



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

DOKTORA TEZİ

**HİBRİT ÖZNİTELİK ÇIKARIMI VE DERİN ÖĞRENME
YÖNTEMLERİYLE EKG SİNYALLERİNDEN KARDİYAK
DURUMLARIN SINIFLANDIRILMASI**

Hazret TEKİN

**Aralık-2024
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

DOKTORA TEZİ

**HİBRİT ÖZNİTELİK ÇIKARIMI VE DERİN ÖĞRENME
YÖNTEMLERİYLE EKG SİNYALLERİNDEN KARDİYAK
DURUMLARIN SINIFLANDIRILMASI**

Hazret TEKİN

**Danışman
Doç. Dr. Yılmaz KAYA**

Diğer Jüri Yeleri

Doç. Dr. Melih KUNCAN Prof. Dr. Necmettin SEZGİN Doç. Dr. Recep MİNAZ

Dr. Öğr. Üyesi Davut SEVİM

**Aralık-2024
BATMAN**

TEZ KABUL VE ONAYI

Hazret TEKİN tarafından hazırlanan “Hibrit Öznitelik Çıkarımı ve Derin Öğrenme Yöntemleriyle EKG Sinyallerinden Kardiyak Durumların Sınıflandırılması” adlı tez çalışması 26/12/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Ana Bilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Necmettin SEZGİN

.....

Danışman

Doç. Dr. Yılmaz KAYA

.....

Üye

Doç. Dr. Melih KUNCAN

.....

Üye

Doç. Dr. M.Recep MİNAZ

.....

Üye

Dr. Öğr. Üyesi Davut SEVİM

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

Hazret TEKİN

Tarih:26.12.2024

ÖZET

DOKTORA TEZİ

HİBRİT ÖZNİTELİK ÇIKARIMI VE DERİN ÖĞRENME YÖNTEMLERİYLE EKG SİNYALLERİNDEN KARDİYAK DURUMLARIN SINIFLANDIRILMASI

Hazret TEKİN

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Yılmaz KAYA

2024, 150 Sayfa

Kardiyovasküler hastalıklar, dünya genelinde hem gelişmiş hem de gelişmekte olan ülkelerde başlıca ölüm nedenlerinden biri olarak karşımıza çıkmaktadır. Bu hastalıklar, bireylerin yaşam kalitesini ciddi ölçüde etkilerken, sağlık sistemleri üzerinde de büyük bir ekonomik ve sosyal yük oluşturmaktadır. Erken teşhis ve doğru tanı, yalnızca hastaların yaşam sürelerini uzatmakla kalmaz, aynı zamanda tedavi maliyetlerini azaltarak toplum sağlığına önemli katkılar sağlar. Özellikle aritmiler, konjestif kalp yetmezliği (KKY) ve normal sinüs ritmi (NSR) gibi kardiyak durumların doğru bir şekilde teşhisi, bu süreçte temel bir rol oynamaktadır. Bu çalışma, çeşitli aritmiler, konjestif kalp yetmezliği (KKY) ve normal sinüs ritmi (NSR) gibi kardiyak durumların sınıflandırılmasına odaklanmaktadır. Çalışma kapsamında, çeşitli aritmi türleri, KKY ve NSR sinyallerini içeren iki farklı veri seti kullanılarak üç ayrı EKG sınıflandırma uygulaması gerçekleştirilmiştir. Bu amaçla, yenilikçi sinyal işleme yöntemleri ile derin öğrenme modelleri bir araya getirilmiş ve EKG sinyallerinin lokal ve global özelliklerini analiz etmek için ortogonal fark bir boyutlu yerel ikili desen (OD-1D-LBP), merkezden bağımsız bir boyutlu yerel ikili desen (CI-1D-LBP) ve sürekli zamanlı dalgacık dönüşümü (CWT) tabanlı motif dönüşümü (MD) yöntemleri uygulanmıştır.

Çalışmanın ilk uygulamasında, OD-1D-LBP yöntemiyle KKY, atriyal fibrilasyon (AF) ve NSR sinyalleri sınıflandırılmıştır. Bu yöntemde çıkarılan öznitelikler uzun kısa süreli bellek (LSTM) ve bir boyutlu konvolüsyonel sinir ağları (1D-CNN) modelleriyle değerlendirilmiş ve en iyi sonuç %98.97 doğruluk oranı ile hibrit OD-1D-LBP+LSTM modeliyle elde edilmiştir. OD-1D-LBP+1D-CNN modeli de %98.86 doğruluk oranı ile rekabetçi bir performans sergilemiştir. OD-1D-LBP'nin, sinyallerin lokal özelliklerini belirginleştirme konusundaki başarısı, kardiyak durumların ayırt edilmesinde etkili bir araç olduğunu ortaya koymuştur.

İkinci uygulamada, CI-1D-LBP yöntemi dört farklı aritmi türünün (ventriküler atım, supraventriküler atım, füzyon atımı ve tanımlanmamış aritmi) sınıflandırılmasında kullanılmıştır. Bu yöntemde elde edilen özniteliklerle LSTM, GRU ve 1D-CNN modelleri uygulanmış, CI-1D-LBP+GRU hibrit modeli %98.59 doğruluk oranıyla en iyi sonucu vermiştir. CI-1D-LBP+LSTM hibrit modeli %98.02, CI-1D-LBP+1D-CNN hibrit modeli ise %97.17 doğruluk oranına ulaşmıştır. CI-1D-LBP+GRU'nun farklı aritmi türlerini ayırt etmedeki başarısı, yöntemin güçlü bir analiz çerçevesi sunduğunu göstermektedir.

Üçüncü uygulamada, motif dönüşümü ve CWT yöntemleri birleştirilmiş ve KKY, AF ve NSR sinyalleri zaman-frekans düzleminde analiz edilmiştir. Bu analiz sonucunda oluşturulan skalogram görüntüleri, DenseNet modelleri ile sınıflandırılmıştır. DenseNet169 modeli %99.31 doğruluk oranı ile en başarılı sonuçları sağlamış, DenseNet121 ve DenseNet201 modelleri ise

sırasıyla %98.30 ve %98.97 doğruluk oranlarına ulaşmıştır. Motif dönüşümü ve CWT'nin entegre kullanımı, sinyallerin zaman-frekans analizinde etkili bir yöntem olduğunu kanıtlamıştır.

Elde edilen sonuçlar, bu tez çalışmasında kullanılan yöntemlerin literatürdeki yaklaşımlara kıyasla üstün performans sunduğunu ve kardiyak durumların teşhisinde önemli bir yenilik sağladığını göstermektedir. Bu yöntemlerin, klinik uygulamalara entegre edilerek kardiyovasküler hastalıkların tanısında doğruluk ve güvenilirliği artırma potansiyeline sahip olduğu öngörülmektedir. Ayrıca, farklı modellerin ve veri setlerinin karşılaştırılması, bu yöntemlerin sadece bir sinyal türünde değil, farklı kardiyak durumların analizinde de genelleştirilebilir ve güvenilir bir çerçeve sunduğunu göstermiştir. Önerilen yöntemlerin ayırt edici öznelilikler çıkarma yeteneği ve derin öğrenme modelleriyle sağladığı yüksek doğruluk oranları, kardiyak sinyallerin analizine yönelik yeni standartlar belirleme potansiyeline sahiptir. Bu çalışma, kullanılan tekniklerin klinik uygulamalara entegrasyonu halinde, tanı süreçlerinin doğruluğunu ve hızını artırarak hasta bakım kalitesini iyileştirme kapasitesine sahip olduğunu göstermektedir. Elde edilen bulgular, sadece literatürdeki yaklaşımlara üstünlük sağlamakla kalmayıp, kardiyovasküler hastalıkların teşhisinde daha güvenilir ve etkili çözümler sunmaktadır.

Anahtar Kelimeler: CI-1D-LBP, 1D-CNN, DenseNET, EKG, GRU, LSTM, Motif dönüşümü, OD-1D-LBP.

ABSTRACT
DOCTORAL THESIS
CLASSIFICATION OF CARDIAC CONDITIONS FROM ECG SIGNALS
USING HYBRID FEATURE EXTRACTION AND DEEP LEARNING
METHODS

Hazret TEKİN

Batman University Graduate Education Institute

Department of Electrical and Electronics Engineering

Advisor: Assoc. Prof. Dr. Yılmaz KAYA

2024, 150 Pages

Cardiovascular diseases are among the leading causes of death worldwide, highlighting the critical importance of early diagnosis and accurate detection. This study focuses on the classification of various cardiac conditions, including arrhythmias, congestive heart failure (CHF), and normal sinus rhythm (NSR). Using two distinct datasets containing signals of various arrhythmias, CHF, and NSR, three separate ECG classification applications were performed. To achieve this, innovative signal processing methods were combined with deep learning models, and OD-1D-LBP, CI-1D-LBP, and Continuous Wavelet Transform (CWT)-based Motif Transformation (MT) techniques were applied to analyze the local and global features of ECG signals.

In the first application, OD-1D-LBP was used to classify CHF, atrial fibrillation (AF), and NSR signals. The features extracted using this method were evaluated with LSTM and 1D-CNN models, with the highest accuracy of 98.97% achieved using the LSTM model. The 1D-CNN model also demonstrated competitive performance with an accuracy of 98.86%. The success of OD-1D-LBP in highlighting local features of signals has proven it to be an effective tool for distinguishing cardiac conditions.

In the second application, CI-1D-LBP was employed to classify four types of arrhythmias: ventricular beats, supraventricular beats, fusion beats, and unidentified arrhythmias. Features extracted through this method were analyzed using LSTM, GRU, and 1D-CNN models, with the GRU model achieving the highest accuracy of 98.59%. The LSTM and 1D-CNN models followed with accuracies of 98.02% and 97.17%, respectively. The ability of CI-1D-LBP to differentiate between various arrhythmia types demonstrates its effectiveness as a robust analytical framework.

In the third application, MT and CWT techniques were combined to analyze CHF, AF, and NSR signals in the time-frequency domain. The resulting scalogram images were classified using DenseNet models. The DenseNet169 model achieved the highest accuracy of 99.31%, while DenseNet121 and DenseNet201 models yielded accuracies of 98.30% and 98.97%, respectively. The integrated use of Motif Transformation and CWT has proven to be an effective approach for time-frequency analysis of cardiac signals.

The results demonstrate that the methods used in this thesis outperform those reported in the literature and provide significant advancements in the diagnosis of cardiac conditions. These methods are projected to enhance accuracy and reliability when integrated into clinical applications for the diagnosis of cardiovascular diseases. Furthermore, the comparison of different models and datasets shows that these methods provide a generalizable and reliable framework not

only for a specific signal type but also for the analysis of various cardiac conditions. The high accuracy achieved through the extraction of distinctive features and the application of deep learning models highlights the potential of these techniques to set new standards for cardiac signal analysis. This study suggests that the integration of these methods into clinical settings can improve the accuracy and efficiency of diagnostic processes, thereby enhancing the quality of patient care. The findings of this work not only surpass existing approaches in the literature but also provide more reliable and effective solutions for the diagnosis of cardiovascular diseases.

Keywords: CI-1D-LBP, DenseNET, ECG, GRU, LSTM, Motif Transformation, OD-1D-LBP, 1D-CNN.

ÖNSÖZ

Öncelikle tez çalışmam ve tüm eğitim hayatım boyunca beni destekleyerek bu aşamaya gelmemi sağlayan anneme, babama ve kardeşlerime teşekkürü borç bilirim. Doktora ve tez çalışmam süresince, yoğun programı içinde benim için vakit ayırıp çalışmalarımı ilgilenen, yol gösteren danışman hocam Doç. Dr. Yılmaz KAYA'a teşekkürlerimi sunarım.

Hazret TEKİN
BATMAN-2024

İÇİNDEKİLER

ÖZET	iv
ÖNSÖZ	viii
İÇİNDEKİLER	ix
ÇİZELGELER/TABLolar LİSTESİ	xi
ŞEKİLLER LİSTESİ	xii
SİMGELER VE KISALTMALAR.....	xiv
1. GİRİŞ.....	1
1.1. Tezin Amacı ve Kapsamı	4
1.2. Hedefler ve Literatüre Sağlanan Katkılar	5
1.3. Tezin Organizasyon Yapısı.....	5
2. ELEKTROKARDİYOĞRAFİ (EKG).....	7
2.1. EKG'nin Tarihçesi ve Gelişimi	7
2.2. EKG'nin Fizyolojik Temelleri.....	8
2.3. EKG Verilerinin Toplanması ve Dijitalleştirilmesi	14
2.4. EKG'nin Klinik Sahada Kullanım Alanları.....	18
2.5. Kardiyak Hastalıklar	20
2.5.1. Normal sinüs ritmi (NSR).....	21
2.5.2. Atriyal fibrilasyon (AF)	22
2.5.3. Ventriküler aritmi (VA)	23
2.5.4. Supraventriküler aritmi (SVA)	24
2.5.5. Füzyon aritmisi (FA).....	25
2.5.6. Konjestif kalp yetmezliği (KKY)	26
3. LİTERATÜR.....	28
4. MATERYAL	50
4.1. Veri Seti-1 (VA-SVA-FA-TA-NSR)	51
4.2. Veri Seti-2 (AF-KKY-NSR)	53
5. METODOLOJİ.....	56
5.1. Öznitelik Çıkarım Yaklaşımları	59
5.1.1. Tek boyutlu ortogonal fark yerel ikili desen (1D-OD-LBP).....	61
5.1.2. Merkezden bağımsız bir boyutlu yerel ikili desen (CI-1D-LBP)	67
5.1.3. Motif dönüşüm.....	74
5.1.4. Sürekli zamanlı dalgacık dönüşümü (CWT)	79
5.2. Derin Öğrenme Sınıflandırma Metotları.....	81
5.2.1. Uzun kısa süreli bellek (LSTM)	82
5.2.2. Bir boyutlu konvolüsyonel sinir ağları (1D-CNN)	85
5.2.3. Kapılı tekrarlayan hücre (GRU)	88

5.2.4. DenseNet transfer öğrenme metotları	90
5.3. Önerilen Yaklaşımlar	94
5.3.1. Ortogonal fark 1D-LBP + {LSTM, 1D-CNN} yaklaşımı	96
5.3.2. Merkez bağımsız 1D-LBP + {1D-CNN, LSTM, GRU} yaklaşımı	99
5.3.3. MD+CWT +DenseNet yaklaşımı	103
5.4. Performans Ölçütleri.....	106
6. UYGULAMA SONUÇLARI VE PERFORMANS DEĞERLENDİRMESİ.....	108
6.1. OD-1D-LBP+{LSTM,1D-CNN} Yönteminin Sonuç ve Bulguları.....	109
6.2. CI-1D-LBP+{LSTM,1D-CNN,GRU} Yönteminin Sonuç ve Bulguları.....	115
6.3. Motif + CWT + DenseNet Yönteminin Sonuç ve Bulguları	123
7. SONUÇLAR VE ÖNERİLER	133
7.1 Sonuçlar	133
7.2 Öneriler	134
KAYNAKLAR.....	137

ÇİZELGELER/TABLolar LİSTESİ

Tablo 4.1. Veri seti-2 (AF-KKY-NSR)) ait bilgiler.....	53
Tablo 5.1. CI-1D-LBP yönteminin uygulanması ile oluşan 8 bitlik örüntü tablosu.....	70
Tablo 6.1. LSTM ve 1D-CNN modellerine ait hiperparametre değerleri.....	109
Tablo 6.2. OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN metotlarının sınıflandırma başarı oranları.....	110
Tablo 6.3. OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN ile ikili sınıflandırma başarı sonuçları.....	113
Tablo 6.4. Farklı uzunluktaki EKG sinyalleri için başarı oranları.....	113
Tablo 6.5. OD-1D-LBP+{LSTM,1D-CNN}modellerinin literatürdeki çalışmalarla karşılaştırılması.....	115
Tablo 6.6. LSTM, 1D-CNN ve GRU modellerinin hiper parametre değerleri.....	116
Tablo 6.7. CI-1D-LBP+LSTM, CI-1D-LBP+1D-CNN ve CI-1D-LBP+GRU metotlarının sınıflandırma başarı oranları.....	118
Tablo 6.8. Farklı veri seti kombinasyonları için sınıflandırma doğruluk oranları.....	121
Tablo 6.9. Farklı sinyal uzunluklarına göre başarı oranları (%).....	122
Tablo 6.10. CI-1D-LBP+GRU modellerinin literatür karşılaştırılması.....	123
Tablo 6.11. MDWS=7 olması durumunda DenseNET ile elde edilen başarı oranları (%).....	125
Tablo 6.12. WS'nin farklı değerleri için başarı oranları (%).....	126
Tablo 6.13. DenseNET, CWT+DenseNET ve MD+CWT+DenseNET yöntemlerinin başarı oranlarının karşılaştırılması (%).....	130
Tablo 6.14. İki etiketli veri setlerinin sınıflandırılmasında başarı oranları (%).....	131
Tablo 6.15. MD+CWT+DenseNET modellerinin literatürdeki çalışmalarla karşılaştırılması.....	132

ŞEKİLLER LİSTESİ

Şekil 2.1. Aksiyon potansiyeli faz evreleri.....	11
Şekil 2.2. Kalp boyunca aksiyon potansiyeli eğrilerinin yayılımı.....	11
Şekil 2.3. Örnek bir EKG parçası.....	13
Şekil 2.4. Tipik bir Elektrokardiyografi cihazının blok şeması.....	16
Şekil 2.5. NSR ait örnek sinyal.....	21
Şekil 2.6. Atriyal fibrilasyon (AF)'li bir bireye ait örnek EKG sinyali.....	23
Şekil 2.7. Ventriküler aritmi (VA) hastası bir bireye ait örnek EKG sinyali.....	24
Şekil 2.8. Supraventriküler aritmi (SVA) hastası bir bireye ait örnek EKG sinyali.....	25
Şekil 2.9. Füzyon aritmi (FA) hastası bir bireye ait örnek EKG sinyali.....	26
Şekil 2.10. KKY hastası bir bireye ait örnek EKG sinyali.....	27
Şekil 4.1. Farklı EKG sinyal örnekleri.....	53
Şekil 4.2. NSR, KKY ve AF sinyallerine ait grafikler.....	55
Şekil 5.1. EKG sinyallerinden öznitelik çıkarma ve sınıflandırma aşamaları.....	59
Şekil 5.2. OD-1D-LBP yönteminin örnek bir sinyale uygulanması.....	62
Şekil 5.3. OD-1D-LBP ortogonal pozisyonlar.....	63
Şekil 5.4. OD-1D-LBP kodların hesaplanması.....	65
Şekil 5.5. OD-1D-LBP çıktısı. (a) Örnek sinyal parçası, (b-d) 1D-OD-LBP çıktı sinyalleri.....	67
Şekil 5.6. CI-1D-LBP yaklaşımın örnek EKG sinyal parçasına uygulanması.....	68
Şekil 5.7. CI-1D-LBP metodunda olası Pc değerleri ve komşu noktalar.....	70
Şekil 5.8. CI-1D-LBP yöntemin örnek sinyale uygulanması (a) örnek EKG sinyali, (b) üretilen sinyaller.....	72
Şekil 5.9. CI-1D-LBP ile üretilen yeni sinyallere ait histogramlar.....	73
Şekil 5.10. MD dönüşüm uygulanmış örnek veri.....	75
Şekil 5.11. Şekil 5.12'deki EKG örnek verisine ait motifler.....	76
Şekil 5.12. WS=4 olması durumunda oluşan 24 adet motif yapısı.....	77
Şekil 5.13. WS farklı değerleri göre oluşan motif histogramlar. (A) orijinal sinyal, (B) WS=4 için motif histogram, (C) WS=5 için motif histogram, (D) WS=6 için motif histogram.....	78
Şekil 5.14. LSTM bloklarının ve bellek hücresi birimlerinin gösterimi.....	83
Şekil 5.15. 1D-CNN ağına dair blok şema yapısı.....	86
Şekil 5.16. GRU blok ve hücre yapıları.....	89
Şekil 5.17. DenseNET blok diyagramı.....	92
Şekil 5.18. Önerilen metodun akış diyagramı.....	96
Şekil 5.19. OD-1D-LBP çıktısı. (A) Örnek sinyal parçası, (B-D) 1D-OD-LBP çıktı sinyalleri.....	97
Şekil 5.20. Önerilen aritmi sınıflandırma sisteminin akış diyagramı.....	99
Şekil 5.21. CI-1D-LBP yöntemin örnek sinyale uygulanması. (A) örnek EKG sinyali, (B) üretilen sinyaller.....	100
Şekil 5.22. CI-1D-LBP ile üretilen yeni sinyallere ait histogramlar.....	101
Şekil 5.23. Motif+CWT +DenseNet sistem diyagramı.....	103
Şekil 6.1. Eğitim ve test setleri için LSTM modeli ile elde edilen karışıklık matrisleri.....	111
Şekil 6.2. Eğitim ve test setleri için 1D-CNN modeli ile elde edilen karışıklık matrisleri.....	112
Şekil 6.3. LSTM ve 1D-CNN modellerinin eğitim sürecinde doğruluk (Accuracy) ve kayıp (Loss) eğrileri.....	112

Şekil 6.4. Eğitim ve test setleri için 1D-CNN modeli ile elde edilen karışıklık matrisleri.....	120
Şekil 6.5. Eğitim ve test setleri için LSTM modeli ile elde edilen karışıklık matrisleri.....	120
Şekil 6.6. Eğitim ve test setleri için GRU modeli ile elde edilen karışıklık matrisleri.....	120
Şekil 6.7. WS parametresinin farklı değerlerine göre sinyal örnekleri için oluşturulan skalogram görüntüler.....	124
Şekil 6.8. Farklı DenseNET modelleri için karışıklık matrisleri.....	128
Şekil 6.9. DenseNET169 modeline ait doğruluk (accuracy) ve kayıp (loss) grafikleri.....	128

SİMGELER VE KISALTMALAR

Simgeler

$f(t)$	: CWT ile dönüştürülecek olan bir boyutlu sinyal fonksiyonu
τ	: CWT dönüşümündeki kaydırma parametresi
b	: CWT dönüşümündeki ölçek parametresi
ψ	: Dalgacık fonksiyonu
$F_{cwt}(\tau, b)$	: CWT dönüşüm fonksiyonu
x_t	: LSTM hücre yapısında giriş verisi
f_t	: LSTM hücresinde unutma kapısı çıktı fonksiyonu
$\tilde{C}_t$	: LSTM hücresinde aday hücre durum kapısı çıktı fonksiyonu
C_t	: LSTM hücresinde güncellenmiş hücre durum kapısı çıktı fonksiyonu
o_t	: LSTM hücresinde çıkış kapısının çıktı fonksiyonu
$\tanh$	: LSTM ve GRU hücresinde hiperbolik tanjant aktivasyon fonksiyonu
h_t	: LSTM hücresinde güncellenmiş gizli durum fonksiyonu
σ	: LSTM ve GRU hücresinde sigmoid aktivasyon fonksiyonu
W	: LSTM ve GRU hücrelerinde ağırlık matrisi sembolü
b_i	: LSTM ve GRU hücresinde eşik değeri vektörü
$\odot$	: LSTM ve GRU hücresinde parametrelerin vektörel çarpım sembolü
r_t	: GRU hücresinde sıfırlama kapısı
z_t	: GRU hücresinde güncelleme kapısı
$\hat{h}_t$	: GRU hücresinde temsili çıkış kapısı
h_t	: GRU hücresinde çıkış vektörünü

Kısaltmalar

AF	: Atrial Fibrilasyon
ANN	: Yapay Sinir Ağları
ARR	: Aritmi
AT	: Atrial Taşikardi
AV	: Atrioventriküler
BIDMC	: Beth Israel Deaconess Medical Center
CI-1D-LBP	: Merkezden Bağımsız Yerel İkili Desen
CNN	: Konvolüsyonel Sinir Ağı
1D-CNN	: Bir Boyutlu Konvolüsyonel Sinir Ağları
CWT	: Sürekli Zamanlı Dalgacık Dönüşümü
DD	: Dalgacık Dönüşümü
DSP	: Dijital Signal Processing
DenseNet	: Dense Convolutional Network
DL	: Derin Öğrenme
DWT	: Ayırık Dalgacık Dönüşümü
EKG	: Elektrokardiyografi
EEG	: Elektroensefalogram
EGG	: Elektrogastrogram
EMG	: Elektromiyogram
ELM	: Aşırı Öğrenme Makinaları
FA	: Füzyon Aritmi

FT	: Fourier Dönüşümü
GRU	: Kapılı Tekrarlayan Hücre
KKY	: Konjestif Kalp Yetmezliği
KNN	: K-En Yakın Komşuluk
LBP	: Yerel İkili Desen
LSTM	: Uzun Kısa Süreli Bellek
MD	: Motif Dönüşümü
MIT-BIH	:Massachusetts Institute of Technology Beth Israel Hospital
MLP	: Çok Katmanlı Algılayıcı
NSR	: Normal Sinüs Ritmi
OD-1D-LBP	: Ortogonal Fark Yerel İkili Desen
PVC	: Prematüre Ventriküler Kasılma
RF	: Random Forest
RNN	: Recurrent Neural Network
SA	: Sinoatriyal Düğüm
STFT	: Kısa Zamanlı Fourier Dönüşümü
SVA	: Supraventriküler Aritmi
SVM	: Destek Vektör Makineleri
TA	: Tanımlanmamış Aritmi
VA	: Ventriküler Aritmi
WS	: Motif Dönüşümde Pencere Boyutu

1. GİRİŞ

Kalp ve damar hastalıkları, dünya genelinde milyonlarca insanı etkileyen ve ciddi sağlık sorunlarına yol açan önemli bir tehdit unsuru olarak dikkat çekmektedir. Bu hastalıkların artan prevalansı, hem bireylerin yaşam kalitesini olumsuz etkilemekte hem de sağlık sistemleri üzerinde büyük bir yük oluşturmaktadır. Dünya Sağlık Örgütü'ne (DSÖ) göre, kardiyovasküler hastalıklar yıllık olarak yaklaşık 17.9 milyon bireyin hayatına mal olmakta ve bu çarpıcı rakam, küresel sağlık sistemleri üzerinde önemli bir baskı oluşturarak, hastalığın önlenmesi ve tedavi yöntemlerinin geliştirilmesi yönünde acil önlemler alınması gerektiğini ortaya koymaktadır (Cardiovascular Diseases (CVDs), 2024; World Health Survey Plus - WHO, 2024). Kalp ve damar hastalıkları, düşük ve orta gelirli ülkelerde daha yüksek oranlarda görülmekte olup bu bölgelerde hastalığa bağlı ölüm oranları daha yüksektir (Bhatia vd., 2022). Zira bu ülkelerde sağlık hizmetlerine erişimin sınırlı olması ve yaşam koşullarının olumsuzluğu, tedavi süreçlerini zorlaştırmaktadır. Gelişmiş ülkelerde ise yaşam tarzına bağlı risk faktörlerinin yaygınlığı, hastalığın erken yaşlarda ortaya çıkmasına neden olmaktadır (Afzal, 2021).

Türkiye, dünya genelinde görülen bu eğilimlerden bağımsız değildir. Türkiye İstatistik Kurumu verilerine göre, 2022 yılında ölümler arasında dolaşım sistemi hastalıkları %35,4 ile en yüksek orana sahiptir (TÜİK Kurumsal, 2023). Dolaşım sistemi hastalıklarından kaynaklı ölümler incelendiğinde, bu ölümlerin %42,3'ü iskemik kalp hastalıklarından, %23,5'i diğer kalp hastalıklarından ve %19,2'si serebro-vasküler hastalıklardan meydana gelmiştir (TÜİK Kurumsal, 2023). Bu veriler, Türkiye'de kalp hastalıklarının halk sağlığı üzerinde ciddi bir tehdit oluşturduğunu açıkça ortaya koymakta ve bu durumun, ülkenin en önemli ölüm nedenlerinden biri olarak dikkat çektiğini göstermektedir. Bu bağlamda, kalp hastalıklarının yaygınlığı, hem bireylerin sağlıklı yaşam standardını olumsuz etkilemekte hem de sağlık sistemleri üzerinde büyük bir baskı oluşturarak, toplum sağlığını tehdit eden önemli bir sağlık sorunu haline gelmektedir.

Kalp ve damar hastalıklarının genellikle belirtisiz seyretmesi, erken teşhis ve müdahaleyi hayati kılarken, hastalığın bu sinsi ilerleyişi ve semptomların çoğunlukla geç fark edilmesi, tedavi sürecinde ciddi bir zorluk oluşturmaktadır (Benjamin vd., 2019). Bu doğrultuda, teknolojik yeniliklerin ve tıbbi cihazların kullanımı, teşhis sürecini hızlandırmak ve daha kesin sonuçlar elde etmek açısından kritik bir kilometre taşıdır.

Kalp ve damar hastalıklarının etkileri yalnızca bireylerin sağlık durumlarıyla sınırlı kalmayıp, aynı zamanda ekonomik boyutta da ciddi sonuçlar ortaya çıkarmaktadır. Bu hastalıklar, hastaların uzun süreli tedavi ve bakım gereksinimleri, iş gücü kayıpları ve sağlık sistemine eklenen mali yükler gibi faktörler aracılığıyla, toplumun genel refahını tehdit eden önemli bir mali yük oluşturmakta ve bu durum, sağlık hizmetleri üzerinde sürdürülebilirlik sorunu yaratmaktadır (Erkol vd., 2011). Dolayısıyla, kalp hastalıklarının önlenmesi ve erken teşhisin yaygınlaştırılması, yalnızca bireylerin sağlığını korumakla kalmaz, aynı zamanda toplumsal ve ekonomik sürdürülebilirliği de destekleyen bir strateji olarak öne çıkmaktadır.

Elektrokardiyogram (EKG) gibi biyomedikal sinyallerin analizine dayalı cihazlar ve ileri analiz yöntemleri, kalp hastalıklarının teşhisinde sağladığı avantajlar sayesinde klinik uygulamalarda giderek daha fazla kullanılmaktadır (Clifford vd., 2006). Türkiye’de de bu tür teknolojilerin benimsenmesi, erken teşhis oranlarını artırarak tedavi süreçlerini geliştirme ve hızlandırma potansiyeline sahiptir. Kardiyak hastalıkların erken ve doğru teşhisi, bu tür hastalıkların etkin bir şekilde ve zamanında yönetilmesi açısından büyük bir öneme sahiptir. Kalp hastalıklarının genellikle belirgin semptomlar göstermeden ilerlemesi, erken teşhisi güçleştirmekte ve hastalığın daha ileri aşamalara geçmesine yol açabilmektedir. Bu bağlamda, bilgisayar tabanlı teknolojilerin ve otomatik teşhis sistemlerinin geliştirilmesi, kardiyak sağlık alanında önemli bir dönüşüm yaratmaktadır.

Son yıllarda, makine öğrenmesi, yapay zekâ ve büyük veri analitiği gibi ileri düzey teknolojilerin entegrasyonu sayesinde, EKG gibi biyomedikal verileri analiz ederek kardiyak anomalileri ve riskleri daha hızlı ve hassas bir şekilde tespit edebilen otomatik teşhis sistemleri geliştirilmiştir (Deo, 2015). Bu tür teknolojiler, hasta verilerini gerçek zamanlı olarak işleyebilir ve sağlık çalışanlarına hastalığın ilerleyişi hakkında önceden bilgi sağlayarak, kişiselleştirilmiş tedavi planlarının oluşturulmasına olanak tanır. Dolayısıyla, bu otomatik teşhis sistemleri yalnızca teşhis süreçlerini hızlandırmakla kalmaz, aynı zamanda sağlık hizmetlerinin kalitesini artırır ve sağlık sistemlerinin genel etkinliğini geliştirir.

Bununla birlikte, bu sistemlerin geniş çapta uygulanabilirliği ve klinik pratiklere entegrasyonu, veri güvenliği, algoritma doğruluğu ve kullanıcı adaptasyonu gibi çeşitli zorlukları da beraberinde getirmektedir (Rafie vd., 2021). Bu nedenle, bilgisayar tabanlı teşhis teknolojilerinin gelişimi hem teknik hem de etik açıdan kapsamlı bir değerlendirme sürecini gerektirmektedir.

EKG, kalbin elektriksel aktivitesini kaydeden ve bu bilgileri görsel bir formda sunan bir test yöntemidir. EKG, kalp kasının elektriksel sinyallerini deri üzerindeki elektrotlar aracılığıyla ölçerek P dalgası, QRS kompleksi ve T dalgası şeklinde grafiksel olarak ifade eder; bu bileşenler, atriyumların ve ventriküllerin elektriksel aktivitelerini yansıtarak kalp ritminin ve fonksiyonunun detaylı bir görünümünü sunar (Hurst, 1998). EKG'nin yüksek çözünürlüklü zaman ölçümü ve hassasiyeti, kalp ritmi düzensizliklerini, miyokard enfarktüsü gibi ciddi durumları ve elektrolit dengesizliklerini tanımlamada önemli bir araç olarak işlev görür (Thygesen vd., 2013). Bu nedenle, EKG verilerinin detaylı analizi, kardiyak hastalıkların erken ve doğru teşhisinde merkezi bir rol oynamaktadır. Son yıllarda gelişen bilgisayar tabanlı analiz yöntemleri, EKG sinyallerini otomatik olarak işleyip yorumlayarak, kalp hastalıklarının teşhisinde hız ve doğruluk sağlamakta önemli bir adım oluşturmıştır. Bu tür sistemler, hem hekimlere teşhis sürecinde değerli bilgiler sunar hem de hastaların tedaviye erken başlamasını sağlayarak sağlık sonuçlarını iyileştirir.

Modern yazılım tabanlı algoritmalar, EKG sinyallerinin analizinde kardiyak hastalıkların teşhisine yönelik önemli yenilikler sunmaktadır. Bu algoritmalar, kalbin elektriksel aktivitelerini detaylı bir şekilde incelemek amacıyla gelişmiş yapay zeka ve makine öğrenimi yöntemlerini kullanarak, geleneksel yaklaşımlara kıyasla daha yüksek doğruluk ve hassasiyet sağlamaktadır. Bu bağlamda, EKG verilerinin otomatik işlenmesi ve sınıflandırılması, erken teşhis ve etkili tedavi süreçlerine katkıda bulunarak kardiyovasküler sağlık alanında devrim niteliğinde bir ilerleme sağlamaktadır. Özellikle derin öğrenme algoritmaları olan konvolüsyonel sinir ağları (CNN) ve uzun kısa süreli bellek (LSTM) EKG sinyallerindeki karmaşık ve ince patolojik değişiklikleri yüksek hassasiyetle tespit edebilme kapasitesine sahiptir (Kaya vd., 2022). Bu sistemler, geniş veri setleri üzerinde eğitim alarak, kalp ritmi düzensizlikleri ve diğer kardiyak anormallikleri tanımlamada mükemmel sonuçlar sunar. Ayrıca, destek vektör makineleri (SVM) ve rastgele ormanlar (RF) gibi klasik makine öğrenimi yöntemleri, EKG verilerini etkili bir şekilde sınıflandırarak teşhis doğruluğunu artırır (Y. Zhang vd., 2019). Yazılımsal algoritmalar, veri ön işleme ve özellik mühendisliği aşamalarında otomasyon sağlayarak, klinik uygulamalarda teşhis süreçlerini hızlandırır ve daha güvenilir sonuçlar elde edilmesini destekler (Zyout vd., 2023). Bu algoritmaların dinamik olarak güncellenmesi ve sürekli öğrenme yetenekleri, yeni kardiyak hastalık modellerine ve bireysel hasta özelliklerine uyum sağlama yeteneğini güçlendirir. Sonuç olarak, modern

yazılımsal algoritmalar, EKG verilerinin analizinde sağladığı yüksek doğruluk ve etkinlikle kardiyak hastalıkların erken teşhisinde önemli bir ilerleme kaydetmektedir.

1.1. Tezin Amacı ve Kapsamı

Bu tez çalışmasının temel amacı, kalp ritim bozuklukları (aritmiler) ve konjestif kalp yetmezliği (KKY) gibi kardiyak hastalıkların erken teşhisinde yüksek performanslı ve yenilikçi Bilgisayar Destekli Tanı (CAD) sistemlerinin geliştirilmesidir. EKG sinyallerinin detaylı analizi ve bu sinyallerden etkili özniteliklerin çıkarılması süreçleri, bu çalışmanın merkezinde yer almaktadır. Bu bağlamda, sinyal işleme teknikleri ve istatistiki-matematiksel algoritmalar kullanılarak, EKG verilerinden anlamlı özellikler elde edilmiştir.

Tezin kapsamı, özellikle yenilikçi hibrit öznitelik çıkarma yöntemlerinin geliştirilmesine odaklanmaktadır. Bu yöntemler arasında, daha çok iki boyutlu görüntü sinyallerine uygulanan yerel ikili desen (LPB) yönteminden esinlenilerek oluşturulan ve tek boyutlu EKG sinyallerine uygulanmak üzere yeni bir yaklaşım olarak tasarlanan ortogonal fark bir boyutlu yerel ikili desen (OD-1D-LBP) ve merkezden bağımsız bir boyutlu yerel ikili desen (CI-1D-LBP) teknikleri bulunmaktadır. Bu teknikler, geleneksel yöntemlere kıyasla EKG sinyallerindeki ince ayrıntıları ve patolojik değişiklikleri daha hassas bir şekilde yakalayabilme potansiyeline sahiptir. Ayrıca, yine bu tez çalışması kapsamında farklı bir uygulamada sunulan, sürekli zamanlı dalgacık dönüşümünden (CWT) önce bir veri ön işleme ve örüntü çıkarma metodu olarak tasarlanan ve EKG verilerinden öznitelik çıkarma sürecinde yenilikçi bir yaklaşım sunan motif dönüşüm (MD) metodu da çalışmada ele alınmıştır.

Bu öznitelik çıkarma yöntemlerinden elde edilen veriler, modern derin öğrenme teknikleri olan 1-boyutlu konvolüsyonel sinir ağları (1D-CNN), uzun kısa süreli bellek (LSTM), kapılı tekrarlayan hücre (GRU) ve DenseNet kullanılarak sınıflandırılmıştır. Bu tez çalışmasında yapılan üç farklı uygulama, dört farklı aritmi türü, konjestif kalp yetmezliği (KKY) ve normal sinüs ritmi (NSR) gibi EKG verilerini yüksek doğruluk oranlarıyla analiz edip sınıflandırarak, bu yeni yöntemlerin kardiyak hastalıkların teşhisindeki etkinliğini ortaya koymayı amaçlamaktadır. Çalışma, bilgisayar tabanlı tanı sistemlerinde yenilikçi yaklaşımların potansiyelini değerlendirerek, EKG sinyallerinin analizi ve sınıflandırılmasında önemli katkılar sağlamayı hedeflemektedir.

1.2. Hedefler ve Literatüre Sağlanan Katkılar

Bu tez, literatüre kardiyak hastalıkların bilgisayar destekli teşhisinde önemli yenilikler ve katkılar sağlayacaktır:

- **Yeni Öznitelik Çıkarma Tekniklerinin Literatüre Katkısı:** OD-1D-LBP ve CI-1D-LBP tekniklerinin tanıtılması, mevcut EKG analiz yöntemlerine kıyasla daha hassas ve etkili bir patolojik tespit sağlama potansiyeline sahiptir. Bu yenilik, kardiyak sinyal işleme alanında önemli bir ilerleme olarak değerlendirilecektir.
- **Motif dönüşüm (MD) Metodunun Yenilikçi Yaklaşımı:** Motif dönüşüm (MD) metodunun sürekli zamanlı dalgacık dönüşümünden (CWT) önce veri ön işleme ve örüntüleme adımı olarak kullanılması, öznitelik çıkarımı sürecine getirdiği yenilikçi yaklaşım ile literatürdeki eksiklikleri dolduracaktır. Bu metodun, EKG sinyallerinin işlenmesinde sunduğu yeni perspektif, ilgili alanda önemli bir katkı olarak kabul edilecektir.
- **Derin Öğrenme Yöntemlerinin Kardiyak Teşhisindeki Etkinliği:** 1D-CNN, LSTM, GRU ve DenseNet gibi derin öğrenme tekniklerinin kardiyak hastalıkların teşhisindeki yüksek doğruluk oranları, literatürdeki yöntemlerin ötesinde pratik ve teorik bir değer sunacaktır. Bu katkı, derin öğrenme tabanlı yaklaşımların EKG sinyal analizindeki etkinliğini destekleyecektir.
- **Klinik Uygulamalar İçin Pratik Çözümler:** Geliştirilen yöntemlerin klinik ortamlarda uygulanabilirliğinin gösterilmesi, kardiyak hastalıkların teşhisinde pratik ve etkili çözümler sunarak sağlık hizmetlerinin iyileştirilmesine katkıda bulunacaktır. Bu, özellikle acil durumlarda ve yüksek hassasiyet gerektiren senaryolarda önemli bir yenilik olarak değerlendirilecektir.

1.3. Tezin Organizasyon Yapısı

Bu tez çalışması EKG'nin genel tanıtımı ve literatür araştırması dışında, dört ana bölümden oluşmaktadır. Her bir bölüm kardiyak hastalıkların teşhisinde kullanılan EKG verilerinin analizi ve sınıflandırılması sürecini kapsamlı bir şekilde ele almıştır.

- **Materyal:** Materyal bölümünde, EKG verileri ve kullanılan veri setleri hakkında detaylı bilgiler sunulmuştur. Veri setinde bulunan EKG sinyallerinin genel yapısı, veri setlerinde yer alan farklı aritmi çeşitleri, konjestif kalp yetmezliği (KKY) ve normal sinüs ritmi (NSR) verileri hakkında kapsamlı açıklamalar yapılmıştır.

▪ **Metot:** Metot bölümünde, öznitelik çıkarma algoritmaları ve sınıflandırma yöntemlerinin derinlemesine analizi gerçekleştirilmiştir. Öznitelik çıkarma teknikleri olarak OD-1D-LBP ve CI-1D-LBP yöntemlerinin detayları sunulmuş ve bu yöntemlerin etkileri incelenmiştir. Ayrıca, veri ön işleme ve örüntüleme metodu olarak tasarlanan motif dönüşümün (MD) genel mimarisi ve ardından uygulanan sürekli zamanlı dalgacık dönüşümü (CWT) metodu da detaylı bir şekilde açıklanmıştır. Sınıflandırmada kullanılan 1D-CNN, LSTM, GRU ve DenseNet derin öğrenme yöntemlerinin teorik arka planlarına da metot kısmında yer verilmiştir.

▪ **Uygulama ve Sonuçları:** Uygulama bölümünde, üç farklı uygulama senaryosu üzerinde durulmuştur. Birinci uygulamada aritmi, konjestif kalp yetmezliği (KKY) ve NSR sinyallerinden oluşan veri setine OD-1D-LBP yöntemi uygulanmıştır. Elde edilen öznitelikler, 1D-CNN ve LSTM makine öğrenmesi yöntemleri kullanılarak sınıflandırılmıştır. İkinci uygulamada, dört farklı aritmi çeşidi ve NSR sinyallerinden oluşan veri setine CI-1D-LBP yöntemi uygulanarak öznitelikler elde edilmiş ve bu öznitelikler, 1D-CNN, LSTM ve GRU yöntemleri ile sınıflandırılmıştır. Üçüncü uygulamada ise aritmi, konjestif kalp yetmezliği (KKY) ve NSR sinyallerinden oluşan veri setine, veri ön işleme ve örüntüleme metodu olarak tasarlanan motif dönüşüm uygulanmıştır. Ardından, oluşturulan motiflerden elde edilen sinyallere sürekli zamanlı dalgacık dönüşümü (CWT) uygulanarak skalogramlar oluşturulmuş ve bu skalogram verileri DenseNet ile sınıflandırılmıştır.

▪ **Sonuç ve Öneriler:** Sonuç ve öneriler bölümünde, yapılan uygulamaların bulguları ve her bir metodunun sınıflandırma performansları etraflıca değerlendirilmiştir. Ayrıca, geliştirilen yöntemlerin diğer biyomedikal sinyaller üzerindeki muhtemel etkinliği ve performansı ile ilgili öneri ve tahminlerde de bulunulmuştur.

2. ELEKTROKARDİYOĞRAFI (EKG)

Elektrokardiyografi (EKG), kalbin elektriksel aktivitesini ölçerek çeşitli kardiyovasküler bozuklukların teşhisinde kullanılan, modern tıbbın vazgeçilmez tanı araçlarından biridir. EKG, kalbin elektriksel sinyallerini kaydederek kalp ritmi, kalp atım hızı ve miyokardiyal fonksiyonlar hakkında bilgi sunar (Mirvis vd., 2001). Kalp ritim bozuklukları (aritmiler), kalp krizi (miyokard enfarktüsü), kalp kası hastalıkları (kardiyomiyopatiler) ve elektrolit dengesizlikleri gibi birçok kardiyovasküler bozukluk, EKG verileriyle kolayca tespit edilebilir (Patil vd., 2016). EKG, sadece tanı koymak için değil, tedavi sürecini izlemek ve özellikle yüksek riskli hastalarda kardiyak olayları erken tespit ederek müdahale edebilmek amacıyla sıkça kullanılan bir izleme aracıdır.

EKG'nin tarihsel gelişimi ve fizyolojik temelleri, bu teknolojinin tıpta ne denli kritik bir yer tuttuğunu daha iyi anlamamızı sağlar. EKG'nin bilimsel ve klinik yönleri derinlemesine incelendiğinde, bu yöntemin modern tıbbın en değerli tanı araçlarından biri olduğu açıkça görülmektedir. EKG'nin tarihçesi, bilimsel ilerlemelerle paralel bir şekilde gelişmiş ve günümüz tıbbında vazgeçilmez bir yer edinmiştir. Aynı zamanda, kalbin elektriksel aktivitesinin fizyolojik temelleri de EKG'nin klinik kullanımı açısından büyük önem taşımaktadır. Aşağıdaki bölümlerde, EKG'nin tarihçesi ve gelişimi, EKG sinyallerinin fizyolojik temelleri ve kardiyak hastalıklara dair ayrıntılı bir inceleme sunulmaktadır.

2.1. EKG'nin Tarihçesi ve Gelişimi

EKG'nin kökeni 19. yüzyılın sonlarına kadar uzanmaktadır. Bu teknoloji, 1901 yılında Willem Einthoven'in geliştirdiği ilk elektrokardiyograf cihazı ile modern bir form kazanmıştır. Einthoven, galvanometreyi kullanarak kalp tarafından üretilen elektrik sinyallerini kaydetmeyi başarmış ve bu cihazla elde edilen ilk EKG verilerini analiz etmiştir (Silverman & Willis Hurst, 1992). Einthoven'in çalışmaları, kalp atımlarının farklı elektriksel fazlarını gösteren P, QRS ve T dalgalarının ilk tanımlanmasını sağlamıştır (Hurst, 1998). Bu buluş, sadece klinik pratiğe değil, aynı zamanda kardiyovasküler fizyoloji ve patoloji alanlarına da büyük katkılar sunmuştur (Snellen, 1994). Einthoven'in elektrokardiyograf cihazı, bugün kullanılan modern cihazların temelini oluşturan bir prensibe dayanmakta olup, ona 1924 yılında Nobel Fizyoloji veya Tıp Ödülü'nü kazandırmıştır.

İlk EKG cihazları, hantal ve büyük boyutlarıyla dikkat çekerken, zamanla teknolojinin olağanüstü ilerlemesi sayesinde bu cihazlar kompakt hale getirilerek taşınabilir ve kullanışlı bir duruma gelmiş; böylece klinik uygulamalarda ve günlük yaşamda önemli bir devrim yaratmıştır (Bansal & Joshi, 2018). 20. yüzyılın ortalarına gelindiğinde, EKG klinik pratiğin bir parçası haline gelmiş ve kalp hastalıklarının tanısında en yaygın kullanılan yöntemlerden biri olmuştur. İlk jenerasyon EKG cihazları, elektrotların doğrudan kalbe yakın bölgelere yerleştirilmesiyle çalışırken, modern cihazlar cilt üzerinden ölçüm yaparak non-invaziv (cerrahi müdahale gerektirmeyen) bir yöntem sunmaktadır (Chlaihawi vd., 2018). Özellikle dijital teknolojilerin gelişimi, EKG'nin daha hassas, hızlı ve güvenilir sonuçlar vermesini sağlamıştır.

1960'lı yıllarda, EKG verilerinin dijital olarak işlenmesi mümkün hale gelmiş, bu gelişme EKG'nin klinik pratiğe daha yaygın olarak entegrasyonunu kolaylaştırmıştır (Burch & DePasquale, 1990). Günümüzde dijital EKG cihazları, bulguları anında analiz ederek otomatik teşhis algoritmalarıyla desteklemekte ve özellikle taşınabilir cihazlar, evde bakım uygulamalarında yaygın olarak kullanılmaktadır. Son yıllarda, giyilebilir teknoloji cihazları (örneğin, akıllı saatler) sayesinde EKG verilerinin günlük yaşamda sürekli olarak izlenmesi mümkün hale gelmiş ve kardiyak ritim bozukluklarının erken teşhis edilmesine olanak tanımıştır (Duncker vd., 2021).

EKG'nin teknolojik gelişimi, sadece cihazlarla sınırlı kalmamış, aynı zamanda matematiksel ve biyofiziksel analizlerde de önemli ilerlemeler kaydedilmiştir. Fourier analizi ve dalgacık dönüşümü tabanlı zaman-frekans analizleri gibi sinyal işleme yöntemleri, EKG sinyallerinin daha ayrıntılı ve hassas bir şekilde analiz edilmesine olanak sağlamıştır (Lee vd., 2017). Yapay zekâ ve makine öğrenmesi gibi yeni teknolojiler, EKG verilerinin hızlı ve doğru yorumlanmasına yardımcı olmakta ve teşhis süreçlerini hızlandırmaktadır (Gala vd., 2024). Bu gelişmeler, özellikle kardiyovasküler hastalıkların erken teşhisinde devrim niteliğinde ilerlemeler sağlamıştır.

