

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ELEKTROKARDİYOĞRAFI SİNYALLERİNDEN ARİTMİLERİN YAPAY
ZEKA DESTEKLİ SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Büşra ÜNLÜ

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Osman EROĞUL

ARALIK 2024





TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Büşra ÜNLÜ



ÖZET

Yüksek Lisans Tezi

ELEKTROKARDİYOGRAFİ SİNYALLERİNDEN ARİTMİLERİN YAPAY

ZEKA DESTEKLİ SINIFLANDIRILMASI

Büşra ÜNLÜ

TOBB Ekonomi ve Teknoloji Üniversitesi
Fen Bilimleri Enstitüsü
Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Osman EROĞUL

Tarih: Aralık 2024

Elektrokardiyografi (EKG) sinyallerinde kalbin belirli bir düzende ve düzenli aralıklarla atması sonucu oluşan normal sinüs ritimi dışında gözlenen ritimler aritmi olarak adlandırılır ve atımın bozuklukları normal olmayan bir durumun hatta hayati risklerin göstergesi olabilir. Bu nedenle aritmilerin bulunması ve hangi tür aritmi olduğunun belirlenmesi önemlidir. EKG sinyallerinden elde edilen öznitelikler ile eğitilen makine öğrenmesi modelleri ile aritmilerin sınıflandırılması uzun yıllardır araştırmacılar tarafından ilgi çeken konulardan olmuştur. Bununla birlikte uzun süren ön sinyal işleme adımlarının ve öznitelik çıkarma adımlarının olmadığı derin öğrenme tekniklerinin kullanılması da güncel konular arasındadır. Bu yöntemlerin performanslarının karşılaştırılması ve kullanılan model parametrelerinin belirlenmesi aşamaları önem taşımaktadır. Bu tez çalışmasında, EKG sinyallerinin analizi ile iki farklı ritim sınıflandırma yöntemi geliştirilerek bu yöntemlerin performansı değerlendirilmiştir. İlk yöntem kalp hızı değişkenliği analizi ile elde edilen özniteliklerle eğitilen makine öğrenmesi modellerinin kullanıldığı sınıflandırma yöntemidir. Sinyal ön işleme ve öznitelik çıkarımı olmadan EKG sinyallerinin spektogram ve skalogram görüntülerinin evrimsel sinir ağlarına girdi olarak verilerek sınıflandırılması ikinci yöntemdir. Bu iki sınıflandırma yönteminin performans sonuçları karşılaştırılmıştır. Çalışmada MIT-BIH Aritmi Veri Tabanı kullanılmıştır. Çalışmada normal sinüs ritmi, atriyal fibrilasyon, sol dal bloğu, sağ dal bloğu,

ventriküler begemini, pacemaker ritim sınıflandırılan ritimlerdir. Kalp hızı değişkenliği analizi tabanlı özniteliklerle gerçekleştirilen sınıflandırmada öncelikle sinyalde gürültü giderme işlemi uygulanmıştır. Filtrelenmiş sinyaller üzerinden R dalgası tepe noktalarının bulunması gerçekleştirilmiştir. R dalgası tepe noktaları ile kalp hızı değişkenliği analizi yapılmış ve öznitelikler çıkarılmıştır. Sonrasında ise makine öğrenmesi modelleri bu öznitelikler ile eğitilmiş ve model performansları değerlendirilmiştir. Tez kapsamında Karar Ağacı, Destek Vektör Makinesi, K-En Yakın Komşu, Topluluk Öğrenme modelleri çalışılmıştır.

Derin öğrenme, evrişimsel sinir ağları tabanlı sınıflandırmada ise EKG sinyallerinde gürültü giderme işlemi yapılarak spektrogram ve skalogram görüntüleri elde edilmiştir. Bu görüntüler farklı sinir ağlarına girdi olarak verilmiştir. Tez kapsamında GoogleNet, ResNet-50, AlexNet ve SqueezeNet çalışılan evrişimsel sinir ağlarıdır. Farklı sinir ağlarının performansının skalogram ve spektrogram görüntüleri ile eğitildiğinde nasıl performans gösterdiği belirlenmiştir. Bu karşılaştırmaya ek olarak öznitelik çıkartma ve makine öğrenmesi modelleri ile gerçekleştirilen ritim sınıflandırma performansının derin öğrenme modelleri kullanılarak gerçekleştirilen sınıflandırma performansı karşılaştırılmıştır.

Kalp hızı değişkenliği analizinde iki dakikalık sinyal uzunluğu ile gerçekleştirilen aritmi sınıflandırmasında en yüksek doğruluk değeri %87,91 ile topluluk öğrenme modeli ile elde edilmiştir. Beş dakikalık sinyal uzunluğunda ise destek vektör makinesi ile %90,48 doğruluğa ulaşılmıştır. Spektrogram çıktıları kullanılarak gerçekleştirilen sınıflandırmada maksimum doğruluk AlexNet ile %91,90'dır. Skalogram çıktıları ile gerçekleştirilen sınıflandırmada ise maksimum doğruluk GoogleNet modeli ile %92,85 olarak elde edilmiştir. En yüksek sınıflandırma performansı skalogram görüntüleri ve evrişimsel sinir ağları kullanılarak elde edilmiştir.

Gözlemlenen bulgular, değerlendirilen bu modellerin EKG sinyallerinde aritmilerin sınıflandırılmasında yüksek performans verdiğini göstermektedir.

Anahtar Kelimeler: Elektrokardiyografi, Kalp hızı değişkenliği, Aritmi sınıflandırılması, Makine öğrenmesi, MIT-BIH aritmi veri tabanı, Derin öğrenme, Evrişimsel sinir ağları.

ABSTRACT

Master of Science

CLASSIFICATION OF ARRHYTHMIAS BASED ON ARTIFICIAL INTELLIGENCE FROM ELECTROCARDIOGRAPHY SIGNALS

Büşra ÜNLÜ

TOBB University of Economics and Technology
Institute of Natural and Applied Sciences
Biomedical Engineering Science Programme

Supervisor: Prof. Dr. Osman EROĞUL

Date: December 2024

Heart rhythms that differ from the normal sinus rhythm occurs as a result of the heart beating in a certain order and at regular intervals in electrocardiography (ECG) signals, are called arrhythmias. Irregularities in the rhythm can be an indicator of abnormal condition or even vital risks. Consequently, the detection and accurate classification of arrhythmias are critically important. The classification of arrhythmias using machine learning models trained with features obtained from ECG signals has been a subject of interest for researchers for many years. However, the application of deep learning techniques which eliminate the need for signal processing and feature extraction steps is also prominent research topic. Comparing the performance of these methods and determining the model parameters are essential for better results. In this thesis, two different rhythm classification methods are developed with the analysis of ECG signals and the performance of these methods are evaluated. The first method involves the rhythm classification with using machine learning models trained with features obtained from Heart Rate Variability (HRV) analysis. The second method classify rhythms by spectrogram and scalogram images as input to Convolutional

Neural Networks (CNNs) without requiring signal preprocessing and feature extraction. The performance results of these two classification methods were compared. MIT-BIH Arrhythmia Database is used in the study. Normal Sinus Rhythm (N), Atrial Fibrillation (AFIB), Left Bundle Branch Block (LBBB), Right Bundle Branch Block (RBBB), Ventricular Bigeminy (B), Pacemaker Rhythm (P) are classified. In the classification performed with HRV-based features, firstly the noise removal process is applied to the signal. R wave peaks are detected on the filtered signals. HRV analysis is performed with R wave peaks and features are extracted. These features are then used to train machine learning models, including Decision Trees (DT), Support Vector Machines (SVM), K-Nearest Neighbors (KNN), and Ensemble Learning methods. In deep learning, CNN-based classification, spectrogram and scalogram images are generated from the denoised ECG signals. These images are then input into CNN architectures such as GoogleNet, ResNet-50, AlexNet, and SqueezeNet to assess their classification performance. It is determined how the performance of different neural networks performed when trained with scalogram and spectrogram images. In addition, the rhythm classification performance performed with feature extraction and machine learning models is compared with the classification performance performed using deep learning models. In the HRV analysis, the highest accuracy value in arrhythmia classification performed with a two-minute signal length is obtained with the ensemble learning model with 87.91%. In the five-minute signal length, 90.48% accuracy is achieved with the SVM. In the classification performed using spectrogram images, the maximum accuracy is 91.90% with AlexNet. In the classification performed with scalogram images, the maximum accuracy is obtained as 92.85% with the GoogleNet. These findings demonstrate that scalogram-based CNN models achieve superior classification performance, highlighting their potential for accurately detecting and classifying arrhythmias in ECG signals. The observed findings show that these evaluated models provide high performance in classifying arrhythmias in ECG signals.

Keywords: Electrocardiography, Heart rate variability, Arrhythmia classification, Machine learning, MIT-BIH arrhythmia database, Deep learning, Convolutional neural networks.

TEŞEKKÜR

Çalışmalarım boyunca rehberliği, desteği, yardım ve katkılarıyla beni yönlendiren danışman hocam Osman EROĞUL'a teşekkür ederim. Bu çalışmayı mümkün kılmakla kalmayıp, gelecekteki hedeflerime yön vermemde de büyük bir rol oynadı. Onunla çalışma fırsatı bulduğum için kendimi son derece şanslı hissediyorum. Kıymetli tecrübelerinden faydalandığım ODTÜ, Elektrik Elektronik Mühendisliği Bölümü öğretim üyesi Yeşim Serinağaoğlu DOĞRUSÖZ'e teşekkür ederim. Fikret KÜÇÜKDEVECİ ve KARDİNERO MEDİKAL SİSTEMLER'deki meslektaşlarıma da destekleri, mükemmel bir çalışma ortamı sağladıkları için teşekkür ederim. Tez çalışmasının bir kısmı 1501- TÜBİTAK Sanayi Ar-Ge Projeleri Destekleme Programı kapsamında (Proje No:3200745, KARDİNBULU-TH Uzaktan Hasta Takip Platformu) gerçekleştirildiği için teşekkür ederim. Hayatım boyunca koşulsuz sevgi ve destekleri ile her zaman yanımda olan aileme ve arkadaşlarıma sonsuz minnettarlığımı sunuyorum. Böyle ebeveynlere sahip olduğum için ne kadar şanslı olduğumu kelimelerle anlatamam.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET.....	vii
ABSTRACT	ix
TEŞEKKÜR.....	xi
İÇİNDEKİLER.....	xiii
ŞEKİL LİSTESİ.....	xv
ÇİZELGE LİSTESİ.....	xvii
KISALTMALAR.....	xix
SEMBOL LİSTESİ	xxi
1. GİRİŞ.....	1
1.1 Tezin Amacı ve Önemi.....	2
1.2 Tezin Kapsamı.....	3
2. KALBİN ANATOMİSİ VE FİZYOLOJİSİ	5
2.1 Kalbin Anatomik Yapısı.....	5
2.2 Kalbin Elektriksel İletim Sistemi	6
2.3 Elektrokardiyogram.....	7
2.4 EKG Derivasyonları	9
2.5 Kalp Ritimleri.....	11
2.5.1 Sinüs Ritmi.....	12
2.5.2 Erken Vurular.....	13
2.5.3 Atriyal Aritmiler.....	15
2.5.4 Ventriküler Aritmiler.....	16
2.5.5 İletim Blokları	17
2.5.6 Pacemaker Ritim	17
2.6 Kalp Hızı Değişkenliği Analizi	18
2.6.1 Zaman Bölgesi Analizleri.....	19
2.6.1.1 İstatiksel Parametreler	20
2.6.1.2 Geometrik Parametreler	25
2.6.2 Frekans Bölgesi Analizler	27
2.6.3 Doğrusal Olmayan Analizler.....	29
3. KURAMSAL TEMELLER VE LİTERATÜR ARAŞTIRMASI	37
3.1 Spektrogram	37
3.2 Skalogram.....	38
3.3 Makine Öğrenmesi Modelleri.....	39
3.3.1 Karar Ağaçları.....	39
3.3.2 Destek Vektör Makinesi.....	40
3.3.3 K-En Yakın Komşu.....	41
3.3.4 Topluluk Öğrenme Yöntemleri	42
3.4 Derin Öğrenme	44
3.5 Evrimsel Sinir Ağları	44
3.5.1 ESA'nın Temel Basamakları.....	45
3.5.1.1 Giriş Katmanı	45
3.5.1.2 Evrişim Katmanı	45
3.5.1.3 Havuzlama Katmanı.....	47
3.5.1.4 Tam Bağlantılı Katman	47
3.5.1.5 Çıkış Katmanı.....	48
3.5.2 GoogleNet	48
3.5.3 ResNet-50.....	49

3.5.4 SqueezeNet.....	51
3.5.5 AlexNet	52
3.6 Aritmi Sınıflandırılmasında Öne Çıkan Çalışmalar	52
4. MATERYAL VE YÖNTEM.....	61
4.1 Kullanılan Veri Seti.....	61
4.2 Ön Çalışma	63
4.3 Tez Akış Şeması.....	65
4.4 Sinyal Ön İşleme	65
4.4.1 EKG Sinyali Gürültü Giderme.....	65
4.4.2 R Dalgalarının Bulunması.....	67
4.4.3 Kalp Hızı Değişkenliği Analizinin Gerçekleştirilmesi	71
4.4.4 Spektrogram Görüntülerinin Üretilmesi	72
4.4.5 Skalogram Görüntülerinin Üretilmesi.....	75
4.5 Öznitelik Çıkarımı.....	77
4.6 Makine Öğrenmesi Modelleri ile Aritmilerin Sınıflandırılması.....	78
4.7 Aritmilerin Evrimsel Sinir Ağları ile Sınıflandırılması.....	81
5. BULGULAR, DEĞERLENDİRME VE TARTIŞMA.....	83
5.1 Bulgular	84
5.2 Değerlendirme ve Tartışma	90
6. SONUÇ VE ÖNERİLER.....	97
KAYNAKLAR	99
ÖZGEÇMİŞ.....	Hata! Yer işareti tanımlanmamış.

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Kalbin Anatomik Yapısı	5
Şekil 2.2 : Kalbin Elektriksel İletimi.....	6
Şekil 2.3 : EKG sinyalinin oluşturun aksiyon potansiyellerinin zamana göre değişimi	7
Şekil 2.4 : EKG karakteristik dalga formu	9
Şekil 2.5 : Einthoven Üçgeni.....	10
Şekil 2.6 : Göğüs Derivasyonları	11
Şekil 2.7 : (a) Normal Sinüs Ritmi, (b) Sinüs Taşikardi, (c) Sinüs Bradikardi, (d) Sinüs Aritmisi.....	13
Şekil 2.8 : (a) Supraventriküler Erken Atım, (b) Ventriküler Erken Vuru.....	14
Şekil 2.9 : Bigemini.....	15
Şekil 2.10 : (a) Atriyal Flutter, (b) Atriyal Fibrilasyon.....	16
Şekil 2.11 : (a) Ventriküler Taşikardi, (b) Ventriküler Fibrilasyon	17
Şekil 2.12 : (a) RBBB ve (b) LBBB.....	18
Şekil 2.13 : Pacemaker Ritim.....	18
Şekil 2.14 : KHD Analizi Parametreleri.....	19
Şekil 2.15 : (a) KHD Histogram ve (b) KHD Takogram Eğrileri.....	20
Şekil 2.16 : RR Histogram üzerinde üçgen indeksi ve TINN değerlerinin gösterimi	26
Şekil 2.17 : KHD sinyali güç spektral yoğunluğu.....	28
Şekil 2.18 : Poincaré Grafiği	30
Şekil 3.1 : EKG sinyali ve EKG sinyalinin spektrogram çıktısı	38
Şekil 3.2 : EKG sinyali ve EKG sinyalinin skalogram çıktısı	39
Şekil 3.3 : Karar ağacı örnek şeması.	40
Şekil 3.4 : DVM iki boyutlu uzayda örnek gösterimi	41
Şekil 3.5 : Evrişimli sinir ağı yapısı	45
Şekil 3.6 : İki boyutlu evrişim işlemi örneği.....	46
Şekil 3.7 : Havuzlama işlemi örnek gösterimi	47
Şekil 3.8 : Başlangıç modülü mimarisi	49
Şekil 3.9 : GoogleNet mimarisi.....	49
Şekil 3.10 : Residual blok diyagramı	50
Şekil 3.11 : ResNet-50 mimarisi	50
Şekil 3.12 : Fire modül mimarisi.....	51
Şekil 3.13 : SqueezeNet Mimarisi.....	51
Şekil 3.14 : AlexNet Mimarisi	52
Şekil 4.1 : Tez Akış Şeması	65
Şekil 4.2 : Orijinal sinyal ve filtrelenmiş EKG sinyali (121 numaralı veri)	67
Şekil 4.3 : Pan ve Tompkins Algoritması aşamaları	68
Şekil 4.4 : QRS kompleksi bulunması adımları: (a) orijinal sinyal, (b) filtrelenmiş sinyal, (c) türev alınmış sinyal çıktısı, (d) kare alınmış sinyal, (e) kayan pencere entegrasyonu ve eşik çizgisi, (f) QRS kompleksi R tepe değerlerinin gösterilmesi	70

Şekil 4.5 : Beş dakikalık ve iki dakikalık sinyal parçaları, R tepe değerleri ve KHD takogram çıktıları	72
Şekil 4.6 : Hamming ve Hanning penceresi.....	73
Şekil 4.7 : (a) Hamming 200ms pencere, (b) Hanning 200ms pencere, (c) Hamming 500ms pencere, (d) Hanning 500ms pencere, (e) Hamming 1000ms pencere, (f) Hanning 1000ms pencere, (g) Hamming 2000ms pencere, (h) Hanning 2000ms pencere spektogram çıktıları	74
Şekil 4.8 : Wavelet fonksiyonları.....	75
Şekil 4.9 : (a) Meksika şapkası, (b) Morse, (c) Morlet, (d) Bump, (e) db4, (f) gaus4, (g) gaus8 wavelet fonksiyonları ile alınmış skalogram çıktıları	76



ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 4.1 : Aritmi türleri ve kullanılan veri numaraları.....	62
Çizelge 4.2 : Spektogram parametrelerinin belirlenmesi	74
Çizelge 4.3 : Skalogram parametrelerinin belirlenmesi	77
Çizelge 4.4 : Karar Ağacı parametreleri.....	78
Çizelge 4.5 : Destek Vektör Makinesi parametreleri	79
Çizelge 4.6 : k-En Yakın Komşu parametreleri	80
Çizelge 4.7 : Topluluk Öğrenmesi modeli parametreleri	81
Çizelge 5.1 : Farklı makine öğrenmesi modelleri ile aritmilerin sınıflandırılma sonuçları (Epok süresi: iki dakika).....	84
Çizelge 5.2 : Farklı makine öğrenmesi modelleri ile aritmilerin sınıflandırılma sonuçları (Epok süresi: beş dakika).....	86
Çizelge 5.3 : Spektogram görüntülerinden farklı sinir ağları ile aritmilerin sınıflandırılma sonuçları.....	88
Çizelge 5.4 : Skalogram görüntülerinden farklı sinir ağları ile aritmilerin sınıflandırılma sonuçları.....	89
Çizelge 5.5 : MIT-BIH Aritmi Veri tabanı için aritmi sınıflandırılması benzer çalışmaların karşılaştırmaları	96



KISALTMALAR

EKG	: Elektrokardiyografi
KHD	: Kalp Hızı Değişkenliği (Heart Rate Variability)
SA	: Sinoatrial
AV	: Atrioventriküler
ms	: Milisaniye
AFIB	: Atriyal Fibrilasyon
B	: Ventriküler Bigemini
P	: Pacemaker Ritim
SVPB	: Supraventriküler Erken Atım
VEV	: Ventriküler Erken Vuru
LBBS	: Sol Dal Bloğu (Left Bundle Branch Block)
RBBB	: Sağ Dal Bloğu (Right Bundle Branch Block)
PSD	: Güç Spektral Yoğunluk
KZFD	: Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform)
SDD	: Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)
KA	: Karar Ağacı (Decision Tree)
DVM	: Destek Vektör Makinesi (Support Vector Machine)
KNN	: K - En Yakın Komşu (K-Nearest Neighbors)
ESA	: Evrişimsel Sinir ağları (Convolutional Neural Networks, CNN)
N	: Normal Sinüs Ritmi
PPV	: Pozitif Prediktif Değeri (Positive Predictive Value)
Hz	: Hertz
ReLU	: Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
ResNet	: Residual Network
HR	: Kalp Hızı (Heart Rate, HR)
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)



SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
N	RR aralıklarının sayısı
HR_i	i. atımın kalp atış hızı
RR_i	i. RR aralık değeri
RR_{i+1}	Bir sonraki RR aralık değeri
h	RR histogram yüksekliği
A	RR histogramın integrali
X	Zaman serisi
ω	Frekans
N	Sinyaldeki örnek sayısı
T	Sinyalin periyodu
w	Pencere fonksiyonu
U	Normalizasyon faktörü
m	Zaman
n	Parça
τ	Pozisyon
s	Ölçek
W	Dalgacık katsayısı
ψ	Dalgacık fonksiyonu
W	Görüntü boyutu
F	Filtre genişliği
P	Dolgu Miktarı
S	Adım boyutu
k	Kontrol edilen komşu sayısı



1. GİRİŞ

Kalbin kasılıp gevşemesini sağlayan elektriksel aktivitenin elektrotlar aracılığıyla vücut yüzeyinden kaydedilmesi ile elde edilen elektrokardiyogram (EKG) kayıtlarının yorumlanması ile birçok kalp anormallliği tespit edilebilmektedir. Normal kalp ritmi olarak adlandırılan sinüs ritmi dışındaki ritimler, aritmi olarak adlandırılmaktadır [1].

European Heart Rhythm Association, 2016 yayınladığı raporda sadece Avrupa’da 15 milyon kalp yetmezliği hastasının olduğu belirtmiştir. Kalp yetmezliği hastalığının görülme oranı(prevalans) %2 iken bu oran 75 yaşının üstünde %20lere ulaşmakta olduğunu bildirmektedir. Kalp yetmezliği ile hastaneye yatan vakaların çoğunun kardiyak aritmilere bağlı olabileceğini belirtmektedir [2].

Andrew ve arkadaşlarının yaptığı çalışmada kalp yetmezliği ile hastaneye yatırılan hastaların %40’ında atriyal fibrilasyon görüldüğünü ve birbirini tetikleyebildiğini belirtmiştir [3].

Başka bir çalışmada hastane dışında gerçekleşen ani kardiyak ölüm (AKÖ) (Sudden Cardiac Death, SCD) durumlarının kaydedilen ilk ritimlerin ventriküler aritmiler (VA’lar) olduğu ve prevalanslarının %30 ile %75 oranında değiştiği belirtilmiştir [4].

Ciddi hastalıkların sebebi veya ilk belirteci olan aritmilerin tanısı ve sınıflandırılması hastalar için uygun tedavi planının belirlenmesinde önemli yere sahiptir. Farklı türdeki aritmiler farklı tedavileri gerektirebilmektedir. Ani kardiyak ölüm, inme riskini arttıran aritmi türlerinin tespit edilip sınıflandırılması sağlık personellerinin belirli ritim türüyle ilişkilendirilen risk düzeyini değerlendirmeleri açısından önemli olmaktadır.

Aritmi teşhisi hastanelerin kardiyoloji bölümü uzman doktorları kardiyologlar tarafından gerekli görülen testler yapılarak gerçekleştirilmektedir. Bu testler kalbin elektriksel aktivitesinin izlendiği EKG, 24 saatlik EKG kaydı yapan Holter cihazları, kalbin ve kalp kapakçıklarının yapısının ve kan akışının izlendiği ekokardiyogram (EKO) testidir. Bu testlerin yapılması ve uzman teknisyen, doktorlar tarafından uzun EKG kayıtlarının incelenmesi ve yorumlanması ekstra iş gücü ve zaman gerektirmektedir. Bu olumsuzlukların giderilmesi için son dönemlerde bilgisayar destekli aritmi analizi ve aritmi sınıflandırma algoritmaları popüler olmuştur. Bu algoritmalar uzaktan takip edilen hastaların kullanımında hastalara, hastanede ise uzman sağlık yetkililerine avantaj sağlamaktadır.

Aritmi analizi ve sınıflandırılması işlemleri, hastalardan alınan EKG kayıtları kullanılarak elde edilen parametreler ile gerçekleştirilmektedir, bu parametrelere sinyale özgü dalgaların özellikleri, kalp hızı değişkenliği (KHD) parametreleri ve daha birçok parametre örnek verilebilir.

Gelişen yapay zekâ teknolojileri ve otomatik sınıflandırma algoritmalarına ilgi artmakta, bu alanda yapılan çalışmalarda EKG kayıtlarının gürültü ve sinyal bozukluklarından arındırılması, özniteliklerin çıkarılması ve normal sinüs atım ve aritmilerin ayırt edilmesi için sınıflandırma algoritmalarının eğitilmesi ve test edilmesi önem kazanmaktadır.

Kalp hızı değişkenliği analizleri tanı koymada yaygın kullanıldığı, kolay elde edildiği ve EKG sinyallerinin yorumlanması için önemli parametreler sunması dolayısıyla bu parametreler ile yüksek doğrulukta aritmi sınıflandırma yapılması güncel araştırma konuları arasına girmiştir. Bu konulara ek ön sinyal işleme ve öznitelik çıkarma adımları olmadan, daha kısa zamanda yüksek doğrulukta sinir ağları ile aritmilerin sınıflandırılması güncel araştırma konuları arasındadır.

1.1 Tezin Amacı ve Önemi

Kalp ritim bozuklukları daha ciddi kalp hastalıklarına ya da hayat kalitesini düşüren yaşam koşullarına neden olmaktadır. Bu atımların belirlenmesi, sınıflandırılması ve EKG kayıtlarındaki anormal atımların miktarının belirlenmesi tanı ve tedavi açısından önemlidir. Tanının yapılması oluşabilecek daha ciddi kalp hastalıklarının gerçekleşmeden önlenmesi, kişinin yaşam koşullarının düzeltilmesi için önem taşımaktadır.

Aritmilerin belirlenmesinde literatürde istatistiksel yöntemler, makine öğrenmesi yöntemleri ve derin öğrenme yöntemlerinin kullanılması güncel çalışma konularıdır.

Bu tez çalışmasında son dönemlerde sinyal işleme, makine öğrenmesi ve derin öğrenme alanında yaşanan bilimsel gelişmelerden faydalanarak; normal ritim ve aritmilerin sınıflandırılması amaçlanmaktadır. Bu amaçla, KHD tabanlı öznitelikler ile makine öğrenmesi algoritmaları kullanılarak aritmi sınıflandırılması sonuçları elde edilmiştir. Bu analize ek olarak öznitelik çıkartma ve ön sinyal işleme adımları olmadan sinir ağları algoritmaları ile aritmilerin sınıflandırılması gerçekleştirilmiştir. Bu iki analiz sonuçlarının karşılaştırılması amaçlanmaktadır. Bu yolla aritmi

sınıflandırmada yüksek performans gösteren metottun belirlenmesi amaçlanmaktadır. Bu sayede erken tanı ve evde izleme ile hastanelerin iş gücünün azalacağını, uzun holter kayıtlarının incelenmesinde oluşacak zaman kaybının azalacağı düşünülmektedir. Sonuç olarak; geliştirilecek bu yöntemlerle hem hastaların sağlığına hem de uzman sağlık çalışanlarına önemli katkılar sağlanabileceği düşünülmektedir.

1.2 Tezin Kapsamı

Bu tez çalışmasında KHD analizi tabanlı öznitelikler kullanılarak makine öğrenmesi algoritmaları ile normal ritim ve aritmi sınıflandırılması gerçekleştirilmiştir, ayrıca spektrogram ve skalogram çıktıları ile evrişimsel sinir ağları kullanılarak ritimlerin sınıflandırılması gerçekleştirilmiştir. İki farklı yöntem kullanarak ritim sınıflandırması gerçekleştirilmiş, bu yöntemlerin performansları değerlendirilmiştir.

