplekslerinin doğru bir şekilde tespiti temel bir adımdır. Bu kompleksin en belirgin ve en sivri noktası olan R-dalgası, kalp kasının ventriküler depolarizasyonunun başladığı anı gösterir. Bu nedenle, R-tepe noktalarının tespiti kalp atım sürelerinin belirlenmesinde ve kalp ritim analizlerinde temel oluşturur. Özellikle uyku apnesi tanısında, solunum paternlerinin analizinde kullanılan kalp atım aralıkları (RR interval) doğrudan R-tepe noktalarına dayandığı için, bu tepe noktalarının hassas bir şekilde belirlenmesi kritik öneme sahiptir. Bu çalışmada, R-tepe noktalarının tespiti için Pan-Tompkins algoritması [63] kullanılmıştır.

Pan-Tompkins algoritması, 1985 yılında Jiapu Pan ve Willis Tompkins tarafından geliştirilmiş ve ilk olarak gerçek zamanlı EKG analizi için önerilmiştir [63]. Gerçek

zamanlı çalışabilirlik, düşük işlem karmaşıklığı ve yüksek doğruluk oranı, algoritmanın tercih edilme nedenleri arasında yer almaktadır.




(a)



(b)

Şekil 2.11. EKG sinyal segment örneği (a) SG filtre öncesi, $y(n)$, (c) SG filtre sonrası, $z(n)$.

Şekil 2.12’de yöntemin adımları akış diyagramı şeklinde özetlenmiştir.




Şekil 2.12. Pan-Tompkins algoritması akış diyagramı

Pan-Tompkins algoritması, EKG sinyalinin R-tepelerini tespit etmek için birbirini izleyen bir dizi sinyal işleme adımından oluşur:

2.4.1. Bant Geçiren Filtreleme

QRS kompleksleri yaklaşık 5–15 Hz frekans bandında yoğunlaştığı için, düşük frekanslı temel kaymaları ve yüksek frekanslı gürültüleri bastırmak amacıyla bir bant

geçiren filtre uygulanır. Bu çalışmada bu adım, 0.5–30 Hz Butterworth bant geçiren filtre ile önceden gerçekleştirilmiştir. Bant geçiren filtrenin çıkış sinyaline uygulanan Savitzky-Golay filtresi sonrasında elde edilen EKG sinyali $z(n)$ Pan-Tompkins algoritmasının girişi olarak kabul edilmiştir. Şekil 2.13’de tipik bir $z(n)$ sinyali gösterilmiştir.




Şekil 2.13. Ön işleme çıkışında EKG sinyal segment örneği.

2.4.2. Türevleme (Differentiation)

Türevleme, EKG sinyalinin zamana göre değişimini analiz ederek eğim bilgisinin elde edilmesini sağlar. Bu işlem, özellikle QRS kompleksinin hızlı yükselip düşen bileşenlerinin daha belirgin hale gelmesine yardımcı olur. Orijinal çalışmada [63], aşağıda verilen 2 noktalı ileri fark yaklaşımıyla türevleme filtresi kullanılmıştır:

$$g_1(n) = z(n + 1) - z(n) \quad (2.19)$$

Burada $z(n)$ ve $g_1(n)$ sırasıyla türevleme adımının giriş ve çıkış sinyallerini temsil eder. Şekil 2.14’de, Şekil 2.13’de gösterilen sinyalin türevlenmiş hali sunulmuştur. Bu şekilde, R tepe noktalarının yer aldığı hızlı değişim bölgelerinin daha belirgin hale geldiği gözlemlenebilir.




Şekil 2.14. Türevleme sonunda EKG sinyal segmenti.

2.4.3. Kare Alma (Squaring)

Kare alma adımı, sinyalin tüm örneklerinin karesi alınarak negatif değerler pozitif hale getirilir ve genlikle orantılı olarak yüksek değişimlere vurgu yapılır. Bu işlem, QRS kompleksinin genlik açısından baskın hale gelmesini ve diğer bileşenlerden daha kolay ayırt edilmesini sağlar. Şekil 2.15'te kare alma işlemi sonrasında belirgin hale gelmiş R tepe değerleri görülebilir.

$$g_2(n) = (g_1[n])^2 \quad (2.20)$$




Şekil 2.15. Kare alma sonunda EKG sinyal segmenti.

2.4.4. Hareketli Ortalama Filtresi (Moving Average Filter - MAF)

Karelenmiş sinyal, bir örnek adımlarla kaydırılan sabit uzunlukta bir pencere boyunca, hareketli ortalama yöntemiyle filtrelenir. Bu işlem, QRS komplekslerinin süresi boyunca enerji yoğunluğunun izlenmesini sağlar ve kare alma adımıyla kaynaklanan kısa süreli varyasyonları baskılar. Genellikle pencere uzunluğu yaklaşık 150 ms (örnekleme oranına bağlı olarak 15–30 örnek) olarak seçilir [63].

$$ekg(n) = \frac{1}{L_{PW}} \sum_{i=0}^{L_{PW}-1} g_2[n-i] \quad (2.21)$$


Burada L_{PW} pencere uzunluğudur ve $L_{PW} = 100 \times 0.15 = 15$ örnek olarak seçilmiştir. Şekil 2.16'da bu adım sonunda elde edilen sinyal gösterilmiştir.




Şekil 2.16. Hareketli ortalama filtre (MAF) çıkışı EKG sinyal segmenti.

2.4.5. Adaptif Eşikleme ve Karar Verme Mekanizması (Dynamic Thresholding and Decision Logic)

Bu adımda, son adımdaki ortalananmış sinyal $EKG(n)$, üzerine adaptif eşikler uygulanarak potansiyel R-tepe noktaları tespit edilir. Eşikler, işlenen sinyal segment genliği ortalaması ve genlik değişimine göre ($eşik = \langle EKG(n) \rangle + 0.5std(EKG(n))$) güncellenir. R-tepe olarak kabul edilen tepelere ait indeksler bir sonraki adım olan R-R aralıkları için saklanır [51]. Her bir segmentte R-tepe adetleri (M) farklılık gösterir.



(a)



(b)

Şekil 2.17. a01, 10. EKG sinyal segmentinin (a) eşikleme sonrası R-tepeler işaretlenmiş, (b) aynı R-tepelerin sinyal üzerinde gösterilmiş hali.

2.5. R-R aralıkları

Bir EKG sinyalinde QRS kompleksinin en yüksek noktası olan R-dalgası, ventriküler depolarizasyonun başlangıcını ifade eder ve kalp atımının zamanlaması açısından referans noktası olarak kabul edilir [52]. R-R aralığı, ardışık iki R-dalgası tepe noktası arasındaki zaman farkı olarak tanımlanır:

$$RR_i = t_{R_{i+1}} - t_{R_i} \quad (2.22)$$

Burada RR_i i . zaman anındaki R-R aralığını saniye cinsinden ifade eder. t_{R_i} ve $t_{R_{i+1}}$ sırasıyla i . ve $i + 1$. R-tepe noktalarının zaman anlarını göstermektedir. Pan-Tompkins algoritmasıyla tespit edilen tepe noktalarının örnek indeksleri olan R_i ve R_{i+1} kullanılarak aşağıdaki şekilde hesaplanır:

$$\begin{aligned} t_{R_i} &= \frac{R_i}{f_s} \\ t_{R_{i+1}} &= \frac{R_{i+1}}{f_s} \end{aligned} \quad (2.23)$$

Bir segment işlendiğinde elde edilen R-R aralıkları zaman serisine, $RR_i, 1 \leq i \leq M$, örnek Şekil 2.18'de yer almaktadır. RR_i 'nin değişiminin iyi gözlenebilmesi amacıyla 2 segment (2 dakika) birleştirilerek gösterilmiştir. R-R aralık adeti olan M her segment için farklı değerler almaktadır.

Kalp atım hızı (Heart Rate - HR) ile R-R aralıkları arasında aşağıdaki ilişki bulunmaktadır:


$$HR = \frac{60}{\mu_{RR}} \quad (2.24)$$

Burada μ_{RR} bir dakika (60 saniye) boyunca hesaplanmış ortalama RR_i değerleridir. Bu nedenle kalp atım hızı kalbin ortalama atım sayısını vermektedir.

Kalp hızı değişkenliği (Heart Rate Variability- HRV), anlık R-R aralıklarının zamanla

değişimine dayanan bir ölçümdür ve kalp atım hızının zamanla nasıl değiştiğini ifade eder.

R-R aralıklarının analizi, özellikle otonom sinir sistemi aktivitesini değerlendirmek ve kardiyak düzenlilik hakkında bilgi edinmek amacıyla kullanılmaktadır. Uyku apnesi gibi solunum bozukluklarında, apne epizotları sırasında kalp hızı değişiklik göstermekte, bu da RR aralıklarında karakteristik varyasyonlara yol açmaktadır [64]. Bu nedenle, RR aralıkları uyku apnesi tespiti gibi uygulamalarda biyobelirteç olarak kullanılmaktadır [52].



Şekil 2.18. EKG sinyal segmentinin (a) R-tepelerin sinyal üzerinde gösterilmiş hali, (b) R-R aralıkları zaman serisi.

- **R-R aralıklarında sinyal temizleme**

R-R aralıklarına ait zaman serilerinin tüm veride hesaplanması sonrasında, bu serilerin EKG sinyalini temsil edebilmeleri ve makine öğrenmesi algoritmalarında güvenilir şekilde kullanılabilmesi amacıyla iki aşamalı bir ön işleme süreci uygulanmıştır. İlk aşamada, fizyolojik olarak geçersiz R-R aralıkları seçilmiş ve zaman serisinden çıkarılmıştır. Ek olarak, Bölüm 2.4.'de anlatılan Pan-Tompkins algoritmasının 4. adımında yer alan ve (2.21) eşitliğiyle tanımlanmış hareketli ortalama filtresine (MAF)

benzer filtre, R-R aralığı zaman serilerine uygulanmıştır. Bu çalışmada, pencere boyu [42] de yer aldığı gibi $L_{PW} = 41$ örnek olarak seçilmiştir. MAF'de her bir segment için hesaplanmış RR_i 'lerin ortalamasının $\pm\%20$ dışına çıkan RR_i değerleri de dışlanmıştır. Bu filtreleme aşaması, veri serisinin hem fizyolojik gerçekliğini korumayı hem de makine öğrenmesi algoritmaları için daha kararlı ve güvenilir bir özellik uzayı sağlamayı amaçlamaktadır.

İkinci aşama, RR_i zaman serilerinin boyutlarını eşitlemek ve sabit uzunlukta vektörler haline getirmek amacıyla kübik spline interpolasyon uygulanmasını kapsamaktadır. Bu işlem, farklı uzunluktaki sinyalleri karşılaştırılabilir hale getirmek ve makine öğrenmesi algoritmalarında kullanılabilir sabit boyutlu özellik vektörleri oluşturmak için gereklidir. Bu aşamada [42] de yer aldığı gibi yeniden örnekleme frekansı $f_{s,yeni} = 4 \text{ Hz}$ seçilmiştir. Buna göre, her bir RR_i zaman serisi, 60 saniyelik bir segment, 240 örnek nokta ile temsil edilmiştir. Böylece tüm segmentler sabit boyutta olup hem zaman çözünürlüğü korunmuş hem de boyutsal tutarlılık sağlanmıştır.

2.6. Elektrokardiyogramdan Türetilmiş Solunum (ECG Derived Respiration-EDR)

Elektrokardiyogramdan (EKG) Türetilmiş Solunum (EDR), solunum aktivitesinin doğrudan EKG sinyalinden elde edilen özellikler aracılığıyla tahmin edilmesini ifade etmektedir. Bu yöntem, ek sensör gereksinimi olmadan, solunum bilgisinin girişimsel olmayan bir şekilde elde edilmesini mümkün kıldığından, klinik ve biyomedikal sinyal işleme alanlarında önemli bir potansiyele sahiptir. Özellikle solunuma özgü sensörlerin mevcut olmadığı ya da güvenilirliğinin sorgulandığı durumlarda, EDR yöntemi gerçek solunum sinyaline ilişkin anlamlı bir alternatif sunmaktadır.

Solunum, torasik empedans değişiklikleri, kalbin anatomik konumundaki solunuma bağlı yer değiştirmeler ve otonom sinir sistemi etkileri aracılığıyla EKG sinyallerinin morfolojisini modüle etmektedir. Bu fizyolojik etkiler, solunum sinyalinin yeniden yapılandırılmasında temel alınabilecek bilgi kaynaklarıdır [23].

Bu çalışmada, literatürde yaygın olarak kullanılan üç farklı EKG'den Türetilmiş

Solunum (EDR) tahmin yöntemi uygulanmıştır: R-tepe genlik yöntemi, QRS kompleks eğim yöntemi ve QRS alan değişimi yöntemi. Her üç yöntemde de, giriş sinyali olarak Bölüm 2.4'te açıklanan Pan-Tompkins algoritmasının 4. adımında elde edilen hareketli ortalama filtresi çıkışı, yani Şekil 2.16'da gösterilen $ekg(n)$ sinyali kullanılmıştır. Buna ek olarak, EKG sinyalleri üzerinde Pan-Tompkins algoritması aracılığıyla tespit edilen R-tepe noktalarının indeks bilgileri de her yöntemde temel parametre olarak değerlendirilmiştir.


- **Yöntem 1: R-Tepe Genlik Modülasyonu**

En eski ve en basit EDR yöntemlerinden biri, solunumun R-tepe genliği üzerindeki modülasyonuna dayanmaktadır. Soluk alıp verme sırasında torasik empedansın ve kalp ekseninin değişmesi, kalbin elektriksel eksenini etkileyerek R-tepe genliğinde dalgalanmalara neden olur [23]. Bu yöntemde, Pan-Tompkins algoritması ile tespit edilen $ekg(n)$ sinyali üzerindeki tepe değer indeksleri R_i kullanılarak, tepe genlikleri $ekg(R_i)$, $1 \leq i \leq M$ elde edilir. Bu örnekler, EDR sinyalinin ayrık zamanlı örneklerini oluşturmaktadır:

$$EDR_{genlik,i} = ekg(R_i) \quad (2.25)$$

Şekil 2.19'da, doğrusal enterpolasyon yöntemi ile bu örneklerden elde edilen EDR sinyalinin a01 numaralı kayıt için 2 dakikalık bir kesiti sunulmuştur.