2.2. EKG'nin Fizyolojik Temelleri

Kalbin çalışması, elektriksel ve mekanik süreçlerin koordineli ve senkron bir şekilde ilerlemesi ile sağlanır. Kalpteki elektriksel aktivite, kasılmayı başlatan uyarılar olarak nitelendirilir ve bu aktiviteyi izleyen mekanik hareket, kanın vücuda pompalanmasını sağlar (Rafie vd., 2021). EKG, bu elektriksel aktivitenin vücut yüzeyindeki yansımaları kaydeder ve kalbin fonksiyonel durumu hakkında bilgi sunar.

Kalbin elektriksel aktivitesi, kasılmayı düzenleyip kanın vücuda etkili şekilde pompalanmasını sağlayan özelleşmiş bir ileti sistemi tarafından yönetilir (Sundnes vd., 2007). Kalbin elektriksel uyarıları, sinoatriyal düğümünden (SA) başlar ve atriyumlar üzerinden atriyoventriküler (AV) düğüme iletilir. Buradan da His demeti, sağ ve sol dal blokları ve Purkinje lifleri aracılığıyla ventriküllere yayılır. Sinüs düğümünde oluşan aksiyon potansiyeli, EKG’de P dalgası olarak kaydedilir ve atriyumların depolarizasyonunu (kasılmasını) temsil eder (Hlaing vd., 2005). P dalgasının ardından gelen QRS kompleksi, ventriküllerin depolarizasyonunu ifade eder ve bu süreç, kalbin kanı büyük dolaşıma pompalamasını sağlar (Wellens, 2007). QRS kompleksi, ventriküllerin senkronize bir şekilde kasılmasıyla oluşan hızlı bir elektriksel aktiviteyi gösterir ve genişliği ventriküler iletimin hızını ve etkinliğini temsil eder (Couceiro vd., 2008). T dalgası ise ventriküllerin repolarizasyonunu, yani kasılma sonrası gevşeme sürecini ifade eder. Bu temel dalgaların morfolojisi ve zamanlaması, kalbin elektriksel fonksiyonunun genel durumu hakkında bilgi verir (Anttonen vd., 2009).

Aksiyon potansiyelleri, kalp hücrelerinin membran potansiyelindeki hızlı değişikliklerle oluşur ve bu süreçte iyon kanalları kritik bir rol oynar (X. D. Zhang vd., 2021). Kardiyak hücreler, elektriksel sinyalleri oluşturmak için sodyum (Na^+), potasyum (K^+), kalsiyum (Ca^{2+}) gibi iyonların hücre zarından giriş çıkışını düzenleyen özel kanallara sahiptir (Beca vd., 2011). Bu iyon akışları, kalp kasının kasılması ve gevşemesi sırasında membran potansiyelinin yükselmesine ve düşmesine neden olur (Benitah vd., 2010).


- **Depolarizasyon:** EKG’de görülen P dalgası, atriyumların depolarizasyonunu temsil eder. Bu süreç, sinüs düğümünden yayılan elektriksel uyarılarla başlar ve atriyal kas hücrelerinin hızlı bir şekilde Na^+ iyonları almasına neden olur.
- **Ventriküler depolarizasyon:** QRS kompleksi, ventriküllerin hızlı depolarizasyonunu yansıtır. Bu sırada, Na^+ iyonları hızla ventrikül kas hücrelerine girer ve ventriküller kasılarak kanı pompalar.
- **Repolarizasyon:** T dalgası, ventriküllerin repolarizasyonunu yani dinlenme durumuna dönmesini gösterir. Bu aşamada K^+ iyonları hücrelerden dışarı çıkar ve hücre içi potansiyelin normale dönmesini sağlar.

Kalp kası hücrelerinin aksiyon potansiyeli, dört ana fazda gerçekleşen bir elektriksel süreçtir. Bu dört faz, kalp hücrelerinin dinlenme durumundan kasılma durumuna geçişini ve tekrar dinlenmeye dönmesini açıklayan ayrıntılı bir biyofiziksel

olaylar dizisidir (Joukar, 2021). Elektrofizyolojik mekanizmaları anlamak için bu fazlar kritik öneme sahiptir. Aşağıda, bu fazlar ve EKG ile ilişkisi açıklanmıştır:

- **Faz 0 (Hızlı Depolarizasyon):** Kalp hücreleri, dışarıdan bir uyarı aldığında sodyum (Na^+) iyon kanalları hızla açılır ve Na^+ iyonları hücre içine doğru büyük bir akış gerçekleştirir. Bu, hücre membranında pozitif bir yük birikimine yol açar ve hücrenin depolarizasyonunu sağlar. EKG'de bu faz, QRS kompleksi ile ilişkilidir, çünkü bu süreç ventriküllerin hızlı bir şekilde kasılmasını başlatır.
- **Faz 1 (Erken Repolarizasyon):** Depolarizasyonun ardından, kısa bir süre içinde potasyum (K^+) kanalları açılır ve potasyum iyonları hücre dışına çıkmaya başlar. Bu, hücre membranının elektriksel potansiyelini hafifçe negatif hale getirir ve erken repolarizasyon evresini başlatır. Bu faz, aksiyon potansiyelinin zirveye ulaşip tekrar düşmeye başladığı ilk evreyi temsil eder.
- **Faz 2 (Plato Fazı):** Kalp hücrelerinin aksiyon potansiyelinde yer alan en uzun fazdır. Bu faz sırasında kalsiyum (Ca^{2+}) iyon kanalları açılır ve kalsiyum iyonları hücre içine girer. Bu, kas hücrelerinin kasılmasını sürdüren kritik bir süreçtir. Aynı zamanda potasyum iyonları hücre dışına çıkmaya devam eder, bu da membran potansiyelinin sabit kalmasını sağlar. EKG'de, bu plato fazı ventriküllerin kasıldığı ve kan pompalandığı süreçtir. Bu faz, EKG'de ST segmenti ile ilişkilidir.
- **Faz 3 (Hızlı Repolarizasyon):** Bu aşamada kalsiyum iyon kanalları kapanır, ancak potasyum kanalları açık kalır, bu da hücre içindeki pozitif yükün hızla azalmasına ve hücrenin tekrar negatif bir membran potansiyeline dönmesine yol açar. Bu hızlı repolarizasyon evresi, ventriküllerin gevşemesini sağlar ve EKG'de T dalgası ile temsil edilir.
- **Faz 4 (Dinlenme Fazı):** Bu faz, hücrelerin aksiyon potansiyelinin olmadığı ve istirahat ettiği bir evredir. Hücre içi ve dışı iyon dengesi, Na^+/K^+ pompaları aracılığıyla geri yüklenir. Kalp kası hücreleri bir sonraki aksiyon potansiyeline kadar dinlenir. Bu evre, EKG'de izoelektrik hat olarak gözlenir ve kalp kası hücreleri bir sonraki uyarıya hazır hale gelir.

Aşağıdaki Şekil 2.1' de her bir fazın renklendirilmiş halde aksiyon potansiyeli faz evreleri ve bu evrelerde gerçekleşen iyon değişimlerinin eğrisi verilmiştir.



Şekil 2.1. Aksiyon potansiyeli faz evreleri (StudMed, 2024)

Şekil 2.1’de gösterilen dört faz, kalp kasının kasılma ve gevşeme döngüsünün elektrofizyolojik temellerini oluşturur (Miranda vd., 2016). Her faz, iyon kanallarının düzenlenmesiyle karakterize edilen kompleks biyokimyasal olaylara dayanır ve EKG’de gözlemlenebilir değişikliklerle klinik olarak yorumlanabilir (Parikh, 2022). Bu süreçlerde meydana gelen anomaliler, kardiyak aritmilere, kalp bloğuna veya diğer kardiyovasküler hastalıklara neden olabilir

Sinüs düğümünde (SA) başlayan aksiyon potansiyelleri, atriyoventriküler (AV) düğüm aracılığıyla ventriküllere iletilir. AV düğüm, sinyallerin ventriküllere geçişini bir an için geciktirir, böylece atriyumların ventrikülleri kanla doldurması için yeterli zaman tanınır. Bu gecikme, fizyolojik açıdan oldukça kritiktir, çünkü ventriküllerin tam olarak dolmasını sağlar. Daha sonra, elektriksel uyarı his demeti ve purkinje lifleri aracılığıyla ventriküllerin her iki tarafına yayılır, bu da ventriküllerin kasılmasına ve kanın vücuda ve akciğerlere pompalanmasına neden olur. Aşağıdaki Şekil 2.2’de kalp boyunca sırası ile sinoatriyal düğümünden miyokart dokularına kadar yedi farklı noktada oluşan aksiyon potansiyel dalgalarının değişimleri verilmiştir.



Şekil 2.2. Kalp boyunca aksiyon potansiyeli eğrilerinin yayılımı (StudMed, 2024)

EKG, kalbin elektriksel aktivitesini grafiksel olarak temsil eden bir araçtır ve bu grafikte çeşitli dalga ve segmentler yer alır. Her biri kalbin farklı elektriksel fazlarını ve kasılma süreçlerini yansıtır (Klabunde, 2017). P dalgası, QRS kompleksi, ST segmenti, T dalgası ve P-Q ile Q-T aralıkları, kalbin fizyolojik işleyişine dair detaylı bilgiler sunar (Anttonen vd., 2009). Bu bölümler, kalp kası hücrelerinin aksiyon potansiyelindeki değişikliklerle ilişkili olup, kardiyak fonksiyonların incelenmesinde kritik rol oynar. Aşağıda temel EKG bileşenleri ve bunların klinik anlamları detaylandırılmıştır:

P Dalgası: P dalgası, atriyal depolarizasyonu yani sağ ve sol atriyumların elektriksel uyarılmasını ve kasılmasını temsil eder. Sinüs düğümünden başlayan elektriksel uyarı, atriyal kas hücrelerine yayılarak atriyumların kasılmasını sağlar ve bu sırada kan ventriküllere pompalanır. P dalgasının morfolojisi, atriyal boyutu, yapısı ve atriyumların uyarılma hızına dair ipuçları sunar (Rosiak vd., 2002). Anormal bir P dalgası, atriyal genişleme, atriyal fibrilasyon veya atriyal taşikardi gibi hastalıklarla ilişkili olabilir (Platonov, 2012).

QRS Kompleksi: QRS kompleksi, ventriküllerin hızlı depolarizasyonunu, yani sağ ve sol ventriküllerin elektriksel uyarılarla kasılmasını gösterir. Bu kompleksin süresi, ventriküllerdeki iletim yollarının normal olup olmadığını ve uyarının ne kadar hızlı yayıldığını gösterir (Kashani & Barold, 2005). Normalde 0.06 ile 0.10 saniye arasında sürmesi beklenir. QRS kompleksinde genişleme olması, ventriküllerde iletim problemlerine veya ventrikül hipertrofisine işaret edebilir (Bryant vd., 2013). Kompleksin her bir bileşeni farklı bölgeleri temsil eder:

- Q dalgası, ventriküllerin septumunun depolarizasyonunu yansıtır.
- R dalgası, ventriküllerin ana kütesinin depolarizasyonunu temsil eder.
- S dalgası, ventriküllerin son kısmının depolarizasyonunu gösterir.


T Dalgası: T dalgası, ventriküllerin repolarizasyonunu yani dinlenme haline dönmesini ifade eder. T dalgasının şekli, ventriküler repolarizasyonun hızı ve doğası hakkında bilgi verir. Anormal bir T dalgası, ventriküler repolarizasyonda bir aksaklık veya kalp kasındaki potasyum dengesizliği gibi durumların göstergesi olabilir (Nerbonne & Kass, 2005). T dalgasının ters dönmesi veya sivri bir yapıya sahip olması, miyokard iskemisi ya da elektrolit dengesizlikleri ile ilişkilendirilebilir (Porthan vd., 2009).

ST Segmenti: ST segmenti, ventriküllerin depolarizasyonu ile repolarizasyonu arasında geçen duraklama dönemini temsil eder. Bu segment, ventriküllerin kasılma halinden dinlenme haline geçişini gösterir. Normal bir ST segmenti, izoelektrik hatta yer alır, yani EKG'nin yatay çizgisi ile aynı hizada olmalıdır. ST segmentinin yükselmesi,

akut miyokard enfarktüsü gibi iskemik olaylarla ilişkili olabilir, bu nedenle klinik olarak büyük öneme sahiptir (Kumar & Lloyd-Jones, 2007). ST segmentinde meydana gelen çökme ise miyokardiyal iskeminin bir işareti olabilir (Di Diego & Antzelevitch, 2014).

P-Q Aralığı (PR Aralığı): P-Q aralığı veya PR aralığı, atriyumların depolarizasyonu ile ventriküllerin depolarizasyonu arasındaki süreyi temsil eder. Bu aralık, sinüs düğümünden çıkan uyarının AV düğümüne ve ventriküllere iletilmesi için geçen zamanı yansıtır. Normalde 0.12-0.20 saniye arasında süren bu aralık, atriyoventriküler iletimdeki bir gecikmenin (AV blok) veya atriyal ileti bozukluklarının göstergesi olabilir (Ali vd., 2024). PR aralığının uzaması, kalpte bir iletim blokajı olduğuna işaret ederken, kısalması ise aksesuar yolların varlığına veya atriyal taşikardiye işaret edebilir (Mittal, 2023).

Q-T Aralığı: Q-T aralığı, ventriküllerin depolarizasyonu ile repolarizasyonu arasındaki toplam süreyi gösterir. Bu aralık, kalp kasının ventriküler kasılma ve gevşeme süresini ölçer ve normalde kalp hızına bağlı olarak değişir. Uzun QT sendromu, ventriküllerdeki repolarizasyon sürecinin uzamasıyla karakterize bir durumdur ve ciddi aritmi riskini artırabilir (Shewakramani & Gorder, 2020). QT aralığının uzaması, ventriküllerde ölümcül olabilecek ani ritim bozukluklarına yol açabilir ve bu durum genellikle genetik anormalliklere, ilaçlara ya da elektrolit dengesizliklerine bağlıdır (Malik & Batchvarov, 2000).



Şekil 2.3. Örnek bir EKG parçası

P dalgası, QRS kompleksi, ST segmenti, T dalgası ve P-Q ile Q-T aralıkları, kardiyak elektriksel aktivitenin en önemli bileşenleridir ve kalbin normal işleyişi

hakkında kritik bilgiler sunar. Bu unsurların her biri, kalp ritmi ve kasılma döngülerinde meydana gelen farklı olayları temsil eder ve kardiyak patolojilerin tespiti için ayrıntılı bir analiz sağlar. Anormal dalgalar ve aralıklar, kardiyak iletim sistemindeki aksaklıkları işaret eder ve bu anomalilerin yorumlanması, doğru tanı ve tedavi için hayati önem taşır.

2.3. EKG Verilerinin Toplanması ve Dijitalleştirilmesi

Elektrokardiyografi (EKG), kalbin elektriksel aktivitesini ölçerek kardiyak işlevlerin değerlendirilmesine olanak sağlayan kritik bir biyomedikal teknolojidir. Vücuttan EKG verilerinin toplanması ve dijitalleştirilmesi, hassas ölçüm ve analiz süreçlerini içeren bir dizi yöntem ve teknolojiye dayanmaktadır. Bu bölümde, EKG verilerinin algılanmasından dijitalleştirilmesine kadar geçen temel süreçler ve kullanılan teknolojik yaklaşımlar detaylı bir şekilde ele alınacaktır.

Elektrotlarla Sinyal Toplama: EKG verilerinin toplanması, vücut yüzeyine yerleştirilen elektrotlar aracılığıyla başlar. Gümüş/gümüş klorür (Ag/AgCl) malzemeden üretilen elektrotlar, düşük empedans ve yüksek sinyal kararlılığı sunarak biyopotansiyellerin doğru algılanmasını sağlar (Wang vd., 2024). Elektrotlar, cilt ile iyi bir elektriksel temas sağlamak için iletken bir jel ile desteklenir (Goyal vd., 2022). Elektrotlar, genellikle Einthoven üçgeni veya Wilson merkezi terminali gibi yerleşim düzenlerine göre konumlandırılır ve bu çok yönlü konumlandırma, kardiyak aktivitenin farklı eksenlerden izlenmesini ve çok kanallı (12 derivasyon) ölçümlerin yapılmasını mümkün kılar (Gargiulo vd., 2018).

Biyopotansiyel Sinyalin Amplifikasyonu: Vücut yüzeyinden alınan EKG sinyalleri, genellikle milivolt (0.5–5 mV) düzeyindedir. Bu düşük genlikli sinyallerin anlamlı hale gelmesi için yükseltilmesi gereklidir. Yüksek giriş empedansına sahip diferansiyel amplifikatörler, bu işlem için kullanılır. Ortak mod sinyalleri (örneğin, güç hattı paraziti) bastırmak amacıyla amplifikatörlerin ortak mod reddi oranı (CMRR) optimize edilir (Xu vd., 2024). Ek olarak, amplifikasyon devreleri elektromanyetik girişim (EMI) ve kas artefaktları gibi gürültülerin etkisini en aza indirmek için koruyucu bileşenlerle desteklenir.

Sinyal Filtreleme: Toplanan sinyaller, genellikle çevresel gürültüler ve artefaktlarla kirlenmiştir. EKG cihazları, bu parazitleri elimine etmek için çeşitli filtreleme yöntemlerini kullanır. Yüksek geçiren filtreler kullanılarak solunumdan kaynaklanan bazal çizgi dalgalanması (0.5 Hz altındaki bileşenleri) temizlenir (Taha ve

Abdel-Raheem, 2020). Düşük geçiren filtreler kullanılarak 100–150 Hz üzerindeki yüksek frekanslı kas artefaktları ve elektromanyetik girişimler bastırılır (Martinek vd., 2021). Çentik (notch) filtreler, şebeke parazitlerini (50/60 Hz) hedefleyerek bu frekansları bastırmada kullanılır (Mir ve Singh, 2024). Bu filtreleme işlemleri, sinyalin klinik analizi için doğru bir şekilde yorumlanmasını sağlar.


Analog-Dijital Dönüştürme (ADC): EKG sinyali analog bir biyopotansiyel olarak elde edilir; ancak dijital analiz sistemleri için sayısal formata dönüştürülmesi gerekir. Analog-dijital dönüştürme işlemi sırasında en az 12-bit çözünürlük, sinyaldeki ince detayları yakalamak için gereklidir. Örnekleme frekansı için Nyquist teoremine göre, sinyaldeki en yüksek frekansın en az iki katı kadar örnekleme frekansı kullanılır. Bu süreç, EKG sinyalinin kayıpsız bir şekilde dijital formata aktarılmasını sağlar.

Dijital Sinyal İşleme (DSP): Dijitalleştirilmiş EKG sinyali üzerinde uygulanan işleme teknikleri, sinyalin temizlenmesi, analiz edilmesi ve klinik tanı için anlamlı hale getirilmesi amacıyla çeşitli yöntemler içerir. Öncelikle, solunum hareketleri veya vücut hareketlerinden kaynaklanan düşük frekanslı bazal çizgi dalgalanmaları, yüksek geçiren filtreler veya polinom yaklaşımları gibi yöntemlerle düzeltilir (Li ve Boulanger, 2021). Bu adım, EKG sinyalinin ana dalga formlarının doğru şekilde tespit edilmesini sağlar. Ardından, dalga formu segmentasyonu gerçekleştirilerek P, QRS ve T dalgalarının başlangıç ve bitiş noktaları belirlenir. QRS kompleksinin tespiti için sıklıkla kullanılan Pan-Tompkins algoritması, dijital sinyal işleme alanında yaygın bir yaklaşım olarak öne çıkar (Pan & Tompkins, 1985).

Bunun yanı sıra, sinyalin zaman ve frekans domenindeki özelliklerini çıkarmak için Fourier dönüşümü kısa zamanlı Fourier dönüşümü ve dalgacık dönüşümü (wavelet transform) gibi teknikler uygulanır. Özellikle dalgacık dönüşümü, EKG sinyalinin zamanla değişen özelliklerini analiz etmede üstün bir performans sergiler. Zaman-frekans analizine ek olarak, empirik mod ayrıştırma (EMD) ve adaptif filtreleme yöntemleri, sinyaldeki nonlinear ve gürültü bileşenlerini ayrıştırarak temiz bir sinyal elde edilmesini sağlar (Li ve Boulanger, 2021). Ayrıca, istatistiksel yöntemler ve kaotik sinyal analizi gibi tekniklerle sinyalin entropisi, fraktal boyutu ve diğer nonlinear özellikleri incelenerek, daha ayrıntılı bir analiz sunulur (Selvan vd., 2022). Bu süreçlerin bir arada uygulanması, EKG sinyalinin sadece temel özelliklerini değil, aynı zamanda klinik tanıya yönelik detaylı parametrelerini de ortaya çıkararak doğru ve güvenilir bir değerlendirme yapılmasını mümkün kılar.

Depolama ve Görselleştirme: Dijitalleştirilmiş ve işlenmiş EKG sinyalleri, genellikle cihazın dahili belleğinde veya bulut tabanlı sistemlerde depolanır. DICOM formatı gibi standartlar, bu verilerin tıbbi bilgi sistemlerine entegrasyonunu kolaylaştırır(Larobina, 2023). Ayrıca, sinyalin gerçek zamanlı görselleştirilmesi için monitör ve çıktı alınması için yazıcı birimleri kullanılır.

Aşağıdaki Şekil 2.4'teki blok şema, insan vücudundan EKG verilerinin toplanması ve işlenmesi için kullanılan elektronik sistemi görsel olarak temsil etmektedir.



Şekil 2.4. Tipik bir Elektrokardiyografi cihazının blok şeması

Elektrot Yerleşimi (RA, LA, RL, LL): RA (right arm) sağ kol üzerine yerleştirilen elektrotu, LA (left arm) sol kol üzerine yerleştirilen elektrotu, RL (right leg) sağ bacak üzerine yerleştirilen referans elektrotu ve LL (left leg) sol bacak üzerine yerleştirilen elektrotu temsil etmektedir. Bu elektrotlar, kalbin ürettiği elektriksel potansiyelleri algılar ve sinyal toplama sürecini başlatır.

Rezistör ve Sinyal Anahtarlama Devresi: Elektrotlar, vücudun farklı bölgelerinden elektriksel potansiyelleri ölçerken, deri direnci ve elektrot kontağı gibi nedenlerle empedans farklılıkları ve küçük voltaj kaymaları oluşabilir. Bu durum sinyal doğruluğunu olumsuz etkilediğinden, rezistörler empedans farklarını dengelemek için kullanılarak yükselteç devresine doğru bir giriş sağlanır. EKG sistemleri birden fazla elektrottan gelen sinyalleri alabilir ve anahtarlama devresi, bu sinyaller arasından belirli bir derivasyonu (örneğin, Lead I, II veya III) seçerek yalnızca istenen sinyalin işlenmesini sağlar. Aynı zamanda, çevresel elektromanyetik alanlardan kaynaklanan ortak mod sinyalleri (örneğin, 50/60 Hz şebeke parazitleri) de EKG sinyallerine karışabilir.

Rezistörler ve anahtarlama devresi, bu ortak mod bileşenlerini bastırarak yükseltece yalnızca iki elektrot arasındaki gerçek biyolojik fark sinyalini işlemesine olanak tanır ve bu süreçte amplifikatörlerin ortak mod reddetme oranı (CMRR) optimize edilir.

Yükselteç Devresi: Yükselteç devresi, elektrotlardan gelen milivolt düzeyindeki zayıf biyopotansiyel sinyalleri yükseltmek için kullanılır ve bu süreçte gürültüyü azaltmak ile sinyalin doğruluğunu korumak amacıyla yüksek giriş empedansına sahip bir fark yükselteci içerir. Bu yapı, sinyalin netliğini artırarak istenmeyen gürültüleri bastırırken, gerçek biyolojik potansiyellerin doğru bir şekilde işlenmesine olanak tanır.

Analog Filtreleme Devreleri: Analog sinyallerin dijital forma dönüştürülmesi işlemi öncesinde yapılan analog filtrelemeler, sinyalin gürültü ve artefaktlardan arındırılarak sayısallaştırma sürecine uygun hale getirilmesini sağlar. Bu aşamada, örtüşme durumunu (aliasing) önlemek için ADC'nin örnekleme frekansı, sinyaldeki en yüksek frekans bileşeninin en az iki katı olarak belirlenir ve yüksek frekanslı gürültüler analog düşük geçiren filtre ile bastırılır. Elektrot kontağı, kas hareketleri ve şebeke parazitlerinden kaynaklanan gürültülerin azaltılması, sinyalin doğruluğunu artırırken, yüksek genlikli gürültülerin ADC'yi saturasyona uğratmasını engellemek için dinamik aralık korunur. Kullanılan filtreler arasında, 0.5 Hz altındaki bazal çizgi dalgalanmalarını ortadan kaldıran yüksek geçiren filtre, 100–150 Hz üzerindeki kas artefaktları ve elektromanyetik girişimi bastıran düşük geçiren filtre ve 50/60 Hz şebeke parazitlerini hedefleyen notch filtre yer alır.

Analog Dijital Çevirici: Analog-dijital dönüştürme (ADC), analog bir sinyalin dijital sistemlerde işlenebilmesi için sayısal formata dönüştürülmesini sağlar ve EKG gibi biyopotansiyel sinyallerde kritik bir rol oynar. Bu işlem sırasında, sinyaldeki ince detayları yakalayabilmek için minimum 12-bit çözünürlük gereklidir ve daha yüksek çözünürlükler daha hassas analizlere olanak tanır. Örnekleme frekansı ise Nyquist teoremine uygun olarak belirlenir; sinyaldeki en yüksek frekansın en az iki katı kadar olmalı, aksi takdirde aliasing (örtüşme) problemi ortaya çıkar. ADC'nin doğru uygulanması, analog sinyalin kayıpsız ve doğru bir şekilde dijital formata aktarılmasını sağlayarak sinyalin analiz ve işleme aşamalarında güvenilir sonuçlar elde edilmesini mümkün kılar.

Dijital Sinyal İşleme: Dijital Sinyal İşleme (DSP) kısmı, analog-dijital çevirici (ADC) tarafından dijital formata dönüştürülen EKG sinyalinin analiz edilerek anlamlı hale getirildiği kritik bir aşamadır. Bu bölümde, sinyalin gürültü ve artefaktlardan arındırılması, bazal çizgi düzeltilmesi, dalga formu segmentasyonu ve aritmi tespiti gibi

işlemler gerçekleştirilir. Yüksek geçiren filtreler, düşük geçiren filtreler ve dijital notch filtreler kullanılarak sinyaldeki kalan gürültüler bastırılır ve daha ileri analiz için temiz bir sinyal elde edilir. İleri işaret işleme yöntemleri ile dijital sinyallerden sinyalleri karakterize edecek anlamlı özniteliklerin veya örüntülerin elde edilmesi sağlanır. Örneğin, Pan-Tompkins algoritması gibi yöntemlerle QRS kompleksi ve diğer EKG bileşenleri (P, T dalgaları) segmentlere ayrılır. Frekans eksenli analizler için Fourier dönüşümü ve dalgacık dönüşümü gibi teknikler uygulanırken, empirik mod ayrıştırma (EMD) ve adaptif filtreleme gibi ileri işaret işleme yöntemleri, sinyalin nonlinear özelliklerini çıkarır. Ayrıca, makine öğrenmesi sınıflandırma algoritmaları (örneğin, destek vektör makineleri veya yapay sinir ağları) kullanılarak, aritmi tespiti ve sinyal sınıflandırması yapılır. DSP, bu işlemlerle EKG sinyalinin klinik tanı ve analiz için kullanılacak detaylı parametrelerini çıkararak güvenilir bir değerlendirme sunar.

Veri Görüntüleme-Yazdırma ve Depolama: Dijitalleştirilen ve işlenen EKG sinyalleri, cihazın dahili belleğinde saklanabilir veya bulut tabanlı depolama sistemleri ve hastane bilgi yönetim sistemleri (HIS) gibi merkezi sunuculara aktarılabilir (Harun-Ar-Rashid vd., 2023). Verilerin DICOM veya HL7 gibi tıbbi standartlara uygun formatlarda kaydedilmesi, diğer sağlık verileriyle entegrasyonu ve paylaşımını kolaylaştırır (Ait Abdelouahid vd., 2023). Görselleştirme aşamasında, işlenen EKG sinyali monitörlerde gerçek zamanlı olarak görüntülenir, böylece dalga formları ve kalp ritmi sağlık uzmanları tarafından anında analiz edilebilir. Ayrıca, yazıcılar aracılığıyla kâğıt çıktılar alınarak fiziksel kayıtlar oluşturulur ve bu çıktılar, hasta raporları veya uzun süreli takiplere yönelik arşivleme için kullanılabilir. Bu süreçler, EKG verilerinin hem etkin bir şekilde analiz edilmesini hem de güvenli bir şekilde saklanmasını sağlar.

2.4. EKG'nin Klinik Sahada Kullanım Alanları

EKG, kardiyak elektriksel aktivitenin grafiğe dökülmesi yoluyla kalp sağlığını değerlendiren, tıbbın en temel tanı araçlarından biridir. Kalbin elektriksel uyarı üretme ve iletme fonksiyonlarının analizine dayanan EKG, kardiyovasküler bozuklukların tespitinde büyük önem taşır. Hem acil durumlarda hem de kronik hastalıkların izlenmesinde yaygın olarak kullanılır. Aşağıda EKG'nin klinikte nasıl bir rol oynadığı, çeşitli kardiyovasküler bozuklukların teşhis ve tedavisinde hangi amaçlarla kullanıldığı ayrıntılı bir şekilde ele alınmaktadır.

▪ **Aritmi Tanısı:** EKG, kalp ritmi bozuklukları (aritmiler) dahil olmak üzere kardiyovasküler hastalıkların teşhisinde temel bir araçtır. Sinüs düğümünün düzensiz çalışması, anormal elektriksel yollar veya diğer kardiyak iletim sistemi sorunları EKG üzerinde çeşitli örüntülerle gözlemlenebilir. Atrial fibrilasyon (AF), ventriküler taşikardi (VT), ventriküler fibrilasyon (VF), supraventriküler taşikardi (SVT), atrioventriküler blok (AV blok), bradikardi ve prematüre ventriküler kasılmalar (PVC) gibi aritmiler, kardiyovasküler hastalıkların tanısında ve tedavisinde önemli bir yer tutmaktadır (Kucia, 2022). Klinik pratikte, aritmilerin hızlı ve güvenilir tespiti, EKG'nin sağlayabileceği en kritik bilgilerin başında gelir.

▪ **Kalp Krizi ve İskemi Tespiti:** Miyokardiyal iskeminin veya akut miyokard enfarktüsünün (kalp krizi) erken teşhisi, hastaların hayatta kalma şansını doğrudan etkileyen bir faktördür. EKG, ST segmenti değişiklikleri ile miyokardiyal hasarı gözlemleyerek tanı koymada kilit bir rol oynar (Antman vd., 2004). ST segment elevasyonu genellikle akut enfarktüsün habercisi olup, acil müdahale gerektirir (Vogel vd., 2019). Ayrıca, ST segment depresyonu veya T dalgası inversiyonu, miyokardiyal iskemi göstergeleri olarak kabul edilir (Tan vd., 2013). Bu bulguların doğru bir şekilde yorumlanması, hastanın invaziv girişimlere yönlendirilip yönlendirilmemesi konusunda kritik bir rehberlik sağlar.

▪ **Kardiyak İletim Bozukluklarının Tanısı:** EKG, kalp kası hücrelerinin uyarılmasında ve iletilmesinde sorun olup olmadığını gösteren bir araçtır. AV bloklar, kalbin atriyumdan ventriküle geçen elektriksel iletisinde yavaşlama ya da kesilme ile kendini gösterir (Quin vd., 2011). İntraventriküler iletim gecikmeleri, QRS kompleksinin genişlemesiyle tespit edilir ve bu durum, genellikle sol dal bloğu gibi iletim bozukluklarının bir belirtisidir (Alboni, 2012). Bu tür iletim anomalilerinin teşhisi, tedavi planının oluşturulmasında önemli bir yer tutar.

▪ **Kalp Yetersizliğinin Takibi:** Kalp yetersizliği olan hastaların takibinde EKG yaygın olarak kullanılır. Sol ventrikül hipertrofisi gibi yapısal kardiyak değişiklikler, EKG yardımıyla değerlendirilebilir (Bacharova, 2022). Kronik kalp yetersizliği olan hastalarda görülen ventriküler aritmiler de EKG ile izlenebilir (Lo & Hsia, 2008). Bu hastaların EKG bulgularına dayalı izlenmesi, kalp fonksiyonlarının kötüleşmesinin erken dönemde tespit edilmesini sağlar ve bu sayede tedavi stratejilerinin optimize edilmesine olanak tanır.

▪ **Elektrolit Dengesizliklerinin Tespiti:** Kandaki elektrolit seviyelerindeki anormallikler, kalp kası hücrelerinin repolarizasyon ve depolarizasyon sürecini

etkileyerek EKG örüntülerinde değişikliklere neden olur (El-Sherif & Turitto, 2011). Hiperkalemi, sivri T dalgaları ve genişlemiş QRS kompleksleri ile ilişkilidir; hipokalemi ise U dalgalarının belirgin hale gelmesine yol açar (Teymouri vd., 2022). Elektrolit bozukluklarının EKG ile tespiti, bu dengesizliklerin hızlı bir şekilde düzeltilmesi için hayati öneme sahiptir, çünkü kalp krizi gibi ölümcül komplikasyonlar bu bozukluklarla ilişkilendirilebilir (Gruebl vd., 2021).

- **Preoperatif ve Postoperatif Değerlendirme:** EKG, cerrahi müdahale öncesi ve sonrasında hastanın kardiyak durumu hakkında bilgi sağlamak amacıyla sıkça kullanılır ve özellikle kardiyak risk faktörleri taşıyan bireylerde olası komplikasyonların değerlendirilmesi için kritik bir araçtır. Aynı şekilde, cerrahi müdahaleler sonrası dönemde EKG ile hastanın kalp ritmi ve fonksiyonları yakından izlenir, böylece potansiyel postoperatif kardiyak komplikasyonlar erken tespit edilebilir (Peretto vd., 2014).

- **İlaç Etkilerinin Takibi:** Kalp ilaçları, özellikle antiaritmik ilaçlar, kalbin elektriksel aktivitesini doğrudan etkileyebilir (Lei vd., 2018). EKG, bu ilaçların tedavi sırasında neden olduğu değişikliklerin izlenmesinde kullanılır. Örneğin, QT aralığının uzaması, bazı antiaritmik ilaçlar veya diğer ilaçların kardiyak yan etkilerini gösterebilir (Malik & Camm, 2001). Bu tür değişiklikler, ilacın dozu veya tedavi planının gözden geçirilmesi gerektiğinin işareti olabilir.

EKG'nin klinik kullanım alanları, geniş bir yelpazede kardiyak hastalıkların tanı ve tedavisini kapsar. Kalp ritim bozukluklarının tespitinden akut miyokardiyal enfarktüs tanısına, elektrolit dengesizliklerinden kalp yetersizliği takibine kadar pek çok kardiyovasküler bozukluğun izlenmesi ve yönetiminde kritik bir rol oynar (Singh vd., 2024). EKG'nin doğru yorumlanması, klinik kararların doğruluğunu artırır ve hastaların tedavi süreçlerinin optimize edilmesine katkıda bulunur.

2.5. Kardiyak Hastalıklar


Kardiyak hastalıklar, kalp ve damar sisteminin bozulması sonucu ortaya çıkan çeşitli durumları kapsamakta olup, dünya genelinde önemli sağlık sorunları arasında yer almaktadır. Bu hastalıklar arasında atriyal fibrilasyon, ventriküler aritmiler, supraventriküler aritmiler, füzyon aritmileri ve konjestif kalp yetmezliği dikkat çekmektedir (Bakshi vd., 2002). Bu bağlamda, kardiyak hastalıkların doğru bir şekilde teşhis edilmesi için EKG analizi büyük bir önem taşımaktadır. Özellikle atriyal

fibrilasyon, ventriküler aritmiler ve supraventriküler aritmiler gibi durumların tanısında, EKG'nin sağladığı ayrıntılı bilgiler, klinik karar verme süreçlerinde önemli bir rol oynamaktadır (Sahoo vd., 2020). EKG, hastalıkların ilerleyişinin izlenmesi ve tedavi sürecinin etkinliğinin değerlendirilmesi açısından da vazgeçilmez bir bileşen olarak kabul edilmektedir. Böylece, EKG analizi, kardiyak hastalıkların yönetiminde kritik bir öneme sahip olup, hastaların sağlık sonuçlarını iyileştirmeye katkıda bulunmaktadır.

2.5.1. Normal sinüs ritmi (NSR)

Normal sinüs ritmi (NSR), sağlıklı bir kalpte elektriksel uyarıların düzenli bir şekilde sinüs düğümünden kaynaklanarak atriyumlar ve ventriküller boyunca iletilmesiyle oluşan düzenli kalp ritmi olarak tanımlanır (Kashou vd., 2017). Dakikada 60-100 vuruş arasında seyreden NSR, kalbin koordineli bir şekilde kan pompalamasını sağlar. Sinüs düğümünden kaynaklanan bu uyarılar, atriyumların kasılmasına ve atriyoventriküler (AV) düğüm üzerinden ventriküllere geçişine olanak tanır (Plappert vd., 2024). EKG'de P dalgası, normal sinüs ritminin en belirgin göstergelerinden biridir ve düzenli bir P-QRS-T döngüsü normal bir kalp işleyişini yansıtır (Bhardwaj & Sivaraman, 2021).

NSR, kalbin hemodinamik olarak stabil çalışmasını sağlayan temel fizyolojik ritimdir. Ancak sinüs düğümündeki elektriksel iletimin bozulması ya da anormal uyarıların kalpte farklı bölgelerde oluşması, çeşitli aritmilerin gelişmesine neden olabilir (John & Kumar, 2016). Bu aritmiler, kalbin elektriksel aktivitesini bozarak kan akışını olumsuz yönde etkiler ve ciddi sağlık sorunlarına yol açabilir. Şekil 2.5'te MIT-BIH aritmi veri tabanından alınmış bir NSR sinyal örneği verilmiştir.



Şekil 2.5. NSR ait örnek sinyal


2.5.2. Atrial fibrilasyon (AF)

Atrial fibrilasyon (AF), kalbin üst odacıkları olan atriyumlarda meydana gelen ve elektriksel iletim sisteminin bozulması sonucu oluşan düzensiz ve genellikle hızlı kalp ritmi bozukluğudur (Friberg & Bergfeldt, 2013). Klinik olarak en sık karşılaşılan aritmi türlerinden biri olan AF, atriyumların düzensiz kasılmasına neden olur ve bu düzensizlik, ventriküllere kanın etkin şekilde iletilmesini engeller. Bu durum, kalbin pompalama fonksiyonunu bozarak atriyumlarda kan durgunluğuna ve pıhtı oluşumuna yol açabilir; bu pıhtılar, beyine ulaşarak iskemik inmeye neden olabilen, AF'nin ciddi komplikasyonlarından biridir (Björck vd., 2013).

Atrial fibrilasyonun etiyolojisi (nedenleri) oldukça karmaşıktır. Hipertansiyon, diyabet, koroner arter hastalığı ve kalp kapak hastalıkları gibi kardiyovasküler rahatsızlıklar, AF'nin gelişiminde önemli bir rol oynar (Liang & Wang, 2021). Ayrıca yaş, genetik faktörler ve yaşam tarzı da bu bozukluğun oluşumunu etkileyebilir (Sagris vd., 2021). AF'nin tedavi stratejileri, hastalığın şiddeti ve semptomlarına göre değişiklik gösterir. Yaygın tedavi yöntemleri arasında:

- **Antiaritmik ilaçlar:** Kalp ritmini düzenlemeye yönelik ilaçlar.
- **Antikoagülanlar:** Kanın pıhtılaşmasını önleyen ilaçlar, özellikle inme riskini azaltmak için kullanılır.
- **Ritim kontrolü:** Elektriksel kardiyoversiyon ile kalbin normal ritme döndürülmesi.
- **Kateter ablasyonu:** Kalpteki anormal elektriksel yolların yok edilmesi için uygulanan invaziv bir tedavi yöntemidir.

Son yıllarda yapılan geniş çaplı araştırmalar, atrial fibrilasyonun uzun vadeli sağlık sonuçları hastalık (morbidite) ve ölüm (mortalite) oranlarını önemli ölçüde artırdığını ortaya koymaktadır (Rahman & Özkısacık, 2024). Klinik olarak en etkili tedavi yöntemlerinin belirlenmesi üzerine tartışmalar devam etmektedir. Aşağıda Şekil 2.6'da AF'li bir bireye ait MIT-BIH aritmi veri tabanından alınan EKG sinyali gösterilmektedir.



Şekil 2.6. Atrial fibrilasyon (AF)'li bir bireye ait örnek EKG sinyali


2.5.3. Ventriküler aritmi (VA)

Ventriküler aritmiler, kalbin alt odacıkları olan ventriküllerden kaynaklanan hızlı ve düzensiz kalp ritmi bozukluklarıdır ve genellikle ciddi kardiyak olaylarla ilişkilidir (Dresen & Ferguson, 2018). Bu aritmi grubunun iki ana alt tipi ventriküler taşikardi (VT) ve ventriküler fibrilasyon (VF)'dir. Ventriküler Taşikardi (VT), ventriküllerin hızlanmış ancak düzenli bir ritimle atması durumudur (Alwan vd., 2018). VT, kalbin etkili bir şekilde kan pompalamasını zorlaştırabilir ve tedavi edilmezse ventriküler fibrilasyona dönüşebilir (Koplan & Stevenson, 2009). Ventriküler Fibrilasyon (VF), ventriküllerin düzensiz ve koordinasyonsuz kasılmasıdır. VF, kalbin durmasına ve ani kardiyak ölüme yol açabilecek en tehlikeli aritmi türlerinden biridir. Acil müdahale gerektirir ve çoğu durumda defibrilasyon uygulanması zorunludur.

Bu aritmiler genellikle iskemik kalp hastalıkları, kardiyomiyopatiler ve miyokard enfarktüsü gibi klinik durumlarla ilişkili olarak ortaya çıkar (Keller & Halperin, 2015). Tedavi yaklaşımları, aritminin tipine ve ciddiyetine bağlı olarak değişiklik gösterir. En yaygın tedavi yöntemleri arasında şunlar yer alır:

- **Farmakoterapi:** Aritminin kontrol altına alınması için kullanılan ilaçlar.
- **Defibrilasyon:** Özellikle VF'de, kalbin normal ritmine döndürülmesi için kullanılan bir elektriksel şok yöntemi.
- **İmplant edilebilir kardiyoverter-defibrilatör (ICD):** Cihaz, ventriküler aritmi algılandığında otomatik olarak defibrilasyon yapar.
- **Ablasyon:** Anormal elektriksel yolların yok edilmesi amacıyla yapılan bir girişimdir.

Aşağıdaki Şekil 2.7'de MIT-BIH Aritmi veri tabanından alınmış ventriküler aritmi (VA) hastası bir bireye ait EKG atımı örneği gösterilmektedir.



Şekil 2.7. Ventriküler aritmi (VA) hastası bir bireye ait örnek EKG sinyali

2.5.4. Supraventriküler aritmi (SVA)

Supraventriküler aritmiler (SVA), kalbin üst odacıkları olan atriyumlar veya atriyoventriküler düğümden kaynaklanan anormal elektriksel iletim bozukluklarıdır (Cossu & Steinberg, 1998). Bu aritmi türleri, kalbin ventriküllerinden değil, daha çok atriyum ya da atriyoventriküler düğümden kaynaklandığı için genellikle ventriküler aritmilere göre daha az ölümcül seyrederler (Wellens, 2007). Ancak, hastalarda çarpıntı, baş dönmesi, nefes darlığı ve bazen bayılma gibi semptomlar ortaya çıkarak yaşam kalitesini önemli ölçüde düşürebilirler (Helton, 2015).


Supraventriküler aritmiler arasında en sık rastlanan formlar, atriyoventriküler nodal reentry taşikardi (AVNRT) ve atriyal taşikardi (AT)'dir (Sohinki & Obel, 2014). AVNRT, atriyoventriküler düğümde elektriksel bir "geri dönüş" döngüsünün oluşmasıyla karakterize edilir ve genellikle aniden başlayan ve sonlanan taşikardi epizodlarına neden olur (Katrissis & Becker, 2007). AT ise, atriyumlarda ortaya çıkan anormal elektriksel sinyallerle karakterize olup, kalbin hızlı ve düzenli bir şekilde atmasına yol açar (Roberts-Thomson vd., 2005).

EKG bulguları açısından SVA, genellikle dar QRS kompleksleri ile kendini gösterir, çünkü bu aritmi türleri ventriküllerin hızlı ve düzensiz kasılmalarına yol açmaz (Wellens, 2007b). Tanı genellikle klinik belirtiler ve EKG analizine dayanarak konur. Tedavi stratejileri hastanın semptomlarının ciddiyetine ve aritminin sıklığına bağlı olarak değişiklik gösterir. Akut tedavi aşamasında:

- **Vagal manevralar:** Kalp hızını yavaşlatmak için kullanılan basit refleks tedavi yöntemleridir.

- **Adenozin:** Hızlı kalp ritmini geçici olarak yavaşlatmak için intravenöz olarak uygulanan bir ilaçtır. Uzun vadeli tedavi ise, nüks eden ve semptomatik vakalarda, genellikle kateter ablasyonu ile yapılır. Bu yöntem, aritmiye yol açan anormal elektriksel yolların yok edilmesini amaçlayan invaziv bir işlemdir.

Literatürde, supraventriküler aritmilerin genellikle “benign” (iyi huylu) bir seyir izlediği belirtilir (Whinnett vd., 2012). Ancak, sık tekrar eden vakalarda invaziv tedavi yöntemlerinin tercih edilmesi önerilmektedir. Özellikle, ablasyon tedavisi, yüksek başarı oranı ve düşük komplikasyon riski nedeniyle nüks eden vakalarda tercih edilen bir yöntem olarak öne çıkmaktadır (Williams vd., 2020). Aşağıdaki Şekil 2.8’de MIT-BIH Aritmi veri tabanından alınmış supraventriküler aritmi (SVA) hastasına ait bir EKG kaydı örneği gösterilmektedir.




Şekil 2.8. Supraventriküler aritmi (SVA) hastası bir bireye ait örnek EKG sinyali

2.5.5. Füzyon aritmisi (FA)

Füzyon aritmisi, ektopik bir odaktan gelen ventriküler uyarı ile doğal sinüs ritminin aynı anda ventrikülleri aktive etmesi sonucu ortaya çıkan, nadir görülen bir ritim bozukluğudur (Nabar vd., 2000). Füzyon dalgaları, EKG’de birbirine karışmış bir QRS kompleksi ile kendini gösterir ve genellikle ventriküler taşikardinin varlığını işaret eder. Tanı süreci, dikkatli bir EKG analizi gerektirir, çünkü füzyon aritmileri başka ciddi aritmilerin bir göstergesi olabilir. Tedavi stratejisi, altta yatan ritim bozukluğuna göre belirlenir ve genellikle ventriküler aritmi tedavileri ile paralellik gösterir (Nlker vd.,

2011). Şekil 2.9’da MIT-BIH Aritmi veri tabanından alınmış FA hastası bir bireye ait EKG atımı verilmiştir.



Şekil 2.9. Füzyon aritmi (FA) hastası bir bireye ait örnek EKG sinyali


2.5.6. Konjestif kalp yetmezliği (KKY)

Konjestif kalp yetmezliği (KKY), kalbin vücuda gerekli miktarda kanı pompalama yetisinin yetersiz kaldığı kronik ve progresif bir hastalık olarak tanımlanır (Ramani vd., 2010). KKY, genellikle sol ventrikül işlev bozukluğu ile ilişkilendirilir ve iki ana mekanizma üzerinden gelişir: sistolik disfonksiyon (kalbin kasılma gücünün azalması) ve diyastolik disfonksiyon (ventriküllerin dolma kapasitesinin bozulması) (Galderisi, 2005). Sistolik disfonksiyonda kalbin kasılma gücü azalırken, diyastolik disfonksiyonda ventriküller yeterince gevşeyip dolamaz; her iki durumda da dokulara yeterli kan ve oksijen sağlanamaması semptomlara yol açar (Borlaug & Kass, 2006).

KKY’nin klinik seyrinde, ilerleyen aşamalarda pulmoner konjesyon (akciğerlerde sıvı birikimi), periferik ödem (ayak bileklerinde şişme), dispne (nefes darlığı) ve yorgunluk gibi belirtiler ortaya çıkar (Koshy vd., 2020). Hastalar bu aşamada günlük aktiviteleri yerine getirmekte zorlanır ve yaşam kaliteleri belirgin bir şekilde düşer. Literatürde, KKY 'nin küresel ölçekte prevalansının (yaygınlık) arttığı vurgulanmaktadır (Savarese vd., 2023). Kalp yetmezliği, özellikle ileri yaşlardaki bireylerde sık görülmekte ve morbidite (bireylerin hastalıklardan etkilenme oranı) ile mortalite (ölüm oranı) oranlarında ciddi bir artışa yol açmaktadır (Dharmarajan & Rich, 2017). Yetersiz tedavi veya hastalığın ilerlemesi durumunda, KKY hastalarında yaşam süresi önemli ölçüde kısalabilir.

Son yıllarda, KKY'nin klinik yönetiminde EKG analiz çalışmalarının önemi artmıştır. EKG, kalp ritmi ve elektriksel aktiviteyi sürekli izleyerek KKY'nin erken

teşhisinde ve izlenmesinde etkili bir araç sunar. Elektrokardiyografi (EKG), KKY hastalarında ventriküler disfonksiyon ve aritmi gibi riskli durumların tespitinde kullanılarak tedaviye yönelik kararların daha doğru ve hızlı bir şekilde alınmasını sağlar (Jahmunah vd., 2019). Klinik EKG analizleri, hastaların durumunun ciddiyetini değerlendirmeye yardımcı olurken, kalp ritmi bozukluklarını izleyerek hastaların uzun dönemli prognozunu(tedavi süreci) iyileştirme potansiyeline sahiptir. Bu bağlamda, KKY'nin tedavi ve yönetiminde kapsamlı ve bireyselleştirilmiş yaklaşımlar hastaların tedavi süreçlerini olumlu yönde etkilemekte ve EKG analizlerinin sağladığı klinik katkılar, bu süreçte önemli bir rol oynamaktadır. Şekil 2.10'da MIT-BIH Aritmi veri tabanından alınmış KKY hastası bir bireye ait örnek EKG atımı verilmiştir.