Tezin ikinci bölümünde, kalbin anatomisi ve fizyolojisi altında kalbin anatomik yapısı, kalbin elektriksel iletim sistemi, elektrokardiyogram, EKG derivasyonları, kalp ritimleri, normal ve aritmi EKG sinyalleri, kalp hızı değişkenliği analizi, kalp hızı değişkenliği analizleri parametreleri özetlenmeye çalışılmıştır.

Üçüncü bölümde; kuramsal temeller ve literatür araştırması verilmiştir. Kullanılan spektrogram, skalogram, makine öğrenmesi modelleri, derin öğrenme, evrişimsel sinir ağları, evrişimsel sinir ağlarının temel katmanları ve tez kapsamında da kullanılan önceden eğitilmiş evrişimsel sinir ağları özetlenmiştir. Daha sonra literatürde öne çıkan aritmi sınıflandırma çalışmaları özetlenmiştir.

Dördüncü bölümde, materyal ve yöntem altında çalışmada kullanılan veri seti ve bu veri setinin özelliklerine değinilmiştir. Ön çalışmadan behsedilmiş ve tez kapsamında uygulanan sinyal ön işleme kısmında gerçekleştirilen EKG sinyali gürültü giderme, R dalgalarının bulunması, KHD analizi, spektrogram ve skalogram görüntülerinin elde edilmesi özetlenmiş, öznitelik çıkarımı, makine öğrenmesi modelleri ile aritmilerin sınıflandırılması, aritmilerin evrişimsel sinir ağları ile sınıflandırılması ve bu aşamalarda kullanılan parametreler açıklanmıştır.

Beşinci bölümde, bulgular, değerlendirme ve tartışma altında iki sınıflandırma yöntemi için elde edilen çıktılar, istatistiksel bulgular değerlendirilmiştir. Sınıflandırmada kullanılan modellerin performansları karşılaştırılmıştır. Literatürde

bulunan benzer alıřmalar ile en yksek performans gsteren model karřılařtırmasına yer verilmiřtir.


Tez alıřmasının genel deęerlendirmesi ve neriler ise; altıncı blmde sonu ve neriler altında sunulmuřtur.



2. KALBİN ANATOMİSİ VE FİZYOLOJİSİ

2.1 Kalbin Anatomik Yapısı

Kalp, düşük basınçlı toplardamarlardan yüksek basınçlı atardamarlara kan akışını ritmik kasılmalarla oluşturduğu basınç farkı sayesinde sağlar. Dolaşım sisteminde görevli temel organdır. Dört adet odacıktan oluşur. Üstteki odacıklar; sağ ve sol atriyum(kulakçık) ve alttaki odacıklar ise sağ ve sol ventrikül(karıncık) olarak adlandırılır. Dokulardan gelen kirli kan ve akciğerden gelen temiz kan kulakçıklara dolar, sağda bulunan triküspit kapakçık ve solda bulunan mitral kapak sayesinde kan kulakçıklara geri kaçamaz ve karıncıklara ulaşır. Septum sağ ve sol odacıklarda bulunan kanın birbirine karışmasını engeller. Kirli kan karıncıklardan sağda bulunan pulmoner kapak ile akciğerlere iletilir ve akciğerlerde temizlenen temiz kan ise solda bulunan aort kapak ile vücuda pompalanır. Bu mekanizma sürekli tekrarlanarak devam eder. Kalbin anatomik yapısı Şekil 2.1’de gösterilmektedir.




Şekil 2.1 : Kalbin Anatomik Yapısı [Url-1]

Bu mekanizma elektriksel bir uyarım ile kulakçıklarda başlar ve karıncıklarda devam eder. Karıncıklarda gerçekleşen kasılma ile kan pulmoner arter ve aorta iletilir. Bu kasılma sistol olarak adlandırılır. Karıncıkların gevşeme ile karıncıklara kan dolar. Karıncıkların gevşemesi ise diastol olarak adlandırılır. Sağlıklı bir insanda gözlenen sistolik ve diastolik basınç değeri 120/80 mmHg civarındadır.

2.2 Kalbin Elektriksel İletim Sistemi

Kalbin elektriksel aktivitesini başlatan özelleşmiş ve kendi kendine depolarize olabilen pacemaker hücrelerinden oluşan hücreler yumağına sinoatrial (SA) düğüm denir. SA düğümünde oluşan elektriksel sinyal kulakçıklar boyunca yayılır. İki kulakçık da depolarize olur ve kulakçıklar kasılır. Elektriksel sinyal kulakçıklardan karıncıklara atrioventriküler (AV) düğüm ile iletilir. Karıncıklar ve kulakçıkların aynı anda kasılmasının engellenmesi AV düğümüne ulaşan sinyalin gecikmesi ile gerçekleştirilir. Elektriksel sinyal his demetine, his demetinden sonra sağ ve sol dallara iletilir. Kalbin iki tarafında bulunan purkinje lifleri ventrikülerdeki kas hücrelerini uyarır. Kalbin elektriksel iletim sistemi Şekil 2.2’de verilmiştir. Ventrikülerin kasılması ile kan karıncıklardan kalp dışına pompalanır. Bu elektriksel iletim sayesinde kalp kası hücrelerinin uyarılması sonucu kalbin çalışmasına özgü bir elektriksel sinyal oluşur [5].




Şekil 2.2 : Kalbin Elektriksel İletimi [5].

Kalp atım hızına SA düğümü karar verir fakat bunu tek başına yapamaz ve otonomik sinir sisteminden etkilenir. Artan sempatik aktivite sonucu kalp atım hızı hızlanırken, artan parasempatik aktivite sonucu kalp atım hızı azalır.

2.3 Elektrokardiyogram

Bir kalp döngüsü boyunca milyonlarca kalp hücresinin uyarılması sonucu aksiyon potansiyelleri üretilir. Bu aksiyon potansiyellerin dalga formları depolarizasyon(kasılma) ve repolarizasyon(gevşeme) sırasında farklı formlardadır. Repolarizasyon sırasında daha yumuşak ve düz dalga formu gözlenirken, depolarizasyon sırasında tepe değeri yüksek dalgalar gözlenmektedir. Kalbin farklı bölgelerinden farklı zamanlarda alınan aksiyon potansiyellerin zamansal ve vektörel toplanması sonucu özel bir dalga formu oluşur [6]. Bu dalga formu vücuda yerleştirilen elektrotlar ile yakalanır ve elektriksel değişimlerini yansıtır. Elektrokardiyograf cihazları ile gerçekleştirilen bu kaydedilme Elektrokardiyografi olarak adlandırılır. Elde edilen grafiğe Elektrokardiyogram denir. Kalpte farklı bölgelerden farklı zamanlarda elde edilen aksiyon potansiyelleri ve EKG dalga formu Şekil 2.3'te gösterilmektedir.




Şekil 2.3 : EKG sinyalinin oluşturulan aksiyon potansiyellerinin zamana göre değişimi [7]

EKG sinyalinin tipik bir dalga formu vardır. Bu dalga formu zamana (x eksen) karşı elektriksel voltaj (y eksen) grafiği şeklinde gösterilir. EKG sinyali kendine özgü karakteristik dalgalar içerir. Sağ ve sol kulakçıkların depolarizasyonu P dalgası ile gösterilmektedir. P dalgası 300 mikro volttan düşük genlikte ve 120 milisaniyeden(ms) kısa süren pozitif dalga formundadır. QRS kompleksi sağ ve sol ventriküler depolarizasyonu göstermektedir. Sağlıklı bir insanda QRS kompleksi uzunluğu 70-120 ms arasında gözlenmektedir. QRS kompleksinde gözlenen ilk negatif dip noktası Q dalgası, ilk pozitif tepe noktası R dalgası ve ikinci negatif dip noktası S dalgasıdır. QRS kompleksinin genlik değeri 2-3 mikrovolt'a kadar ulaşabilmektedir. T dalgası ise ventriküler repolarizasyonu gösterir. Uzunluğu 300 ms ye kadar ulaşabilir. T dalgasından sonra gözlenebilen bir diğer dalga formu U dalgasıdır. U dalgasının kaynağı kesin değilse de ikincil ventriküler kasılma sonucu oluşabilmektedir.

EKG sinyallerinin incelenmesinde zamana göre değerlendirme de oldukça önemlidir. Segmentler, bir dalga formunun sonundan diğer dalga formunun başına kadar geçen alanı belirtmek için kullanılırken; aralıklar, iki dalga arası geçen zamanı ifade etmektedir. Segmentler için zamandan çok morfolojiden bahsedilmektedir. Örneğin segmentlerin yükselmesi, alçalması.

PR segmenti, P dalgasının bitiminden QRS kompleksinin başlangıcına kadarki bölgeyi ifade eder. ST segmenti, QRS dalgasının bitiminden T dalgasının başlangıcına kadar olan sinyal bölgesini belirtmektedir. ST segmentindeki morfolojik değişiklik (ST çökmesi ya da ST yükselmesi) iskemi belirtisi olabilmektedir. TP segmenti, T dalgasının sonunda P dalgasının başladığı alanı ifade eder. Bu alan taban çizgisi olarak kabul edilir ve referans noktası olarak alınarak segmentler için çökme, yükselme yorumu yapılabilir.

PR aralığı, P dalgasının başlangıcından QRS dalgası başlangıcına kadar geçen süreyi belirtir. QRS aralığı, QRS dalgasının süresini ifade eder. Bu ölçüm Q dalgasının başından S dalgasının sonuna kadar geçen süredir. QT aralığı, Q dalgasının başından T dalgasının sonuna kadar geçen süreyi ifade eder. RR aralığı ise bir atımda bulunan R dalgasının tepe noktasından bir sonra gelen atımdaki R tepe noktası arasındaki geçen süreyi ifade eder [8]. EKG'de bulunan dalgalar, segmentler ve aralıklar Şekil 2.4'te gösterilmektedir.



Şekil 2.4 : EKG karakteristik dalga formu [5]

2.4 EKG Derivasyonları

Vücut yüzeyinin belirli bölümlerine yerleştirilen elektrotlar sayesinde kalbin ürettiği elektriksel potansiyeller elde edilebilmektedir. Kalbin farklı bölgelerinin incelenmesi için birden fazla elektrot kullanılır. Elektrotlar arasında oluşan potansiyeller farkın gösterilmesine derivasyon adı verilir. Bu bağlamda elektrot ve derivasyon kavramları ayrışmaktadır [8]. Klinikte en yaygın kullanılan vücut üzerine 10 adet elektrodun yerleştirilmesi ile kaydedilen standart 12 derivasyonlu EKG ölçümüdür. Standart bipolar ekstremitte derivasyonları, unipolar güçlendirilmiş ekstremitte derivasyonları ve unipolar göğüs derivasyonlarıdır.


Sol bacak (Left Leg, LL), sağ kol (Right Arm, RA) ve sol kol (Left Arm, LA) arasındaki voltaj farkının ölçüldüğü standart bipolar ekstremitte derivasyonu 3 adettir. Bu bölümlerden elde edilen voltaj değerleri sırası ile V_{LL} , V_{RA} ve V_{LA} ile ifade edilmektedir.

$$I = V_{LA} - V_{RA} \quad (2.1)$$

$$II = V_{LL} - V_{RA} \quad (2.2)$$

$$III = V_{LL} - V_{LA} \quad (2.3)$$

Frontal düzlemdeki merkezde kalp olacak şekilde birbirleriyle 60°'lik açı yapan üç eksen üzerindeki izdüşümlerinin ölçülmesi ile kardiyak vektörü izdüşümü belirlenir. Bu eksenlerin oluşturduğu üçgene Einthoven Üçgeni adı verilir. Einthoven Üçgeni Şekil 2.5'te gösterilmektedir.



Şekil 2.5 : Einthoven Üçgeni [5]


Unipolar güçlendirilmiş ekstremite derivasyonları 3 adettir ve aVF, aVL ve aVR olarak adlandırılır. Bu derivasyonların ölçülmesinde standart bipolar ekstremite derivasyonlarının ölçümünde kullanılan elektrotlar kullanılır. Einthoven Üçgeni'nde bir köşesi ile geriye kalan iki köşenin ortalaması arasındaki voltaj farklarının hesaplanması ile bulunmaktadır.

$$aVR = V_{RA} - \frac{V_{LA} + V_{LL}}{2} \quad (2.4)$$

$$aVL = V_{LA} - \frac{V_{RA} + V_{LL}}{2} \quad (2.5)$$

$$aVF = V_{LL} - \frac{V_{LA} + V_{RA}}{2} \quad (2.6)$$

Unipolar göğüs derivasyonları, diğer bir adıyla prekordiyal derivasyonlar, daha ayrıntılı görüş için göğüs üzerine 6 adet elektrodun yerleştirilmesi ile alınır. Bu derivasyonlar V1, V2, V3, V4, V5 ve V6 olarak gösterilmektedir. Prekordiyal derivasyon ölçümü için elektrotların yerleşimi Şekil 2.6’da gösterilmektedir.



Şekil 2.6 : Göğüs Derivasyonları [9]

Göğüs derivasyonlarının kaydedilmesi özellikle olarak kalbin yapısal ve işlevsel bozukluklarının gözlenmesi için önem taşımaktadır. Örneğin, V1 ve V2 sağ ventrikül aktivitesini yansıtırken, V3 ve V4 derivasyonları sol ventrikülün ön duvarını, V5 ve V6 derivasyonları ise yan duvarından gelen elektriksel aktiviteyi göstermektedir [6].

2.5 Kalp Ritimleri

SA düğümü tarafından başlatılan elektriksel dürtü ile kalp ritmi kontrol edilmektedir. Dinilenim durumunda normal ritim dakikada 50-100 atım olmalıdır. Normal ritimden farklı gözlenen hız, iletim ve düzenliliğindeki farklılıklara aritmi denir.

Elektriksel dürtünün SA düğümü dışındaki diğer pacemaker hücreleri tarafından oluştuğunda veya elektriksel uyarılarının iletişiminin bozulduğunda aritmi gözlenebilmektedir. Çeşitli durumlarda kalp atış hızının ayarlanmasından sorumlu parasempatik ve sempatik sinir sisteminin aritmilerin oluşmasında kontrolü yoktur.

Elektriksel uyarıların yayılımının tamamen ya da kısmi engellendiği durumlarda da atımın şekli ya da kalp atım hızı etkilenmekte ve aritmi oluşmaktadır.

Aritmiler oluşum noktalarına göre sınıflandırılırlar. Farklı aritmi türleri için kulakçıklar ve karıncıkların birbiri ile ilişkileri aşağıda verilmiştir.

- a) Atriyal ve ventriküler ritim ilişkilidir. Ritim bozukluğu ventrikül ya da atriyum kaynaklı olabilir.
- b) Atriyal ve ventriküler ritim ilişkilidir. Atriyal ritim ventriküler ritmin hızından fazla ise ritim bozukluğu atriyum kaynaklı olabilir.
- c) Atriyal ve ventriküler ritim ilişkili, ventriküler ritim atriyal ritimden fazla ise ritim bozukluk kaynağı ventrikül olabilir.
- d) Atriyal ve ventriküler ritim birbirinden bağımsız, aynı hızda ya da birisi diğerinden fazla olduğu durumlarda da aritmi gözlenebilmektedir.

Aritmiler kaynak aldıkları noktaya göre sınıflandırılmalarından farklı olarak atımın hızına göre de sınıflandırılmaktadır. Kalbin dakikada 60 atımdan düşük kalp hızında olması Bradikardi diye adlandırılırken dakikada 100 atımdan fazla kalp hızının olması Taşikardi olarak adlandırılır. Örneğin, dakikada 100 atımı geçen ve atriyum kaynaklı ritim bozukluğu Atriyal Taşikardi olarak adlandırılır [6].

2.5.1 Sinüs Ritmi


Normal ritim, sinüs ritmi kalbin elektriksel aktivitesinin ilk ateşlendiği SA düğümünde ritmik olarak üretilen aksiyon potansiyelleri ve bütün kalp boyunca depolarizasyonun gerçekleşmesi ile kontrol edilir. SA düğümü korku anında ya da ilaç etkisi ile normalden daha hızlı ateşleme yaparsa Sinüs Taşikardi olarak adlandırılır. SA düğümü kondisyonu yüksek bazı atletlerde ve yaşlılarda çok fazla kalp atışı yavaşlatıcı ilaçlar alındığında normalden daha yavaş ateşleme yapar ise bu ritme Sinüs Bradikardi denir. Akciğerlerde meydana gelen hafif değişikliklere karşı parasempatik sistemin yavaş yanıtı ile patolojik olmayan Sinüs Aritmisi olarak bilinen nefes alma nedeniyle kalp atış hızında döngüsel değişiklikler olabilir [10]. Bu ritimler on saniyelik EKG sinyalleri halinde Şekil 2.7’de gösterilmiştir.



(a)



(b)



(c)



(d)

Şekil 2.7 : (a) Normal Sinüs Ritmi, (b) Sinüs Taşikardi, (c) Sinüs Bradikardi, (d) Sinüs Aritmisi

2.5.2 Erken Vurular

Normal sinüs ritmi beklenen sinüs atımı yerine beklenenden önce meydana gelen bir atım ile bozulmaya uğrar. Bu atım Erken Atım (Premature Beat), Ektopik Atım ve Ekstrasistol olarak adlandırılır. Bu atım SA düğümü dışında herhangi bir noktadan kaynak bulabilir. Bu atım normal veya anormal formda olabileceği gibi P dalgasının varlığını da etkileyebilir.

Erken atımlar kaynak noktalarına göre isimlendirilirler. Erken atımın oluşmasına neden olan kaynak nokta karıncıklardan bağımsız yani kulakçık veya AV düğümü kaynaklı ise Supraventriküler Erken Atım (Supraventricular Premature Beat, SVPB) olarak adlandırılır. Sinüs düğümü dışında, atriyumun herhangi bir yerinden kaynak

alıyorsa Atriyal Prematüre Atım (APA), Atriyal Prematür Sistol (APS) (Premature Atrial Complex, PAC) olarak adlandırılırlar [10].

Erken atım karıncıklardan köken alıyorsa bu erken atım Ventriküler Erken Vuru (VEV) (Ventricular Premature Beat, VPB veya Premature Ventricular Complex, PVC) olarak adlandırılmaktadır. Bu atımlar Ventriküler Prematür Atım (VPA), Ventriküler Ekstra Sistol (VES) olarak da isimlendirilmektedir. Karıncıklarda oluşan bu beklenmedik atım nedeniyle bir sonraki sinüs atımı da etkilenir ve erken atım ile sinüs atım arasında geçen süre uzar. Bu duraklamaya kompensatör duraklama denir. Bu duraklamanın iki sinüs atımdaki R dalgaları arasındaki RR uzunluğundan fazla olması beklenir. VPB normal iletim yolunu izlemediği için uzamış QRS morfolojisi ile sonuçlanabilir. Kompensatör duraklama ise RR aralığının uzamasına neden olur. Karıncıklardaki farklı noktalarda oluşan ateşleme sonucu gözlenen ventriküler erken vurular birden fazla QRS kompleksi morfolojisinde olabilmektedir [6]. Bu normal olmayan atımlara örnekler Şekil 2.8’de verilmiştir. Şekilde a numaralı EKG sinyalinde mavi ok ile gösterilen SVPB beşinci sinüs atımından sonra meydana gelmiştir. Anormal P dalgası formu bir önceki atımın T dalgasını etkilemiştir. Şekilde b numaralı EKG sinyalinde ise VEV atımlar mavi ok ile işaretlenmiştir.



(a)



(b)

Şekil 2.8 : (a) Supraventriküler Erken Atım, (b) Ventriküler Erken Vuru

Normal sinüs ritim sayısına ve ondan sonra gelen ventriküler erken vuru sayısına göre ritim türleri değişiklik göstermektedir. Normal sinüs ritminden sonra bir adet erken vuru gözleniyorsa bu ritim Bigemini olarak adlandırılmaktadır. Şekil 2.9’da mavi ok ile gösterilen VEV atım ve bigemini EKG örneği gösterilmektedir. Benzer şekilde her

iki sinüs atımından sonra bir adet ventriküler erken vuru gözleniyorsa bu ritim Trigemini olarak adlandırılmaktadır. Üç normal atımdan sonra gözlenen bir adet erken vurunun olduğu ritim ise Kuadrigemini olarak adlandırılmaktadır. İki adet ventriküler erken vuru arka arkaya gelmesi ile Ventriküler Couplet; üç adet erken vurunun arka arkaya gelmesi ile ise Ventriküler Triplet oluşmaktadır. Kalp hızının yavaş olduğu ve erken vurunun erken olduğu durumlarda sinüs atımı normal zamanında gözlenebilir. Bu tür erken vurular enterpolasyonlu olarak adlandırılır [6].



Şekil 2.9 : Bigemini

2.5.3 Atriyal Aritmiler

Atriyumlardaki elektriksel iletim bozuklukları sonucu kaynak noktalarına göre birden fazla ritim bozukluğundan bahsedilmektedir. Kulakçıkların depolarize olması sonucu EKG sinyalinde gözlemlenen dalga P dalgasıdır. Atriyumlardaki ektopik odağın konumuna göre P dalgasının olması gerektiği şekilden farklı negatif formda görülmesi ya da hiç gözlenmemesi (QRS kompleksi ile çakışması) ile karakterize edilmektedir. Elektriksel ateşlemenin kaynak noktası SA düğümünden uzakta ve AV düğümüne yakın ise elektriksel iletim normalden farklı yayılım gösterir ve anormal, negatif P dalgası gözlemlenir. Kaynak noktası AV düğümüne ve karıncıklara yakın ise ventriküler depolarizasyon ve atriyumların depolarizasyonu aynı anda başlayabilir. Bu durumda P dalgasının gözlemlenmediği ve QRS kompleksi ile çakıştığı atım formu gözlenir [6].

Atriyal Taşikardi, uyarıların atriyumun değişik noktalarından bir veya daha fazla odaktan oluşması sonucu gözlemlenen bir atım bozukluğu türüdür. Elektriksel uyarılar ventrikülere iletilir. Dakikada gerçekleşen atım sayısı 140-200 atıma ulaşabilir. Bu hız nedeniyle P dalgaları T dalgaları ile çakışabilir.

Atriyal Flutter ve Atriyal Fibrilasyon atriyumlardaki ateşlemenin artması ile ventriküllerle senkronize çalışmaması sonucu oluşur. P dalgasının morfolojisi bu atımlarda bozulmuştur ve yerini daha düz ve dalgalı bir yapıya bırakmıştır. Bu atım

bozukluğu kan akışını da etkileyebilmektedir. Kulakçıklarda kan akışı yavaşlamakta ve pıhtı oluşmasına neden olabilmektedir. Pıhtının diğer vücut bölümlerine ulaşması ise felç ile sonuçlanabilmektedir. Kalbin dakikada 300 defa attığı ve F dalgası olarak adlandırılan testere dişine benzer özelleşmiş dalga formunun gözlemlendiği düzenli ve hızlı ritim bozukluğu Atriyal flutter olarak adlandırılmaktadır. Atriyumlarda ateşlenen bütün P dalgaları ventrikülere iletilemez ve AV düğümünde bloklanır. Atriyal fibrilasyon ise dakikada 400-700 atımın gerçekleştiği atım bozukluğu türüdür. Atriyumların atriyal flutterdan farklı olarak atriyumların titreşmesi, düzensiz kasılması ve ventrikülerinde düzensiz depolarizasyonu sonucu gerçekleşir. Bu çok biçimli dalgalar f olarak ifade edilir. Atriyal flutter ve Atriyal fibrilasyon dalga formları Şekil 2.10'da gösterilmektedir.



Şekil 2.10 : (a) Atriyal Flutter, (b) Atriyal Fibrilasyon


2.5.4 Ventriküler Aritmiler

Atriyal taşiaritmilere benzer mekanizmaya sahip ventriküler taşiaritmiler Ventriküler Taşikardi, Ventriküler Flutter ve Ventriküler Fibrilasyondur. Bu dalga formları Şekil 2.11'de gösterilmektedir. Ventriküler taşikardi kalbin dakikada 120 atımdan fazla attığı durumlarda gözlenir. Morfolojik olarak QRS kompleksi daha geniş ve yüksek genlik değerine sahiptir. P dalgaları görünmeyebilir. T dalgalarını belirgindir ve ventriküler döngü birbirini takip eder. Ventriküler flutter normal EKG dalga formundan farklı olarak daha karmaşık bir dalga formundadır. Belirgin QRS kompleksi ve T dalgası içermez. Büyük genlikte dalgalar gözlemlenir. Ventriküler flutter ventriküler fibrilasyona dönüşebilir. Ventrikülerin düzenli olarak depolarizasyon gerçekleştiremediği atım bozukluğu Ventriküler Fibrilasyondur. Bu

aritmi türünde dakikada 350-400 atım gözlenebilir. Bu ritim sonucu kalp vücuda ve beyine kan gönderemez. Kalp ve solunum durması ile sonuçlanıp ölümcül olabilir [6].



(a)



(b)

Şekil 2.11 : (a) Ventriküler Taşikardi, (b) Ventriküler Fibrilasyon


2.5.5 İletim Blokları

Kalbin elektriksel iletimi iletim yolundaki blok nedeni ile bozulabilir. Bu iletim AV düğümünün gerçekleştirdiği kulakçıklardan karıncıklar arasındaki elektriksel iletim ile ilişkilidir. Bu iletimde eğer dürtüler gecikmeli iletilirse AV bloğu türü minör olarak adlandırılır. Dürtülerden bazılarının ventrikülere ulaşmaması sonucu AV blok türü orta derece AV bloğu. Hiçbir dürtünün ventrikülere ulaşmadığı blok ise tam AV bloğu olarak adlandırılır.

Sol Dal Bloğu (Left Bundle Branch Block, LBBB), normalde septum soldan sağa doğru aktive olurken sol dal bloğunda, uyarı önce sağ dal demeti aracılığı ile sağ ventriküle, oradan da septum üzerinden sol ventriküle yayıldığında gözlenmektedir. Bu yayılım sonucu QRS kompleksinin süresinde uzama gözlenebilir. RBBB ve LBBB ritim formu Şekil 2.12’de gösterilmektedir. Sağ Dal Bloğu (Right Bundle Branch Block, RBBB) ise kalbin normal elektriksel aktivitesinin bloklanması sonucu elektriksel iletimde ve sağ ventrikül depolarizasyonunda gecikme olur. Bu blok türünde de gecikme sonucu QRS kompleksinin süresinde gecikmeler gözlenebilir [6].



(a)




(b)

Şekil 2.12 : (a) RBBB ve (b) LBBB

2.5.6 Pacemaker Ritim

Kalp pilleri iki elektrodu da kalp içinde (bipolar) hem kulakçık hem karıncık etkili ya da yalnızca bir elektrodu kalp içinde diğer elektrot kalp pilinin üzerinde (unipolar) kulakçık veya karıncık etkili şeklinde olabilmektedir. Uyarının uygulandığı odacık sadece atriyum, sadece ventrikül ya da hem atriyum hem ventrikül şeklinde olabilir. Algılanmanın gerçekleştiği odacık ve kalp pilinin oluşturduğu tepki (uyarı göndermesini engelleme, uyarı gönderimini tetikleme veya her ikisinin de gözlenebildiği değişik çalışma prosedürlerine sahip kalp pilleri vardır. Kalp pili EKG sinyallerinde sivri uç olarak gözlenebilmektedir. Atrial uyarımda sivri uç P dalgasından önce görülebilirken ventriküler uyarımda QRS kompleksinden hemen önce görülebilir. Pacemaker ritim örneği Şekil 2.13'te verilmiştir.