Daha sürekli ve fizyolojik olarak anlamlı bir solunum dalga formu elde edebilmek için, Bölüm 2.5'te açıklandığı üzere, kübik spline enterpolasyon yöntemi uygulanmıştır. Bu yöntem, EDR sinyalinin zamansal sürekliliğini sağlarken solunum döngüsünün yumuşak geçişlerle temsil edilmesine olanak tanımaktadır.



Şekil 2.19. Genlik modülasyonu yöntemi sonucu bulunan EDR zaman serisi.

- **Yöntem 2: QRS Eğim Değişimi**

QRS kompleksinin eğimi, R-tepe ile komşu Q ve S dalgaları arasındaki gerilim değişim hızını tanımlar ve solunumla birlikte değişiklik göstermektedir. Bu değişim, solunum döngüsü boyunca kalbin yönelimi ve iletim yollarındaki farklılıklardan kaynaklanmaktadır [65].

Eğime dayalı EDR [65]'de aşağıdaki şekilde hesaplanmaktadır:

$$EDR_{eğim,i} = \frac{ekg(R_i) - ekg(Q_i)}{t(R_i) - t(Q_i)} + \frac{ekg(S_i) - ekg(R_i)}{t(S_i) - t(R_i)} \quad (2.26)$$


Burada $ekg(Q_i)$, $ekg(R_i)$, $ekg(S_i)$ sırasıyla Q, R ve S noktalarındaki EKG genliklerini, $t(Q_i)$, $t(R_i)$, $t(S_i)$ ise ilgili zaman noktalarını ifade etmektedir.

Bu tezde, QRS kompleksinin eğimi, R-tepe etrafındaki 50 ms'lik bir pencerede EKG sinyalinin en yüksek mutlak türevi (eğim) olarak yaklaşık hesaplanmaktadır:

$$EDR_{eğim,i} = \max(|ekg(k+1) - ekg(k)|, k \in [R_i - w, R_i + w]) \quad (2.27)$$

Burada $ekg(k)$, EKG sinyalini, w , 50 ms'lik pencere uzunluğunu temsil eder. Bu yöntem, QRS eğimini dolaylı olarak solunum etkilerine duyarlı bir ölçü olarak sunar.

Şekil 2.20'de QRS eğim değişimi yöntemi uygulanarak bulunan EDR sinyali a01 boyunca ve 2 dakikalık bir aralıkta görünmektedir.




Şekil 2.20. QRS eğimi yöntemi sonucu bulunan EDR zaman serisi

- **Yöntem 3: QRS Alan Değişimi**

Diğer bir güçlü teknik, QRS kompleksi altındaki alanın hesaplanmasına dayanmaktadır. Solunum aktivitesi, iletim yollarını ve QRS morfolojisini değiştirerek bu alanı etkilemektedir [28]. QRS segmenti altındaki alan yaklaşık olarak şu şekilde hesaplanmaktadır:

$$EDR_{alan,i} = \sum_{k=R_i-w}^{R_i+w} |ekg(k)| \quad (2.28)$$

Burada w , 50 ms'lik pencere uzunluğunu ve $ekg(k)$, EKG sinyal örneklerini göstermektedir. Bu toplam, solunuma bağlı morfolojik değişimin bir göstergesi olarak kullanılmaktadır. Şekil 2.21'de QRS alan değişimi yöntemi uygulanarak bulunan EDR sinyali a01 boyunca ve 2 dakikalık bir aralıkta gösterilmiştir.



Şekil 2.21. QRS alan yöntemi sonucu bulunan EDR zaman serisi

Karşılaştırma ve Uygulamalar

Her bir EDR yöntemi, EKG üzerindeki solunum modülasyonunun farklı yönlerini yakalamaktadır. R-tepe genliği yöntemi basit ve etkilidir, ancak hareket kaynaklı artefaktlara duyarlıdır. Eğim temelli yöntemler, küçük morfolojik değişimlere karşı hassastır ve gürültülü ortamlarda genlik tabanlı yaklaşımlardan genellikle daha başarılıdır. QRS alan değişimi yöntemi, sinyal enerjisini bir bölgede toplayarak daha sağlam bir yapı sunmaktadır.

Elde edilen EDR sinyalleri çeşitli uygulamalarda değerlidir:

- Uyku apnesi tespiti: EDR sinyalleri, obstrüktif uyku apnesi tanısında solunum kemerlerine alternatif veya tamamlayıcı olarak kullanılabilir [66].

- Solunum hızı tahmini: Yoğun bakım veya ayaktan izleme ortamlarında EDR, gerçek zamanlı solunum izleme imkânı sağlamaktadır [23], [67].
- Otonom sinir sistemi değerlendirmesi: Solunumsal sinüs aritmisi analizi EDR kullanılarak gerçekleştirilebilmektedir.

Bu tez kapsamında, EDR sinyalleri (3 yöntem), apne ve normal solunum olayları sırasında solunum paternlerini karşılaştırmak amacıyla kullanılmakta olup, yalnızca EKG sinyaline dayalı apne tespit sistemlerinin geliştirilmesine katkı sağlamaktadır.



3. MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE APNEA TESPİTİ

Bu tezde, Obstrüktif Uyku Apnesi (OSA) tanısının otomatikleştirilmesine yönelik bir makine öğrenmesi tabanlı yöntem önerilmektedir. Önerilen yaklaşım, iki aşamadan oluşmaktadır: ilk aşamada sinyal verilerinden anlamlı öznitelikler çıkarılmakta, ikinci aşamada ise bu özniteliklere uygulanan ağırlıklandırma işleminin ardından çeşitli sınıflandırma algoritmaları ile tanı süreci gerçekleştirilmekte ve performans değerlendirmeleri yapılmaktadır.

3.1. Öznitelik Çıkarma

Bu bölümde, elektrokardiyogram (EKG) sinyalinden Obstrüktif Uyku Apnesi (OSA) tespitiye yönelik makine öğrenmesi tabanlı analizlere temel oluşturmak amacıyla öznitelik çıkarımı gerçekleştirilmiştir. Tez kapsamında iki ana öznitelik grubu elde edilmiştir. İlk grup, zaman domen, frekans domen ve doğrusal olmayan analizler sonucunda elde edilen özniteliklerin birleşiminden oluşurken; ikinci grup ise zaman-frekans alanında gerçekleştirilen analizlerle türetilen öznitelikleri içermektedir.

3.1.1. Zaman, Frekans ve Doğrusal Olmayan Öznitelikler

Obstrüktif uyku apnesinin (OSA) elektrokardiyogram (EKG) sinyalleri kullanılarak tespit edilmesinde hem kardiyak hem de solunum sistemi dinamiklerini yansıtacak şekilde geniş bir öznitelik kümesi çıkarılmıştır. Bu öznitelikler, Bölüm 2.1’de açıklanmış ön işleme yöntemleri sonrasında,

- Tek kanallı EKG sinyali ($ekg(n)$),
- Eşitlik (2.22) ile elde edilmiş R-R aralıkları zaman serisi (RR_t) ve 4 Hz ile yeniden örneklenmiş hali,

- Eşitlik (2.24) ile elde edilmiş ortalama kalp atım hızı (HR) ve kalp atım hızı değişkenliği (HRV),
- Eşitlik (2.25), (2.27) ve (2.28) ile elde edilmiş sırasıyla genlik, eğim ve alan temelli EKG türevli solunum (EDR) zaman serileri ($EDR_{genlik,i}$, $EDR_{eğim,i}$ ve $EDR_{alan,i}$) ve 4 Hz ile yeniden örneklenmiş hali kullanılarak türetilmiştir.

Zaman alanındaki öznitelikler, EKG sinyali ve zaman serilerinin ortalaması, maksimumu, minimumu ve standart sapması gibi temel istatistiksel betimleyicilerdir ve solunum çabasındaki değişiklikleri yansıtarak apne olayları sırasında farklılık göstermektedir [67]. Bu kategorideki öznitelikler Tablo 3.1’de 1-17 sıraları arasında yer almaktadır.

Uyku apnesi tespitinde yaygın olarak kullanılan kalp atım hızı değişkenliği (HRV) öznitelikleri, R-R aralıklarından türetilmiştir. HRV öznitelikleri arasında ortalama kalp atım hızı (HR) ve ardışık iki R-R aralığı arasındaki farkların ($\Delta_{RR,i} = RR_{i+1} - RR_i$) kullanılmasıyla hesaplanan standart sapma ($std(\Delta_{RR})$), 50 ms’den büyük fark sayısı ($\Delta_{RR>50}$) ve yüzdesi ($\% \Delta_{RR>50}$) yer almaktadır. Literatürde yer alan çalışmalarda HRV ’nin doğrusal olmayan bir karakterizasyonunu olarak kullanılan Poincaré grafiği betimleyicileri, $SD1$, $SD2$ ve $SD2/SD1$ oranı da [19] hesaplanarak özniteliklere eklenmiştir. Bu tezde [19] da yer alan aşağıdaki geometrik yaklaşımlar kullanılmıştır:

$$SD1^2 = \frac{std(\Delta_{RR})^2}{2} \quad (3.1a)$$

$$SD1^2 = 2std(RR)^2 - \frac{std(\Delta_{RR})^2}{2} \quad (3.1b)$$

Burada $std()$ standart sapmayı ifade eder. Bu kategorideki öznitelikler Tablo 3.1’de 18-23 sıraları arasında yer almaktadır.

Frekans alanı öznitelikleri, R-R aralıkları zaman serisi üzerinden elde edilmiştir. Güç spektral yoğunluğu (PSD), $S_{RR}(f)$, Welch yöntemi kullanılarak hesaplanmış ve çok düşük frekans ($VLF: f < 0.04 \text{ Hz}$), düşük frekans ($LF: 0.04 < f < 0.15 \text{ Hz}$) ve

yüksek frekans (HF: $0.15 < f < 0.4 \text{ Hz}$) bantlarındaki güç değerleri bulunmuştur. LF/HF oranı, toplam güç ve maksimum PSD değerine karşılık gelen frekans parametreleri de hesaplanarak, apne epizodları ile ilişkili dengesizlikleri değerlendirmek ve baskın otonom ritimlerini belirlemek için kaydedilmiştir [20].

Welch yönteminde, ilk olarak, $f_{s,yeni} = 4 \text{ Hz}$ ile yeniden örneklenmiş sabit uzunlukta R-R aralıkları zaman serisi $RR_i, 1 \leq i \leq 240$, Hamming pencerelemeye, 53 örnek uzunluğunda %50 örtüşen 8 pencereye ayrılmıştır. 256 noktalı Fourier dönüşümüyle hesaplanmış her bir pencerenin güç spektrumunun ortalaması alınarak $S_{RR}(f)$ bulunmuştur. Burada frekans çözünürlüğü $\Delta f = f_{s,yeni}/256 = 0.016 \text{ Hz}$ ve frekans bölmesi sayısı yani $S_{RR}(f)$ 'nin uzunluğu $MS_{RR} = 256/2 + 1 = 129$ dır. Bu kapsamdaki öznitelikler, Tablo 3.1'de 24-32 sıraları arasında yer almaktadır.

HRV'ye ek olarak, başka doğrusal olmayan ve sinyal morfolojisine ilişkin öznitelikler de hesaplanmıştır. R-R zaman serisinin karmaşıklığını değerlendirmek amacıyla permütasyon sinyal entropisi (PSE), H_{RR} , kullanılmıştır. Düşük PSE değerleri apne kaynaklı periyodikliklere işaret edebildiği gibi, yüksek PSE değerleri rastgele ve düzensizliği göstermektedir [68]. Bu tezde [69] de yer alan yaklaşım ile PSE aşağıdaki gibi hesaplanmıştır:

- Gömülü boyut ($m = 3$) ve gecikme parametresi ($\tau = 1$) alınarak, R-R aralıkları zaman serisi $RR_i, 1 \leq i \leq 240$ için, her bir $[RR_i \quad RR_{i+1} \quad RR_{i+2}]$ boyutta olası sıralamaları bir sembol (j) ile ifade edilir. Gömülü boyut ($m = 3$) için sembol sayısı $3! = 6$ dır.
- R-R aralıkları zaman serisi $RR_i, 1 \leq i \leq 240$ içinde her bir sembol (j) için görülme olasılığı (p_j), j 'nin görülme adedinin toplam sembol miktarına bölünerek hesaplanır.
- Permütasyon entropisi aşağıdaki şekilde bulunur:

$$H_{RR} = - \sum_{j=1}^6 p_j \ln p_j \quad (3.2)$$

Burada $\ln$. natürel logaritmayı ifade eder. Tablo 3.1'de 33. sırada öznitelik yer almaktadır.

R-R aralıkları zaman serisi $RR_i, 1 \leq i \leq 240$ sıfır geçiş sayısı ve tepe-tepe genliği de sinyal morfolojisi ve dinamik aralığı tanımlamak amacıyla özniteliklere dahil edilmiştir.

Bu öznitelikler bir araya getirildiğinde, EKG üzerinden yansıtılan kardiyovasküler ve solunumsal fizyolojinin kapsamlı bir temsili sağlanmıştır. Tablo 3.1’de öznitelikler toplu halde özetlenmiştir.

Tablo 3.1. EKG, RR Aralıkları ve EDR Sinyallerinden Zaman, Frekans ve Doğrusal Olmayan Özniteliklerden elde edilen özellikler.