Şekil 2.10. KKY hastası bir bireye ait örnek EKG sinyali

3. LİTERATÜR

Literatürde, aritmi ve diğer kardiyak hastalıkların teşhisine yönelik yapılan EKG analizleri, karmaşık bir süreç içermekte olup, genellikle üç temel aşamada ele alınmaktadır. İlk aşama, ham EKG sinyallerinin dış etkenler ve donanımsal kaynaklı gürültülerden arındırılmasıdır. Bu aşamada, sinyallerin temizlenmesi amacıyla çeşitli dijital filtreleme teknikleri uygulanmakta, düşük ve yüksek frekanslı parazitler, elektriksel parazitlenmeler ve kas hareketlerinden kaynaklanan gürültüler yok edilmektedir. Yaygın olarak kullanılan yöntemler arasında Butterworth, Chebyshev ve dijital dalgacık dönüşümleri gibi filtreleme algoritmaları bulunmaktadır (Podder vd., 2020). Bu işlem, sinyalin daha sonra işlenecek olan kritik bileşenlerinin net bir şekilde korunmasını sağlamaktadır.

İkinci aşamada, sinyallerin karakterize edilmesi ve sınıflandırma aşaması için kullanılacak özniteliklerin çıkarılması süreci gerçekleştirilmektedir. Bu adımda, zaman ve frekans tabanlı analiz yöntemleri ile sinyallerin matematiksel ve istatistiksel özellikleri elde edilmektedir. QRS kompleksi, P ve T dalgalarının zamanlama ve genlik değerleri gibi kardiyak ritmi temsil eden önemli özellikler bu aşamada öne çıkmaktadır. Ayrıca, istatistiksel yöntemler, sinyaldeki varyans, ortalama, enerji ve entropi gibi özellikleri hesaplayarak hastalıklara özgü örüntülere dair bilgi sağlar (Kutlu & Kuntalp, 2012). Öznitelik çıkarımında, dalgacık dönüşümleri, Fourier dönüşümleri ve zaman-frekans analizleri de sıkça başvurulan yöntemlerdendir (Tekin & Kaya, 2024).

Son aşama ise, elde edilen özniteliklerin makine öğrenmesi ve yapay zeka teknikleri ile sınıflandırılmasıdır. Burada, en uygun sınıflandırıcı algoritmanın seçilmesi ve modelin optimize edilmesi büyük önem taşır. Destek vektör makineleri (SVM), yapay sinir ağları (ANN), karar ağaçları ve derin öğrenme teknikleri gibi yöntemler, EKG verilerini sınıflandırmak için sıkça kullanılmaktadır (Mohebbanaaz vd., 2022). Modelin doğruluğunu artırmak amacıyla parametre optimizasyonu, çapraz doğrulama ve hiperparametre ayarlamaları gibi süreçler uygulanmaktadır (Pfob vd., 2022). Bunun yanında, sınıflandırma işleminin yalnızca yüksek başarı oranına sahip olması yeterli olmayıp, aynı zamanda işlem süresi ve hesaplama maliyetlerinin de makul düzeyde tutulması gerekmektedir. Böylelikle, modelin gerçek zamanlı klinik uygulamalarda kullanımı mümkün hale gelebilir.

Tüm bu aşamalar göz önüne alındığında, EKG sinyallerine dayalı kardiyak hastalık teşhis modellerinde temel motivasyon, teşhis doğruluğunu artırırken, hesaplama

maliyetlerini en aza indirmek ve sistemin genel performansını iyileştirmek. Literatürdeki çalışmalar, yüksek doğruluk oranına sahip, aynı zamanda hesaplama verimliliği yüksek algoritmaların geliştirilmesine odaklanmıştır. Bu denge, gelecekteki araştırmalarda da kritik bir rol oynamaya devam edecektir .

Acharya vd. (2019), konjestif kalp yetmezliğinin (KKY) tanısında kullanılmak üzere, 11 katmanlı bir evrişimli sinir ağı (CNN) modeli geliştirmişlerdir. Bu model, geleneksel yöntemlerin aksine, EKG sinyallerinin ön işlem adımlarını minimum düzeyde tutarak, daha az veri hazırlığı gerektiren bir çözüm sunmaktadır. Ayrıca, karmaşık matematiksel algoritmalarla manuel olarak öznitelik çıkarımı yapılmasına gerek duymadan, sinir ağının ham EKG sinyallerinden doğrudan öğrenebilme kapasitesi sayesinde yazılım üzerindeki işlem yükünü büyük ölçüde azaltmaktadır. Araştırmacıların geliştirdiği bu CNN modeli, %98.97 gibi son derece yüksek bir doğruluk oranıyla, kardiyak hastalıkların tanısında kayda değer bir başarıya ulaşmış ve modern tıbbi teşhis yaklaşımlarında önemli bir potansiyel sunmuştur.

Afkhami vd. (2016), kardiyak aritmilerin hassas bir şekilde sınıflandırılması için yenilikçi bir yöntem sunmuşlardır. Bu çalışmada, bireysel kalp atımlarının morfolojik ve istatistiksel özellikleri kullanılarak sınıflandırıcı eğitilmiştir. Zaman tabanlı bilgileri temsilen iki RR aralığı özelliği bu çalışmada yer almıştır. Kalp atımlarının olasılık yoğunluk fonksiyonunu modellemek için Gauss karışım modeli (GMM) ve geliştirilmiş bir beklenti eniyileme (EM) algoritması kullanılmıştır. GMM parametrelerinin yanı sıra çarpıklık, basıklık ve 5. moment gibi şekil parametreleri de öznitelik vektörüne dahil edilmiştir. Bu zenginleştirilmiş öznitelikler daha sonra bir karar ağaçları topluluğunu eğitmek için kullanılmıştır. Çeşitli yaygın aritmi türlerini içeren MIT-BIH aritmi veritabanı, önerilen algoritmayı test etmek için kullanılmıştır. Deneylerde, yöntem "sınıf odaklı" değerlendirme şemasında %99,70, "konu odaklı" değerlendirme şemasında ise %96,15 doğruluk oranlarına ulaşmıştır. Her iki durumda da bu sonuçlar mevcut yöntemlere kıyasla önemli bir doğruluk artışı sağlamıştır.

Akdağ vd. (2022), EKG sinyallerinin sınıflandırılması için, tek boyutlu yerel ikili desen (1D-DS-LBP) tekniklerini Uzun Kısa Süreli Bellek (LSTM) ağlarıyla birleştiren yenilikçi bir yöntem önermiştir. 1D-DS-LBP yöntemi, komşu veri noktaları arasındaki büyüklük ilişkilerini analiz etmeye odaklanmaktadır. EKG sinyalleri aşağı örnekleme yapılarak, elde edilen sinyal gruplarından hesaplanan bir boyutlu yerel ikili desenlerin (1D-LBP) histogramları oluşturulmakta ve bu histogramlar LSTM modeline girdi referansları olarak kullanılmaktadır. LSTM mimarisi, 1D-DS-LBP ile dönüştürülen EKG

sinyallerine hem tek yönlü hem de çift yönlü yapılandırmalarla uygulanmıştır. Bu çalışmada, MIT-BIH ve BIDMC veri tabanlarından elde edilen 972 EKG sinyaline, kongestif kalp yetmezliği (KKY), aritmi (ARR) ve normal sinüs ritmi (NSR) gibi üç farklı durum temsili kullanılarak test edilmiştir. Elde edilen sonuçlar, önerilen yönteminin %96,80 ile %99,79 arasında değişen sınıflandırma doğruluklarıyla, literatürdeki yöntemlere kıyasla önemli ölçüde daha yüksek performans gösterdiğini ortaya koymuştur. Bu bulgular, önerilen yaklaşımın tıbbi alanda geniş kapsamlı uygulamalar için yüksek bir potansiyele sahip olduğunu göstermektedir.

Çınar ve Tuncer (2021), kongestif kalp yetmezliği ve aritmi hastalarına ait EKG verilerini sağlıklı bireylerle karşılaştırmak amacıyla yeni bir hibrit derin öğrenme modeli geliştirmişlerdir. Bu model, 8 katmanlı bir Evrişimsel Sinir Ağı (CNN) olan AlexNet yapısını, sınıflandırma görevinde başarılı bir makine öğrenme yöntemi olan SVM ile entegre ederek hibrit bir yapı oluşturmuştur. Geliştirilen yöntem, EKG verilerinin sınıflandırılmasında spektrogram görüntülerini kullanmış ve %96.77 gibi dikkat çekici bir doğruluk oranı elde etmiştir. Ayrıca, bu hibrit modelin performansı, aynı veri setleri üzerinde uygulanan geleneksel sınıflandırma algoritmaları olan SVM, K-En Yakın Komşu (KNN) ve Uzun Kısa Süreli Bellek (LSTM) yöntemleri ile de karşılaştırılmıştır. Bu karşılaştırmalar sonucunda, SVM %68.75, KNN %65.63 ve LSTM ise %90 doğruluk oranlarına ulaşmış, ancak önerilen hibrit model bu yöntemlere kıyasla üstün bir performans sergileyerek daha etkili bir sınıflandırma sağlamıştır. Bu çalışma, kardiyak hastalıkların teşhisinde derin öğrenme tabanlı hibrit modellerin potansiyelini vurgulamaktadır.

Dang vd. (2019), EKG sinyallerini kullanarak atriyal fibrilasyon (AF) kalp atışlarının otomatik tespiti için yeni bir derin öğrenme yaklaşımı olan derin CNN-Bİ-LSTM ağ modelini tanıtmaktadırlar. Model, dört konvolüsyonel katman, iki adet Çift Yönlü Uzun Kısa Süreli Bellek (Bİ-LSTM) katmanı ve iki tam bağlı katmandan oluşmaktadır. Çalışmada iki tür veri seti kullanılmıştır: RR aralıkları (set A) ve P-QRS-T dalgalarından oluşan kalp atışları dizileri (set B). Önerilen yöntem, set A için eğitim setinde %99.94 ve doğrulama setinde %98.63 doğruluk oranları ile oldukça olumlu bir performans sergilemiştir. Görülmemiş veriler içeren test setinde ise model %96.59 doğruluk, %99.93 duyarlılık ve %97.03 özgüllük elde etmiştir. Bu sonuçlar, önerilen algoritmanın birçok güncel yöntemden daha üstün performans gösterdiğini ve AF'nin otomatik tespiti için etkili bir çözüm sunduğunu göstermektedir.

Darmawahyuni vd. (2020), konjestif kalp yetmezliği (KKY) hastaları ile sağlıklı bireylerin EKG verilerini sınıflandırmayı amaçlayan çalışmalarında, sinyal gürültüsünü azaltmak ve sınıflandırma performansını artırmak amacıyla ayırık dalgacık dönüşümünü (DWT) kullanarak EKG sinyallerini gürültüden arındırmışlardır. Gürültüden temizlenen bu sinyaller, daha etkili bir sınıflandırma elde edebilmek amacıyla ilk olarak 5 ve 15 dakikalık segmentlere bölünmüş, ardından uygun bir ölçekle normalize edilmiştir. Bu ön işleme adımlarının ardından, sınıflandırma işlemi için geri beslemeli bir sinir ağı yapısı olan RNN-LSTM (Tekrarlayan Sinir Ağı - Uzun Kısa Süreli Bellek) mimarisi kullanılarak derin öğrenme algoritması uygulanmıştır. Çalışmanın sonuçları, önerilen yöntemle %99'un üzerinde bir sınıflandırma doğruluğuna ulaşıldığını ortaya koymuş ve bu yöntemin KKY tanısında yüksek performans sergileyen bir çözüm sunduğunu göstermiştir. Bu sonuçlar, ayırık dalgacık dönüşümü ve derin öğrenme tabanlı yaklaşımların kardiyolojik verilerin işlenmesinde sunduğu potansiyeli vurgulamaktadır.

Daydulo vd. (2023), EKG sinyallerini kardiyak aritmi (ARR), konjestif kalp yetmezliği (KKY) ve normal sinüs ritmi (NSR) gibi üç ana kategoriye otomatik olarak sınıflandırabilen bir derin öğrenme modeli geliştirmeyi hedeflemiştir. Bu hedef doğrultusunda, PhysioNet platformundan erişilebilen MIT-BIH ve BIDMC veri setlerinden elde edilen EKG verileri, ön işleme adımına tabi tutulmuş ve derin öğrenme modelinin eğitimi için segmentlere ayrılmıştır. Çalışmada, ResNet 50 ve AlexNet gibi önceden eğitilmiş modeller, en iyi sınıflandırma sonuçlarını elde etmek amacıyla ince ayar yapılmış ve optimize edilmiştir. Modelin performansını değerlendirmek için F ölçütü, hatırlama, kesinlik, duyarlılık, özgüllük ve doğruluk gibi kriterler kullanılarak çok sınıflı bir karmaşıklık matrisinden elde edilen ölçütler belirlenmiştir. Önerilen derin öğrenme modeli, test verileri üzerinde %99,2 genel sınıflandırma doğruluğu, %99,2 ortalama duyarlılık, %99,6 ortalama özgüllük ile %99,2 ortalama hatırlama, kesinlik ve F ölçütü değerlerine ulaşmıştır. Bu çalışma, aritmi sınıflandırmasına yönelik sağlam bir yaklaşım sunmakta olup, mevcut en son sistemlerle kıyaslandığında, EKG sinyallerinin görsel analizinde ortaya çıkan teşhis süresi ve hata oranlarını önemli ölçüde azaltma potansiyeline sahiptir.

Dhyani vd. (2023), EKG sinyallerinin analizi ve karakterizasyonu için 3-D Süreksiz Dalga Dönüşümü (DWT) ve Destek Vektör Makinesi (SVM) kullanmaktadır. Çalışma, EKG sinyal ön işleme, özellik çıkarımı ve EKG sinyallerinin sınıflandırılması olmak üzere üç aşamadan oluşmaktadır. 3-D dalgacık dönüşümü, gürültü azaltma ve dalga katsayılarının çıkarımını içeren bir ön işleme tekniği olarak görev yapmaktadır. Bu

çalışmada, SVM, EKG sinyallerini dokuz farklı kalp atış tipine sınıflandırmak için kullanılmaktadır. Çalışmada, Çin Fizyolojik Sinyal Yarışması (CPSC) 2018 aritmi veri seti kullanılarak yaklaşık 6400 EKG atışı incelenmiştir. Sınıflandırmada en yüksek doğruluk, Symlet-8 (Sym8) dalgası ile 4. seviye dalga katsayıları kullanılarak elde edilmiştir. SVM sınıflandırıcısı, CPSC 2018 veri setinde ortalama %99.02 doğruluk oranı sağlamış; bu sonuç, karmaşık destek vektör makinesi (CSVM) %98.5 ve ağırlıklı destek vektör makinesi (WSVM) %99 doğruluk oranlarını geride bırakmıştır.

Elhaj vd. (2016), EKG verilerinin aritmi tespiti için sınıflandırılmasında doğruluğu artırmak amacıyla doğrusal ve doğrusal olmayan özniteliklerin birleştirilmesinin etkinliğini incelemiştir. Çalışmada, Tıbbi Cihazların Geliştirilmesi Derneği (AAMI) tarafından önerilen beş aritmi atım sınıfı analiz edilmiştir: non-ektopik atımlar (N), supraventriküler ektopik atımlar (S), ventriküler ektopik atımlar (V), füzyon atımları (F) ve sınıflandırılmayan veya pille çalışan atımlar (U). Araştırmada, yüksek dereceli istatistikler ve dağılım parametreleri gibi doğrusal olmayan öznitelikler ile bağımsız bileşen analizi (ICA) gibi öznitelik azaltma yöntemleri, doğrusal özniteliklerle (özellikle, ayrık dalgacık dönüşümüne (DWT) uygulanan temel bileşen analizi (PCA)) birleştirilmiştir. Bu birleştirilmiş öznitelikler, destek vektör makineleri (SVM) ve yapay sinir ağları gibi sınıflandırıcılarla, on katlı çapraz doğrulama yöntemi kullanılarak değerlendirilmiştir. Önerilen yöntem, destek vektör makineleri ve radyal baz fonksiyonu (RBF) yöntemlerinin kombinasyonu ile %98,91 gibi yüksek bir sınıflandırma doğruluğu elde etmiştir.

Eltrass vd. (2021), konjestif kalp yetmezliği (KKY), aritmi (ARR) ve normal sinüs ritmi (NSR) EKG verilerini analiz etmek amacıyla, yenilikçi bir derin öğrenme yaklaşımı geliştirmişlerdir. Bu yaklaşım, sabit-q kararsız Gabor dönüşümünü (CQ-NSGT) ve evrişimli sinir ağı (CNN) modelini bir araya getirerek, EKG sinyallerinin zaman-frekans temsiline dönüştürülmesini sağlamaktadır. CQ-NSGT, EKG verilerini yüksek çözünürlüklü bir zaman-frekans temsiline dönüştürerek, sinyallerin özelliklerini daha etkin bir şekilde yakalamakta ve bu temsil, önceden eğitilmiş olan AlexNet CNN modeline verilmiştir. Elde edilen sonuçlar, modelin %98,82 gibi yüksek bir doğruluk oranı ile başarılı bir performans sergilediğini göstermektedir. Bu çalışma, derin öğrenme ve gelişmiş sinyal işleme tekniklerinin kardiyolojik verilerin analizi konusundaki potansiyelini vurgulamakta ve EKG sinyallerinin daha doğru bir şekilde sınıflandırılmasına önemli bir katkı sağlamaktadır.

Essa ve Xie (2021) çalışmasında, EKG sinyallerinin farklı aritmi türlerine göre sınıflandırılması amacıyla derin öğrenmeye dayalı çok modellenli bir sistem geliştirilmiştir. Yazarlar, iki farklı “*bagging*” modelini tanıtmaktadır: CNN-LSTM, yerel özellikleri ve EKG verilerindeki zamansal dinamikleri yakalamak için Konvolüsyonel Sinir Ağlarını (CNN) ve Uzun Kısa Süreli Bellek ağlarını (LSTM) birleştirirken, RRHOS-LSTM, LSTM ile RR aralıkları ve yüksek mertebeden istatistikler (HOS) gibi klasik özellikleri kullanarak anormal kalp atışlarını vurgulamaktadır. Veri setindeki aritmi sınıflarının dengesiz dağılımını ele almak için her iki model, alt örnekleme ve düşük temsil edilen sınıflara daha yüksek ağırlık atayan ağırlıklı kayıp fonksiyonları kullanılarak eğitilmiştir. Her iki modelin tahminleri, tam bağlantılı ileri beslemeli bir sinir ağı olan meta-sınıflandırıcı aracılığıyla birleştirilmiştir. Son olarak, bu sınıflandırma çıktısı, yanlış pozitifleri azaltmak amacıyla başka bir CNN-LSTM modeli ile rafine edilmiştir. MIT-BIH aritmi veri tabanı üzerinde yapılan deneysel değerlendirmeler, sistemin etkinliğini ortaya koymuş ve %95.81’lik bir doğruluk oranı elde edilmiştir. Ayrıca, F1 skoru ve pozitif öngörü değeri açısından da sistem, diğer güncel yöntemlere göre sırasıyla %3 ve %8 oranında üstünlük sağlamıştır.

Falaschetti vd. (2022), EKG verileri üzerinde doğrudan çalışan tekrarlayan sinir ağlarına (RNN) dayalı bir aritmi sınıflandırma algoritması önermektedir. Çalışma, RNN mimarisinin farklı katman türlerini kullanarak ağ belleğini uygulama yollarını araştırmakta ve bu mimarilerin etkinliğini ve verimliliğini değerlendirmektedir. Araştırmada MIT-BIH aritmi veri tabanı ve Tıbbi Aletlerin Geliştirilmesi Derneği (AAMI) tarafından önerilen değerlendirme protokolü kullanılmaktadır. Farklı ağ yapılarının tasarımı ve etkinliği test edildikten sonra, bu modellerin gömülü bir platforma aktarılabilirliği de incelenmiştir. Bu amaçla, ST firmasına ait STM32 mikrodenetleyici mimarisi kullanılmış ve önceden oluşturulmuş RNN modelleri, platforma özgü optimize edilmiş koda dönüştürülerek, kaynak kullanım performansı değerlendirilmiştir. Sonuçlar, temel RNN modelinin bellek kullanımı, parametre sayısı ve çıkarım süresi açısından diğer mimarilere göre üstün olduğunu göstermektedir. Bununla birlikte, LSTM tabanlı RNN modeli, en yüksek doğruluk oranını (%90) elde ederek, daha fazla kaynak kullanmasına rağmen en başarılı model olarak öne çıkmıştır.

Faust ve Acharya (2021), RR interval sinyalleri kullanarak aritmilerin tespitine yönelik yeni bir yaklaşım sunmaktadır. Araştırmada, normal sinüs ritmi (NSR) ile beş farklı aritmi türünü ayırt etmeyi amaçlayan bir derin öğrenme algoritması geliştirilmiştir. Model, 10.093 katılımcıdan elde edilen verilerle eğitilmiş ve 10 katlı çapraz doğrulama

ile performansı değerlendirilmiştir. Altı sınıflı sınıflandırma problemi için algoritmanın genel doğruluk oranı %98,37 olarak belirlenmiştir. Aritmiyi, beş farklı aritmi türünü NSR ile birleştirerek tanımlayan ikili sınıflandırma senaryosunda ise, model %98,55 doğruluk, %99,40 duyarlılık ve %94,30 özgüllük değerlerine ulaşmıştır. Bu sonuçlar, modelin Supraventriküler Taşikardi (SVT), Sinüs Taşikardisi (ST), Sinüs Bradikardisi (SB), Atriyal Fibrilasyon (AF), Atriyal Flutter (AFL) ve NSR ile ilişkili RR interval dizilerini yüksek doğrulukla ayırt edebileceğini göstermektedir. Ayrıca, önerilen algoritmanın aritmilerin varlığı konusunda güvenilir ve bağımsız bir ikinci görüş sunma potansiyeli, klinik karar verme süreçlerini güçlendirebilir.

Gutiérrez-Gnecchi vd. (2017), normal sinüs ritmi, atriyal fibrilasyon, erken kulakçık atımı, sol dal bloğu, sağ dal bloğu, erken karıncık atımı, sinoatrial kalp bloğu ve süpraventriküler taşikardi gibi sekiz farklı EKG kaydını sınıflandırmayı amaçlayan kapsamlı bir çalışma gerçekleştirmişlerdir. Bu çalışma, MIT-BIH Aritmi veri tabanından seçilen toplam 900 atım üzerinde yapılmış olup, ön işleme aşamasında EKG sinyallerine bant geçiren filtre uygulanarak gürültü ve istenmeyen bileşenlerin etkisi azaltılmıştır. Özellik çıkarımı işlemi için ise Kuadratik (2. dereceden) Dalgacık Dönüşümü kullanılarak, sinyallerin önemli özellikleri belirlenmiş ve bu özellikler, sınıflandırma aşamasında kullanılmak üzere hazırlanmıştır. Sınıflandırma işlemi sırasında Olasılıksal Sinir Ağları (PSO) modeli tercih edilmiştir. Elde edilen sonuçlar, genel sınıflandırma oranının %92.746 ile %100 arasında değişkenlik gösterdiğini ortaya koyarak, önerilen yöntemlerin EKG kaydı sınıflandırmasında etkili bir performans sergilediğini göstermektedir. Bu çalışma, kardiyolojik sinyallerin analizi ve sınıflandırılması alanında önemli bir katkı sağlamaktadır.

Hadiyoso ve Rizal (2017), EKG sinyallerinin özelliklerini çıkarmak amacıyla Hjorth Tanımlayıcı Yüksek Düzey Kompleksliği yöntemini kullanarak bir araştırma gerçekleştirmişlerdir. Bu çalışmada test verileri, Normal Sinüs Ritmi, Aritmi ve Konjestif Kalp Yetmezliği olmak üzere üç farklı EKG sinyal türünden oluşmaktadır. Özelliklerin sınıflandırılması aşamasında, K-En Yakın Komşu (KNN) ve Çok Katmanlı Yapay Sinir Ağı (ÇKYSA) yöntemleri uygulanmış olup, her iki yöntem de oldukça başarılı sonuçlar elde etmiştir. Özellikle, her iki sınıflandırma yönteminde de %94'lük bir doğruluk oranı sağlanmış, bu da araştırmanın EKG sinyallerinin analizi ve sınıflandırılmasında etkili bir yaklaşım sunduğunu göstermektedir. Bu çalışma, kardiyolojik sinyallerin daha doğru ve güvenilir bir şekilde analiz edilmesi için önemli bir katkı sağlamaktadır.

Haleem vd. (2021) EKG sinyallerinin analizi için iki aşamalı çok sınıflı bir algoritma geliştirmiştir. İlk aşamada, EKG segmentasyonu, dikkat mekanizmasıyla entegre edilmiş Konvolüsyonel İki Yönlü Uzun Kısa Süreli Bellek (Bi-LSTM) sinir ağıları kullanılarak gerçekleştirilmiştir. İkinci aşamada ise, ilk aşamadan elde edilen EKG darbelerinin sınıflandırılması için zaman adaptif Konvolüsyonel Sinir Ağları (CNN) uygulanmıştır. Normal EKG ile aritmi ve konjestif kalp yetmezliği gibi kardiyak olaylar arasında otomatik ayırım yapabilmek ve ani kardiyak ölümü tahmin edebilmek amacıyla, EKG darbeleri Kısa Süreli Fourier Dönüşümü (STFT) kullanılarak 2D görüntülere dönüştürülmüştür. Algoritmanın doğruluğu, MIT/BIH-PhysioNet veri tabanlarından elde edilen verilerle farklı zaman ölçekleri üzerinden değerlendirilmiştir. 4 dakikalık EKG segmenti kullanılarak, konjestif kalp yetmezliği olaylarının otomatik olarak tespitinde %100, aritmi olaylarında %97,9 ve ani kardiyak ölümleri tahmin etmede %100 doğruluk oranına ulaşılmıştır. Bu sonuçlar, kardiyovasküler hastalık tanısında önemli bir ilerlemeyi temsil etmekte olup, alan uzmanlarına sinyal özelliklerini hesaplayarak otomatik bir sistem aracılığıyla değerli destek sunmaktadır.

Han vd. (2020), EKG aritmi tespitinde daha etkili ve güvenilir bir yöntem sunmak amacıyla Uzun Kısa Süreli Bellek (LSTM) ve Tek Boyutlu Evrişimsel Sinir Ağı (1D-CNN) tabanlı hibrit bir yaklaşım geliştirmişlerdir. Bu yenilikçi yöntem, EKG sinyallerinin karmaşık yapısını ve zaman bağımlılıklarını daha iyi anlayabilme kapasitesine sahip iki güçlü derin öğrenme tekniğini bir araya getirerek, aritmi tespitinde yüksek başarı oranları elde etmeyi hedeflemektedir. Çalışma, MIT-BIH Aritmi veri tabanından alınan toplam 48 EKG sinyali kullanılarak gerçekleştirilmiştir. Bu veri seti, farklı aritmi türlerini kapsayan zengin bir içerik sunarak modelin kapsamlı bir şekilde test edilmesine olanak tanımaktadır. Yapılan değerlendirme neticesinde, önerilen hibrit modelin %92,03 oranında bir doğruluk elde ettiği görülmüş, bu doğruluk oranı, yalnızca 1D-CNN modelinin %90,98 ve Çok Katmanlı Algılayıcı (MLP) modelinin %86,15 olan doğruluk oranlarını geride bırakarak daha yüksek bir performans sergilemiştir. Bu bulgular, LSTM ve 1D-CNN bileşenlerinin bir araya getirilmesinin EKG aritmi tespitinde önemli bir iyileştirme sağladığını ortaya koymaktadır.

Huang vd. (2019), EKG aritmilerini sınıflandırmak amacıyla derin öğrenme tabanlı bir yaklaşım olarak Konvolüsyonel Sinir Ağı (CNN) modelini kullanmışlardır. Bu araştırmada, EKG sinyalleri, Kısa Zamanlı Fourier Dönüşümü (STFT) tekniği ile spektrogramlara dönüştürülmüştür; bu dönüşüm, sinyallerin zaman-frekans temsili sağlayarak, karmaşık aritmi yapılarını daha belirgin hale getirmektedir. Elde edilen bu

spektrogram görüntüleri üzerinden, toplam beş farklı aritmi türü sınıflandırılmıştır. Araştırmanın gerçekleştirilmesi sürecinde, MIT-BIH veri tabanından alınan kayıtlar kullanılmış ve bu kayıtlarla yapılan değerlendirme neticesinde, CNN modelinin %99,00 oranında oldukça yüksek bir doğruluk elde ettiği belirlenmiştir. Bu sonuç, CNN modelinin EKG aritmi sınıflandırmasındaki etkinliğini ve STFT ile elde edilen spektrogramların, aritmi türlerinin ayırımında sağladığı avantajı net bir şekilde ortaya koymaktadır.

Jun vd. (2018), elektrokardiyogram (EKG) sinyallerinin aritmi sınıflandırması için derin iki boyutlu konvolüsyonel sinir ağı (CNN) kullanan etkili bir yöntem önermektedir. Her EKG atışı, CNN sınıflayıcısı için girdi olarak kullanılan iki boyutlu gri tonlamalı bir görüntüye dönüştürülmektedir. Önerilen CNN modelinin optimizasyonu, “batch normalizasyon”, veri artırma, “xavier başlatma” ve “dropout” gibi çeşitli derin öğrenme tekniklerini içermektedir. Ayrıca, önerilen sınıflayıcının performansı, AlexNet ve VGGNet gibi iki tanınmış CNN mimarisiyle karşılaştırılmaktadır. Değerlendirme, MIT-BIH aritmi veri tabanındaki EKG kayıtları kullanılarak gerçekleştirilmiştir. Sonuçlar, önerilen sınıflayıcının %99.05 ortalama doğruluk ve %97.85 ortalama duyarlılık elde ettiğini göstermektedir. CNN sınıflayıcısının güvenilirliğini sağlamak için, tüm EKG kayıtlarını test verisi olarak kullanan 10 katlı çapraz doğrulama yöntemi uygulanmıştır. Deneysel bulgular, önerilen CNN sınıflayıcısının dönüştürülmüş EKG görüntülerini kullanarak, EKG sinyallerinin manuel ön işleme gerektirmeden olağanüstü sınıflandırma doğruluğu elde edebileceğini doğrulamaktadır.

Karpagachelvi vd. (2012), EKG sinyallerinin sınıflandırılması amacıyla geniş bir veri setini inceleyerek normal sinüs ritmi, erken kulakçık atımı, erken karıncık atımı, sağ dal bloğu, sol dal bloğu ve yapay vuru atımları gibi farklı aritmi türlerini ele almışlardır. Bu kapsamda, MIT-BIH Aritmi veri tabanında yer alan toplam 20 kayıttan elde edilen 40916 atım üzerinde detaylı bir analiz gerçekleştirilmiştir. Özellik çıkarımında kullanılan Ayırık Dalgacık Dönüşümü (DWT) tekniği, EKG sinyallerinin zaman ve frekans alanındaki önemli özelliklerini ortaya koyarak sınıflandırma sürecine katkı sağlamıştır. Sınıflandırma aşamasında ise, Destek Vektör Makineleri (SVM) ile Aşırı Öğrenme Makinesi (ELM) yöntemleri uygulanmış, bu iki modelin performansı detaylı bir şekilde karşılaştırılmıştır. Araştırmanın sonuçları, en yüksek başarı oranının PSO-SVM sınıflandırıcısında %90,52 olarak rapor edildiğini göstermektedir. Bu bulgu, önerilen yöntemlerin EKG sinyalleri üzerinde etkin bir sınıflandırma gerçekleştirebileceğini ve

aritmî tespitinde kullanılabilecek potansiyel uygulamaların geliştirilmesine katkıda bulunabileceğini ortaya koymaktadır.

Kumar vd. (2018), çeşitli dalgacık dönüşümlerinin kapsamlı bir analizini gerçekleştirmiş ve biortogonal dalgacık dönüşümünün elektrokardiyogram (EKG) sinyallerinde QRS kompleksini tespit etme konusunda en etkili yöntem olduğunu belirlemiştir. EKG tespit süreci esas olarak iki ana adımdan oluşmaktadır: sinyalin gürültüden arındırılması ve uyarlanabilir eğim tahmin eşiği ile çeşitli EKG zirvelerinin tanımlanması. Ayrıca, çalışma, EKG verilerinin kablosuz iletiminde önemli zorlukları ortaya koymakta, özellikle veri dönüşümü ve enerji tüketimi konularında sorunlar yaşandığını vurgulamaktadır. Tıbbî düzenleyici kurumların kayıpsız sıkıştırma teknikleri talebi doğrultusunda, yazarlar yüksek bit sıkıştırma oranı sağlayan bir kayıpsız sıkıştırma yöntemi önermektedir. Özellikle, LZMA (Lempel-Ziv-Markov zincir algoritması) tabanlı EKG veri sıkıştırma tekniği tanıtılmakta olup, bu yöntem en yüksek sinyal-gürültü oranını ve en düşük ortalama kare hatayı sağlamaktadır. Ek olarak, önerilen EKG tespit tekniği, sağlıklı bireyler ile miyokard enfarktüsü, konjestif kalp yetmezliği ve koroner arter hastalığı olan hastalar arasında ayırım yapma konusunda olağanüstü bir doğruluk sergilemekte ve tespit doğruluğu, duyarlılık, özgüllük ve hata oranları sırasıyla %99,92, %99,94, %99,92 ve 0,0013 olarak ulaşmaktadır. LZMA veri sıkıştırma tekniği ayrıca 18,84 gibi dikkate değer bir sıkıştırma oranı elde etmektedir. Bu önerilen algoritmanın avantajları ve etkinliği, mevcut yöntemlerle yapılan karşılaştırmalarla doğrulanmıştır.

Kusuma ve Jothi (2022), elektrokardiyogram (EKG) sinyalleri kullanarak konjestif kalp yetmezliğini (KKY) tespit etmek amacıyla Derin Konvolüsyonel Sinir Ağı ve Uzun Kısa Süreli Bellek Mimarisi (DCNN-LSTM) tabanlı otomatik bir tanı sistemi önermektedir. Özel olarak, derin özelliklerin çıkarılması amacıyla Konvolüsyonel Sinir Ağı (CNN) kullanılmakta, çıkarılan bu özelliklerin değerlendirilmesi içinse Uzun Kısa Süreli Bellek (LSTM) modeli devreye girmektedir. Önerilen DCNN-LSTM yapısı, EKG sinyallerinin en az ön işleme tabi tutulması ile geliştirilmiş olup, tanı aşamasında herhangi bir sınıflandırma sürecine veya manuel olarak mühendislik yapılmış özelliklere ihtiyaç duymamaktadır. Gerçek zamanlı EKG sinyalleri veri setleri üzerinde gerçekleştirilen deneyler, bu DCNN-LSTM modelinin %99,52 doğruluk, %99,31 duyarlılık, %99,28 özgüllük, %98,94 F-Skoru ve %99,9 AUC (Eğri Altında Alan) değerleri elde ettiğini doğrulamıştır. Bu sonuçlar, önerilen sistemin konjestif kalp yetmezliği tespitinde yüksek bir performans sergilediğini göstermektedir.

Li vd. (2022), EKG aritmi sınıflandırması için yenilikçi bir yaklaşım olarak Derin Artık Evrişimsel Sinir Ağı (ResNet) modelini önermişlerdir. Bu çalışmada, MIT-BIH veri tabanındaki EKG sinyalleri, örtüşen segmentasyon yöntemi kullanılarak 5 saniyelik segmentlere ayrılmıştır; bu segmentasyon işlemi, sinyallerin zaman içindeki değişikliklerini daha iyi yakalamak amacıyla gerçekleştirilmiştir. Elde edilen segmentler, ayrık dalgacık dönüşümü (DWT) tekniği ile gürültüden arındırılmış, böylece sınıflandırma sürecinde daha net ve anlamlı verilerin kullanılabilmesi sağlanmıştır. Önerilen ResNet modelinin performansı, normal segmentler için %94.54 oranında bir duyarlılık, %93.33 oranında bir pozitif öngörü ve %80.80 oranında bir özgüllük elde etmiştir. Ancak, supraventriküler ektopik segmentlerde %35.22 duyarlılık, %65.88 pozitif öngörü ve %98.83 özgüllük gibi farklı sonuçlar gözlemlenmiştir. Ventriküler ektopik segmentlerde ise, model %88.35 duyarlılık, %79.86 pozitif öngörü ve %94.92 özgüllük ile dikkat çekici bir yüksek performans sergilemiştir. Bu bulgular, ResNet modelinin EKG aritmi sınıflandırmasındaki etkinliğini ve çeşitli aritmi türleri için sağladığı farklı performansları açıkça ortaya koymakta, ayrıca modelin klinik uygulamalarda ve kardiyolojik analizlerde nasıl bir rol oynayabileceğini göstermektedir.

Lynn vd. (2019), aritmi tespitinde önemli bir yenilik sunarak Bi-GRU (Çift Yönlü Kapılı Tekrarlayan Hücreler) modelini önermişlerdir. Bu model, özellikle zaman serisi verilerinin analizi için geliştirilmiş bir yapay zeka yaklaşımı olarak öne çıkmakta ve uzun-kısa vadeli hafıza (LSTM) modeline göre daha yüksek bir doğruluk oranı sağlamaktadır. Gerçekleştirilen deneysel çalışmalar neticesinde, Bi-GRU modelinin sınıflandırma doğruluğu %98.55 olarak belirlenmiştir. Bu sonuç, Bi-GRU yönteminin, zaman içindeki bağıntıları daha etkin bir şekilde öğrenme yeteneği sayesinde aritmi tespitinde sağladığı başarımın altını çizmektedir. Lynn ve ekibinin bu çalışması, Bi-GRU modelinin kardiyolojik verilerin analizi alanındaki potansiyelini ortaya koymakta ve bu tür derin öğrenme tekniklerinin klinik uygulamalarda nasıl etkili bir şekilde kullanılabileceğine dair önemli ipuçları sunmaktadır. Bi-GRU yönteminin, özellikle aritmi tespiti gibi kritik sağlık alanlarında, daha doğru ve güvenilir sonuçlar elde etmek için güçlü bir araç olabileceği vurgulanmaktadır.

Madan vd. (2022), aritmi, konjestif kalp yetmezliği (KKY) ve normal sinüs ritmi (NSR) gibi farklı kardiyolojik durumların etkili bir şekilde sınıflandırılmasına yönelik yenilikçi bir yaklaşım geliştirmişlerdir. Bu yaklaşım, Konvolüsyonel Sinir Ağı (CNN) ve Uzun Kısa Süreli Bellek (LSTM) mimarilerinin kombinasyonunu içeren hibrit bir model sunmaktadır. Araştırmada, EKG sinyalleri önce gürültü temizleme işlemlerinden

geçirilmiş, ardından bu sinyallerin zaman-frekans temsili için skalogramlara dönüştürülmüştür. Bu dönüşüm, sinyallerin kritik özelliklerini daha iyi ortaya koyarak, modelin genel performansını artırmayı hedeflemiştir. Elde edilen sonuçlar, geliştirdikleri hibrit modelin %98,7 ile %99 arasında son derece yüksek doğruluk oranları ile sınıflandırma gerçekleştirdiğini göstermektedir. Madan ve ekibinin bu çalışması, hibrit modelin EKG verilerinin sınıflandırılmasında sağladığı üstün başarı ile, derin öğrenme tekniklerinin kardiyovasküler hastalıkların tanı ve takip süreçlerinde ne denli etkili olabileceğini gözler önüne sermektedir.

Marzog ve Abd (2020), elektrokardiyogram (EKG) verilerinin otomatik sınıflandırılması amacıyla yenilikçi bir dalgacık yayılma dönüşümüne dayanan bir metodoloji geliştirmiştir. Bu yöntem, aritmi (ARR), konjestif kalp yetmezliği (KKY) ve normal sinüs ritmi (NSR) gibi çeşitli EKG patolojilerine odaklanmaktadır. Dalgacık yayılma dönüşümünü kullanan bu yaklaşım, ölçekleme fonksiyonunun bant genişliğinden faydalanarak EKG sinyallerini zaman açısından kritik bir şekilde aşağı örneklemekte ve bu süreç sonucunda her bir yayılma yolunun 16 zaman penceresi içermesini sağlamaktadır. Bu metodoloji, modelin EKG sinyallerinden yer değiştirmelere ve bozulmalara karşı dayanıklı, sağlam özellikler çıkarmasını mümkün kılmaktadır. Performans değerlendirmesi için MIT-BIH aritmi veri seti kullanılarak gerçekleştirilen deneysel çalışmalar, sinir ağı (NN) ile %99,7 ve destek vektör makinesi (SVM) ile %99,92 gibi olağanüstü sınıflandırma doğruluk oranları elde edilmiştir. Dalgacık yayılma dönüşümüne dayanan bu yenilikçi yaklaşım, EKG anormalliklerinin otomatik tespiti ve sınıflandırılması alanında önemli bir potansiyele sahip olup, klinik pratikte kalp rahatsızlıklarının yorumlanması ve teşhisinde güvenilir bir araç sunmaktadır.

Masetic ve Subasi (2016) tarafından gerçekleştirilen bu çalışma, iki aşamadan oluşmaktadır: özellik çıkarımı ve sınıflandırma aşaması. Özellik çıkarım aşamasında, özneliliklerin elde edilmesi için otoregresif (AR) Burg yöntemi uygulanmıştır. Sınıflandırma aşamasında ise, C4.5 karar ağaçları, k-en yakın komşu, destek vektör makineleri, yapay sinir ağları ve rastgele orman sınıflayıcısı gibi beş farklı sınıflayıcı incelenmiştir. EKG sinyalleri, BIDMC Konjestif Kalp Yetmezliği ve PTB Tanısal EKG veri tabanlarından alınmış ve çeşitli deneylerle sınıflandırma işlemi gerçekleştirilmiştir. Deneysel sonuçlar, duyarlılık, özgüllük, doğruluk, F ölçütü ve ROC eğrisi gibi çeşitli istatistiksel ölçütlerle değerlendirilmiş ve rastgele orman yönteminin %100 sınıflandırma doğruluğu sağladığı görülmüştür. Rastgele orman yönteminin etkileyici performansı,

konjestif kalp yetmezliğini (KKY) tespit etmedeki önemli rolünü ortaya koymakta ve tıpta faydalı bilgi ifade etme açısından değerli bir katkı sağlamaktadır.

Mathunjwa vd. (2021), aritmi sınıflandırmasını etkin bir şekilde sağlamak amacıyla yeni bir derin öğrenme yöntemi tasarlamışlardır. Çalışmada, EKG sinyallerinin iki saniyelik segmentleri kullanılarak oluşturulan 2-boyutlu (2D) tekrar plot görüntüleri üzerinden sınıflandırma gerçekleştirilmiştir. Araştırmanın ilk aşamasında, gürültü ve ventriküler fibrilasyon (VF) kategorileri ayrıştırılmıştır. İkinci aşamada ise atriyal fibrilasyon (AF), normal, erken AF ve erken VF kategorileri arasında ayırım yapılmıştır. Model eğitim ve test süreçleri, PhysioNet web sitesinde erişilebilen kamuya açık EKG veri setleri kullanılarak gerçekleştirilmiştir. Çalışmada, MIT-BIH Aritmi Veritabanı, Creighton Üniversitesi Ventriküler Taşikardi Veritabanı, MIT-BIH Atrial Fibrilasyon Veritabanı ve MIT-BIH Malign Ventriküler Ektopi Veritabanı kullanılarak altı farklı aritmi türü karşılaştırılmıştır. Beş katlı çapraz doğrulama uygulandıktan sonra, birinci aşamada $95,3 \pm 1,27$ ve ikinci aşamada $98,41 \pm 0,11$ oranlarında yüksek test doğrulukları elde edilmiştir. Sonuç olarak, bu çalışma, klinik uygulamalarda farklı aritmi türlerinin tespit edilmesi ve ayrıştırılması için gelişmiş bir model sunmaktadır.

Mohonta vd. (2022), kardiyovasküler sağlık alanında önemli bir yenilik sunarak sürekli dalgacık dönüşümü (CWT) ile iki boyutlu evrişimsel sinir ağı (2D-CNN) yaklaşımını birleştirerek beş farklı aritmi türünü sınıflandırmaya yönelik etkileyici bir model geliştirmişlerdir. Bu çalışmada, EKG sinyalleri, CWT ile işlenerek detaylı bir zaman-frekans temsili olan skalogramlara dönüştürülmüştür. Bu skalogramlar, EKG sinyallerinin kritik özelliklerini daha iyi yansıtmakta ve böylece modelin sınıflandırma performansını artırmaktadır. Araştırma kapsamında, elde edilen skalogramlardan 0.225 saniye uzunluğundaki kısa EKG segmentleri, 2D-CNN tabanlı bir ağ modeli aracılığıyla sınıflandırılmıştır. 2D-CNN'in, görüntü verileri üzerinde yüksek başarıyla çalışabilme yeteneği, bu modelin EKG verileriyle etkili bir şekilde entegre edilmesini sağlamıştır. Sonuçlar, önerilen yöntemin ortalama duyarlılık, özgüllük ve doğruluk oranlarının sırasıyla %98.87, %99.85 ve %99.65 olduğunu ortaya koymaktadır. Bu bulgular, Mohonta ve ekibinin geliştirdiği modelin aritmi tespitindeki etkinliğini ve CWT skalogramlarının, derin öğrenme algoritmaları için sağlamış olduğu avantajları gözler önüne sermektedir.

Murawwat vd. (2022), kardiyovasküler sağlık alanında önemli bir yenilik sunarak, “Çok Değişkenli Ampirik Mod Ayrıştırma” (MEMD) ve Yapay Sinir Ağı (YSA) yöntemlerinin birleşiminden oluşan etkili bir hibrit yaklaşım geliştirmişlerdir. Bu

yaklaşımında, MEMD tekniği, EKG sinyallerindeki gürültüyü giderme ve önemli öznitelikleri çıkartma amacıyla kullanılmıştır. MEMD sayesinde, EKG sinyallerinin daha temiz bir biçimde analiz edilmesi mümkün hale gelmiş, böylece sinyalin içindeki kritik bilgiler daha belirgin hale getirilmiştir. Elde edilen bilgiler arasında, RR aralıkları ve kalp atış hızı gibi temel veriler yer almakta olup, bu veriler, Taşikardi ve Bradikardi türündeki aritmilerin sınıflandırılmasında Çok Katmanlı İleri Beslemeli Sinir Ağları (MLP) tarafından işlenmiştir. MLP modelinin kullanımı, bu tür aritmi sınıflandırmalarında daha yüksek bir doğruluk oranı elde edilmesini sağlamış ve sonuç olarak %89.8 oranında bir başarı elde edilmiştir. Murawwat ve ekibinin bu çalışması, EKG sinyallerinin analizinde MEMD'nin sağladığı avantajların yanı sıra, YSA tekniklerinin aritmi tespitindeki etkinliğini de gözler önüne sermekte ve modern makine öğrenme yöntemlerinin kardiyovasküler hastalıkların tanı süreçlerine entegre edilmesinin önemini vurgulamaktadır.

Nahak vd. (2023), elektrokardiyogram (EKG) verilerini kullanarak aritmi, konjestif kalp yetmezliği ve normal sinüs ritmini sınıflandırmak üzere yenilikçi bir iki aşamalı yaklaşım önermiştir. İlk aşamada, EKG parçalarından lineer ve non-lineer özelliklerin elde edildiği geleneksel bir özellik çıkarımı tabanlı model devreye sokulmuştur. Bu modelin lineer özellikleri, zamanla değişen ve ölçekli değişkenlik bilgilerini başarıyla yakalarken, non-lineer özellikler, durağan olmayan sinyalin karmaşık doğasını açığa çıkarmakta ve belirsizliği nicelendirerek önemli veriler sağlamaktadır. İkinci aşamada ise, EKG'nin zaman-frekans temsillerinden otomatik olarak derinlemesine bilgi çıkarımı yapmak amacıyla önceden eğitilmiş derin öğrenme ağları kullanılmaktadır. Bu iki yaklaşımın entegrasyonu, aritmi ve konjestif kalp yetmezliği gibi klinik durumların daha etkin bir şekilde teşhis edilmesine imkân tanımaktadır. Araştırma, Physionet veri tabanı üzerinde gerçekleştirilmiş olup, önerilen birleşik sistem %99,06 doğruluk, %99,14 duyarlılık, %99,68 özgüllük ve %99,32 keskinlik gibi etkileyici performans metrikleri elde etmiştir. Bu performans sonuçları, mevcut en iyi sistemlere kıyasla daha üstün bir başarı sergilemektedir. Ayrıca, denek seviyesinde yapılan deneylerde oylama yöntemi kullanılarak performans metriklerinde anlamlı bir iyileşme sağlandığı gözlemlenmiştir.

Nainwal vd. (2022), EKG sinyallerinin analizi için önemli bir yaklaşım geliştirmişlerdir. Bu çalışmada, ilk olarak EKG sinyalleri, alçak geçiren filtre uygulaması ile gürültüden arındırılmış ve bu süreç, sinyalin kalitesini artırarak daha sağlam bir temel oluşturmuştur. Ardından, elde edilen temizlenmiş sinyaller üzerinden dalgacık dönüşümü (wavelet transform) yöntemi kullanılarak detaylı bir öznitelik vektörü oluşturulmuştur.