Şekil 2.13 : Pacemaker Ritim

2.6 Kalp Hızı Değişkenliği Analizi

Kalp hızı değişkenliği (KHD) (Heart Rate Variability, HRV), birbirini takip eden kalp atımlarında bulunan R dalgaları arasındaki geçen süreler ile ilişkilidir. Bu süreler RR aralıkları olarak adlandırılmaktadır. SA düğümünün ateşlemesini ve kalp ritminin


ayarlanmasında rol oynayan sempatik ve parasempatik sinir sistemi aktivitesine verilen bir yanıttır. Ektopik atımların temizlendiği ve sadece SA düğümü tabanlı oluşan atımlar arası uzaklık ise NN aralığı olarak adlandırılmaktadır. KHD, farklı sürelerde kayıt alınmış EKG sinyallerindeki RR aralıklarının ölçülmesi ve doğrusal yöntemler (zaman bölgesi analizleri, frekans bölgesi analizleri ve zaman-frekans bölgesi analizleri) ve doğrusal olmayan yöntemler uygulanarak ölçülebilir. KHD analizi yaygın kullanılan parametreler Şekil 2.14' te gösterilmektedir.




Şekil 2.14 : KHD Analizi Parametreleri

2.6.1 Zaman Bölgesi Analizleri

RR aralıklarının zamanla değişiminin gösterildiği takogram veya histogram olarak adlandırılan eğriler elde edilir. Takogram grafiğinde x ekseninde sinyalin zamanı(sn) gösterilirken y düzleminde RR aralıklarının süresi(ms) gösterilmektedir. Histogram eğrisinde ise x ekseninde RR aralıklarının süreleri(ms) gösterilirken y ekseninde bu RR aralıklardan EKG kaydında kaç adet olduğu(frekans) gösterilmektedir. Eğriler Şekil 2.15'te verilmiştir. Bu eğriler zaman bölgesi analizleri için önemlidir.



(a)



(b)

Şekil 2.15 : (a) KHD Histogram ve (b) KHD Takogram Eğrileri

Zaman alanında KHD analizleri istatistiksel parametreler ve geometrik parametrelerin belirlenmesi ile gerçekleştirilmektedir. İstatistiksel yöntemler istatistiksel olarak değerlendirme yapmak için kullanılırken; geometrik yöntemler RR aralıkları eğrileri üzerinden elde edilen geometrik şekil ve şeklin özelliklerinin çıkarılması ile elde edilir [11].

2.6.1.1 İstatistiksel parametreler

HRmax

HRmax (Maximum Heart Rate), maksimum kalp hızını gösterir.

HRmin

HRmin (Minimum Heart Rate), minimum kalp hızını gösterir.

Ortalama HR

Ortalama kalp hızını gösterir.

$$\text{OrtalamaHR} = \frac{1}{N} \sum_{i=1}^N HR_i \quad (2.7)$$

Bu denklemde N, RR aralıklarının sayısını göstermektedir. HR_i ise i. atımın kalp atış hızını göstermektedir.

Ortalama RR

RR aralıklarının sürelerinin ortalamasını gösterir. RR aralıklarının ortalaması alınarak bulunur.

$$\text{OrtalamaRR} = \frac{1}{N} \sum_{i=1}^N RR_i \quad (2.8)$$

Denklemde görülen RR_i , EKG sinyalinde i. RR aralık değeridir.

SDNN

SDNN (Standard Deviations of NN intervals), RR aralıkları ya da KHD analizi öncesi ektopik atımların temizlendiği ve sadece SA düğümü tabanlı oluşan atımların NN aralıklarının standart sapmasının alınması ile SDNN bulunur. Varyans değerinin kareköküdür.

$$\text{SDNN} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (RR_i - \text{OrtalamaRR})^2} \quad (2.9)$$

SDANN

SDANN (Standard Deviation of the Averages of NN Intervals), beş dakikalık sinyal bloklarındaki ortalama NN ve RR aralıklarının standart sapmasını ifade etmektedir.

$$SDANN = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (RR_i - OrtalamaRR_i)^2} \quad (2.10)$$

$OrtalamaRR_i$ segmentteki RR aralıklarının ortalamasını ifade etmektedir.

STDHR

STDHR (Standard Deviation of Heart Rate), kalp atım hızlarının standart sapmasını göstermektedir.

$$STDHR = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (HR_i - OrtalamaHR)^2} \quad (2.11)$$

RMSSD

RMSSD (Root Mean Square Of Successive Differences), EKG kaydında bulunan tüm RR aralıkların farklarının karelerinin toplamının kareköküdür. Ardışık kalp atışları arasındaki aralıkların standart sapmasıdır. Parasempatik aktiviteyi yansıtmaktadır.

$$RMSSD = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (RR_{i+1} - RR_i)^2} \quad (2.12)$$

Denklemden kullanılan değişkenlerden RR_{i+1} bir sonraki RR aralığını, RR_i ise mevcut RR aralığını ifade eder.

SDNN İndeks

SDNN, uzun süreli EKG kayıtlarında beş dakikalık segmentlerden elde edilen bir istatistiksel KHD parametresidir. Bu segmentlerdeki RR intervallerinin standart sapmalarının ortalamasıdır.

$$SDNN \text{ İndeks} = \frac{1}{N} \sum_{i=1}^N SDNN_i \quad (2.13)$$

NN50

Tüm kayıt boyunca aralarında 50 milisaniyeden fazla fark olan komşu RR aralıklarının sayısını ifade etmektedir.

$$NN50 = \sum_{i=1}^N \{|RR_{i+1} - RR_i| > 50ms\} \quad (2.14)$$

pNN50

Tüm kayıt boyunca aralarında 50 milisaniyeden fazla fark olan komşu RR aralıklarının yüzdesini ifade etmektedir. NN50 sayısının toplam RR interval sayısına bölümü ile bulunur.

$$pNN50 = \frac{NN50}{N} \cdot 100 \quad (2.15)$$

SDSD

SDSD (Standard Deviation of Successive Differences), ardışık RR aralıkları arasındaki farkların standart sapmasını ifade etmektedir.

$$SDSD = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (|RR_i - RR_{i+1}| - RRdif)^2} \quad (2.16)$$

$$RRdif = \frac{1}{N-1} \sum_{i=1}^N |RR_i - RR_{i+1}| \quad (2.17)$$

CVNN

CVNN(Coefficient of Variation of NN Intervals), RR aralığı varyasyon katsayısını ifade etmektedir.

$$CVNN = \frac{SDNN}{OrtalamaRR} \quad (2.18)$$

CVSD

CVSD (Coefficient of Variation of Successive Differences), ardışık RR aralıkları arasındaki farkların varyasyon katsayısını ifade eder.

$$CVSD = \frac{RMSSD}{OrtalamaRR} \quad (2.19)$$

MedyanRR

RR aralıklarının sürelerinin medyanını ifade eder.

MadNN

MadNN (Median Absolute Deviation) RR aralıklarının sürelerinin medyanına olan mutlak sapmaların medyanını ifade eder.

$$MadNN = \text{Median}(|RR_i - \text{Median}(RR)|) \quad (2.20)$$

MCVNN

MCVNN (Median Coefficient of Variation of NN intervals), RR aralıklarının medyan mutlak sapmasının bu aralıkların medyanına oranıdır.

$$MCVNN = \frac{MadNN}{MedyanRR} \quad (2.21)$$

IQRNN

IQRNN (Interquartile Range of NN intervals), RR aralıklarının çeyrekler arası aralığını (Interquartile Range, IQR) ifade eder. Çeyrekler arası aralık RR aralıklarının sıralanmasından sonra %75'lik dilimindeki değerden %25'lik dilimindeki değer çıkarılması ile elde edilir.

SDRMSSD


SDRMSSD (Standard Deviations of NN intervals / Root Mean Square Of Successive Differences), SDNN değerinin RMSSD değerine bölünmesi ile bulunur. Frekans bölgesindeki karşılığı düşük frekansın yüksek frekansa oranını ifade eder [URL-2].

Prc20NN ve Prc80NN

Prc20NN (20th percentile of the NN intervals), RR aralıkları sıralandıktan sonra yüzde yirmilik diliminde bulunan RR aralığı değerini ifade eder. RR aralıklarının dağılımının alt kısmını incelemek için kullanılabilir. Benzer şekilde Prc80NN (80th percentile of the NN intervals) ise RR aralıklarının yüzde seksenlik dilimindeki RR aralığı değerini ifade eder. RR aralıklarının yüksek kısmı ile ilgili bilgi verir.

2.6.1.2 Geometrik parametreler

Geometrik parametreleri RR histogramı üzerinde oluşturulan geometrik şekilden elde edilirler. Kalp hızı histogramı ya da RR histogram kullanılabilir. Kalp hızı histogramda yatay eksen kalp hızı değerleri varken RR histogramda RR aralıkları vardır. Dikey düzlemde ise yatay eksenindeki değerden kaç adet olduğu (frekansı) bulunmaktadır. Histogram üzerindeki en yüksek barın uzunluğu histogramın yüksekliği (h) olarak alınır. RR dağılımını gösteren RR histogramı Şekil 2.16'da gösterilmektedir.



Şekil 2.16 : RR Histogram üzerinde üçgen indeksi ve TINN değerlerinin gösterimi [Url-3]

Üçgen İndeksi

Üçgen indeksi (Triangular Index), RR histogramının integralinin (toplam RR aralığı sayısı), histogramın yükseklik değerine bölünmesi ile elde edilmektedir.

$$\text{KHD Üçgen İndeksi} = \frac{A}{h} \quad (2.22)$$

2.22 numaralı eşitsizlikte A, RR histogramın integralini ve h ise histogramın yüksekliğini ifade etmektedir.

TINN

TINN (Triangular Interpolation of NN Interval Histogram), RR histogramın taban uzunluğunu ifade etmektedir.

2.6.2 Frekans Bölgesi Analizler

KHD için frekans bölgesi analizlerinin arkasındaki sebep kardiyovasküler kontrolün (parasempatik ve sempatik sinir sistemi) etkisi ile belirli ritimlerden oluştuğunun gözlemlenmesidir. Frekans bölgesi analizleri ile belirli frekans bantları için kalp atış hızının salınımı hakkında bilgi elde edilebilir. Sinyalin frekans bileşenlerine ayrılması Güç Spektral Yoğunluk (Power Spectral Density, PSD) analizi ile gerçekleştirilebilir. Sinyali oluşturan frekans bileşenlerinin güç dağılımını analizi için özel bir eğri kullanılır. Eğrinin x ekseninde frekans (Hz) ve y ekseninde güç spektrum yoğunluğu verilir. Her bir frekans bileşenin güç yoğunluğunun temsil edildiği örnek güç spektral yoğunluğu eğrisi Şekil 2.17’de verilmiştir.

0-0.5Hz arasında değişen beş frekans bandında PSD analizi ölçümleri gerçekleştirilir. Total gücün yüzde beşini oluşturan Yüksek Frekans (High Frequency, HF), Düşük Frekans (Low Frequency, LF) bantlarıdır. Total gücün çoğunu oluşturan diğer frekans bantları ise Ultra Düşük Frekans (Ultra Low Frequency, ULF), Çok Düşük Frekans (Very Low Frequency, VLF) ve Çok Yüksek Frekans (Very High Frequency, VHF) bandıdır. PSD analizi frekans bantlarının maksimum frekans değeri ve güç değerleri

VHF için 0,4 - 0,5 Hz frekans aralığındaki değerler,

HF için 0,15-0,4 Hz frekans aralığındaki değerler,

LF için 0,04-0.15Hz frekans aralığındaki değerler,

VLF için $0,003 \pm 0,04$ Hz frekanstaki değerler,

ULF için 0,003HZ’ten düşük frekanstaki değerleri içerir [12].

TP, toplam spektral güç (Total Spectral Power),

LF/HF, düşük frekans gücünün yüksek frekans gücüne oranı,


LFn düşük frekans gücünün normalize edilmiş hali (LF/TP),

HFn, yüksek frekans gücünün normalize edilmiş hali (HF/TP),

LnHF, HF bileşeninin logaritmik dönüşümü olan frekans bölgesi analizi parametrelerindendir.

PSD analizi için parametrik ve parametrik olmayan metotlar vardır. Ayırık Fourier Dönüşümü (Discrete Fourier Transform, DFT), Hızlı Fourier Dönüşümü (Fast Fourier Transform, FFT) ve Welch periyodogram parametrik olmayan metotlardan yaygın

kullanılan yöntemlerdir. Parametrik metotlara ise Burg periyodogram örnek verilebilir.



Şekil 2.17 : KHD sinyali güç spektral yoğunluğu [11]

Fourier Dönüşümü

Zaman bölgesi verilerinin frekans bölgesi verilerine dönüştürmek için kullanılan Fourier dönüşümü sürekli fonksiyonlar için tanımlandığı için; RR uzunluklarının bulunduğu zaman serisinin ayırık zaman verileri için Ayırık Fourier dönüşümü kullanılır. t_j zamanında $X(t_j)$, analize uğrayan zaman serisi olacak şekilde Fourier dönüşümü 2.23 ve 2.24 numaralı denklemlerde verilmiştir.

$$FT_x(\omega) = \sum_{j=0}^{N-1} X(t_j)e^{-i\omega t_j} \quad (2.23)$$

$$\omega_n = \frac{2\pi}{T} = 2\pi f_n \quad n = 1, 2, \dots, N \quad (2.24)$$

Denklemden kullanılan değişkenlerden $FT_x(\omega)$, analize uğrayan zaman serisinin frekans düzlemindeki karşılığı, ω ise frekans bileşenlerini ifade etmektedir. N sinyalin örnek sayısını, ω_n frekans bileşenlerinin frekansını, T sinyalin periyodunu ve f_n ise n 'inci frekans bileşeninin frekansını ifade eder. Spektral güç yoğunluğu ise 2.25 numaralı denklem ile hesaplanmaktadır.

$$P_x(\omega) = \frac{1}{N} \sum_{j=0}^{N-1} |X(t_j)e^{-i\omega t_j}|^2 \quad (2.25)$$

Welch Periyodogram

Welch periyodogram ile gerçekleştirilen güç spektral yoğunluğu aşağıdaki formül ile uygulanmaktadır. Segment uzunluğu ve kullanılan pencerenin türü sonuçlar için önemlidir [11].

$$P_{Mod,X}(f) = \frac{1}{M \cdot U} \left| \sum_{n=0}^{M-1} x_i(n)w(n)e^{-j2\pi fn} \right|^2 \quad (2.26)$$

Denklemlerde kullanılan değişkenler: M segment uzunluğu, $x_i(n)$ i. segment, f frekans, w pencere fonksiyonu, U normalizasyon faktörüdür.


2.6.3 Doğrusal Olmayan Analizler

RR aralıklarından oluşan zaman serisinde RR aralıklarının seyrinin doğrusal olmaması değerler arasındaki ilişkinin düz bir çizgi olarak çizilemeyeceği anlaşılır. Doğrusal olmayan analizlerde araştırılan parametreler KHD'yi düzenleyen mekanizmaların tahmin edilemezliğini gösterir [13].

Poincare Grafiği

Bitişik RR aralıkları arasındaki ilişkiyi yansıtan grafikdir. Bu grafikte yatay ekseninde mevcut RR aralığı (RR_n), dikey ekseninde ise bir sonraki RR aralığı (RR_{n+1}) değerleri vardır. Grafikte noktalar bulut adı verilen yapı oluşturur. Bu yapının geometrik şekli (elipse yakın ya da yuvarlak) kardiyovasküler hastalıkların teşhisinde de kullanılabilmektedir. Poincaré grafiğinde elde edilen bulut $y=x$ ve $y=-x$ doğrularının kesiştiği noktada ortalınır. Bu noktaya merkez nokta (centroid) denir. Bu iki doğrudan $y=-x$ doğrusu merkez doğrusu L2, $y=x$ merkez doğrusu ise L1 diye adlandırılır. Sol taraftaki noktaya olan mesafe RR aralıklarının bir öncekinden ne kadar kısa olduğunu

göstermektedir. Sağ taraftaki noktaya olan mesafe ise RR aralıklarının bir öncekinden ne kadar uzun olduğunu göstermektedir. Bulut üzerinden çıkarılarak elde edilen parametreler doğrusal olmayan analiz sonucu elde edilen parametrelerdir. Poincaré Grafiği ve parametreler Şekil 2.18’de gösterilmektedir.



Şekil 2.18 : Poincaré Grafiği [Url-3]

S

S (Sum of the areas under the Poincaré plot of RR intervals), geometrik bu parametre oluşan elipsin alanı ile ilişkilidir.

SD1

SD1 (Standard Deviation of the Poincaré Plot's Short-Term Axis), parasempatik sinir sistemi etkileriyle alakalıdır. Genelde kısa süreli KDH analizlerinde anlık değişikliklerle ilişkilidir. Elipsin genişliği olarak belirtilir ve $y=x$ eksenine dik olan noktaların uzaklıklarının standart sapmasıdır.

SD2

SD2 (Standard Deviation of the Poincaré Plot's Long-Term Axis), parasempatik ve sempatik sinir sistemi ile ilişkili olabilir. Uzun süreli KDH analizlerinde uzun seyirli değişimlerle ilişkilidir. Elipsin uzunluğu ile ilişkilidir ve $y=x$ eksenini boyunca her noktanın uzunluklarının standart sapması alınarak bulunur.

SD1/SD2

RR aralığı zaman serisinin öngörülemezliğinin ölçüm yoludur. KHD sinyalinin rastgeleliği ile ilişkilidir [11,13]. SD1'in SD2'ye bölünmesi ile elde edilir.

CSI

CSI (Cardiac Sympathetic Index), kalp sempatik fonksiyonu ölçen bir parametredir. CSI değerinin modifiye edilmiş şekli de 2.28 numaralı denklemde verilmiştir.

$$CSI = \frac{4 * SD2}{4 * SD1} \quad (2.27)$$

$$CSI_Modified = \frac{(4 * SD2)^2}{4 * SD1} \quad (2.28)$$

CVI

CVI (Cardiac Vagal Index), kalp parasempatik fonksiyonunun bir göstergesidir.

$$CVI = \log_{10}(4 * SD2 * 4 * SD1) \quad (2.29)$$

PIP

PIP (Percentage of Inflection Points), RR aralıkları serisindeki dönüm noktalarının yüzdesini ifade eder.

IALS

IALS (Inverse of the Average Length of Segments), kalp atışlarındaki hızlanma ve yavaşlama dinamiklerinin hızını temsil eder. RR aralıklarının artıp azaldığı segmentler bulunur, her segmentin uzunluğu hesaplanır ve ortalama segment uzunluğuna bölünmesi ile elde edilir.

PSS

PSS (Percentage of Short Segments), kalp atışının hızlanması ve yavaşlama sırasındaki segmentleri oluşturan RR aralıklarının sayısının üç veya daha az RR aralığından oluşuyorsa o segmentler kısa segmentlerdir. Kısa segmentlerin toplam segment sayısına bölünmesi ile segmentlerin yüzde kaçının kısa olduğu bilgisini PSS ile ifade edilir.

PAS

PAS (Percentage of NN Intervals in Alternation Segments), değişim segmentlerindeki RR aralıklarının yüzdesini ifade eder. Kalp hızının hızlandığı segmentlerde bulunan RR aralıklarının sayısının dört ve üstünde olduğu segmentler değişim (alternation) segmenti olarak ifade edilir. Değişim segmentlerinin sayısının toplam segment sayısına bölünmesi ile segmentlerin kaçının değişim segmenti olduğu bilgisi PAS ile ifade edilir.

GI

GI (Guzik's Index), Poincare grafiğinde L1 doğrusunun üzerinde bulunan noktaların (RR_{n+1} değerlerinin RR_n değerlerinden büyük olduğu, kalp hızının azaldığı), L1 doğrusuna uzaklığının, grafikte bulunan bütün noktaların L1 doğrusuna olan uzaklığına bölünmesi ile bulunur.

SI

SI (Slope Index), Poincare grafiğinde L1 doğrusunun üzerinde bulunan noktaların faz açılarının toplamının ve bütün noktaların açı değerleri toplamına bölünmesi ile hesaplanır. Faz açısının bulunması 2.30 numaralı eşitsizlikte gösterilmiştir.

$$\theta = \left| \frac{\pi}{4} - \arctan\left(\frac{y}{x}\right) \right| \quad (2.30)$$

θ faz açısını, x RR_n değerini ve y RR_{n+1} değerini ifade eder.

AI

AI (Area Index), Poincare grafiğinde L1 doğrusu üzerinde bulunan her noktanın faz açısı ve merkez noktaya olan uzaklığı yarı çap kabul edilerek alan değeri bulunur. Bu alan değeri toplamının tüm noktaların alan değerleri toplamına oranı AI olarak ifade edilir. Noktaların yarı çap (r) ve alan değerleri 2.31 ve 2.32 numaraları eşitsizliklerde verilmiştir.

$$r = \sqrt{x^2 + y^2} \quad (2.31)$$

$$\text{Alan} = \frac{1}{2} * \theta * r^2 \quad (2.32)$$

PI

PI (Porta's Index), Poincare grafiğinde L1 doğrusu altında bulunan noktaların sayısının bütün noktaların sayısına oranı PI olarak ifade edilir.

SD1a ve SD1d

SD1a (SD1 Acceleration), kalp atışının hızlanmasının (RR aralıklarının kısalması) ve SD1d (SD1 Deceleration), yavaşlamasının (RR aralıklarının uzaması) kısa süreli asimetresini (Short-term Asymmetry, SD1) ifade eder. L1 çizgisine olan uzaklık değerleri ile hesaplanır. Hızlanma ve yavaşlama segmentlerindeki mesafelerin ($RR_{n+1} - RR_n$) karelerinin ortalamasının kareköküdür.

C1a ve C1d

C1a (C1 Acceleration), kalp atışının hızlanmasının ve C1d (C1 Deceleration), yavaşlamasının kısa süreli KHD'ye katkısını ifade eder. SD1a ve SD1d değerlerinden ile elde edilirler.

$$SD1I = \sqrt{SD1a^2 + SD1d^2} \quad (2.33)$$

$$C1a = \left(\frac{SD1a}{SD1I} \right)^2 \quad (2.34)$$

SD2a ve SD2d

SD2a (SD2 Acceleration), kalp atışının hızlanmasının (RR aralıklarının kısalması) ve SD2d (SD2 Deceleration) yavaşlamasının (RR aralıklarının uzaması) uzun süreli asimetresini (Long-term Asymmetry, SD2) ifade eder. Kalp hızının hızlanma ve yavaşlama segmentlerinin L2 çizgisine olan uzaklıklarını dikkate alarak hesaplanır. Her iki değer de segmentler içindeki mesafelerin karelerinin ortalamasının karekökü olarak hesaplanır,

C2a ve C2d

C2a (C2 Acceleration), kalp atışının hızlanmasının ve C2d (C2 Deceleration) yavaşlamasının uzun süreli KHD'ye katkısını ifade eder. C1a ve C1d parametrelerine benzer şekilde hesaplanırlar ve hesaplamalarında kullanılan denklemlerde (Eşitsizlik 2.33 ve 2.34) SD1a ve SD1d yerine SD2a ve SD2d değerlerinin koyulması ile elde edilirler.

SDNNa ve SDNNd

Hızlanmaların toplam katkısı (SDNN Acceleration, SDNNa) ve yavaşlamaların toplam katkısı (SDNN Deceleration, SDNNd) kalp atışının hızlanması ve yavaşlamasının total asimetresini ifade eder. SDNNd kalp hızının yavaşlama segmentlerine ait bileşenlerle (SD1d ve SD2d) hesaplanır. SDNNa ise kalp hızının

hızlanması segmentlerine ait bileşenlerle (SD1a ve SD2a) hesaplanır. Total SDNN ise bu iki parametreden elde edilir.

$$SDNNd = \sqrt{0,5 * (SD1d^2 + SD2d^2)} \quad (2.35)$$

$$SDNNa = \sqrt{0,5 * (SD1a^2 + SD2a^2)} \quad (2.36)$$

$$\text{Total SDNN} = \sqrt{SD1a^2 + SD2a^2} \quad (2.37)$$

Ca ve Cd

Kalp hızı yavaşlamalarının ve hızlanmalarının KHD'ye toplam katkılarını ifade eder.

$$Ca = \left(\frac{SDNNa}{SDNN} \right)^2 \quad (2.38)$$

$$Cd = \left(\frac{SDNNd}{SDNN} \right)^2 \quad (2.39)$$

ApEn

Yaklaşık entropi (Approximate Entropy, ApEn), KHD sinyalinin karmaşıklığını ölçer. Küçük ApEn değeri sinyalin düzenli olduğunu hakkında yorum yapmamızı sağlar.

SampEn

Örnek entropi (Sample Entropy, SampEn), yaklaşık entropi ile benzer amaç için uygulanmaktadır. Zaman serileri daha kısa olduğunda da SampEn hesaplaması yapılabilmektedir [13].

ShanEn

Shannon Entropi (Shannon Entropy, ShanEn), KHD sinyalinde bulunan bilgi miktarının nicelleştirilmesi amacıyla hesaplaması yapılabilmektedir.

Sinyalin karmaşıklığını ölçmek için Bulanık Entropi (Fuzzy Entropy, FuzzyEn) ile kavramların bir kümedeki üyelik dereceleri incelenebilir. KHD sinyallerinin karmaşıklığının sabit bir zaman ölçeğinde değil birden fazla ölçekte hesaplamayı sağlayan Çok Ölçekli Entropi (Multiscale entropy, MSEn) yöntemi de kullanılabilir. Bileşik Çok Ölçekli Entropi (Composite Multiscale Entropy, CMSEn), Rafine Çok Ölçekli Entropi (Refined Composite Multiscale Entropy, RCMSEn) gibi versiyonları da kullanılabilir.

KHD sinyalinin karmaşıklığını ve dinamik yapısını tanımlayan başka ölçütler de vardır. Korelasyon Boyutu (Correlation Dimension, CD), sinyalin geometrik özelliklerini analiz ederek, kaotik davranışların ve karmaşık yapılarının boyutunu tahmin eder. Higuchi Fraktal Boyutu (Higuchi's Fractal Dimension, HFD) zaman serisinin karmaşıklığını ölçülmesinde kullanılan bir diğer ölçüttür. Katz Fraktal Boyutu (Katz's Fractal Dimension, KFD) ise sinyalin karmaşıklığını ölçer ve karmaşık dalga biçimleri gibi değişen farklı fraktal özelliklerini çıkarır.

3. KURAMSAL TEMELLER VE LİTERATÜR ARAŞTIRMASI

3.1 Spektrogram

Spektrogram, bir sinyalin zamana göre değişen frekans spektrumunu gösterir. Yatay eksen zamanı temsil ederken, dikey eksen frekansı temsil etmektedir. Belirli bir zamanda belirli bir frekansın genliğin büyüklüğü bir renk haritası ile temsil edilir [14]. Düşük genlikler ve yüksek genlikler sırasıyla mavi renk ve kırmızı renk ile temsil edilmektedir. Bu aralıkta bulunan genlikler ise bu iki renk arasındaki bir renk ile temsil edilir.


Spektrogram çıktıları zaman sinyallerine Kısa Zamanlı Fourier Dönüşümü (KZFD) (Short Time Fourier Transform, STFT) uygulanarak elde edilir. KZFD diğer zaman-frekans yöntemlerine göre hesaplama açısından daha verimli olması, fizyolojik sinyallerde zaman-frekans desenlerini tanımlamak için uygun ve uygulaması kolay olması avantajlarından. Pencerelemenin spektral sızıntıya neden olması ve sabit pencere genişliği nedeniyle esnekliğin az olması dezavantajlarından [15]. Bir $x[n]$ sinyalinin spektrogramı $x[n]$ sinyalinin KZFD uygulanması sonrası magnitüde değerinin karesinin hesaplanması ile elde edilir [14].