No.	Özellik kodu	Özellik adı	Kaynak	Kategori	Matematiksel formül	Açıklama
1	ort(EKG)	Ortalama EKG Sinyali	EKG Sinyali	Zaman Alanı Özniteliği	$\mu_{EKG} = \frac{1}{6000} \sum_{n=1}^{6000} ekg(n)$	EKG sinyalinin ortalama değeridir. Kalp aktivitesinin genel seviye bilgisi sağlar.
2	max(EKG)	Maksimum EKG Değeri	EKG Sinyali	Zaman Alanı Özniteliği	$\max ekg(n)$	EKG sinyalinin en yüksek değerini temsil eder. Anormal zirve aktivite göstergesi olabilir.
3	min(EKG)	Minimum EKG Değeri	EKG Sinyali	Zaman Alanı Özniteliği	$\min ekg(n)$	EKG sinyalinin en düşük değeridir.
4	std(EKG)	EKG Standart Sapması	EKG Sinyali	Zaman Alanı Özniteliği	$\sigma_{EKG} = \sqrt{\frac{1}{6000} \sum_{n=1}^{6000} (ekg(n) - \mu_{EKG})^2}$	EKG sinyalinin değişkenliğini gösterir.
5	ort(RR)	Ortalama RR Aralığı	R-R aralıkları zaman serisi	Zaman Alanı Özniteliği	$\mu_{RR} = \frac{1}{240} \sum_{i=1}^{240} RR_i$	Kalp atım aralıklarının ortalamasıdır.
6	max(RR)	Maksimum RR Aralığı	R-R aralıkları zaman serisi	Zaman Alanı Özniteliği	$\max RR_i$	RR aralıklarındaki maksimum değerdir.
7	min(RR)	Minimum RR Aralığı	R-R aralıkları zaman serisi	Zaman Alanı Özniteliği	$\min RR_i$	RR aralıklarındaki minimum değerdir.
8	std(RR)	RR Standart Sapması	R-R aralıkları zaman serisi	Zaman Alanı Özniteliği	$\sigma_{RR} = \sqrt{\frac{1}{240} \sum_{i=1}^{240} (RR_i - \mu_{RR})^2}$	RR aralıklarının varyasyonunu gösterir.
9	ort(HR)	Ortalama Kalp Atım Hızı	R-R aralıkları zaman serisi	Zaman Alanı Özniteliği	$\frac{60}{\mu_{RR}}$	Dakika başına kalp atımıdır.
10	P-t-P(RR)	Tepe Tepe Değeri	R-R aralıkları zaman serisi	Zaman Alanı Özniteliği	$\max RR_i - \min RR_i$	Sinyalin genlik aralığını gösterir.
11	ort(EDR _{genlik})	Ortalama EDR Genliği	EDR Genlik (Amp)	Solunum Özelliği	$\mu_{EDR_{genlik}} = \frac{1}{240} \sum_i EDR_{genlik,i}$	Solunum eğrisinden türetilen EDR sinyalinin ortalama genliğidir.
12	std(EDR _{genlik})	EDR Genlik Standart Sapması	EDR Genlik (Amp)	Solunum Özelliği	$\sigma_{EDR_{genlik}} = \sqrt{\frac{1}{240} \sum_{i=1}^{240} (EDR_{genlik,i} - \mu_{EDR_{genlik}})^2}$	Solunum genliğinde zamana bağlı değişimi temsil eder.
13	ort(EDR _{eğim})	Ortalama EDR Eğimi	EDR Eğim	Solunum Özelliği	$\mu_{EDR_{eğim}} = \frac{1}{240} \sum_i EDR_{eğim,i}$	Solunum sinyalinin ortalama eğimini temsil eder.
14	std(EDR _{eğim})	EDR Eğim Standart Sapması	EDR Eğim	Solunum Özelliği	$\sigma_{EDR_{eğim}} = \sqrt{\frac{1}{240 - 1} \sum_{i=1}^{240} (EDR_{eğim,i} - \mu_{EDR_{eğim}})^2}$	Eğimdeki değişkenliği yansıtır.

No.	Özellik kodu	Özellik adı	Kaynak	Kategori	Matematiksel formül	Açıklama
15	ort(EDR _{alan})	Ortalama EDR Alanı	EDR Alan	Solunum Özelliği	$\mu_{EDR_{alan}} = \frac{1}{240} \sum_{i=1}^{240} EDR_{alan,i}$	Solunum döngüsünün altındaki ortalama alandır.
16	std(EDR _{alan})	EDR Alanı Standart Sapması	EDR Alan	Solunum Özelliği	$\sigma_{EDR_{alan}} = \sqrt{\frac{1}{240} \sum_{i=1}^{240} (EDR_{alan,i} - \mu_{EDR_{alan}})^2}$	Solunum hacmindeki değişkenliği temsil eder.
17	f(EDR _{alan})	Solunum Frekansı	EDR Alan	Solunum Frekansı	-	Solunum sinyalinin baskın frekans bileşeni.
18	std(Δ_{RR})	RR Farklarının Standart Sapması	R-R aralıkları zaman serisi	HRV Özelliği	$\sigma_{\Delta_{RR}} = \sqrt{\frac{1}{240} \sum_{i=1}^{240} (\Delta_{RR,i} - \mu_{\Delta_{RR}})^2}$	RR aralıklarındaki farkların standart sapmasıdır.
19	n($\Delta_{RR>50}$)	50ms'yi aşan RR farklarının sayısı	R-R aralıkları zaman serisi	HRV Özelliği	-	-
20	%($\Delta_{RR>50}$)	50ms'yi aşan RR farklarının tüm RR sayısına	R-R aralıkları zaman serisi	HRV Özelliği	$\frac{n(\Delta_{RR} > 50)}{240}$	-
21	SD1	Poincaré SD1	R-R aralıkları zaman serisi	HRV Özelliği	$SD1^2 = \frac{std(\Delta_{RR})^2}{2}$	Kalbin kısa süreli değişkenliğini temsil eder.
22	SD2	Poincaré SD2	R-R aralıkları zaman serisi	HRV Özelliği	$SD1^2 = 2std(RR)^2 - \frac{std(\Delta_{RR})^2}{2}$	Uzun vadeli kalp ritmi değişkenliğini gösterir.
23	oran(SD1,SD2)	SD1 / SD2 Oranı	R-R aralıkları zaman serisi	HRV Özelliği	$\frac{SD1}{SD2}$	Otonom sinir sistemi dengesini yansıtır.
24	VLF(RR)	Çok Düşük Frekans Gücü (0–0.04 Hz)	R-R aralıkları zaman serisi	Frekans Domeni HRV	$\int_0^{0.04} S_{RR}(f) df$	Çok düşük frekanstaki HRV bileşenlerinin gücüdür.
25	LF(RR)	Düşük Frekans Gücü (0.04–0.15 Hz)	R-R aralıkları zaman serisi	Frekans Domeni HRV	$\int_{0.04}^{0.15} S_{RR}(f) df$	Sempatik ve parasempatik aktiviteyi birlikte yansıtır.
26	HF(RR)	Yüksek Frekans Gücü (0.15–0.4 Hz)	R-R aralıkları zaman serisi	Frekans Domeni HRV	$\int_{0.15}^{0.4} S_{RR}(f) df$	Parasempatik sinir sistemi aktivitesini temsil eder.
27	power(RR)	Toplam HRV Gücü (0–0.4 Hz)	R-R aralıkları zaman serisi	Frekans Domeni HRV	$\int_0^{0.4} S_{RR}(f) df$	HRV'nin toplam spektral gücüdür.
28	oran(LF,HF)	LF / HF Oranı	R-R aralıkları zaman serisi	Frekans Domeni HRV	$\frac{LF}{HF}$	Sempatik/parasempatik dengeyi ölçer.
29	nLF	Normalize Edilmiş LF	R-R aralıkları zaman serisi	Frekans Domeni HRV	$\frac{LF}{Power - VLF}$	Normalize düşük frekans bileşenidir.
30	nHF	Normalize Edilmiş HF	R-R aralıkları zaman serisi	Frekans Domeni HRV	$\frac{HF}{Power - VLF}$	Normalize yüksek frekans bileşenidir.
31	max(f _{power})	Maksimum Güçte Frekans	R-R aralıkları zaman serisi	Frekans Domeni HRV	-	Güç spektrumundaki en yüksek frekansa karşılık gelen değerdir.
32	power(RR _{band})	Bant Güç (0.15–0.4 Hz)	R-R aralıkları zaman serisi	Frekans Domeni HRV	-	Belirli frekans bandındaki toplam gücü temsil eder.
33	H _{RR}	Pseudo-Entropi	R-R aralıkları zaman serisi	Entropi Özelliği	$H_{RR} = - \sum_{j=1}^6 p_j \ln p_j$	RR sinyalinin bilgi içeriği ve düzensizliğini ölçer.

3.1.2. Zaman-Frekans Alanından Elde Edilen Öznitelikler

Bu tezde, Sürekli Dalgacık Dönüşümü (CWT) zaman-frekans yöntemi, $f_{s,yeni} = 4 \text{ Hz}$ ile yeniden örneklenmiş R-R aralıkları zaman serisinin (RR_i) ve genlik, eğim ve alan temelli EDR zaman serilerinin ($EDR_{genlik,i}$, $EDR_{eğim,i}$ ve $EDR_{alan,i}$) zaman-frekans özniteliklerinin çıkarılması için uygulanmıştır [70]. CWT özellikle durağan olmayan davranışlar sergileyen biyomedikal sinyallerin analizine uygundur [71][72]. Ek olarak sınıflandırma performansının artırılması amacıyla EDR ve R-R aralıkları arasındaki ilişki olan Kardiyopulmoner Eşleşim (CPC) de değerlendirilmiştir.

- **Sürekli Dalgacık Dönüşümü (CWT)**


CWT’de sinyaller, yüksek frekans bileşenleri için kısa zaman pencereleri, düşük frekans bileşenleri için ise uzun zaman pencereleri ile, hem zaman hem de frekans boyutunda ortogonal bileşenlerine ayrılır. Devamlı bir sinyal olan $x(t)$ ’nin CWT dönüşümü, $x(t) \xrightarrow{CWT} \Psi_x(a, b)$, $x(t)$ ’nin "dalgacık" olarak adlandırılan sinyaldeki zaman ve frekans ölçeklerine göre ayarlanabilen yerel bir fonksiyon üzerine projeksiyonu ile hesaplanır. Dalgacıklar “anne dalgacık” adı verilen $\psi(t)$ ’den $\Psi_{a,b}(t) = 1/\sqrt{a} \psi\left(\frac{t-b}{a}\right)$ eşitliği ile elde edilmektedir. Burada, a frekansın tersi olan ölçek parametresi, b ise zaman kaydırma parametresidir. Şekil 3.1’de ölçekleme ve kaydırmaya örnek olarak iki dalgacık temsili olarak gösterilmiştir. Bu durumda, CWT katsayıları aşağıdaki şekilde bulunur [71]:

$$\Psi_x(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt \quad (3.3)$$

Şekil 3.1’de ayrıca zaman-frekans düzlemindeki Heisenberg pencere boyutları’ da yer almaktadır. Aynı adlı prensibe göre pencerelerin alanlarının en küçük değeri: $\sigma_t \sigma_f \geq \frac{1}{4\pi}$ ’dir. Bu durumda zaman çözünürlüğü ile frekans çözünürlüğün ters orantılıdır.

CWT ile birlikte kullanılan “yaygın anne dalgacıklar” şunlardır:

- Morlet (amor): Biyomedikal sinyal işleme için yaygın kullanılan kompleks bir dalgacıktır [73].
- Meksika Şapkası: Zirve tespiti için uygundur.



Şekil 3.1. Genleşme ve kaydırmaya örnek olarak iki dalgacık, $\psi_{a_1,b_1}(t)$ ve $\psi_{a_2,b_2}(t)$ zaman-frekans düzleminde temsili gösterilmiştir.

- Daubechies: Ayırık dalgacık dönüşümleri için idealdir.

Morlet dalgacığı, Gaussian zarfla modüle edilmiş düzlemsel bir dalga içerir ve zaman ve frekans düzleminde aşağıdaki şekilde tanımlanır:

$$\psi(t) = e^{-\beta(t^2/2)} e^{j\omega_0 t} \quad (3.4)$$

Burada ω_0 dalgacığın merkez frekansıdır.

3.1.3. Zaman-Frekans Alanı Analizi Kullanılarak Kardiyopulmoner Eşleşim (CPC)

Bu bölümde, hem R-R aralıkları zaman serisi hem de EDR zaman serisinden elde edilen bütünleşik bilgilerin kullanılması yoluyla uyku kalitesinin nicel olarak ölçülmesi ve uyku solunumu olaylarının tespiti amaçlanmıştır. Bu yöntem Thomas ve arkadaşları tarafından tanıtılmış olup, kardiyopulmoner eşleşim (CPC) olarak adlandırılmaktadır [74]. Sürekli Dalgacık Dönüşümü, EDR ve R-R zaman serilerinin analizinde kullanılmış ve ardından bu iki sinyal arasındaki ilişki (CPC) hesaplanmıştır.

Kardiyopulmoner Eşleşim (CPC), kalp ve solunum sistemleri arasındaki dinamik etkileşimi tanımlamakta olup, otonom sinir sisteminin sempatik ve parasempatik dalları tarafından düzenlenmektedir. Solunumda meydana gelen değişimlerin, respiratuar sinüs aritmisi (RSA) yoluyla R-R aralıklarını etkilediği ve kalp atım hızının

solunum döngüsü ile senkronize olarak değiştiği gösterilmiştir. Bu senkronizasyon, apne ya da diğer uyku bozuklukları sırasında bozulmakta ve böylece uyku fizyopatolojisine dair invaziv olmayan bir bakış sunulmaktadır [75].

CPC analizi, bu kardiyorespiratuvar senkronizasyonu zaman ve frekans boyunca ölçmekte olup, genellikle koherens (coherence) veya dalgacık temelli yöntemlerle gerçekleştirilir. Sürekli Dalgacık Dönüşümü (CWT) gibi zaman-frekans analiz yöntemleri, R-R ve EDR zaman serileri arasında iki boyutlu bir eşleşim matrisi oluşturarak, bu matristen düşük frekanslı eşleşim (LFC) ve yüksek frekanslı eşleşim (HFC) gibi özniteliklerin çıkarılmasına olanak tanır. Bu öznitelikler, otonom sinir sisteminin farklı dallarına karşılık gelmekte ve uyku evresi geçişleri ya da apne olaylarının varlığı hakkında bilgi sağlamaktadır [67].