Bu öznitelik vektörünün boyutunun optimize edilmesi amacıyla "Improved Monarch Butterfly" (IMBO) optimizasyon algoritması uygulanmış ve bu sayede öznitelik vektörünün boyutunu azaltarak sınıflandırma performansını artırmak mümkün kılınmıştır. Optimize edilen öznitelik vektörü, daha sonra Evrişimsel Sinir Ağı (CNN) ile sınıflandırma işlemi için kullanılmıştır. Bu işlem sonucunda, elde edilen başarı oranı %99.49 olarak kaydedilmiştir. Nainwal ve ekibinin bu çalışması, EKG sinyallerinin temizlenmesi ve öznitelik çıkarımı aşamalarında kullanılan yenilikçi tekniklerin yanı sıra, optimizasyon yöntemlerinin sınıflandırma süreçlerindeki etkisini vurgulamaktadır.

Pal vd. (2021), elektrokardiyogram (EKG) sinyallerinden kalp atışı sınıflandırması için derin öğrenme tekniklerini kullanan yenilikçi bir yaklaşım sunmaktadır. Yazarlar, aritmi tespiti için kalp atışlarının hızlı ve sağlam bir şekilde sınıflandırılmasını sağlayan 'CardioNet' adında otomatik bir sistem geliştirmiştir. Bu sistem, milyonlarca görüntüden oluşan ImageNet veri seti üzerinde eğitilmiş önceden eğitilmiş DenseNet mimarisini kullanmaktadır. DenseNet'in eğitim sürecinde elde edilen ağırlıklar, CardioNet'in EKG veri seti üzerinde ince ayar yapması için kullanılmakta, böylece daha hızlı eğitim ve test süreçleri sağlanmaktadır. EKG veri seti, intraclass varyasyonları göz önünde bulundurularak kalp atışı morfolojisinin kapsamlı bir şekilde öğrenilmesi için artırma işlemi ile hazırlanmıştır. Aritmi sınıflandırması için MIT-BIH aritmi veri seti ve PTB veri seti olmak üzere iki standart EKG veri seti kullanılarak 29 farklı kalp atışı türü sınıflandırılmaktadır. Önerilen CardioNet sistemi, %98.92 gibi etkileyici bir sınıflandırma doğruluğu elde ederek diğer yöntemleri geride bırakmakta ve farklı düzensiz kalp atışları ile aritmiler karşısında dayanıklılık göstermektedir.

Panchal vd. (2024) çalışmasında, elektrokardiyogram (EKG) sinyallerinin sınıflandırmasını geliştirmek için iki multimodal görüntü tabanlı füzyon tekniği, Multimodal Görüntü Füzyonu (MIF) ve Multimodal Özellik Füzyonu (MFF) incelenmiştir. İlk olarak, ham EKG verileri farklı görüntü modlarına dönüştürülmüş ve ardından sınıflandırma için birleştirilmiştir. Kullanılan modlar arasında Gramian Açısıl Alanı (GAF), Markov Geçiş Alanı (MDF) ve Tekrar Grafiği (RP) görüntüleri bulunmaktadır. MIF yönteminde, üç farklı moddan elde edilen birleşik görüntü, sınıflandırma için bir konvolüsyonel sinir ağına (CNN) verilmiştir. MFF tekniğinde ise, önce mod görüntülerinden özellikler çıkarılmış, ardından bu görüntüler birleştirilerek gerekli benzersiz bilgiler elde edilmiştir. Çalışmada EKG5000 veri seti kullanılmıştır. Yeni tasarlanan model, Konjestif Kalp Yetersizliği (KKY) şiddetinin sınıflandırılmasında %97,79 doğruluk (MIF yöntemi) ve %98,19 doğruluk (MFF yöntemi) ile önemli bir

başarı göstermiştir. Bu sonuçlar, multimodal füzyon tekniklerinin EKG sinyali sınıflandırmasındaki doğruluğu artırma potansiyelini vurgulamaktadır.

Panganiban vd. (2021), EKG sinyallerinin analizi için yenilikçi bir yaklaşım benimseyerek, bu sinyallerin spektrogram görüntülerini oluşturmuş ve ardından bu görüntüler üzerinde Evrişimsel Sinir Ağı (CNN) yöntemini uygulayarak aritmi sınıflandırması gerçekleştirmişlerdir. Öne çıkan bu çalışma, görsel verilerin işlenmesi konusundaki yenilikçi yöntemleri kullanarak, EKG sinyallerinin daha etkili bir şekilde analiz edilmesine olanak tanımaktadır. Bu süreçte, Google'ın Inception V3 modelini kullanarak CNN'in son katmanını yeniden eğitmişlerdir. Böylece, modelin derin öğrenme yeteneklerinden tam anlamıyla faydalanarak, elde edilen görüntüler üzerindeki sınıflandırma doğruluğunu artırmayı hedeflemişlerdir. Çalışmanın sonuçları, ikili sınıflandırma görevinde %98,73 oranında yüksek bir doğruluk sağlarken, beşli sınıflandırma görevinde ise %97,33 oranında bir başarı elde edilmiştir. Panganiban ve ekibinin bu araştırması, EKG sinyallerinin görselleştirilmesi ve derin öğrenme yöntemleri ile analiz edilmesi konularında önemli bir ilerleme kaydetmekte ve kardiyovasküler hastalıkların erken teşhisinde modern teknolojilerin potansiyelini ortaya koymaktadır.

Porumb vd. (2020), yalnızca bir ham elektrokardiyogram (EKG) atımı kullanarak kongestif kalp yetmezliğini (KKY) doğru bir şekilde tespit eden bir evrişimli sinir ağı (CNN) modelini tanıtarak önemli bir araştırma boşluğunu ele almaktadır. Bu yaklaşım, genellikle kalp hızı değişkenliğine dayanan mevcut yöntemlerle karşılaştırılmaktadır. Model, toplamda 490,505 kalp atımı içeren kamuya açık EKG veri setlerinde eğitim ve test edilmiştir ve sonuç olarak %100 KKY tespit doğruluğu elde edilmiştir. Yüksek tespit doğruluğu sağlamanın yanı sıra, model, KKY teşhisi için kritik öneme sahip olan ve farklı sınıfları ayırt etmekte önemli rol oynayan belirli kalp atımı dizilerini ve EKG'nin morfolojik özelliklerini de tanımlamaktadır.

Rahul ve Sharma (2022), EKG aritmilerinin tespitinde etkili bir yaklaşım sunmak amacıyla, 1-D Evrişimsel Sinir Ağı (CNN) ile Çift Yönlü Uzun Kısa Süreli Bellek (Bi-LSTM) mimarilerinin bir kombinasyonunu temel alan yenilikçi bir hibrit model geliştirmiştir. Bu model, EKG verilerinin analizi için ileri düzey makine öğrenimi yöntemlerinin entegrasyonunu içermektedir. Verilerin ön işlenmesi aşamasında, durağan dalgacık dönüşümleri (SWT) ve Savitzky-Golay (SG) medyan filtresi gibi modern teknikler bir araya getirilmiş ve bu sayede sinyal gürültüsü azaltılarak daha temiz bir veri seti elde edilmiştir. Bu ön işleme süreci, modelin genel performansını artırarak, daha doğru ve güvenilir sınıflama sonuçları elde edilmesini sağlamıştır. Geliştirilen hibrit 1-D

CNN-Bi-LSTM modelinin sonuçları, %99,44 gibi oldukça yüksek bir doğruluk oranı ile aritmi tespitinde önemli bir başarı elde ettiğini göstermektedir.

Sangaiah vd. (2020) elektrokardiyogram (EKG) sinyallerinin kapsamlı bir analizine yönelik yenilikçi bir çerçeve sunmuştur. Bu çerçeve, EKG sinyal kalitesinin artırılmasına yönelik olarak özel bir filtre kombinasyonu ile gürültü bastırma işlemi gerçekleştirilmesini, ardından öz niteliklerin çıkarılması için tasarlanmış bir dalgacık dönüşümü uygulanmasını ve son olarak aritmi verilerinin olan Normal (N), Sağ Dal Bloğu (RBBB), Sol Dal Bloğu (LBBB), Prematüre Ventiküler Kontraksiyon (PVC) ve Atrial Prematüre Kontraksiyon (APC) gibi kategorilere ayrılması amacıyla gizli Markov modelinin (HMM) kullanılmasını kapsamaktadır. Bu çalışmada çıkarılan ana özellikler arasında sinyalin minimum, maksimum, ortalama, standart sapma ve medyan değerleri yer almaktadır. Elde edilen verilerin analizi, MIT-BIH aritmi veri seti ile MIT-BIH gürültü stres testi veri setinde toplam kırk beş EKG kaydı üzerinde gerçekleştirilmiştir. Bu deneyler sonucunda önerilen model, %99.7 genel doğruluk oranı elde ederken, duyarlılık oranı da %99.7 olarak belirlenmiştir. Ayrıca, modelin pozitif öngörü değeri %100 olarak hesaplanmıştır, bu da modelin aritmi tespitindeki güvenilirliğini göstermektedir. Önerilen yaklaşımın tespit hata oranı ise yalnızca 0.0004 olarak kaydedilmiştir. Bu çalışma, ayrıca aritmilerin tanınmasına yönelik bir IoMD (Tıbbi Nesnelerin İnterneti) yaklaşımını da içermektedir. IoMD uygulamaları, tıbbi verilerin uzaktan izlenmesi ve analizi için bir altyapı sunarak, klinik karar verme süreçlerini geliştirme potansiyeline sahiptir.

Salem vd. (2018), dört farklı EKG aritmi türünü analiz etmek ve sınıflandırmak amacıyla yenilikçi bir yöntem geliştirmişlerdir. Bu çalışmada, EKG sinyalleri, kısa zamanlı Fourier dönüşümü (STFT) kullanılarak spektrogramlara dönüştürülmüş ve elde edilen bu görsel temsiller, derin öğrenme alanında önemli bir ilerleme kaydeden hibrit bir modelin girdi verileri olarak kullanılmıştır. Özellikle, bu hibrit model, DenseNET mimarisinin yanı sıra Destek Vektör Makineleri (SVM) algoritmasını birleştirerek, iki güçlü yöntemden faydalanmakta ve EKG verilerinin sınıflandırılmasında yüksek doğruluk oranı sağlamaktadır. Yaklaşık 7000 örnek üzerinde gerçekleştirilen kapsamlı testler sonucunda, geliştirilen hibrit model %97,23 oranında etkileyici bir doğruluk elde etmiştir. Salem ve ekibinin bu çalışması, EKG sinyallerinin analizinde derin öğrenme tekniklerinin ve geleneksel makine öğrenimi yöntemlerinin bir araya getirilmesinin, aritmi tespiti gibi karmaşık tıbbi sorunların çözümüne önemli katkılar sağladığını göstermektedir.

Senturk (2023), elektrokardiyogram (EKG) sinyallerinin derin öğrenme (DL) tabanlı sınıflandırmasını kolaylaştırmak amacıyla, kalp hastalığı teşhisi için genellikle kullanılan tepe analizi gerektirmeyen verimli bir ön işleme yöntemi önermektedir. EKG sinyalleri, sınıflandırma için sürekli zamanlı dalgacık dönüşümü (CWT) kullanılarak iki boyutlu bir skalogram görüntüsüne dönüştürülmüştür. Çalışmada, EKG sinyalleri için Physionet kamu veri seti kullanılmıştır. Önerilen ön işleme yöntemi, aritmi (ARR), kongestif kalp yetmezliği (KKY) ve normal sinüs ritmi (NSR) gibi durumların sınıflandırılmasında %98,7 doğruluk oranı ile önemli bir etkinlik göstermiştir. Ayrıca, önerilen ön işleme ile desteklenen AlexNet tabanlı derin öğrenme çözümü, kendine ait bir evrişimli sinir ağı (CNN) modeline göre %12'den fazla bir performans artışı sağlamıştır. Önerilen mimari, yalnızca %1,33 oranında bir örnek kaçırma ile çalışmıştır. Bu yaklaşım, diğer biyomedikal sinyallere ve farklı derin öğrenme modellerine kolaylıkla uyarlanabilir ve kritik tıbbi sorunların hızlı ve doğru sınıflandırılması için önemli bir fırsat sunmaktadır.

Sharma vd. (2022), kongestif kalp yetmezliğini (KKY) teşhis etmek için Elektrokardiometriks (ECM) yöntemini geliştirmiştir. Bu yaklaşım, bir boyutlu (1-D) elektrokardiyogram (EKG) sinyallerini renkli üç boyutlu (3D) bir matris şeklinde dönüştürerek KKY teşhisini kolaylaştırmaktadır. ECM tekniği, manuel olarak notasyona tabi tutulmuş KKY EKG sinyalleri ile karşılaştırıldığında, KKY'nin etkilediği süreyi etkili bir şekilde tespit etmektedir. Ayrıca, ECM yöntemi hem yanlış pozitif hem de yanlış negatif oranlarını azaltarak genel tespit doğruluğunu artırmaktadır. Önerilen yöntemin performansı BIDMC KKY veri tabanında test edilmiş ve %97.6 doğruluk, %98.0 duyarlılık, %97.0 özgüllük, %99.4 kesinlik ve %98.3 F1-Skoru elde edilmiştir. Bu çalışma, ECM tekniğinin KKY'nin doğru, sezgisel ve verimli bir şekilde tespitini sağladığını ve uygulayıcıların tanı doğruluğundan ödün vermeden KKY'yi teşhis etmelerine olanak tanıdığını göstermektedir.

Thanapatay vd. (2010), normal kalp atımları ile sol dal bloğu, sağ dal bloğu, erken kulakçık atımı ve erken karıncık atımı gibi kardiyak anomalileri sınıflandırmak amacıyla, elektrokardiyogram (EKG) sinyallerinden öznetelik çıkarımında oldukça etkin bir yöntem kombinasyonu kullanmışlardır. Bu bağlamda, Ayrık Dalgacık Dönüşümü (DWT) ve Temel Bileşen Analizi (PCA) tekniklerini entegre ederek, sinyallerdeki en belirgin ve anlamlı özelliklerin öne çıkarılmasını sağlamışlardır. Çalışmanın sınıflandırma aşamasında ise, makine öğrenmesi alanında yaygın olarak kullanılan ve sınıflandırma performansı ile öne çıkan Destek Vektör Makineleri (SVM) algoritmasından

faaydalanılmıřtır. Elde edilen  znitelikler, SVM modeli ile iřlenmiř ve sınıflandırma performansı aısından son derece y ksek bir doėruluk oranı elde edilmiřtir. MIT-BIH Aritmi veri seti  zerinde gerekleřtirilen deneyler sonucunda, modelin doėruluėu %97.64 olarak rapor edilmiřtir. Bu alıřma, EKG sinyallerinden kardiyak olayların tespitinde DWT ve PCA gibi g l   zellik ıkarma y ntemlerinin bir araya getirilmesiyle elde edilen verimli sonuların yanı sıra, SVM algoritmasının sınıflandırma yetkinliėini vurgulamaktadır.

Varghese vd. (2022), kardiyak aritmaların tanısını desteklemek amacıyla derin sinir aėlarına (DNN) dayanan otomatik bir EKG atım sınıflandırma sistemi geliřtirmiřlerdir. Bu sistem, Internet of Things (IoT) teknolojiyle donatılmıř bir EKG izleme cihazı kullanarak toplanan verilerin bir sunucuya aktarılmasını saėlamaktadır. Elde edilen veriler, bir derin  ėrenme modeli aracılıėıyla analiz edilmekte ve sonular birincil saėlık hizmeti saėlayıcılarıyla paylařılmaktadır. Model, MIT-BIH EKG aritmi veritabanını kullanarak, normal atım (N), sol dal bloku atımı (L), saė dal bloku atımı (R) ve erken ventrik ler kasılma (V) gibi d rt sınıfa ayrılacak řekilde eėitilmiřtir. Veriler,  rt řen kayar pencere y ntemi ile  rneklenmiř ve eėitim ile test iin %80-%20 oranında b l nm řt r; bu s rete on katlı apraz doėrulama da uygulanmıřtır.  nerilen y ntem, herhangi bir  n iřleme gerektirmeden basit bir model ile  nceki alıřmalara g re daha y ksek doėruluk oranlarına ulařmıřtır. Eėitim ve test setleri iin sırasıyla %99,09 ve %99,03 oranlarında doėruluk elde edilmiřtir. Ayrıca, kesinlik, hatırlama ve F1 skorları 0,99 olarak hesaplanmıřtır. Bu model, basit ve etkili bir EKG izleme sistemi geliřtirme amacına ulařmakta ve performansını  nemli  l de artırmaktadır. Bu derin  ėrenme yaklařımının gerek zamanlı tele saėlık izleme sistemlerinde kullanılması da m mk nd r.

Vijayavanan vd. (2014), elektrokardiyogram (EKG) sinyallerinden  znitelik ıkarmak amacıyla, morfolojik yapı analizi temelinde etkili bir yaklařım geliřtirmiřlerdir. Bu alıřmada,  zniteliklerin ıkarılması s recinde kullanılan morfolojik yapılar, kalp ritmi bozukluklarının belirlenmesinde  nemli ipuları sunarken, ayrıntı d zeyini artırarak sınıflandırma performansını da olumlu y nde etkilemiřtir. Sinyallerin  n iřleme ařamasında, EKG verilerinin daha anlařılır ve temiz hale getirilmesi amacıyla Ayrık Dalgacık D n ř m  (DWT) uygulanmıř ve bu sayede sinyaldeki g r lt  ortadan kaldırılmıřtır. Sınıflandırma ařamasında ise, kardiyak anomalilerin doėru bir řekilde tespit edilebilmesi iin Olasılıksal Yapay Sinir Aėları (PNN) tercih edilmiřtir. Bu model, verilerin olasılıksal daėılımını dikkate alarak, daha esnek ve doėru sonular sunmasıyla

öne çıkmaktadır. MIT-BIH Aritmi veri tabanından alınan kayıtlar kullanılarak gerçekleştirilen deneylerde, her bir kategoriden yaklaşık 150 kayıt eğitim için, 50 kayıt ise test için ayrılmıştır. Eğitim ve test süreçleri sonrasında, sistemin genel sınıflandırma doğruluğu %96.5 olarak rapor edilmiştir. Bu çalışma, EKG sinyallerinin morfolojik özniteliklerinin çıkarılması ve ayırık dalgacık dönüşümüyle işlenmesiyle elde edilen sonuçların yanı sıra, PNN modelinin sınıflandırma performansına yaptığı olumlu katkıyı göstermektedir.

Yang ve Yan (2020), elektrokardiyogram (EKG) aritmileri sınıflandırmak için yenilikçi birçok boyutlu öznitelik çıkarma ve seçim yöntemi sunmaktadır. Önerilen yaklaşım, önce görüntü şekil özelliklerini çıkarmak için çoklu aralık simetrik nokta deseni (MSDP) adında yeni bir yöntem geliştirilmesiyle başlamaktadır. Bu özellikler, zaman-frekans özellikleri, morfolojik özellikler ve RR aralığı özellikleri ile birleştirilerek kapsamlı bir öznitelik seti oluşturulmaktadır. Öznitelik seçimini geliştirmek amacıyla, genetik algoritma (GA) ve destek vektör makinesi (SVM) ile entegre edilmiş yeni bir ortalama ağırlık tabanlı ReliefF yöntemi (WReliefF) önerilmektedir. Bu yöntem, WReliefF-GA-SVM adı verilen hibrit bir öznitelik seçim yöntemi oluşturmaktadır. Yöntem, iki aşamada çalışmaktadır: Filtre aşamasında, WReliefF kullanılarak öznitelikler ortalama ağırlıklarına göre sıralanmaktadır. Sarma aşamasında ise, GA ve SVM birleştirilerek SVM sınıflandırma performansı, uygunluk fonksiyonu olarak kullanılarak en iyi öznitelik alt kümesi aranmaktadır. Bu yöntemin etkinliği, MIT-BIH aritmi veri setinden beş farklı EKG atış türünün birer karşı hepsi (OAA) SVM modeli kullanılarak sınıflandırılmasıyla gösterilmektedir. Sonuçlar, önerilen yöntemle sırasıyla %99.42, %99.83 ve %99.74 oranında etkileyici ortalama duyarlılık, özgüllük ve doğruluk oranları elde edildiğini göstermektedir.

Yang ve Wei (2020), aritmilerin doğru sınıflandırılması için parametrik ve morfolojik özellikleri birleştiren yeni bir yöntem geliştirmiştir. EKG sinyallerindeki önemli olaylar tespit edildikten sonra, genlik, aralık ve süre gibi parametrik özellikler çıkarılmış ve QRS kompleksi morfolojisindeki değişiklikleri görsel desenler olarak analiz eden yenilikçi bir özellik tanıtılmıştır. Bu öznitelik vektörleri, yapay sinir ağı, destek vektör makineleri (SVM) ve k-en yakın komşu (KNN) gibi üç sınıflandırıcıya uygulanmıştır. MIT-BIH aritmi veri tabanı üzerinde yapılan değerlendirmede, KNN kullanılarak %97.70 genel doğruluk elde edilmiştir. Ana aritmi türleri için doğruluk oranları %99.92'ye kadar çıkmış ve yöntemin mevcut çalışmalara göre sınıflandırma performansında ilerleme sağladığı gösterilmiştir.

Wu vd. (2017), elektrokardiyografi (EKG) aritmilerinin sınıflandırılması için yenilikçi bir özellik öğrenimi yaklaşımı sunmuş ve bu yöntem, Doğrudan İndirekt Algoritmalar (DİA) ile Yapay Öğrenme Kullanımı (YOK) temellerine dayanarak geliştirilmiştir. Bu yöntemde, özellik çıkarımı sürecini daha etkin hale getirmek amacıyla, Gaussian-Bernoulli kısıtlı Boltzmann makinesi (GBRBM) ve Bernoulli-Bernoulli kısıtlı Boltzmann makinesi (BBRBM) olmak üzere iki farklı makine öğrenimi algoritmasından yararlanılmıştır. Ayrıca, ağ performansını ve doğruluğunu daha da optimize etmek için, elde edilen gizli temsil katmanının üzerine bir softmax regresyon tabakası eklenmiş ve bu katman, geri yayılım yöntemiyle ince ayarlamalar yapılarak geliştirilmiştir. Önerilen bu model, geleneksel yöntemlerin aksine hem öğrenme süresinde kayda değer bir kısalık sağlamış hem de sınıflandırma doğruluğunu %99.5 seviyelerine çıkararak üstün performans sergilemiştir. Çalışma, EKG aritmilerinin sınıflandırılmasında kullanılan klasik yöntemlere kıyasla daha verimli ve hızlı sonuçlar elde edilmesi açısından dikkate değer bir başarı göstermiştir.

Zhang vd. (2020), konjestif kalp yetmezliği (KKY) tanısına yönelik elektrokardiyografi (EKG) sinyallerinin incelenmesine dair kapsamlı bir araştırma gerçekleştirmişlerdir. Physionet veritabanından temin edilen KKY hastalarına ait EKG verileri, öncelikli olarak sinyal kalitesini iyileştirmek amacıyla çeşitli gürültü giderme yöntemleri ile işlenmiş ve bu sayede sinyaller, gürültüden arındırılmış hale getirilmiştir. Ardından, sinyaller belirli bir sayıdaki ardışık kalp atımını içeren segmentlere ayrılmıştır. Bu segmentler, doğrudan tekrar eden sinir ağları (RNN) modeline hem eğitim hem de test verisi olarak sunulmuştur. RNN modeli, zaman bağımlı verilerdeki ardışıklığı başarılı bir şekilde öğrenerek sınıflandırma işlemini gerçekleştirmiştir. Çalışmanın sonuçları, önerilen yöntemin KKY tespiti için sırasıyla %93.42 doğruluk, %93.12 duyarlılık ve %93.72 özgüllük oranları ile yüksek bir performans sergilediğini göstermiştir. Bu bulgular, özellikle KKY gibi ciddi kardiyovasküler hastalıkların erken teşhisinde RNN tabanlı yaklaşımların ne denli etkili ve güvenilir olduğunu ortaya koymaktadır.

Zheng vd. (2021), elektrokardiyogram (EKG) sinyallerinden öznelik çıkarımını optimize etmek amacıyla Tekil Değer Ayrıştırması (SVD) adını verdikleri yenilikçi bir yöntem geliştirmişlerdir. Bu metodoloji, EKG sinyallerindeki karmaşık yapısal bilgiyi etkili bir şekilde sadeleştirip öznelik vektörlerine dönüştürerek, sınıflandırma süreçlerinde daha verimli bir temel sağlamaktadır. Özellikle, SVD'nin yalnızca üç tekil değer kullanılarak elde edilen öznelikleri, evrişimli sinir ağı (CNN) ve destek vektör makinesi (SVM) algoritmaları ile işlenmiştir. Her iki algoritmada da yüksek performans

gösteren bu yaklaşım hem doğruluk hem de işlem verimliliği açısından dikkate değer sonuçlar elde edilmesini sağlamıştır. Çalışmanın sonuçlarına göre, yalnızca üç tekil değer seçildiğinde dahi, CNN ve SVM algoritmalarının her ikisinde de ortalama doğruluk oranları %96'nın üzerinde rapor edilmiştir. Bu bulgular, SVD temelli öz nitelik çıkarımının, EKG sinyalleri üzerinde ileri düzey sınıflandırma süreçleri için güçlü bir çözüm sunduğunu ve tanı süreçlerinin hassasiyetini artırdığını ortaya koymaktadır.

4. MATERYAL

Bu tez çalışmasında, geliştirilen yeni yaklaşımların performansını değerlendirmek ve geçerliliğini test etmek amacıyla iki farklı EKG veri seti kullanılmıştır. Bu veri setlerinden ilki, aritmi tespiti uygulamalarında yaygın olarak kullanılan MIT-BIH aritmi veri tabanından elde edilmiştir. Bu veri seti, dört farklı aritmi türüne ait EKG sinyallerini içermektedir. Bu aritmi türleri sırasıyla ventriküler atım (VA), supraventriküler atım (SVA), füzyon atımı (FA) ve tanımlanmamış bir atım çeşidi olan (TA) atımlarıdır (Goldberger vd., 2000b; Moody & Mark, 2001). Ayrıca, sağlıklı bireylerden alınan normal sinüs ritmi (NSR) sinyalleri de bu veri setine dahil edilmiştir. Böylece hem normal hem de patolojik verilerin birlikte kullanılması, geliştirilen modellerin genel geçerliliğini ve doğruluğunu test etme fırsatı sağlamaktadır.

İkinci veri seti, hem MIT-BIH hem de Beth Israel Deaconess Medical Center (BIDMC) veri tabanlarından alınmış olan EKG sinyallerinden oluşmaktadır (Moody ve Mark, 2001; Goldberger vd., 2000; Baim vd., 1986). Bu veri setinde aritmi (AF), konjestif kalp yetmezliği (KKY) olan bireylere ait sinyaller ve normal sinüs ritmine (NSR) sahip bireylere ait veriler bulunmaktadır. Bu veri setleri kardiyak aritmi, konjestif kalp yetmezliğinin tespiti konusunda geniş çapta kabul görmüş ve akademik araştırmalarda sıklıkla referans alınan kaynaklardır (Moody ve Mark, 2001; Goldberger vd., 2000; Baim vd., 1986). MIT-BIH ve BIDMC veri tabanlarından alınan sinyaller, EKG verilerinin çeşitli aritmi türlerini içererek, sinyal işleme tekniklerinin ve makine öğrenmesi modellerinin daha geniş bir spektrumda test edilmesine olanak tanımaktadır.

Her iki veri seti, geliştirilen yaklaşımların üç farklı uygulamada doğruluğunu ve performansını test etmek için temel veri kaynakları olarak kullanılmıştır. Bu sayede, geliştirilen modellerin hem aritmik olayları hem de normal kalp atımlarını başarılı bir şekilde ayırt edip edemediği detaylı olarak test edilmiştir. Bu tez çalışmasında, iki farklı veri seti kullanılarak yeni hibrit sınıflandırma yöntemlerinin performansları detaylı bir şekilde test edilmiştir. İlk olarak, Veri Seti-1 kullanılarak yenilikçi bir yöntem olarak önerilen merkezden bağımsız bir boyutlu yerel ikili desen (CI-1D-LBP) tabanlı sınıflandırma modelleri incelenmiştir. Bu kapsamda, CI-1D-LBP+LSTM, CI-1D-LBP+1D-CNN ve CI-1D-LBP+GRU gibi hibrit sınıflandırma modelleri, ventriküler atım (VA), supraventriküler atım (SVA), füzyon atımı (FA), tanımlanmamış atım (TA) ve normal sinüs ritmi (NSR) sinyallerini içeren bu veri seti üzerinde test edilmiştir. Söz konusu yöntemler, EKG sinyallerindeki örüntüleri daha etkili bir şekilde modellemek ve

sınıflandırma başarısını artırmak amacıyla geliştirilmiş olup, LBP tabanlı metotlar ile derin öğrenme tekniklerinin birleşimi sayesinde üstün performans sağlamayı hedeflemektedir.

Veri Seti-2'de ise, yine bu çalışmaya özgü olarak tasarlanan ortogonal fark bir boyutlu yerel ikili desen (OD-1D-LBP) temelli sınıflandırma modellerinin performansları incelenmiştir. Bu aşamada, OD-1D-LBP-LSTM ve OD-1D-LBP-1D-CNN hibrit sınıflandırma modelleri test edilmiş ve bu modeller, aritmi (AF), konjestif kalp yetmezliği (KKY) ve normal sinüs ritmi (NSR) sinyallerini içeren veri seti üzerinde performans açısından değerlendirilmiştir. OD-1D-LBP metodu, EKG sinyallerindeki farklılıkları yakalayabilmek için kullanılan yenilikçi bir tekniktir ve özellikle farklı kalp rahatsızlıklarının tespitinde LBP'nin özellik çıkarma kabiliyetini, derin öğrenme yöntemleriyle birleştirerek sınıflandırma başarısını artırmayı amaçlamaktadır.

Son olarak, yine Veri Seti-2 üzerinde gerçekleştirilen bir başka uygulamada, veri ön işleme aşamasında yeni bir metodoloji olarak önerilen Motif dönüşümü (MD) tabanlı bir yaklaşımın performansı test edilmiştir. Bu bağlamda, MD+CWT+DenseNET hibrit sınıflandırma modeli ile veri ön işleme ve sınıflandırma süreçlerinin performansı değerlendirilmiştir. Motif dönüşümü, EKG sinyallerinin karakteristik özelliklerini daha verimli bir şekilde çıkararak, zaman-frekans analizini sürekli dalgacık dönüşümü (CWT) ile birleştirip, derin sinir ağı yapısı olan DenseNET ile güçlendirilmiştir. Bu yöntem, sinyallerin daha ayrıntılı ve hassas analizine imkân vererek, sınıflandırma doğruluğunu en üst seviyeye çıkarmayı amaçlamaktadır. Bu çalışmalar sonucunda, her bir hibrit modelin ilgili veri setleri üzerinde ne kadar etkili olduğu belirlenmiş ve bu yöntemlerin klinik uygulamalarda kullanılabilecek sınıflandırma algoritmalarına dönüştürülme potansiyelleri değerlendirilmiştir.


4.1. Veri Seti-1 (VA-SVA-FA-TA-NSR)

Veri Seti-1, Massachusetts Institute of Technology (MIT) ve Beth Israel Hospital (BIH) iş birliğiyle 1975-1979 yılları arasında toplanmış geniş kapsamlı bir veri setidir. Bu veri seti, kalp aritmilerinin analizi için önemli bir referans kaynağıdır ve özellikle sinyal işleme ve makine öğrenmesi çalışmalarında kullanılmaktadır (Moody & Mark, 2001). Veri setinin ham hali, her biri yaklaşık 30 dakika uzunluğunda olan 48 farklı kayıttan oluşmaktadır. Her bir kayıt, iki kanallı EKG sinyallerini içermekte ve saniyede 360 örnekleme frekansı ile toplanmıştır. Bu yüksek örnekleme frekansı, sinyallerin

detaylı bir analizine olanak tanımaktadır. Ayrıca, sinyallerin 11-bit çözünürlükte kaydedilmesi ve 10 mV tam ölçekli ölçüm kullanılması, EKG sinyallerinin detaylı bir şekilde incelenmesine imkân sağlamaktadır (Goldberger vd., 2000c). Bu özellikler, veri setinin aritmi sınıflandırma çalışmaları için güçlü bir temel oluşturmasını sağlar. Veri seti hem normal sinüs ritmi hem de aritmik kalp ritimlerinin incelenmesi ve sınıflandırılması için kullanılmaktadır. Aritmik olayların detaylı bir şekilde analiz edilmesine olanak tanıyan bu veri seti, sinyal işleme algoritmalarının geliştirilmesi ve doğrulanması için yaygın bir şekilde tercih edilmektedir.

Bu çalışmada kullanılan MIT-BIH aritmi veri seti, orijinal olarak 360 Hz örnekleme frekansına sahip olmasına rağmen, çalışmamızda sinyaller 125 Hz'e yeniden örneklenmiştir. Bu yeniden örnekleme işlemi, hem verilerin işlenmesinde hesaplama maliyetini düşürmek hem de belirli uygulamalarda sinyal çözünürlüğünü optimize etmek amacıyla yapılmıştır. Yeniden örnekleme işlemi, sinyalin genel yapısını ve özelliklerini koruyarak daha düşük bir örnekleme hızında analiz yapılmasına olanak tanımıştır. Bu işlem, sinyal işleme algoritmalarının etkinliğini ve performansını artırmak için sıkça başvurulmuş bir tekniktir.

Çalışma kapsamında, MIT-BIH aritmi veri setinden elde edilen ventriküler atım (VA), supraventriküler atım (SVA), füzyon atımları (FA) ve tanımlanmamış atım çeşidi (TA) olmak üzere dört farklı aritmi türüne ait EKG verileri ile normal sağlıklı bireylere ait kalp atımlarını gösteren normal sinüs ritmi (NSR) verileri kullanılmıştır (Moody ve Mark, 2001; Goldberger ve ark., 2000). Bu veri seti, her biri 187 örnek içeren toplam 113.382 adet EKG kaydından oluşmaktadır. Bu kayıtlar arasında 90.589 adet NSR, 7.236 adet ventriküler atım (VA), 5.179 adet supraventriküler atım (SVA), 2.339 adet füzyon atım (FA) ve 8.039 adet tanımlanmamış atım (TA) bulunmaktadır. Tüm EKG verileri, 125 Hz örnekleme frekansına sahiptir. Aşağıda Şekil 4.1'de, veri setindeki NSR, VA, SVA, FA ve TA atımlarına ait örnek EKG grafikleri sunulmaktadır. Bu grafikler, farklı aritmi türlerinin EKG sinyallerindeki karakteristik özellikleri görsel olarak ortaya koymaktadır.



Şekil 4.1. Farklı EKG sinyal örnekleri

Veri setindeki EKG sinyallerini içeren Şekil 4.1’de, farklı aritmi türlerinin normal sinüs ritmi ile kıyaslandığında ne kadar belirgin bir farklılık sergilediği açıkça gözlemlenmektedir. Normal Sinüs Ritmi (NSR), düzenli ve istikrarlı kalp atımlarını temsil ederken, diğer aritmi türleri olan ventriküler atım (VA), supraventriküler atım (SVA), füzyon atımı (FA) ve tanımlanmamış atım (TA), kalp ritminde düzensizlikler ve normal dışı dalga şekilleri göstermektedir. Bu grafikler, aritmilerin tanınmasını ve analizini kolaylaştırmak için önemli bir referans sunmaktadır. Her aritmi türü, kendi karakteristik özellikleriyle sinyallerde fark edilmekte, bu da teşhis ve tedavi süreçlerinde önemli bir rol oynamaktadır. Sonuç olarak, bu sinyallerin detaylı analizi, aritmi tespiti ve sınıflandırılması için büyük önem taşımakta olup, doğru teşhis için gerekli olan kalp ritmindeki anormal değişikliklerin görsel bir ifadesini sağlamaktadır.

4.2. Veri Seti-2 (AF-KKY-NSR)

Bu veri setinde, aritmi (AF) ve normal sinüs ritmi (NSR) verileri MIT-BIH aritmi veri tabanından, konjestif kalp yetmezliği (KKY) verileri ise Beth Israel Deaconess

Medical Center (BIDMC) veri tabanından elde edilmiştir (Baim vd., 1986; Moody & Mark, 2001). BIDMC verileri ileri düzeyde konjestif kalp yetmezliği olan 15 denneğin uzun süreli EKG kayıtlarını içermektedir. Bu denekler, yaşları 22 ile 71 arasında değişen 11 erkek ve yaşları 54 ile 63 arasında değişen 4 kadından oluşmakta olup, tüm hastalar NYHA sınıf 3–4 kategorisinde, yani ciddi kalp yetmezliği olan bireylerdir. Bu grup, daha geniş bir çalışma grubunun bir parçasını teşkil etmekte olup, oral inotropik ajan milrinone tedavisi(kalp yetmezliğini hafifleten ve kan dolaşımını iyileştiren ilaç tedavisi) almadan önce geleneksel tıbbi tedavi görmüşlerdir (Baim vd., 1986; Goldberger vd., 2000a; Moody & Mark, 2001).


Veri setindeki ham EKG kayıtları yaklaşık 20 saat sürmekte ve her bir kayıt, saniyede 250 örnekle alınan, 12-bit çözünürlükte, ± 10 milivolt aralığında iki adet EKG sinyali içermektedir. Orijinal analog kayıtlar, Boston'daki Beth Israel Hastanesi'nde (günümüzde Beth Israel Deaconess Tıp Merkezi) ambulatuvar EKG kaydedicileri kullanılarak gerçekleştirilmiştir ve kayıtlar, tipik olarak yaklaşık 0.1 Hz ile 40 Hz arasında değişen bir bant genişliğinde alınmıştır. Bu veri seti, hem ileri düzeyde kalp yetmezliği olan hastaların klinik izlemelerine dayalı olarak detaylı EKG kayıtları sağlamakta hem de bu kayıtların analiz edilmesiyle ilgili yapılan ek çalışmalar için zengin bir kaynak sunmaktadır. Veri setinin geniş kapsamlı ve uzun süreli olması, araştırmacılara hem klinik gözlemler hem de sinyal işleme alanındaki analizler için güçlü bir veri kaynağı sunmaktadır.

Bu veri seti toplamda 162 adet EKG sinyali içermektedir ve bu sinyallerin 96'sı aritmi (AF), 30'u konjestif kalp yetmezliği (KKY) ve 36'sı normal sinüs ritmi (NSR) olarak sınıflandırılmıştır. Şekil 4.2'de örnek EKG sinyalleri sunulmaktadır. Şekilden de gözlemlenebileceği üzere, AF sinyalleri arasında atımlar arasında belirgin varyasyonlar bulunmaktadır. Buna karşılık, NSR sinyalleri, daha tutarlı aralıklarla atım gösteren bir yapıya sahiptir. KKY sinyalleri ise kalbin pompalama etkinliğinde bir düşüş olduğunu işaret etmektedir. AF sinyalleri, yaşları 23 ile 89 arasında değişen 47 bireyden (25 erkek, 22 kadın) elde edilmiş olup, bu sinyallerin toplamda 576 segmenti bulunmaktadır. KKY sinyalleri ise, yaşları 22 ile 71 arasında değişen 15 bireyden (11 erkek, 4 kadın) elde edilen toplam 180 segmentten oluşmaktadır. Son grup olan NSR sinyalleri, yaşları 20 ile 50 arasında değişen 18 bireyden (5 erkek, 13 kadın) elde edilen toplam 216 segmentten oluşmaktadır. Aşağıda Tablo 4.1'de veri seti ile ilgili detaylı bilgiler verilmiştir.

Tablo 4.1. Veri seti-2 (AF-KKY-NSR)) ait bilgiler

EKG	EKG Segment uzunlukları	Hasta Sayıları	Cinsiyet		Yaş Aralıkları	
			Erkek	Kadın	Erkek	Kadın
AF	576	47	25	22	32-89	23-89
KKY	180	15	11	4	22-71	54-63
NSR	216	18	5	13	26-45	20-50

EKG Sinyalleri - Farklı Kayıtlar



Şekil 4.2. NSR, KKY ve AF sinyallerine ait grafikler

5. METODOLOJİ

EKG sinyallerinden öznitelik çıkarma ve sınıflandırma aşamaları, kalp ritmi bozukluklarını teşhis etmek ve sinyalleri kategorize etmek amacıyla yapılan üç ana adımdan oluşur. Aşağıda, bu süreçlerin her bir aşaması detaylandırılmıştır ve açıklamalar uygun bir blok şema görseli ile Şekil 5.1’de desteklenmiştir. EKG sinyalleri, ham veri olarak oldukça karmaşık sinyallerdir. Öznitelik çıkarma işlemi, bu ham sinyallerden anlamlı ve yararlı bilgileri elde etmeyi amaçlar. Öznitelik çıkarma adımları şunları içerir:

- **Sinyal Ön İşleme:** EKG sinyalleri, genellikle çevresel gürültü, elektromanyetik parazitler ve vücut hareketlerinden kaynaklanan artefaktlar gibi istenmeyen bileşenler içerebilir. Bu nedenle, sinyallerin daha sağlıklı ve anlamlı hale getirilmesi için filtreleme ve arıtma işlemleri yapılır. Bant geçiren filtreler, istenmeyen düşük ve yüksek frekans bileşenlerini ortadan kaldırarak yalnızca ilgili frekans aralığındaki sinyalleri geçirir. Temel kayma düzeltmeleri ise, sinyalin baz hattındaki sapmaları düzelterek sinyalin doğru bir şekilde yorumlanmasını sağlar. Ayrıca, daha ayrıntılı bir ön işleme sürecinde yüksek geçiren filtreler ile düşük frekanslı gürültüler ortadan kaldırılırken, düşük geçiren filtreler yüksek frekanslı parazitleri baskılar. Buna ek olarak, sinyallerin düzgün bir ölçekleme ile analiz edilebilmesi için normalizasyon uygulanır, böylece farklı genlik değerlerine sahip sinyaller karşılaştırılabilir hale gelir. Bu işlemler, sinyalin saflaştırılmasını ve daha sonraki analiz adımları için uygun hale getirilmesini sağlar.

- **Zaman ve Frekans Eksenli Öznitelikleri:** EKG sinyalinden anlamlı bilgilerin çıkarılabilmesi için zaman ve frekans alanında özniteliklerin belirlenmesi kritik bir aşamadır. Zaman eksenli öznitelikler, sinyalin doğrudan zamana dayalı karakteristiklerini ifade eder ve genellikle sinyallerin ortalaması, maksimum ve minimum tepe noktaları, varyansı ve kalp atımları arasındaki R-R aralıkları gibi önemli ölçümleri içerir. Bu öznitelikler, sinyalin genel yapısını ve zamansal değişikliklerini anlamaya yönelik ipuçları sunar. Örneğin, R-R aralıkları aritmilerin tespitinde temel veriler arasında yer alır. Bununla birlikte, sinyallerin frekans eksenli öznitelikleri, sinyalde gizlenmiş frekans bileşenlerini ortaya çıkarmak amacıyla Fourier dönüşümü (FD), kısa zamanlı Fourier dönüşümü (STFT) ve Dalgacık dönüşümü (DD) gibi yöntemler kullanılarak elde edilir. Fourier dönüşümü, sinyalin tüm zaman boyunca ortalama frekans bileşenlerini ortaya koyarken, kısa zamanlı Fourier dönüşümü (STFT), sinyaldeki frekansların zamanla nasıl değiştiğini anlamak için kullanılır. STFT ile, sinyalin hem zamansal hem

de frekans bileşenlerini bir arada analiz ederek zaman-frekans çözünürlüğü elde edilir. Daha ileri bir analiz yöntemi olan Dalgacık dönüşümü (DD), sinyalin hem düşük frekanslı (genel yapı) hem de yüksek frekanslı (detaylar ve anormallikler) bileşenlerini ortaya koyar. Dalgacık katsayıları, sinyalin zaman-frekans alanında daha detaylı analizini sağlar ve sinyaldeki kısa süreli anomalilerin tespitinde oldukça etkilidir. Bu yöntem ile elde edilen veriler, sinyalin ayrıntılı bir zaman-frekans çözümlemesini sunan spektrogram ve skalogram analizleriyle görselleştirilir. Spektrogram, sinyalin frekans bileşenlerini zamana bağlı olarak renkli bir harita ile gösterirken, skalogram ise dalgacık katsayılarını kullanarak sinyalin hem zamansal hem de frekans alanındaki davranışlarını incelemek için güçlü bir araçtır. Bu analizler sayesinde, sinyalin yapısındaki hem zamansal hem de frekans eksenli değişiklikler net bir şekilde ortaya konarak, sınıflandırma algoritmalarına uygun öznitelikler oluşturulur.

- **P, QRS ve T Dalgaları:** EKG sinyallerinde en kritik öznitelikler, P, QRS ve T dalgalarıdır. Bu dalgaların genlikleri, zaman aralıkları ve morfolojileri öznitelik çıkarma işlemi için önemlidir.

Öznitelikler çıkarıldıktan sonra, bu bilgilerin bir sınıflandırıcı model tarafından işlenmesi gerekir. Bu aşama, çıkarılan özniteliklerin çeşitli algoritmalarla analiz edilerek doğru kategoriye atanmasını içerir. Kullanılan başlıca sınıflandırma yöntemleri:

- **Destek Vektör Makineleri (SVM):** Destek Vektör Makineleri (SVM), özellikle doğrusal olmayan veri kümelerinin ayrıştırılması ve sınıflandırılmasında sıklıkla tercih edilen güçlü bir makine öğrenmesi algoritmasıdır. Bu yöntem, EKG sinyallerinden çıkarılan özniteliklerin sınıflandırılmasında büyük etkinlik gösterir ve temel olarak sınıflar arasındaki en iyi ayırt edici sınırı bulmayı hedefler. SVM, öznitelikler arasında optimum bir ayırma hiper düzlemi oluşturmak suretiyle, sınıflandırma işlemini gerçekleştirir. Özellikle EKG sinyalleri gibi karmaşık ve gürültülü verilerde, sınıflar arasında lineer bir ayırım yapılamadığı durumlarda, SVM'nin doğrusal olmayan sınıflandırmalarda kernel (çekirdek) fonksiyonlarını kullanarak bu verileri daha yüksek boyutlu bir uzaya dönüştürmesi, sınıflandırma performansını artıran önemli bir faktördür. Bu dönüşüm, özellikle aritmi gibi kardiyak anormalliklerin tespit edilmesinde yüksek doğruluk oranlarına ulaşmayı sağlar. SVM'nin RBF (Radial Basis Function) gibi kernel fonksiyonları, EKG sinyallerinden çıkarılan zaman ve frekans eksenli öznitelikleri üzerinde etkili bir şekilde çalışarak, farklı aritmi türlerinin birbirinden ayrılmasını mümkün kılar.


- **Yapay Sinir Ağları (ANN):** Yapay Sinir Ağları (ANN), biyolojik sinir ağlarını taklit eden ve EKG sinyallerinin öğrenme ve sınıflandırılmasında yaygın olarak kullanılan derin öğrenme tabanlı bir yöntemdir. ANN, çok katmanlı yapısı sayesinde, EKG sinyallerindeki hem düşük seviyeli öznitelikleri (P, QRS, T dalgaları) hem de daha karmaşık örüntüleri öğrenme kapasitesine sahiptir. Giriş katmanına sunulan sinyaller, gizli katmanlardaki nöronlar aracılığıyla işlenir ve sinir hücrelerinin ağırlıkları, geri yayılım algoritması kullanılarak optimize edilir. Bu süreç, sinyallerdeki hataları minimize ederek, sınıflandırma doğruluğunu artırmayı amaçlar. ANN hem doğrusal hem de doğrusal olmayan ilişkileri öğrenme yeteneği sayesinde, aritmi gibi karmaşık kalp hastalıklarının tespitinde büyük başarı gösterir. Yapay sinir ağlarının esnek ve derinlemesine öğrenme yapısı, EKG sinyallerinin doğru analiz edilmesine önemli katkı sağlar.

- **LSTM ve GRU Tabanlı Modeller:** LSTM ve GRU özellikle zaman serisi verileri gibi ardışık ve zamana bağlı sinyallerin işlenmesinde etkili olan derin öğrenme modelleridir. Bu modeller, EKG sinyallerinin dinamik yapısını öğrenmek ve sinyaller arasındaki uzun süreli bağımlılıkları yakalamak için tasarlanmıştır. LSTM ve GRU, klasik yapay sinir ağlarına göre daha gelişmiş bir bellek mekanizmasına sahip olup geçmişteki bilgileri koruyarak sinyalin zamansal yapısındaki önemli olayları ve örüntüleri tanımlamada yüksek performans gösterir. Bu özellikleri sayesinde, kalp atımları arasındaki ilişkileri ve aritmi gibi anomalileri daha etkin bir şekilde analiz ederler. LSTM ve GRU'nun ardışık verilerle çalışabilme kabiliyeti, özellikle EKG sinyallerinin analizinde doğru ve güvenilir sınıflandırmalar yapma potansiyelini artırmaktadır.

Şekil 5.1’de gösterilen blok şemadaki sıralamaya göre, EKG sinyalleri öncelikle gürültü ve istenmeyen bileşenlerin giderildiği bir sinyal ön işleme aşamasından geçirilir. Bu aşamada, sinyallerin temizlenmesi amacıyla bant geçiren filtreler, yüksek geçiren filtreler ve düşük geçiren filtreler gibi teknikler uygulanarak hem temel kayma hem de elektromanyetik gürültü gibi istenmeyen sinyaller ortadan kaldırılır. Ayrıca, sinyallerin daha iyi analiz edilebilmesi için normalizasyon işlemi yapılır. Normalizasyon, sinyallerin farklı genlik ve ölçeklerdeki değerlerinin sabit bir aralıkta toplanmasını sağlayarak analiz ve sınıflandırma süreçlerinde karşılaştırılabilir hale getirir. Bu ön işleme adımından sonra, EKG sinyalleri üzerinde öznitelik çıkarma işlemi gerçekleştirilir. Zaman ve frekans alanındaki öznitelikler, sinyalin anlamlı bilgi taşıyan bölümlerini elde etmek için kullanılır. Zaman eksenli öznitelikleri, sinyaldeki P, QRS ve T dalgalarının genlikleri, süreleri ve aralıkları gibi özellikleri içerirken, frekans eksenli öznitelikleri, sinyaldeki

frekans bileşenlerinin analizini sağlar. Frekans analizinde, genellikle Fourier dönüşümü, kısa süreli Fourier dönüşümü (STFT) ve sürekli dalgacık dönüşümü (CWT) gibi teknikler kullanılır. Frekans alanındaki bu analizler, sinyallerin zaman-frekans çözümlemelerini sağlamak için spektrogram ve skalogram yöntemleriyle görselleştirilir. Spektrogram, sinyaldeki frekansların zaman içindeki değişimlerini renkli bir harita ile gösterir, böylece sinyaldeki belirgin anomaliler gözlemlenebilir. Skalogram ise dalgacık katsayıları kullanılarak sinyalin hem zaman hem de frekans alanındaki değişimlerini inceleyen bir tekniktir.