KZFD ve spektrogram denklemleri 3.1 ve 3.2 de gösterilmektedir. Denklemden $w[n]$ pencere fonksiyonunu, m zamanı, ω frekansı ve n parçayı temsil etmektedir [16].

$$\text{KZFD } \{x[n]\}(m, \omega) = X(m, \omega) = \sum_{n=-\infty}^{\infty} x[n]w[n-m]e^{-j\omega n} \quad (3.1)$$

$$\text{spektrogram } \{x[n]\}(m, \omega) = |\text{KZFD}\{x[n]\}(m, \omega)|^2 \quad (3.2)$$

Burada $w[n]$ pencereleme işlemi, m zamanı, ω frekansı, n parçayı temsil etmektedir. EKG sinyalleri, durağan olmayan ve zamanla değişen frekans içeriğine sahip çok bileşenli bir sinyaldir [17]. KZFD, zamanla değişen sinyallerin anlık frekansları ve genlik bilgilerinin elde edilmesini sağlar, bu sayede EKG sinyallerinin hem zaman hem frekans alanlarında temsil edilebildiği spektrogramlar elde edilebilmektedir. Şekil 3.1’de EKG sinyali ve spektrogramı verilmiştir.



Şekil 3.1 : EKG sinyali ve EKG sinyalinin spektrogram çıktısı


3.2 Skalogram

Skalogram, bir sinyalin frekans içeriğinin zaman içerisinde değişimini gösterir. Skalogram sinyali çeşitli ölçeklerdeki pencerelere ayırma yeteneği olan sürekli dalgacık dönüşümü (SDD) (Continuous Wavelet Transform, CWT) uygulanarak elde edilir. Bu sayede zaman serisindeki hem yüksek hem de düşük frekanslı bileşenler iyi bir zaman ve ölçek çözünürlüğü ile analiz edilebilmektedir [18]. SDD esnek zaman frekans çözünürlüğüne sahip olması, durağan olmayan sinyallerin zaman frekans analizinde etkili olması avantajlarındandır. Ayrıca KSFD'ye göre daha yüksek çözünürlük sunar. Dezavantajları ise hesaplama açısından daha yoğun ve wavelet seçimi performansı etkilemektedir [15]. SDD 'nin matematiksel gösterimi 3.3'te gösterilmektedir.

$$W_x(s, \tau) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \psi * \left(\frac{t - \tau}{s} \right) dt \quad (3.3)$$

$x(t)$ zaman serisi sinyalini, $W(s, \tau)$ dalgacık katsayısı, $\psi(t)$ temel dalgacık fonksiyonu eşleniği, s ölçek ve τ pozisyon parametresidir [19]. EKG sinyalleri, durağan olmayan

sinyallerdir ve dalgacık dönüşümü ile elde edilen skalogram görüntüleri sayesinde sinyal bileşenlerinin zaman frekans alanındaki ilişkileri detaylı incelenebilir. Şekil 3.2’de EKG sinyali ve skalogram görüntüsü verilmiştir.




Şekil 3.2 : EKG sinyali ve EKG sinyalinin skalogram çıktısı

3.3 Makine Öğrenmesi Modelleri

3.3.1 Karar Ağaçları

Karar Ağaçları (KA) (Decision Trees, DT), denetimli sınıflandırma tekniklerinden biridir. Karar ağaçları büyük miktarda veriyi işleyebildiği ve minimum alan bilgisi gerektirdiği için popüler modellerdendir [20]. Yapısı gereği ağaca benzetilir. Kök düğüm ağaçtaki en yüksek düğümdür. Sınıflandırılacak bir örnek öncelikle kök düğümündeki teste tabi tutulur. Bu testin sonucu örneğin hangi düğüme iletileceğine karar verir. Bu işlem yaprak düğümüne ulaşınca kadar devam eder. Yaprak düğümü sınıflandırma sonucunu yani sınıfı içerir. Şekil 3.3’te örnek karar ağacı şeması gösterilmektedir. Karar ağaçları diğer modellerle karşılaştırıldığında avantajı anlama kolaylığı ve yorumlanabilir olmasıdır [21].



Şekil 3.3 : Karar ağacı örnek şeması.

Sınıflandırıcının performansını etkileyen parametreler vardır, bu parametreler ağacın büyüklüğü ve düğümlerin ayrılmasında kullanılan metottur. Büyük ağaçlarda daha çok dallanma gözlenir bu dallanma aşırı öğrenme ile sonuçlanabilir. Düğümlerin ayrılması genellikle alt düğümlerin safsızlık derecesine bağlıdır. Safsızlık derecesinin ölçülmesi için kullanılan metotlar Entropi, Gini ve Sınıflandırma Hatası metotlarıdır. Bu safsızlık metotlarının hesabı Eşitlik 3.4 -3.6’da verilmiştir.

$$\text{Entropi}(t) = - \sum_{i=0}^{c-1} p(i|t) \log_2 p(i|t) \quad (3.4)$$

$$\text{Gini}(t) = 1 - \sum_{i=0}^{c-1} [p(i|t)]^2 \quad (3.5)$$

$$\text{Sınıflandırma Hatası}(t) = 1 - \max_i [p(i|t)] \quad (3.6)$$


Burada $p(i | t)$ belirli bir t düğümünde i sınıfına ait olan örnekleri ve c sınıf sayısını belirtmektedir [22]. Entropi ve gini düğümlerdeki safsızlığı ölçmekte ve en düşük safsızlığa sahip düğümden ilerlemesini sağlamaktadır.

3.3.2 Destek Vektör Makinesi

Destek Vektör Makineleri (DVM) (Support Vector Machines, SVM) sınıflandırma ve regresyon için kullanılan başka bir makine öğrenmesi algoritmasıdır. DVM ile

sınıflandırma yapılırken amaç iki sınıf için maksimum marj ile ayırım yapan hiper düzlemin bulunmasıdır [23].

Destek vektörleri karar hiper düzleme en yakın olan veri noktalarıdır. Hiper düzlem etrafındaki marjının maksimum olması istenen durumdur. Marjin, hiper düzlem ile tanımlanan ve iki sınıf arasındaki mesafe miktarıdır. İki sınıfın olduğu iki boyutlu düzlemde örnek sınıflandırma Şekil 3.4’te gösterilmektedir.



Şekil 3.4 : DVM iki boyutlu uzayda örnek gösterimi [20]

Hiper düzlem belirlendikten sonra test örnekleri bu düzleme göre sınıflandırılır. Sınıflandırılacak yeni örneğin düzleme uzaklığının negatif ya da pozitif olmasına ve düzlemin sağında ya da solunda konumlanacağına göre sınıfı belirlenir.

DVM sınıflandırma çalışmalarında sınıfların en iyi şekilde ayrılabilmesi için kernel fonksiyonu kullanılır. Sınıflandırıcının performansını kullanan kernel türü etkiler. Doğrusal ayrılabilir olmayan verileri doğrusal ayrılabilir olması için gerekli formata dönüştürür. Doğrusal, polinomial, radyal tabanlı, sigmoid kernel farklı DVM kernellerindendir [23].

3.3.3 K-En Yakın Komşu

K- En Yakın Komşu (K-Nearest Neighbors, KNN), benzer nesneler birbirine yakın bulunur varsayımına dayanan denetimli öğrenme modelidir [24]. Sınıflandırılacak nesnenin sınıfının belirlenmesi eğitim verisinde ona en yakın nesnenin sınıfının bulunması ile gerçekleştirilir. Eşit uzaklıkta birden fazla sınıf olduğu durumlarda sayıca fazla olan sınıf seçilerek nesnenin sınıfına karar verilir. “k” parametresi kullanıcı tarafından belirlenir ve oylanacak komşuların sayısını ifade eder. Örneğin, iki sınıfın bulunduğu bir senaryoda k değerinin tek sayı olması eşitlik probleminin

olmaması için önemlidir. Çok sınıfın bulunduğu sınıflandırmalarda bu tek k değeri seçimi her zaman doğru sonuç ile sonuçlanmayabilir, bu senaryolarda modelin tanımlanmasında uygun mekanizmanın seçilmesi kritiktir [21].

Algoritma performansını etkileyen bir diğer parametre ise nesneler arasındaki uzaklıkların ölçümünde kullanılan yöntemlerdir. Minkowski uzaklığı mesafe ifade eden bir metriktir. Formülü Eşitlik 3.7’de verilmiştir.

$$D(x, y) = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \quad (3.7)$$

Minkowski uzaklığı hesaplanırken n sayıda özneliği bulunan x ve y noktaları $x = (x_1, x_2, x_3, \dots, x_n)$ ve $y = (y_1, y_2, y_3, \dots, y_n)$ vektörleri şeklinde ifade edilmektedir [25]. Geometrik mesafelerin (Öklid uzaklığı) karşılaştırılması iki nokta arası mesafelerin karşılaştırılması şeklinde tanımlanır. Minkowski uzaklığındaki p değerinin 2 alınması ile hesaplanır. Öklid uzaklığının hesaplanması Eşitlik 3.8’de gösterilmektedir.

$$D(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.8)$$

Bir diğer benzerlik ölçeği olan uzaklık hesaplama metotlarına Manhattan uzaklığı, Chebyshev uzaklığı örnek verilebilir. Minkowski uzaklığındaki p değerinin 1 olduğu özel durum Manhattan uzaklığını; $n \rightarrow \infty$ durumu Chebyshev uzaklığını ifade eder [25].

3.3.4 Topluluk Öğrenme Yöntemleri

Topluluk öğrenmesi yöntemleri (Ensemble Learning), sınıflandırma amacıyla birden fazla sınıflandırıcının eğitilmesine dayanan denetimli öğrenme tekniklerindendir. Birden fazla sınıflandırıcının ortak bir karar vermesi sonucu gerçekleşen topluluk öğrenme yöntemleri gürültülü verilerde, az veri sayısının ve özneliğin olduğu senaryolarda daha verimli sonuçlar alınmasını sağlayabilir [23]. Topluluk öğrenme yöntemlerinde bulunan sınıflandırıcılar temel sınıflandırıcılar denir. Tek bir sonuç için birden fazla temel sınıflandırıcı kullanıldığında daha yüksek doğruluk elde edilebilir

[26]. Temel sınıflandırıcıların doğru sonuçlar üretmesi, çeşitli olması ve yeteri kadar veri görmesi sonuçları etkilemektedir [27]. Zayıf sınıflandırıcıları bir araya getirerek topluluk öğrenme algoritması oluşturmak için torbalama (Bagging), arttırma (Boosting) ve istifleme (Stacking) yöntemleri vardır.

Torbalama

Torbalama, aynı veri topluluğunun farklı örneklerine uygulanan sınıflandırıcıların tahminlerinin ortalaması alınarak ya da en yüksek sayıda olan tahminin seçilmesi ile sınıflandırma gerçekleştiren makine öğrenmesi algoritmasıdır. Torbalama (bootstrap aggregating) algoritması iki aşamada açıklanmaktadır. İlk aşama olan önyükleme (bootstrap) aşaması veri setinden veri seti ile aynı boyutta veri örneklemi oluşturulmaktadır. Toplama (aggregating) ise veri setlerinin birbirinden bağımsız eğitilmesi sonucu elde edilen tahminlerin birleştirilmesi ile (ortalaması alınarak ya da çoğunluğun görüşü kabul edilerek) daha doğru sonuçlar elde edilirken tahmin varyansı azaltılabilmektedir [28,29]. Torbalama algoritmasına Rastgele Orman örnek verilebilir [23].

Arttırma

Arttırma, güçlü bir model elde edebilmek için zayıf bir öğrenme modeli kullanan topluluk öğrenme yöntemidir. Torbalama yönteminden farklı olarak örneklemeler rastgele elde edilmez. İlk örneklemeye uygulanan modele etkisi az ve çok olan etkenler belirlenir ve yeni örneklemeye modele katkısı az olan etkenlerin ağırlığı arttırılarak elde edilir. Bu işlem en iyi sınıflandırma modeli elde edilene ya da iyi sınıflandırılmayan verilerin sınıflandırılması sonlanana kadar devam eder. Adaptive Boosting (AdaBoost) en bilinen arttırma algoritmalarından biridir. AdaBoost algoritmasında sınıflayıcılar önceki sınıflandırıcıların hatalı sınıflandırmalarına göre ağırlıklandırma yaparak iteratif olarak öğrenir. Bu sayede doğru sınıflandırma oranı her aşamada artabilmektedir. Teorik olarak AdaBoost aşırı uyuma karşı gelebilir [30] fakat aykırı verilere atanan ağırlık değerleri sonucu model etkilenebilmektedir [23,28,29]. İstifleme yöntemi ise farklı tür zayıf sınıflandırıcıların çıktıları meta sınıflandırıcı için girdi kabul edilerek bu tahminlerden tahmin üretilmektedir [23].

3.4 Derin Öğrenme


Derin öğrenme, makine öğrenmesinin bir alt kümesidir. Makine öğrenmesinde derin ve klasik mimariler birbirinden farklıdır. Klasik mimaride veriden özniteliklerin çıkarılması ve daha az karmaşık bir sınıflandırıcının varlığı söz konusudur. Derin mimari ise basitten komplekse doğru özniteliklerin çıkarılması ve sınıflandırıcı unsurlarının eş zamanlı öğrenilmesini içerir [31]. Karmaşık verilerden öğrenmek için sinir ağlarına ve sinir ağlarını eğitmek için geliştirilen algoritmalara odaklanır. [32]. İnsan beyinde elektriksel uyarı alan nöronlar uyarana bağlı olarak nöronun aktivasyonunu tetikler ve çıkış sinyali dendritler aracılığıyla diğer nöronlara iletilir böylece nöron ağı oluşur. Derin öğrenmede kullanılan çok katmanlı sistemler beyin nöronlarına benzer olduğu için sinir ağları olarak adlandırılmıştır. Sinir ağlarında bulunan katman ve nöron sayıları problemin karmaşıklığına bağlı olsa da sinir ağı modellerinde üç ana katman olan girdileri alıp bir sonraki katmana ileten giriş katmanı, girdiler üzerinde hesaplamalar yapan gizli katman ve çıktı tahminini üreten çıkış katmanından oluşur[33]. Rosenblatt 1958 yılında sinir ağlarının yapı taşı olan tek bir nöronun olduğu perceptron modeli bazı problemlere basit bir yöntem olmuş fakat karmaşık problemlerin çözümü için 1990'larda Prof. Geoffrey Hinton birden fazla nöron ile çalışmalara devam etmiş ve sinir ağlarının yapı taşlarından olan çok katmanlı perceptrona geçilmiştir [34].

Derin öğrenmenin güçlü yönlerinden biri, verinin yüksek düzeydeki temsillerini otomatik olarak öğrenebilmesidir. Bu farklı senaryolara göre çeşitlilik gösterir örneğin bilgisayarlı görüde kullanılan, görüntülerdeki desenleri tanımak için evrimsel sinir ağları (ESA) (Convolutional Neural Networks, CNN) ve doğal dil işlemede kullanılan ardışık verileri işlemek için kullanılan tekrarlayan sinir ağları (Recurrent Neural Networks, RNN) örnek olarak verilebilir. Derin öğrenme görüntü, konuşma tanıma, doğal dil işleme, robotik, sağlık, finans alanında geniş bir kullanım alanına sahiptir [33].

3.5 Evrimsel Sinir Ağları

Evrimsel sinir ağları derin sinir ağlarının bir formudur. Yapısal olarak öznitelik çıkartma (Feature Extraction) ve sınıflandırma (Classification) olmak üzere iki bölümden oluşur. ESA mimarisinde evrim katmanı (Convolution Layer), havuzlama

katmanı (Pooling Layer) ve tam bağlantılı katman (Fully Connected Layer) olmak üzere üç ana katman vardır [33]. Öznitelik çıkartma yapısı giriş katmanından (Input Layer) tam bağı katmana kadar olan bölümdür. Sınıflandırma bölümü ise tam bağı katman ve çıkış (Output Layer) katmanını içerir. Temel ESA yapısı Şekil 3.5'te gösterilmektedir.



Şekil 3.5 : Evrişimli sinir ağı yapısı [35]


3.5.1 ESA'nın Temel Basamakları

3.5.1.1 Giriş katmanı

Evrişimsel sinir ağlarının ilk katmanıdır. Ağı veri setinden gelen verileri almasını ve bir sonraki katmana iletilmesini sağlar. Girdi olarak verilen verinin türüne göre veri boyutu ve özellikleri değişiklik gösterebilir. Bir görüntü verisinin boyutu görüntünün yüksekliği, genişliği ve renk kanalı sayısına göre belirlenmektedir. Bir görüntü verisi için giriş verisi görüntünün piksel değerlerinden oluşan matristir [36].

3.5.1.2 Evrişim katmanı

Evrişim katmanları girdi verisine önemli öznitelikleri belirgin hale getirmek ve gürültüyü azaltmak için filtreler uygular. Her bir filtre giriş matrisinin küçük bir bölümüne uygulanan farklı ağırlıktaki değerler içeren matristir. Bu filtre matrisi giriş matrisinin üzerinde dikey ve yatay yönde kayan bir pencere gibi hareket ederek giriş matrisindeki değerlerle nokta çarpımı gerçekleştirir. Bu işlem evrişim olarak adlandırılır [33]. Evrişim işleminin uygulandığı yapı girdi olarak adlandırılır, ikinci yapı kernel ya da filtre olarak adlandırılır. İşlem çıktısı ise özellik haritası (Feature Map) olarak adlandırılır [37]. Evrişim işlemi Şekil 3.6 'da gösterilmiştir.



Şekil 3.6 : İki boyutlu evrişim işlemi örneği [37]

Her özellik haritası, farklı bir ağırlık setini kullanan farklı filtrelerin evrişim işlemi sonucu elde edilir. Evrişim katmanlarında kullanılan farklı filtreler elde edilen özellik haritalarını belirler ve her bir filtre giriş görüntüsünün farklı bölümünü öğrenir. Birden fazla özelliğin olması ve hiyerarşik olarak artan özellik karmaşıklığı çok sayıda filtre uygulanması ile yani birden fazla evrişim katmanı ile sağlanır [31].

Evrişim işlemi sırasında bazı hiper parametreler elde edilen özellik matrisinin boyutunu etkilemektedir. Bunlar adım sayısı (stride), dolgu (padding) ve derinlik (depth) değerleridir. Adım değeri evrişim sırasında filtrenin girdi matrisi üzerinde kayarken attığı adım sayısıdır. Eğer değeri bir ise filtre bir piksel kayarak evrişim işlemini gerçekleştirir. Dolgu ise girdi matrisinin çevresi yatay ve dikey olarak seçilen değer ile doldurulması işlemidir. Çoğunlukla sıfır değeri (Zero Padding) ile doldurulur. Derinlik değeri ise evrişim katmanı için kullanılan filtrelerin sayısını ifade etmektedir [38]. Çıkış matrisinin genişliğinin değeri Eşitlik 3.9' da verilmiştir.

$$\text{Çıkış genişliği} = \frac{(W + 2P - F)}{S} + 1 \quad (3.9)$$


Girdi matrisinin genişliği W, filtrenin genişliği F, dolgu miktarı P ve adım boyutu S olarak ifade edilmektedir.

Doğrusal bir işlem olan evrişim katmanının çıktıları ağına daha hızlı öğrenmesi için doğrusal olmayan bir fonksiyon uygulanır. Öznitelik haritasında elde edilen verilerden negatif değerler en yaygın kullanılan ReLU aktivasyon fonksiyonu ile sıfır ile değiştirilir. Eşitlik 3.10 'da ReLU fonksiyonu verilmiştir [36].

$$f(x) = \{ x, x \geq 0; 0, x < 0 \} \quad (3.10)$$

3.5.1.3 Havuzlama katmanı

Havuzlama katmanı evrişim katmanından sonra yapılan işlemdir. Bir önceki katmandan gelen bağlantı sayısını azaltarak öğrenilmesi gereken parametre sayısını azaltır. Bu sayede eğitim için gereken süreyi ve aşırı öğrenme riskini azaltmış olur. Özellik matrisini alt pencerelere ayırarak bu alt pencerelerdeki bilgiler bir öğeye indirgenir. Genellikle maksimum değer, ortalama değer veya L2 norm değeri (karelerinin toplamının karekök değeri) alınarak bu işlem gerçekleştirilir. Bu katmanda öğrenme olmaz [31]. Maksimum ve ortalama havuzlama işlemi ve çıktı matrisleri Şekil 3.7'de verilmiştir.



Şekil 3.7 : Havuzlama işlemi örnek gösterimi [38]

3.5.1.4 Tam bağlantılı katmanı

Öznitelik çıkartma aşamasında bulunan bir dizi evrişim ve havuzlama katmanından sonra elde edilen özellik matrisi bütün nöronları birbirine bağlı ve birkaç katmandan

oluşan sinir ağına girdi olarak bu katmanda verilir. Sinir ağının girişine matris formundaki veri düzleştirilerek ve vektör forma getirilerek verilir. Bu işlem düzleştirme (Flattening) işlemidir [38].

Sinir ağında bulunan her katman çıktısı diğer katman ile bağlantılıdır ve bütün parametreler bu katmanda yer aldığı için aşırı öğrenme problemine yol açabilir. Aşırı öğrenmenin engellenmesi için sönümlleme (Dropout) uygulanan tekniklerdendir. Eğitim aşamasında nöronlardan bazılarının göz ardı edilir. Ağdaki düğüm düğüm etkileşimini azaltarak önemli özelliklerin öğrenilmesine ve genelleme yeteneğinin artmasına yarar [31]. Sönümlleme işlemi sonucunda havuzlama işlemine benzer şekilde öğrenme olmaz.

3.5.1.5 Çıkış katmanı


Mimarinin son katmanı çok sınıflı problemlerde Softmax aktivasyon katmanı yani sınıflandırma katmanını içerir. Son tam bağlantılı katmanın çıktısı softmax katmanına iletilir ve kullanıcı tarafından belirlenen sınıf sayısı kadar olasılık dağılımı elde edilir. Bu olasılıkların toplamı 1.0 olmalıdır [36,39].

3.5.2 GoogleNet


2014 yılında Google ILSVRC yarışmasında Inception mimarisinin özel bir uygulaması olan GoogleNet'i tanıtmıştır. En dikkat çekici özellikleri arasında hata oranının düşük olması ve hızlı çalışması ve daha düşük bellek kullanımına sahip olması vardı [40].

22 katmanlı derin bir ağ olan GoogleNet eğer havuzlama katmanları da dahil edilirse 27 katmandan oluşmakta ve katmanların çoğunda ReLU aktivasyon fonksiyonu kullanılmaktadır. Sınıflandırıcıdan önce kullanılan ve tam bağlantılı katmanın yerine eklenen ortalama havuzlama katmanı ve doğrusal katman varlığı ağın farklı etiket gruplarına kolay uyum sağlamasını sağlamaktadır. Tam bağlantılı katman kaldırılrsa da sönümlleme kullanımı aşırı öğrenmenin önlenmesi için gerekli olarak görülmüştür. GoogleNet özellik çıkarımı için bir başlangıç modülü konsepti (Inception module) sunmuştur. Bu modül farklı filtre boyutlarıyla havuzlama, evrişim gibi birden fazla işlemi paralel çalıştırmayı sağlamaktadır [38]. Şekil 3.8'de başlangıç modülü yapısı verilmiştir. GoogleNet mimarisi ise Şekil 3.9'da verilmiştir. Ağ girdi olarak 224×224

Kırmızı Yeşil Mavi (Red Green Blue – RGB) görüntü girişini kabul etmektedir. Global Ortalama Havuzlama (Global Average Pooling, GAP) katmanı ise özellik haritasının ortalamasının alınması gerçekleştirilerek her özellik haritası için tek bir değer elde etmek amaçlanmıştır. Bu yapı ile ağıın parametre sayısı azaltılmaya çalışılmaktadır [40-43].



Şekil 3.8 : Başlangıç Modülü Mimarisi [41]




Şekil 3.9 : GoogleNet mimarisi [40]

3.5.3 ResNet-50


Araştırmacıların modele daha fazla katman eklenmesinin model doğruluğunu arttıracaklarını düşünmesi sonucu iki sorun ile karşılaşmışlardır. Bu sorunlar derin ağların eğitilmesi zorlaşmış ve doğrulukta artış sağlamadığı gözlenmiştir. Bu

sorunların ortadan kaldırılması için ResNet (Residual Networks) modelinde residual bağlantılar sinir ağına katmanları atlayabilen bağlantılar eklemiştir ve her evrişim katmanında ağıın veri hakkında bazı özellikleri öğrenmesini hataların ise ileri katmanlara iletilmesini sağlamaktadır. Katmanlar arası kullanılan batch normalizasyon sayesinde ise her katmanın giriş dağılımının ortalaması 0 ve varyansı 1 olacak şekilde ayarlanır. Bu sayede katmanlar arası uyum sağlama durumuna gerek kalmaz ve sinir ağlarının öğrenme hızının artmasını sağlar [38]. Residual blok Şekil 3.10'da verilmiştir.



Şekil 3.10 : Residual Blok Diyagramı [40]


ResNet'i He ve arkadaşları geliştirmiştir [44]. 34 katmandan başlayıp 1202 katmana kadar çıkan çeşitli ResNet türleri geliştirilmiştir. En yaygın tür ResNet-50'dir ve bu model 49 evrişimsel katman ile bir tam bağlantılı katmandan oluşur [43]. ResNet-50 mimarisi Şekil 3.11'de verilmiştir.



Şekil 3.11 : ResNet-50 mimarisi [45]


3.5.4 SqueezeNet

Parametre sayısını azaltarak doğruluk değerini koruma ve sınırlı parametre ile doğruluğu maksimize etmek amacıyla ile yola çıkan Iandola ve arkadaşları bu amaç için üç strateji geliştirmişlerdir. Toplam parametre sayısını azaltmak için 3x3'lük filtrelerin 1x1'lik filtrelerle değiştirilmesi, filtrelerin giriş kanal sayısını azaltmak ve büyük aktivasyon haritası elde etmek için örnekleme azaltmayı ağıın sonuna kaydırmaktır. Bu stratejilerin uygulanması için fire modül (Fire Module) tanıtmışlardır. Fire modül sadece 1x1 filtrelerden oluşan bir sıkıştırma (squeeze) konvolüsyon katmanını ve sıkıştırma katmanından beslenen ve hem 1x1 hem de 3x3 konvolüsyon filtrelerinden oluşan bir genişletme (expand) katmanını içerir. Fire modül yapısı Şekil 3.12'de verilmiştir.



Şekil 3.12 : Fire modül mimarisi [46]


SqueezeNet mimarisi Şekil 3.13'te verilmiştir. Mimaride ağıın sonuna doğru Fire modülde bulunan filtre sayısının kademeli artması ve ağıın ilerleyen aşamalarında uygulanan havuzlama uygulamaları ulaşmak istenen hedef için atılan diğer adımlardandır [46].



Şekil 3.13 : SqueezeNet Mimarisi [46]

3.5.5 AlexNet

2012 yılında Toronto Üniversitesi'nde Alex Krizhevsky ve profesörü Jeffry Hinton tarafından geliştirilen AlexNet [47], basit yapısı ve sığ derinliği ile yaygın kullanılmaktadır. AlexNet mimarisinde aşırı öğrenmeyi engellemek için ReLU aktivasyon fonksiyonu ve sönümleme kullanılmaktadır [40]. Erken katmanlarda büyük boyutlu filtre kullanılan AlexNet'i eğitmek amacıyla iki GPU paralel olarak kullanılmıştır [43]. AlexNet mimarisi Şekil 3.14'te verilmiştir.



Şekil 3.14 : AlexNet Mimarisi [43]

3.6 Aritmi Sınıflandırılmasında Öne Çıkan Çalışmalar

EKG sinyali her bir atımda bulunan karakteristik dalgaların ve aralıkların (P dalgası, QRS kompleksi, T dalgası, RR aralığı, PR aralığı ve ST segmenti gibi) bulunması ve bu dalgaların yükseklik(genlik), genişlik ve dalgalar arası uzaklık değerlerinden elde edilen özniteliklerin ve çeşitli makine öğrenmesi modellerinin eğitilmesinde kullanıldığı çalışmalar yaygın olarak görülmektedir.

Santanu ve arkadaşları yaptıkları çalışmada normal, LBBB, RBBB ve pacemaker atımları sınıflandırmak adına Q genliği, R genliği, S genliği, T genliği, QT aralığı, ST aralığı, RR aralığı, QRS dalgası süresi öznitelikleri elde etmişlerdir. Bu öznitelikler ve DVM sınıflandırıcısı ile yüksek doğruluk değerinde sınıflandırma performansı elde etmişlerdir [48].