EKG-apne çalışmalarında, CPC yöntemi, obstrüktif ve santral apne olaylarına bağlı otonom kontrol değişikliklerinin ve düzensiz solunumun tespiti amacıyla yaygın şekilde kullanılmaktadır. Ayrıca, normal ve anormal uyku durumlarını ayırt etmede, apne şiddeti ve türünü sınıflandırmada da etkili olduğu gösterilmiştir [76]. Bu eşleşimin pasif biçimde ölçülmesi, doğrudan solunum sensörlerine gerek olmadan sürekli ve uzun süreli izlemeyi mümkün kıldığından, giyilebilir cihazlar ve ayaktan izlem sistemleri açısından avantajlıdır [77].

Sonuç olarak, kardiyopulmoner eşleşim, kalp ve solunum sistemleri arasındaki etkileşimi analiz etmek için güçlü ve invaziv olmayan bir çerçeve sunmaktadır. Apne tespiti, otonom denge değerlendirmesi ve uyku kalitesinin analizi açısından klinik ve araştırma ortamlarında kullanışlı bir araçtır.

- **CPC Analizinde CWT'nin Kullanımı**

Bu çalışmada apne tespitine yönelik kardiyopulmoner etkileşimlerin değerlendirilmesi amacıyla, R-R aralığı (RR) ve EKG-türetilmiş solunum (EDR) sinyallerine Sürekli Dalgacık Dönüşümü (CWT) temelli kardiyopulmoner eşleşim (CPC) analizi uygulanmıştır.

CWT detayları Bölüm 3.2'de yer almaktadır [73]. Düşük frekans (LF) ve yüksek frekans (HF) bantları sırasıyla 0.01–0.15 Hz ve 0.15–0.4 Hz olarak belirlenmiştir

[74]. Her bir kayıt ve 1 dakikalık segment için $f_{s,yeni} = 4 \text{ Hz}$ ile yeniden örneklenmiş R-R aralıkları zaman serisi (RR_i) ve genlik, eğim ve alan temelli EDR zaman serileri ($EDR_{genlik,i}$, $EDR_{eğim,i}$ ve $EDR_{alan,i}$) ortalamaları çıkarılarak normalize edilmiştir. CWT dalgacık katsayıları $\Psi_{RR}(a, b)$ ve $\Psi_{EDR}(a, b)$ kullanılarak CPC matrisi $C(a, b)$ aşağıdaki şekilde hesaplanmıştır:

$$C(a, b) = \frac{|\Psi_R(a, b) \cdot \Psi_E^*(a, b)|^2}{|\Psi_R(a, b)|^2 \cdot |\Psi_E(a, b)|^2 + \epsilon} \quad (3.3)$$

Burada ϵ , sıfıra bölmeyi önlemek için kullanılan küçük bir sabittir [67]. Bu metrik, RR ve EDR zaman serileri arasındaki yerel koherensi çoklu ölçek ve zaman noktalarında ölçmektedir [72].

Tablo 3.2. Zaman-Frekans Alanı, Sürekli Dalgacık Dönüşümü ve CPC kullanılarak çıkarılmış özellikler.

No.	Özellik Kodu	Özellik Adı	Kaynak	Kategori	Matematiksel Formül	Açıklama
1	top(CPC)	Toplam Eşleşme Gücü	CPC Matrisi	Zaman-Frekans Özelliği	$Total = \sum_{a,b} C(a, b)$	Tüm zaman ve frekanslarda CPC matrisinin toplam gücüdür. Kardiyopulmoner senkronizasyonun genel seviyesini yansıtır.
2	LF(CPC)	Düşük Frekans Eşleşme Gücü	CPC Matrisi	Zaman-Frekans Özelliği	$LFC = \sum_{f \in LF} \sum_b C(f, b)$	0.01–0.15 Hz frekans bandındaki CPC gücüdür. Parasempatik aktiviteyle ilişkilidir.
3	HF(CPC)	Yüksek Frekans Eşleşme Gücü	CPC Matrisi	Zaman-Frekans Özelliği	$HFC = \sum_{f \in HF} \sum_b C(f, b)$	0.15–0.4 Hz frekans bandındaki CPC gücüdür. Solunumsal modülasyonla ilişkilidir.
4	oran(LF,HF)	LF/HF Güç Oranı	CPC Matrisi	Zaman-Frekans Özelliği	$\frac{LFC}{HFC + \epsilon}$	LF ve HF güçlerinin oranıdır. Sempatik/parasempatik denge hakkında bilgi verir.
5	nLF	Normalize LF Gücü	CPC Matrisi	Zaman-Frekans Özelliği	$\frac{LFC}{Total + \epsilon}$	LF bandının toplam güce oranıdır. Göreli parasempatik etkiyi gösterir.
6	nHF	Normalize HF Gücü	CPC Matrisi	Zaman-Frekans Özelliği	$\frac{HFC}{Total + \epsilon}$	HF bandının toplam güce oranıdır. Göreli solunumsal etkiyi gösterir.
7	H _{CPC}	CPC Entropisi	CPC Matrisi	Zaman-Frekans / Nonlinear Özellik	$H_{CPC} = - \sum C(a, b) \log_2(C(a, b) + \epsilon)$	CPC matrisinin Shannon entropisidir. Kardiyopulmoner senkronizasyonun düzensizliğini yansıtır.
8	std(CPC)	CPC Standart Sapması	CPC Matrisi	Zaman-Frekans / İstatistiksel	$std(C(:))$	CPC matrisinin varyasyon seviyesidir. Zaman içindeki senkronizasyon değişimini gösterir.
9	max(CPC)	CPC Maksimum Değeri	CPC Matrisi	Zaman-Frekans Özelliği	$max(C(:))$	CPC matrisindeki en yüksek senkronizasyon değeridir. En güçlü etkileşimi temsil eder.

CPC matrisinin hesaplanmasının ardından, LF ve HF bantlarında ortalama güçler zaman ve frekans boyunca CPC değerlerinin ortalaması alınarak elde edilmiştir. Bu analizden altı öznelik çıkarılmıştır: toplam eşleşme (CPC matrisinin ortalaması), düşük frekans eşleşmesi (LFC), yüksek frekans eşleşmesi (HFC), LF/HF oranı, normalize LF gücü ve normalize HF gücü. Bu öznelikler, apne epizodlarında değişime uğrayan kardiyorespiratuvar etkileşimin gücünü ve dengesini karakterize etmektedir [67]. Bu bölümden çıkarılan öznelikler Tablo 3.2’de sunulmuştur.

3.2. Makine Öğrenmesi

Makine öğrenmesi, yapay zekanın (AI) bir alt dalı olarak, sistemlerin her bir görev için açıkça programlanmasına gerek olmaksızın verilerden otomatik olarak desenler öğrenmesini ve tahminlerde bulunmasını mümkün kılmaktadır.

Makine öğrenmesinin temelleri, 20. yüzyılın ortalarında istatistik ve bilgisayar bilimleri alanlarında yapılan erken dönem çalışmalara dayanmaktadır. "Makine öğrenmesi" terimi ilk kez 1959 yılında Arthur Samuel tarafından ortaya atılmış ve bilgisayarların açık bir şekilde programlanmaksızın öğrenme yeteneği olarak tanımlanmıştır [78]. Bu tarihten itibaren, özellikle hesaplama gücündeki artış ve büyük veri kümelerinin erişilebilir hale gelmesiyle birlikte alan hızlı bir gelişim göstermiştir. Biyomedikal sinyal işleme alanında, geleneksel yöntemlerle kolayca tespit edilemeyen karmaşık ve doğrusal olmayan desenlerin algılanabilmesi nedeniyle makine öğrenmesi giderek daha fazla benimsenmiştir.

Makine öğrenmesi yaklaşımları, denetimli öğrenme (Supervised Learning), denetimsiz öğrenme (Unsupervised Learning), yarı denetimli öğrenme (Semi-supervised Learning) ve pekiştirmeli öğrenme (Reinforcement Learning) olmak üzere dört ana kategoriye ayrılmaktadır. Bu öğrenme metotları, etiketli verilerin mevcut olup olmamasına ve nasıl kullanıldığına göre birbirinden ayrılmaktadır. EKG sinyallerinden apne tespiti probleminde, apne olaylarının varlığını veya yokluğunu gösteren etiketli veri kümeleri bulunduğu için, denetimli öğrenme yöntemi en uygun yaklaşım olarak belirlenmiştir.

Denetimli öğrenmede, modeller etiketli giriş-çıkış çiftleri kullanılarak eğitilmekte ve bu sayede daha önce görülmemiş yeni girdiler için doğru çıktılar tahmin edilmesi mümkün hale gelmektedir. Yaygın olarak kullanılan denetimli öğrenme algoritmaları arasında karar ağaçları (Decision Tree), destek vektör makineleri (Support Vector Machines- SVM), en yakın komşu algoritması (K-Nearest Neighbors-KNN), lojistik regresyon (Logistic Regression), naif Bayes (naïve Bayes) ve rastgele ormanlar (random forests) ile yükseltme (boosting) algoritmaları gibi topluluk (ensemble) yöntemleri yer almaktadır [79]. Bu yöntemlerin etkinliği, çıkarılan özniteliklerin doğasına ve sinyalin karmaşıklık düzeyine bağlı olarak değişiklik göstermektedir.

“Decision Tree”, öznitelik uzayını bilgi kazancı ya da entropi minimizasyonuna dayalı olarak yinelemeli şekilde bölerek çalışan basit fakat güçlü modellerdir. Yorumlanabilir olmalarına karşın, aşırı öğrenmeye (overfitting) eğilimli olabilirler. Bu sınırlamayı aşmak için bir topluluk yöntemi olan “Random Forest” geliştirilmiştir; bu yöntem, çok sayıda karar ağacı oluşturarak ve bunların çıktısını birleştirerek varyansı azaltmakta ve genelleme yeteneğini artırmaktadır [80]. “Random Forest”, biyomedikal sinyallerin sınıflandırılması, özellikle de uyku apnesi tespiti gibi görevlerde, gürültüye karşı dayanıklılıkları ve çok sayıda özneliği aynı anda işleyebilme yetenekleri nedeniyle oldukça uygun bulunmuştur.

Destek vektör makineleri (SVM), verileri maksimum marjla ayıran optimal hiper düzlemi bulmayı amaçlayan başka bir yaygın yöntemdir. Bu yöntem, yüksek boyutlu öznitelik uzaylarında etkili sonuçlar verebilmekte olup, EKG tabanlı sınıflandırma problemlerinde başarıyla uygulanmıştır. Ancak performansı, kullanılan çekirdek (kernel) fonksiyonu ve parametre ayarlarına büyük ölçüde bağlı olabilmektedir.

En yakın komşu (KNN) algoritması, öznitelik uzayında komşu olan örneklerin çoğunluk etiketine göre sınıflandırma yapan parametrik olmayan bir yöntemdir. Uygulaması basit olmakla birlikte, mesafe metriğinin seçimine duyarlıdır ve büyük veri kümelerinde yüksek hesaplama maliyeti gerektirir. Lojistik regresyon ise, ikili sınıflandırma amacıyla geliştirilmiş bir istatistiksel model olup, yorumlanabilmesi ve olasılık tabanlı çıktı üretme özelliği sayesinde yaygın olarak başvuru modeli olarak kullanılmaktadır.

AdaBoost ve gradyan yükseltme makineleri gibi boosting algoritmaları, zayıf sınıflandırıcıları ardışık olarak birleştirerek güçlü bir genel model oluşturmaktadır. Bu yöntemler çeşitli biyomedikal uygulamalarda umut verici sonuçlar ortaya koymuştur; ancak, aşırı öğrenmenin önlenmesi için dikkatli şekilde düzenlenmeleri gerekmektedir.

Denetimsiz öğrenme yöntemleri ise etiketli veri kullanılmaksızın çalışmakta olup, genellikle kümeleme ve boyut indirgeme amacıyla kullanılmaktadır. Bu yöntemler keşifsel veri analizi açısından faydalı olsalar da apne tespiti gibi doğrudan sınıflandırma görevlerinde yalnız başlarına yeterli değildir; ancak daha sonra uygulanacak etiketleme stratejileriyle birlikte kullanılabilirler.

Makine öğrenmesi yöntemleri arasında, özellikle “random forest” modelleri, EKG-türetilmiş özniteliklerden apne tespiti için en etkili yaklaşımlardan biri olarak öne çıkmaktadır. Bu durum, söz konusu modellerin karmaşık doğrusal olmayan etkileşimleri yakalama yeteneklerinden, aşırı öğrenmeye karşı dirençli olmalarından ve çeşitli fizyolojik veri kümelerinde gözlemlenen yüksek sınıflandırma doğruluklarından kaynaklanmaktadır [81]. Bu nedenle, bu tezde hem geleneksel EKG özniteliklerini hem de sürekli dalgacık dönüşümü (CWT) ile elde edilen ileri düzey kardiyopulmoner eşleşim (CPC) özniteliklerini kullanarak apne olaylarının sınıflandırılması amacıyla rastgele orman yöntemi tercih edilmiştir.

3.3. Rastgele Ormanlar ile Sınıflandırma

Rastgele Ormanlar (Random Forest), birden fazla karar ağacının tahminlerini birleştirerek sınıflandırma doğruluğunu ve dayanıklılığı artıran, yaygın olarak benimsenmiş bir topluluk (ensemble) öğrenme yöntemidir. İlk olarak Breiman (2001) tarafından sunulan Rastgele Ormanlar yöntemi, bagging (bootstrap aggregating) yaklaşımını genişletmekte ve yalnızca eğitim örneklerinde değil, aynı zamanda her düğümde kullanılacak özelliklerin seçiminde de rastgelelik unsuru eklemektedir. Bu yöntem, tek bir karar ağacında yaygın olarak karşılaşılan aşırı öğrenme (overfitting) riskini önemli ölçüde azaltmakta ve düşük sapma ile varyans iyileştirilmesi sağlamaktadır [81].