Bu yöntemler, sinyalin sadece zamansal değil, frekans yapısını da ortaya koyarak EKG sinyallerindeki anormalliklerin tespit edilmesine olanak tanır. Bu özneliklerin çıkarılmasından sonra, elde edilen veriler makine öğrenmesi veya derin öğrenme algoritmalarına beslenir. Bu aşamada, sıklıkla LSTM, 1D-CNN ve SVM gibi algoritmalar kullanılır. Bu modeller, sinyallerin öğrenilmesi ve sınıflandırılması için özelleştirilmiştir. Özneliklerin sınıflandırıcıya verilmesiyle, her bir sinyalin belirli bir kategoriye atanması sağlanır. Son olarak, sınıflandırıcı model, EKG sinyallerini doğru kategoriye (örneğin, normal sinüs ritmi (NSR), ventriküler atım (VA) veya supraventriküler atım (SVA)) atayarak sınıflandırma sonucunu verir. Modelin performansı, doğruluk, hassasiyet ve özgüllük gibi metrikler ile değerlendirilir ve böylece sınıflandırma algoritmasının başarı oranı ölçülür.



Şekil 5.1. EKG sinyallerinden öznelik çıkarma ve sınıflandırma aşamaları

5.1. Öznelik Çıkarım Yaklaşımları

Tez çalışması kapsamında, EKG sinyallerinden daha etkili ve ayırt edici özniteliklerin elde edilmesine yönelik çeşitli yeni metotlar önerilmiştir. Bu yöntemler, görüntü işleme alanında sıklıkla kullanılan yerel ikili desen algoritmasını (LBP) tek boyutlu sinyallere uyarlayarak, EKG sinyallerine özgü dinamik yapıların ve örüntülerin daha etkin bir şekilde tespit edilmesini sağlamaktadır. Özellikle bir boyutlu ortogonal fark yerel ikili desen (1D-OD-LBP) yöntemi, sinyalin her bir noktasının komşularıyla karşılaştırılması yoluyla ikili bilgiler üreterek öznitelik çıkarımı yapılmasına imkân tanır. Ortogonal fark alma yöntemi, belirli yönlerde (örneğin, yatay, dikey ve çapraz) farkların alınmasını içerir. Bu yöntem, sinyaldeki yerel yönelim ve desen bilgisini daha iyi yakalamaya yardımcı olur. Bu metot, EKG sinyallerindeki yerel farklılıkları tespit etmeye odaklanmış olup, çıkışta 0-255 arasında değişen sinyal değerleri oluşturarak sınıflandırma için kullanılır. Bu oluşturulan değerler ile, sinyalin yapısal özelliklerini özetleyen histogramlar oluşturur.

Benzer şekilde, merkezden bağımsız bir boyutlu yerel ikili desen (CI-1D-LBP) yöntemi, klasik yerel ikili desen (LBP) algoritmasının tek boyutlu sinyallere uygulanması için geliştirilen bir öznitelik çıkarma tekniğidir. Bu yöntem, sinyalin komşu noktalar arasındaki değişim trendini belirlemek için uygundur. Daha çok dizisel bağımlılıkları yakalar. Matematiksel olarak 1D-OD-LBP yöntemine göre daha basit ve daha az işlem yükü getirir. CI-1D-LBP, sinyallerdeki yerel örüntüleri detaylı yakalamak ve sinyalin yapısal özelliklerini sınıflandırma için anlamlı özniteliklere dönüştürmek amacıyla tasarlanmıştır. CI-1D-LBP yönteminde, her bir sinyal noktası, belirli bir pencere içinde yer alan komşu noktalarıyla karşılaştırılır. Bu karşılaştırmalar sonucunda, her nokta için bir ikili kodlama yapılır. Yani, bir sinyal noktası, komşu noktalarından daha büyük veya daha küçük olup olmadığına göre ikili 0 ve 1 değerleri alır. Bu şekilde, sinyal boyunca hareket eden bir pencere fonksiyonu aracılığıyla, her bir pencere için bir LBP örüntü değeri oluşturulur. CI-1D-LBP'de, sinyallerde belirlenen dokuz nokta karşılaştırmaya tabi tutulur ve bu karşılaştırmalar sonucunda 0-255 arasında değişen LBP değerleri elde edilir. Bu LBP değerleri, sinyalin yapısal özelliklerini özetleyen histogramlar oluşturur.

Tez kapsamında yine farklı bir uygulamada kullanılmak üzere, yeni bir sinyal ön işleme-örüntüleme metodu olarak Motif dönüşümü (MD) geliştirilmiştir. Bu yöntem, geleneksel CWT'nin dezavantajlarını ortadan kaldırmayı amaçlamakta ve daha etkin öznitelik çıkarımı sağlamaktadır. MD dönüşümü, EKG sinyallerinin her bir örnek değerinin büyüklük ve küçüklük açısından kıyaslanmasıyla motifler oluşturarak, bu motiflere uygulanan CWT sonucunda elde edilen skalogram görüntüleriyle daha doğru

sınıflandırma yapılmasına olanak tanır. Bu şekilde, önerilen yöntemler sayesinde EKG sinyallerinden çıkarılan öznitelikler daha yüksek doğruluk oranlarıyla sınıflandırma modellerine entegre edilmiştir.

5.1.1. Tek boyutlu ortogonal fark yerel ikili desen (1D-OD-LBP)


Yerel ikili desenler (LBP), ilk olarak Ojala ve arkadaşları tarafından iki boyutlu görüntü işleme alanında tanıtılmıştır ve doku analizi, yüz tanıma ve görüntü segmentasyonu gibi uygulamalarda yaygın olarak kullanılmıştır (Ojala vd., 1996). LBP'nin temel çalışma prensibi, bir merkez pikselin çevresindeki komşu piksellerle karşılaştırılması sonucu elde edilen ikili bir kodlama sistemine dayanır ve bu kodlama sistemi üzerinden yerel örüntülerin çıkarımı gerçekleştirilir (Nanni vd., 2010). 2 boyutlu görüntü işleme alanında başarılı sonuçlar elde edilen bu yöntem, son yıllarda biyomedikal sinyaller gibi tek boyutlu sinyallerin analizine uyarlanarak kullanılmaktadır (Akdağ vd., 2022). Özellikle zaman serileri ve biyomedikal sinyallerin incelenmesi için tek boyutlu LBP (1D-LBP) yöntemleri geliştirilmiş, bu yöntemlerle sinyallerin lokal örüntüleri daha hassas bir şekilde analiz edilebilmiştir.

Bu çalışmada, iki boyutlu LBP yönteminin temellerinden esinlenerek geliştirilen ve tek boyutlu sinyallere uyarlanan OD-1D-LBP yöntemi sunulmaktadır. OD-1D-LBP, her bir örnek nokta (merkez) ile sağ ve sol komşuları arasında yapılan ortogonal fark hesaplamaları sonucu elde edilen ikili kodlamayı kullanarak sinyalin yerel örüntülerini ortaya çıkarır. Elde edilen bu ikili kodlar, sinyalin her bir noktasındaki örüntülerin daha detaylı ve anlamlı bir şekilde analiz edilmesine olanak sağlar.

OD-1D-LBP yöntemi, bir sinyalin her bir örnek noktasını (merkez nokta olarak belirlenen P_c) çevresindeki komşu noktalarla karşılaştırarak, sinyaldeki lokal örüntüleri yakalamayı amaçlar. Sinyalin her bir örnek noktası, 3×3 'lük bir matris içine yerleştirilir ve bu merkez nokta, 8 komşu noktayla ortogonal olarak karşılaştırılır. Sinyalin önemli noktalarını seçip bu tip bir matris oluşturarak, belirgin kardiyak olayların daha iyi yakalanmasını sağlanır. Bu, sinyalin daha anlamlı ve daha öngörülebilir hale gelmesine yardımcı olur. Bu matris, EKG sinyallerini daha iyi görselleştirmek ve örüntü çıkarımı yapmak için kullanılmaktadır. OD-1D-LBP yöntemi aşağıdaki örnek sinyal parçası üzerinde detaylıca anlatılmıştır.

Şekil 5.2 (a)'daki sinyal boyunca herhangi bir örnek nokta " P_c " olarak seçilip, o anki sinyal verisinin etrafındaki komşu noktalar (P_1 - P_8) ile değerlendirilmiştir. P_c için


solundan {P1,P2,P3,P4} ve sağından {P5,P6,P7,P8} komşu alınmıştır. Bu değerler bir vektör olarak Şekil 5.2 (b)'de görülmektedir. Daha sonra bu değerler Şekil 5.2 (c)'deki gibi 3x3 şeklinde bir matris şeklinde gösterilmiştir. Bu 3x3'lük matris, merkezdeki Pc noktasının ortogonal komşularla karşılaştırılması için düzenlenmiştir. Yani merkez noktadaki değer (Pc) etrafındaki 8 komşu ile karşılaştırılmakta ve bu komşu değerlerin Pc'ye göre büyük mü küçük mü olduğu analiz edilmektedir. Bu karşılaştırmalar sonucunda bir ikili kodlu vektör oluşturulmakta ve bu, sinyalin her bir örnek noktasındaki lokal örüntüyü tanımlamaya yardımcı olmaktadır.



Şekil 5.2. OD-1D-LBP yönteminin örnek bir sinyale uygulanması

Bu yaklaşımda her bir nokta için hesaplamalar iki ortogonal konum ile yapılmaktadır. İki ortogonal durum için noktalar arasındaki komşuluk bilgisi Şekil 5.3'te verilmiştir. Birinci ortogonal gösterim Şekil 5.3(a) gösterilmektedir. {P1, P3, P5 ve P7} noktaların komşu oldukları noktalar arasındaki ilişki gösterilmektedir. Örneğin P1 noktasının {P2, Pc ve P8} ile komşuluğu bulunmaktadır. P5 noktası ise {P4,Pc ve P6} ile komşudur. Diğer noktaların komşuluk ilişkileri Şekil 5.3 üzerinde oklar ile gösterilmiştir. İkinci ortogonal gösterim ise Şekil 5.3(b)'de verilmiştir. Burada {P2, P4, P6 ve P8} merkez nokta ile diğer komşu noktalar arasındaki bağlantılar gösterilmektedir. İkinci

ortogonal durum için P2 noktası {P1, Pc ve P3} ile komşudur. Diğer P4, P6 ve P8 noktaların komşuluk bilgileri şekil üzerinde görülmektedir.



Şekil 5.3. OD-1D-LBP ortogonal pozisyonlar

Şekil 5.3'te gösterilen ortogonal pozisyonlar için fark değerleri aşağıdaki eşitlikler ile elde edilmektedir.

$$D1 = [(P1 - P2), (P1 - Pc), (P1 - P8)] \quad (5.1)$$

$$D2 = [(P3 - P2), (P3 - Pc), (P3 - P4)] \quad (5.2)$$

$$D3 = [(P5 - P4), (P5 - Pc), (P5 - P6)] \quad (5.3)$$

$$D4 = [(P7 - P6), (P7 - Pc), (P7 - P8)] \quad (5.4)$$

$$D5 = [(P2 - P1), (P2 - Pc), (P2 - P3)] \quad (5.5)$$

$$D6 = [(P4 - P3), (P4 - Pc), (P4 - P5)] \quad (5.6)$$

$$D7 = [(P6 - P5), (P6 - Pc), (P6 - P7)] \quad (5.7)$$

$$D8 = [(P8 - P7), (P8 - Pc), (P8 - P1)] \quad (5.8)$$

Bu eşitlikler, Pc etrafındaki 8 komşu noktanın fark değerlerini elde ederek sinyalin lokal örüntüsünü çıkarma yöntemini göstermektedir. Her bir ortogonal pozisyon için üçer fark değerinin hesaplanması, sinyaldeki yönlü değişimlerin daha detaylı bir şekilde incelenmesine olanak tanımaktadır. Eşitliklere bakıldığında her nokta merkez ve diğer komşular arasındaki farklar alınmaktadır. Örneğin P1 noktası için komşu olduğu P2, Pc ve P8 noktalar ile farklar alınmıştır. Burada D1, D2, D3 ve D4, birinci ortogonal grubun farklarına ait vektörler ve D5, D6, D7 ve D8, ikinci ortogonal grubun farklarına ait vektörlerdir. Daha sonra bu elde edilen vektörler, üretilen eşik bir değer ile karşılaştırılır. Eşik değerler aşağıdaki denklem (5.9)'a göre oluşturulmaktadır. Bu hesaplamalar, her bir noktanın merkezle ve komşu noktalarla olan farklarını çıkartarak sinyalin lokal yapısını anlamayı sağlamaktadır. Böylece sinyaldeki her bir örnek noktanın etrafındaki yapısal değişiklikleri daha hassas bir şekilde incelenebilmektedir. Eşik değer her fark vektörü

{D1, D2, D3, D4, D5, D6, D7 ve D8} için ayrı ayrı hesaplanır. Her eşik değeri ait olduğu fark vektörünün toplamıdır.

$$Threshold = \sum_{i=1}^n x_i, \text{ where } n = 3 \quad (5.9)$$

Burada i her fark vektöründeki 3 tane değeri belirtir. Bu eşitlik uygulandığında sekiz adet eşik değeri {T1, T2, T3, T4, T5, T6, T7 and T8} elde edilmiş olacaktır. Sonraki aşamada her fark vektörü {D1, D2, D3, D4, D5, D6, D7 and D8} kendi eşik değeri ile karşılaştırılır. Bir farkın eşik değerden büyük eşit olması durumunda “1” diğer durumda “0” şeklinde bir bitlik değeri oluşturmaktadır. Karşılaştırma işlemleri aşağıdaki eşitliklere göre gerçekleştirilmektedir.

$$BP1 = \begin{cases} D1 \geq T1 & 1 \\ D1 < T1 & 0 \end{cases}, \quad BP2 = \begin{cases} D2 \geq T2 & 1 \\ D2 < T2 & 0 \end{cases} \quad (5.10)$$

$$BP3 = \begin{cases} D3 \geq T3 & 1 \\ D3 < T3 & 0 \end{cases}, \quad BP4 = \begin{cases} D4 \geq T4 & 1 \\ D4 < T4 & 0 \end{cases} \quad (5.11)$$

$$BP5 = \begin{cases} D5 \geq T5 & 1 \\ D5 < T5 & 0 \end{cases}, \quad BP6 = \begin{cases} D6 \geq T6 & 1 \\ D6 < T6 & 0 \end{cases} \quad (5.12)$$

$$BP7 = \begin{cases} D7 \geq T7 & 1 \\ D7 < T7 & 0 \end{cases}, \quad BP8 = \begin{cases} D8 \geq T8 & 1 \\ D8 < T8 & 0 \end{cases} \quad (5.13)$$

Birinci ortogonal grup, BP1, BP2, BP3 ve BP4'ten oluşur ve her biri 3 bitlik bir vektördür. Bu dört vektör birleştirilerek toplamda 12 bitlik bir vektör elde edilir. Aynı şekilde, ikinci ortogonal grup, BP5, BP6, BP7 ve BP8'den oluşur ve her biri 3 bitten oluşur. Bu dört vektör bir araya getirilerek ikinci grup için de toplamda 12 bitlik bir vektör oluşturulur. Bu iki ortogonal grup yan yana birleştirilerek 24 bitlik bir vektör oluşturulur.

$$V = [BP1, BP2, BP3, BP4, BP5, BP6, BP7, BP8] \quad (5.14)$$

$$V = [b1, b2, b3, \dots, b24] \quad (5.15)$$

V vektörü 24 bitlik bir vektörü temsil eder. Daha sonra V vektörü 8 bitlik 3 parçaya bölünür.

$$1D - OD - LBP1 = [b1, b2, b3, \dots, b8] \quad (5.16)$$

$$1D - OD - LBP2 = [b9, b10, b11, \dots, b16] \quad (5.17)$$

$$1D - OD - LBP3 = [b17, b18, b19, \dots, b24] \quad (5.18)$$

Bu 8 bitlik değerlerin daha sonra onluk karşılıkları bulunarak sinyal üzerindeki bir noktanın OD-1D-LBP değerleri oluşturulmuş olur. Sinyal üzerindeki her bir nokta için

(A)

(B)

(C)

(D)

(E)

(F)

(G)

OD-1D-LBP Code 1=254


OD-1D-LBP Code 2=15

OD-1D-LBP Code 3=255

Şekil 5.4 Ortogonal Fark 1D-LBP (OD-1D-LBP) algoritmasını adım adım açıklayan bir yapıya sahiptir. Her bir adımda, merkez nokta P_c etrafında belirlenen noktalar ve bu noktalar arasındaki karşılaştırmalar gösterilmektedir. Görselde, her aşama aşağıdaki gibi açıklanabilir:

1. **(A):** İlk aşamada 3x3'lük bir matris oluşturulmuş ve merkezde $P_c = 8$ değeri bulunmaktadır. Bu matrisin köşelerinde ve kenarlarında bulunan diğer noktalar ($P_1, P_2, \dots, P_8$) sayısal olarak gösterilmiştir.
2. **(B):** Bu adımda, merkez noktadaki P_c etrafındaki diğer komşu noktalar belirlenmiş, ancak henüz herhangi bir işlem yapılmamıştır. Bu matris, hesaplamalarda kullanılacak komşuluk yapısını göstermektedir.
3. **(C):** Komşu noktalar arasında belirli yönlerde (dikey, yatay veya çapraz) fark işlemi yapılmaktadır. Oklarla gösterilen yönler, hangi noktaların farkının alınacağını belirtir.
4. **(D):** Her bir yön için fark sonuçları gösterilmiştir. Örneğin, D_1, D_2, D_3 ve D_4 pozisyonları için hesaplanan fark değerleri -6, -5, 2 gibi sonuçlara sahiptir. Bu sonuçlar, merkez nokta ile komşu noktalar arasındaki farkları temsil eder.
5. **(E):** Bu adım, D pozisyonlarındaki fark değerlerinin karşılaştırılmasını içerir. Elde edilen fark sonuçlarına göre, pozitif veya negatif farklar belirlenmiş ve bir tür ikili değer atanmıştır (örneğin, 1 veya 0 gibi).
6. **(F):** Bu adımda, karşılaştırma sonuçları ikili formatta gösterilmiştir. Her bir D pozisyonu için karşılaştırma sonucu 1 veya 0 olarak gösterilmiştir. Bu ikili değerler, merkez noktanın etrafındaki yönler göre elde edilen öznitelik değerlerini temsil eder.
7. **(G):** Son aşamada, elde edilen ikili değerler bir araya getirilerek OD-1D-LBP kodları oluşturulmuştur. Örneğin, her bir yön için ayrı ayrı hesaplanan ikili değerler, bir bit dizisi olarak gösterilmiş ve her bir bit dizisinin karşılık geldiği OD-1D-LBP kodu belirtilmiştir.

Sonuç olarak OD-1D-LBP yönteminin bir sinyale uygulanması sonucunda, her örnek noktanın farklı ortogonal gruplar ve fark hesaplamalarıyla elde edilen özelliklerine göre üç farklı sinyal oluşturulur. Örnek bir sinyale OD-1D-LBP yönteminin uygulanmasından sonra oluşan bu üç sinyal, Şekil 5.5'te gösterilmiştir. Her bir sinyal, 0-255 aralığında değişen değerlere sahiptir. Oluşan bu sinyallerin daha sonra sınıflandırılabilir hale getirilmesi için histogram analizleri yapılır ve sonraki blokta, bu sinyallere ait histogramlar sunulmaktadır. Histogramlar, sinyallerdeki özelliklerin dağılımını inceleyerek sınıflandırma algoritmalarında kullanılacak öznitelikleri elde etmede önemli bir rol oynar.



Şekil 5.5. OD-1D-LBP çıktısı. (a) Örnek sinyal parçası, (b-d) 1D-OD-LBP çıktı sinyalleri


Şekil 5.5(a)'da orijinal sinyal, ham EKG sinyalini temsil etmekte olup, sinyaldeki tipik P, QRS ve T dalgaları açıkça görülmektedir. Şekil 5.5'teki (b), (c) ve (d) sinyalleri ise OD-1D-LBP yöntemiyle elde edilen üç farklı işlenmiş sinyali göstermektedir. Bu sinyaller, orijinal sinyalin lokal örüntülerini ve merkez nokta etrafındaki farklarla ilgili öznitelikleri içerir. Elde edilen bu işlenmiş sinyaller, orijinal sinyal ile ilgili daha detaylı bilgi sağlar ve her bir örnek noktanın çevresindeki örüntülerin vurgulanmasına olanak tanır. Bu sayede, sinyalin yapısal detayları daha belirgin hale getirilerek, sinyal işleme sürecinde kullanılmak üzere anlamlı öznitelikler elde edilir. Bu yöntem, sinyalin daha derin özelliklerini ortaya çıkaran bir işleme tekniğidir. Orijinal sinyalin örüntüleri, merkeze alınan noktanın etrafındaki komşularla karşılaştırılarak detaylı bir şekilde işleniyor ve ardından sınıflandırıcılar için uygun hale getirilmektedir. Özellikle EKG sinyallerindeki anomalileri tespit etmek için bu tip öznitelik çıkarma yöntemleri oldukça etkilidir.

5.1.2. Merkezden bağımsız bir boyutlu yerel ikili desen (CI-1D-LBP)

Bu tez çalışmasında, EKG analizi için yeni bir öznitelik çıkarım yöntemi olarak merkezden bağımsız bir boyutlu yerel ikili desen (CI-1D-LBP) önerilmiştir. CI-1D-LBP, tek boyutlu EKG sinyallerindeki lokal yapıları incelemek amacıyla geliştirilmiş yenilikçi bir tekniktir. Yöntemin ana amacı, sinyalin belirli bir penceresinde bulunan noktaların lokal özelliklerini ikili kodlarla temsil ederek, sinyalin karakteristik özelliklerini öznitelik vektörleri şeklinde çıkarmaktır.

Bu yaklaşım, özellikle aritmi gibi kalp ritmi bozukluklarının tespiti için özgün ve etkili bir çözüm sunmaktadır. Önerilen yöntemde, sinyal üzerinde hareket eden sabit bir pencere boyutu (Window Size - WS) tanımlanır. Bu çalışmada, pencere boyutu 9 olarak seçilmiştir. 9 noktalık bir pencere boyutunun tercih edilmesinin temel nedeni, sinyalin lokal yapılarını detaylı bir şekilde incelemeye olanak tanımasıdır. Daha küçük bir pencere, lokal değişimlerin tam olarak yakalanmasını engelleyebilirken, daha büyük bir pencere, sinyalin genel yapısını bozarak gereksiz bilgi içerebilir. 9 noktalık pencere, hem sinyalin karakteristik yapısını bozmadan lokal özellikleri yakalamaya imkân tanır, hem de çevresel varyasyonları yeterince kapsayarak anlamlı öznitelikler elde edilmesini sağlar. Bu pencere boyutu, sinyaldeki kısa süreli değişimlerin incelenmesinde avantaj sağlar ve özellikle aritmi gibi ritmik anomalilerin belirlenmesine yönelik güçlü bir yapıya sahiptir.

CI-1D-LBP yöntemi Şekil 5.6’da belirtilen EKG sinyal parçası üzerinde detaylıca anlatılmıştır. CI-1D-LBP sinyal üzerinde noktasal olarak ilerleyen, pencere boyutu $WS(Window\ Size)=9$ olan pencere içerisine giren değerler üzerinden gerçekleştirilmektedir. Herhangi bir zamanda $WS=9$ pencere içerisine giren değerler 9 adet değer olarak vektörel şekilde $P=\{P_c,P_1,P_2,P_3,P_4,P_5,P_6,P_7,P_8\}$ ifade edilmektedir.



Şekil 5.6. CI-1D-LBP yaklaşımının örnek EKG sinyal parçasına uygulanması

WS penceresine giren 9 değer, bir merkez nokta (P_c , Point Center) ve 8 komşu değer ($P = \{P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8\}$) olarak kabul edilir. Burada dikkat çekici bir unsur, pencere içerisindeki her bir değerın sırayla merkez (P_c) olarak seçilmesidir. Diğer bir deyişle, pencere içerisindeki her bir değer, belirli bir pozisyonda merkez olarak kabul

edilip, çevresindeki diğer 8 değerle karşılaştırılır. Şekil 5.7’de gösterildiği gibi, pencere içerisindeki her bir değer sırayla P_c olarak seçildiğinde toplam 9 farklı durum oluşur. Bu 9 durumun her birinde, P_c değeri, pencere içerisindeki diğer 8 komşu değerle karşılaştırılarak bir ikili dizi oluşturulur. Bu karşılaştırma işlemi şu koşullu ifadeye dayanır.

$$CI - 1D - LBP = \begin{cases} P_c > P_i & 1, & P_i = \{P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8\} \\ P_c \leq P_i & 0, & P_i = \{P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8\} \end{cases} \quad (5.19)$$

Bu koşula göre, P_c değeri her bir P_i ile kıyaslanır; P_c, P_i ’den büyükse sonuç “1”, küçük veya eşitse sonuç “0” olarak kaydedilir. Bu işlem sonucunda, her P_c değeri için 8-bitlik bir ikili dizi elde edilir. Bu ikili dizi, merkez değerın çevresindeki komşulara göre konumunu temsil eden bir öznitelik vektörü olarak kullanılır.

Bu yöntemde, pencere içerisindeki her bir noktanın sırasıyla merkez olarak seçilmesi, sinyalin her bölgesinde lokal detayların çıkarılmasına olanak tanır. CI-1D-LBP yöntemi sayesinde, sinyal boyunca elde edilen bu ikili diziler, aritmi gibi ritmik anomalilerin tespiti için anlamlı bir öznitelik kümesi sağlar. Şekil 5.7’de 9 uzunluğunda bir pencere ($WS = 9$) içinde her bir noktanın sırayla merkez nokta (P_c) olarak alındığı ve sekiz komşu nokta ile karşılaştırmaların yapıldığı sıralamayı göstermektedir. Görselde her satır, pencere içerisindeki farklı bir noktanın merkez olarak seçildiği durumu temsil etmektedir. Turuncu renkle işaretlenen değerler, her seferinde merkeze alınan P_c değerlerini göstermektedir; kırmızı renkle belirtilen diğer değerler ise o anki P_c ’nin komşuları olarak ele alınan noktalardır.

0.0966	0.1081	0.1150	0.1043	0.1167	0.1205	0.1477	0.1254	0.1572
P1	<u>Pc</u>	P2	P3	P4	P5	P6	P7	P8
0.0966	0.1081	0.1150	0.1043	0.1167	0.1205	0.1477	0.1254	0.1572
P1	P2	<u>Pc</u>	P3	P4	P5	P6	P7	P8
0.0966	0.1081	0.1150	0.1043	0.1167	0.1205	0.1477	0.1254	0.1572
P1	P2	P3	<u>Pc</u>	P4	P5	P6	P7	P8
0.0966	0.1081	0.1150	0.1043	0.1167	0.1205	0.1477	0.1254	0.1572
P1	P2	P3	P4	<u>Pc</u>	P5	P6	P7	P8
0.0966	0.1081	0.1150	0.1043	0.1167	0.1205	0.1477	0.1254	0.1572
P1	P2	P3	P4	P5	<u>Pc</u>	P6	P7	P8
0.0966	0.1081	0.1150	0.1043	0.1167	0.1205	0.1477	0.1254	0.1572
P1	P2	P3	P4	P5	P6	<u>Pc</u>	P7	P8
0.0966	0.1081	0.1150	0.1043	0.1167	0.1205	0.1477	0.1254	0.1572
P1	P2	P3	P4	P5	P6	P7	<u>Pc</u>	P8
0.0966	0.1081	0.1150	0.1043	0.1167	0.1205	0.1477	0.1254	0.1572
P1	P2	P3	P4	P5	P6	P7	P8	<u>Pc</u>
0.0966	0.1081	0.1150	0.1043	0.1167	0.1205	0.1477	0.1254	0.1572

Şekil 5.7. CI-1D-LBP metodunda olası Pc değerlerinin ve komşu noktaların gösterimi

Aşağıdaki Tablo 5.1’de örnek olarak, Şekil 5.9’da verilen dokuz farklı noktaya ait CI-1D-LBP yönteminin uygulanması ile oluşan 8 bitlik örüntülerin tablosu verilmiştir.


Tablo 5.1. CI-1D-LBP yönteminin uygulanması ile oluşan 8 bitlik örüntü tablosu

Merkez Nokta (Pc)	Merkez Noktaların Diğer Noktalar ile Karşılaştırma Sonuçları								8-bit Kod
P1	0	0	0	0	0	0	0	0	00000000
P2	1	0	1	0	0	0	0	0	10100000
P3	1	1	1	0	0	0	0	0	11100000
P4	1	0	0	0	0	0	0	0	10000000
P5	1	1	1	1	0	0	0	0	11110000
P6	1	1	1	1	1	0	0	0	11111000
P7	1	1	1	1	1	1	1	0	11111110
P8	1	1	1	1	1	1	0	0	11111100
P9	1	1	1	1	1	1	1	1	11111111

Bu tablo, merkez nokta olarak seçilen her bir değerin komşularına göre lokal özelliklerini ifade eden bir öznitelik vektörü oluşturulmasını sağlar. Kodlar, sinyalin lokal varyasyonlarını yakalamakta ve bu öznitelikler, özellikle aritmi gibi anormal durumların tespit edilmesinde anlamlı veri sağlamaktadır. 8-bit kodlar, sinyalin belirli pozisyonundaki lokal yapının detaylı bir özetini sunar ve bu öznitelikler daha sonra sınıflandırma veya analiz algoritmalarında kullanılabilir. Her bir karşılaştırma, merkez noktanın komşu noktalardan büyük ya da küçük olmasına göre ikili bir değer (1 veya 0) atayarak 8-bitlik bir öznitelik vektörü üretir. Bu 8-bitlik vektör, 0 ile 255 arasında bir değere çevrilir ve orijinal sinyalin belirli bir pozisyonundaki lokal yapıyı temsil eden bir öznitelik olarak kaydedilir.

CI-1D-LBP yöntemi, bu işlemi pencerenin sinyal boyunca kaydırılmasıyla her pozisyonda tekrarlar ve böylece sinyalin tüm noktaları için bir öznitelik seti oluşturur. Her bir merkez noktanın sırasıyla ele alınması ve diğer noktalarla karşılaştırılması, her pozisyonda orijinal sinyalin farklı bir perspektiften analiz edilmesini sağlar. Bu yapı, CI-1D-LBP yönteminin uygulandığı bir EKG sinyalinden 9 farklı sinyalin üretilmesine olanak tanır. Bu sinyaller, orijinal sinyalin lokal varyasyonlarını ikili kodlarla ifade ederek, her pozisyonun çevresi ile olan ilişkisini özetler. CI-1D-LBP yöntemi ile elde edilen bu sinyaller, orijinal sinyalin tüm lokal detaylarını içeren öznitelik sinyalleri olarak tanımlanabilir.

Şekil 5.8’da (a) ve (b) bölümlerinde gösterilen sonuçlar, CI-1D-LBP yönteminin bir örnek EKG sinyaline uygulanması ile elde edilen verileri ortaya koymaktadır. Şekil 5.8(a), CI-1D-LBP yöntemi uygulanmadan önceki orijinal EKG sinyalini göstermektedir. Bu sinyal, kalp atımlarının belirgin özelliklerini içeren karakteristik bir dalga formuna sahiptir. Şekil 5.8(b) ise orijinal sinyale CI-1D-LBP yöntemi uygulandıktan sonra elde edilen 9 farklı öznitelik sinyalini göstermektedir. Her bir öznitelik sinyali, pencere içerisindeki bir noktanın merkez olarak kabul edilmesi ile elde edilen CI-1D-LBP özelliklerini temsil eder. Bu yöntem sayesinde, orijinal sinyalin lokal yapısı ayrıntılı bir şekilde incelenmiş ve her pozisyonda çevresel varyasyonların bir öznitelik vektörü olarak kaydedilmesi sağlanmıştır. Elde edilen bu 9 öznitelik sinyali, orijinal sinyaldeki lokal değişimlerin ikili kodlarla özetlenmiş bir versiyonu olarak düşünülebilir ve sinyalin aritmi gibi ritmik anomalileri tespit etmede daha güçlü bir veri yapısı sunar. Bu öznitelikler, lokal varyasyonların belirginleştirilmesini sağlayarak, orijinal sinyale kıyasla anomali tespiti ve analiz süreçlerinde önemli bir avantaj sağlamaktadır.




Şekil 5.8. CI-1D-LBP yöntemin örnek sinyale uygulanması. (a) örnek EKG sinyali, (b) üretilen sinyaller

CI-1D-LBP yöntemi uygulandıktan sonra elde edilen 9 farklı sinyalin öznitelik dağılımı, bu sinyallerin histogramları çıkarılarak analiz edilmiştir. Her bir sinyal, CI-1D-LBP işlemi sonucunda orijinal EKG sinyalinin belirli lokal yapısını temsil eden ikili değerlerden oluştuğu için, bu sinyallerin histogramları birbirinden farklı özellikler göstermektedir. CI-1D-LBP yöntemi ile üretilen 9 farklı sinyalin histogramları, LSTM, 1D-CNN ve GRU gibi derin öğrenme modellerine giriş olarak kullanılmıştır. Bu yaklaşım, her bir sinyalin lokal yapısını karakterize eden özniteliklerin modeller tarafından öğrenilmesini sağlamaktadır.

Örnek bir EKG sinyali için elde edilen 9 farklı CI-1D-LBP sinyalinin histogramları Şekil 5.9’da gösterilmiştir. Şekilden de anlaşılacağı üzere, her bir histogram, sinyaldeki lokal varyasyonların farklı bir temsilini sunmakta ve her bir CI-1D-LBP sinyali kendine özgü bir dağılım oluşturmaktadır. Bu farklılıklar, veri setindeki her bir EKG sinyalini ayrıntılı olarak karakterize etmekte ve her bir örneğe ait öznitelik matrislerinin oluşturulmasına olanak tanımaktadır. Bu histogramlar, modellerin sinyaller arasındaki farklılıkları öğrenebilmesi ve aritmi gibi anomalilerin daha hassas tespit edilebilmesi açısından önemli bir girdi sağlamaktadır. Sonuç olarak, CI-1D-LBP yöntemi

ile elde edilen histogram temelli öznitelikler, sinyalin lokal yapısal özelliklerini ortaya koyarak makine öğrenimi ve derin öğrenme modelleri için zengin bir veri seti oluşturmaktadır.



Şekil 5.9. CI-1D-LBP ile üretilen yeni sinyallere ait histogramlar

CI-1D-LBP yöntemi, tek boyutlu EKG sinyallerindeki lokal yapıyı ikili karşılaştırmalarla temsil ederek her bir sinyal örneğine özgü zengin öznitelikler çıkarmaktadır. Bu yöntem, orijinal sinyalden türetilen 9 farklı sinyalin her birinin histogramlarını elde ederek sinyaller arasındaki lokal varyasyonları anlamlandırır. Elde edilen histogramlar, LSTM, 1D-CNN ve GRU gibi derin öğrenme modelleri için güçlü öznitelik matrisleri sunarak aritmi gibi kardiyolojik anomalilerin tespitinde daha hassas analizler yapılmasına katkı sağlar. Bu metodoloji, EKG sinyallerindeki karmaşık yapıları sadeleştirip modellerin öğrenebileceği öznitelik vektörlerine dönüştürmesi açısından etkili ve verimlidir. Sonuç olarak, CI-1D-LBP yöntemi, biyomedikal sinyallerdeki lokal varyasyonları öne çıkararak sinyal analizi ve sınıflandırmada daha yüksek performans elde etmeye olanak tanır; özellikle, aritmi gibi ritmik bozuklukların erken teşhisinde anlamlı bir katkı sağlamaktadır.

5.1.3. Motif dönüşüm


Bu çalışmada, Motif dönüşüm (MD) adı verilen yeni bir dönüşüm yöntemi geliştirilmiştir. MD yöntemi, sinyal işleme alanında özellikle şablon tanıma (*template matching*) ve desen çıkarımı (*pattern extraction*) başlıkları altında değerlendirilebilecek bir yaklaşımdır. Bu başlıklar, sinyaldeki belirli örüntüleri veya tekrar eden motifleri bulmaya ve analiz etmeye yönelik yöntemleri içermektedir. Motif dönüşüm, özellikle EKG gibi biyomedikal sinyallerde belirli özelliklerin öne çıkarılmasını sağlayarak sinyalin içerdiği anlamlı yapıları ortaya koymada etkili bir çözüm sunmaktadır.

Motif dönüşüm yöntemi, sinyalin belirli bölümlerini kıyaslayarak desenler oluşturmaya dayanır. Bu yönüyle, sembolik dinamik analiz ve sinyal örüntü tanıma alt başlıklarıyla yakından ilişkilidir. Yöntem, sinyaller içerisindeki örnek değerlerin birbirleriyle kıyaslanarak belirli bir sembol veya motif yapısına dönüştürülmesini amaçlar (Kaya & Ertuğrul, 2019). Her bir motif, sinyaldeki belirli bir pencere boyutu (örneğin, dört veya beş ardışık nokta) içinde değerlendirilen sinyal değerlerinin büyüklük sıralamasına göre oluşturulur. Bu sıralama, sinyalin dalgalanmalarına göre farklı motiflerin ortaya çıkmasını sağlar ve bu motiflerin tekrarlanma sıklıkları öznitelik olarak değerlendirilir. Bu yöntemde, sinyalin belirli bir pencerede oluşan örüntüleri belirlenerek, her pencere içinde sinyalin özlü ve anlamlı bir temsili sağlanmaktadır.

Motif dönüşüm yöntemi, örüntü tanımlama ve sembolik dönüşüm gibi geleneksel yöntemlere yenilikçi bir bakış açısı kazandırarak, özellikle EKG sinyalleri gibi karmaşık biyomedikal verilerde belirgin özelliklerin çıkarılmasını sağlar. Bu sayede, sinyalin temel yapısını koruyarak önemli özelliklerin öne çıkarılması ve daha etkili bir sınıflandırma yapılması mümkün hale gelir. Motif dönüşüm, sürekli zamanlı dalgacık dönüşümü (CWT) gibi daha yoğun hesaplama gerektiren yöntemlerin öncesinde kullanılarak sinyalin yapısını sadeleştirir ve öznitelik çıkarma sürecini iyileştirir. Böylece, sinyalin çeşitli frekans bileşenleri arasında anlamlı motiflerin belirlenmesi sağlanır ve bu motiflerin zaman ve frekans alanındaki davranışları incelenebilir. CWT'den önce MD dönüşümünün uygulanması, sinyaldeki anlamlı örüntüleri öne çıkarır, hataları azaltır ve daha net bir sınıflandırma sağlar. Bu sıralama, analiz sürecinin doğruluğunu ve verimliliğini ciddi oranda artırır. Bu yaklaşım, özellikle biyomedikal sinyal işleme alanında doğru ve etkili bir tanı süreci için yüksek kaliteli veri çıkarımı sağlar. Bu yöntem, geleneksel sinyal işleme tekniklerine kıyasla özellikle tekrarlayan örüntülerin tespitinde yenilikçi bir çözüm sunmakta olup, sinyaldeki ince yapısal özelliklerin

belirginleştirilmesine ve hastalık tespitinde önemli bilgilerin elde edilmesine katkı sağlamaktadır.

Önerilen yaklaşım, EKG sinyallerinden motif adı verilen yapıları çıkararak farklı tek boyutlu sinyaller oluşturur. Motifler, EKG sinyallerindeki her bir örnek değerin büyüklüğü açısından karşılaştırılması ile oluşturulmaktadır. Motifler, sinyal üzerinde alınan örnek sayısına göre belirlenir; bu da pencere boyutu (WS) olarak bilinir. Örneğin, pencere boyutu "WS = 3" olarak ayarlandığında, toplamda $3! = 3 * 2 * 1 = 6$ motif elde edilir. Benzer şekilde, WS = 4 olduğunda, $4! = 4 * 3 * 2 * 1 = 24$ motif elde edilir. Motif desenlerinin elde edilme süreci Şekil 5.10'da gösterilen sinyal segmentinde örneklenmiştir. Aşağıdaki sinyalde, WS = 4 olarak bir pencere boyutu seçilmiştir. Her pencere dört sinyal değerini (P1, P2, P3 ve P4) içerir ve bu değerlerin göreceli büyüklükleri bir motif olarak değerlendirilir.




Şekil 5.10. MD dönüşüm uygulanmış örnek veri (Tekin & Kaya, 2024)

Şekil 5.10'da EKG sinyali üzerinde belirli pencere boyutları seçilerek motif yapıları oluşturulmuştur. Bu çalışmada pencere boyutu WS = 4 olarak belirlenmiş ve her motif dört ardışık örnek noktasını (P1, P2, P3 ve P4) içermektedir. Bu motif yapıları, sinyalin belirli bölümlerindeki küçük dalgalanmaları ve ana örüntüleri daha iyi yakalayabilmek için dört noktanın göreceli büyüklük sıralamalarına göre düzenlenmiştir. Her motifte, penceredeki dört örnek nokta arasında büyüklük sıralaması karşılaştırılarak bir desen yapısı elde edilmiştir. Örneğin, Motif 1 ve Motif 2, sinyalin daha düz olduğu, küçük genlikli dalgalanmalar içeren bölgeleri temsil etmekte olup, P1, P2, P3 ve P4 arasındaki göreceli büyüklüklerin daha benzer ve düzenli bir desen oluşturduğu gözlemlenmiştir. Öte yandan, Motif 3 ve Motif 4, sinyalde daha belirgin dalgalanmaların olduğu bölgelere denk gelmekte ve bu bölgelerde örnek değerlerin büyüklük

sıralamasında belirgin farklılıklar gözlenmektedir; bu durum, genlikler arasındaki belirgin sıçramaları ifade etmektedir. Motifler, EKG sinyalinin ardışık dört noktasının göreceli büyüklüklerine göre sınıflandırılarak elde edilmiştir. WS=4 için teorik olarak toplamda 24 farklı motif yapısı oluşturulabilmekteyken, görselde yalnızca sinyalin ilgili bölümlerine ait dört motif örneği sunulmuştur.

Aşağıda Şekil 5.11’de, pencere boyutu WS = 4 olarak belirlenmiş olup, dört ardışık veri noktası (P1, P2, P3 ve P4) arasındaki göreceli büyüklük sıralamaları esas alınarak farklı motif yapıları oluşturulmuştur. Her bir tablo, dört sinyal değerinin sıralanış biçimine göre farklı bir motif örüntüsünü temsil etmektedir. Görseldeki her bir motif, sinyal segmentindeki dört veri noktasının büyükten küçüğe doğru sıralanması sonucu ortaya çıkan özgün örüntüleri göstermektedir. Örneğin, ilk motif, $P1 > P4 > P3 > P2$ şeklinde bir sıralama ilişkisi sunarken, ikinci motif $P3 > P1 > P2 > P4$ sıralamasına göre yapılandırılmıştır. Bu tür sıralamalar, her bir motifin sinyalin belirli bir segmentindeki göreceli büyüklük ilişkilerini yansıtarak sinyalin lokal özelliklerini daha detaylı analiz etmeyi mümkün kılar.


Motif yapıları, sinyaldeki ardışık veri noktaları arasında yapılan karşılaştırmalar yoluyla oluşturularak, sinyalin her bir segmentine özgü anlamlı desenlerin ortaya çıkmasını sağlamaktadır. Böylece, sinyalin belirli pencerelerindeki yapısal özellikler öne çıkarılarak sinyalin karakteristik özelliklerinin analiz edilmesine katkıda bulunmaktadır. Bu motifler, sinyalin zaman-frekans çözümlemesi ve özellik çıkarımı gibi ileri düzey analizlerde kullanılmak üzere önemli bilgi taşıyan yapı taşları olarak değerlendirilmektedir.



Şekil 5.11. Şekil 5.10’deki EKG örnek verisine ait motifler

Aşağıdaki Şekil 5.12’de, pencere boyutu WS = 4 olarak belirlenen sinyal segmentlerinde ortaya çıkabilecek tüm olası motif kombinasyonlarını göstermektedir. Görsel, sinyal boyunca gerçekte meydana gelen belirli motifleri değil, teorik olarak dört

örnek noktadan oluşan 24 farklı motif yapısını temsil etmektedir. WS değeri, sinyaldeki motif sayısını ve formunu doğrudan etkiler; bu durumda, $WS = 4$ olması nedeniyle 24 farklı motif (örüntü) elde edilmiştir. Bu teorik motif örüntüleri, sinyal boyunca hangi motiflerin ne sıklıkta tekrarlandığını analiz etmek için temel teşkil eder. Sinyal üzerinde her bir motifin tekrarlanma frekansı, belirli bir öznitelik olarak değerlendirilir ve bu motif frekansları, sinyalin yapısal özelliklerinin çıkarılmasında kullanılır. Bu bağlamda, her motifin sinyal boyunca gözlenme sıklığı, sinyalin karakteristik yapısını daha iyi anlamak için önemli bir veri sağlamaktadır.




Şekil 5.12. $WS=4$ olması durumunda oluşan 24 adet motif yapısı (Kaya & Ertuğrul, 2019)

Şekil 5.13'te, pencere boyutları $WS = 4$, $WS = 5$ ve $WS = 6$ olarak belirlenmiş motiflerin sinyal boyunca tekrarlanma frekanslarını gösteren histogramlar sunulmuştur. Bu histogramlar, her bir motifin sinyalde ne kadar sıklıkta tekrarlandığını görselleştirmekte ve farklı pencere boyutlarının sinyaldeki motif dağılımını nasıl etkilediğini ortaya koymaktadır. $WS = 4$ durumunda elde edilen histogramda, daha az sayıda motif çeşidi bulunmaktadır ve belirli motiflerin baskın olarak tekrarlandığı gözlenmektedir. Bu, küçük pencere boyutunun sinyalin temel yapı taşlarını yakalamada yeterli olduğu, ancak daha ince detayları kaçırabileceği anlamına gelir. $WS = 5$ durumunda motif çeşitliliği artar ve histogramda daha dengeli bir frekans dağılımı elde edilir. Bu pencere boyutu, sinyaldeki daha fazla örüntüyü tanımlama kapasitesine sahip

olduğundan, sinyalin hem ana yapısını hem de bazı detaylarını daha iyi yansıtır. $WS = 6$ durumunda ise, motif sayısı artmakta ve her bir motifin frekansı nispeten düşmektedir. Bu durumda, sinyalde daha fazla örüntü çeşidi elde edilmekte; ancak her motifin tekrar sayısı azaldığı için sinyaldeki bazı motifler daha nadir gözlenmektedir. Bu durum, sinyalin ayrıntılı analizini mümkün kılarken bazı motiflerin düşük frekansla temsil edilmesine neden olur.

Bu histogramlar, farklı pencere boyutları kullanılarak sinyaldeki motif dağılımının nasıl değiştiğini ve hangi motiflerin daha baskın hale geldiğini anlamak için önemli bilgiler sunar. Her bir pencere boyutunun seçimi, sinyalin analiz edilecek yapısına göre uyarlanarak sinyaldeki ana yapının veya detayların öne çıkarılmasına olanak tanır.



Şekil 5.13. WS farklı değerleri göre oluşan motif histogramlar. (A) orijinal sinyal, (B) $WS=4$ için motif histogram, (C) $WS=5$ için motif histogram, (D) $WS=6$ için motif histogram

Histogramlar, sinyaldeki örüntülerin (motiflerin) tekrarlanma sayılarını görselleştirerek, her bir motifin sinyal boyunca hangi sıklıkta meydana geldiğini sayısal olarak ifade eder. Bu tekrarlanma sayıları, özellikle biyomedikal sinyal işleme uygulamalarında sinyalin karakteristik özelliklerini öne çıkaran önemli bir öznitelik seti olarak kullanılır. Örneğin, EKG sinyallerinde belirli motiflerin tekrarlanma sıklığı, kalp ritminin düzeni ve dalga formlarının özellikleri hakkında bilgi sunarak, potansiyel kardiyak anormalliklerin tespitine katkı sağlar. Bu histogram tabanlı öznitelikler, makine öğrenmesi ve derin öğrenme algoritmalarında sınıflandırma ve tahmin modelleri için temel bir giriş verisi olarak kullanılabilir. Her bir motifin tekrarlanma sıklığı, sinyalin yapısal ve fonksiyonel özelliklerini özetleyen bir bilgi katmanı sunar. Böylelikle,

örüntülerin tekrarlanma sayılarına dayalı histogramlar, sinyaldeki normal ve anormal durumları ayırt etmede kullanılmakta ve tanı destek sistemlerinde doğruluğu artırıcı bir rol oynamaktadır.