Yun-Chi ve arkadaşlarının çalışmasında ise yine EKG sinyalinde elde edilen PQRST kompleksi öznitelikleri ile LBBB, RBBB, ventriküler erken vurular ve atriyal erken vuruların sınıflandırılması doğrusal diskriminant analizi ile yüksek doğrulukta sınıflandırılmıştır [49].

EKG sinyallerinden elde edilen öznitelikler farklılaşmaktadır. EKG sinyallerine uygulanan KHD analizi sonucu elde edilen değerlerin klinikte birçok hastalığın tanısında kullanıldığı görülmektedir. Bu analizin sonucu elde edilen parametrelerin aritmi analizi ile kullanıldığı çalışmalar yaygın olarak görülmektedir.

Yoon Jae ve arkadaşları yaptığı çalışmada farklı uzunluklardaki EKG sinyallerinde KHD analizinin hesaplama başarı oranı incelenmiştir. KHD analizlerinde kullanılan sinyalin uzunluğu çok az olduğunda RR aralıklarının sayısının az olacağından KHD analizi hesaplamalarında başarısızlığa neden olacağı belirtilmiştir. Beş saniyeden kısa sinyallerde bu oranın önemli ölçüde azaldığını görmüşlerdir. Aritmi tespiti için beş saniyelik segmentlere uyguladıkları KHD analizinden elde edilen SDNN, RMSSD, SDSD, pRR20 ve pRR50 öznitelikleri elde etmişler. Ensemble öğrenme ve Taguchi yöntemi ile elde ettikleri öznitelikleri birleştirerek aritmi tespitinde %89,13 doğruluk oranı elde etmişlerdir [50].

En yaygın görülen aritmi türlerinden olan atriyal fibrilasyon nefes darlığı, yorgunluk, baş dönmesi sorunlarının görüldüğü ve yaşam kalitesini direkt etkileyen aritmilerdendir. Atriyal fibrilasyonun tespit edilmesi literatürde çalışılan yaygın konulardandır. Abhimanyu ve Pushpendra yaptıkları çalışmada atriyal fibrilasyon atışlarının tespiti için KHD analizi kullanmışlardır. Atriyal fibrilasyon ve normal atımlar için 31 kalp atımı içeren segmentler belirlemişlerdir. Bu segmentlere göre yaklaşık 25-30 saniyelik segmentler elde etmişlerdir. Bu segmentlere uygulanan KHD analizi sonucu zaman bölgesi, frekans bölgesi ve doğrusal olmayan öznitelikleri elde etmişler. Tahmin sıralamasında zaman bölgesinde NN20, doğrusal olmayan özniteliklerden SD2 ve frekans bölgesinde ise HF için varyans değerinin en yüksek önem skoruna sahip olduğunu belirtmişlerdir. KNN modeli ile gerçekleştirilen sınıflandırma sonucunda %99,46 doğruluk değeri elde etmişlerdir [51]. Atriyal fibrilasyonun türlerinden olan erken evresi paroksizmal atriyal fibrilasyonun başlangıcının öngörülmesi için Ali ve arkadaşları EKG sinyali kısa dönem KHD analizi için önerilen beş dakikalık segmentlere bölmüşlerdir. Zaman bölgesi, frekans

bölgesi KHD analizi ölçütleri elde etmişlerdir ve KNN modeli ile 2,5-7,5 dakika önceden atriyal fibrilasyonun tespiti %90 doğruluk ile gerçekleştirilebilir olduğunu göstermişlerdir [52].

Markos ve Dimitros'un normal ve aritmik atımları sınıflandırmak için çalışmalarında RR aralığı takogram sinyallerinden 32 RR aralığından oluşan segmentler çıkarmışlardır. Zaman bölgesi ve zaman-frekans bölgesi analizler gerçekleştirmiş farklı kombinasyonlarda öznelilikler belirlemişlerdir. Bu öznelilikler bir dizi yapay zekânın eğitilmesinde kullanmışlardır. Zaman bölgesi analizi için elde ettikleri duyarlılık değeri %87.5 ve zaman-frekans bölgesi için bu değer %90 olarak belirtmişlerdir [53].

Sivanantham ve Shenbaga normal, erken atriyal kasılma, RBBB ve pacemaker atımların sınıflandırılması için KHD analizi zaman, frekans bölgesi ve doğrusal olmayan parametreleri kullanmışlardır. DVM makinesini sınıflandırıcı olarak kullanmışlardır. Sınıflandırma performansı %90,26 olarak elde etmişlerdir [54].

Skalogram ve spektogram görüntüleri ile sinir ağlarının eğitilmesine dayanan aritmilerin sınıflandırılması literatürde genellikle atımların sınıflandırılması şeklinde gerçekleştirilmiştir. Bu bağlamda her bir atımın, P dalgası, QRS kompleksi ve T dalgasının bulunduğu sinyal parçasının, skalogram ve spektogram görüntüsüne dönüştürülmesi ve sinir ağı kullanılarak atımların sınıflandırılması şeklinde gerçekleşmektedir.

Mateo ve Juan'ın yaptığı çalışmada normal atım, atriyal erken kasılmalar ve ventriküler erken kasılmaların sınıflandırılması için KSFD ve SDD kullanarak spektogram ve skalogram elde etmişlerdir. Bu görüntüleri ALexNet, ResNet-50 ve DVM kullanarak sınıflandırmışlardır [55].

Imane ve arkadaşlarının yaptığı çalışmada iki wavelet metodunu birleştirerek düşük ve yüksek frekanslı görüntüleri temizlemişlerdir. Sonrasında ise R dalgası tepe değerleri bulunmuş ve her 0,6 saniyelik kalp atımı sinyali için sürekli dalgacık dönüşümü uygulanarak skalogram görüntüleri elde etmişlerdir. Skalogram görüntülerine iki boyutlu ayrık dalgacık dönüşümü uygulanmış dört farklı frekans birleşeni elde edilerek skalogram görüntülerinden öznelilikler çıkarılmıştır. Kapsül sinir ağı (CapsNet) kullanılarak atımları sınıflandırmasını gerçekleştirmişlerdir [56].

Shadhon ve arkadaşları 0,225 saniyelik kalp atım sinyallerinin RGB skalogram görüntüye çevirmiş ve CNN modelinin eğitilmesi ve aritmilerin sınıflandırılması çalışması gerçekleştirmişlerdir. Bu çalışma ile daha kısa süreli verilerle ama çok veri ile hızlı aritmi sınıflandırması yaptıklarını iletmişlerdir [57].

Acharya ve arkadaşları diğer çalışmalarla karşılaştırdıklarında daha uzun olan 2 saniyelik ve 5 saniyelik EKG sinyalleri ile çalışmışlardır. CNN tabanlı bu çalışma normal sinüs ritmi, atriyal fibrilasyon, atriyal flutter, ventriküler fibrilasyon sınıflandırmışlardır. Bu çalışma CNN metotlarında kullanılan EKG sinyallerinin uzunluklarının karşılaştırıldığı çalışmalardandır [58].

Furqon ve arkadaşları MIT-BIH aritmi veri tabanından aldıkları bir saniyelik sinyal epoklarına sürekli dalgacık dönüşümü uygulayarak elde ettikleri skalogram sinyallerini CNN modellerinden EfficientNet-V2'in eğitilmesi çalışmasında beş adet aritmi türü sınıflandırılmıştır. Bu çalışmada skalogramların elde edilmesinde farklı wavelet fonksiyonları uygulanmıştır. En yüksek sonucun meksika şapkası fonksiyonunda elde edildiğini belirtilmiştir. Elde edilen skalogramlar farklı renk haritaları ile denenmiş ve en iyi performans veren Jet renk haritası olduğu belirtilmiştir [59].

Shu Lih ve arkadaşları EKG sinyallerinden 5 farklı aritmi sınıfının sınıflandırılması için CNN- LSTM (Uzun Kısa Süreli Bellek, Long Short-Term Memory) modeli önermişlerdir. Model eğitimi her atımın uzunluğunun farklı olabileceği ve sabit bir uzunluk değeri kullanmak için 1000 örnekten oluşan yaklaşık üç saniyelik sinyal parçaları kullanmışlar. Uzun sinyal parçalarını kullanmalarının model performansı için olumsuz olmadığını ve değişken uzunluktaki kalp atımlarının sınıflandırılması için önemli olduğunu belirtmişler [60]. CNN-LSTM birlikte model oluşturan bir diğer çalışma da Parul ve arkadaşlarıdır. Bu çalışmada ise 500 örneklilik sinyaller kullanarak normal sinüs atımı, kardiyak aritmi ve kongestif kalp yetmezliği sınıflandırmışlardır [61]. Bir diğer iki farklı modelin kullanıldığı çalışmada Teeranan ve arkadaşları her bir atımın dalga formu morfolojisini ve zaman içerisindeki kalp atışlarının spektrogram tabanlı desenini birleştiren bir sınıflandırma geliştirmişler. Bu modelde atımlardan ve spektrogram çıktılarından CNN ile elde edilen öznetelikler LSTM'e verilmiştir. Bu metotla normal sinüs ritmi, atriyal fibrilasyon, supraventriküler taşiaritmi, bigemini ve trigemini sınıflandırmışlardır [62]. Sinüs atımı, kardiyak aritmi ve kongestif kalp yetmezliği atımlarının sınıflandırılması için AlexNet modelini

kullanan Rashidah ve arkadaşları da 500 örnekten oluşan sinyallerden skalogram sinyalleri elde etmiş ve model eğitimi için kullanmışlar ve yüksek performansta sonuçlar elde etmişlerdir [63].

Skalogram ve spektogram sinyallerinin sınıflandırma performansını karşılaştıran Saravanakumar ve Srinivasan her bir atım uzunluğunun R tepe değerinden önce ve sonra sırasıyla 100 ve 150 örnek alarak, 250 örnekten oluşan sinyal parçalarına kısa süreli Fourier dönüşümü ve sürekli dalgacık dönüşümü uygulamış spektogram ve skalogram sinyalleri elde etmişlerdir. Bu sinyalleri CapsNet ve ViT tabanlı hibrit bir aritmi sınıflandırma modeli ile eğitmişler. Bu çalışmada 16 sınıflı sınıflandırma için skalogram görüntülerinin en yüksek doğrulukta performans gösterdiğini belirtmişler [64].

Tao ve arkadaşları yaptıkları çalışmada R dalgası tepe değerlerine bağlı RR aralığı ile ilişkili öznitelikler ve 200 örnekten oluşan kalp atımı sinyallerinden elde ettikleri skalogram görüntülerinden elde ettikleri özelliklerle birleştirilerek, EKG sınıflandırması için tam bağlantılı katmana girdi olarak verilmişlerdir. Bu çalışma ile üç farklı sınıf aritmi sınıflandırması gerçekleştirmişlerdir. Ayrıca kullanılan wavelet türünün de etkisini araştırmış ve en yüksek performans gösteren waveletin mexican hat wavelet olduğunu belirtmişlerdir [65].

Gürültü giderilmiş ve giderilmemiş EKG sinyallerinin geri yayımlı sinir ağı (Backpropagation Neural Network), karar ağacı ve CNN tabanlı sınıflandırma modellerindeki etkisini inceleyen Mengze ve arkadaşları gürültüden arındırılmış ve kaydedildiği haliyle arasında performans olarak çok büyük fark olmasa da gürültü giderilmiş veriler altında önerdikleri CNN ağının daha iyi performans gösterdiklerini belirtmişlerdir [66].

2D-CNN lerin EKG analizinde kullanımında doğruluğu yüksek ve efektif sonuçlar elde edilmesi için Min-Seo ve arkadaşları birden fazla parametre değerini karşılaştırmıştır. CWT tabanlı görüntü dönüştürme yöntemlerinde en yüksek başarının Ricker fonksiyonu ve ResNet-18 ile elde edildiğini belirtirlerken STFT tabanlı görüntü dönüştürme yöntemlerinde Hann penceresi ve ResNet-18 in en yüksek performans gösterdiğini belirtmişlerdir. STFT yöntemleri ile CWT yöntemini karşılaştırdıkları çalışmada CWT yöntemi STFT yöntemlerine göre daha yüksek performans gösterdiğini belirtmişler [67].

Parshuram ve Ajita çalışmalarında dört aritmi türünün sınıflandırılması için 12 kanalın da kullanmışlardır. 10 saniyelik EKG sinyallerinde her 1 saniye skalogramları her kanaldan hesaplanıp, 12 kanallı tek bir görüntü elde etmek için satır bazında istiflemişlerdir. Farklı sinir ağlarında performansını karşılaştırmış ve ResNet-50 için en iyi performansı elde ettiklerini belirtmişler. Bu bağlamda önceden eğitilmiş modellerin ince ayar yapılmış versiyonları sıfırdan yazılan CNN modellerinden daha iyi performans göstermiştir sonucuna ulaşmışlardır [68].

Hayatı tehdit eden ve dönüşü olmayan sonuçları doğurabilen şoklanabilir atımlar ventriküler aritmiler ve normal atımların sinir ağları ile sınıflandırılmasını içeren Dakun ve arkadaşlarının çalışmasında farklı segmentlerde sinyal uzunluklarından elde edilen skalogram görüntüleri farklı sinir ağlarında test edilmiştir. Çalışma 2D CNN çalışmalarının 1D CNN çalışmalarından daha iyi sonuçlar verdiği belirtilmiştir [69].

Birden fazla modelin birlikte kullanıldığı ya da bir model çıktısının diğer modele girdi olarak verildiği çalışmalar literatür de yaygın olarak görülmektedir.

Kalp yetmezliği, aritmi ve normal atımlardan oluşan üç sınıflı çalışmada Öznur ve Özgür skalogram görüntülerinin sinir ağlarına verilmesi ile öznelik elde ettikleri ve SVM ile sınıflandırma gerçekleştirdiklerinde yüksek performans elde ettiklerini belirtmişlerdir [70]. Bir diğer hibrit çalışma normal atım, supraventriküler ektopik atım, ventriküler ektopik atım ve füzyon atımın sınıflandırılması için gerçekleştirilen LSTM ve CNN kullanılan çalışmadır. Çalışmada hem EKG sinyalinin zamansal özellikleri LSTM ile hem de mekânsal özellikleri CNN ile elde edilmiştir. Bu modeller çapraz birleştirme ile birleştirildiği belirtilmiştir [71].

Araçlarda sürücülerde sürüş sırasında direksiyondan alınan EKG sinyallerinde aritmi analizi çalışması yapan Do Hoon ve arkadaşları sürekli dalgacık dönüşümü ve kısa zamanlı Fourier dönüşümü kullanarak farklı sinir ağları ile denemeler yapmışlardır ve en iyi performansın skalogram görüntüleri ile GoogleNet ile elde ettiklerini belirtmişlerdir [72].

Aritmi sınıflandırma çalışmalarında literatürde sinir ağlarına girdi olarak verilecek girdilerin özelliklerinin değerlendirilmesi önemli konulardandır. EKG sinyalindeki karakteristik gürültülerin etkisi, skalogram görüntüleri ve spektogram görüntülerinin elde edilmesinde kullanılan farklı parametre değerlerinin etkisini inceleyen Rafael ve arkadaşları sinir ağlarının performansını önemli derece etkileyen gürültü türünün taban

hattı kayması olduğunu belirtmişlerdir. Ayrıca çalışmada aritmi sınıflandırma skalogram görüntülerinin spektrogram görüntülerinden daha iyi çalıştığını da belirtmişlerdir [73].

Normal atım, LBBB, RBBB ve pacemaker atım sınıflandırılması için spektrogram ve skalogram görüntülerinden elde edilen özniteliklerin kullanıldığı Sara ve Thirimachos'un çalışmasında tek boyutlu sinyalde tek boyutlu yerel ikili desen ile elde ettiği öznitelikleri, spektrogram ve skalogramdan elde ettikleri öznitelikleri DVM ve KNN sınıflandırıcıları ile aritmilerin sınıflandırılması için kullanmışlardır. En yüksek performansı skalogram çıktıları ile eğittikleri DVM algoritması ile elde etmişlerdir [74].

Uzun süreli EKG sinyallerinin spektrogramına dayalı kardiyak aritmi (15 sınıf) tespiti için altı CNN tabanlı sınıflayıcının performansını inceleyen Tabassum ve Sunwoong, VGG-16, ResNet-50, Inception, MobileNet, DenseNet ve EfficientNet gibi güncel CNN tabanlı modeller ile sınıflandırmışlardır. En yüksek performans değeri DenseNet modeli ile elde etmişlerdir. Önceden eğitilmiş modellerin daha az zaman harcayarak doğru sonuçlar elde edebilmeyi sağladığını belirtmişlerdir [75].

Spektrogram tabanlı ve CNN modelleri kullanılarak aritmilerin sınıflandırılmasında farklı spektrogram elde edilme yöntemlerini ve CNN modellerinin karşılaştırılmasını yapan Ali ve arkadaşları 10 farklı aritmi türünün sınıflandırılması için AOCT-NET, Mobile-Net, Squeeze-Net ve Shuffle-Net modellerini ve bu modellere girdi olarak verilen spektrogramların elde edilmesinde kullanılan Biyospektrum, Üçüncü Dereceden Kumulant, Log-Ölçek Spektrumu ve Mel-Ölçek Spektrumu spektral temsillerin performansını karşılaştırmışlardır. Bu bağlamda en iyi sonuç CNN mimarileri arasında MobileNet ile ve kullanılan spektrum temsilleri arasında ise en yüksek doğruluk oranı Bi-Spectrum ile elde etmişlerdir [76].

Ventriküler fibrilasyon ani kalp ölümü belirteçlerinden olan ventriküler atımlardandır ve teşhisi kritik öneme sahip olduğunu belirten Li-Ming ve arkadaşları ventriküler fibrilasyonun önceden belirlenmesi ve müdahale edilebilir olması için ventriküler fibrilasyon öncesi sinyalde 1-5 dakika arası ve 10-50 saniye arası segmentler belirlemişlerdir. Bu segmentlerden spektrogram ve skalogram görüntüleri elde etmiş CNN performanslarını karşılaştırmışlardır. Daha uzun süreli segmentlerde spektrogram çıktılarının skalogram çıktılarına göre biraz daha fazla performans gösterdiğini elde

etmişlerdir. Kısa süreli segmentlerde ise uzunlara göre daha düşük performans elde ettiklerini iletmişlerdir [77].





4. MATERYAL VE YÖNTEM

Bu bölümde ilk olarak tez kapsamında aritmi sınıflandırılması için kullanılan EKG sinyallerinin alındığı veri seti tanıtılacak, daha sonra yapılan ön çalışma hakkında bilgi verilecektir. Sinyallere uygulanan sinyal ön işleme metotları ve parametreleri hakkında bilgi verilecektir. Önerilen birinci yöntem olan makine öğrenmesi metotları ile aritmilerin belirlenmesi konusunda kullanılan öznelilikler açıklanacaktır. Daha sonra ise makine öğrenmesi modelleri ve model parametreleri verilecektir. En son olarak, önerilen ikinci yöntem olan derin öğrenme ile aritmilerin belirlenmesi için çoğunlukla kullanılan farklı mimariler ve parametreler verilecektir.

4.1 Kullanılan Veri Seti

Bu tez kapsamında, 1975-1979 yılları arasında Beth Hastanesi Aritmi Laboratuvarı'nda kaydedilen 400'den fazla uzun EKG kayıtlarından oluşturulan 30 dakikalık 48 adet kayıttan oluşan MIT-BIH Aritmi Veri Tabanı veri seti olarak seçilmiştir. Denekler, 32 ile 89 yaş aralığında 25 erkek ve 23 ile 89 yaş aralığında 22 kadından oluşmaktadır [78,79].

MIT-BIH aritmi veri tabanında bulunan sinyallerin elde edildiği derivasyonlar farklılık göstermektedir. Bu derivasyonlar MLII, V1, V2, V4 ve V5'tir. MLII derivasyonu göğse yerleştirilen elektrotlardan elde edilen modifiye edilmiş Lead II derivasyondur. Tez çalışmalarında da çoğu denekte ortak olarak bulunduğu, belirgin QRS formu içerdiği ve yüksek R dalgası görüntüsünden dolayı kullanılan derivasyon MLII derivasyonudur. 102 ve 104 numaralı verilerde MLII kanal verisi bulunmadığı için bu veriler analize dahil edilmemiştir.

Veri tabanındaki sinyaller, 0,1-100 Hertz (Hz) bant geçiren filtreden geçtikten sonra 10 mV aralığında 11 bit çözünürlükte, kanal başına saniyede 360 örnek olacak şekilde sayısallaştırılmıştır.

Veri setinde her bir atımın ve ritimlerin 2 adet kardiyalog tarafından gerçekleştirilen notasyonlaması sınıflandırma için etiket olarak kullanılmıştır.

Tez kapsamında sınıflandırmaya alınan aritmi türleri 6 adettir. Bunlar, Normal Sinüs Ritmi (N), Atriyal Fibrilasyon (AFIB), Ventriküler Bigemini (B), Pacemaker ritim (P), Sol Dal Bloğu (LBBB), Sağ Dal Bloğu (RBBB)'dur. Aritmilerin türleri, sınıf etiketleri ve veri tabanından hangi sinyallerden elde edildikleri Çizelge 4.1 'de verilmiştir.

Çizelge 4.1 : Aritmi türleri ve kullanılan veri numaraları.

Aritmi	Sınıf	Kayıt No.
Normal Sinüs Ritmi	N	100,101,103,105,106,108,112,113,114,115,116,117,119,121,122,123,200,202,205,213,215,220,234
Sol Dal Bloğu	LBBB	109,111,207,214
Sağ Dal Bloğu	RBBB	118,124,212,231
Atriyal Fibrilasyon	AFIB	201,202,203,210,217,219,221
Ventriküler Bigemini	B	106,119,200,207
Pacemaker Ritim	P	107,217

Her veri 30 dakikalık EKG sinyalini içermektedir. Veriler analizden önce iki dakikalık ve beş dakikalık segmentlere ayrılmıştır. Bu segmentasyon veri sayısını arttırmak için ve KHD analizlerinin yapılması için gerçekleştirilmiştir. İki dakikalık segmentler için veri dağılımı 317 adet normal sinüs ritmi ve 292 adet aritmi (76 AFIB, 56 LBBB, 60 RBBB, 26 P, 74 B) içermektedir. Beş dakikalık segmentler için 126 normal sinüs ritmi ve 83 adet aritmi (21 AFIB, 22 LBBB, 23 RBBB, 11 P, 6 B) içermektedir. Veriler %70 eğitim ve %30 test verisi içerecek şekilde ayrılmıştır.

4.2 Ön Çalışma

Tez ön çalışmasında [80] sol ventriküler disfonksiyonu ve kardiyomiyopati ile ilişkili olabilen ventriküler atım bozukluklarından olan VEV atımların [81] ve normal atımların sınıflandırılması adına çalışmalar yapılmıştır. Bu çalışmada ana hedef VEV atımların yüksek doğrulukta, anlaşılabilir ve az sayıda öznitelik ile sınıflandırılması olmuştur. EKG sinyallerine uygulanan gürültü giderme işlemi ile gürültülerin sınıflandırma performansını etkilemesi önlenmiştir. MIT-BIH Aritmi Veri Tabanı ile eğitilen ve test edilen sınıflandırıcının St. Petersburg Kardiyolojik Teknikler Enstitüsü 12 Derivasyonlu Aritmi Veri Tabanından (INCART) [82] alınan sinyaller ile test edilmesi sınıflandırıcı performansının doğruluğunu arttırmış ve aşırı öğrenmeyi önlemeye yardımcı olmuştur.

Bu çalışmada ilk olarak MIT-BIH Aritmi Veri Tabanından VEV atım ve normal atımların bulunduğu veriler belirlenmiştir. Normal vuruşlar, 100, 101, 103, 106, 119, 200 ve 213 numaralı kayıtlardan seçildi. Öte yandan, VEV vuruşları 106, 119, 200, 213, 221, 223 ve 228 numaralı kayıtlardan elde edildi. Toplamda 79 normal vuruş ve 79 VEV'den oluşan 158 vuruş çıkarıldı. St. Petersburg Kardiyolojik Teknikler Enstitüsü 12 Derivasyonlu Aritmi Veri Tabanından ise I13, I18, I19, I27, I30 ve I47 numaralı kayıtlardan, önemli sayıda normal ve VEV vuruş içeren kayıtlar seçildi.

Sinyal işleme aşamasında R-dalgalarını tespit etmek için Pan ve Tompkins tarafından önerilen algoritma kullanılmıştır. R tepe noktalarının bulunmasından sonraki aşama Q ve S dalgalarının bulunması olmuştur. Bu dalgalar literatürde yüksek sonuç veren Yeh ve Wang tarafından önerilen algoritma kullanılmıştır [83]. Farklı örnekleme frekanslarına sahip olan iki veri tabanı için algoritmadaki parametreler ayarlanmıştır. EKG sinyaline özgü dalgaların bulunmasından sonra Q ve S dalgaları arasındaki zaman farkını ifade eden QRS genişliği, R dalgalarının genlik değeri ve iki R dalgası arasındaki zaman farkı ifade eden RR aralıkları öznitelik olarak belirlenmiştir. Sınıflandırma aşamasında karar ağaçları, DVM, KNN modelleri 158 veri ile 5 katlı çapraz doğrulama kullanılarak eğitilmiştir ve 31 veri ile test edilmiştir. Modellerin etkinliğini değerlendirmek, aşırı öğrenme sorununu ele almak ve VEV sınıflandırıcılarının genelleme yeteneğini ölçmek için INCART veri setinden alınan 78 vuruş test verisi olarak kullanılmıştır.


Modellerin doğruluğu dikkatlice değerlendirildikten sonra, çeşitli veri kümelerinde en yüksek doğruluğa sahip model seçilmiştir. Çalışma sonucunda MIT-BIH Aritmi Veri Tabanı ile elde edilen sınıflandırma algoritmalarının ortalama maksimum doğruluk ve standart sapma değerlerinin karşılaştırması yapılmıştır. DVM ile %87,41, KNN(K=5) ile %94,31, karar ağacı ile %93,04 ve KNN(K=7) ile %93,02 de yüksek doğruluk oranlarına ulaşmıştır. Sınıflandırıcılar INCART veri setiyle de test edilmiştir. DVM, KNN (K=5), KNN (K=7) ve karar ağacı algoritmalarında elde edilen doğruluk oranları sırasıyla %74,36, %70,51, %67,95 ve %94,87 olarak bulunmuştur. Karar ağacı, INCART veri setinde en etkili algoritma olarak bulunmuş ve %100 duyarlılık, %86,6 özgüllük ve %92,3 pozitif prediktif değeri elde etmiştir.

Bu çalışma, VEV'leri ve normal atımları sınıflandırmak için yüksek doğrulukta bir sınıflandırma algoritması önerilmesi amaçlanmıştır. VEV'ler ve normal atımlar, (QRS genişliği, R dalgası genliği ve RR aralığı) üç öznitelik ile karar ağacı yöntemiyle doğru şekilde sınıflandırılmıştır (MIT-BIH için maksimum doğruluk %93,04 ve INCART veri seti için %94,87). Algoritmanın yüksek doğruluğuna katkıda bulunan önemli bir faktör, bilgilendirici ve daha az karmaşık özniteliklerin seçilmesiydi. Çalışmanın bir diğer önemli yönü hem normal hem de VEV atımlarını içeren iki ayrı veri setinin kullanılmasıydı. Bu yaklaşım, algoritmanın performansının farklı türdeki sinyaller üzerinde kapsamlı bir şekilde değerlendirilmesini sağlamış, böylece algoritmanın sağlamlığını ve genelleme yeteneğini güçlendirmiştir. Ayrıca, veri setleri, yanlış pozitiflerin olasılığını azaltarak algoritmanın doğruluğunu artırmak amacıyla titiz bir ön işleme sürecine tabi tutulmuştur. Atım bazında sınıflandırma, ardışık atımların izlenmesiyle çeşitli aritmi türlerinin teşhisinde önemli bir potansiyele sahiptir.