Rastgele Orman yöntemi, özellikle obstrüktif uyku apnesi (OSA) gibi biyomedikal sınıflandırma problemleri için uygun hale getiren çeşitli avantajlara sahiptir:

- Aşırı öğrenmeye karşı dayanıklılık: Tek bir karar ağacının aksine, topluluk yapısı modelin verideki gürültüyü öğrenmesini engellemektedir.
- Yüksek boyutlu verileri işleme yeteneği: Rastgele Orman, geniş sayıda giriş özelliğini, kapsamlı boyut indirgeme veya ön seçim işlemlerine gerek duymadan işleyebilmektedir.
- Öznitelik önem derecelendirmesi: Model, sınıflandırma kararlarına en çok katkı sağlayan özniteliklerin belirlenmesine olanak tanımaktadır.
- Kararlılık ve yorumlanabilirlik: Birden çok karar ağacının birleşik yapısı, özellikle klinik araştırmalarda, sonuçların tekrarlanabilirliğini ve açıklanabilirliğini artırmaktadır.


Bu avantajlar göz önünde bulundurularak, bu çalışmada uyku apnesi tespiti için EKG-türetilmiş ve CPC-tabanlı özelliklerin sınıflandırmadaki etkinliğini değerlendirmek amacıyla temel sınıflandırıcı olarak Rastgele Orman yöntemi tercih edilmiştir.

Rastgele Orman algoritmasının güçlü genelleme performansı, yüksek boyutlu verileri işleme kapasitesi, gömülü öznitelik seçimi mekanizması ve aşırı öğrenmeye karşı direnci nedeniyle, bu çalışmada kullanılması uygun görülmüştür. Modelin performansını değerlendirmek amacıyla, Bölüm 2.1’de detayları verilen veri tabanındaki toplam 70 adet EKG kaydı kullanılmıştır. Tüm veri seti, %80 eğitim ve %20 test olarak tabakalı (stratified) biçimde ayrılmıştır. Eğitim verileri, çapraz doğrulama ve öznitelik seçimi süreçlerinde kullanılmış; test verileri ise model geliştirme aşamalarında tamamen dışlanarak, tarafsız bir değerlendirme yapılması sağlanmıştır.

Modelin dayanıklı olması ve aşırı öğrenmenin azaltılması amacıyla, eğitim verileri üzerinde k-katlı çapraz doğrulama (Cross-Validation) uygulanmıştır. Bu çalışmada k değeri olarak 10 seçilmiştir. Bu yöntemde, eğitim veri kümesi eşit büyüklükte 10 alt kümeye bölünmekte, her alt küme bir doğrulama kümesi olarak kullanılırken kalan 9 küme eğitim için kullanılmakta ve bu işlem tüm kombinasyonlar için tekrarlanmaktadır. Böylece her örnek hem eğitim hem doğrulama için kullanılarak modelin genelleme kapasitesine dair güvenilir bir tahmin elde edilmektedir. 10-katlı

çapraz doğrulama, hesaplama yükü ile güvenilirlik arasında pratik bir denge sunduğu için orta büyüklükteki veri kümelerinde yaygın olarak tercih edilmektedir. Daha düşük k değerleri (ör. 2 veya 3), performans metriklerinde yüksek varyansa neden olabileceken; daha yüksek değerler (ör. 20 gibi), daha istikrarlı tahminler sunsa da işlem süresini artırmaktadır.


Her çapraz doğrulama döngüsünde, Minimum Gereksizlik Maksimum İlgililik (Minimum Redundancy Maximum Relevance mRMR) algoritması ile öznitelik seçimi gerçekleştirilmiştir. Bu algoritma, hedef sınıfa yüksek düzeyde ilişkili (maksimum ilgi) ve birbirleriyle düşük düzeyde ilişkili (minimum gereksizlik) özniteliklerin seçimini amaçlamaktadır. Bu ikili ölçüt sayesinde, seçilen öznitelikler sınıflandırma görevine tamamlayıcı bilgiler sunmakta ve modelin hem performansını hem de yorumlanabilirliğini artırmaktadır. Her bir döngüde, mRMR sıralamasına göre en üst K öznitelik seçilerek boyut indirgeme uygulanmıştır. Şekil 3.2’de tüm öznitelikleri kullanarak öznitelik sayısına karşı eğitim seti çapraz doğruluk ve test seti doğruluk değişimleri gösterilmiştir.



Şekil 3.2. Öznitelik sayısına karşı eğitim seti çapraz doğruluk (mavi grafik) ve test seti doğruluk (turuncu grafik) değişimleri.

Bu tezde elde edilen sonuçlara göre, mRMR yöntemi kullanılarak yapılan öznitelik seçimi sonucunda en iyi performans $topK = 20$ ile elde edilmiştir. Ancak, $topK > 20$ değerlerinde modelin aşırı öğrenmeye (overfitting) eğilim gösterdiği

gözlemlenmiştir. Tez kapsamında farklı öznitelik setleri kullanıldığından ve adil bir karşılaştırma yapılabilmesi için değerlendirmelerin aynı *topK* değeri üzerinden gerçekleştirilmesi gerektiğinden, en iyi *topK* = 10 ve *topK* = 15 olacak şekilde belirlenmiş ve modelin performansı bu iki değer üzerinden incelenmiştir. Nihai Rastgele Orman modeli, bu seçilen öznitelikler kullanılarak, 150 karar ağacı ve bootstrap örnekleme (bagging) yöntemi ile eğitilmiş; ardından ayrılmış olan %20'lik test veri seti üzerinde test edilmiştir. Şekil 3.3'de tüm özellik serisinde uygulanan mRMR yöntemi ile *topK* = 15 için kullanılan öznitelikler ve mRMR skor değerleri gösterilmiştir.



Şekil 3.3. *topK* = 15 için kullanılan öznitelikler ve mRMR skor değerleri.

Değerlendirme Metrikleri

Bu tezde değerlendirme metrikleri olarak Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall), F1-Skoru, Alıcı Operatör Karakteristik Eğrisi Altındaki Alan (AUC- Area Under the ROC Curve), Matthews Korelasyon Katsayısı (MCC) ve Cohen's Kappa Katsayısı kullanılmıştır. Aşağıdaki tanımlar yapılmıştır.

- TP: Gerçek pozitifler (True Positives)
- TN: Gerçek negatifler (True Negatives)
- FP: Yanlış pozitifler (False Positives)
- FN: Yanlış negatifler (False Negatives)

Doğruluk (Accuracy), doğru olarak tahmin edilen örneklerin toplam tahmin sayısına oranı olarak tanımlanmaktadır. Bu metrik, genel sınıflandırma performansına dair genel bir fikir verse de, dengesiz sınıf dağılımlarına sahip veri kümelerinde yanıltıcı olabilir. Doğruluk aşağıdaki şekilde hesaplanmaktadır:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.4)$$

Kesinlik (Precision), pozitif olarak tahmin edilen örneklerden kaç tanesinin gerçekten pozitif olduğunu gösterir. Klinik uygulamalarda, özellikle apne olmayan bireylerin yanlışlıkla apne olarak sınıflandırılması durumunda ortaya çıkabilecek gereksiz müdahaleler düşünüldüğünde, bu metrik büyük önem arz etmektedir. Kesinlik aşağıdaki formülle hesaplanmaktadır:

$$Precision = \frac{TP}{TP + FP} \quad (3.5)$$

Duyarlılık (Recall) ya da diğer adıyla Sensitivity, modelin gerçek pozitif vakaları ne ölçüde doğru tespit edebildiğini göstermektedir. Apne tespitinde, gerçek apne olaylarının gözden kaçırılması (yanlış negatifler) ciddi sağlık risklerine yol açabileceğinden bu metrik kritik öneme sahiptir. Duyarlılık şu şekilde hesaplanmaktadır:

$$Recall = \frac{TP}{TP + FN} \quad (3.6)$$

F1-Skoru, kesinlik ve duyarlılık metriklerinin harmonik ortalamasıdır. Hem yanlış pozitiflerin hem de yanlış negatiflerin önemli olduğu senaryolarda dengeli bir değerlendirme sağlamaktadır. Özellikle sınıf dengesizliği bulunan veri setlerinde faydalı bir metriktir. Aşağıdaki formül ile hesaplanmaktadır:

$$F1 - score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (3.7)$$

Özgüllük (specificity), bir sınıflandırma modelinin negatif sınıfa ait örnekleri doğru bir şekilde tanıma yeteneğini değerlendirmek amacıyla kullanılan temel ölçütlerden biridir. Bu ölçüt, gerçek negatif (true negative) sayısının, model tarafından negatif olarak sınıflandırılması gereken toplam örnek sayısına (gerçek negatif + yalancı pozitif) oranlanmasıyla hesaplanmaktadır. Diğer bir ifadeyle, özgüllük değeri, modelin yalancı pozitif oranını ne ölçüde düşük tuttuğunu gösterir. Yüksek özgüllük, modelin sağlıklı bireyleri yanlışlıkla hasta olarak sınıflandırma olasılığının düşük olduğunu göstermektedir. Bu nedenle, özellikle yanlış pozitif sonuçların önemli olduğu klinik uygulamalarda özgüllük kritik bir başarı ölçütü olarak değerlendirilmektedir.

$$Specificity = \frac{TN}{TN + FP} \quad (3.8)$$

Alıcı Operatör Karakteristik Eğrisi Altındaki Alan (AUC- Area Under the ROC Curve), modelin sınıflar arasında ayırt etme yeteneğini farklı eşik değerleri üzerinden özetleyen bir ölçüttür. AUC, doğru pozitif oranı ile yanlış pozitif oranı arasındaki dengeyi ifade eder. Yüksek AUC değerleri, genel ayırım performansının güçlü olduğunu göstermektedir.

$$AUC = \int_0^1 TPR(FPR^{-1}(x)) \quad (3.9)$$

Burada:

TPR: Gerçek pozitif oranı $(\frac{TP}{TP+FN})$

FPR: Yanlış pozitif oranı $(\frac{FP}{FP+T})$

Matthews Korelasyon Katsayısı (MCC), karışıklık matrisinin dört bileşenini de dikkate alan dengeli bir değerlendirme sunmaktadır. Özellikle dengesiz veri kümelerinde güvenilir bir performans ölçütü olarak kabul edilmektedir. MCC aşağıdaki şekilde tanımlanmaktadır:

$$MCC = \frac{(TP.TN) - (FP.FN)}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (3.10)$$

MCC değeri -1 ile +1 arasında değişmektedir. +1 mükemmel sınıflandırmayı, 0 rastgele tahmini ve -1 tam tersini (tam uyumsuzluk) ifade etmektedir.

Cohen's Kappa Katsayısı, sınıflandırma sonuçları ile gerçek etiketler arasındaki uyumu, tesadüfen oluşabilecek uyumu da dikkate alarak değerlendirmektedir. Aşağıdaki formülle hesaplanır:

$$k = \frac{P_o - P_e}{1 - P_e} \quad (3.11)$$

Burada:

- P_o : Gözlemlenen (gerçek) uyum oranı
- P_e : Beklenen (tesadüfi) uyum oranı

Bu katsayı 0 ile 1 arasında değer almaktadır ve 0.8'in üzerindeki Kappa değerleri, güçlü uyumu ve modelin tesadüfiden çok daha iyi tahmin yaptığını göstermektedir. Bu çalışmada, birleşik öznitelik kümesinde gözlenen yüksek Kappa değeri, modelin sağlamlığını desteklemektedir.

Tüm bu metrikler bir arada ele alındığında, modelin yalnızca doğruluk açısından değil, aynı zamanda klinik açıdan anlamlı ve güvenilir sınıflandırmalar yapma yeteneği bakımından da kapsamlı bir şekilde değerlendirildiği görülmektedir. Özellikle F1, AUC, MCC ve Kappa metriklerinde elde edilen yüksek performans, geliştirilen modelin etkinliğini ve pratik kullanım potansiyelini teyit etmektedir.

Rastgele Orman (Random Forest) sınıflandırma modelinin geliştirilmesinin ardından, önerilen işlem hattı (pipeline), özniteliklerin görelî etkinliğini değerlendirmek amacıyla üç farklı öznitelik grubuna uygulanmıştır. Bu gruplar şunlardır:

- CWT tabanlı Kardiyopulmoner Eşleşim (CPC) özellikleri kullanılmadan, yalnızca EKG sinyalleri, R-R aralıkları ve EKG-türetilmiş solunum (EDR)

sinyallerinden elde edilen zaman-domeni, frekans-domeni, doğrusal olmayan ve istatistiksel öznitelikleri içeren temel öznitelik kümesi;

- Yalnızca sürekli dalgacık dönüşümüne (CWT) dayalı CPC analizinden türetilen, spektral güç ve oran ölçümlerini içeren CPC tabanlı öznitelik kümesi;
- Hem temel (RR/EDR tabanlı) hem de CPC tabanlı özniteliklerin birleştirilmesiyle oluşturulan birleşik öznitelik kümesi.



4. SONUÇLAR

Bölüm 2.1’de detayları verilen veri seti Bölüm 2.3’de anlatılan ön işleme adımları sonrasında, Bölüm 3’deki öznitelik çıkarma ve Rastgele Orman sınıflandırması ile solunum bilgileri çıkarılmış ve apne epizodları teşhis edilmiştir. Bu bölümde Bölüm 3.3.1’de yer alan değerlendirme metrikleri ve açıklamaları sunulacaktır.