5.1.4. Sürekli zamanlı dalgacık dönüşümü (CWT)

CWT, özellikle durağan olmayan ve non-lineer özellikler taşıyan sinyallerin zaman-frekans analizinde yaygın olarak kullanılan bir yöntemdir. CWT, sinyalin hem zaman hem de frekans ekseninde ayrıntılı çözünürlük sunarak geçici veya kısa süreli olayların incelenmesine olanak sağlar ve bu yönüyle klasik Fourier analizinden farklılaşır (Kingsbury & Magarey, 1998). Özellikle EKG gibi kalp atım örüntülerinde ani değişimlerin izlenmesinin gerektiği durumlarda, CWT'nin frekans ve zaman boyutundaki üstün çözünürlüğü, sinyalin yapısal özelliklerini derinlemesine anlamak için değerli bir araçtır (Mateo & Talavera, 2020). Kısa zamanlı Fourier dönüşümü (STFT), frekans analizinde sabit boyutlu pencere fonksiyonları kullanırken, CWT sinyali enerji yoğunluğuna göre optimize edilen dalgacık fonksiyonlarıyla analiz eder, bu da sinyalin özellikle geçici olaylar içeren bölümlerini daha net yakalamayı sağlar (Lee vd., 2017). CWT dönüşümü ile sinyallerdeki katsayılar aşağıda verilen formül ile hesaplanmaktadır:

$$F_{cwt}(\tau, b) = \frac{1}{\sqrt{|b|}} \int f(t) \psi^* \left(\frac{t-\tau}{b} \right) dt \quad (5.20)$$

Formülde, $f(t)$ dönüştürülecek olan bir boyutlu sinyali göstermektedir. Kaydırma parametresi " τ ", ölçek parametresi " b " ve dalgacık fonksiyonu " ψ " sembolleri ile gösterilmiştir. Ölçek parametresi büyük olduğunda, sinyal genişler ve düşük frekanslarda kullanılır; ölçek parametresi küçük değerde olursa sinyal sıkıştırılır ve yüksek frekanslarda kullanılır.

Bu dönüşüm sırasında kullanılan dalgacık fonksiyonları, CWT'nin analiz gücünü ve doğruluğunu doğrudan etkiler. CWT, ölçekleme (scale) ve kaydırma (translation) parametreleri aracılığıyla sinyal üzerinde yerel analizler gerçekleştirir (Lotfollahi-Yaghin & Koohdaragh, 2011). Bu süreçte, belirli bir ölçek ve kaydırma değeri ile ana dalgacık (ana fonksiyon) sinyale uygulanarak, sinyalin o andaki zaman ve frekans bileşenleri analiz edilir (Chopra & Marfurt, 2015). Ölçek, sinyalin yüksek veya düşük frekans bölgelerine odaklanmasını sağlarken; kaydırma, sinyalde bu frekansların belirli bir zamanda nasıl yayıldığını gösterir. Ölçekleme parametresi, ana dalgacığın daraltılıp

genişletilmesine olanak tanır; küçük ölçekler yüksek frekans bileşenlerini analiz ederken, büyük ölçekler düşük frekans bileşenlerini analiz etmeye uygundur. Kaydırma parametresi ise ana dalgacığın sinyal boyunca zaman ekseninde hareket ettirilmesini sağlar, bu sayede sinyalin belirli zaman aralıklarındaki özellikleri incelenebilir.

CWT’de kullanılan ana dalgacık, sinyalin özelliklerine göre seçilmelidir; genellikle Morlet, Meyer, Haar gibi dalgacık fonksiyonları tercih edilir (Chopra & Marfurt, 2015). Ana dalgacık seçimi, dönüşüm sonucunda elde edilecek verinin sinyalin karakteristik özelliklerine uygun olarak analiz edilmesi açısından kritiktir. Morse dalgacığı, EKG sinyalleri ile uyumlu bir morfolojiye sahip olması ve yüksek zaman-frekans yerleştirme kapasitesi ile öne çıkan bir dalgacık türüdür. Bu dalgacığın sunduğu yüksek çözünürlük, sinyaldeki ani değişimleri ve kısa süreli olayları yakalamada büyük avantaj sağlar. Özellikle EKG sinyallerinde, kalp atış döngüsü içerisindeki kısa süreli dalgalanmalar gibi ayrıntılı örüntülerin analiz edilmesinde Morse dalgacığının yüksek doğruluk sunan yapısı etkili sonuçlar üretir (Byeon vd., 2020). Morlet dalgacığı, Gauss fonksiyonu ile modüle edilmiş bir sinüs dalgası şeklinde tanımlanır ve yüksek frekans çözünürlüğü ile bilinir. Bu özellik, kısa süreli değişimler içeren sinyallerin frekans bileşenlerini ayırt etmede avantaj sağlar ve özellikle EKG gibi geçici olaylar içeren sinyallerde tercih edilir. Meyer dalgacığı ise geniş bir frekans bandını kapsar ve sürekli, pürüzsüz bir analiz sunar. Bu dalgacık, sinyalin frekans çözünürlüğünden çok geniş spektrumları kapsayan geçiş bölgelerinin analizinde kullanılır ve sinyallerin yumuşak geçişler gösteren kısımlarında faydalıdır (Kingsbury & Magarey, 1998).

CWT dönüşümleri sonucu oluşan skalogram, sinyalin CWT dönüşümünün mutlak değeridir ve zaman ve frekansın bir fonksiyonu olarak çizilir (Narin, 2022). Aslında sinyalin zaman kaydırma parametresi (τ) ve ölçek parametresindeki (b) enerji dağılımının bir ölçüsüdür. Enerji dağılımı aşağıda verilen formül ile bulunur.

$$E_{cwt}(\tau, b) = \sum_{\tau} \sum_b (F_{cwt}(\tau, b))^2 \quad (5.21)$$

CWT, sinyalde oluşan her bir ölçek ve kaydırma değeri için sürekli olarak dönüşüm işlemi gerçekleştirdiğinden, bu dönüşüm sonrasında yüksek çözünürlüklü skalogram adı verilen iki boyutlu bir zaman-frekans temsili elde edilir. Skalogram, sinyalin her bir zaman dilimindeki frekans bileşenlerini görsel olarak sunarak sinyalin yapısını detaylandırır. Skalogramlar, farklı dalgacık türleri (örneğin Morlet, Meyer, Haar) kullanılarak oluşturulabilir ve bu dalgacıkların seçimi analiz edilen sinyalin yapısına göre

belirlenir. Morlet dalgacığı, özellikle biyomedikal sinyallerde tercih edilmekte olup, yüksek frekans çözünürlüğü sunarak sinyalin ince detaylarının analizini mümkün kılar. Meyer dalgacığı ise daha genelleştirilmiş bir analiz sağlayarak geniş bir frekans bandını kapsar ve sinyalin genel yapı analizi için uygundur. Dalgacık seçimi, elde edilen skalogramın çözünürlüğünü ve analiz doğruluğunu doğrudan etkilediğı için, analiz edilen sinyalin doğasına göre optimize edilmesi önemlidir.

Özetle, CWT ve skalogram kullanımı, sinyalde zamanla değişen frekans bileşenlerini analiz etmeyi sağlayarak geleneksel frekans analiz yöntemlerinin sınırlamalarını aşmaktadır. Zaman-frekans düzleminde sağladığı yüksek çözünürlük ve lokal analiz yeteneğı sayesinde, özellikle biyomedikal uygulamalarda sinyalin karakteristik özelliklerinin çıkarılmasında dalgacık dönüşümü oldukça değerli bir araç olarak öne çıkar.

5.2. Derin Öğrenme Sınıflandırma Metotları

Son yıllarda, tıp, mühendislik, görüntü işleme ve doğal dil işleme gibi alanlarda yaşanan büyük veri ve hesaplama teknolojilerindeki ilerlemeler sayesinde, derin öğrenme oldukça büyük bir gelişim göstermiştir. Derin öğrenme, çok katmanlı sinir ağıları kullanarak karmaşık veri örüntülerini anlamlandırma yeteneğine sahiptir ve bu özellik, geniş veri kümelerinden anlamlı çıkarımlar yapabilmesini sağlar (Lecun vd., 2015). Bu bağlamda, günümüzde biyomedikal alanında derin öğrenme teknikleri, tanı süreçlerini destekleme ve teşhis doğruluğunu artırma amaçlarıyla sıklıkla kullanılmakta olup, özellikle hata oranlarını azaltmaya yönelik büyük katkılar sunmaktadır (Litjens vd., 2017). Kalp hastalıkları, dünya genelinde en önemli ölüm nedenlerinden biridir ve özellikle gelişmekte olan ülkelerde halk sağlığını tehdit eden başlıca problemler arasında yer alır. Kalp hastalıklarının önlenmesi ve erken teşhisi, bu hastalıkların yarattığı olumsuz etkileri azaltmada büyük önem taşımaktadır. Bu doğrultuda, kalbin elektriksel aktivitelerini değerlendiren EKG, kalp rahatsızlıklarının tanısında yaygın olarak kullanılan, girişimsel olmayan bir tekniktir (Acharya vd., 2017). EKG sinyalleri, kalbin yapısal ve işlevsel bozukluklarını tespit etmekte büyük önem taşır. Ancak, bu sinyallerin karmaşık yapısı analiz süreçlerini zorlaştırmakta ve geleneksel analiz yöntemlerinin ötesinde yeni yaklaşımların geliştirilmesine ihtiyaç duyulmaktadır.

Derin öğrenme modellerinin karmaşık veri örüntülerini öğrenme ve özellik çıkarma yetenekleri, EKG sinyalleri analizinde özellikle önem kazanmaktadır.

konvolüsyonel sinir ağları (CNN) ve uzun kısa süreli bellek (LSTM) gibi modeller, EKG sinyalleri gibi zaman serisi verilerindeki örüntüleri belirleme ve sınıflandırma işlemlerinde yüksek başarı sağlamaktadır (Rajpurkar vd., 2017). Özellikle EKG sinyalleri üzerine uygulanan derin öğrenme temelli algoritmalar, aritmi gibi kalp ritim bozukluklarının otomatik tespitini mümkün kılarak insan hatalarını azaltmakta etkili olmaktadır (Hannun vd., 2019). Derin öğrenme teknolojilerinin EKG analizine katkıları, karmaşık biyomedikal sinyallerin değerlendirilmesi ve gelecekte tanı süreçlerinin iyileştirilmesi açısından kritik bir adım olarak değerlendirilmektedir.


5.2.1. Uzun kısa süreli bellek (LSTM)

Uzun kısa süreli bellek (Long Short-Term Memory, LSTM) ağları, sıralı verilerdeki uzun süreli ilişkileri öğrenmek için yinelenen sinir ağlarına (Recurrent Neural Networks, RNN) getirilmiş bir yenilik olarak öne çıkar. RNN'ler, veri dizilerindeki zaman bağımlılıklarını modellemek için geliştirilmiş olsa da uzun dizilerde bilgi kaybı ve gradyan sönmesi gibi sorunlarla karşılaşabilir (Hochreiter & SchmidhTAer, 1997). LSTM, bu problemlere çözüm sağlamak amacıyla özel bir yapıya sahiptir; hücre durumu (cell state) adı verilen bir yapıyı kullanarak uzun süreli bağımlılıkları muhafaza edebilir. Bu özellik, LSTM ağlarını biyomedikal sinyaller, doğal dil işleme, ses tanıma ve video analizinde çok daha verimli hale getirmektedir (Greff vd., 2017)

Bir LSTM hücresinde, giriş, çıkış, güncelleme ve unutma şeklinde eğitilebilir 4 kapı bulunmaktadır (Landi vd., 2021). Bu kapılar, hücrenin içine ve dışına bilgi akışını düzenleyerek bilgi ekleme veya çıkarma yeteneğine sahiptir ve bu nedenle hücre, belirli zaman aralıklarında değerleri hatırlar (Hu vd., 2020). Kapılar, hücre durumunda hangi bilgilere izin verileceğine karar veren farklı sinir ağlarıdır, ayrıca kapılar eğitim sırasında hangi bilgilerin saklanması veya unutulması gerektiğini öğrenirler (Zhou vd., 2021). Unutma Kapısı, hücreye gelen bilginin hangi kısımlarının silinmesi gerektiğini belirlerken, giriş kapısı, hücre durumuna hangi yeni bilgilerin ekleneceğine karar verir. Aday hücre durumu, mevcut bilgilere dayalı olarak yeni bir bilgi üretir, çıkış kapısı ise bu bilginin bir sonraki adıma nasıl aktarılacağını kontrol eder. Kapılar, sigmoid ve tanh aktivasyon fonksiyonları ile yönetilerek hücrenin çalışma süreci etkin bir şekilde organize edilir (Smagulova & James, 2019a).

LSTM ağları, özellikle biyomedikal alanında, zamanla değişen ve karmaşık yapıda olan verilerin analizinde büyük bir potansiyele sahiptir. Elektrokardiyografi

(EKG) sinyalleri gibi zaman serisi veriler, kalbin elektriksel aktivitesini kaydederek kalp sağlığını değerlendirmeye yönelik kritik bilgiler sunar. LSTM'nin uzun vadeli bağımlılıkları öğrenebilme kabiliyeti, EKG sinyallerindeki karmaşık örüntüleri ve düzensizlikleri daha iyi tanımlamaya olanak tanır. Örneğin, LSTM ağları, aritmi gibi düzensiz kalp ritimlerini otomatik olarak sınıflandırarak geleneksel yöntemlere kıyasla daha yüksek doğruluk oranlarına ulaşabilir (Zihlmann vd., 2017). Bu özellik, tanı sürecini hızlandırmak ve hata oranlarını düşürmek için kritik bir avantaj sağlar (Rajpurkar vd., 2017). LSTM algoritması, zaman serisi verilerinden otomatik özellik çıkarma yeteneği ve karmaşık lineer olmayan durumları öğrenmesi ile dikkat çekmektedir (Smagulova & James, 2019b). Bu özelliklerinden dolayı EKG, EMG, EEG gibi lineer olmayan sinyallerden öznetelik çıkarımı ve sınıflandırılma işlemlerinde LSTM modeli sıklıkla kullanılmaktadır. LSTM mimarisine blokların ve bellek hücresi birimlerinin gösterimi Şekil 5.14'te gösterilmektedir.



Şekil 5.14. LSTM bloklarının ve bellek hücresi birimlerinin gösterimi

LSTM hücresi t zamanındaki ara çıkışı belirten uzun dönem (long term) C_t hücre durumu ve kısa dönem (short term) h_t hücre durumu şeklinde iki durum içermektedir. LSTM hücre yapısı incelendiğinde $x = \{x_1, x_2, \dots, x_n\}$ t zamanındaki giriş verileri olmak üzere giriş (i_t), unutma (f_t) ve aday hücre durumunu ifade eden ($\hat{C}_t$) kapılarını kullanarak bilgiler güncellenir. Güncellenmiş hücre durumu (C_t) ile sembolize edilirken, gizli durumun hangi bilgileri içermesi gerektiğini belirleyen ve çıkış kapısının çıktısını ifade eden çıkış kapısı (o_t) ile gösterilmiştir. Burada h_t güncellenmiş gizli durumu ifade eder. Çıkış kapısının çıktısı o_t , güncellenmiş hücre durumu C_t üzerindeki tanh aktivasyon fonksiyonu ile çarpılır. Bu, LSTM hücresinin o adım için çıkardığı son çıktıdır. t zamanında, ilgili kapılar ve katmanlar aşağıdaki fonksiyonları hesaplar:

$$i_t = \sigma(W_i x_t + W_{hi} h_{t-1} + b_i) \quad (5.22)$$

$$f_t = \sigma(W_f x_t + W_{fi} h_{t-1} + b_f) \quad (5.23)$$

$$o_t = \sigma(W_o x_t + W_{oi} h_{t-1} + b_o) \quad (5.24)$$

$$\check{C}_t = \tanh(W_c x_t + W_{hc} h_{t-1} + b_c) \quad (5.25)$$

$$C_t = f_t \odot C_t + i_t \odot \check{C}_t \quad (5.26)$$

$$h_t = o_t \odot \tanh(C_t) \quad (5.27)$$

Burada σ ve $\tanh$ sigmoid ve hiperbolik tanjant aktivasyon fonksiyonlarıdır. W ağırlık matrisi, b eşik değerleri vektörünü belirtir. $\odot$ matris veya vektör çarpımlarını belirtir. Hücre durumu, göreceli bilgileri aktaran bir ulaşım otoyolu görevi görür ve taşınan bilgiler kapılar tarafından dikkatlice düzenlenir. Kapılar, hücre durumunda hangi bilgilere izin verildiğine karar veren farklı sinir ağlarıdır. Ayrıca kapılar eğitim sırasında hangi bilgilerin saklanması veya unutulmasını öğrenmektedir. Giriş kapısı, yeni hafızanın $\tanh$ aktivasyon fonksiyonu ve önceki hafıza bloğun etkisi ile bir sinir ağı tarafından oluşturulduğu bir bölümdür. Çıkış kapısı ise mevcut LSTM bloğunun çıktısının üretildiği bölümdür.

LSTM tabanlı modellerin EKG sinyalleri üzerindeki yüksek doğruluk oranları, bu yöntemi insan gözlemlerine dayalı manuel analizlere kıyasla daha avantajlı hale getirmektedir. Aritmi gibi düzensiz kalp ritimleri, kısa süreli veri analizleriyle gözden kaçabilecek karmaşıklıklara sahip olduğundan, LSTM'nin hücre durumu ve kapı mekanizmaları aracılığıyla sağlanan uzun vadeli bilgi takibi, bu tür anormalliklerin daha güvenilir bir şekilde tespit edilmesine olanak tanımaktadır. Bu durum, tanı süreçlerindeki hata payını en aza indirirken, LSTM ağlarının EKG analizinde sadece tanı doğruluğunu artırmakla kalmayıp, aynı zamanda tanı sürecini hızlandırarak klinik karar destek sistemlerinde önemli bir yer edinmesine imkân vermektedir.


Günümüzde, klasik LSTM mimarisine ek olarak geliştirilen çeşitli LSTM tabanlı modeller, biyomedikal sinyallerin analizinde performans ve doğruluğu daha da artırmaktadır. Özellikle Dikkat Mekanizmalı LSTM (Attention-based LSTM) ve Bi-LSTM (Bidirectional LSTM) gibi yeni LSTM mimarileri, daha hassas örüntü tanımlama ve tahminleme özellikleri sunarak, EKG gibi karmaşık biyomedikal verilerde üstün performans sağlamaktadır (Ezzat vd., 2024). Özellikle dikkat mekanizmasına sahip LSTM modelleri, ağırlıklı önemli bilgilere odaklanmasını sağlayarak tanı doğruluğunu artırırken, çift yönlü LSTM modelleri ise veriyi hem ileri hem de geri yönde analiz ederek daha kapsamlı bir veri işleme imkânı sunmaktadır (Schuster & Paliwal, 1997). Bu yeni

nesil LSTM modelleri, EKG sinyallerindeki kalp ritim bozuklukları ve anormal örüntülerin tespit edilmesinde, klasik modellere göre daha başarılı sonuçlar vermekte; dolayısıyla kardiyovasküler hastalıkların erken teşhisinde etkin bir araç olarak kullanılmaktadır. Bu gelişmeler, LSTM ağlarının biyomedikal alanda yalnızca daha yüksek doğruluk oranlarına ulaşmakla kalmayıp, tanı süreçlerini hızlandırma ve klinik karar destek sistemlerine entegre olma potansiyelini de güçlendirmektedir.

5.2.2. Bir boyutlu konvolüsyonel sinir ağları (1D-CNN)

Konvolüsyonel sinir ağları (CNN), derin öğrenmenin en temel ve yaygın kullanılan yapı taşlarından biri olarak, özellikle görüntü tanıma, görüntü işleme, tıbbi görüntü analizi ve doğal dil işleme gibi çeşitli alanlarda başarıyla kullanılmaktadır (Eren vd., 2019). Bu ağların esnek yapısı, farklı problemlere uyum sağlayabilecek çeşitli mimarilere dönüştürülmesine olanak tanır. Bu dönüşüm, ağın yapısında veya hiper parametrelerde yapılan ayarlamalarla sağlanmakta ve modelin ilgili uygulama için en iyi performansı göstermesine katkı sağlamaktadır (Vijayvargiya vd., 2021). CNN mimarileri, problem alanına bağlı olarak iki ana türde, yani 1D-CNN ve 2D-CNN olarak yapılandırılabilir.

2D-CNN, iki boyutlu verilerdeki özellikleri çıkarmak için ideal bir model iken, 1D-CNN ise özellikle tek boyutlu veriler üzerinde, örneğin EKG, EEG ve ses sinyalleri gibi zaman serisi verilerinde kullanılır (Hsieh & Kiang, 2020). 1D-CNN yapısal olarak 2D-CNN ile benzer prensiplere dayanmakla birlikte, tek boyutlu sinyallerin işlenmesi için optimize edilmiştir. 2D-CNN, görüntü verileri üzerinde uygulanarak iki boyutlu öznitelik çıkarımı ve sınıflandırma işlemlerinde başarı gösterirken, 1D-CNN, tek boyutlu sinyallerde zamanla değişen örüntüleri tespit etmek için kullanılır. 1D-CNN modellerinde, evrişim çekirdeği (kernel) tek boyutlu olduğu için daha az hesaplama maliyeti ve daha az parametreye ihtiyaç duyar; bu da modelin hızını artırır ve büyük veri setlerinde verimli çalışmasına olanak tanır (J. Wang vd., 2021). CNN mimarileri, farklı uygulamalara göre özelleştirilebilen birkaç temel katmandan oluşur. Bu katmanlar, evrişim katmanı, havuzlama katmanı, aktivasyon fonksiyonları ve tam bağlantılı katmanlardır. Bu katmanların her biri, modelin farklı özellikleri öğrenmesi ve veriyi analiz etmesi için özel bir rol üstlenir. Örnek bir 1D-CNN ağına ait blok şema aşağıda Şekil 5.15'te verilmiştir.



Şekil 5.15. 1D-CNN ağına dair blok şema yapısı

- **Evrişim Katmanı:** Evrişim katmanı, CNN mimarisinin temel yapı taşı olup, veri içerisindeki özellikleri öğrenir. Bu katmanda birçok filtre (kernel) veri üzerinde belirli bir kaydırma işlemiyle öznitelikleri çıkarmak için kullanılır. Filtreler, giriş verisi üzerinde tarama yaparak farklı seviyelerde özelliklerin öğrenilmesini sağlar.
- **Havuzlama Katmanı:** Bu katman, öznitelik haritalarının boyutlarını azaltmak amacıyla kullanılır ve veri içindeki önemli bilgileri korurken işlem maliyetini düşürür. Havuzlama türleri arasında maksimum havuzlama, ortalama havuzlama ve toplam havuzlama bulunur; maksimum havuzlama, her alt matristeki en büyük değeri alırken, ortalama havuzlama, değerlerin ortalamasını alır. Bu katman genellikle evrişim katmanından sonra kullanılarak verinin daha verimli işlenmesine katkı sağlar.
- **Aktivasyon Fonksiyonları:** CNN modellerinde, doğrusal olmayan ilişkilerin modellenmesini sağlayan aktivasyon fonksiyonları büyük önem taşır. ReLU (Rectified Linear Unit) ve Softmax, CNN ağlarında sıklıkla kullanılan aktivasyon fonksiyonlarıdır. ReLU, ağıdaki negatif değerleri sıfıra çekerek modelin doğrusal olmayan örüntüleri öğrenmesini sağlarken, Softmax sınıflandırma katmanında kullanılarak her sınıf için olasılık tahminleri yapar.
- **Tam Bağlantılı Katman:** Bu katman, ağı son aşamasında yer alan ve tüm nöronların birbirine bağlandığı bir yapıdır. Bu katman, özelliklerden elde edilen bilgiyi son sınıflandırma veya regresyon aşamasında kullanır ve ağ boyunca elde ettiği özellikleri bir araya getirerek çıktıyı oluşturur.

1D-CNN, özellikle tek boyutlu veriler üzerinde uygulandığında, görüntü işleme gibi alanlarda kullanılan 2D-CNN ile benzer avantajlar sunar. EKG gibi tek boyutlu sinyallerin analizinde, zaman serisi verilerinin işlenmesine olanak tanır ve EKG sinyallerindeki belirli örüntüleri tanımlamada başarılıdır. 1D-CNN, ardışık evrişim ve havuzlama katmanları ile öznitelik çıkarımı yaparak sinyallerden anlamlı özellikler elde eder. Örneğin, bir 1D-CNN ağı EKG sinyalinden elde edilen öznitelikleri tam bağlantılı katmana aktarır; ardından sınıflandırma problemi için softmax ve classification katmanları kullanılarak son karar verilir (T. Wang vd., 2021).

1D-CNN, tek boyutlu sinyallerin analizinde derin öğrenme yöntemleri arasında önemli bir yer edinmiştir. Yapısal olarak 2D-CNN ağlarına benzer bir prensibe dayansa da 1D-CNN'in evrişim çekirdekleri tek boyutlu olduğundan hesaplama yükü daha düşüktür ve bu durum, yüksek veri yoğunluğuna sahip zaman serisi verilerde daha hızlı ve verimli işlem yapılmasını sağlar (Kiranyaz vd., 2016). EKG, EEG ve ses gibi zamanla değişen ardışık verilere uygulandığında, 1D-CNN sinyalin karmaşık örüntülerini yüksek doğrulukla çıkarabilmekte ve sınıflandırabilmektedir. Bu özellikleri, 1D-CNN'in biyomedikal veri analizinde ve özellikle EKG sinyallerinin işlenmesinde öne çıkmasını sağlamaktadır (Rajpurkar vd., 2017). 1D-CNN'in başarısının ardında yatan en önemli etkenlerden biri, sinyallerdeki uzun vadeli bağımlılıkları ve kısa süreli değişimleri aynı anda yakalayabilme kapasitesidir. Evrişim katmanları aracılığıyla sinyal boyunca öznitelik çıkarımı yapılırken, havuzlama katmanları ile veri boyutunun azaltılması ve önemli özelliklerin korunması sağlanır. Bu özellik, ağı gereksiz bilgileri elerken anlamlı bilgileri öğrenmesine yardımcı olur ve sinyallerdeki belirgin desenlerin tanımlanmasını kolaylaştırır. Bununla birlikte, aktivasyon fonksiyonları ve tam bağlantılı katmanlarla sınıflandırma doğruluğu artırılır, bu da sinyaldeki her bir önemli bilginin sınıflandırma sürecine etkili bir şekilde dahil edilmesine olanak tanır.


EKG sinyalleri üzerinde yapılan analizlerde, 1D-CNN'in yüksek performans göstermesi, kardiyak bozuklukların ve ritim düzensizliklerinin tespitinde önemli bir avantaj sunmaktadır. EKG sinyalleri, kalbin elektriksel aktivitesini kaydettiğinden, bu sinyallerde yer alan belirli örüntüler veya anormallikler kalp sağlığı hakkında kritik bilgiler verebilir. 1D-CNN, EKG sinyallerinin karmaşık yapısını analiz ederek, aritmi gibi kardiyak anormallikleri doğru bir şekilde tespit edebilir (Acharya vd., 2017). Geleneksel yöntemlerin aksine, 1D-CNN sinyal boyunca örüntü tanımada daha hızlı ve otomatik bir yaklaşım sunar; böylece tanı sürecinin hızlanmasına ve insan hatalarının en aza indirilmesine katkı sağlar (Hannun vd., 2019).

Sonuç olarak, 1D-CNN modelleri, EKG sinyallerinin sınıflandırılması ve analiz edilmesinde yalnızca yüksek doğruluk sunmakla kalmaz, aynı zamanda büyük veri kümeleri üzerinde hızlı sonuçlar elde edilmesine de olanak tanır. Bu nedenle, 1D-CNN, kardiyovasküler hastalıkların erken teşhisi ve sürekli izlenmesi için gelişmiş bir araç olarak önemli bir potansiyele sahiptir ve klinik uygulamalarda tanı süreçlerinin güvenilirliğini artırmak amacıyla yaygın bir şekilde kullanılabilir.

5.2.3. Kapılı tekrarlayan hücre (GRU)

Kapılı tekrarlayan hücre (Gated Recurrent Unit - GRU), tekrarlayan sinir ağlarının (RNN) geliştirilmiş bir versiyonu olarak, uzun vadeli bağımlılıkları öğrenme yeteneğini artırmak amacıyla geliştirilmiştir (Chi & Chu, 2021). LSTM (Long Short-Term Memory) algoritmasının sadeleştirilmiş bir yapısı olan GRU, gradyan kaybolma sorununu aşmak ve uzun vadeli ilişkileri daha etkin bir şekilde modellemek için içsel bellek özelliklerini kullanır. Bu amaçla, GRU modelinde yer alan güncelleme ve sıfırlama kapıları, ağıın hangi bilgiyi hatırlayacağı ve hangisini göz ardı edeceği konusunda filtreleme işlevi görmektedir (Lynn vd., 2019b).

LSTM ağları ile benzer şekilde GRU modelleri de veri akışını kontrol eden kapı birimleri içerir; ancak LSTM'nin aksine, GRU'nun ayrı bir hafıza hücresi bulunmaz. Bu yapı, sıralı verilerin uzun vadeli bağımlılıklarını daha basit bir yapıda ve verimli bir şekilde işleyebilmesine olanak tanır (Althelaya vd., 2018). LSTM'nin giriş ve unutma kapıları GRU'da güncelleme kapısı adı altında tek bir yapıya indirgenmiştir; bu da GRU'nun daha az parametreye sahip olmasını ve dolayısıyla daha hızlı eğitim süreci sunmasını sağlar. LSTM, uzun vadeli bilgileri hücre durumunda, kısa vadeli bilgileri ise gizli durumda depolayarak iki ayrı bellek yapısı sunarken; GRU hem kısa hem de uzun vadeli bilgileri aynı gizli durumda tutarak daha kompakt bir bellek yönetimi sağlar. GRU'nun yapısı temel olarak sıfırlama kapısı (reset gate), güncelleme kapısı (update gate) ve çıktı hesaplama adımlarından oluşur. Şekil 5.16'da örnek bir GRU hücresinin yapısı gösterilmektedir.



Şekil 5.16. GRU blok ve hücre yapıları

Şekilde gösterildiği üzere, ağ mevcut girdi vektörü x_t tarafından beslenirken, önceki katman değerleri h_{t-1} olarak ifade edilmiştir. W_{xr} , W_{xz} , W_{xh} ve W_{hr} , W_{hz} , W_{hh} ağırlık matrisleridir. b_r , b_z , b_h ise eşik değeri vektörleridir. Sıfırlama kapısı (reset gate) r_t ve güncelleme kapısı (update gate) z_t ile ifade edilmiştir. GRU biriminde, doğrudan h_t çıkış vektörünü hesaplamak yerine, önce bunun için bir temsili $\hat{h}_t$ hesaplanmaktadır. Aşağıdaki denklemlerde sıfırlama kapısı r_t , güncelleme kapısı z_t , temsili çıkış kapısı $\hat{h}_t$ ve h_t çıkış vektörünü hesaplayan matematiksel ifadeler verilmiştir. Denklemlerde $\odot$ sembolü matris veya vektör çarpımlarını belirtir.

$$r_t = \sigma(W_{xr}x_t + W_{hr}h_{t-1} + b_r) \quad (5.28)$$

$$z_t = \sigma(W_{xz}x_t + W_{hz}h_{t-1} + b_z) \quad (5.29)$$

$$\hat{h}_t = \tanh(W_{xh}x_t + W_{hh}(h_{t-1} \odot r_t) + b_h) \quad (5.30)$$

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot \hat{h}_t \quad (5.31)$$

GRU'nun yapısı, güncelleme kapısı (update gate) ve sıfırlama kapısı (reset gate) olmak üzere iki temel kapıdan oluşur. Bu kapılar, GRU'nun hangi bilgileri hatırlayacağını ve hangilerini unutacağını belirlemekte kritik rol oynar. GRU'nun bu sade yapısı, modeli LSTM'ye göre daha hızlı ve hesaplama açısından daha verimli hale getirir, çünkü daha az sayıda parametre içerir. LSTM'de bulunan ayrı hücre durumu (cell state) GRU'da yoktur; GRU, tüm bilgiyi aynı gizli durumda (hidden state) saklar. Güncelleme kapısı,

LSTM'deki giriş ve unutma kapılarının birleştirilmiş halidir. Güncelleme kapısı sayesinde GRU, veriyi etkin bir şekilde işleyebilir ve veri dizilerinde önemli olan bilgileri korur. Sıfırlama kapısı, modelin gereksiz bilgileri göz ardı etmesini sağlar. Eğer bu kapının çıktısı düşük bir değerse, önceki gizli durumun etkisi sınırlı olur. Bu da modelin, yeni girdiye daha fazla odaklanmasını sağlar. Temsili çıktı $\hat{h}_t$, sıfırlama kapısının kontrolünde, geçmiş bilgilerin belirli bir kısmını unutarak güncellenmiş bir durumu temsil eder. Sıfırlama kapısı tarafından düzenlenen önceki gizli durum ve mevcut girişten oluşur. Son adımda, güncelleme kapısının yardımıyla, temsili çıktı durumu $\hat{h}_t$ ve önceki gizli durum h_{t-1} birleştirilerek yeni gizli durum h_t hesaplanır. Bu işlem, güncelleme kapısının modelin geçmişten getireceği bilgi ile yeni durumda eklenecek bilgiyi dengelemesini sağlar.

GRU'nun en belirgin avantajı, LSTM'deki giriş ve unutma kapılarını tek bir güncelleme kapısında birleştirerek daha sade bir yapı sunmasıdır. Bu, modelin parametre sayısını azaltarak eğitim sürecini hızlandırır. Ayrıca, LSTM'nin aksine ayrı bir hücre durumu bulunmayan GRU hem kısa vadeli hem de uzun vadeli bilgiyi aynı gizli durumda depolayarak daha kompakt bir yapı sunar. Bu yapı, veri işleme sürecini hızlandırmakla kalmaz, aynı zamanda modelin bellek kullanımını da optimize eder. Bu özellikler, GRU'yu özellikle büyük veri setleri ve gerçek zamanlı analiz gerektiren uygulamalarda cazip bir seçenek haline getirir.

GRU, özellikle EKG sinyalleri gibi uzun vadeli bağımlılıklar içeren zaman serisi verilerde etkili bir şekilde kullanılabilir. EKG sinyalleri, kalp ritminin zamana bağlı olarak değişen örüntülerini içerir. GRU'nun güncelleme ve sıfırlama kapıları, bu tür sinyallerdeki düzensizlikleri yakalayıp önemli bilgilerin korunmasını ve gereksiz bilgilerin filtrelenmesini sağlar. Örneğin, GRU, aritmi gibi kardiyovasküler anormalliklerin tespitinde hızlı ve güvenilir sonuçlar sunar. Bu özellikleri sayesinde GRU, EKG sinyallerinin analizinde ve kardiyovasküler hastalıkların erken teşhisinde güçlü bir araç olarak kullanılmaktadır.

5.2.4. DenseNet transfer öğrenme metotları

Transfer öğrenme, CNN tabanlı bir derin öğrenme tekniği olup, özellikle sınıflandırma ve görüntü analizi problemlerinde yüksek performansıyla dikkat çekmektedir (Saputra vd., 2023). Bu yöntemde, daha önce eğitilmiş ve iyi bir başarı elde


etmiş bir modelin ağırlık parametreleri, farklı bir sınıflandırma problemi için yeniden kullanılır. Transfer öğrenmenin temel amacı, çok sayıda eğitim verisiyle optimize edilmiş ağırlıkları, yeni bir veri seti üzerinde daha hızlı bir öğrenme süreci sağlamak için kullanmaktır (Guo vd., 2019). Bu süreçte, önceki modelin sahip olduğu bilgi, farklı veri türleri üzerinde yeniden eğitim sürecini hızlandırır ve daha az veri ile yüksek doğruluk oranlarına ulaşılmasını sağlar (Chen vd., 2021). Böylece, transfer öğrenme yöntemi, sınırlı veri koşullarında dahi etkili sonuçlar sunmaktadır.

DenseNet, transfer öğrenme teknikleri arasında yaygın olarak kullanılan ve öne çıkan bir CNN tabanlı mimaridir. Geleneksel CNN yapısında, konvolüsyon ve havuzlama işlemleri sırasında özellik haritalarında bilgi kaybı yaşanabilmektedir. Bu kaybı en aza indirmek ve bilgi aktarımını artırmak amacıyla geliştirilen “Densely Connected Convolutional Networks” (DenseNet) modeli, her bir katmanı bir sonraki katmanlarla doğrudan bağlantılı hale getirir (G. Huang vd., 2017). Normal bir CNN’de katman sayısı N ise bağlantı sayısı da N kadar olurken, DenseNet modelinde bu bağlantılar $N(N+1)/2$ şeklinde artar; böylece katmanlar arasındaki bilgi aktarımı güçlendirilmiş olur (Chauhan vd., 2021). Bu yapı, modelin önceki katmanların tüm özellik haritalarını giriş olarak kullanmasını sağlayarak daha zengin özellik temsilleri sunar (Bian vd., 2019).

DenseNet modelinin katmanlar arasındaki yoğun bağlantı yapısı, özellik haritalarının aktarımı sırasında bilgi kaybını minimuma indirir ve daha etkili bir bilgi paylaşımı sağlar. Özellikle sınıflandırma problemlerinde, her bir katmanın önceki katmanlardan gelen tüm özellik haritalarını giriş olarak kullanması, ağırlık performansını önemli ölçüde artırır. DenseNet yapısında, her katman kendisinden önce gelen katmanın çıktısını doğrudan kullanabildiği için bilgi akışı hızlı ve verimli bir şekilde sağlanır (Saputra vd., 2023). Bu çalışma kapsamında, DenseNet121, DenseNet201 ve DenseNet169 gibi çeşitli DenseNet mimarileri kullanılmış olup, bu modeller sınıflandırma başarısı açısından karşılaştırılmıştır. DenseNet mimarisinin sunduğu bir diğer avantaj, katmanlar arasındaki yoğun bağlantıların etkisiyle daha az parametre kullanarak verimli bir şekilde öğrenme gerçekleştirmesidir. Katmanların birbiriyle sıkı bağlantılı olması, her bir katmanın sadece kendi özelliklerini değil, aynı zamanda önceki katmanlardan gelen bilgileri de doğrudan kullanabilmesini sağlar. Böylelikle, bilgi aktarımı güçlendirilir ve veriye ilişkin ayırt edici özelliklerin kaybolması önlenir (Guo vd., 2019).

Aşağıda Şekil 5.17, bir DenseNet modelinin genel yapısını gösterir. Model, girişten itibaren ardışık yoğun bloklar (Dense Blocks) ile yapılandırılmış olup, her bir

yoğun blok kendi içinde konvolüsyonel katmanlar ve havuzlama işlemlerinden oluşur. Bu yapı, özelliklerin daha derin katmanlara etkili bir şekilde iletilmesini sağlar. Model, son katmanda doğrusal bir yapı ve sınıflandırma katmanı ile sonuçlandırılarak kategorik veri setlerini sınıflandırmaktadır.



Şekil 5.17. DenseNET blok diyagramı

Şekil 5.17 DenseNet (Densely Connected Convolutional Network) modelinin mimari yapısını özetleyen bir blok diyagramıdır. DenseNet, katmanlar arasındaki bilgi aktarımını artırmak için tasarlanmış yoğun bağlantılı bir konvolüsyonel sinir ağıdır. Görseldeki yapının ana bileşenleri aşağıdaki gibidir:

Evrişim (Convolution): İlk adımda, giriş verisi bir evrişim katmanından geçirilir. Bu katman, girdideki düşük seviyeli özellikleri öğrenmek için filtreler uygular.

Yoğun Blok 1 (Dense Block 1): Bu blok, ardışık konvolüsyonel katmanlardan oluşur ve her katman, önceki katmanların tüm özellik haritalarını giriş olarak kullanır. Bu yapı, bilgi aktarımını artırarak özellik öğrenimini güçlendirir.

Havuzlama (Pooling): Her yoğun bloktan sonra bir havuzlama katmanı bulunur. Bu katman, özellik haritalarının boyutlarını küçülterek parametre sayısını azaltır ve modelin karmaşıklığını yönetilebilir seviyede tutar.

Yoğun Blok 2 (Dense Block 2): İkinci yoğun blok, önceki yoğun bloktaki bilgilere ek olarak kendi konvolüsyon işlemlerini uygular ve bu bilgiler bir havuzlama katmanına gönderilir.

Yoğun Blok 3 (Dense Block 3): Üçüncü yoğun blok, önceki tüm yoğun blokların çıktısını da kullanarak özellik haritalarını günceller. Bu blokta elde edilen özellikler, yeniden havuzlama işlemine tabi tutulur.

Doğrusal (Linear): Son aşamada, bir doğrusal katman kullanılır. Bu katman, ağdan elde edilen özellikleri sınıflandırmak için kullanılır.

Tahmin (Prediction): Son olarak, modelin sınıflandırma çıktısı gösterilmektedir. Bu örnekte, model üç farklı durumu (Aritmi - AF, Konjestif Kalp Yetmezliği - KKY, Normal Sinüs Ritmi - NSR) tahmin etmektedir.

Görseldeki bu yapı, DenseNet'in her katmanının önceki tüm katmanlardan gelen bilgiyi nasıl kullandığını ve böylece daha az parametre ile yüksek performans elde ettiğini göstermektedir. Bu mimari, özellikle sınıflandırma ve tanı problemlerinde etkili bir çözüm sunar. DenseNet, derin öğrenme mimarileri arasında öne çıkan bir yapıya sahiptir çünkü daha az sayıda parametre ile daha zengin bilgi temsilleri oluşturma kabiliyetine sahiptir. Diğer derin öğrenme ağları aynı derinlikte daha fazla parametre gerektirirken, DenseNet'in yoğun bağlantı mimarisi sayesinde bu gereksinim önemli ölçüde azaltılmıştır. Bunun temel nedeni, her bir katmanın yalnızca kendine özgü özellik haritalarını değil, aynı zamanda önceki katmanlardan gelen tüm özellik haritalarını da kullanmasıdır. Böylelikle, önceki katmanlarda öğrenilen özelliklerin yeniden hesaplanması gerekmez, bu da modelin işlem verimliliğini artırır. Bu yapı, DenseNet'in sınıflandırma ve segmentasyon gibi görevlerde bilgi kaybını minimumda tutarak daha yüksek doğruluk oranlarına ulaşmasını sağlamaktadır. DenseNet, bilgi akışını artıran bu yoğun bağlantılı yapısı sayesinde sınırlı veri ile bile başarılı performanslar sergileyebilen bir model olarak öne çıkmaktadır. Verinin çeşitli katmanlar arasında etkin şekilde aktarılması, modelin karmaşık özellikleri daha iyi öğrenmesini sağlamak ve bu durum sınıflandırma, segmentasyon ve görüntü analizi gibi derin öğrenme uygulamalarında performansın artmasına katkıda bulunmaktadır (Chen vd., 2021). Özellikle transfer öğrenme yöntemleriyle birleştirildiğinde, DenseNet daha önce eğitilmiş olan ağırlıkları verimli bir şekilde kullanarak sınırlı sayıda veriyle bile yüksek doğruluğa ulaşabilmektedir (J. Wang vd., 2021). Bu özellikleri nedeniyle, DenseNet, görüntü işleme, tıbbi teşhis, doğal dil işleme ve diğer alanlarda yaygın olarak tercih edilen bir mimari haline gelmiştir. DenseNet'in sağladığı bu avantajlar, yoğun bağlantı yapısının model

parametrelerini verimli bir şekilde kullanması ve her bir katmanda bilgiyi en üst düzeyde işlemeyi mümkün kılmasıdır. Bu yapısal özellikler, özellikle büyük veri setleriyle çalışmanın mümkün olmadığı durumlarda ve sınırlı veriyle hızlı öğrenme sağlanması gereken uygulamalarda DenseNet'i değerli bir seçenek haline getirir (Guo vd., 2019).

5.3. Önerilen Yaklaşımlar

Bu tez çalışmasında, EKG sinyallerinin analizi ve sınıflandırılması amacıyla üç ayrı uygulama gerçekleştirilmiştir. Her bir uygulamada, farklı bir öznelik çıkarımı ve sınıflandırma yöntemi kullanılarak EKG verilerindeki anormalliklerin tespiti hedeflenmiştir. Bu uygulamalar, kalp ritim bozukluklarının ve konjestif kalp yetmezliği gibi kalp hastalıklarının sınıflandırılması için yeni yaklaşımlar sunmaktadır.

Birinci uygulamada, KKY, AF hastalarına ait EKG verileri ile sağlıklı bireylerin normal kalp ritmi (NSR) sinyallerinden ayırt edici öznelikler çıkarmak amacıyla yeni bir yöntem geliştirilmiştir. Bu yöntemde, yerel ikili desen tabanlı bir teknik olan ortogonal fark bir boyutlu yerel ikili desen (OD-1D-LBP) yöntemi kullanılmıştır. OD-1D-LBP yöntemi, sinyalin lokal yapısını ortogonal farklarla değerlendirerek sinyaldeki karakteristik özellikleri çıkarır ve sınıflandırma için anlamlı öznelikler sunar. OD-1D-LBP yöntemi, sinyaldeki lokal varyasyonları ve farklılıkları belirginleştirerek kalp yetmezliği ve ritim bozuklukları gibi hastalıkların daha doğru tespit edilmesini sağlamaktadır. Bu yöntemin uygulanması sonucunda elde edilen öznelik sinyallerinden histogramlar çıkarılmış ve bu histogramlar, derin öğrenme yöntemlerinden LSTM ve 1D-CNN modellerine giriş verisi olarak kullanılmıştır. LSTM modeli, zaman boyutunda bağımlılıkları öğrenme yeteneği sayesinde EKG sinyallerindeki kalp atım paternlerini başarıyla analiz etmiş; 1D-CNN modeli ise sinyalin ardışık özelliklerini öğrenerek kalp yetmezliği ve aritmi gibi rahatsızlıkları etkili bir şekilde sınıflandırmıştır. Bu uygulama, OD-1D-LBP yöntemiyle çıkarılan özneliklerin derin öğrenme modellerine entegrasyonu sayesinde, kalp hastalıklarının tespitinde güçlü bir çözüm sunmuştur.


İkinci uygulamada, MIT-BIH veri seti tabanından elde edilen EKG sinyalleri kullanılarak farklı aritmi türlerinin sınıflandırılması hedeflenmiştir. Bu uygulamada dört farklı aritmi türüne ait EKG verileri ve normal sinüs ritmi (NSR) verileri sınıflandırmaya dahil edilmiştir. Kullanılan aritmi türleri ventriküler atım (VA), supraventriküler atım (SVA), füzyon atımları (FA) ve tanımlanmamış aritmi atımı (TA) olarak belirlenmiştir. Bu uygulamada sınıflandırma için gerekli öznelikleri çıkarmak amacıyla yeni bir metot

olarak merkezden bağımsız tek boyutlu yerel ikili desen (CI-1D-LBP) yöntemi geliştirilmiştir. CI-1D-LBP yöntemi, EKG sinyallerindeki lokal varyasyonları yakalayarak sinyallerin karakteristik özelliklerini öne çıkaran özniteliklerin elde edilmesini sağlar. CI-1D-LBP yöntemi ile her bir sinyal örneği için lokal değişimlerin özelliklerini özetleyen 9 farklı sinyal elde edilmektedir. Bu sinyallerin her biri, orijinal sinyalin belirli bir lokal yapısını temsil etmekte olup, CI-1D-LBP yöntemiyle çıkarılan özniteliklerin detaylı bir görünümünü sunmaktadır. Her bir CI-1D-LBP sinyalinden histogramlar oluşturularak bu histogramlar, sınıflandırma işlemi için 1D-CNN, LSTM ve GRU gibi derin öğrenme modellerine giriş verisi olarak kullanılmıştır. Bu derin öğrenme modelleri, her bir sinyalin lokal yapısındaki farklılıkları öğrenerek ventriküler ve supraventriküler atımlar gibi çeşitli aritmilerin tespitinde yüksek doğruluk sağlamıştır. Böylelikle, CI-1D-LBP yöntemiyle çıkarılan öznitelikler, farklı aritmi türlerini karakterize eden zengin veri yapıları sunmuştur.

Üçüncü uygulamada, EKG sinyallerinin lokal özelliklerini daha belirgin hale getirmek amacıyla yeni bir sinyal ön işleme modeli geliştirilmiştir. Bu model, sürekli zamanlı dalgacık dönüşümünden (CWT) önce uygulanan bir veri örüntüleme algoritması olan Motif dönüşümü (MD) ile EKG sinyallerini dönüştürmektedir. MD dönüşümü, sinyalin lokal yapısındaki tekrar eden desenleri ve önemli detayları ortaya çıkarmak için kullanılmıştır. Bu işlem, sinyalde karakteristik motiflerin oluşturulmasını sağlar; bu motifler, sinyaldeki belirli yapıların daha iyi tanımlanmasına ve sınıflandırmada kullanılacak olan özniteliklerin daha etkili bir şekilde çıkarılmasına yardımcı olmaktadır. Motif dönüşümü sonrası elde edilen tek boyutlu sinyaller, sürekli zamanlı dalgacık dönüşümü (CWT) ile işlenmiş ve bu sinyallerden skalogram görüntüler üretilmiştir. Skalogramlar, sinyalin zaman-frekans yapısını görselleştiren ve her bir zaman diliminde frekans dağılımını gösteren iki boyutlu temsiller olarak öznitelik çıkarımında önemli bir rol oynamaktadır. Bu görüntüler, sinyaldeki frekans özelliklerinin zamana göre değişimini ortaya koyarak sinyalin ayrıntılı analizini mümkün kılmaktadır. Son aşamada, bu skalogram görüntüleri DenseNET tabanlı derin transfer öğrenme yöntemleri ile sınıflandırılmıştır. DenseNET modeli, verinin karmaşık yapısını derin katmanlar aracılığıyla öğrenerek kalp ritim bozukluklarının tespitinde yüksek doğruluk sağlamıştır. Bu uygulama, sinyaldeki lokal örüntülerin belirginleştirilmesi ve detaylı zaman-frekans analizinin yapılması sayesinde EKG sinyallerindeki anormallikleri etkin bir şekilde tanımlamaktadır.

5.3.1. Ortogonal fark 1D-LBP +{LSTM, 1D-CNN} yaklaşımı

Bu çalışmada, EKG sinyallerinin analizi ve sınıflandırılması amacıyla dört aşamadan oluşan bir metodoloji önerilmiştir. Her bir aşama (blok), EKG sinyallerindeki anormalliklerin tespiti ve sınıflandırılması için gerekli olan veri hazırlama, öznelik çıkarımı ve model eğitimi işlemlerini içermektedir. Bu yaklaşıma ait sistem akış diyagramı Şekil 5.18’de verilmiştir. Her aşamada gerçekleştirilen işlemler kısaca açıklanmıştır.