Ön çalışmada EKG sinyalinde bulunan her atım üzerinden belirlenen dalgaların EKG sinyali üzerinde doğru şekilde tespit edilmesi ve belirtilen özniteliklerin çıkarılması önemli bir ön sinyal işleme aşaması gerektirmektedir. Ön çalışmada sadece VEV atımlar ve normal atımların sınıflandırılması üzerine çalışılmıştır. Tez ön çalışmasında elde edilen bilgiler ile çalışma daha ileriye götürülmüştür. Altı aritmi türünün sınıflandırılması atım bazlı değil belirli bir sürede alınan EKG sinyali (iki dakika ve beş dakika) üzerinden gerçekleştirilmiştir. Tez çalışmasında sınıflandırılması gerçekleştirilen aritmi türlerinden olan bigemini bir anormal atım ve bir adet VEV atımın birbirini takip etmesi ile gerçekleşen aritmi türüdür.

4.3 Tez Akış Şeması

Tez çalışmasında önerilen yöntemler ve kullanılan modeller için genel akış şeması Şekil 4.1’de verilmektedir.



Şekil 4.1 : Tez Akış Şeması

4.4 Sinyal Ön İşleme

4.4.1 EKG Sinyali Gürültü Giderme

EKG sinyallerinde kayıt alma ortamına ve kayıt cihazına bağlı olarak yaygın olarak gürültüler gözlemlenmektedir. Bu gürültülere elektrot hareketi kaynaklı gürültüler, güç hattı girişimi gürültüsü, kas kasılması, solunum kaynaklı taban hattı kayması, hareket kaynaklı gürültüler örnek verilebilir. Bahsi geçen gürültülerin EKG sinyallerinden temizlenmesi, diğer biyomedikal sinyal türlerine benzer olarak sinyalde istenen bilgi bozulmadan gerçekleştirilmesi önemlidir. Örneğin güç hattı girişimi

gürültüsünün filtrelenmesi KDH analizi için uygun iken geç potansiyellerin analizinde kullanılmak için spektral olarak gürültü ile örtüşebileceği için uygun değildir.

Solunum ya da vücut hareketleri kaynaklı deri elektrot arası empedans farkı sonucu oluşan düşük frekanslı sinyal bileşeni olan taban hattı kaymasının (Baseline Wander) frekans değeri genellikle 0,5Hz 'den düşüktür. Stres testinin ileri adımları sırasında artan nefes alıp verme ve hareket sonucu taban hattı kaymasının frekansı değişiklik gösterebilir. Taban hattı kayması gürültüsünün temizlenmesi için kullanılan metotlar doğrusal filtreleme ve polinom uydurma (polynomial fitting) metotları kullanılmaktadır. Yaygın kullanılan doğrusal filtrelerden ileri geri IIR filtreleme $x(n)$ sinyalinin bir IIR filtresi $h(n)$ ile filtrelenmesinden sonra elde edilen $z_1(n)$ sinyalinin ters çevrilip $h(n)$ ile tekrar işlenmesi sonucu $z_2(n)$ sinyali elde edilir, son olarak bu elde edilen filtrelenmiş sinyal çıktısının tekrar ters çevrilmesi ile çıkış sinyali $s(n)$ elde edilmesi ile gerçekleşir. Eşitlik 4.1'de ileri geri IIR filtreleme adımları verilmiştir [6].

$$\begin{aligned} z_1(n) &= h(n) * x(n), \\ z_2(n) &= h(n) * z_1(-n), \\ s(n) &= z_2(-n). \end{aligned} \tag{4.1}$$


Bir güç hattının neden olduğu elektromanyetik alan sonucu sinyalin üzerine binmiş EKG sinyalinden bağımsız 50Hz ve 60Hz frekansında sinüzoidal gözlenen gürültüler güç hattı girişimi (Power Line Interference) gürültüleridir [6,84]. Güç hattı girişimi temizlenmesi için doğrusal ve doğrusal olmayan filtreler örnek verilebilir. Genellikle belirli bir frekansın baskılanması ve sinyalin geri kalanının geçişine izin verilmesi amacı ile bant durduran filtreler tercih edilmektedir. Fitrenin derecesi, çentiğin genişliği ve filtre türü filtre performansını etkilemektedir [6,85].

Hareket kaynaklı gürültüler, hastanın hareketi ile elektrotların hareket etmesi veya kopması sonucu oluşmaktadır. Kas gürültüleri ise kalbe ek olarak kas kasılmalarının elektrotlar tarafından algılanması ile oluşur. Bu gürültülerin biçimleri ve frekansları tahmin edilemez olabilmektedir [10,84]. Kas gürültüsü frekans içeriği EKG sinyalleri ile üst üste binmiş olarak bulunabilmekte ve filtreleme işini zorlaştırabilmektedir. Hareket kaynaklı gürültüler ve kas gürültüleri sadece sinyalin belirli bir zaman aralığında gözlemlenebilirken sinyalde belli aralıklarda rastgele de gözlemlenebilmektedir. Bu durum da kontrolsüz yapılan filtreleme işlemlerinin

sinyalde bozulmalara neden olup EKG'nin tanısal yorumlanmasını etkileyebilmektedir [6].

Sinyallerde bulunan taban hattı kaymasının temizlenmesi için ileri geri faz kaymasız IIR filtre kullanılmıştır. Filtre türü olarak durdurma ve geçiş bandında dalgalanma olmayan Butterworth yüksek geçiren filtre kullanılmıştır. Filtre derecesi 1 ve kesim frekansı 0.5Hz olarak alınmıştır. MATLAB *butter* ve *filtfilt* fonksiyonları kullanılmıştır.

Sinyallerde bulunan güç hattı girişimi gürültüsünün temizlenmesi için ikinci derece IIR notch filtre kullanılmıştır. MATLAB *iirnotch* fonksiyonu kullanılmış ve parametreleri çentik frekansı (w_0) 0,33 ve kalite faktörü (Q) 30 olarak seçilmiştir. Orijinal sinyal ve filtrelenmiş sinyal çıktıları Şekil 4.2'de verilmiştir.




Şekil 4.2 : Orijinal sinyal ve filtrelenmiş EKG sinyali (121 numaralı veri)

4.4.2 R Dalgalarının Bulunması

QRS kompleksi AV düğümüne iletilen depolarizasyonun his demeti boyunca iletilmesi ve ventrikülerin sırayla aktive olması sırasında oluşmaktadır [86]. EKG sinyallerinde R tepe noktalarının bulunması çalışmalarda öznelite çıkarma adımından

önce önemli bir adım olarak kabul edilir. Bu yüzden QRS kompleksinin bulunması literatürde dikkat çeken konulardandır. Yüksek doğruluk oranı ile Pan ve Tompkins'in algoritması tez çalışması için tercih edilmiştir. Bu algoritma altı adımdan oluşmaktadır. Alçak geçiren filtreleme, yüksek geçiren filtreleme, türev alma, kare alma, kayan pencere yaklaşımı, eşikleme işlemi olarak listelenebilir. Bu adımlarda ortak amaç R dalgalarının yükseltilmesidir. Filtreleme işlemi kaskad şeklinde gerçekleştirilir. Alçak geçiren filtreyi yüksek geçiren filtre takip eder. Sonrasında alınan türev QRS kompleksinin eğimi ile ilgilidir. Kare alma işlemi ile yüksek genlikteki T dalgalarının bastırılması ve yanlış pozitif R dalgalarının bulunması engellenir. Negatif bileşenler sinyalden kaldırılır ve pozitif bileşenler sinyalde daha fazla yükseltilir. Kayan pencere yaklaşımı ile belirli bir genişlikteki örnek kayarak ortalama alma işlemini gerçekleştirir. Bu adımın nedeni R dalgasının eğim verisine ek dalga formu özelliğinin de elde edilmek istenmesidir. Ortalama değerlerden oluşan sinyalde maksimum değeri bulmak için eşikleme uygulaması yapılmıştır. Eşik değerinin belirlenmesi doğru tepe değerlerin bulunması için önemli bir parametredir [87]. Pan ve Tompkins algoritması akış şeması şekil 4.3'te verilmiştir.



Şekil 4.3 : Pan ve Tompkins Algoritması aşamaları

Tez kapsamında R dalgalarının tepe değerlerinin bulunması için kullanılan bu algoritmanın ilk aşamasında 5. derece alçak Butterworth filtre uygulanmıştır. Kesim frekansı 12 Hz'dir. Denominator ve numerator değerleri MATLAB *butter* fonksiyonu ile elde edilmiş filtre hem ileri hem de geri yönde uygulanarak sinyal kayması yok edilmiştir. Algoritma ikinci aşamasında ise filtrelenmiş sinyale 5. derece 0.5 Hz kesim frekansı olan butterworth yüksek geçiren filtre uygulanmıştır. Bu filtre kesim

frekanslarının seçilme nedeni literatürde açıklandığı gibi QRS kompleksinin enerjisinin üst düzeyi çıkması için istenen geçiş bandı değeridir [87]. Filtreleme için kullanılan fark denklemi 4.2 numaralı eşitlikte verilmiştir.

$$a(1) * y(n) = b(1) * x(n) + b(2) * x(n - 1) + \dots + b(nb + 1) * x(n - nb) - a(2) * y(n - 1) - \dots - a(na + 1) * y(n - na) \quad (4.2)$$

Denklemde x filtre uygulanacak sinyali ifade ederken, b numerator ve a denominator değerlerini ve y filtrelenmiş sinyali ifade etmektedir.

Kaskad olarak filtrelenen sinyale türev uygulanmıştır. Literatürde uygulanan beş nokta türev kullanılmıştır. Türev alma işleminde kullanılan transfer fonksiyon 4.3 numaralı denklemde verilmiştir. Denklemde bulunan T değeri örnekleme periyodunu ifade etmektedir.

$$y(nT) = \left(\frac{1}{8}\right) [-x(nT - 2T) - 2x(nT - T) + 2x(nT + T) + x(nT + 2T)] \quad (4.3)$$

Türevi alınan sinyale kare alma işlemi uygulanmıştır. Uygulanan bu işlem için kullanılan denklem 4.4'te verilmiştir.

$$y(nT) = [x(nT)]^2 \quad (4.4)$$

Kare alma işleminden sonra uygulanan metot kayan pencere entegrasyonu uygulanmıştır. Sinyaller için kullanılan pencere genişliği denemeler sonucu 120 örnek genişliğinde seçilmiştir. Bu işlem için kullanılan denklem 4.5'te verilmiştir.


$$y(nT) = \left(\frac{1}{N}\right) [x(nT - (N - 1)T) + x(nT - (N - 2)T) + \dots + x(nT)] \quad (4.5)$$

Kayan pencere entegrasyonu sonrası R tepe değerlerinin bulunması için eşikleme yapılmıştır. Literatürden farklı bir yol denenmiştir. Eşikleme işlemi ilk 500 örnekte maksimum değerin bulunması ile başlar, bu maksimum sinyal seviyesidir. Bu örnekten 40 örnek (360Hz için 0,12sn) sonrasında 72 örnek (0.2 sn) arasında maksimum arama tekrar yapılır. Bulunan maksimum değeri gürültü seviyesidir. Bu seviyelerle de 4.6 numaralı formül ile eşik değeri bulunur.

$$\text{Eşik} = \text{Gürültü Seviyesi} + \text{Sinyal Seviyesi} * 0,2 \quad (4.6)$$

Belirlenen eşik değerinin üzerindeki genlik değerlerine geçici olarak 1, altındaki değerlere ise 0 atanır. Bizim için değerli olanlar 1 atanırlardır. Bu değerlerinde sinyalde kaç numaralı örneğe denk geldiği bilgisi de tutulur. Bu veriler ile işlenmemiş sinyalde +- 15 örnek ile maksimum aranarak tepe noktası yani R noktası tayini yapılır. QRS dalgasındaki R noktasının tayini bu şekil gerçekleştirilmiştir.


Algoritma veri seti için ilk olarak 10 saniyelik verilerle denemiştir. Deneme sonucu literatürde de en yüksek başarısız tespit yüzdesine sahip 108 numaralı veride en düşük pozitif prediktif değeri (PPV) %27 olarak elde edilmiştir. Bu veri için P dalga boylarının R dalga boylarından büyük olmasıdır. Bu veri için R tepe değerlerinin belirlenmesinde düzeltmeler yapılmıştır. Pan ve Tompkins algoritması adımlarındaki sinyal çıktıları Şekil 4.4'te verilmiştir.




Şekil 4.4 : QRS kompleksi bulunması adımları: (a) orijinal sinyal, (b) filtrelenmiş sinyal, (c) türev alınmış sinyal çıktısı, (d) kare alınmış sinyal, (e) kayan pencere entegrasyonu ve eşik çizgisi, (f) QRS kompleksi R tepe değerlerinin gösterilmesi

4.4.3 Kalp Hızı Değişkenliği Analizinin Gerçekleştirilmesi

Ultra kısa süreli (<5 dakika) KHD metriklerinin önemi literatürde farklı hastalıklar için değerlendirilmiştir. Bu metriklerin 24 saatlik KHD metriklerinin yerini alamayacağı belirtilmiştir [88] fakat bu bağlamda otonomik tonun değerlendirilmesinde, stress seviyesi ölçülmesinde, egzersiz performansının değerlendirilmesinde, dinlenim durumu KHD analizinde iki dakikalık verilerden elde edilen ve beş dakikalık verilerden elde edilen metrikler karşılaştırdığında güvenilirlik gösterdiği ve bir veya iki dakikalık hatta daha kısa süreli EKG verilerinden elde edilen KHD metriklerinin güvenilir kullanılabileceği belirtilmiştir [89-92]. Veri tabanından elde edilen EKG sinyalleri beş dakikalık verilere ve iki dakikalık kayıtlara bölünmüştür. Şekil 4.5'te 100 numaralı veri için beş dakikalık ve iki dakikalık segmentlerde R tepe değerleri sinyal üzerinde gösterilmiştir ve KHD takogram eğrileri verilmiştir. Her 30 dakikalık kayıttan beş dakikalık altı adet EKG sinyali elde edilirken; iki dakikalık on beş adet EKG sinyali elde edilmiştir. Bu sayede her iki sinyal uzunluğu seçiminde de hem kalp hızı değişkenliği için gereken minimum süre sağlanmıştır ve veri sayısı artırılmıştır.





Şekil 4.5 : Beş dakikalık ve iki dakikalık sinyal parçaları, R tepe değerleri ve KHD takogram çıktıları


4.4.4 Spektrogram Görüntülerinin Üretilmesi

EKG sinyallerinin EKG'ye özgü dalgaların belirlenmesi ve özniteliklerin çıkarılması adımları olmadan sinir ağıları kullanılarak aritmi sınıflandırılması yapılabilmesi için literatürde de yaygın kullanılan spektrogram ve skalogram görüntülerinin elde edilmesi ve sinir ağlarına girdi olarak verilmesi planlanmıştır.


CNN modelleri kullanılarak yapılan sınıflandırma çalışmalarında literatürde CNN modellerinin eğitilmesinde girdi olarak verilen iki boyutlu sinyal görsel temsillerinin (sinyal görüntüsü, spektrogram ve skalogram görüntüleri) performansının bir boyutlu sayısal değerleri ve bu sinyallerden elde edilen özniteliklerin verilmesinde elde edilen performans değerinden daha yüksek olduğu gözlenmiştir [93,94].


Bu doğrultuda spektrogram görüntülerinin elde edilmesi için literatürdeki çalışmalarda yaygın kullanılan parametre değerleri incelenmiştir [16,67]. Spektrogram görüntülerinin elde edilmesi için pencere türü, pencere boyutu ve örtüşme değeri belirlenmesi için bir dizi deneme yapılmıştır. Bu değişkenlerin model sonucuna etkisi değerlendirilmiştir. Bu kısımda örtüşme oranı hep %50 alınarak dört farklı pencere uzunluğu (200ms, 500ms, bir saniye ve iki saniye), iki farklı pencere türü (Hanning ve Hamming) ile gürültüden temizlenmiş sinyallerin spektrogram çıktıları elde edilmiştir. Kullanılan pencere türlerinin zaman düzleminde gösterimi Şekil 4.6'da verilmiştir.

Farklı parametrelerin denendiği 116 numaralı verinin ilk segmenti için spektrogram çıktıları Şekil 4.7’de verilmiştir. Çıktılar farklı sinir ağlarına verilerek performansları değerlendirilmiştir.



Şekil 4.6 : Hamming ve Hanning penceresi





Şekil 4.7 : (a) Hamming 200ms pencere, (b) Hanning 200ms pencere, (c) Hamming 500ms pencere, (d) Hanning 500ms pencere, (e) Hamming 1000ms pencere, (f) Hanning 1000ms pencere, (g) Hamming 2000ms pencere, (h) Hanning 2000ms pencere spektrogram çıktıları


Yapılan analizler sonucu her üç modelde de yüksek sonuç veren parametre değerleri seçilmiştir. Pencere türü hanning penceresi, pencere uzunluğu 1000ms ve örtüşme değeri 500ms olarak belirlenmiştir. Çizelge 4.2’de spektrogram parametreleri ve model doğruluk değerleri verilmiştir.

Çizelge 4.2 : Spektrogram parametrelerinin belirlenmesi.


Spektrogram			GoogleNet	ResNet-50	AlexNet	SqueezeNet
Pencere	Pencere Uzunluğu (ms)	Örtüşme Değeri (ms)	Doğruluk (%)	Doğruluk (%)	Doğruluk (%)	Doğruluk (%)
Hamming	200	100	88,33	87,85	89,52	85,23
Hanning	200	100	90	86,42	92,38	85,95
Hamming	500	250	88,8	87,14	92,14	87,38
Hanning	500	250	89,28	86,19	89,52	86,9
Hamming	1000	500	86,9	83,09	89,04	85,71
Hanning	1000	500	90,47	85,23	91,90	87,38
Hamming	2000	1000	79,76	75,23	85,95	74,04
Hanning	2000	1000	80,47	75	87,14	76,66

4.4.5 Skalogram Görüntülerinin Üretilmesi

Skalogram görüntülerinin elde edilmesi için literatürdeki çalışmalar incelenmiştir. Çalışmalarda kullanılan wavelet fonksiyonları da dikkate alınmıştır. [59,65,67,70]. Skalogram görüntülerinin elde edilmesi için farklı wavelet fonksiyonları ile bir dizi deneme yapılmıştır. Bu değişkenlerin model sonucuna etkisi değerlendirilmiştir. Bu kısımda denemesi yapılan wavelet fonksiyonları mexican hat, morse, morlet, bump, db4, gaus4 ve gaus8'dir. Kullanılan wavelet fonksiyonları zaman düzlemi gösterimleri Şekil 4.8'de verilmiştir. Farklı wavelet fonksiyonları uygulanmış 100 numaralı veri birinci segment için skalogram çıktıları Şekil 4.9'de verilmiştir. Skalogram çıktıları farklı sinir ağlarına verilerek performansları değerlendirilmiştir.



Şekil 4.8 : Wavelet fonksiyonları [95-97]



Şekil 4.9 : (a) Meksika şapkası, (b) Morse, (c) Morlet, (d) Bump, (e) db4, (f) gaus4, (g) gaus8 wavelet fonksiyonları ile alınmış skalogram çıktıları

Yapılan analizler sonucu her üç modelde de yüksek sonuç veren wavelet penceresi seçilmiştir. Wavelet fonksiyonu olarak Bump fonksiyonu seçilmiştir. Çizelge 4.3'te skalogram parametreleri ve model doğruluk değerleri verilmiştir.

Çizelge 4.3 : Skalogram parametrelerinin belirlenmesi.

Scalogram	GoogleNet	ResNet-50	AlexNet	SqueezeNet
Wavelet	Doğruluk (%)	Doğruluk (%)	Doğruluk (%)	Doğruluk (%)
Mexican hat	84,79	84,67	83,11	79,88
Morse	90,95	87,14	90	89,76
Morlet	88,80	88,09	90,95	87,85
Bump	92,85	89,28	91,19	90,71
db4	87,85	87,14	92,38	87,85
gaus4	90,23	86,66	88,57	83,80
gaus8	90,71	86,90	87,14	83,57

4.5 Öznitelik Çıkarımı

Tez çalışmasının bu bölümünde aritmilerin sınıflandırılması için kullanılacak makine öğrenmesi modellerinin eğitilmesi ve test edilmesi için girdi olarak verilen KHD analizi öznitelikler çıkarılmıştır. Her segment için KHD analizi gerçekleştirilmiştir ve öznitelikler elde edilmiştir. Bu öznitelikler zaman bölgesi, frekans bölgesi ve doğrusal olmayan özniteliklerden oluşmaktadır. KHD analizinin gerçekleştirilmesi sonucu beş dakikalık segmentler için 68 adet öznitelik (209 x 68 öznitelik matrisi) elde edilirken iki dakikalık sinyaller için öznitelik sayısı 65 (609 x 65 öznitelik matrisi) olarak belirlenmiştir. Bu düşüşün nedeni KHD analizinden elde edilen özniteliklerin sinyal uzunluğunun azalması dolayısıyla değerlerinin elde edilememesi ve değerlendirilmeye alınmamasıdır. Örneğin, ULF değeri beş dakikalık segmentlerden elde edilemezken; VLF değeri beş dakikalık sinyallerde bulunsa da iki dakikalık sinyallerden elde edilememiştir. Belirli bir zaman dilimi içerisindeki ortalama RR sürelerinin standart sapmasının (Standard Deviation of Average RR Intervals, SDANN) ve belirli zaman diliminde bulunan RR aralıklarının standart sapmalarının ortalaması (Mean of the Standard Deviations of RR Intervals, SDNNI) beş dakikalık sinyallerden elde edilirken iki dakikalık sinyallerden elde edilememiştir. Hem iki dakikalık hem de beş dakikalık sinyallerin KHD analizinden elde edilecek özniteliklerin belirlenmesinde açık kaynak NeuroKit2 referans alınmıştır [98]. Beş dakikalık ve iki dakikalık segment uzunluklarının aritmi analizine etkisini görmek adına ortak öznitelikler belirlenmiş ve öznitelik sayıları eşitlenmiştir. Her iki uzunluktaki sinyaller için öznitelik sayısı 65 olarak belirlenmiştir.

4.6 Makine Öğrenmesi Modelleri ile Aritmilerin Sınıflandırılması

Farklı segment uzunluklarına uygulanan KHD analizi ile çıkarılan öznitelikler dört farklı sınıflandırıcıya girdi olarak verilmiş ve sınıflandırılmıştır. Bu sınıflandırıcılar Karar Ağacı, DVM, KNN ve Ensemble modelidir.

Karar ağacı sınıflandırıcısında model parametreleri yaprak düğümdeki minimum gözlem sayısı, dallanma düğümündeki minimum gözlem sayısı, maksimum karar bölme sayısı ve bölme kriteridir. Model eğitimi için MATLAB *fitctree* fonksiyonu kullanmıştır. En iyi sonuç veren model parametrelerinin bulunması için farklı değerler denenmiştir. Yaprak düğümdeki minimum gözlem sayısı 1, 5, 10 ve 20 değerleri seçilmiştir. Dallanma düğümündeki minimum gözlem sayısı için seçilen parametreler 2, 5 ve 10'dur. Maksimum karar bölme sayısı değeri için 10, 20, 50 ve 100 model eğitimi için belirlenen değerlerdendir. Son olarak bölme kriteri olarak gini çeşitlilik indeksi ('gdi'), twoing kuralı ('twoing') ve maksimum sapma azalımı ya da çapraz entropi ('davience') kullanılan parametrelerdendir. En iyi performans veren karar ağacı parametrelerinin belirlenmesi için kullanılan parametreler Çizelge 4.4'te verilmiştir. Her iki epok değeri için yüksek sonuç veren yaprak düğümündeki minimum gözlem sayısı 1, dallanma düğümündeki minimum gözlem sayısı 5, maksimum karar bölme sayısı 50 ve bölme kriteri twoing seçilmiştir.

Çizelge 4.4 : Karar Ağacı parametreleri.

Epok Uzunluğu	Yaprak düğümdeki minimum gözlem sayısı	Dallanma düğümündeki minimum gözlem sayısı	Maksimum karar bölme sayısı	Bölme kriteri	Doğruluk (%)
2 dakika	1	5	50	twoing	78,51
2 dakika	1	5	100	davience	77,58
2 dakika	1	2	100	gdi	75,65
5 dakika	1	2	20	twoing	77,90
5 dakika	5	5	100	davience	77,41
5 dakika	5	10	20	gdi	73,32
2 dakika	1	2	20	twoing	74,28
5 dakika	1	5	50	twoing	75,64

Destek vektör makinesi model parametreleri kernel fonksiyonu ve çok sınıflı sınıflandırma için kullanılan kodlama yöntemi olarak seçilmiştir. Kernel fonksiyonu olarak doğrusal ('linear'), gaussian, polinom ('polynomial') fonksiyonlar seçilmiştir.

Kodlama yöntemi olarak her sınıf için ayrı DVM modeli oluşturan bir-birine karşı (onevsone) kodlama yöntemi ve her sınıf için diğer sınıflara karşı bir sınıflandırıcı oluşturan bir-hepsine karşı (onevsall) yöntemi seçilmiştir. Model eğitimi için MATLAB *fitcsvm* fonksiyonu kullanmıştır. En iyi performans veren destek vektör makinası parametrelerinin belirlenmesi için kullanılan parametreler Çizelge 4.5'te verilmiştir. Destek vektör makinesi modeli için iki epok süresi için de aynı model parametreleri yüksek performans göstermiştir. Kernel fonksiyonu polynomial ve kodlama yöntemi de onevsone olarak seçilmiştir.

Çizelge 4.5 : Destek Vektör Makinesi parametreleri.

Epok Uzunluğu	Kernel	Kodlama Yöntemi	Doğruluk (%)
2 dakika	polynomial	onevsone	85,82
2 dakika	polynomial	onevsall	83,13
2 dakika	gaussian	onevsone	81,64
2 dakika	gaussian	onevsall	83,24
2 dakika	linear	onevsall	78,07
2 dakika	linear	onevsone	76,20
5 dakika	polynomial	onevsone	90,48
5 dakika	polynomial	onevsall	90,32
5 dakika	gaussian	onevsone	80,80
5 dakika	gaussian	onevsall	86,29
5 dakika	linear	onevsall	80,32
5 dakika	linear	onevsone	78,71

KNN model eğitimi için parametreler komşu sayısı ve uzaklık olarak seçilmiştir. Komşu sayısı olarak 5, 11 ve 20 değerleri denenmiştir. Komşuluk değerinin çift olarak seçildiği parametrede en yakın komşu verisi kullanılmıştır. Veri noktası ile komşunun arasındaki uzaklığı hesaplamak için chebyshev, minkowski mesafesi, manhattan mesafesi ve öklidyen mesafe kullanılmıştır. Model eğitimi için MATLAB *fitcknn* fonksiyonu kullanmıştır. En iyi performans veren KNN parametrelerinin belirlenmesi için kullanılan parametreler Çizelge 4.6'da verilmiştir. KNN modeli için her iki epok değeri için en yüksek performans gösteren model parametreleri komşu sayısı 5 ve uzaklık manhattan mesafesi seçilmiştir.

Çizelge 4.6 : k-En Yakın Komşu parametreleri.