4.1. Değerlendirme Metrikleri Sonuçları

Değerlendirme metriklerini hesaplamak için önce sonuçlardan elde edilen bir hata matrisi (confusion matrix) hesaplanması gerekmektedir. Şekil 4.1’de tüm özellikleri kullanarak $topK = 15$ için elde edilen hata matrisi sunulmuştur. Burada test veri setinde sınıflandırma sonuçları olarak

Gerçek Negatif (TN) = 2351

Yanlış Pozitif (FP) = 270


Yanlış negatif (FN) = 190

Gerçek pozitif (TP) = 1366.

Olarak bulunmuştur. Sınıflandırıcı performansı Bölüm 3.3.1’de anlatılan üç farklı öznitelik grubuna üzerinden değerlendirilmiş ve elde edilen sonuçlar Tablo 4.1 ve Tablo 4.2’de özetlenmiştir.

4.2. mRMR ve Random Forest ile Nihai Model Değerlendirmesi

Önerilen apne tespit yönteminin performansını değerlendirmek amacıyla üç farklı özellik kümesi kullanılarak deneyler gerçekleştirilmiştir: (1) EKG, RR aralıkları ve



Şekil 4.1. Tüm özellikleri kullanarak $topK = 15$ için elde edilen hata matrisi.

EDR sinyallerinden çıkarılan zaman-frekans özellikleri; (2) yalnızca CWT tabanlı CPC yönteminden (EDR, genlik, eğim) türetilen özellikler ve (3) her iki türü içeren birleşik özellik kümesi. Her yapılandırma için mRMR algoritması kullanılarak en iyi $topK = 10$ ve $topK = 15$ özellik seçimi yapılmıştır. Eğitim verileri üzerinde 10 katlı çapraz doğrulama ile Random Forest sınıflandırıcıları eğitilmiş, ardından değerlendirme, birey-bağımsız bir test kümesi üzerinde gerçekleştirilmiştir. Tablo 4.1’de 3 farklı özellik seti kullanılarak $topK = 10$ için elde edilen değerlendirmeler görülmektedir. Tablo 4.2’de ise aynı özellik setlerini kullanarak $topK = 15$ için elde edilen değerlendirmeler sunulmuştur.

Yukarıdaki iki tablodan, üç farklı özellik kümesine ait sınıflandırma başarımları hakkında çeşitli önemli çıkarımlar yapılabilmektedir.

- **Zaman-Frekans Özellikleri:**

EKG, RR aralıkları ve EDR sinyallerinden elde edilen zaman-frekans özelliklerinin, genel olarak yüksek sınıflandırma başarımı sağladığı gözlemlenmiştir. $topK = 10$ için %86.76 test doğruluğu, 0.8242 F1 skoru ve 0.9441 AUC değeri elde edilmiştir. Bu sonuçlar, kesinlik ve duyarlılık arasında dengeli bir performansa işaret etmektedir. Ancak özgüllük değeri (0.4702) görece düşük kalmış, bu da apne olmayan olayların apne olarak sınıflandırılma eğilimini göstermektedir.

Tablo 4.1. $TopK = 10$ için çıkarılmış sınıflandırma sonuçları.

Ölçüt	Zaman-Frekans Özellikleri	CWT-CPC Özellikleri	Birleşik Özellikler
Eğitim Doğruluğu	90.13%	79.83%	90.19%
Test Doğruluğu	86.76%	80.20%	88.77%
Kesinlik (Precision)	0.8156	0.7044	0.8233
Duyarlılık (Recall)	0.8329	0.8072	0.8895
F1-Skoru	0.8242	0.7523	0.8551
AUC	0.9441	0.8767	0.9505
MCC	0.7181	0.5925	0.7652
Cohen's Kappa	0.718	0.5887	0.7637
Özgüllük	0.4702	0.3628	0.8867

Tablo 4.2. $TopK = 15$ için çıkarılmış sınıflandırma sonuçları.

Ölçüt	Zaman-Frekans Özellikleri	CWT-CPC Özellikleri	Birleşik Özellikler
Eğitim Doğruluğu	90.44%	80.40%	90.94%
Test Doğruluğu	85.64%	81.42%	88.99%
Kesinlik (Precision)	0.817	0.7116	0.835
Duyarlılık (Recall)	0.7918	0.8246	0.8779
F1-Skoru	0.8042	0.7639	0.8559
AUC	0.9431	0.8853	0.956
MCC	0.691	0.6112	0.7675
Cohen's Kappa	0.6908	0.6066	0.7669
Özgüllük	0.54	0.3443	0.897

- CWT-CPC Özellikleri:**


Yalnızca solunumla ilişkili sinyallerden (EDR, genlik, eğim) elde edilen CWT-CPC tabanlı özelliklerin sınıflandırma başarımı, zaman-frekans özelliklerine kıyasla bir miktar daha düşük kalmıştır. $topK = 10$ için test doğruluğu %80.20, kesinlik 0.7044

ve AUC 0.8767 olarak hesaplanmıştır. Duyarlılık değeri yüksek kalmıştır (0.8072), bu da apne olaylarının genel olarak iyi tespit edildiğini, ancak yanlış pozitiflerin arttığını göstermektedir. Tüm özellik kümeleri arasında en düşük özgüllük değeri (0.3628) bu kümede gözlenmiştir; bu da normal (apne olmayan) segmentlerin belirgin şekilde yanlış sınıflandırıldığını göstermektedir.

- **Birleşik Özellikler:**

En yüksek genel sınıflandırma başarımı, zaman-frekans ve CWT-CPC özelliklerinin birleştirilmesiyle elde edilmiştir. $topK = 10$ için test doğruluğu %88.77, kesinlik 0.8233 ve duyarlılık 0.8895 olarak bulunmuş, bu da 0.8551 ile en yüksek F1 skoruna ulaşılmasını sağlamıştır. Ayrıca AUC değeri 0.9505 ile maksimuma ulaşmıştır ve bu durum sınıflar arası ayırt ediciliğin çok yüksek olduğunu göstermektedir. En dikkat çekici iyileşme özgüllükte gözlemlenmiştir (0.8867), bu da apne olmayan olayların doğru sınıflandırılma oranında ciddi bir artış olduğunu ortaya koymaktadır. Benzer eğilimler $topK = 15$ için de korunmuş, bu da iki özellik türünün birlikte kullanımının sağlam bir genel performans sunduğunu doğrulamaktadır.

İkili sınıflandırma problemlerinde özellikle dengesiz veri kümeleri için sınıflandırma başarımını değerlendirmede Hassasiyet-Duyarlılık (PR) eğrisi sıklıkla tercih edilmektedir. Bu eğri, farklı karar eşiklerine göre modelin hassasiyet ve duyarlılık değerleri arasındaki değişimi yansıtmaktadır. Hassasiyet, pozitif olarak tahmin edilen örneklerin ne kadarının gerçekten pozitif olduğunu gösterirken; duyarlılık, gerçek pozitif örneklerin ne kadarının doğru şekilde tahmin edildiğini belirtmektedir. Özellikle apne gibi nadir olayların tespitinde, PR eğrisi sayesinde modelin yalancı pozitif ve kaçırılan gerçek pozitifler arasındaki dengesini değerlendirmek mümkün olmaktadır. Bu çalışma kapsamında, elde edilen model çıktılarıyla PR eğrisi çizilmiş ve doğruluk-eşik dengesine dair değerlendirme yapılmıştır. Birleşik özelliklerde $topK = 15$ için PR eğrisi Şekil 4.2’de gösterilmektedir.



Şekil 4.2. Birleşik özelliklerde $topK = 15$ için PR eğrisi.


Receiver Operating Characteristic (ROC) eğrisi, bir sınıflandırma modelinin tüm eşik değerleri için duyarlılık (true positive rate) ve özgülük (false positive rate) arasındaki değişimi göstermektedir. Bu eğri, modelin pozitif sınıfı ne derece doğru tahmin ettiğini ve aynı zamanda negatif sınıfı yanlış pozitif olarak tahmin etme eğilimini ne ölçüde bastırdığını ortaya koymaktadır. ROC eğrisi altında kalan alan (AUC), modelin genel ayırt edicilik gücünü nicel olarak ifade etmektedir. Dengeli sınıf dağılımına sahip veri kümelerinde ROC eğrisi, model başarımını değerlendirmek için uygun ve yaygın bir yöntemdir. Bu çalışmada, geliştirilen sınıflandırma modeli için ROC eğrisi hesaplanmış ve modelin ayırt edicilik gücü görsel olarak sunulmuştur. Şekil 4.3'te birleşik özelliklerde $topK = 15$ için hesaplanan ROC eğrisi görünmektedir.

4.3. Özet ve Çıkarımlar

Elde edilen bulgular doğrultusunda aşağıdaki sonuçlara varılmıştır:

- Zaman-frekans tabanlı özellikler, EKG kaynaklı sinyallerle yapılan apne tespiti için güçlü bir temel performans sunmaktadır.

- Yalnızca CPC özellikleri, faydalı olmakla birlikte, apne ve apne olmayan olayları ayırt etme konusunda daha düşük etkililiğe sahiptir.



Şekil 4.3. Birleşik özelliklerde $topK = 15$ için ROC eğrisi.

- Her iki özellik kümesinin birlikte kullanımı, özellikle duyarlılık, AUC, F1 skoru ve özgüllük açısından sınıflandırıcı performansını anlamlı şekilde artırmaktadır. Dolayısıyla hem kardiyak hem de solunumsal sinyallerden elde edilen bilgilerin entegre edildiği çok modlu bir özellik füzyonu yaklaşımının, uyku apnesi olaylarının daha doğru ve güvenilir biçimde tespiti için etkili bir yöntem sunduğu sonucuna varılmıştır. Bu sonuçlar, sinyal işleme teknikleri ile makine öğrenmesinin fizyolojik olayların tespitinde birlikte kullanımının önemini desteklemektedir.

5. TARTIŞMA VE ÖNERİLER

Bu bölümde Bölüm 4’de verilen sonuçlar tartışılacak ve yeni çalışmalar için önerilerde bulunulacaktır.

5.1. Önceki Çalışmalar ile Kıyaslama

Bu tez çalışmasında, EKG sinyallerinden türetilen R-R aralıkları ve EKG-türetilmiş solunum (EDR) sinyallerinden elde edilen özniteliklere ek olarak sürekli dalgacık dönüşümüne (CWT) dayalı kardiyopulmoner eşleşim (CPC) özellikleri çıkarılmıştır. Öznitelik seçimi için minimum Redundancy Maximum Relevance (mRMR) yöntemi kullanılmış ve en bilgilendirici 10 öznitelik ile rastgele orman (Random Forest) sınıflandırıcısı eğitilmiştir. Elde edilen model, %88.99 doğruluk, 0.8779 duyarlılık ve 0.897 özgüllük değerleri ile yüksek performans göstermiştir.

Bu sonuçlar, senkroskuzing dönüşüm (SST) tabanlı CPC analizi yapılan çalışmada elde edilen %82,49 doğruluk, 0.7819 duyarlılık ve 0.7571 özgüllük sonuçlarına [42] kıyasla daha yüksek performansa işaret etmektedir. 2004 yılında yapılan bir çalışmada [82] ise, farklı zaman ölçeklerinde (30 saniye ve 5 dakika) RR ve EDR sinyalleri kullanılarak doğrusal ayırıcı bir sınıflandırıcı eğitilmiş; 30 saniyelik segmentlerde %84,6 doğruluk ve 5 dakikalık segmentlerde %95,5 birey sınıflama doğruluğu rapor edilmiştir. [41]’de geliştirilen dalgacık dönüşümü ve rastgele orman temelli yaklaşımda %82,43 doğruluk elde edilmiştir.

Oto-regresif model tabanlı çalışmada ise %85,5 doğruluk, 0.839 duyarlılık ve 0.885 özgüllük rapor edilmiştir [39]. [30]’de, tek kanallı EKG’den çıkarılan özniteliklerle yapılan sınıflandırmalarda %89 doğruluk elde edilmiştir. Zaman-frekans dağılımları

ve dinamik özniteliklerle KNN sınıflandırıcı kullanılan bir diğer çalışmada %92,67 doğruluk rapor edilmiştir [83]. Destek vektör makineleri (SVM) ile yapılan sınıflamada öznitelik kombinasyonları karşılaştırılmış ve en yüksek doğruluk değeri %96,5 olarak hesaplanmıştır [84]. Bir başka çalışmada, 1 boyutlu evrişimli sinir ağı (1D-CNN) ile derin öğrenme temelli sınıflamada %95,28 doğruluk elde edilmiştir [85]. Yapılan karşılaştırmalar sonucu Tablo 5.1’de özet olarak sunulmaktadır.

Tablo 5.1. Benzer çalışmalar ve sonuçların karşılaştırılması tablosu.

No	Yazar	Kaynak	Öznitelik	Yöntem	Doğruluk (accuracy)	Duyarlılık (Recall)	Özgüllük (specificity)
1	Wang.Y	[42]	R-R aralıkları/ EDR/SST-CPC	Karar Ağacı	82.49	0.7819	0.7571
2	P. Chazal	[82]	R-R aralıkları /EDR değişik zaman skala	LD sınıflandırıcı	87-91	0.8-1	0.95-1
3	Tuncer	[41]	Dalgacık dönüştürücü	Rasgele Orman	82.43	-	-
4	M. Mendez	[39]	HRV	KNN	85.55	0.839	0.885
5	B. Yılmaz	[30]	R-R aralıkları	SVM-KNN	89	-	-
6	Q. Manrique,	[83]	Zaman-frekans dağılımları/ dinamik öznitelikler	KNN	92.67	-	-
7	L. Almazaydeh,	[84]	Değişik epoklarda EKG	SVM	96.5	92.9	100
8	Thompson et al.	[85]	EKG sinyalleri	1D-CNN	95.28	0.9612	0.973
9	Önerilen çalışma	-	EDR (genlik,eğim,alan) CWT-CPC	Rasgele Orman	88.99%	0.8779	0.897

Sonuç olarak, bu tez çalışmasında kullanılan mRMR tabanlı öznitelik seçimi ve rastgele orman algoritması, geleneksel makine öğrenmesi yöntemlerine kıyasla rekabetçi bir doğruluk ve istikrarlı duyarlılık/özgüllük değerleri sağlamış, derin öğrenme temelli yöntemler dışında birçok literatür çalışmasını geride bırakmıştır. Özellikle duyarlılık ve özgüllük bakımından dengeli bir performans sergilenmiş, modelin genel geçerliliği güçlendirilmiştir.