Şekil 5.18. Önerilen metodun akış diyagramı

Blok 1: İlk aşamada, 80 farklı bireyden toplanan EKG sinyalleri analiz edilmiştir. Her bir bireye ait EKG sinyali, 78 saniyelik segmentlere bölünmüş ve her segment 1000 örnek olacak şekilde düzenlenmiştir. Bu segmentasyon işlemi sonucunda toplamda 972 farklı EKG sinyali örneği elde edilmiştir. Segmentasyon işlemi, uzun süreli EKG kayıtlarının daha yönetilebilir parçalara bölünmesini sağlarken, analizlerin her bir segment üzerinde ayrı ayrı gerçekleştirilmesine de imkan tanımaktadır. Elde edilen her bir segment, sinyal işleme ve sınıflandırma işlemlerinin gerçekleştirileceği sonraki bloğa iletilmiştir.

Blok 2: İkinci aşamada, segmentlenmiş EKG sinyallerine ortogonal fark bir boyutlu yerel ikili desen (OD-1D-LBP) yöntemi uygulanarak öznelik çıkarımı gerçekleştirilmiştir. OD-1D-LBP yöntemi, sinyaldeki lokal farklılıkları belirgin hale getirerek, her bir EKG segmenti için 3 farklı öznelik sinyali üretmektedir. Bu yöntemin temel amacı, EKG

sinyalinde yer alan karakteristik yapıları ve lokal desenleri yakalayarak, her bir sinyalin özünde taşıdığı bilgiyi daha anlaşılır bir hale getirmektir. Şekil 5.19'da bir örnek EKG sinyaline OD-1D-LBP yönteminin uygulanması sonucu elde edilen üç farklı sinyal gösterilmiştir. Bu sinyallerin her birindeki değerler, 0 ile 255 arasında değişim göstermekte olup, sinyalin lokal yapısına dair zengin bir bilgi seti sunmaktadır. Elde edilen her bir öznelik sinyali, sinyalin farklı özelliklerini temsil etmekte ve sonraki aşamada kullanılmak üzere histogramları çıkarılmaktadır. Bu histogramlar, EKG sinyalinin lokal yapısını özetleyerek sınıflandırma algoritmalarına giriş verisi olarak sunulmaktadır.



Şekil 5.19. OD-1D-LBP çıktısı. (A) Örnek sinyal parçası, (B-D) 1D-OD-LBP çıktı sinyalleri

Blok 3: Üçüncü aşamada, OD-1D-LBP yöntemi ile elde edilen öznelik sinyallerine ait histogramlar derin öğrenme modellerine giriş olarak sağlanmaktadır. Bu aşamada sınıflandırma işlemleri, LSTM ve 1D-CNN modelleri kullanılarak gerçekleştirilmiştir. LSTM modeli, zaman bağımlılıklarını öğrenme kapasitesi ile öne çıkarken, 1D-CNN modeli sinyalin ardışık örüntülerini yakalamada etkili bir araç olarak kullanılmaktadır. OD-1D-LBP histogramları, her bir modelin giriş katmanına verilerek EKG sinyallerindeki farklı kalp ritim bozukluklarının tanımlanması ve sınıflandırılması sağlanmıştır. Bu aşamada gerçekleştirilen sınıflandırma işlemleri, derin öğrenme modellerinin EKG sinyallerindeki karmaşık paternleri öğrenmesine ve anlamlandırmasına olanak tanımaktadır.

Blok 4: Son aşama olan Blok 4, karar verme ve performans değerlendirme aşamasıdır. Bu aşamada, sınıflandırma modellerinin başarı oranları, performans ölçütleri ve karışıklık

matrisleri hesaplanarak değerlendirilmiştir. Karışıklık matrisi, modellerin sınıflandırma doğruluğunu görselleştirerek hangi sınıfların doğru veya yanlış sınıflandırıldığını analiz etmeye olanak tanımaktadır. Performans ölçütleri arasında doğruluk, duyarlılık, özgüllük ve F1 skor gibi ölçütler yer almakta olup, bu ölçütler modellerin EKG sinyalleri üzerinde ne derece başarılı olduğunu göstermektedir. Bu sonuçlar, önerilen metodolojinin EKG sinyallerindeki anormalliklerin tespiti ve sınıflandırılması açısından etkinliğini ve doğruluğunu ortaya koymaktadır.

Bu uygulamada geliştirilen dört aşamalı metodoloji, EKG sinyallerinin lokal yapılarını ayrıntılı bir şekilde inceleyerek kalp ritim bozukluklarının tespitinde ileri düzeyde bir analiz sağlamaktadır. Bu metodoloji, EKG sinyallerinin öncelikle segmentlere ayrılarak yönetilebilir veri parçalarına dönüştürülmesiyle başlamakta, ardından OD-1D-LBP yöntemi ile her bir segmentin karakteristik özniteliklerinin çıkarılmasıyla devam etmektedir.

OD-1D-LBP yöntemi, EKG sinyallerindeki lokal varyasyonları yakalayıp her bir sinyaldeki ince yapısal farklılıkları öznitelik vektörleri aracılığıyla ifade eder ve her sinyalin yapısını daha anlamlı hale getirir. Bu özniteliklerin histogramlar halinde derlenmesi, sinyallerdeki bilgi yoğunluğunu korurken, girdi verisinin derin öğrenme modelleri tarafından işlenebilir hale getirilmesini sağlamaktadır. Histogramlardan elde edilen veriler, LSTM ve 1D-CNN gibi güçlü derin öğrenme modellerine sunulmuş ve bu modeller aracılığıyla kalp ritim bozuklukları doğrulukla sınıflandırılmıştır.


Bu metodolojinin en önemli avantajı, EKG sinyallerinin karmaşık yapısını derinlemesine analiz ederek her bir örneğin kendine özgü özelliklerini belirgin hale getirmesidir. OD-1D-LBP yöntemi, geleneksel LBP yöntemlerinden farklı olarak sinyaldeki yönlü değişimleri ve ince ayrıntıları daha hassas bir şekilde ortaya çıkarmakta ve böylece sinyallerin karakteristik farklılıklarını daha etkin bir şekilde yakalamaktadır. Bu özellik, özellikle benzer sinyal paternlerine sahip aritmilerin ayırt edilmesinde önemli bir katkı sağlamaktadır. LSTM ve 1D-CNN modelleri ise sinyallerin zaman ve uzamsal özelliklerini öğrenebilme kapasiteleri sayesinde, bu öznitelikleri yüksek doğrulukla sınıflandırabilmektedir. LSTM modeli, sinyaldeki zaman bağımlılıklarını öğrenerek ritim bozukluklarının zamana bağlı örüntülerini yakalayabilmekte; 1D-CNN modeli ise sinyaldeki ardışık yapıların derinlemesine analizini yaparak, sinyalin her bir noktasındaki lokal bilgiyi işleyebilmektedir.

Sonuç olarak, bu dört aşamalı metodoloji, EKG sinyallerinde yüksek doğrulukla sınıflandırma yaparak kalp ritim bozukluklarının tespitinde güvenilir ve etkin bir çözüm

sunmaktadır. OD-1D-LBP yöntemi ile çıkarılan özneliklerin LSTM ve 1D-CNN modellerine sağladığı zengin bilgi, bu metodolojiyi geleneksel yöntemlerden ayıran en önemli faktördür. Bu çalışma, EKG sinyallerindeki detaylı varyasyonları ve lokal yapısal farklılıkları derin öğrenme yöntemleriyle işleyerek aritmi gibi ciddi kardiyak durumların tanısında kullanılabilecek değerli bir araç sunmaktadır. Bu yaklaşımın özellikle klinik tanı süreçlerinde doğru teşhis ve erken müdahale açısından önemli bir katkı sağlaması beklenmektedir.

5.3.2. Merkez bağımsız 1D-LBP + {1D-CNN, LSTM, GRU} yaklaşımı


Bu çalışmada, EKG sinyallerinden aritmi türlerini tespit etmek amacıyla yine dört aşamalı bir öznelik çıkarım ve sınıflandırma metodolojisi önerilmiştir. Bu yöneme ait süreçler Şekil 5.20’de gösterilen sistem diyagramında ayrıntılı olarak açıklanmıştır. Her bir aşamada, EKG sinyallerinin karakteristik yapısını çıkarmak ve sınıflandırma işlemlerini en doğru şekilde gerçekleştirmek için uygulanan işlemler detaylandırılmıştır.



Şekil 5.20. Önerilen aritmi sınıflandırma sisteminin akış diyagramı

Blok 1: İlk aşamada, veri集中的 her bir EKG sinyaline Merkezden Bağımsız Tek Boyutlu Yerel İkili Desen (CI-1D-LBP) yöntemi uygulanmıştır. Bu yöntem, sinyalin lokal özelliklerini ikili karşılaştırmalarla çıkararak, her bir sinyal örneğini 9 farklı sinyal halinde dönüştürmektedir. CI-1D-LBP ile üretilen bu yeni sinyaller, sinyalin belirli bir segmentinde yer alan lokal yapının özneliklerini temsil eder ve bu sinyallerin her biri 0 ile 255 arasında değişen değerler almaktadır. Böylece, orijinal EKG sinyalindeki önemli


yapısal özellikler CI-1D-LBP yöntemiyle ayrıntılı bir şekilde çıkarılmış olur. Şekil 5.21’de gösterildiği gibi, bir örnek EKG sinyaline uygulanan CI-1D-LBP yöntemi sonucunda elde edilen 9 sinyalin her birinin özgün bir yapı ortaya koyduğu gözlemlenmiştir. Bu sinyaller, bir sonraki aşamada histogram analizi için kullanılmaktadır.



Şekil 5.21. CI-1D-LBP yöntemin örnek sinyale uygulanması. (A) örnek EKG sinyali, (B) üretilen sinyaller

Blok 2: İkinci aşamada, CI-1D-LBP yönteminin çıkışında elde edilen 9 farklı sinyalin histogramları hesaplanmıştır. Her bir sinyal için çıkarılan histogramlar, o sinyalin lokal yapısına dair özniteliklerin daha yoğun bir şekilde özetlenmesini sağlar. Bu histogramlar, EKG sinyalinin belirli bir segmentindeki frekans dağılımlarını ortaya koyarak, her sinyalin kendine özgü bir profil oluşturmaya olanak tanır. Örnek bir EKG sinyali için oluşturulan 9 histogram, Şekil 5.22’de gösterilmiştir ve her bir histogramın yapısal farklılıklar gösterdiği dikkati çekmektedir. Bu farklılıklar, veri集中的 her bir EKG

örneğin karakteristik özelliklerini içeren öznitelik matrislerinin oluşturulmasını sağlar. Böylece, sınıflandırma modelleri için anlamlı giriş verileri elde edilmiş olur.



Şekil 5.22. CI-1D-LBP ile üretilen yeni sinyallere ait histogramlar

Blok 3: Üçüncü aşama, sınıflandırma aşamasıdır ve CI-1D-LBP yöntemiyle elde edilen histogramlar, derin öğrenme modellerine giriş verisi olarak sağlanmaktadır. Bu aşamada kullanılan derin öğrenme modelleri arasında LSTM, GRU ve 1D-CNN bulunmaktadır. LSTM ve GRU modelleri, EKG sinyallerinin zaman bağımlılıklarını öğrenmede etkili olup, sinyaldeki ardışık paternleri analiz ederken yüksek performans göstermektedir. 1D-CNN modeli ise, sinyaldeki lokal yapıları öğrenmede güçlü bir sınıflandırma yeteneği sunmaktadır. Her bir derin öğrenme modeli, CI-1D-LBP histogramlarından elde edilen özniteliklerin sınıflandırılmasında kullanılarak EKG sinyallerindeki aritmi türlerinin doğru bir şekilde tespit edilmesine olanak tanımaktadır.

Blok 4: Son aşama, karar ve değerlendirme aşamasıdır. Bu aşamada, sınıflandırma modellerinin performansları, doğruluk oranları, duyarlılık ve özgüllük gibi ölçütler ile analiz edilmiştir. Karışıklık matrisleri kullanılarak modellerin doğru ve yanlış

sınıflandırma oranları görselleştirilmiş ve performans değerlendirmesi yapılmıştır. Bu analizler, sınıflandırma modellerinin EKG sinyallerindeki aritmi türlerini ne derece başarılı bir şekilde tespit ettiğini ortaya koymaktadır. Karışıklık matrisleri ve diğer performans ölçütleri, CI-1D-LBP yöntemi ile elde edilen öz niteliklerin derin öğrenme modelleri tarafından ne kadar etkili bir şekilde değerlendirildiğini göstermektedir.

Bu dört aşamalı metodoloji, EKG sinyallerindeki lokal yapısal özelliklerin derinlemesine analiz edilmesini sağlayarak, aritmi gibi ritim bozukluklarının tespiti için kapsamlı ve yenilikçi bir öz nitelik çıkarımı ve sınıflandırma stratejisi sunmaktadır. CI-1D-LBP yöntemi ile elde edilen öz niteliklerin, LSTM, GRU ve 1D-CNN gibi derin öğrenme modelleriyle entegrasyonu, sinyallerdeki kompleks dinamikleri ve zamansal bağımlılıkları detaylı bir şekilde yakalayarak, EKG sinyallerinin çok boyutlu yapısını yüksek doğrulukla analiz etmeye imkan tanımaktadır.


Bu metodolojinin en önemli avantajlarından biri, her bir sinyal örneği için çoklu öz nitelik sinyalleri üreterek orijinal sinyalin lokal varyasyonlarını korumasıdır. CI-1D-LBP yöntemi, sinyaldeki küçük fakat önemli farklılıkları ikili kodlarla ifade ederek, sinyallerin incelikli yapısının ortaya konmasını sağlamakta ve her bir sinyal için benzersiz bir öz nitelik profili oluşturulmasına olanak tanımaktadır. Elde edilen histogram verileri, sinyallerin frekans dağılımlarını özetleyerek derin öğrenme modellerine anlamlı ve yoğun bilgi içeren bir giriş sağlamaktadır. Bu durum, modellerin sinyallerdeki farklı aritmi türlerini ayırt edebilme yeteneğini güçlendirmektedir. Metodolojinin bir diğer avantajı ise, derin öğrenme modellerinin her birinin EKG sinyallerindeki farklı özellikleri öğrenebilme kabiliyetlerini etkin bir şekilde kullanmasıdır. LSTM ve GRU gibi zaman bağımlılıklarını öğrenebilen modeller, EKG sinyallerindeki ritmik değişimleri anlamlandırmada güçlü bir yapı sunarken, 1D-CNN modeli sinyalin ardışık örüntülerini ve lokal varyasyonları daha ayrıntılı bir şekilde analiz edebilmektedir. Bu modellerin kombinasyonu hem sinyaldeki zamansal örüntüleri hem de lokal yapısal özellikleri başarılı bir şekilde değerlendirerek, farklı aritmi türlerinin yüksek doğruluk oranlarıyla sınıflandırılmasına olanak tanımaktadır.

Sonuç olarak, bu dört aşamalı metodoloji, EKG sinyallerinde karmaşık paternleri çıkarma ve sınıflandırmada son derece etkili ve güvenilir bir yaklaşımdır. Klinik uygulamalarda EKG sinyallerinin detaylı değerlendirilmesini sağlama potansiyeline sahip olan bu metodoloji, özellikle kalp ritim bozukluklarının erken teşhisi ve doğru sınıflandırılması açısından önemli bir katkı sunmaktadır. Bu çalışma, EKG sinyallerinin

biyomedikal analizinde yeni ve etkili bir yaklaşım geliştirerek, sağlık alanında daha hızlı ve kesin teşhisler yapılabilmesine olanak sağlamaktadır.

5.3.3. MD+CWT +DenseNet yaklaşımı

Bu çalışmada, aritmi (AF), normal sinüs ritmi (NSR) ve konjestif kalp yetmezliği (KKY) sinyallerinin analiz ve sınıflandırılması amacıyla beş aşamadan oluşan bir yöntem önerilmiştir. Bu yaklaşımın sistem diyagramı Şekil 5.23'te sunulmuştur. Her bir aşamada gerçekleştirilen işlemler şu şekilde özetlenmiştir:



Şekil 5.23. Motif+CWT +DenseNet sistem diyagramı

Aşama A: 80 kişiden toplamda 162 EKG kaydı elde edilmiştir. Bu kayıtlardan, gürültü ve artefakt kaynakları temizlendikten sonra her bir temizlenmiş EKG sinyali, uzunluğu 10000 örnek (78 s) olan 6 segment sinyale bölünmüştür. Bu işlem sonucunda toplamda 972 EKG sinyali elde edilmiştir.

Aşama B: Bu aşamada, EKG sinyallerine çeşitli pencere boyutları kullanılarak Motif dönüşümü uygulanmıştır. Şekil 1 (B)'de gösterildiği gibi, $WS=4$, $WS=5$ ve $WS=6$ pencere boyutları ile örnek bir EKG sinyali üzerinde Motif dönüşümü gerçekleştirilmiş ve her pencere boyutu için farklı sinyaller elde edilmiştir.

Aşama C: Motif dönüşümünden elde edilen sinyaller, CWT dönüşümüne tabi tutulmuştur. Bu işlem sonucunda, sinyallerin zaman ve frekansa göre değişen özelliklerini içeren skalogramlar elde edilmiştir. CWT ile tek boyutlu sinyallerden görüntü elde edilirken belirli bir filtre seti kullanılmıştır. Bu görüntüler, sinyalin zaman-frekans temsili ve genlik bilgilerini içermektedir. CWT'nin uygulanmasında kullanılan filtre parametreleri sabit tutulmuş olup, EKG sinyallerinin morfolojik yapısına benzerliği ve zaman-frekans lokalizasyon yeteneği nedeniyle Morse dalgacığı tercih edilmiştir.

Aşama D: Bu aşamada, sınıflandırma işlemleri DenseNet transfer öğrenme yöntemleri kullanılarak gerçekleştirilmiştir. Bu amaç doğrultusunda DenseNet121, DenseNet201 ve DenseNet169 mimarileri kullanılmıştır.

Aşama E: Son aşamada, EKG sinyalleri üç kategoriye ayrılarak sınıflandırılmıştır: AF, KKY ve NSR.

Bu metodolojinin ilk aşamasında (Aşama A), geniş bir EKG veri seti üzerinde gürültü ve artefaktların temizlenmesi ile başlanmıştır. Gürültü giderimi, sinyallerin analizinde doğruluğun artırılması açısından kritik öneme sahiptir. Elde edilen temiz EKG sinyalleri, her biri 10000 örnekten oluşan 78 saniyelik segmentlere bölünerek toplamda 972 sinyal elde edilmiştir. Bu segmentasyon işlemi, veri setinin daha düzenli bir yapıya kavuşmasını sağlarken, her bir EKG kaydının lokal özelliklerinin bağımsız olarak analiz edilmesine olanak tanır.

Aşama B'de, bu segmentlere Motif dönüşümü uygulanarak her bir sinyal, farklı pencere boyutları kullanılarak yeniden düzenlenmiştir. Bu işlem, sinyallerdeki belirgin örüntüleri ve lokal yapı özelliklerini daha iyi yansıtmak için kullanılmıştır. Motif dönüşümünde kullanılan farklı pencere boyutları ($WS=4$, $WS=5$, $WS=6$) ile elde edilen sinyaller, örüntülerin genişliğini ve yoğunluğunu değiştirerek sinyalin farklı yönlerini vurgulamaktadır. Böylece, her bir pencere boyutu için oluşturulan sinyaller, orijinal EKG sinyalinin yapısal çeşitliliğini ortaya koyar.

Üçüncü aşamada (Aşama C), Motif dönüşümünden elde edilen sinyaller CWT dönüşümüne tabi tutularak skalogram görüntüleri elde edilmiştir. CWT, sinyallerin hem zaman hem de frekans bilgisini içermesi bakımından EKG sinyallerinin analizinde oldukça avantajlıdır. CWT, DenseNet gibi derin öğrenme modelleriyle kullanıldığında

skalogramlar üzerinden zengin öznitelikler öğrenerek daha yüksek sınıflandırma doğruluğu sağlar. CWT, EKG gibi zamanla değişen sinyallerin zaman-frekans analizi için ayrıntılı ve hassas bir çözüm sunar. CWT'nin 2 boyutlu skalogramları, sinyalin enerji dağılımını zaman ve frekans eksenlerinde görselleştirerek anlık değişimlerin ve lokalize olayların tespit edilmesini kolaylaştırır. Bu özellik, özellikle aritmi gibi kısa süreli anormalliklerin belirlenmesinde DWT'ye (Ayrık Dalgacık Dönüşümü) kıyasla üstünlük sağlar. Ayrıca, sürekli ölçeklendirme yapısı ve farklı dalgacıklarla analiz esnekliği sunan CWT, sinyalin hem düşük hem de yüksek frekans bileşenlerini detaylı bir şekilde inceleme olanağı verir. CWT ile elde edilen skalogramlar, görselleştirilebilir yapısı sayesinde derin öğrenme modelleriyle (örneğin CNN) kolayca entegre edilebilir. Bu durum, sinyalin karmaşık örüntülerinin tespitinde etkili bir yol sunar. Öte yandan, DWT daha az bilgi içerir ve genellikle tek boyutlu öznitelikler sağlar, bu da geleneksel makine öğrenmesi yöntemlerine uygundur. Ancak, CWT'nin detaylı analiz avantajına rağmen hesaplama maliyetleri daha yüksektir ve analiz süresi daha uzundur. Bu nedenle, CWT'nin tercih edilmesi, bilgi zenginliği ile işlem hızı arasında bir denge kurulmasını gerektirir. Bu aşamada, Morse dalgacığı tercih edilmiştir çünkü bu dalgacık, EKG sinyallerinin morfolojik yapısına uygun bir yapıya sahip olup, sinyalin zaman-frekans lokalizasyonunu güçlü bir şekilde yansıtır. Bu skalogram görüntüleri, sinyallerin zaman-frekans temsili açısından zengin bilgiler sunmakta ve sinyallerin zamansal değişimlerini detaylı bir şekilde göz önüne sermektedir.

Dördüncü aşamada (Aşama D), sınıflandırma işlemleri DenseNet tabanlı transfer öğrenme yöntemleri ile gerçekleştirilmiştir. Bu aşamada, DenseNet121, DenseNet201 ve DenseNet169 gibi çeşitli mimariler kullanılarak, farklı derinliklere sahip modellerin performansı incelenmiştir. DenseNet mimarisi, her bir katmandaki bilginin sonraki katmanlara yoğun bir şekilde aktarılmasını sağlayarak, sınıflandırma işleminin doğruluğunu artırır. Bu özellik, EKG sinyallerindeki karmaşık örüntüleri daha etkin bir şekilde öğrenme yeteneği sunmaktadır.

Son aşamada sınıflandırma işlemi gerçekleştirilmiş ve EKG sinyalleri AF (aritm), KKY (konjestif kalp yetmezliği) ve NSR (normal sinüs ritmi) olarak üç farklı kategoriye ayrılmıştır. Bu sınıflandırma işlemi, EKG sinyallerinde belirli kalp hastalıklarının tespitinde ve normal durumun ayırt edilmesinde önemli bir araç sunmaktadır. Bu metodoloji, EKG sinyallerinde ayrıntılı zaman-frekans analizinin gerçekleştirilmesi ve transfer öğrenme modellerinin kullanılması sayesinde yüksek doğruluk oranları ile sonuçlanmış olup, kardiyovasküler rahatsızlıkların tespitinde önemli bir katkı

sağlamaktadır. Bu yaklaşım, klinik uygulamalarda kalp hastalıklarının erken teşhisi ve yönetiminde güçlü bir analiz aracı olarak kullanılabilir.

Bu çalışmada önerilen metot, EKG sinyallerindeki kompleks yapısal özellikleri analiz ederek aritmi, konjestif kalp yetmezliği ve normal sinüs ritmi gibi durumların yüksek doğruluk oranları ile sınıflandırılmasını sağlayan güçlü bir yöntem sunmaktadır. Motif dönüşümü ve CWT gibi öznitelik çıkarım tekniklerini kullanarak sinyallerin zamansal ve frekans eksenli bileşenlerini derinlemesine analiz eden bu metodoloji, DenseNet tabanlı transfer öğrenme modelleriyle entegre edilmiştir. Bu entegrasyon, sinyallerdeki ince detayların dahi etkin bir şekilde öğrenilmesine olanak tanımakta ve sinyalin çok boyutlu yapısını başarıyla modellemektedir. Özellikle, EKG sinyallerindeki karmaşık örüntülerin morfolojik benzerliklerini ve zamansal değişimlerini detaylı bir biçimde ele alması, bu metodolojiyi geleneksel analiz yöntemlerinden ayıran en önemli faktörlerden biridir. Klinik açıdan bakıldığında, kalp hastalıklarının erken teşhisinde ve tedavi sürecinin izlenmesinde kullanılabilecek bu yaklaşım, EKG analizinde yeni bir bakış açısı sunarak sağlık alanında önemli bir katkı sağlayabilir.

5.4. Performans Ölçütleri

Bu çalışmada, EKG sinyallerinden çıkarılan özniteliklerin sınıflandırma performansını değerlendirmek için çeşitli performans ölçütleri kullanılmıştır. Sınıflandırma modelinin doğruluğunu ve etkinliğini değerlendirmek amacıyla doğruluk (accuracy), duyarlılık (sensitivity), özgüllük (specificity), F1 skoru ve karışıklık matrisi (confusion matrix) gibi temel ölçütlerden faydalanılmıştır. Bu ölçütler, modelin sınıflandırma başarısını nesnel bir şekilde değerlendirerek, sonuçların güvenilirliğini ve modele dair iyileştirme fırsatlarını belirlemekte yardımcı olmaktadır.

1.Doğruluk (Accuracy): Doğruluk, modelin doğru sınıflandırdığı örneklerin toplam örnek sayısına oranıdır ve modelin genel performansını değerlendirmek için yaygın olarak kullanılan bir ölçüttür. Yüksek doğruluk değeri, modelin hem pozitif hem de negatif sınıfları iyi ayırt edebildiğini gösterir.

$$\text{Doğruluk(Accuracy)} = \frac{TP+TN}{TP + TN + FP + FN} \times 100 \quad (5.32)$$

Burada, TP doğru pozitif sayısını, TN doğru negatif sayısını, FP yanlış pozitif sayısını ve FN yanlış negatif sayısını temsil eder.

2. Duyarlılık (Sensitivity) veya Gerçek Pozitif Oranı (Recall): Duyarlılık, modelin pozitif sınıfları doğru bir şekilde tanımlama başarısını ölçer. Hastalık tespitinde özellikle önemli olan bu ölçüt, pozitif örneklerin ne kadarının doğru şekilde tespit edilebildiğini gösterir.

$$Duyarlılık(Recall) = \frac{TP}{TP+FN} \quad (5.33)$$

3. Özgüllük (Precision): Özgüllük, modelin negatif sınıfları doğru bir şekilde tanımlama becerisini ifade eder. Bu ölçüt, özellikle yanlış pozitiflerin azaltılması gereken durumlarda kritik bir öneme sahiptir, zira negatif örneklerin doğru sınıflandırılma oranını gösterir.

$$Özgüllük(Precision) = \frac{TP}{TP+FP} \quad (5.34)$$

4. F1 Skoru: F1 skoru, duyarlılık ve kesinliğin (precision) harmonik ortalaması olarak hesaplanır ve özellikle dengesiz veri setlerinde performansı değerlendirmek için yararlıdır. F1 skoru, yanlış pozitif ve yanlış negatif sınıflandırmalar arasında bir denge sağlayarak, modelin genel başarısını daha dengeli bir şekilde yansıtır.

$$F1 - score = 2x \frac{(Duyarlılık \times Özgüllük)}{Duyarlılık + Özgüllük} \quad (5.35)$$

5. Karışıklık Matrisi (Confusion Matrix): Karışıklık matrisi, sınıflandırma modelinin tahmin performansını görselleştirir. Modelin doğru ve yanlış sınıflandırdığı örneklerin sayısını gösteren bu tablo, modelin hangi sınıflarda güçlü veya zayıf olduğunu ortaya koyar ve model iyileştirme sürecinde yönlendirici bir araç görevi görür.

Bu performans ölçütleri, önerilen metodolojinin sınıflandırma başarısını kapsamlı bir şekilde değerlendirirken, elde edilen sonuçların doğruluğunu ve güvenilirliğini analiz etmekte kritik bir rol oynar. EKG sinyallerinde aritmi ve konjestif kalp yetmezliği gibi rahatsızlıkların güvenilir tespiti için yüksek doğruluk, duyarlılık ve özgüllük değerlerine ulaşmak büyük önem taşır. Bu nedenle, bu ölçütler üzerinde yapılan analizler, modelin genel başarısını değerlendirmenin yanı sıra, sınıflandırmadaki güçlü ve zayıf yönleri belirleyerek modeli geliştirmek için de önemli bilgiler sağlar

6. UYGULAMA SONUÇLARI VE PERFORMANS DEĞERLENDİRMESİ

Bu bölümde, çalışmanın bulguları ve geliştirilen yöntemlerin etkinliği, sınıflandırma performanslarına dayalı olarak detaylandırılacaktır. Çalışma kapsamında, konjestif kalp yetmezliği (KKY), farklı aritmi türleri ve normal sinüs ritmi (NSR) gibi kardiyak durumların doğru bir şekilde sınıflandırılmasını amaçlayan üç farklı yöntem geliştirilmiştir: OD-1D-LBP, CI-1D-LBP ve Motif dönüşümü (MD) tabanlı CWT sinyal ön işleme modeli. Bu yöntemler, her bir uygulama için özgün öznitelikler çıkararak EKG sinyallerindeki belirgin yapıları ortaya koymayı ve derin öğrenme modellerine yüksek doğrulukta giriş verileri sağlamayı hedeflemiştir.

Birinci uygulamada, konjestif kalp yetmezliği (KKY), aritmi (AF) ve sağlıklı bireylerin normal sinüs ritmi (NSR) sinyallerine ait EKG verileri üzerinde analiz yapılmıştır. Bu veriler MITBIH ve BIDMC veri tabanlarına ait kalp yetmezliği ve ritim bozuklukları olan hastaların sinyallerini içeren bir veri setinden alınmıştır. Bu çalışmada geliştirilen ortogonal fark bir boyutlu yerel ikili desen (OD-1D-LBP) yöntemi, sinyaldeki lokal varyasyonları belirginleştirerek hastalıklı ve sağlıklı sinyaller arasında ayırt edici öznitelikler çıkarmak amacıyla kullanılmıştır. Elde edilen öznitelikler histogramlar halinde çıkarılmış ve ardından 1D-CNN ve LSTM gibi derin öğrenme modellerine giriş verisi olarak uygulanmıştır.

İkinci uygulamada, MIT-BIH arşivinden alınan ve dört farklı aritmi türünü (ventriküler atım (VA), supraventriküler atım (SVA), füzyon atımı (FA), tanımlanmamış aritmi atımı (TA)) içeren EKG veri seti kullanılmıştır. Bu veri seti ayrıca sağlıklı bireylerin normal sinüs ritmi (NSR) sinyallerini de içermektedir. Aritmi türlerini sınıflandırmak için geliştirilen merkezden bağımsız bir boyutlu yerel ikili desen (CI-1D-LBP) yöntemi, sinyallerdeki lokal yapıları belirginleştirici özniteliklerle karakterize etmiştir. CI-1D-LBP yöntemi, her bir sinyal örneği için 9 farklı sinyal çıkartarak, bu lokal değişimlerin her birini ayrı ayrı temsil etmiştir. Bu öznitelik histogramları 1D-CNN, LSTM ve GRU modellerine giriş verisi olarak uygulanmış, her bir model sinyallerdeki farklı aritmi türlerini yüksek doğruluk oranlarıyla sınıflandırmıştır.

Üçüncü uygulamada ise, birinci uygulamada da kullanılan konjestif kalp yetmezliği (KKY), aritmi (AF) ve sağlıklı bireylerin normal sinüs ritmi (NSR) sinyallerine ait EKG veri setine sürekli zamanlı dalgacık dönüşümü (CWT) öncesinde bir veri örüntüleme algoritması olan Motif dönüşümü (MD) uygulanmıştır. MD, sinyaldeki tekrarlayan motifleri ve lokal yapıları çıkararak, EKG sinyallerinin belirgin özelliklerini

analiz etmeyi sağlamıştır. MD sonrası elde edilen tek boyutlu sinyaller, CWT ile işlenmiş ve skalogram görüntüleri oluşturulmuştur. Bu skalogram görüntüleri, sinyalin zaman-frekans yapısını görselleştirerek öznitelik çıkarımında kullanılmıştır. DenseNET tabanlı derin transfer öğrenme modelleri ile analiz edilen bu skalogramlar, kalp ritim bozukluklarının yüksek doğrulukla sınıflandırılmasına olanak sağlamıştır.

Bulguların değerlendirilmesi aşamasında, kullanılan yöntemlerin doğruluğunu ve sınıflandırma başarısını belirlemek amacıyla doğruluk (accuracy), duyarlılık (sensitivity), özgüllük (specificity), F1 skoru gibi performans ölçütleri ile karışıklık matrisi (confusion matrix) analiz edilmiştir. Bu sonuçlar, geliştirilen yöntemlerin kalp hastalıklarının tespitinde sağladığı katkıları ve kullanılan derin öğrenme modellerinin sınıflandırma yeteneğini ayrıntılı bir şekilde ortaya koymaktadır

6.1. OD-1D-LBP+{LSTM,1D-CNN} Yönteminin Sonuç ve Bulguları

Bu uygulamada, kalp hastalıklarının tespiti amacıyla EKG sinyallerinden ayırt edici özniteliklerin çıkarılmasını sağlayan yerel ikili desen (LBP) tabanlı ortogonal fark bir boyutlu yerel ikili desen (OD-1D-LBP) yöntemi kullanılmıştır. Bu yöntem, her sinyal değerini kendi komşu değerleriyle karşılaştırarak elde edilen ikili bilgileri temel alır ve sinyalin lokal yapısını belirginleştirir. Bu yaklaşım, giriş olarak verilen bir EKG sinyalinden 0 ile 255 arasında değişen değerlerde üç farklı sinyal üretir. Önerilen yöntemin performansını değerlendirmek amacıyla, aritmi (AF), normal sinüs ritmi (NSR) ve konjestif kalp yetmezliği (KKY) durumlarına ait toplam 972 EKG sinyali içeren bir veri seti kullanılmıştır.

OD-1D-LBP ile dönüştürülmüş EKG sinyallerinden elde edilen histogramlar, LSTM ve 1D-CNN derin öğrenme modellerine giriş olarak sunulmuş ve bu modeller aracılığıyla sınıflandırma işlemi gerçekleştirilmiştir. LSTM ve 1D-CNN modelleri, tek boyutlu sinyallerin analizi ve sınıflandırılmasında yaygın olarak kullanılan derin öğrenme yöntemleridir. Bu çalışmada, EKG sinyallerinin sınıflandırılmasında kullanılan LSTM ve 1D-CNN modellerinin hiper parametre değerleri Tablo 6.1'de detaylandırılmıştır.

Tablo 6.1. LSTM ve 1D-CNN modellerine ait hiperparametre değerleri

LSTM KONFİGÜRASYON MODELİ		1D-CNN KONFİGÜRASYON MODELİ	
Parametreler	Değerler	Parametreler	Değerler

Katmanlar	SequenceInput bi-LSTM(100) fullyConnected SoftMax Classification	Katmanlar	SequenceInput convolution1dLayer reluLayer layerNormalizationLayer convolution1dLayer reluLayer layerNormalizationLayer globalAveragePooling1dLayer fullyConnectedLayer softmaxLayer classificationLayer
Girdi Boyutu	3/256	Girdi Boyutu	3/256
Gizli Katman Boyutu	100	Filtre Boyutları ve Ölçüsü	32-64 / 3
Çıkış Katman Boyutu	3	Çıkış Katman Boyutu	3
Mini Yığın Boyutu	27	Mini Yığın Boyutu	27
Optimizasyon Algoritması	adam	Optimizasyon Algoritması	sgdm
Öğrenme Oranı	0.01	Maksimum Epoch Sayısı	70

Bu çalışmada, sınıflandırma doğruluğunu en üst düzeye çıkarmak amacıyla LSTM ve 1D-CNN modellerinin hiper parametreleri özenle optimize edilmiştir. Her iki modelde de en iyi sınıflandırma sonuçlarının elde edilmesi için en uygun mini yığın boyutu (batch) boyutu 27 olarak belirlenmiştir. LSTM modeli için “adam” optimizasyon algoritması tercih edilmiş, 1D-CNN modelinde ise “sgdm” algoritmasının daha başarılı sonuç verdiği gözlemlenmiştir. OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN modellerinin sınıflandırma başarı oranları Tablo 6.2’de gösterilmiş olup, bu başarı oranları, farklı eğitim-test oranları ile gerçekleştirilen sınıflandırma işlemlerinden elde edilmiştir.

Tablo 6.2. OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN metotlarının sınıflandırma başarı oranları


Model	Eğitim-Test Oranları	Doğruluk (Accuracy) (%)	Duyarlılık (Recall)	Kesinlik (Precision)	F1-Skoru (F1-Score)
OD-1D-LBP +LSTM	%70-%30	98.63	0.981	0.984	0.982
	%60-%40	98.97	0.993	0.983	0.987
	%50-%50	98.35	0.989	0.972	0.980
OD-1D-LBP+1D-CNN	%70-%30	98.86	0.971	0.983	0.976
	%60-%40	98.63	0.966	0.989	0.976
	%50-%50	96.84	0.931	0.927	0.926

Tablo 6.2 incelendiğinde, OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN modellerinin EKG sinyallerini yüksek doğruluk oranlarıyla sınıflandırabildiği


görülmektedir. Her iki derin öğrenme modelinde de başarılı sınıflandırma sonuçları elde edilmiş olup, genel performans açısından OD-1D-LBP + LSTM modelinin OD-1D-LBP + 1D-CNN modeline göre üstün bir başarı sergilediği tespit edilmiştir. En yüksek başarı oranı, OD-1D-LBP + LSTM modeliyle %60-%40 eğitim-test oranında %98.97 olarak elde edilmiştir. Öte yandan, OD-1D-LBP+1D-CNN modeli için en yüksek doğruluk oranı %70-%30 eğitim-test oranında %98.86 olarak gözlenmiştir. Bu bulgular, OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN modellerinin EKG sinyallerini yüksek doğrulukla sınıflandırma yeteneğine sahip olduğunu göstermektedir ve OD-1D-LBP+LSTM modelinin bu çalışmada daha iyi sonuçlar sağladığı ortaya konulmuştur.

Şekil 6.1 ve Şekil 6.2’de, OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN derin öğrenme modelleri için en iyi performansı gösterdiği sonuçlara ait karışıklık matrisleri verilmiştir. Bu matrisler hem eğitim hem de test setlerine göre ayrı ayrı sunulmuştur. Karışıklık matrisleri incelendiğinde, OD-1D-LBP+LSTM modelinin eğitim setinde %100 doğruluk oranıyla başarılı bir performans sergilediği, OD-1D-LBP+1D-CNN modelinin ise %99.17 doğruluk oranına ulaştığı görülmektedir. Bu durum, OD-1D-LBP+LSTM modelinin eğitim sürecinde OD-1D-LBP+1D-CNN modeline göre daha yüksek bir genel doğruluk sağladığını göstermektedir.


Şekil 6.3’te OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN modellerinin eğitim süreci boyunca doğruluk (accuracy) ve kayıp (loss) değerleri izlenmiştir. Bu grafikler, önerilen modellerin eğitim süreçlerindeki başarısını ve öğrenme hızını değerlendirmek amacıyla kullanılmaktadır. Kayıp değerleri, modellerin ne kadar hızlı öğrendiğini ve eğitim verilerini ezberleme eğiliminde olup olmadığını anlamak için incelenmiştir. Grafikteki doğruluk ve kayıp eğrileri, OD-1D-LBP ile elde edilen özniteliklerin LSTM ve 1D-CNN modellerinde yüksek doğruluk oranlarına ulaşarak başarı sağladığını göstermektedir.



Şekil 6.1. Eğitim ve test setleri için LSTM modeli ile elde edilen karışıklık matrisleri



Şekil 6.2. Eğitim ve test setleri için 1D-CNN modeli ile elde edilen karışıklık matrisleri



Şekil 6.3. LSTM ve 1D-CNN modellerinin eğitim sürecinde doğruluk (Accuracy) ve kayıp (Loss) eğrileri

Bu uygulamada, OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN yöntemleri kullanılarak aritmi (AF) ve konjestif kalp yetmezliği (KKY) hastalıklarına ait EKG sinyallerinin, normal sinüs ritmi (NSR) sinyallerinden ayrıştırılması da ayrıca incelenmiştir. Bu amaçla, veri seti ikili sınıflandırmaya tabi tutulmuş ve her bir hastalık durumu, sağlıklı sinyallerden ayrı olarak değerlendirilmiştir. Ayrıca, AF ve KKY sinyalleri de kendi aralarında sınıflandırmaya tabi tutularak, iki hastalık durumunun birbirinden ayrıştırılması sağlanmıştır. Elde edilen sınıflandırma sonuçları Tablo 6.3'te sunulmuştur.

Tablo 6.3. OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN ile ikili sınıflandırma başarı sonuçları

Veri Setleri	OD-1D-LBP+LSTM	OD-1D-LBP+1D-CNN
AF-NSR	99.21	95.24
KKY-NSR	99.24	98.99
AF-KKY	98.94	97.40

Tablo 6.3'te görüldüğü gibi, OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN modelleri ile her bir ikili sınıflandırma senaryosunda başarılı sonuçlar elde edilmiştir. OD-1D-LBP+LSTM modeli, tüm kategorilerde OD-1D-LBP+1D-CNN modeline göre daha yüksek doğruluk sağlamış ve özellikle KKY-NSR ayrımında %99.24 doğruluk oranına ulaşmıştır. Bu sonuçlar, OD-1D-LBP tabanlı öznetelik çıkarma yönteminin ikili sınıflandırma performansını artırmada etkili olduğunu göstermektedir.

Şu ana kadar EKG sinyallerinin segment uzunluğunun 10000 olduğu durumlar için analiz sonuçları verilmiştir. Uygulama kapsamında, farklı segment uzunluklarının (5000, 2000 ve 1000) sınıflandırma başarısı üzerindeki etkisi de değerlendirilmiştir. Bu bağlamda, farklı segment uzunlukları için modelin doğruluğuna yönelik sonuçlar Tablo 6.4'te sunulmuştur.

Tablo 6.4. Farklı uzunluktaki EKG sinyalleri için başarı oranları

Segment uzunlukları	Segment sayısı	Segment oranları (NSR,AF,KKY)	OD-1D-LBP+LSTM (%)	OD-1D-LBP+1D-CNN (%)
10000	972	NSR(216),AF(576),KKY(180)	98.97	98.86
5000	2106	NSR(467),AF(1248),KKY(391)	99.17	96.23
2000	4860	NSR(1080),AF(2880),KKY(900)	98.85	96.43
1000	10530	NSR(2340), AF(6240), KKY(1950)	96.91	96.80

Tablo 6.4 farklı segment uzunluklarının OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN modelleri üzerindeki sınıflandırma başarısına etkisini detaylı bir şekilde sunmaktadır. Segment uzunlukları 10000, 5000, 2000 ve 1000 olarak belirlenmiş ve her bir segment uzunluğu için elde edilen sınıflandırma doğruluk oranları (OD-1D-LBP+LSTM ve OD-1D-LBP+1D-CNN) karşılaştırılmıştır. Ayrıca, segment sayısı ve her bir segment uzunluğunda NSR (Normal Sinüs Ritmi), AF (Aritmi) ve KKY (Konjestif Kalp Yetmezliği) sınıflarına ait örnek dağılımı da tabloya eklenmiştir. Bu kapsamda, her bir segment uzunluğu ile elde edilen sınıflandırma başarısı aşağıda detaylandırılmıştır:

1. **Segment Uzunluğu 10000:** 10000 veri noktasına sahip segmentler kullanıldığında, toplam 972 segment oluşturulmuştur. Bu segmentlerin 216'sı NSR, 576'sı AF ve 180'i KKY sinyallerine aittir. Bu segment uzunluğunda OD-1D-LBP+LSTM modeli %98.97 doğruluk sağlarken, OD-1D-LBP+1D-CNN modeli %98.86 doğruluk oranına ulaşmıştır. Her iki model de bu segment uzunluğunda yüksek başarı göstermiştir.
2. **Segment Uzunluğu 5000:** 5000 veri noktasına sahip segmentler ile toplam 2106 segment elde edilmiştir. Bu segmentler NSR (467), AF (1248) ve KKY (391) sinyallerinden oluşmaktadır. Bu segment uzunluğunda OD-1D-LBP+LSTM modeli %99.17 doğruluğa ulaşarak en yüksek başarı oranını sağlamışken, OD-1D-LBP+1D-CNN modeli %96.23 doğruluk oranı ile daha düşük bir performans sergilemiştir. LSTM modelinin bu segment uzunluğunda özellikle başarılı olduğu gözlemlenmiştir.
3. **Segment Uzunluğu 2000:** 2000 veri noktasına sahip segmentler kullanılarak 4860 segment oluşturulmuştur. Segment dağılımı NSR (1080), AF (2880) ve KKY (900) şeklindedir. Bu segment uzunluğunda OD-1D-LBP+LSTM modeli %98.85 doğruluk oranına ulaşırken, OD-1D-LBP+1D-CNN modeli %96.43 doğruluk sağlamıştır. LSTM modeli yine daha yüksek bir performans sergilemiştir.
4. **Segment Uzunluğu 1000:** 1000 veri noktasına sahip segmentler ile toplam 10530 segment elde edilmiştir. Bu segmentlerde NSR (2340), AF (6240) ve KKY (1950) sinyalleri yer almaktadır. Segment uzunluğunun en küçük olduğu bu senaryoda, OD-1D-LBP+LSTM modeli %96.91 doğruluk oranına, OD-1D-LBP+1D-CNN modeli ise %96.80 doğruluk oranına ulaşmıştır. Bu sonuçlar, segment uzunluğunun daha kısa olduğu durumlarda dahi her iki modelin yüksek doğruluk sağlayabildiğini göstermektedir.

Tablo 6.4 segment uzunluklarının sınıflandırma performansı üzerindeki etkisini net bir şekilde göstermektedir. Genel olarak, segment uzunluğu düştükçe doğruluk oranlarında hafif bir azalma gözlenmektedir; ancak LSTM ve 1D-CNN modelleri tüm segment uzunluklarında yüksek doğruluk oranlarını koruyabilmiştir. Özellikle, 5000 segment uzunluğunda OD-1D-LBP+LSTM modelinin %99.17 ile en yüksek doğruluğa ulaşması dikkat çekicidir. Bu sonuçlar, OD-1D-LBP yöntemi ile çıkarılan özneteliklerin, farklı segment uzunlukları için sağlam ve tutarlı sınıflandırma sonuçları verdiğini göstermektedir.

Bu çalışmada elde edilen sonuçlar literatürde benzer veri setleri üzerinde yapılan çalışmalarla da karşılaştırılmıştır. Karşılaştırma tablosu Tablo 6.5'te verilmiştir. Tablodaki sonuçlardan görüleceği gibi önerilen yaklaşım ile kabul edilebilir yüksek sonuçların elde edildiği tespit edilmiştir.

Tablo 6.5. OD-1D-LBP+{LSTM, 1D-CNN} modellerinin literatürdeki çalışmalarla karşılaştırılması

Literatür Kaynakları	EKG Veri Setleri	Metodoloji	Sınıflandırma Başarısı (%)
Çınar ve Tuncer (2021)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	Hybrid AlexNet-SVM	96.77
Acharya vd. (2019)	Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	11-Layer CNN	98.97
Eltrass vd. (2021)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	CQNSGT+AlexNET	98.82
Huang vd. (2019)	Konjestif Kalp Yetmezliği, R-R Aralıkları	Multiple Input Neural Network	93.76
Kaouter vd. (2019)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	2D-CNN	93.75
Kumari vd. (2020)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	DWT+SVM	95.92
Rahuja (2021)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	CWT+CNN	97.3
Senturk (2023)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	CWT+CNN(AlexNet)	98.7
Tez Çalışması	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	OD-1D-LBP+LSTM OD-1D-LBP+1D-CNN	98.97 98.86

6.2. CI-1D-LBP+{LSTM,1D-CNN,GRU} Yönteminin Sonuç ve Bulguları

Bu çalışmada, ventriküler atım (VA), supraventriküler atım (SVA), füzyon atımları (FA) ve tanımlanmamış bir aritmi türü (TA) olmak üzere toplam dört farklı aritmi çeşidi ile sağlıklı bireylere ait normal sinüs ritmini (NSR) temsil eden EKG sinyalleri üzerinde ayırt edici özneliliklerin elde edilmesi hedeflenmiştir. Bu amaçla, özgün bir yöntem olarak CI-1D-LBP tekniği kullanılmıştır. Önerilen yöntem, her bir EKG sinyali boyunca hareket eden bir pencere fonksiyonunun sınırları içerisinde kalan sinyal segmentlerini analiz ederek, dokuz referans noktası üzerinden elde edilen ikili bilgileri temel almaktadır. Her bir referans noktası, çevresindeki komşu noktalar ile

karşılaştırılarak, sinyalin lokal özelliklerini temsil eden ikili değerler oluşturulmaktadır. Bu ikili değerlerin özetlenmesiyle, her bir sinyal segmenti için 0 ile 255 arasında değişen histogramlar elde edilmiştir.

Oluşturulan bu histogram verileri, sırasıyla LSTM, 1D-CNN ve GRU gibi güncel derin öğrenme modellerine giriş öznitelik seti olarak sunulmuştur. Derin öğrenme modelleri, EKG sinyallerindeki karmaşık örüntüleri ve farklı aritmi türlerini ayırt etmeye yönelik güçlü bir sınıflandırma performansı sergilemek için optimize edilmiştir. Kullanılan LSTM modeli, zaman bağımlılıklarını yakalamada üstün performans gösterirken, 1D-CNN modeli, sinyallerin lokal özelliklerini öğrenmeye odaklanmıştır. GRU modeli ise LSTM'nin zaman serisi verilerinde sağladığı avantajları daha az hesaplama maliyetiyle gerçekleştirebilecek şekilde tasarlanmıştır.