Epok Uzunluğu	Komşu Sayısı	Uzaklık	Doğruluk (%)
2 dakika	5	Chebychev	74,28
2 dakika	5	Manhattan	86,09
2 dakika	5	Euclidean	81,48
2 dakika	5	Minkowski	82,03
2 dakika	11	Chebychev	72,08
2 dakika	11	Manhattan	84,45
2 dakika	11	Euclidean	81,64
2 dakika	11	Minkowski	82,19
2 dakika	20	Chebychev	77,52
2 dakika	20	Manhattan	80,21
2 dakika	20	Euclidean	78,40
2 dakika	20	Minkowski	78,07
5 dakika	5	Chebychev	81,29
5 dakika	5	Manhattan	88,87
5 dakika	5	Euclidean	88,85
5 dakika	5	Minkowski	86,77
5 dakika	11	Chebychev	74,03
5 dakika	11	Manhattan	79,19
5 dakika	11	Euclidean	77,90
5 dakika	11	Minkowski	78,87
5 dakika	20	Chebychev	68,06
5 dakika	20	Manhattan	73,06
5 dakika	20	Euclidean	73,54
5 dakika	20	Minkowski	73,22

Ensemble model için en iyi sonuç veren modelin bulunması için seçilen parametreler topluluk öğrenmesi için seçilen metottur. Model eğitimi için MATLAB *fitcensemble* fonksiyonu kullanmıştır. Metot olarak çok sınıflı sınıflandırma için kullanılan AdaBoost (Adaptive Boosting) (AdaBoostM2) ve Bagging (Bootstrap Aggregating) (Bag) metotları seçilmiştir. AdaBoostM2 metodu için öğrenme oranı parametresi de model performansı için değerlendirilmiştir. En iyi performans veren ensemble model parametrelerinin belirlenmesi için kullanılan parametreler Çizelge 4.7’de verilmiştir. Ensemble model için parametre değerleri AdaBoostM2 ve öğrenme oranı 1 olarak seçilmiştir.

Çizelge 4.7 : Topluluk Öğrenmesi modeli parametreleri.

Epok Uzunluğu	Metot	Öğrenme Oranı	Doğruluk (%)
2 dakika	AdaBoostM2	1	87,91
2 dakika	AdaBoostM2	0,1	82,08
2 dakika	Bag		83,40
5 dakika	AdaBoostM2	1	86,77
5 dakika	AdaBoostM2	0,1	81,93
5 dakika	Bag		82,74

4.7 Aritmilerin Evrişimsel Sinir Ağları ile Sınıflandırılması

Tez çalışmasının bu bölümünde, aritmelerin sınıflandırılması için oluşturulan spektrogram ve skalogram görüntüleri, literatürde sıkça kullanılan farklı sinir ağı modellerine girdi olarak verilmiştir.

GoogleNet mimarisinde model parametreleri Mini-Batch Boyutu 32, maksimum Eğitim Tur (Epoch) Sayısı 50 ve öğrenme hızı 0,0001 olarak seçilmiştir. Her epokta eğitim verileri karıştırılmıştır. Modelin doğrulanması için validasyon veri seti ile her 30 adımda bir modelin performansı kontrol edilmiştir.

ResNet-50 mimarisinde model parametreleri Mini-Batch Boyutu 32, Epoch Sayısı 30 ve öğrenme hızı 0,0001 olarak seçilmiştir. Her epokta eğitim verileri karıştırılmıştır. Modelin doğrulanması için validasyon veri seti ile her 30 adımda bir modelin performansı kontrol edilmiştir.

AlexNet mimarisinde model parametreleri Mini-Batch Boyutu 64, Epoch Sayısı 50 ve öğrenme hızı 0,0001 olarak seçilmiştir. GoogleNet ve ResNet-50 modellerinde olduğu gibi her epokta eğitim verileri karıştırılmıştır. Modelin doğrulanması için validasyon veri seti ile her 30 adımda bir modelin performansı kontrol edilmiştir.

Son olarak SqueezeNet mimarisinde model parametreleri Mini-Batch Boyutu 10, Epoch Sayısı 6 ve öğrenme hızı 0,0001 olarak seçilmiştir. Her epokta eğitim verileri karıştırılmıştır. Modelin doğrulanması için validasyon veri seti ile her 3 adımda bir modelin performansı kontrol edilmiştir.

Üretilen görüntüler ağı girdi olarak verilmeden önce o ağın giriş boyutuna göre yeniden boyutlandırılmıştır. GoogleNet ve ResNet-50 için girdi boyutu 224x224x3 iken AlexNet ve SqueezeNet için 227x227x3 girdi boyutudur. Spektrogram ve skalogram görüntüleri AlexNet ve SqueezeNet için yeniden boyutlanmıştır.



5. BULGULAR, DEĞERLENDİRME VE TARTIŞMA

Tüm sinyal ön işleme, makine öğrenmesi ve derin öğrenme modelleri MATLAB (R2022a) ve Python ortamında gerçekleştirilmiştir. Kullanılan bilgisayar Windows 10 64 bit işletim sistemine sahip olup, donanımsal olarak NVIDIA Quadro RTX 4000 ekran kartına, Intel(R) Core(TM) i9-10900K işlemcisine, 32GB RAM belleğine sahiptir.

Tezin makine öğrenme modellerinin eğitilmesi ve test edilmesi aşamasında deneyler on kez tekrarlanmıştır. Derin öğrenme modellerinin eğitilmesi ve test edilmesi aşamasında ise modellerin eğitimi daha uzun sürdüğü için beş kez tekrarlanmıştır. Elde edilen bulgularda ortalama performans değeri ve standart sapma değeri birlikte sunulmuştur.

Sınıflandırmada kullanılan modellerin performansını değerlendirmek için literatürde yaygın kullanılan metrikler kullanılmıştır. Bu metrikler doğruluk, kesinlik veya pozitif tahmin değeri (Positive Predictive Value, PPV), duyarlılık, özgüllük ve F1 skor 'dur. Bu performans metrikleri Eşitsizlik 5.1- Eşitsizlik 5.5'te verilmiştir.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \times 100 \quad (5.1)$$

$$\text{Kesinlik veya PPV} = \frac{DP}{DP + YP} \times 100 \quad (5.2)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \times 100 \quad (5.3)$$

$$\text{Özgüllük} = \frac{DN}{DN + YP} \times 100 \quad (5.4)$$

$$\text{F1 Skor} = \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \times 100 \quad (5.5)$$

Doğru Pozitif (DP): Belirli bir sınıfa ait olan ve doğru bir şekilde sınıflandırılan aritmleri temsil eder.

Doğru Negatif (DN): İlgili sınıfa ait olmayan ve doğru şekilde o sınıfa ait değil olarak sınıflandırılan aritmleri temsil eder.

Yanlış Pozitif (YP): İlgili sınıfa ait olmadığı halde model tarafından o sınıfa ait olarak yanlış sınıflandırılan aritmlerdir.

Yanlış Negatif (YN): İlgili sınıfa ait olduğu halde model tarafından o sınıfa ait değil olarak yanlış sınıflandırılan aritmlerdir.

Birden fazla aritmi türünü sınıflandıran modellerin performans metrikleri her bir sınıf için bağımsız olarak hesaplanmıştır. Her bir sınıf eşit ağırlıkta değerlendirilmiş ve metriklerinin ortalaması (makro ortalaması) alınarak doğruluk, kesinlik, duyarlılık, özgüllük ve F1 skor metrikleri elde edilmiştir.


5.1 Bulgular

KHD tabanlı özneliliklerin makine öğrenmesi modellerinin eğitimi için girdi olarak verildiği sınıflandırma gerçekleştirilmiştir. İki dakikalık epoklara uygulanan KHD analizi sonucu elde edilen özneliliklerin makine öğrenmesi modellerine verilerek aritmlerin sınıflandırılmasında kullanılan modellerin performansı Çizelge 5.1’de verilmiştir. Çizelgede gözlenen sonuçlar 10 tekrar sonucu ortalama ve standart sapma değeri ile verilmiştir. En yüksek doğruluk $87,91 \pm 0,02$ ile ensemble modelde gözlenmiştir. Ensemble model en yüksek PPV, duyarlılık, özgüllük ve f1 skor değerine sahiptir.

Çizelge 5.1 : Farklı makine öğrenmesi modelleri ile aritmlerin sınıflandırılma sonuçları (Epok süresi: iki dakika).

Performans Metrikleri	Karar Ağacı	DVM	KNN	Ensemble
Doğruluk (%)	$78,51 \pm 0,02$	$85,82 \pm 0,02$	$86,09 \pm 0,02$	$87,91 \pm 0,02$
PPV (%)	$74,76 \pm 5,74$	$88,42 \pm 2,41$	$87,85 \pm 4,62$	$89,71 \pm 3,71$
Duyarlılık (%)	$71,82 \pm 5,11$	$80,52 \pm 4,79$	$83,54 \pm 3,11$	$83,03 \pm 3,81$
Özgüllük (%)	$94,34 \pm 0,77$	$95,82 \pm 0,68$	$96,16 \pm 0,51$	$96,53 \pm 0,74$
F1 Skor (%)	$73,19 \pm 4,87$	$84,22 \pm 3,14$	$85,61 \pm 2,45$	$86,17 \pm 2,72$

İki dakikalık EKG sinyali üzerinden gerçekleştirilen KHD analizi sonucu elde edilen öznitelikler ve makine öğrenmesi modelleri ile gerçekleştirilen aritmi sınıflandırmasında her bir aritmi türü için modellerin performansı Şekil 5.1’de verilmiştir. Şekilde gözlenen sonuçlar, AFIB için en yüksek doğruluk değeri %91 ile KNN ile elde edilirken en düşük sınıflandırma performansı %52 ile karar ağacı modelinde elde edilmiştir. Ventriküler bigemini için en yüksek ve en düşük doğruluk değerleri sırasıyla %100 ensemble model ve %50 DVM ile elde edilmiştir. LBBB için %88 en yüksek sınıflandırma performansı KNN modeli ile elde edilirken en düşük performans %63 ile karar ağacı ile elde edilmiştir. Normal sinüs ritmi için sırasıyla en yüksek doğruluk değeri %94 ile ensemble ve DVM ile elde edilirken en düşük performans gösteren model %90 ile karar ağacıdır. Pacemaker atım için en yüksek performans %100 KNN ile en düşük performans %37 karar ağacı ile elde edilmiştir. RBBB aritmi türü için en yüksek doğruluk değeri ise %74 ile DVM ve en düşük doğruluk değeri %56 ile karar ağacı ile elde edilmiştir.



Şekil 5.1 : Aritmi türlerinin modellerdeki performans karşılaştırması (Epok süresi: İki dakika)


Beş dakikalık epoklara uygulanan KHD analizi sonucu elde edilen özniteliklerin makine öğrenmesi modellerine verilerek aritmilerin sınıflandırılmasında kullanılan modellerin performansı ise Çizelge 5.2’de verilmiştir. İki dakikalık verilerde olduğu gibi beş dakikalık verilerde de 10 tekrar sonucu model performansları ortalama ve

standart sapma değeri ile verilmiştir. En yüksek doğruluk DVM modelde gözlenmiştir. DVM model en yüksek doğruluk, PPV, özgüllük ve f1 skor değerleri elde edilmiştir. En yüksek duyarlılık değeri ise KNN modelinde gözlenmiştir. KNN modelinin özgüllük performansı da diğer modellere göre yüksektir.

Çizelge 5.2 : Farklı makine öğrenmesi modelleri ile aritmilerin sınıflandırılma sonuçları (Epok süresi: beş dakika).

Performans Metrikleri	Karar Ağacı	DVM	KNN	Ensemble
Doğruluk (%)	77,90 ± 0,04	90,48 ± 4,33	88,87 ± 0,03	86,77 ± 0,02
PPV (%)	70,30 ± 10,62	93,97 ± 3,03	89,64 ± 4,22	90,94 ± 5,03
Duyarlılık (%)	68,93 ± 8,08	83,53 ± 6,53	83,60 ± 6,89	77,83 ± 7,53
Özgüllük (%)	93,83 ± 1,24	96,56 ± 1,68	96,85 ± 1,25	95,09 ± 1,03
F1 Skor (%)	69,48 ± 8,86	88,38 ± 4,69	86,38 ± 4,62	83,71 ± 5,47

Beş dakikalık EKG sinyali üzerinden gerçekleştirilen KHD analizi sonucu elde edilen öznitelikler ve makine öğrenmesi modelleri ile gerçekleştirilen aritmi sınıflandırmasında her bir aritmi türü için modellerin performansı Şekil 5.2’de verilmiştir. Şekilde gözlenen sonuçlar, AFIB için en yüksek doğruluk değeri %100 ile karar ağacı ve KNN ile elde edilirken en düşük sınıflandırma performansı %83 ile ensemble modelinde elde edilmiştir. Ventriküler bigemini için en yüksek doğruluk değerleri %100 olarak karar ağacı, DVM ve KNN ile elde edilmiştir. Ensemble model ise %50 ile en düşük doğruluk gösteren model olmuştur. LBBB için %100 en yüksek sınıflandırma performansı DVM ve KNN modelleri ile elde edilirken en düşük performans %67 ile ensemble model ile elde edilmiştir. Normal sinüs ritmi için sırasıyla en yüksek doğruluk değeri %95 ile ensemble ile elde edilirken en düşük performans gösteren model %81 ile karar ağacıdır. Pacemaker atım için en yüksek performans %67 ile karar ağacı ve KNN için eşittir. %50 ile en düşük performans ensemble ve DVM ile elde edilmiştir. RBBB aritmi türü için en yüksek doğruluk değeri ise %100 ile DVM ve en düşük doğruluk değeri %83 ile KNN ile elde edilmiştir.



Şekil 5.2 : Aritmi türlerinin modellerdeki performans karşılaştırması(Epok süresi: Beş dakika)

Spektrogram ve skalogram çıktılarının sinir ağlarına eğitim için girdi olarak verilmiş ve aritmi sınıflandırılması gerçekleştirilmiştir.


Her epogun spektrogram ve skalogram görüntüleri elde edilmiştir ve sinir ağlarına aritmi sınıflandırılması için girdi olarak verilmiştir. Model eğitimlerinde kullanılan modeller ve sınıflandırmadaki performansları Çizelge 5.3'te verilmiştir. GoogleNet modeli için eğitim süresi 75,76 saniye iken test süresi 0,67 saniyedir. ResNet-50 modeli için eğitim süresi 127,50 saniye iken test süresi 1,72 saniyedir. AlexNet modeli için eğitim süresi 26,10 saniye iken test süresi 0,33 saniyedir. SqueezeNet modeli için eğitim süresi 18,04 saniye iken test süresi 0,30 saniyedir. Çizelgede gözlenen sonuçlar 5 tekrar sonucu ortalama ve standart sapma değeri ile verilmiştir. En yüksek doğruluk AlexNet'te gözlenmiştir. En yüksek PPV, duyarlılık, özgüllük ve f1 skor değeri AlexNet modelinde gözlemlenmiştir.

Çizelge 5.3 : Spektrogram görüntülerinden farklı sinir ağları ile aritmilerin sınıflandırılma sonuçları.

Performans Metrikleri	GoogleNet	ResNet-50	AlexNet	SqueezeNet
Doğruluk (%)	90,47 ± 2,22	85,23 ± 2,16	91,90 ± 3,19	87,38 ± 2,98
PPV (%)	90,80 ± 2,45	87,07 ± 2,86	92,44 ± 4,34	84,86 ± 5,75
Duyarlılık (%)	87,93 ± 3,79	78,12 ± 4,36	90,93 ± 4,08	85,47 ± 5,81
Özgüllük (%)	97,27 ± 0,87	95,69 ± 0,67	97,67 ± 0,90	96,92 ± 0,70
F1 Skor (%)	89,30 ± 2,36	82,32 ± 3,44	91,63 ± 3,56	85,16 ± 5,73

İki dakikalık EKG sinyallerinden elde edilen spektrogram çıktılarından sinir ağları kullanılarak gerçekleştirilen aritmi sınıflandırmasında her bir aritmi türü için modellerin performansı Şekil 5.3'te verilmiştir.

Şekilde gözlenen sonuçlar, AFIB için en düşük doğruluk değeri %80 ile ResNet-50 ile elde edilirken diğer sinir ağlarındaki performansı %100'dür. Ventriküler bigemini için en yüksek doğruluk değerleri %100 olarak AlexNet ve ResNet-50 ile elde edilmiştir. GoogleNet ise %67 ile en düşük doğruluk gösteren sinir ağı olmuştur. LBBB için %100 en yüksek sınıflandırma performansı GoogleNet ve AlexNet ile elde edilirken en düşük performans %63 ile ResNet-50 ile elde edilmiştir. Normal sinüs ritmi için sırasıyla en yüksek doğruluk değeri %100 ile AlexNet ile elde edilirken en düşük performans gösteren ağ %87 ile SqueezeNet'tir. Pacemaker atım için en yüksek performans %100 ile GoogleNet ve AlexNet için eşittir. %80 ile en düşük performans ResNet-50 ve SqueezeNet ile elde edilmiştir. RBBB aritmi türü için en yüksek doğruluk değeri ise %89 ile SqueezeNet ve en düşük doğruluk değeri %56 ile GoogleNet ile elde edilmiştir.




Şekil 5.3 : Aritmi türlerinin modellerdeki performans karşılaştırması (Spektogram)

Skalogram görüntülerinin sinir ağırları ile sınıflandırılması sonucu kullanılan modeller ve sınıflandırmadaki performansları Çizelge 5.4'te verilmiştir. GoogleNet modeli için eğitim süresi 77,73 saniye iken test süresi 0,71 saniyedir. ResNet-50 modeli için eğitim süresi 125,16 saniye iken test süresi 1,70 saniyedir. AlexNet modeli için eğitim süresi 25,09 saniye iken test süresi 0,30 saniyedir. SqueezeNet modeli için eğitim süresi 17,12 saniye iken test süresi 0,92 saniyedir. Çizelgede gözlenen sonuçlar 5 tekrar sonucu ortalama ve standart sapma değeri ile verilmiştir. En yüksek doğruluk değeri %92,85±2,52 ile GoogleNet ile ulaşılmıştır. SqueezeNet modelinde de yüksek doğrulukta, duyarlılık ve özgüllükte çıktılar elde edilmiştir. GoogleNet modeli en yüksek PPV, duyarlılık, özgüllük ve f1 skor değerine sahiptir.

Çizelge 5.4 : Skalogram görüntülerinden farklı sinir ağırları ile aritmilerin sınıflandırılma sonuçları.

Performans Metrikleri	GoogleNet	ResNet-50	AlexNet	SqueezeNet
Doğruluk (%)	92,85 ± 2,52	89,28 ± 0,84	91,19 ± 1,59	90,71 ± 4,86
PPV (%)	93,01 ± 3,32	92,13 ± 2,97	91,38 ± 3,92	91,35 ± 4,00
Duyarlılık (%)	92,03± 2,73	85,36 ± 1,84	88,50 ± 3,80	87,01 ± 8,37
Özgüllük (%)	98,06 ± 0,65	96,61 ± 0,47	97,62 ± 0,42	97,57 ± 1,38
F1 Skor (%)	92,48 ± 2,06	88,58 ± 0,89	89,82 ± 2,21	89,03 ± 5,93

İki dakikalık EKG sinyallerinden elde edilen skalogram çıktılarından sinir ağıları kullanılarak gerçekleştirilen aritmi sınıflandırmasında her bir aritmi türü için modellerin performansı Şekil 5.4'te verilmiştir. Şekilde gözlenen sonuçlar, AFIB için en yüksek doğruluk değeri %100 ile dört sinir ağında da elde edilmiştir. Ventriküler bigemini için en yüksek doğruluk değerleri %100 olarak GoogleNet ile elde edilmiştir. ResNet-50 ise %67 ile en düşük doğruluk değeri gösteren sinir ağı olmuştur. LBBB için %100 en yüksek sınıflandırma performansı ResNet-50 ve AlexNet ile elde edilirken en düşük performans %62 ile SqueezeNet ile elde edilmiştir. Normal sinüs ritmi için sırasıyla en yüksek doğruluk değeri %100 ile SqueezeNet ile elde edilirken en düşük performans gösteren ağ %83 ile AlexNet'tir. Pacemaker atım için en düşük performans %80 ile SqueezeNet ile elde edilirken diğer bütün ağlarda %100 sınıflandırma performansı elde edilmiştir. RBBB aritmi türü için en yüksek doğruluk değeri ise %89 ile GoogleNet ve en düşük doğruluk değeri %33 ile SqueezeNet ile elde edilmiştir.



Şekil 5.4 : Aritmi türlerinin modellerdeki performans karşılaştırması (Skalogram)

5.2 Değerlendirme ve Tartışma

Bu tez çalışmasında, makine öğrenmesi ve derin öğrenme kullanılarak aritmilerin sınıflandırılması gerçekleştirilmiştir. Öncelikle, EKG sinyallerine uygulanan KHD analizi sonucu elde edilen özneliliklerle makine öğrenmesi modelleri kullanılarak daha

sonrasında daha çok zaman alan, sinyal işleme ve öznitelik çıkarma aşamaları gerektiren analizler olmadan EKG sinyallerinden elde edilen spektogram ve skalogram görüntüleri kullanılarak dört farklı evrimsel sinir ağları ile aritmi sınıflandırılması gerçekleştirilmiştir. Bu sayede bu iki yöntemin karşılaştırılması sağlanmıştır.


Birinci kısımda farklı uzunluklardaki (iki dakika ve beş dakika) sinyallere uygulanan KHD analizinden elde edilen özniteliklerle eğitilen makine öğrenmesi modellerinin (Karar Ağacı, k- En Yakın Komşu, Destek Vektör Makinesi ve Ensemble) başarıları araştırılmıştır.

İkinci kısımda aritmi analizi için literatürde sıklıkla kullanılan skalogram görüntülerinin ve spektogram görüntülerinin evrimsel sinir ağlarındaki (GoogleNet, ResNet-50, AlexNet ve SqueezeNet) başarıları araştırılmıştır.

Çalışmada kullanılan EKG sinyalleri MIT-BIH Aritmi veri tabanından alınmıştır. İlk kısımda KHD analiz öznitelikleri ile gerçekleştirilen sınıflandırmada iki sinyal uzunluğu incelenmiştir. İlk olarak iki dakikalık segmentler için veri dağılımı 317 adet normal sinüs ritmi ve 292 adet aritmi (76 AFIB, 56 LBBB, 60 RBBB, 26 P, 74 B) içermektedir. İkinci olarak beş dakikalık segmentler için 126 normal sinüs ritmi ve 83 adet aritmi (21 AFIB, 22 LBBB, 23 RBBB, 11 P, 6 B) içermektedir.

Spektogram ve skalogram görüntüleri ise iki dakikalık segmentlerden elde edilmiştir ve veri dağılımı 317 adet normal sinüs ritmi ve 292 adet aritmi (76 AFIB, 56 LBBB, 60 RBBB, 26 P, 74 B) şeklindedir. Veriler her iki kısım için %70 eğitim ve %30 test verisi içerecek şekilde ayrılmıştır.

Tez kapsamında ele alınan dört farklı yöntemin en yüksek doğruluk veren model için performans çıktıları doğruluk, PPV, duyarlılık, özgüllük, F1 skor değerleri Şekil 5.5'te verilmiştir.



Şekil 5.5 : Analizlerin performans karşılaştırması

En yüksek sınıflandırma performansı gösteren yöntem %93 doğruluk değerine sahip olan skalogram ve GoogleNet'in kullanıldığı yöntem olmuştur. Bu yöntem ayrıca en yüksek duyarlılık, fl skor ve özgüllük performansı da göstermektedir. En yüksek PPV değeri beş dakikalık sinyallerde gerçekleştirilen KHD analizi ve DVM modeli ile elde edilirken ikinci en yüksek PPV performansı gösteren yöntem skalogram ve GoogleNet olmuştur.

KHD analizi ile elde edilen öznelilikler ve makine öğrenmesi modellerinin kullanıldığı yöntemin performansı iki farklı EKG sinyal uzunluğu için karşılaştırılmıştır. Beş dakikalık sinyallere uygulanan KHD analizi sonucu elde edilen öznelilikler ile en yüksek performans gösteren DVM modeli için %90 doğruluk, %94 PPV, %84 duyarlılık, %97 özgüllük ve %88 fl skor değeri gözlenmiştir. İki dakikalık sinyallere uygulanan KHD analizi ile en yüksek performans gösteren Ensemble modeli için %88 doğruluk, %90 PPV, %83 duyarlılık, %97 özgüllük ve %86 fl skor değeri gözlenmiştir (Şekil 5.5).

Beş dakikalık sinyallerden elde edilen KHD metriklerinin sınıflandırma performansına etkisi ile iki dakikalık sinyallerden elde edilen KHD metriklerinin sınıflandırma performansına etkisi yakındır. Fakat iki dakikalık sinyallerle yapılan çalışmanın

performansının beş dakikalık sinyallere göre daha düşük olmasının nedeni sinyal uzunlukları kısaltıldıkça diğer bir ifade ile RR aralığı sayısı azaldıkça KHD analizi sonucu elde edilen parametrelerin doğruluğu etkilenmektedir. Beş dakikalık sinyallerin kullanıldığı yöntemdeki performansın daha yüksek olmasının nedeni uzun sinyallerden elde edilen KHD analizi parametrelerinin daha doğru değerler olması olabilir.

Skalogram görüntüleri ile eğitilen evrimsel sinir ağı ve spektogram görüntülerinin girdi olarak verildiği evrimsel sinir ağlarının kullanıldığı iki yöntemin performansı karşılaştırılmıştır. Spektogram görüntüleri kullanılarak aritmilerin sınıflandırılmasında en yüksek performans gösteren AlexNet için %92 doğruluk, %92 PPV, %91 duyarlılık, %98 özgüllük ve %92 f1 skor değeri gözlenmiştir. Skalogram görüntüleri ile aritmilerin sınıflandırılmasında en yüksek performans gösteren GoogleNet için %93 doğruluk, %93 PPV, %92 duyarlılık, %98 özgüllük ve %92 f1 skor değeri gözlenmiştir (Şekil 5.5). EKG sinyallerinin zaman frekans analizinin gerçekleştirilmesinde kullanılan kısa süreli fourier dönüşümü ve sürekli dalgacık dönüşümü ile elde edilen spektogram ve skalogram görüntüleri aritmi sınıflandırılması için evrimsel sinir ağlarının eğitilmesinde kullanılan yüksek performans gösteren girdilerden olmuştur. Spektogram görüntülerinin elde edilmesinde hanning penceresi en yüksek performansı verirken skalogram görüntülerinin elde edilmesinde kullanılan bump dalgacık fonksiyonu en yüksek sınıflandırma performansı göstermiştir. Skalogram görüntüleri literatür ile paralel olarak spektogram görüntülerinden daha yüksek performans göstermiştir. Bunun nedeni skalogram görsellerinde EKG sinyalindeki ani değişikliklerin daha yüksek çözünürlükte görülebildiği ve spektogramdaki sabit pencere uzunluğunun sinyaldeki yüksek ve düşük frekans bileşenlerinin tespitinde kısıtlayıcı olması olabilir.

Tez kapsamında sınıflandırılan altı ritim türünün ayrı ayrı sınıflandırma performansı sınıflandırıcıya ve elde edildiği EKG sinyalinin süresine göre değişiklik göstermektedir. Farklı aritmi türleri için analizlerin karşılaştırılması sonucu AFIB için skalogram ve sinir ağlarının kullanılması dört sinir ağına da en yüksek başarı göstermiştir. Bigemini için beş dakikalık KHD analizi ve makine öğrenmesi modelleri ile yapılan sınıflandırma ve spektogram görüntüleri ile sinir ağları ile yapılan sınıflandırma yüksek performans göstermiştir. LBBB için en düşük başarımlar iki

dakikalık KHD analizi ve makine öğrenmesi modelleri ile elde edilirken diğer analizler yaklaşık olarak aynı performansı göstermiştir. Normal ritim için spektrogram ve makine öğrenmesi modelleri en yüksek performans değerini göstermiştir. P atım için skalogram ve sinir ağları en yüksek performans vermiştir. Beş dakikalık KHD analizi ve makine öğrenmesi modelleri ile yapılan çalışmada ise P atım türü düşük performans ile sınıflandırılmıştır. RBBB için beş dakikalık KHD analizi ve makine öğrenmesi modelleri en iyi sınıflandırma performansını göstermiştir. İki dakikalık KHD analizi ve makine öğrenmesi modelleri ile yapılan çalışmada ise en düşük sınıflandırma performansı gösteren aritmi türü RBBB olmuştur. Skalogram ve spektrogram görselleri ile evrişimsel sinir ağları RBBB sınıflandırmasında çok yüksek performans göstermemiştir.