5.2. Öneriler ve Gelecek Çalışma

Son yıllarda yapılan çalışmalar, EKG sinyalleri üzerinden gerçekleştirilen derin öğrenme tabanlı yöntemlerin daha yüksek doğruluk oranlarına ulaştığını göstermektedir. Bu bağlamda, ilerleyen çalışmalarda çeşitli derin öğrenme mimarileri

(örneğin 1D-CNN, LSTM, Transformer tabanlı modeller) uygulanarak performansın daha da artırılması mümkündür. Ayrıca bu tezde kullanılan veriler PhysioNet gibi açık erişimli bir veri tabanına dayansa da, gerçek dünyadan farklı yaş grupları ve klinik profillerden elde edilecek verilerle yöntemin test edilmesi, modelin genellenebilirliğini artıracak ve gerçek uygulamalara yönelik önemli bir adım olacaktır. Klinik ortamlardan toplanacak EKG verileriyle modelin doğruluğu yeniden değerlendirilerek, sistemin pratik uygulanabilirliği araştırılabilir.



KAYNAKÇA

- [1] Anu Shilvya, J., and Jose, P. S. H. "Review on Obstructive Sleep Apnea Detection Using ECG Signals." *2022 4th International Conference on Smart Systems and Inventive Technology (ICSSIT)*, 2022, pp. 680–684. IEEE.
- [2] Moridani, M. K., Heydar, M., and Jabbari Behnam, S. S. "A Reliable Algorithm Based on Combination of EMG, ECG and EEG Signals for Sleep Apnea Detection." *2019 5th Conference on Knowledge Based Engineering and Innovation (KBEI)*, 2019, pp. 256–262. IEEE.
- [3] Slowik, J. M., Sankari, A., and Collen, J. F. "Obstructive Sleep Apnea." *StatPearls*, StatPearls Publishing, 2024.
- [4] Mehrtash, M., Bakker, J. P., and Ayas, N. "Predictors of Continuous Positive Airway Pressure Adherence in Patients with Obstructive Sleep Apnea." *Lung*, vol. 197, no. 1, 2019, pp. 115–121. Springer.
- [5] Malhotra, A., Ayappa, I., Ayas, N., Collop, N., Kirsch, D., McArdle, N., Mehra, R., Pack, A. I., Punjabi, N., White, D. P., and Gottlieb, D. J. "Metrics of Sleep Apnea Severity: Beyond the Apnea-Hypopnea Index." *Sleep*, vol. 44, no. 7, 2021, zsab030. Oxford University Press.
- [6] Peppard, P. E., Young, T., Barnet, J. H., Palta, M., Hagen, E. W., and Hla, K. M. "Increased Prevalence of Sleep-Disordered Breathing in Adults." *American Journal of Epidemiology*, vol. 177, no. 9, 2013, pp. 1006–1014. Oxford University Press,
- [7] Levin, K. H., and Chauvel, P. "Jessica Vensel Rundo and Ralph Downey III." *Clinical Neurophysiology: Basis and Technical Aspects*, vol. 160, 2019, p. 381. Elsevier.
- [8] Ferber, R., Millman, R., Coppola, M., Fleetham, J., Murray, C. F., Iber, C., McCall, W. V., Nino-Murcia, G., Pressman, M., Sanders, M., Strohl, K., Votteri, B., and Williams, A. "Portable Recording in the Assessment of

Obstructive Sleep Apnea." *Sleep*, vol. 41, no. 9, 2018, zsy134. Oxford University Press,

- [9] Rosen, I. M., Kirsch, D. B., Carden, K. A., Malhotra, R. K., Ramar, K., Aurora, R. N., Kristo, D. A., Martin, J. L., Olson, E. J., Rosen, C. L., Rowley, J. A., and Shelgikar, A. V. "Clinical Use of a Home Sleep Apnea Test: An Updated American Academy of Sleep Medicine Position Statement." *Journal of Clinical Sleep Medicine*, vol. 14, no. 12, 2018, pp. 2075–2077. American Academy of Sleep Medicine.
- [10] Tang, C., Yi, W., Xu, M., Jin, Y., Zhang, Z., Chen, X., Liao, C., Smielewski, P., and Occhipinti, L. G. "A Deep Learning-Enabled Smart Garment for Accurate and Versatile Sleep Conditions Monitoring in Daily Life." *arXiv preprint*, arXiv:2408.00753, 2024.
- [11] Navarro-Martínez, S., Carrasco-Llatas, M., Matarredona-Quiles, S., Diez Ares, J. Á., Peris Tomás, N., and Trullenque Juan, R. "Feasibility of At-Home Continuous Overnight Pulse Oximetry for Obstructive Sleep Apnea Screening in Bariatric Surgery Candidates." *European Archives of Oto-Rhino-Laryngology*, vol. 278, no. 9, 2021, pp. 3533–3539. Springer.
- [12] Guilleminault, C., Connolly, S., Winkle, R., Melvin, K., and Tilkian, A. "Cyclical Variation of the Heart Rate in Sleep Apnoea Syndrome: Mechanisms, and Usefulness of 24 h Electrocardiography as a Screening Technique." *The Lancet*, vol. 323, no. 8369, 1984, pp. 126–131. Elsevier.
- [13] Penzel, T., Kantelhardt, J. W., Grote, L., Peter, J. H., and Bunde, A. "Comparison of Detrended Fluctuation Analysis and Spectral Analysis for Heart Rate Variability in Sleep and Sleep Apnea." *IEEE Transactions on Biomedical Engineering*, vol. 50, no. 10, 2003, pp. 1143–1151. IEEE.
- [14] Fonseca, P., Long, X., Radha, M., Haakma, R., Aarts, R. M., and Overeem, S. "Sleep Stage Classification with ECG and Respiratory Effort." *Physiological Measurement*, vol. 36, no. 10, 2015, pp. 2027–2040. IOP Publishing.
- [15] Kapur, V. K., Auckley, D. H., Chowdhuri, S., Kuhlmann, D. C., Mehra, R., Ramar, K., and Harrod, C. G. "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*, vol. 13, no. 3, 2017, pp. 479–504. American Academy of Sleep Medicine.

- [16] Paul, T., Hassan, O., McCrae, C. S., Islam, S. K., and Mosa, A. S. M. "An Explainable Fusion of ECG and SpO₂-Based Models for Real-Time Sleep Apnea Detection." *Bioengineering*, vol. 12, no. 4, 2025, p. 382. MDPI.
- [17] Erdenebayar, U., Kim, Y. J., Park, J. U., Joo, E. Y., and Lee, K. J., "Deep Learning Approaches for Automatic Detection of Sleep Apnea Events from an Electrocardiogram." *Computer Methods and Programs in Biomedicine*, vol. 180, 2019, p. 105001. Elsevier,
- [18] Webster, J. G. *Medical Instrumentation: Application and Design*. 4th ed., Wiley, 2009.
- [19] Malik, M., and Camm, A. J. "Heart Rate Variability." *Clinical Cardiology*, vol. 13, no. 8, 1990, pp. 570–576.
- [20] "Heart Rate Variability: Standards of Measurement, Physiological Interpretation and Clinical Use." *Circulation*, vol. 93, no. 5, 1 Mar. 1996, pp. 1043–1065.
Published by the Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology. PMID: 8598068.
- [21] R. J. Thomas, J. E. Mietus, C.-K. Peng, and A. L. Goldberger, "An electrocardiogram-based technique to assess cardiopulmonary coupling during sleep," *Sleep*, vol. 28, no. 9, pp. 1151–1161, Sep. 2005.
- [22] Peng, C. K., Havlin, S., Stanley, H. E., and Goldberger, A. L. "Quantification of Scaling Exponents and Crossover Phenomena in Nonstationary Heartbeat Time Series." *Chaos*, vol. 5, no. 1, 1995, pp. 82–87.
- [23] Moody, G. B., Mark, R. G., Zoccola, A., and Mantero, S. "Derivation of Respiratory Signals from Multi-Lead ECGs." *Computers in Cardiology*, vol. 12, 1985, pp. 113–116.
- [24] Moody, G. B., Mark, R. G., Bump, M. A., Weinstein, J. S., Berman, A. D., Mietus, J. E., and Goldberger, A. L. "Clinical Validation of the ECG-Derived Respiration (EDR) Technique." *Computers in Cardiology*, vol. 13, no. 1, 1986, pp. 507–510.
- [25] Drinnan, M., Allen, J., Langley, P., and Murray, A. "Detection of Sleep Apnoea from Frequency Analysis of Heart Rate Variability." *Computers in Cardiology 2000*, vol. 27, Cambridge, MA, USA, IEEE, 2000, pp. 259–262.
- [26] Mietus, J. E., Peng, C. K., Ivanov, P. C., and Goldberger, A. L. "Detection of Obstructive Sleep Apnea from Cardiac Interbeat Interval Time Series."

Computers in Cardiology 2000, vol. 27, Cambridge, MA, USA, IEEE, 2000, pp. 753–756.

- [27] Hossen, A. "A Soft Decision Algorithm for Obstructive Sleep Apnea Patient Classification Based on Fast Estimation of Wavelet Entropy of RRI Data." *Technology and Health Care*, vol. 13, no. 3, 2005, pp. 151–165.
- [28] Penzel, T., McNames, J., de Chazal, P., Raymond, B., Murray, A., & Moody, G. (2002). Systematic comparison of different algorithms for apnoea detection based on electrocardiogram recordings. *Medical and Biological Engineering and Computing*, 40(4), 402–407.
- [29] Khandoker, A. H., Palaniswami, M., & 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), 37–48.
- [30] Yilmaz, B., Asyali, M. H., Arikan, E., Yektin, S., and Ozgen, F. "Sleep Stage and Obstructive Apneic Epoch Classification Using Single-Lead ECG." *Biomedical Engineering Online*, vol. 9, 2010.
- [31] Le, T. T., Le, V. T., & Le, B. T. (2018). Obstructive Sleep Apnea Detection using Frequency Analysis of Electrocardiographic RR Interval and Machine Learning Algorithms. *Journal of Biomedical Physics & Engineering*, 8(2), 133–144.
- [32] Wang, C., Nguyen, T. N., & Nguyen, T. (2021). Screening sleep apnea based on heart rate variability and long short-term memory. *Frontiers in Physiology*, 11, 607521.
- [33] Cao, Z., Liu, J., & Zhang, L. (2022). R-R interval-based sleep apnea screening by a recurrent neural network in a large clinical polysomnography dataset. *Sleep*, 45(6), zsac051.
- [34] Osa, T., Morita, Y., Tsuji, T., et al. (2024). A multi-task learning model using RR intervals and respiratory effort to assess sleep disordered breathing. *BioMedical Engineering OnLine*, 23, 16.
- [35] Alvarez, D., Hornero, R., Abásolo, D., del Campo, F., & Zamarrón, C. (2009). Sleep apnea detection based on spectral analysis of three ECG-derived respiratory signals. *Physiological Measurement*, 30(3), 275–289.
- [36] Tong, G. M., Zhang, H. C., Guo, J. H., & Han, F. (2014). Detection of sleep apnea-hypopnea syndrome with ECG derived respiration in Chinese

- population. *International Journal of Clinical and Experimental Medicine*, 7(5), 1269–1275.
- [37] Li, Y., Wang, Y., & Zhang, H. (2021). Obstructive sleep apnea detection from single-lead electrocardiogram signals using one-dimensional squeeze-and-excitation residual group network. *Computers in Biology and Medicine*, 135, 104573.
 - [38] van Steenkiste, T., Varon, C., & Van Huffel, S. (2023). The Use of Respiratory Effort Improves an ECG-Based Deep Learning Algorithm to Assess Sleep-Disordered Breathing. *Diagnostics*, 13(13), 2146.
 - [39] Mendez, M. O., Ruini, D., Villantieri, O., Matteucci, M., Penzel, T., and Bianchi, A. "Detection of Sleep Apnea from Surface ECG Based on Features Extracted by an Autoregressive Model." *Proceedings of the IEEE International Conference on Engineering in Medicine and Biology Society (EMBS 2007)*, Aug. 2007, pp. 6105–6108.
 - [40] Pinho, J. C., & Muehlsteff, J. (2011). Electrocardiogram-derived respiration in screening of sleep-disordered breathing. *Sleep & Breathing*, 15(2), 225–233.
 - [41] Tuncer, E. "Development of New Machine Learning Based Algorithm for the Diagnosis of Obstructive Sleep Apnea from ECG Data." *Journal of Computer Science Research*, vol. 5, no. 3, 2023, pp. 15–21.
 - [42] Wang, Y., Shi, W., and Yeh, C.-H. "A Novel Measure of Cardiopulmonary Coupling During Sleep Based on the Synchrosqueezing Transform Algorithm." *IEEE Journal of Biomedical and Health Informatics*, vol. 27, no. 4, April 2023, pp. 1790–1800.
 - [43] Ichimaru, Y., and Moody, G. B. "Development of the Polysomnographic Database " *Psychiatry and Clinical Neurosciences*, vol. 53, 1999, pp. 175–177.
 - [44] McNicholas, W., Doherty, L., Ryan, S., Garvey, J., Boyle, P., and Chua, E. *St. Vincent's University Hospital/University College Dublin Sleep Apnea Database*. 2004.
 - [45] Penzel, T., Moody, G. B., Mark, R. G., Goldberger, A. L., and Peter, J. H. "Apnea-ECG Database." *Computers in Cardiology 2000*, vol. 27, 2000, pp. 255–258.
 - [46] <https://www.physionet.org/content/slpdb/1.0.0/>
 - [47] <https://physionet.org/content/ucddb/1.0.0/>
 - [48] <https://physionet.org/content/apnea-ecg/1.0.0/>