Spektrogram çıktılarının sinir ağları ile sınıflandırılmasında en düşük eğitim ve test süresi SqueezeNet ile elde edilmiştir. Skalogram çıktılarında ise bu model eğitimde SqueezeNet olurken test için AlexNet olmuştur.

Sonuçlar literatürle paralellik göstermiştir ve skalogram görüntülerinin sinir ağları ile sınıflandırmasındaki performansı spektrogram görüntülerine göre daha yüksek performans değerleri elde edilmiştir.

Skalogram ve spektrogram tabanlı sınıflandırma çalışmalarında genellikle her bir kalp atımının sınıflandırılma için kullanılması sonucu kullanılan verinin büyüklüğü EKG sinyallerindeki atım sayısına bağlı olarak artmaktadır. Derin öğrenmede veri sayısının fazla olması nedeniyle sınıflandırma performansının da pozitif yönde etkilenmesi beklenen sonuçlardandır. Literatürde aynı veri seti ile yapılan çalışmalardan Acharya ve arkadaşlarının çalışmasında elde edilen sonuçlar tezde bahsedilen sonuçlara yakındır. Çalışmada modellerin eğitilmesinde veri sayısı daha fazladır fakat yaklaşık değerler elde edilmiştir [58]. Shu Lih ve arkadaşlarının çalışmasında hibrit model kullanılması başarıyı arttırmış olabilir [60]. Tabassum ve Sunwoong'un yaptığı çalışmada 10 saniyelik EKG sinyallerinin spektrogramına dayalı sınıflandırma gerçekleştirmişlerdir ve tez kapsamındaki çalışmadan düşük performans değerine sahiptir [75]. Tezde bahsedilen skalogram tabanlı sinir ağları ile gerçekleştirilen sınıflandırma diğer çalışmalarda her bir atımın bulunması adımını içermemektedir. Bu nedenle R tepe değerlerinin belirlendiği sinyal ön işleme aşamasına gerek duyulmamaktadır. Belirli ölçüde uzun sinyal parçalarında gerçekleştirilen

sınıflandırma farklı uzunluklarda olabilecek atımlardan, yanlış belirlenen atımlardan, gürültülü ya da sınıflandırılmayan atımların varlığından daha az etkilenmektedir. Gürültüden arındırılmış iki dakikalık sinyallerde gerçekleştirilen bu sınıflandırma daha az sinyal ön işleme ve zaman ile yüksek sınıflandırma performansı sağlamaktadır.

Literatürdeki EKG sinyallerinden benzer veri tabanı ile aritmilerin sınıflandırılması amacıyla gerçekleştirilen benzer çalışmaların bulguları ve bu tez çalışmasında en yüksek performans gösteren skalogram çıktıları ile GoogleNet modelinden elde edilen sonuçların 5 kez tekrarının ortalaması ile karşılaştırması Çizelge 5.5'te verilmiştir.



Çizelge 5.5 : MIT-BIH Aritmi Veri tabanı için aritmi sınıflandırılması benzer çalışmaların karşılaştırmaları.

Referans No	Kullanılan Veri Seti	Sinyal Uzunluğu	Aritmi Türleri	Yöntem	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	PPV (%)	F1 Skor (%)
[56]	MIT-BIH Aritmi Veri tabanı	0,6 saniye	Belirtilmemiş	CapsNet	96,1	96,7	-	97,6	96,3
[57]	MIT-BIH Aritmi Veri tabanı	0,225 saniye	N, LBBB, RBBB, Atriyal Prematür Atım, Ventriküler Prematür Atım	CNN	99,65	98,87	99,85	-	-
[58]	MIT-BIH Aritmi Veri tabanı	2 saniye	N, Atriyal Fibrilasyon, Atriyal Flutter, Ventriküler Fibrilasyon	CNN	92,50%	98,09%	93,13%	-	-
[60]	MIT-BIH Aritmi Veri tabanı	3 saniye	N, LBBB, RBBB, Atriyal prematür atım, Ventriküler prematür atım	CNN-LSTM	98,1	97,5	98,7	98,7	-
[75]	MIT-BIH Aritmi Veri tabanı	10 saniye	15 adet aritmi	DenseNet	88,4	88,5	-	87,0	85,7
Tez kapsamındaki çalışma	MIT-BIH Aritmi Veri tabanı	120 saniye	N, RBBB, LBBB, AFIB, P, B	GoogleNet	92,85	92,03	98,06	93,01	92,48

6. SONUÇ VE ÖNERİLER

Kalp atımı sırasında normal olmayan ritimlerin EKG kayıtlarından tespit edilmesi ve tanı konulması tedavi süreci başarısı için önemlidir, bu nedenle bu kayıtların incelenmesi uzman sağlık çalışanları veya yazılım programları tarafından yapılmaktadır. Uzun kayıtların incelenmesi ve aritmilerin türünün, sayısının belirlenmesinin daha kısa sürede ve yüksek doğrulukta gerçekleştirilmesi önem taşımaktadır.

Gelişen makine öğrenmesi uygulamaları ile aritmilerin belirlenmesinde kullanılan yöntemler de gelişmekte ve araştırmacılar tarafından ilgi çekici konu olmaya devam etmektedir.

Bu tez çalışmasında, normal olmayan ritimlerin belirlenmesi amacıyla makine öğrenmesi yöntemleri kullanılmıştır. Çalışma kapsamında normal sinüs ritmi, atriyal fibrilasyon, sol dal bloğu, sağ dal bloğu, ventriküler bigemini ve pacemaker ritimlerin bulunduğu EKG verileri MIT-BIH aritmi veri tabanından alınmıştır. EKG sinyallerine özgü bulunan gürültülerin temizlenmesi için gürültü giderme işlemi uygulanmıştır ve filtrelenmiş sinyal kayıtları iki dakika ve beş dakika olmak üzere segmentlere ayrılmıştır. Bu EKG segmentlerinde R dalgası tepe noktaları bulunmuştur. Bulunan R tepe değerleri ile KHD analizi uygulanmış ve iki sinyal uzunluğu için de öznitelik çıkartma işlemi gerçekleştirilmiştir. KHD tabanlı öznitelikler literatürde yaygın kullanılan dört farklı makine öğrenmesi modeline girdi olarak verilmiştir. İki dakikalık ve beş dakikalık EKG sinyal uzunluğu için modellerin performansı karşılaştırılmıştır. KHD analizi ve makine öğrenmesi modellerinin kullanıldığı aritmi sınıflandırma çalışmasında en başarılı performans beş dakikalık sinyallere uygulanan KHD analizi öznitelikleri ile eğitilen DVM ile elde edilmiştir.

Bir diğer yöntem olarak öznitelik çıkartma adımına gerek duymadan ve sinyal ön işleme sürecini kısaltan evrimsel sinir ağları ile aritmi sınıflandırılması gerçekleştirilmiştir. Evrimsel sinir ağlarına girdi olarak iki dakikalık sinyallerden elde edilen skalogram ve spektogram görselleri verilmiştir. ESA mimarileri ile aritmi

sınıflandırılmasında skalogram görüntülerinin ve spektogram görüntülerinin performansı karşılaştırılmıştır. Bu karşılaştırmaya ek olarak KHD analizi ve makine öğrenmesi modelleri ile gerçekleştirilen çalışmanın çıktıları da spektogram, skalogram görüntüleri ve ESA mimarileri ile gerçekleştirilen çalışma performansları ile karşılaştırılmıştır. En başarılı performans skalogram görüntüleri ile eğitilen GoogleNet mimarisi ile elde edilmiştir. Normal sinüs ritim ve aritmi türleri için en iyi ve en kötü performans gösteren yöntem ve sınıflandırıcılar da karşılaştırılmıştır.

Tez çalışmasında en başarılı bulunan model, literatürdeki benzer çalışmalar ile karşılaştırılmış ve her bir atımın değil belirli bir sürede alınan EKG sinyalinin değerlendirildiği çalışmada daha çok veri sayısı kullanılan yöntemlere göre yüksek performans elde edilmiştir.

Skalogram ve GoogleNet mimarisinin kullanıldığı sınıflandırma modelinin yüksek performans göstermesi ilerleyen çalışmalarda tez ön çalışmasında olduğu gibi ikinci bir veri setinden alınan EKG sinyalleri ile model performansı genişletilerek, farklı sınıflandırma modelleri denenerek geliştirilecektir. Tek kanal EKG sinyallerinin kullanıldığı tez çalışması birden fazla kanaldan alınan sinyallerin kullanılması ile geliştirilecektir.

Aritmilerin belirlenmesi ve sınıflandırılması amacıyla bu çalışmada karşılaştırılan yöntem ve sınıflandırıcıların geliştirilerek ventriküler fibrilasyon, ventriküler taşikardi, atriyal flutter, Wolff-Parkinson-White sendromu gibi daha fazla aritmi türünün belirlenmesinde de çalışılması planlanmaktadır.

KAYNAKLAR

- [1] **Strauss, David G., and Douglas Schocken.** Marriott's Practical Electrocardiography, Wolters Kluwer Health, 2021. ProQuest Ebook Central, <https://ezproxy.etu.edu.tr:2724/lib/tobb-ebooks/detail.action?docID=6882211>.
- [2] **Lip, Gregory YH, et al.** "European heart rhythm association/heart failure association joint consensus document on arrhythmias in heart failure, endorsed by the Heart rhythm society and the Asia Pacific heart rhythm society." *Ep Europace* 18.1 (2016): 12-36.
- [3] **Ambrosy, Andrew P., et al.** "The global health and economic burden of hospitalizations for heart failure: lessons learned from hospitalized heart failure registries." *Journal of the American College of Cardiology* 63.12 (2014): 1123-1133.
- [4] **Tang, Pok Tin, Mohammad Shenasa, and Noel G. Boyle.** "Ventricular arrhythmias and sudden cardiac death." *Cardiac electrophysiology clinics* 9.4 (2017): 693-708.
- [5] **Eroğul, O., and İ. Karagöz.** "Biyolojik sinyaller ve tıbbi cihazlar." Ankara Üniversitesi Basımevi 229 (2003).
- [6] **Sörnmo, Leif, and Pablo Laguna.** Bioelectrical signal processing in cardiac and neurological applications. Vol. 8. Academic press, 2005.
- [7] **J. Malmivuo and R. Plonsey.** Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields. Oxford University Press (Web Edition), 1995.
- [8] **Goldberger, Ary.** Goldberger's clinical electrocardiography. Philadelphia: Elsevier, 2018.
- [9] **Lemay, Mathieu.** Data processing techniques for the characterization of atrial fibrillation. Diss. Université Laval, Canada, 2007.
- [10] **Clifford, Gari D., and Francisco Azuaje.** Advanced methods and tools for ECG data analysis. Ed. Patrick McSharry. Vol. 10. Boston: Artech house, 2006.
- [11] **Gospodinov, Mitko, Evgeniya Gospodinova, and Galya Georgieva-Tsaneva.** "Mathematical methods of ECG data analysis." *Healthcare data analytics and management*. Academic Press, 2019. 177-209.
- [12] **Electrophysiology, Task Force of the European Society of Cardiology the North American Society of Pacing.** "Heart rate variability: standards of measurement, physiological interpretation, and clinical use." *Circulation* 93.5 (1996): 1043-1065.
- [13] **Shaffer, Fred, and Jay P. Ginsberg.** "An overview of heart rate variability metrics and norms." *Frontiers in public health* 5 (2017): 290215.

- [14] **Mergu, Rohini R., and Shantanu K. Dixit.** "A new paradigm for plotting spectrogram." *Journal of Information Systems and Communication* 3.1 (2012): 158.
- [15] **Vidyasagar, KE Ch, et al.** "Signal to Image Conversion and Convolutional Neural Networks for Physiological Signal Processing: A Review." *IEEE Access* (2024).
- [16] **Huang, Jingshan, et al.** "ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network." *IEEE access* 7 (2019): 92871-92880.
- [17] **Tereshchenko, Larisa G., and Mark E. Josephson.** "Frequency content and characteristics of ventricular conduction." *Journal of electrocardiology* 48.6 (2015): 933-937.
- [18] **Shukla, Rahul, et al.** "Epileptic seizure detection using continuous wavelet transform and deep neural networks." *Sensing Technology: Proceedings of ICST 2022*. Cham: Springer International Publishing, 2022. 291-300.
- [19] **Türk, Ömer.** EEG işaretlerinden epilepsi türlerinin sınıflandırılmasında skalogram tabanlı derin öğrenme yaklaşımı (Scalogram based deep learning approach for classification of epilepsy types from EEG signals). Diss. Dicle University, Turkey, 2019.
- [20] **Chakraborty, Sanjay, Sk Hafizul Islam, and Debabrata Samanta.** *Data classification and incremental clustering in data mining and machine learning*. Berlin/Heidelberg, Germany: Springer, 2022.
- [21] **Kubat, Miroslav.** *An introduction to machine learning*. Springer, Cham, 2017.
- [22] **Tan, Pang-Ning, Michael Steinbach, and Vipin Kumar.** "Classification: basic concepts, decision trees, and model evaluation." *Introduction to data mining* 1 (2006): 145-205.
- [23] **Rafatirad, Setareh, et al.** "Machine learning for computer scientists and data analysts." (2022).
- [24] **Lee, Wei-Meng.** *Python machine learning*. John Wiley & Sons, 2019.
- [25] **Nayak, Swathi, et al.** "Study of distance metrics on k-nearest neighbor algorithm for star categorization." *Journal of Physics: Conference Series*. Vol. 2161. No. 1. IOP Publishing, 2022
- [26] **Sarkar, Dipayan, and Vijayalakshmi Natarajan.** *Ensemble Machine Learning Cookbook: Over 35 practical recipes to explore ensemble machine learning techniques using Python*. Packt Publishing Ltd, 2019.
- [27] **Zhou, Zhi-Hua.** *Ensemble methods: foundations and algorithms*. CRC press, 2012.
- [28] **Khan, Azal Ahmad, Omkar Chaudhari, and Rohitash Chandra.** "A review of ensemble learning and data augmentation models for class imbalanced problems: combination, implementation and evaluation." *Expert Systems with Applications* (2023): 122778.

- [29] **Ganaie, Mudasir A., et al.** "Ensemble deep learning: A review." Engineering Applications of Artificial Intelligence 115 (2022): 105151.
- [30] **Wang, Fei, et al.** "Feature learning viewpoint of AdaBoost and a new algorithm." IEEE Access 7 (2019): 149890-149899.
- [31] **Tufféry, S.** "Deep learning: From big data to artificial intelligence with r." (2022)
- [32] **Campesato, Oswald.** Artificial intelligence, machine learning, and deep learning. Mercury Learning and Information, 2020.
- [33] **Wong, Kelvin KL.** Cybernetical intelligence: Engineering cybernetics with machine intelligence. John Wiley & Sons, 2023

- [34] **Rivas, Pablo.** Deep Learning for Beginners: A beginner's guide to getting up and running with deep learning from scratch using Python. Packt Publishing Ltd, 2020.
- [35] **Matinyan, Senik, Pavel Filipcik, and Jan Pieter Abrahams.** "Deep learning applications in protein crystallography." Acta Crystallographica Section A: Foundations and Advances 80.1 (2024).
- [36] **Beale, Mark Hudson, Martin T. Hagan, and Howard B. Demuth.** "Deep learning toolbox." R2018b User's Guide; The MathWorks, Inc.: Natick, MA, USA (2018).
- [37] **Bengio, Yoshua, Ian Goodfellow, and Aaron Courville.** Deep learning. Vol. 1. Cambridge, MA, USA: MIT press, 2017
- [38] **Teoh, Teik Toe.** Convolutional neural networks for medical applications. Springer, 2023.
- [39] **İnik, Özkan, and Erkan Ülker.** "Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri." Gaziosmanpaşa Bilimsel Araştırma Dergisi 6.3 (2017): 85-104.
- [40] **Sewak, Mohit, Md Rezaul Karim, and Pradeep Pujari.** Practical convolutional neural networks: implement advanced deep learning models using Python. Packt Publishing Ltd, 2018.
- [41] **Szegedy, Christian, et al.** "Going deeper with convolutions." Proceedings of the IEEE conference on computer vision and pattern recognition. 2015.
- [42] **Xiao, Perry.** Artificial intelligence programming with Python: from zero to hero. John Wiley & Sons, 2022
- [43] **Alzubaidi, Laith, et al.** "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions." Journal of big Data 8 (2021): 1-74.
- [44] **He, Kaiming, et al.** "Deep residual learning for image recognition." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
- [45] **Ali, Luqman, et al.** "Performance evaluation of deep CNN-based crack detection and localization techniques for concrete structures." Sensors 21.5 (2021): 1688.

- [46] **Iandola, Forrest N.** "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size." arXiv preprint arXiv:1602.07360 (2016).
- [47] **Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton.** "Imagenet classification with deep convolutional neural networks." Advances in neural information processing systems 25 (2012).
- [48] **Sahoo, Santanu, et al.** "Multiresolution wavelet transform based feature extraction and ECG classification to detect cardiac abnormalities." Measurement 108 (2017): 55-66.
- [49] **Yeh, Yun-Chi, Wen-June Wang, and Che Wun Chiou.** "Cardiac arrhythmia diagnosis method using linear discriminant analysis on ECG signals." Measurement 42.5 (2009): 778-789.
- [50] **Kim, Yoon Jae, et al.** "Proposition of novel classification approach and features for improved real-time arrhythmia monitoring." Computers in biology and medicine 75 (2016): 190-202.
- [51] **Udawat, Abhimanyu Singh, and Pushpendra Singh.** "An automated detection of atrial fibrillation from single lead ECG using HRV features and machine learning." Journal of Electrocardiology 75 (2022): 70-81.
- [52] **Narin, Ali, et al.** "Early prediction of paroxysmal atrial fibrillation based on short-term heart rate variability." Physica A: Statistical Mechanics and its Applications 509 (2018): 56-65.
- [53] **Tsipouras, Markos G., and Dimitrios I. Fotiadis.** "Automatic arrhythmia detection based on time and time–frequency analysis of heart rate variability." Computer methods and programs in biomedicine 74.2 (2004): 95-108.
- [54] **Sivanantham, A., and S. Shenbaga Devi.** "Cardiac arrhythmia detection using linear and non-linear features of HRV signal." 2014 IEEE International Conference on Advanced Communications, Control and Computing Technologies. IEEE, 2014.
- [55] **Mateo, Carlos, and Juan Antonio Talavera.** "Analysis of atrial and ventricular premature contractions using the short time fourier transform with the window size fixed in the frequency domain." Biomedical Signal Processing and Control 69 (2021): 102835.
- [56] **El Boujnoui, Imane, et al.** "A wavelet-based capsule neural network for ECG biometric identification." Biomedical Signal Processing and Control 76 (2022): 103692.
- [57] **Mohonta, Shadhon Chandra, Mohammad Abdul Motin, and Dinesh Kant Kumar.** "Electrocardiogram based arrhythmia classification using wavelet transform with deep learning model." Sensing and Bio-Sensing Research 37 (2022): 100502.
- [58] **Acharya, U. Rajendra, et al.** "Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network." Information sciences 405 (2017): 81-90.

- [59] **Furqon, Muhammad, et al.** "Arrhythmia Classification Using EFFICIENTNET-V2 with 2-D Scalogram Image Representation." 2021 TRON Symposium (TRONSHOW). IEEE, 2021.
- [60] **Oh, Shu Lih, et al.** "Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats." *Computers in biology and medicine* 102 (2018): 278-287.
- [61] **Madan, Parul, et al.** "A hybrid deep learning approach for ECG-based arrhythmia classification." *Bioengineering* 9.4 (2022): 152.
- [62] **Pokaprakarn, Teeranan, et al.** "Sequence to sequence ECG cardiac rhythm classification using convolutional recurrent neural networks." *IEEE journal of biomedical and health informatics* 26.2 (2021): 572-580.
- [63] **Olanrewaju, Rashidah Funke, et al.** "Classification of ECG signals for detection of arrhythmia and congestive heart failure based on continuous wavelet transform and deep neural networks." *Indones J Electr Eng Comput Sci* 22.3 (2021): 1520-1528.
- [64] **Chandrasekaran, Saravanakumar, Srinivasan Chandran, and Immaculate Joy Selvam.** "FPGA-Based Implementation of Real-Time Cardiologist-Level Arrhythmia Detection and Classification in Electrocardiograms Using Novel Deep Learning." *International Journal of Circuit Theory and Applications* (2024).
- [65] **Wang, Tao, et al.** "Automatic ECG classification using continuous wavelet transform and convolutional neural network." *Entropy* 23.1 (2021): 119.
- [66] **Wu, Mengze, et al.** "A study on arrhythmia via ECG signal classification using the convolutional neural network." *Frontiers in computational neuroscience* 14 (2021): 564015.
- [67] **Song, Min-Seo, and Seung-Bo Lee.** "Comparative study of time-frequency transformation methods for ECG signal classification." *Frontiers in Signal Processing* 4 (2024): 1322334.
- [68] **Aarotale, Parshuram N., and Ajita Rattani.** "Deep Learning Models for Arrhythmia Classification Using Stacked Time-frequency Scalogram Images from ECG Signals." *2023 Computing in Cardiology (CinC)*. Vol. 50. IEEE, 2023.
- [69] **Lai, Dakun, et al.** "Intelligent and efficient detection of life-threatening ventricular arrhythmias in short segments of surface ECG signals." *IEEE Sensors Journal* 21.13 (2020): 14110-14120.
- [70] **Ozaltin, Oznur, and Ozgur Yeniay.** "A novel proposed CNN–SVM architecture for ECG scalograms classification." *Soft Computing* 27.8 (2023): 4639-4658.
- [71] **Toma, Tabassum Islam, and Sunwoong Choi.** "A parallel cross convolutional recurrent neural network for automatic imbalanced ECG arrhythmia detection with continuous wavelet transform." *Sensors* 22.19 (2022): 7396.

- [72] **Kim, Do Hoon, Gwangjin Lee, and Seong Han Kim.** "An ECG stitching scheme for driver arrhythmia classification based on deep learning." *Sensors* 23.6 (2023): 3257.
- [73] **Holanda, Rafael, Rodrigo Monteiro, and Carmelo Bastos-Filho.** "Preprocessing selection for deep learning classification of arrhythmia using ecg time-frequency representations." *Technologies* 11.3 (2023): 68.
- [74] **Abdeldayem, Sara S., and Thirimachos Bourlai.** "Automatically detecting arrhythmia-related irregular patterns using the temporal and spectro-temporal textures of ECG signals." 2018 24th International Conference on Pattern Recognition (ICPR). IEEE, 2018.
- [75] **Toma, Tabassum Islam, and Sunwoong Choi.** "A comparative analysis of 2D deep CNN models for arrhythmia detection using STFT-based long duration ECG spectrogram." 2022 Thirteenth International Conference on Ubiquitous and Future Networks (ICUFN). IEEE, 2022.
- [76] **Alqudah, Ali Mohammad, et al.** "ECG heartbeat arrhythmias classification: A comparison study between different types of spectrum representation and convolutional neural networks architectures." *Journal of Ambient Intelligence and Humanized Computing* (2022): 1-31.
- [77] **Tseng, Li-Ming, and Vincent S. Tseng.** "Predicting ventricular fibrillation through deep learning." *IEEE Access* 8 (2020): 221886-221896.
- [78] **Moody GB, Mark RG.** The impact of the MIT-BIH Arrhythmia Database. *IEEE Eng in Med and Biol* 20(3):45-50 (May-June 2001). (PMID: 11446209)
- [79] **Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., ... & Stanley, H. E. (2000).** PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation* [Online]. 101 (23), pp. e215–e220.
- [80] **Ünlü, Büşra, and Osman Eroğul.** "Detection of Premature Ventricular Contractions Using Machine Learning." 2023 Medical Technologies Congress (TIPTEKNO). IEEE, 2023
- [81] **Babayiğit, Erdi, Taner Ulus, and Bülent Görennek.** "Important tips reflected in our daily practice from the American College of Cardiology Electrophysiology Council report on premature ventricular contractions." *Anatolian Journal of Cardiology/Anadolu Kardiyoloji Dergisi* 23.4 (2020)
- [82] **Goldberger, Ary L., et al.** "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals." *circulation* 101.23 (2000): e215-e220.
- [83] **Yeh, Yun-Chi, and Wen-June Wang.** "QRS complexes detection for ECG signal: The Difference Operation Method." *Computer methods and programs in biomedicine* 91.3 (2008): 245-254.
- [84] **Sahay, Shalini, and A. K. Wadhwani.** "Computer-Aided Interpretation of ECG Signal—A Challenge." *Medical Imaging and Health Informatics* (2022): 335-358.

- [85] **Yakut, Önder, Serdar Solak, and Emine Doğru Bolat.** "EKG işaretindeki gürültülerin temizlenmesi için IIR tabanlı sayısal filtre tasarımı." *Politeknik Dergisi* 21.1 (2018): 173-181.
- [86] **Goy, Jean-Jacques, et al.** *Electrocardiography (ECG)*. Vol. 1. Bentham Science Publishers, 2013.
- [87] **Pan, Jiapu, and Willis J. Tompkins.** "A real-time QRS detection algorithm." *IEEE transactions on biomedical engineering* 3 (1985): 230-236.
- [88] **Shaffer, Fred, and Jay P. Ginsberg.** "An overview of heart rate variability metrics and norms." *Frontiers in public health* 5 (2017): 258.
- [89] **Pereira, Tania, et al.** "Heart rate variability metrics for fine-grained stress level assessment." *Computer methods and programs in biomedicine* 148 (2017): 71-80.
- [90] **Srivastav, Shival, et al.** "Exploring Ultra-short Heart Rate Variability Metrics in Patients with Diabetes Mellitus: A Reliability Analysis." *International Journal of Applied and Basic Medical Research* 14.3 (2024): 169-173.
- [91] **Wu, Liang, et al.** "An optimization study of the ultra-short period for HRV analysis at rest and post-exercise." *Journal of Electrocardiology* 63 (2020): 57-63.
- [92] **Munoz, M. Loretto, et al.** "Validity of (ultra-) short recordings for heart rate variability measurements." *PloS one* 10.9 (2015): e0138921.
- [93] **Özseven, Turgut.** "Comparative Performance Analysis of Time-Frequency Domain Images and Raw Signal Data for Classification of ECG Signals." *Düzce Üniversitesi Bilim ve Teknoloji Dergisi* 12.2 (2024): 745-761.
- [94] **ŞEN, Sena Yağmur, and Nalan Özkurt.** "ECG arrhythmia classification by using convolutional neural network and spectrogram." 2019 *Innovations in Intelligent Systems and Applications Conference (ASYU)*. IEEE, 2019.
- [95] **Lee, Gregory, et al.** "PyWavelets: A Python package for wavelet analysis." *Journal of Open Source Software* 4.36 (2019): 1237.
- [96] **Mao, Shujuan, et al.** "On the measurement of seismic traveltime changes in the time–frequency domain with wavelet cross-spectrum analysis." *Geophysical Journal International* 221.1 (2020): 550-568.
- [97] **Misiti, Michel, et al.** "Wavelet Toolbox™ Getting Started Guide." The Mathworks (1997).
- [98] **Makowski, Dominique, et al.** "NeuroKit2: A Python toolbox for neurophysiological signal processing." *Behavior research methods* (2021): 1-8.
- Url-1**<<https://ufhealth.org/conditions-and-treatments/transposition-of-the-great-arteries>>, alındığı tarih: 27.11.2024.
- Url-2**<<https://neuropsychology.github.io/NeuroKit/functions/hrv.html>>, alındığı tarih: 29.11.2024
- Url-3** <<https://www.kubios.com/hrv-analysis-methods/>>, alındığı tarih: 06.03.2024.