- [49] Jeyajothi, E. S., Anitha, J., Rani, S., and Tiwari, B. "A Comprehensive Review: Computational Models for Obstructive Sleep Apnea Detection in Biomedical Applications." *BioMed Research International*, vol. 2022, 2022, Article ID 7242667.
- [50] Kher, R. "Signal Processing Techniques for Removing Noise from ECG Signals." *Journal of Biomedical Engineering Research*, vol. 3, no. 1, 2019, pp. 1–9.
- [51] Clifford, G. D., Azuaje, F., and McSharry, P. E. *Advanced Methods and Tools for ECG Data Analysis*. Artech House, 2006.
- [52] Sörnmo, L., and Laguna, P. *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. Elsevier, 2005.
- [53] Moody, G. B., and Mark, R. G. "The Impact of the MIT-BIH Arrhythmia Database." *IEEE Engineering in Medicine and Biology Magazine*, vol. 20, no. 3, 2001, pp. 45–50.
- [54] Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., and Adam, M. "Automated Diagnosis of Coronary Artery Disease Using Different Durations of ECG Segments with Convolutional Neural Network." *Knowledge-Based Systems*, vol. 132, 2017, pp. 62–71.
- [55] Faust, O., Hagiwara, Y., Hong, T. J., Lih, O. S., and Acharya, U. R. "Deep Learning-Based Automatic Classification of Heartbeats Using ECG Signals: A Review." *Computers in Biology and Medicine*, vol. 100, 2018, pp. 376–385.
- [56] Hannun, A. Y., Rajpurkar, P., Haghpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P., and Ng, A. Y. "Cardiologist-Level Arrhythmia Detection and Classification in Ambulatory Electrocardiograms Using a Deep Neural Network." *Nature Medicine*, vol. 25, no. 1, 2019, pp. 65–69.
- [57] Qureshi, S. A., Masood, I., Hashmi, M., Hanninen, S., Sarwar, M., and Jameel, A. "Noise Reduction of Electrocardiographic Signals Using Wavelet Transforms." *Elektronika ir Elektrotechnika*, vol. 20, no. 2, 2014, pp. 51–55.
- [58] Dai, B., and Bai, W. "Denoising ECG by Adaptive Filter with Empirical Mode Decomposition." *arXiv*, 18 Aug. 2021.
- [59] Oppenheim, A. V., Willsky, A. S., and Nawab, S. H. *Signals and Systems*. 2nd ed., Prentice Hall, 1996.
- [60] Su, K. *Analog Filters*. 2nd ed., Springer, 2002.

- [61] Savitzky, A., and Golay, M. J. E. "Smoothing and Differentiation of Data by Simplified Least Squares Procedures." *Analytical Chemistry*, vol. 36, no. 8, 1964, pp. 1627–1639.
- [62] Schafer, R. W. "On the Frequency-Domain Properties of Savitzky-Golay Filters." *2011 Digital Signal Processing and Signal Processing Education Meeting (DSP/SPE)*, Sedona, AZ, USA, 2011, pp. 54–59.
- [63] Pan, J., and Tompkins, W. J. "A Real-Time QRS Detection Algorithm." *IEEE Transactions on Biomedical Engineering*, no. 3, 1985, pp. 230–236.
- [64] Hamilton, P. S. "Open Source ECG Analysis Software Documentation." *Computers in Cardiology*, vol. 29, 2002, pp. 101–104.
- [65] Mateo, J., and Laguna, P. "Analysis of Heart Rate Variability in the Presence of Ectopic Beats Using the Heart Timing Signal." *IEEE Transactions on Biomedical Engineering*, vol. 50, no. 3, Mar. 2003, pp. 334–343.
- [66] Varon, C., Caicedo, A., Testelmans, D., Buyse, B., and Van Huffel, S. "A Novel Algorithm for the Automatic Detection of Sleep Apnea From Single-Lead ECG." *IEEE Transactions on Biomedical Engineering*, vol. 62, no. 9, Sept. 2015, pp. 2269–2278.
- [67] Charlton, P. H., Bonnici, T., Tarassenko, L., Alastruey, J., Clifton, D. A., Beale, R., and Watkinson, P. J. "Extraction of Respiratory Signals from the Electrocardiogram and Photoplethysmogram: Technical and Physiological Determinants." *Physiological Measurement*, vol. 38, no. 5, 2017, pp. 669–690.
- [68] Bandt C, Pompe B. Permutation entropy: a natural complexity measure for time series. *Phys Rev Lett*. 2002 Apr 29;88(17):174102.
- [69] Polat, H. "Permütasyon Entropi Tabanlı Karmaşıklık Analizi ile EEG İşaretlerinden Şizofreni Tespiti." *Journal of the Institute of Science and Technology*, vol. 12, no. 4, Dec. 2022, pp. 2085–2096.
- [70] Vázquez-Seisdedos, C. R., Neto, J. E., Marañón Reyes, E. J., Klautau, A., & de Oliveira, R. C. L. F. "New approach for T-wave end detection on electrocardiogram: Performance in noisy conditions." *BioMedical engineering OnLine*, vol. 10, no. 1, 2011, pp. 1–26.
- [71] Cohen, L. *Time-Frequency Analysis*. Prentice Hall, 1995.
- [72] Addison, P. S. "Wavelet transforms and the ECG: a review." *Physiological Measurement*, vol. 26, no. 5, 2005, pp. R155–R199.
- [73] Mallat, S. (1999). *A Wavelet Tour of Signal Processing*. Academic Press.

- [74] Torrence, C., and Compo, G. P. "A practical guide to wavelet analysis." *Bulletin of the American Meteorological Society*, vol. 79, no. 1, 1998, pp. 61–78.
- [75] Penzel, T., Kantelhardt, J. W., Bartsch, R. P., Riedl, M., & Havlin, S. "Modulations of heart rate, ECG, and cardio-respiratory coupling observed in polysomnography." *Frontiers in Physiology*, vol. 7, 2016, article 460.
- [76] Bunde, A., Havlin, S., Kantelhardt, J. W., Penzel, T., Peter, J. H., & Voigt, K. "Correlation between normal heartbeat intervals and mortality risk in patients with congestive heart failure." *Physica A: Statistical Mechanics and its Applications*, vol. 330, no. 1–2, 2003, pp. 412–417.
- [77] Thomas, R. J., et al. "Quantitative assessment of sleep-disordered breathing using ECG-based cardiopulmonary coupling analysis." *Sleep*, vol. 28, no. 9, 2005, pp. 1151–1161.
- [78] Samuel, A. L. "Some Studies in Machine Learning Using the Game of Checkers." *IBM Journal of Research and Development*, vol. 3, no. 3, 1959, pp. 210–229.
- [79] Kourou, K., Tsiliki, G., Christodoulou, E., Naoum, P., and Fotiadis, D. I. "Machine Learning Applications in Cancer Prognosis and Prediction." *Computational and Structural Biotechnology Journal*, vol. 13, 2015, pp. 8–17.
- [80] Breiman, L. "Random Forests." *Machine Learning*, vol. 45, no. 1, 2001, pp. 5–32.
- [81] Sharma, M., Sharma, B., Acharya, U. R., and Garcia, M. "A Machine Learning Approach to Detect Sleep Apnea Using Photoplethysmogram Signals." *Biomedical Signal Processing and Control*, vol. 59, 2020, article 101877.
- [82] de Chazal, P., Penzel, T., and Heneghan, C. "Automated Detection of Obstructive Sleep Apnea at Different Time Scales Using the Electrocardiogram." *Physiological Measurement*, vol. 25, no. 4, 2004, pp. 967–983.
- [83] Quiceno-Manrique, A. F., Alonso-Hernandez, J. B., Travieso-Gonzalez, C. M., Ferrer-Ballester, M. A., and Castellanos-Dominguez, G. "Detection of Obstructive Sleep Apnea in ECG Recordings Using Time-Frequency Distributions and Dynamic Features." *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2009, pp. 5559–5562.

- [84] Almazaydeh, L., Elleithy, K., and Faezipour, M. “Obstructive Sleep Apnea Detection Using SVM-Based Classification of ECG Signal Features.” *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2012, pp. 4938–4941.
- [85] Thompson, S., Fergus, P., Chalmers, C., and Reilly, D. “Detection of Obstructive Sleep Apnea Using Features Extracted from Segmented Time-Series ECG Signals Using a One Dimensional Convolutional Neural Network.” *2020 International Joint Conference on Neural Networks (IJCNN)*, 2020, pp. 1–8.



EKLER

EK 1

Tablo Ek1.1. Apne-EKG Veri tabanı kayıtları hakkında ek bilgiler.

Kayıt	Uzunluk	Apne olmayan	Apne	Saat	AI	HI	AHI	Yaş	Cinsiyet	Boy	Ağırlık
	Dakika	Dakika	Dakika	Apneli saat						Cm	Kg
a01	490	20	470	9	12.5	57.1	69.6	51	M	175	102
a02	529	109	420	9	57.2	12.3	69.5	38	M	180	120
a03	520	274	246	9	38.4	0.7	39.1	54	M	168	80
a04	493	40	453	9	73.4	4	77.4	52	M	173	121
a05	455	179	276	8	35	6	41	58	M	176	78
a06	511	305	206	8	16.6	8.1	24.7	63	M	179	104
a07	512	190	322	9	46	17	63	44	M	177	105
a08	502	313	189	7	32	10	42	51	M	179	88
a09	496	115	381	9	23.1	8.6	31.7	52	M	178	82
a10	518	418	100	6	11	10	21	58	M	176	78
a11	467	245	222	8	11	3	14	58	M	168	103
a12	578	44	534	10	70	10.2	80.2	52	M	173	121
a13	496	252	244	9	32	10	42	51	M	179	88
a14	510	127	383	8	17.3	37.4	54.7	51	M	175	102
a15	511	143	368	9	46	6	52	60	M	176	113
a16	483	163	320	7	17	24	41	44	M	177	105
a17	486	328	158	5	21	12	33	40	M	179	96
a18	490	52	438	9	75.5	6.9	82.4	52	M	178	82
a19	503	298	205	9	34	0	34	55	M	178	90
a20	511	196	315	9	35	6	41	58	M	176	78
b01	488	469	19	2	0.12	0.12	0.24	44	F	170	63
b02	518	425	93	5	14	5	19	53	M	176	85
b03	442	369	73	4	22	2	24	53	M	176	85
b04	430	420	10	1	0.7	0	0.7	42	M	180	64
b05	434	377	57	3	2	3	5	52	M	180	135
c01	485	485	0	0	0	0	0	31	M	184	74
c02	503	502	1	0	0	0	0	37	M	180	83
c03	455	455	0	0	0	0	0	39	M	184	65
c04	483	483	0	0	0	0	0	41	F	180	65
c05	467	464	3	0	0	0	0	28	F	169	57
c06	469	468	1	0	0	0.25	0.25	28	F	171	65
c07	454	450	4	0	0	0	0	30	F	168	56
c08	535	535	0	0	0	0	0	42	M	180	64
c09	469	467	2	0	0	0	0	37	M	180	83
c10	432	431	1	0	0	0	0	27	M	184	72
x01	524	149	375	9	46	17	63	44	M	177	105
x02	470	261	209	7	27.3	10.4	37.7	46	M	167	69
x03	466	454	12	1	0.13	0	0.13	44	F	170	63
x04	483	483	0	0	0	0	0	39	M	184	65

Kayıt	Uzunluk	Apne olmayan	Apne	Saat	AI	HI	AHI	Yaş	Cinsiyet	Boy	Ağırlık
	Dakika	Dakika	Dakika	Apneli saat						Cm	Kg
x05	506	190	316	9	34	0	34	55	M	178	90
x06	451	451	0	0	0	0	0	31	E	170	66
x07	510	270	240	8	11	10	21	58	E	176	78
x08	518	194	324	8	48	0	48	55	E	178	90
x09	509	342	167	5	1.8	16.7	18.5	43	E	177	80
x10	511	415	96	6	3	7	10	39	E	170	131
x11	458	445	13	1	2	3	5	52	E	180	135
x12	528	471	57	4	21	12	33	40	E	179	96
x13	507	215	292	8	18.5	0.2	18.7	57	E	171	97
x14	491	52	439	9	61.2	18.3	79.5	38	E	180	120
x15	499	299	200	8	11.3	4.6	15.9	63	E	179	104
x16	516	451	65	4	22	2	24	53	E	176	85
x17	401	400	1	0	0	0	0	27	K	158	53
x18	460	458	2	0	0	0	0	27	E	184	72
x19	488	81	407	9	50.1	6.1	56.2	54	E	168	80
x20	514	250	264	8	34	9	43	51	E	179	88
x21	511	391	120	4	14	5	19	53	E	176	85
x22	483	481	2	0	0	0	0	27	K	158	53
x23	528	409	119	3	9.9	4.4	14.3	43	E	177	80
x24	430	429	1	0	0	0	0	31	E	170	66
x25	511	220	291	9	48	0	48	55	E	178	90
x26	521	177	344	9	14.4	0.7	15.1	57	E	171	97
x27	499	11	488	9	71	4	75	60	E	176	113
x28	496	62	434	9	71	4	75	60	E	176	113
x29	471	471	0	0	0	0	0	41	K	180	65
x30	512	186	326	9	17	24	41	44	E	177	105
x31	558	42	516	10	86.8	6.7	93.5	29	K	183	100
x32	539	114	425	9	63.3	8.5	71.8	29	K	183	100
x33	474	471	3	0	0.13	0	0.13	28	K	169	57
x34	476	472	4	0	0.38	0	0.38	30	K	168	56
x35	484	484	0	0	0	0	0	31	E	184	74

Burada Apne indeksi (AI), saatte gözlemlenen apne sayısını ifade eder, HI ise saatte gözlemlenen hipopne sayısını belirtir. Apne-Hipopne indeksi (AHI), AI ve HI'nin toplamı olarak tanımlanır.