Bu bağlamda, her bir derin öğrenme modelinin performansını optimize etmek için çeşitli hiper parametre değerleri seçilmiş ve bu hiper parametre değerleri Tablo 6.6'da detaylı bir şekilde sunulmuştur. Bu çalışmanın temel amacı, CI-1D-LBP yöntemi ile öznitelik çıkarımı ve derin öğrenme modelleri aracılığıyla yüksek doğrulukta sınıflandırma gerçekleştirmek ve farklı aritmi türlerini ayırt etmeye yönelik güçlü bir sistem geliştirmektir.

Tablo 6.6. LSTM, 1D-CNN ve GRU modellerinin hiper parametre değerleri

Model	Katmanlar	Girdi Boyutu	Gizli Katman Boyutu	Çıkış Katman ı Boyutu	Mini Yığın Boyutu / Maksimum Epochs Sayısı	Optimizasyon Algoritması	Öğrenme Oranı
LSTM	SequenceInput LSTM(100) FullyConnected SoftMax Classification	3/256	100	3	127 / 30	Adam	0.01
1D-CNN	SequenceInput Convolution1DLayer ReLU LayerNormalization Convolution1DLayer ReLU LayerNormalization GlobalAveragePooling 1DLayer FullyConnected SoftMax Classification	3/256	#filters: 32-64 Filter size: 3	3	127 / 70	SGDM	Max Epochs: 70
GRU	SequenceInput GRULayer FullyConnected SoftMax Classification	3/256	#filters: 32-64 Filter size: 3	3	127 / 30	RMSProp	Max Epochs: 30

Bu çalışmada kullanılan LSTM, 1D-CNN ve GRU modellerine ait hiper parametre değerleri, katman yapıları ve diğer model özellikleri Tablo 6.6’da detaylı bir şekilde sunulmuştur. Modeller, EKG sinyallerindeki karmaşık yapıları analiz etmek ve farklı aritmi türlerini sınıflandırmak amacıyla dikkatlice tasarlanmış ve optimize edilmiştir. LSTM modeli, zaman bağımlılıklarını öğrenmeye yönelik olarak tasarlanmış bir yapıya sahiptir. Model, 100 gizli nöron içeren bir LSTM katmanı ile donatılmıştır. Girdi boyutu, her bir veri örneğinin üç özellikten oluştuğunu ve zaman ekseninde 256 uzunluğunda bir diziye sahip olduğunu ifade eden 3/256 olarak belirlenmiştir. LSTM modeli, öğrenme işlemi için “Adam” optimizasyon algoritmasını kullanmakta ve öğrenme oranı 0.01 olarak seçilmiştir. Mini yığın boyutu 127 olarak ayarlanmış ve model, maksimum 30 “epoch” boyunca eğitilmiştir. Çıkış katmanı ise üç farklı sınıfa yönelik sınıflandırma işlemini gerçekleştirmektedir.

1D-CNN modeli ise sinyallerin lokal özelliklerini öğrenmeye odaklanmış bir yapıya sahiptir. Bu model, birden fazla Convolution1D katmanı ile bu katmanların ardından yer alan ReLU aktivasyon fonksiyonlarını ve normalizasyon katmanlarını içermektedir. Ayrıca, modelde global ortalama havuzlama işlemi gerçekleştirilmiştir. 1D-CNN modelinin filtre sayıları 32 ile 64 arasında değişmekte olup, filtre boyutu 3 olarak belirlenmiştir. Bu yapı, EKG sinyallerindeki lokal örüntülerin etkin bir şekilde öğrenilmesini sağlamaktadır. Model, optimizasyon işlemleri için SGDM algoritmasını kullanmakta ve maksimum 70 epoch boyunca eğitilmektedir. Girdi boyutu, çıkış katmanı ve mini yığın boyutu LSTM modeli ile aynı olarak belirlenmiştir.

GRU modeli, LSTM’ye benzer şekilde zaman serisi verilerinin analiz edilmesine odaklanmış, ancak hesaplama maliyetlerini düşürmek amacıyla daha sade bir hücre mimarisiyle tasarlanmıştır. GRU modelinde de filtre sayıları 32 ile 64 arasında değişmekte ve filtre boyutu 3 olarak seçilmiştir. Girdi boyutu ve çıkış katmanı diğer modellerle aynıdır. Optimizasyon işlemleri RMSProp algoritması ile gerçekleştirilmekte ve model maksimum 30 epoch boyunca eğitilmektedir. Bu model, LSTM’nin sağladığı avantajları daha düşük bir hesaplama maliyetiyle sunmayı amaçlamaktadır.

Bu bağlamda, her bir modelin farklı yapısal özellikleri ve hiper parametre ayarları, EKG sinyallerindeki karmaşık örüntülerin ve farklı aritmi türlerinin yüksek doğrulukla sınıflandırılmasını sağlamak üzere titizlikle düzenlenmiştir. Özellikle LSTM modeli, zaman bağımlılıklarını güçlü bir şekilde analiz ederken, 1D-CNN modeli lokal örüntüleri öğrenmeye odaklanmış; GRU modeli ise hesaplama maliyetlerini optimize ederek zaman serisi verilerinde etkin bir analiz sunmayı hedeflemiştir.

Normal sinüs ritmi (NSR) ile ventriküler atım (VA), supraventriküler atım (SVA), füzyon atımı (FA) ve tanımlanmamış bir aritmi türü (TA) olmak üzere toplam beş farklı sınıfa ait EKG sinyalleri, LSTM, 1D-CNN ve GRU modelleri kullanılarak sınıflandırılmıştır. Bu modellerle gerçekleştirilen sınıflandırma işlemlerine ait başarı oranları, Tablo 6.7’de detaylı bir şekilde sunulmaktadır. Çalışmada, sınıflandırma performansını değerlendirmek amacıyla farklı eğitim-test veri oranları kullanılmış ve her bir modelin bu oranlara göre sergilediği performans incelenmiştir. Söz konusu modellerin EKG sinyallerindeki karmaşık yapıları ne ölçüde etkili bir şekilde analiz ettiği ve farklı aritmi türlerini ayırt etme konusundaki doğruluk oranları, elde edilen bulgular ışığında karşılaştırmalı olarak değerlendirilmiştir.

Tablo 6.7. CI-1D-LBP+LSTM, CI-1D-LBP+1D-CNN ve CI-1D-LBP+GRU metotlarının sınıflandırma başarı oranları

Metotlat	Eğitim-Test Oranı (Training-Test)	Doğruluk (%) (Accuracy (%))	Duyarlılık (Recall)	Kesinlik (Precision)	F1- Skoru (F1- score)
CI-1D-LBP+1D CNN	70%-30%	97.17	0.953	0.952	0.952
	60%-40%	95.92	0.915	0.893	0.901
	50%-50%	95.48	0.903	0.868	0.892
CI-1D-LBP+LSTM	70%-30%	98.02	0.973	0.941	0.956
	60%-40%	96.21	0.964	0.880	0.917
	50%-50%	95.87	0.895	0.918	0.904
CI-1D-LBP+GRU	70%-30%	98.59	0.975	0.945	0.958
	60%-40%	96.25	0.933	0.904	0.918
	50%-50%	95.81	0.920	0.887	0.898


Tablo 6.7'ye göre, üç farklı derin öğrenme modeli ile gerçekleştirilen sınıflandırma işlemlerinde genel olarak yüksek başarı oranlarına ulaşıldığı gözlenmiştir. Ancak hücresel ağ yapılarının benzerliği göz önünde bulundurulduğunda, CI-1D-LBP+LSTM ve CI-1D-LBP+GRU modellerinin, CI-1D-LBP+1D-CNN modeline kıyasla daha yüksek doğruluk oranları sunduğu dikkat çekmektedir. Özellikle, CI-1D-LBP+GRU modeli, %70-30 eğitim-test oranında %98.59 gibi oldukça yüksek bir doğruluk oranı ile tüm modeller arasında en iyi performansı göstermiştir. Benzer şekilde, CI-1D-LBP+LSTM modeli de %70-30 eğitim-test oranında %98.02 doğruluk oranı ile GRU modeline yakın bir başarı sergilemiştir. CI-1D-LBP+1D-CNN modeli ise aynı oranlarda %97.17 doğruluk oranı ile yüksek bir performans göstermesine rağmen, diğer iki modele kıyasla bir miktar geride kalmıştır. Bu bulgular, özellikle zaman serisi verilerinin işlenmesinde GRU ve LSTM modellerinin, CNN tabanlı yapılara kıyasla daha etkili olduğunu göstermektedir. Bunun

temel nedeni, GRU ve LSTM gibi tekrarlayan sinir ağlarının, zaman bağımlılıklarını daha iyi modelleyebilmesi ve uzun vadeli ilişkileri öğrenme kapasitesinin daha yüksek olmasıdır. Bu bağlamda, beş etiketli EKG verilerinin sınıflandırılmasında CI-1D-LBP+GRU modeli, üstün performansı ile diğer modellerden ayrılmıştır. Bu sonuçlar, derin öğrenme modellerinin farklı özelliklerini ve veri yapıları üzerindeki etkilerini anlamada önemli bir katkı sağlamaktadır.


Şekil 6.4, Şekil 6.5 ve Şekil 6.6'da sırası ile beş etiketli EKG verilerinin sınıflandırılması amacıyla kullanılan CI-1D-LBP+1D-CNN, CI-1D-LBP+LSTM ve CI-1D-LBP+GRU modellerine ait en başarılı sonuçların karışıklık matrisleri sunulmaktadır. Bu matrisler, modellerin hem eğitim hem de test setleri üzerindeki performanslarını detaylı bir şekilde göstermektedir. Elde edilen bulgular, CI-1D-LBP+GRU modelinin tüm EKG sınıfları için CI-1D-LBP+LSTM ve CI-1D-LBP+1D-CNN modellerine kıyasla daha yüksek başarı yüzdelerine ulaştığını açıkça ortaya koymaktadır. Eğitim ve test setlerine ait karışıklık matrislerinde, CI-1D-LBP+GRU modeli, özellikle zaman bağımlılıklarının belirgin olduğu karmaşık sınıflar (örneğin, supraventriküler atım ve tanımlanmamış aritmi) üzerinde diğer modellere göre daha üstün bir performans sergilemiştir. Bunun temel nedenlerinden biri, GRU modelinin zaman serisi verilerindeki uzun vadeli ilişkileri düşük hesaplama maliyetleri ile etkili bir şekilde modelleyebilmesidir.

Öte yandan, CI-1D-LBP+LSTM modeli, benzer şekilde zaman bağımlılıklarını güçlü bir şekilde öğrenebilmesine rağmen, hesaplama maliyetlerinin daha yüksek olması ve parametre optimizasyonunun daha karmaşık olması nedeniyle GRU modeline kıyasla bir miktar geride kalmıştır. CI-1D-LBP+1D-CNN modeli ise lokal örüntülerin öğreniminde etkili olmuş ancak uzun vadeli bağımlılıkların daha belirgin olduğu sınıflarda, GRU ve LSTM modellerine kıyasla daha düşük doğruluk oranları sunmuştur. Bununla birlikte, modelin normal sinüs ritmi (NSR) gibi belirgin özelliklere sahip sınıfları yüksek doğrulukla sınıflandırdığı gözlemlenmiştir.


Sonuç olarak, CI-1D-LBP+GRU modeli, genel performans ve her bir sınıf için sağladığı yüksek doğruluk oranları ile diğer modellere kıyasla en iyi sonuçları sunmuştur. Bu durum, GRU modelinin hem eğitim hem de test aşamalarında zaman serisi analizine uygun yapısı sayesinde, EKG verilerinin sınıflandırılmasında daha üstün bir seçenek olduğunu göstermektedir. Elde edilen bu sonuçlar, farklı derin öğrenme modellerinin sınıflandırma görevlerindeki avantaj ve dezavantajlarını anlamada önemli bir katkı sunmaktadır.



Şekil 6.4. Eğitim ve test setleri için 1D-CNN modeli ile elde edilen karışıklık matrisleri



Şekil 6.5. Eğitim ve test setleri için LSTM modeli ile elde edilen karışıklık matrisleri



Şekil 6.6. Eğitim ve test setleri için GRU modeli ile elde edilen karışıklık matrisleri

Bu çalışmada, farklı veri seti kombinasyonları kullanılarak dört farklı aritmi türüne (ventriküler atım - VA, supraventriküler atım - SVA, füzyon atımı - FA, tanımlanmamış aritmi - TA) ait EKG sinyalleri, kendi içlerinde sınıflandırılmıştır. Ayrıca

her bir aritmi çeşidi, normal sağlıklı bireylere ait EKG sinyalleri (NSR) ile ayrı ayrı karşılaştırılarak (NSR-VA, NSR-SVA, NSR-FA, NSR-TA) sınıflandırılmıştır. Bu sınıflandırma işlemlerinde kullanılan CI-1D-LBP+LSTM, CI-1D-LBP+1D-CNN ve CI-1D-LBP+GRU modellerine ait başarı oranları Tablo 6.8’de sunulmaktadır.

Tablo 6.8. Farklı veri seti kombinasyonları için sınıflandırma doğruluk oranları

Veri Setleri	CI-1D LBP+LSTM	CI-1D-LBP-1D+CNN	CI-1D-LBP+GRU
VA-SVA-FA-TA	98.70	97.81	99.08
NSR-VA	99.12	98.23	99.87
NSR-SVA	99.20	98.19	100
NSR-FA	99.47	98.48	99.71
NSR-TA	99.66	98.32	100

Tablo 6.8’e göre, dört aritmi türünün kendi içlerindeki sınıflandırılmasında en yüksek doğruluk oranı CI-1D-LBP+GRU modeli ile %99.08 olarak elde edilmiştir. CI-1D-LBP+LSTM modeli %98.70 doğruluk oranı ile GRU modeline yakın bir performans sergilemiştir. Buna karşın CI-1D-LBP+1D-CNN modeli %97.81 ile diğer modellere kıyasla daha düşük bir doğruluk sağlamıştır. Bu sonuç, GRU ve LSTM modellerinin, karmaşık zaman serisi verilerindeki örüntüleri öğrenmede daha etkili olduğunu göstermektedir. Her bir aritmi çeşidinin NSR ile sınıflandırılmasında ise yine CI-1D-LBP+GRU modeli üstün bir performans göstermiştir. Özellikle NSR-SVA ve NSR-TA sınıflarında GRU modeli %100 doğruluk oranı ile mükemmel bir sınıflandırma gerçekleştirmiştir. CI-1D-LBP+LSTM modeli bu sınıflarda sırasıyla %99.20 ve %99.66 oranında doğruluk sağlamışken, CI-1D-LBP+1D-CNN modeli %98.19 ve %98.32 ile diğer iki modele göre daha düşük sonuçlar vermiştir. Benzer şekilde NSR-VA ve NSR-FA sınıflarında da GRU modeli en yüksek doğruluk oranlarını sunmuştur. Bu sonuçlar, CI-1D-LBP yönteminin öznelilik çıkarma aşamasında sağladığı başarının, GRU ve LSTM gibi zaman bağımlılıklarını öğrenme kapasitesine sahip modellerle birleştirildiğinde, yüksek doğruluk oranlarıyla sonuçlandığını göstermektedir. Öte yandan, CNN tabanlı modellerin daha sınırlı zaman serisi analizi kapasitesi nedeniyle, özellikle uzun vadeli bağımlılıkların ön planda olduğu sınıflarda geride kaldığı gözlemlenmiştir.

Sonuç olarak, CI-1D-LBP+GRU modeli hem karmaşık aritmi sınıflandırmalarında hem de aritmi-NSR sınıflandırmalarında diğer modellere kıyasla daha üstün performans sergilemiştir. Bu durum, GRU modelinin zaman serisi

verilerindeki örüntüleri düşük hata oranlarıyla öğrenme kapasitesinin altını çizmektedir ve aritmi sınıflandırma problemlerinde kullanımı için güçlü bir alternatif sunmaktadır.

Bu çalışmada, farklı sinyal uzunluklarına sahip EKG verileri kullanılarak gerçekleştirilen sınıflandırma işlemleri ile sinyal uzunluğunun sınıflandırma başarımları üzerindeki etkisi incelenmiştir. Elde edilen bulgular, sinyal uzunluğu arttıkça sınıflandırma modellerinin doğruluk oranlarının anlamlı bir şekilde yükseldiğini ortaya koymaktadır. Bu durum, sinyal uzunluğunun artmasıyla birlikte modellerin sinyalin zaman ve frekans boyutlarındaki örüntülerini daha iyi öğrenebilmesine bağlanabilir. Tablo 6.9’da NSR ve dört farklı aritmi türüne (NSR, VA, SVA, FA, TA) ait EKG verilerinin farklı sinyal uzunluklarında elde edilen sınıflandırma başarımları sunulmaktadır.

Tablo 6.9. Farklı sinyal uzunluklarına göre başarımları (%)

Sinyal Uzunluğu	CI-1D-LBP-LSTM	CI-1D-LBP-1D CNN	CI-1D-LBP-GRU
187	91.20	89.10	91.89
374	92.11	91.32	92.81
561	94.05	93.14	94.76
748	95.24	94.18	95.83
935	96.31	95.91	96.81
1122	97.04	96.33	97.60
1309	98.02	97.17	98.59

Tabloya göre, sinyal uzunluğu 187 olarak seçildiğinde tüm modellerde sınıflandırma başarımları nispeten düşük kalmıştır (örneğin, CI-1D-LBP-GRU için %91.89). Ancak sinyal uzunluğu arttıkça sınıflandırma doğruluk oranlarının belirgin bir şekilde yükseldiği görülmektedir. Örneğin, sinyal uzunluğu 1309 olduğunda CI-1D-LBP-GRU modeli %98.59 doğruluk oranı ile en yüksek performans sergilemiştir. CI-1D-LBP-LSTM ve CI-1D-LBP-1D-CNN modelleri de sırasıyla %98.02 ve %97.17 doğruluk oranları ile oldukça başarılı sonuçlar elde etmişlerdir. Sonuçlar, önerilen sınıflandırma modellerinin sinyal uzunluğuna duyarlılığını ve performanslarının sinyaldeki bilgi miktarıyla doğru orantılı olarak arttığını göstermektedir. GRU tabanlı model, farklı sinyal uzunlukları boyunca en yüksek başarımlarını sergileyerek, sinyal uzunluğundaki artışın sınıflandırma performansına etkisini en iyi değerlendiren model olarak öne çıkmıştır. LSTM tabanlı model de benzer şekilde yüksek doğruluk oranları sağlamış, ancak GRU modeline kıyasla bir miktar geride kalmıştır. CNN modeli ise lokal özellikleri öğrenme kapasitesi nedeniyle kısa sinyal uzunluklarında diğer modellerle rekabetçi bir

performans sergilerken, sinyal uzunluğu arttıkça LSTM ve GRU modellerinin gerisinde kalmıştır. Bu bulgular, özellikle uzun sinyallerin analizi gereken durumlarda GRU ve LSTM modellerinin tercih edilmesi gerektiğini göstermektedir. Ayrıca, sinyal uzunluğunun artırılmasının sınıflandırma doğruluğunu iyileştirmek için etkili bir strateji olduğu sonucuna varılmıştır. Bu sonuçlar, sinyal işleme ve sınıflandırma problemlerinde veri hazırlık sürecinde sinyal uzunluğu seçimlerinin önemini vurgulamaktadır.

Bu çalışmada elde edilen sonuçlar literatürdeki diğer çalışmalarla da karşılaştırılmıştır. Karşılaştırma tablosu Tablo 6.10’da verilmiştir. Tablodaki sonuçlardan görüleceği gibi önerilen yaklaşımlar ile kabul edilebilir yüksek sonuçların elde edildiği tespit edilmiştir.

Tablo 6.10. CI-1D-LBP+GRU modellerinin literatürdeki çalışmalarla karşılaştırılması


Literatür Kaynakları	EKG Veri Setleri	Metodoloji	Sınıflandırma Başarısı (%)
Acharya vd. (2017)	Aritmi, Normal Sinüs Ritmi	9-layer deep convolutional neural network (CNN)	93.50
Kumari vd. (2021)	Aritmi, Normal Sinüs Ritmi	DWT + SVM	95.92
Murawwat vd.(2022)	Aritmi, Normal Sinüs Ritmi	Multivariate Empirical Mode Decomposition (MEMD)-ANN	89.8
Sharma vd. (2020)	Aritmi, Normal Sinüs Ritmi	Fourier-Bessel expansion + LSTM	90.07
Zheng vd. (2021)	Aritmi, Normal Sinüs Ritmi	Singular Value Decomposition (SVD)-CNN-SVM	96-97
Faust ve Acharya (2021)	Aritmi, Normal Sinüs Ritmi	ResNet	95.55
Mohammadalipour vd. (2018)	Aritmi, Normal Sinüs Ritmi	Karar Ağaçları (DT)-SVM	97.1
Karpagachelvi vd. (2012)	Aritmi, Normal Sinüs Ritmi	DWT-SVM-ELM	90.52
Salem vd. (2018)	Aritmi, Normal Sinüs Ritmi	STFT-DenseNET	97.23
Tez Çalışması	Aritmi, Normal Sinüs Ritmi	CI-1D-LBP+GRU	98.59

6.3. Motif + CWT + DenseNet Yönteminin Sonuç ve Bulguları

Bu uygulamada, EKG sinyalleri üzerinden konjestif kalp yetmezliği (KKY), aritmi (AF) ve sağlıklı bireylerin normal sinüs ritmi (NSR) gibi kardiyak durumların tespitine yönelik yenilikçi bir yöntem önerilmiştir. Çalışmanın temelinde, EKG sinyallerine uygulanan Motif dönüşümü (MD) ve bu dönüşüm sonucu elde edilen tek

boyutlu sinyallere sürekli zamanlı dalgacık dönüşümü (CWT) uygulanarak üretilen skalogram görüntülerinin analizi yer almaktadır. Son aşamada ise, elde edilen skalogram görüntüler, DenseNet121, DenseNet169 ve DenseNet201 gibi farklı transfer öğrenme mimarileri kullanılarak sınıflandırılmıştır.

Analizlerde toplam 972 EKG sinyali kullanılmıştır. Bu veri seti, AF, KKY ve NSR sinyallerinden oluşmaktadır. Motif dönüşümü, sinyal üzerindeki örnek değerlerin büyüklük ve küçüklük ilişkilerine dayanarak belirli örüntüler (motifler) çıkarmaktadır. Motifler, sinyaldeki örnekleme sayısına bağlı olarak farklı desenlerde oluşmaktadır. Örneğin, dönüşüm işlemi sırasında pencere boyutu $WS = 4$ olduğunda $4! = 24$ farklı motif yapısı elde edilirken, $WS = 5$ olduğunda $5! = 120$ farklı motif örüntüsü oluşturulmaktadır. Motif dönüşümünden sonra elde edilen tek boyutlu sinyallere CWT uygulanarak zaman-frekans özelliklerini yansıtan skalogram görüntüler oluşturulmuştur. Şekil 6.7’de verilen skalogram görüntüleri, farklı pencere boyutlarında ($WS = 4$, $WS = 5$, $WS = 6$, $WS = 7$, $WS = 8$) üretilen skalogramların, AF, KKY ve NSR sinyalleri için nasıl değiştiğini göstermektedir. Görüntülere dikkatle bakıldığında, pencere boyutundaki değişimin, skalogramların yapısını ve detay seviyesini önemli ölçüde etkilediği görülmektedir.



Şekil 6.7. WS parametresinin farklı değerlerine göre sinyal örnekleri için oluşturulan skalogram görüntüler

AF sinyalleri için küçük pencere boyutlarında (örneğin, $WS = 4$) sinyalin genel yapısı daha az detay içerirken, pencere boyutu arttıkça ayrıntılar artmış, ancak aşırı büyük pencere boyutlarında ($WS = 8$) detay kaybı gözlemlenmiştir. KKY sinyallerinde, orta seviyede bir pencere boyutu ($WS = 6$ veya $WS = 7$), sinyalin zaman-frekans düzlemindeki

karakteristik özelliklerini en iyi şekilde yansıtmıştır. NSR sinyallerinde ise, özellikle WS = 7 pencere boyutunda, ayırt edici detaylar öne çıkmış, ancak WS = 8’de sinyal özelliklerinin bastırıldığı görülmüştür.

Bu analizler, pencere boyutunun (WS) EKG sinyallerindeki ayırt edici özelliklerin yakalanmasında kritik bir parametre olduğunu göstermektedir. Daha küçük pencere boyutları, sinyalin mikro düzeydeki varyasyonlarını yansıtırken, daha büyük pencere boyutları sinyalin makro yapısını ortaya koymaktadır. Ancak aşırı büyük pencere boyutlarında (WS = 8), sinyalin belirgin yapıları düzleşmekte ve bu da ayırt edici bilgilerin kaybolmasına yol açmaktadır.

Motif dönüşümüne dayalı olarak oluşturulan skalogram görüntüler, farklı pencere boyutlarının zaman-frekans analizinde doğrudan etkisini göstermektedir. WS = 7, AF, KKY ve NSR gibi kardiyak durumların belirgin örüntülerini ortaya koyarak en yüksek sınıflandırma doğruluğuna katkı sağlamaktadır. Daha büyük veya daha küçük pencere boyutları, veri kaybı veya bilgi karmaşası yaratabilir. Bu bağlamda, Motif dönüşüm ve CWT tabanlı yaklaşımlar, EKG sinyallerinin analizinde etkili bir yöntem olarak öne çıkmaktadır. DenseNet mimarileriyle entegre edilen bu yöntem, kalp hastalıklarının teşhisinde yenilikçi bir yaklaşım sunmaktadır.

AF, KKY ve NSR’ye ait EKG sinyallerinin birbirinden ayrıştırılması ve sınıflandırılmasına yönelik gerçekleştirilen çalışmada, farklı eğitim-test oranlarına dayalı çeşitli denemeler yapılmıştır. Bu denemelerde, Motif dönüşümü (MD) parametresi olarak $MD_{WS=7}$ seçilmiş ve dönüşüm sonrasında elde edilen CWT tabanlı skalogram görüntüler DenseNet121, DenseNet169 ve DenseNet201 mimarileri ile sınıflandırılmıştır. Farklı eğitim-test oranlarına göre elde edilen sınıflandırma sonuçları Tablo 6.11’de sunulmaktadır.

Tablo 6.11. $MD_{WS=7}$ olması durumunda DenseNET ile elde edilen başarı oranları (%)

Eğitim-Test Oranları	DenseNET121	DenseNET169	DenseNET201
%50-50	97.94	98.96	98.96
%60-40	97.93	99.12	98.96
%70-30	98.30	99.31	98.96

Tablo 6.11 incelendiğinde, her üç DenseNet mimarisinin yüksek doğruluk oranları ile başarılı sınıflandırma gerçekleştirdiği görülmektedir. DenseNet169, özellikle %60-%40 ve %70-%30 eğitim-test oranlarında en yüksek doğruluk değerlerine (%99.12 ve %99.31) ulaşarak diğer mimarilere kıyasla üstün bir performans sergilemiştir.

DenseNet121 ve DenseNet201 ise %70-%30 eğitim-test oranında %98.30 ve %98.96 doğruluk oranları ile başarılı sonuçlar elde etmiştir. Bu sonuçlar, Motif dönüşümü tabanlı CWT ile üretilen skalogramların, özellikle DenseNet169 ile analiz edildiğinde EKG sinyallerindeki kardiyak durumların (AF, KKY, NSR) hassas bir şekilde ayrıştırılmasını sağladığını göstermektedir. Eğitim-test oranları açısından bakıldığında, %70-%30 oranı ile yapılan denemelerde genel performansın diğer oranlara göre daha iyi olduğu gözlemlenmiştir. Bu durum, modelin daha fazla eğitim verisi ile daha iyi bir öğrenme kapasitesine sahip olduğunu ve genelleştirme başarısını artırdığını ortaya koymaktadır. DenseNet121 ve DenseNet201 mimarilerinin performansları da dikkat çekicidir. Her iki model, tüm eğitim-test oranlarında oldukça istikrarlı sonuçlar elde etmiş, özellikle %50-%50 oranında bile yüksek doğruluk (%97.94 ve %98.96) sağlamıştır. Bu, kullanılan Motif dönüşümü ve CWT tabanlı yaklaşımın farklı DenseNet mimarileri ile uyumlu bir şekilde çalıştığını ve her bir mimarinin genel olarak sınıflandırma başarısında etkili olduğunu göstermektedir. Sonuç olarak, elde edilen bulgular, Motif dönüşümü ve CWT tabanlı skalogram görüntülerinin, EKG sinyallerinin sınıflandırılmasında yüksek doğruluk ve güvenilirlik sağladığını, DenseNet169'un ise en iyi sonuçları verdiğini göstermektedir. Bu bulgular, önerilen yöntemin kalp hastalıklarının teşhisinde güçlü bir araç olabileceğini ortaya koymaktadır.

Motif dönüşümü (MD) sırasında kullanılan pencere boyutu (WS) parametresinin, sınıflandırma doğruluğu üzerindeki etkisini incelemek amacıyla farklı WS değerleriyle denemeler yapılmıştır. Bu denemeler, %70-%30 eğitim-test oranı kullanılarak gerçekleştirilmiştir. Farklı WS değerlerine göre elde edilen sınıflandırma sonuçları Tablo 6.12'de sunulmaktadır.

Tablo 6.12. WS'nin farklı değerleri için başarı oranları (%)


MD_{ws} parametresi	DenseNET121	DenseNET169	DenseNET201
WS=4	95.83	94.79	96.49
WS=5	96.88	97.92	99.12
WS=6	96.88	97.92	98.97
WS=7	98.30	99.31	98.97
WS=8	90.62	91.15	95.96

Tablo 6.12 incelendiğinde, WS parametresinin sınıflandırma doğruluğu üzerinde belirgin bir etkisi olduğu görülmektedir. DenseNet121, DenseNet169 ve DenseNet201 mimarilerinin tümünde, WS değeri 7 olarak seçildiğinde en yüksek doğruluk oranlarına ulaşıldığı gözlemlenmiştir. DenseNet169 modeli, WS=7 durumunda %99.31 doğruluk


oranı ile diğer modeller arasında en iyi performansı göstermiştir. DenseNet121 ve DenseNet201 ise bu parametre değerinde sırasıyla %98.30 ve %98.97 doğruluk oranları elde etmiştir.

Pencere boyutunun (WS) sınıflandırma performansı üzerindeki etkisini anlamak için detaylı bir inceleme yapılmıştır. Küçük pencere boyutları (WS=4) kullanıldığında, sinyaldeki mikro düzeydeki özellikler daha belirgin hale gelmekle birlikte, makro düzeydeki özelliklerin kaybolması nedeniyle sınıflandırma doğruluğunda bir düşüş gözlenmiştir. Benzer şekilde, aşırı büyük pencere boyutlarında (WS=8), sinyalin genelleştirilmiş yapıları belirsizleşmiş ve bu durum ayırt edici özelliklerin kaybolmasına neden olmuştur. Bu da sınıflandırma doğruluğunda önemli bir düşüşe yol açmıştır. En yüksek performansın WS=7 değerinde elde edilmesi, bu pencere boyutunun sinyalin zaman-frekans özelliklerini en iyi şekilde temsil ettiğini göstermektedir. Bu durum, WS değerinin doğru seçiminin, EKG sinyallerindeki belirgin örüntülerin yakalanmasında ve sınıflandırmada önemli bir rol oynadığını ortaya koymaktadır. DenseNet169 mimarisi, tüm WS değerlerinde istikrarlı bir şekilde en yüksek performansı sağlamış ve özellikle WS=7 durumunda %99.31 doğruluk oranına ulaşmıştır. DenseNet201 mimarisi ise, yüksek doğruluk oranları elde etmiş olsa da WS=8 durumunda performansında belirgin bir düşüş gözlenmiştir. DenseNet121 modeli de yüksek başarı göstermesine rağmen, diğer modellerle karşılaştırıldığında biraz daha düşük performans sergilemiştir. Sonuçlar, pencere boyutu (WS) parametresinin doğru seçiminin, Motif dönüşümünden elde edilen skalogram görüntülerinin sınıflandırma doğruluğunu doğrudan etkilediğini göstermektedir. WS=7 değeri hem zaman hem de frekans özelliklerini en iyi şekilde temsil ederek en yüksek doğruluğu sağlamıştır. Bunun yanı sıra, DenseNet mimarilerinin hepsi, özellikle WS=7 ve WS=5 değerlerinde başarılı sınıflandırma sonuçları elde etmiştir. Ancak, DenseNet169, önerilen yöntemin uygulandığı bu çalışmada en yüksek doğruluğu sağlayarak üstün performansını bir kez daha ortaya koymuştur. Bu bulgular, EKG sinyallerinin sınıflandırılması ve kalp hastalıklarının teşhisi için WS parametresinin ve DenseNet mimarilerinin dikkatle optimize edilmesi gerektiğini göstermektedir.

Şekil 6.8, DenseNET121, DenseNET169 ve DenseNET201 modelleri kullanılarak yapılan sınıflandırma işlemlerine ait karışıklık matrislerini göstermektedir. Karışıklık matrisleri, AF (aritmî), KKY (konjestif kalp yetmezliği) ve NSR (normal sinüs ritmi) sınıflarının tahmin edilen ve gerçek sınıflar arasındaki ilişkiyi sayısal ve oran bazında detaylandırmaktadır. Ayrıca, Şekil 6.9'da en yüksek performansı gösteren DenseNET169 modeline ait doğruluk (accuracy) ve kayıp (loss) grafikleri sunulmuştur.



Şekil 6.8. Farklı DenseNET modelleri için karışıklık matrisleri



Şekil 6.9. DenseNET169 modeline ait doğruluk (accuracy) ve kayıp (loss) grafikleri

Karışıklık matrislerinden görüldüğü üzere, tüm DenseNET modelleri yüksek doğruluk oranları ile başarılı sınıflandırma gerçekleştirmiştir. DenseNET169 modeli, AF sınıfında %99.43, KKY sınıfında %98.03 ve NSR sınıfında %100 doğruluk oranlarına ulaşarak diğer modeller arasında üstün performans göstermiştir. Özellikle KKY sınıfında

elde edilen %98.03 doğruluk oranı, kritik kalp hastalıklarının başarılı bir şekilde sınıflandırıldığını göstermektedir. DenseNET121 ve DenseNET201 modelleri de AF ve NSR sınıflarında %98.86 ve %99.42 gibi yüksek doğruluk oranlarına ulaşmıştır. Ancak, DenseNET169 modeli, AF ve KKY sınıflarında hata oranlarının (sırasıyla %0.57 ve %1.97) düşük olması ile diğer modellerden ayrılmıştır. Bu durum, DenseNET169'un sinyal örüntülerini daha iyi öğrenme kapasitesine sahip olduğunu göstermektedir.

Şekil 6.9'da yer alan performans grafikleri, DenseNET169 modelinin eğitim sürecindeki doğruluk ve kayıp değerlerini göstermektedir. Eğitim ve doğrulama doğruluk oranlarının her “epoch” boyunca düzenli olarak arttığı ve belirli bir noktadan sonra stabilize olduğu görülmektedir. Bu, modelin öğrenme sürecinde istikrarlı bir performans sergilediğini ve overfitting (aşırı öğrenme) problemi yaşanmadığını ortaya koymaktadır. Eğitim ve doğrulama kayıplarının hızla düşmesi, modelin hatalarını etkili bir şekilde azalttığını ve genel öğrenme sürecinin başarılı bir şekilde tamamlandığını göstermektedir.

Karışıklık matrisleri ve performans grafikleri bir bütün olarak değerlendirildiğinde, önerilen Motif dönüşümü (MD) ve CWT tabanlı yaklaşımın, DenseNET modelleri ile birleştirildiğinde EKG sinyallerinden elde edilen verilerin sınıflandırılmasında oldukça etkili olduğu görülmektedir. DenseNET169 modeli, diğer modellere kıyasla daha yüksek doğruluk oranlarına ulaşmış ve özellikle kritik sınıflar olan AF ve KKY için daha düşük hata oranları sağlamıştır.

Bu bulgular, önerilen yöntemle üretilen skalogram görüntülerinin, özellikle DenseNET169 gibi güçlü bir derin öğrenme mimarisi ile analiz edildiğinde, kardiyak durumların hassas bir şekilde tespit edilmesini sağladığını ortaya koymaktadır. Performans grafikleri ayrıca modelin eğitim sürecinin verimli geçtiğini ve genel sınıflandırma performansını desteklediğini göstermektedir. Bu nedenle, DenseNET169 hem genel doğruluk hem de istikrar açısından önerilen yaklaşımın en uygun mimarisi olarak öne çıkmaktadır.

EKG sinyallerinin sınıflandırma performansını değerlendirmek amacıyla, dönüşüm yöntemleri kullanılmadan ve farklı dönüşüm aşamaları uygulanarak DenseNET modelleri ile sınıflandırma işlemleri gerçekleştirilmiştir. İlk aşamada, ham EKG sinyalleri herhangi bir ön işleme tabi tutulmaksızın doğrudan DenseNET modellerine giriş olarak verilmiştir. İkinci aşamada ise yalnızca CWT dönüşümü uygulanarak elde edilen skalogram görüntüleri, Motif dönüşümü (MD) uygulanmaksızın sınıflandırma işlemleri için kullanılmıştır. Her iki senaryo için elde edilen sınıflandırma sonuçları ve MD+CWT+DenseNET uygulanmış sınıflandırma sonuçları Tablo 6.13'te sunulmaktadır.

Bu analiz, dönüşüm yöntemlerinin sınıflandırma üzerindeki etkisini ayrıntılı bir şekilde incelemek için gerçekleştirilmiştir

Tablo 6.13. DenseNET, CWT+DenseNET ve MD+CWT+DenseNET yöntemlerinin başarı oranlarının karşılaştırılması (%)

Model	DenseNET121	DenseNET169	DenseNET201
DenseNET	89.56	91.66	90.13
CWT+DenseNET	94.97	94.79	92.71
MD+CWT+DenseNET	98.30	99.31	98.97

Tablodaki sonuçlar, ham EKG sinyalleri, yalnızca CWT uygulanmış skalogram görüntüler ve MD+CWT kombinasyonu ile elde edilen skalogram görüntülerin DenseNET modelleriyle sınıflandırılması arasındaki performans farklarını ortaya koymaktadır. Ham EKG sinyalleriyle yapılan sınıflandırmada doğruluk oranları (%89.56, %91.66 ve %90.13) oldukça düşüktür. Bu durum, ham verilerdeki ayırt edici özelliklerin yeterince açık olmaması nedeniyle sınıflandırma başarısını olumsuz etkilemektedir. CWT uygulamasıyla elde edilen skalogram görüntülerin kullanılması doğruluk oranlarını (%94.97, %94.79 ve %92.71) artırmıştır. CWT'nin sinyalin zaman-frekans analizini görselleştirmede etkili bir yöntem olduğu görülmektedir. Ancak yalnızca CWT kullanılması, sinyallerdeki daha ince detayların tam olarak yakalanmasını sağlayamamaktadır. MD+CWT kombinasyonu ise en yüksek doğruluk oranlarını (%98.30, %99.31 ve %98.97) sağlamıştır. Bu durum, Motif dönüşümü'nün sinyaldeki önemli örüntüleri belirgin hale getirerek CWT ile DenseNET modellerinin öğrenme kapasitesini artırdığını göstermektedir. Özellikle DenseNET169 modeli, %99.31 doğruluk oranı ile en iyi performansı sergilemiştir. Bu sonuçlar, MD+CWT+DenseNET yaklaşımının EKG sinyallerinin sınıflandırılmasında üstün bir yöntem olduğunu açıkça ortaya koymaktadır.

Çalışmada, MD+CWT yöntemleri kullanılarak oluşturulan skalogram görüntüler yardımıyla AF (aritmî) ve KKY (konjestif kalp yetmezliği) gibi kardiyak rahatsızlıklara ait EKG sinyallerinin NSR (normal sinüs ritmi) sinyallerinden ayrıştırılması ve sınıflandırılması incelenmiştir. Ayrıca, AF ve KKY sinyallerinin birbirinden ayrıştırılması da değerlendirilmiştir. İki etiketli veri setleri (AF-NSR, KKY-NSR, AF-KKY) üzerinde gerçekleştirilen sınıflandırma işlemleri DenseNET121, DenseNET169 ve DenseNET201 modelleri kullanılarak yapılmış ve Tablo 6.14'te sunulan sonuçlar elde edilmiştir.

Tablo 6.14. İki etiketli veri setlerinin sınıflandırılmasında başarımlar oranları (%)

Veri setleri	DenseNET121	DenseNET169	DenseNET201
AF-NSR	99.37	98.12	98.61
KKY-NSR	100.00	100.00	100.00
AF-KKY	99.31	98.61	98.61

Sonuçlar değerlendirildiğinde, KKY-NSR sınıflandırmasında tüm DenseNET modellerinin %100 doğruluk oranı ile mükemmel bir performans sergilediği görülmüştür. Bu durum, KKY sinyallerinin NSR sinyallerinden ayrıştırılmasının daha belirgin ayırt edici özelliklere sahip olduğunu göstermektedir. MD dönüşümü ve CWT'nin sağladığı zengin zaman-frekans temsilleri, modelin öğrenme kapasitesini artırarak bu yüksek doğruluk oranlarına ulaşılmasını sağlamıştır. AF-NSR ve AF-KKY sınıflandırmalarında da DenseNET modelleri yüksek doğruluk oranları elde etmiştir. AF-NSR sınıflandırmasında DenseNET121 modeli %99.37 doğruluk oranı ile diğer modellere kıyasla en iyi performansı göstermiştir.

Benzer şekilde, AF-KKY sınıflandırmasında da DenseNET121 %99.31 doğruluk oranı ile en başarılı model olmuştur. DenseNET169 ve DenseNET201 modelleri ise AF ve KKY sinyallerinin ayrıştırılmasında benzer doğruluk oranları (%98.61) sağlamıştır. Bu bulgular, önerilen MD+CWT yönteminin yalnızca belirgin sinyallerin ayrıştırılmasında değil, daha karmaşık ve benzer örüntülere sahip sinyallerin sınıflandırılmasında da etkili olduğunu ortaya koymaktadır. Genel olarak değerlendirildiğinde, çalışma, MD ve CWT kombinasyonunun kardiyak rahatsızlıkların doğru ve güvenilir bir şekilde tespit edilmesi için güçlü bir araç olduğunu göstermektedir.

Bu çalışmada elde edilen sonuçlar literatürdeki diğer çalışmalarla ile de karşılaştırılmıştır. Karşılaştırma tablosu Tablo 6.15'te verilmiştir. Önerilen yöntem hem zaman hem de frekans domeninden öznetelik çıkarımı yaparak güçlü bir derin öğrenme modeli ile birleştirilmiş ve literatürdeki en yüksek performans sergilemiştir. Bu sonuçlar, önerilen yöntemin EKG sinyallerinde aritmi, konjestif kalp yetmezliği ve normal sinüs ritmi gibi sınıfların teşhisinde etkin bir alternatif sunduğunu kanıtlamaktadır. Elde edilen bulgular, metodolojinin literatüre önemli bir katkı sağladığını ve kalp hastalıklarının teşhisinde güvenilir bir araç olarak kullanılabileceğini göstermektedir.

Tablo 6.15. MD+CWT+DenseNET modellerinin literatürdeki çalışmalarla karşılaştırılması

Literatür Kaynakları	EKG Veri Setleri	Metodoloji	Sınıflandırma Başarısı (%)
Kaouter vd. (2019)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	2D-CNN	93.75
Çınar ve Tuncer (2021)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	Hybrid Alexnet-SVM	96.77
Acharya vd. (2019)	Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	11-Layer CNN	98.97
Eltrass vd. (2021)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	CQNSGT+AlexNET	98.82
Madan vd. (2022)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	CWT+CNN+LSTM	98.7- 99.0
Kaya vd. (2022)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	AT+LSTM	98.97
Kumari vd. (2020)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	DWT+SVM	95.92
Rahuja (2021)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	CWT+CNN	97.3
Senturk (2023)	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	CWT+CNN(AlexNet)	98.7
Tez Çalışması	Aritmi, Konjestif Kalp Yetmezliği, Normal Sinüs Ritmi	MD+CWT+DenseNET	99.31

7. SONUÇLAR VE ÖNERİLER

7.1 Sonuçlar

Bu tez çalışmasında, kardiyak durumların doğru ve güvenilir bir şekilde sınıflandırılması amacıyla üç farklı yöntem geliştirilmiş ve bu yöntemler, derin öğrenme modelleri ile entegre edilerek kapsamlı bir şekilde değerlendirilmiştir. OD-1D-LBP, CI-1D-LBP ve Motif dönüşümü (MD) tabanlı Sürekli Zamanlı Dalgacık Dönüşümü (CWT) yöntemleri ile gerçekleştirilen analizler, EKG sinyallerindeki ayırt edici yapıları etkin bir şekilde ortaya koymuş ve sınıflandırma doğruluğunu literatürdeki diğer çalışmalara kıyasla daha yüksek seviyelere taşımıştır. Çalışma boyunca kullanılan dönüşüm yöntemleri, tek boyutlu EKG sinyallerinin iki boyutlu analiz tekniklerinden (LBP tabanlı) ilham alınarak sınıflandırılması için yenilikçi bir yaklaşıma dayanmaktadır. Geleneksel olarak tek boyutlu zaman serisi verileri üzerine odaklanan analiz yöntemleri, sinyallerin lokal ve global özelliklerini sınırlı bir bağlamda değerlendirme eğilimindedir. Bu çalışmada ise, EKG sinyalleri iki boyutlu zaman-frekans analiz tekniklerinden türetilen yöntemlerle ele alınmış, böylece sinyallerin içerdiği bilgi daha zengin bir perspektifle işlenmiştir. Bu yaklaşım, sinyallerin detaylı bir şekilde görselleştirilmesini ve anlamlı özniteliklerin çıkarılmasını sağlamış, sınıflandırma performansında önemli bir artışa yol açmıştır.

Bu çalışmanın birinci uygulamasında, Ortogonal Fark Tek Boyutlu Yerel İkili Desen (OD-1D-LBP) yöntemi kullanılarak, konjestif kalp yetmezliği (KKY), aritmi (AF) ve sağlıklı bireylerin normal sinüs ritmi (NSR) durumlarına ait EKG sinyalleri analiz edilmiştir. Bu yöntemin temel avantajı, sinyalin lokal varyasyonlarını belirginleştirerek hastalıklı ve sağlıklı durumlar arasında ayırt edici öznitelikler oluşturabilmesidir. Elde edilen özniteliklerin LSTM ve 1D-CNN gibi derin öğrenme modellerine giriş olarak sunulması, %98.97 doğruluk oranına ulaşılmasını sağlamıştır. Özellikle LSTM modelinin zaman bağımlılıklarını öğrenme kapasitesi, OD-1D-LBP yönteminin performansını daha da artırmıştır. Öte yandan, 1D-CNN modelinin lokal örüntüleri öğrenme kabiliyeti de %98.86 doğruluk oranı ile başarılı sonuçlar vermiştir.

İkinci uygulamada, Merkezden Bağımsız Tek Boyutlu Yerel İkili Desen (CI-1D-LBP) yöntemi geliştirilerek dört farklı aritmi türünün (ventriküler atım, supraventriküler atım, füzyon atımı, tanımlanmamış aritmi) ve normal sinüs ritminin sınıflandırılması hedeflenmiştir. Bu yöntem, sinyalin lokal yapılarının analiz edilmesine dayanmaktadır ve

her bir sinyal için özgün histogram öznitelikleri üretmektedir. Derin öğrenme modelleri ile yapılan analizlerde, GRU modeli %98.59 doğruluk oranı ile en yüksek performansı göstermiştir. GRU'nun düşük hesaplama maliyeti ve zaman bağımlılıklarını öğrenme kapasitesi, bu yöntemin sınıflandırma başarısını artırmıştır. LSTM ve 1D-CNN modelleri de bu yöntemin güçlü öznitelik çıkarma potansiyelini desteklemiş, her iki modelde de yüksek doğruluk oranları elde edilmiştir.

Üçüncü uygulamada ise, Motif dönüşümü (MD) ve CWT yöntemleri bir arada kullanılarak zaman-frekans temelli analiz gerçekleştirilmiştir. MD, sinyaldeki tekrarlayan yapıları çıkararak, sinyalin temel örüntülerini belirginleştirmiştir. Ardından, CWT uygulanarak elde edilen skologram görüntüleri, DenseNet modelleri ile sınıflandırılmıştır. DenseNet169 modeli, %99.31 doğruluk oranı ile en başarılı sonucu vermiştir. CWT'nin tercih edilmesinin temel nedeni, sinyalin sürekli bir zaman-frekans temsiline olanak tanınması ve bu süreçte bilgi kaybının önlenmesidir. DWT'nin aksine, CWT'nin sürekli yapısı hem lokal hem de global sinyal özelliklerinin detaylı bir şekilde analiz edilmesine olanak tanımıştır. Ayrıca, CWT ile oluşturulan skologram görüntüleri, derin öğrenme modellerinin sınıflandırma performansını artırmış ve EKG sinyallerinin karmaşık yapılarının daha iyi anlaşılmasını sağlamıştır.

Çalışma boyunca kullanılan dönüşüm yöntemlerinin etkinliği, doğruluk (accuracy), duyarlılık (sensitivity), özgüllük (specificity) ve F1 skoru gibi performans ölçütleri ile değerlendirilmiştir. Özellikle, OD-1D-LBP yöntemi ile LSTM modelinin birleşimi %98.97 doğruluk oranı ile en iyi sonuçları sunarken, GRU ve DenseNet169 gibi modellerin de rekabetçi bir performans sergilediği görülmüştür. Literatürdeki benzer çalışmalarla yapılan karşılaştırmalarda, önerilen yöntemlerin üstünlüğü açıkça ortaya konulmuş, özellikle MT+CWT+DenseNet169 kombinasyonu %99.31 doğruluk oranı ile literatürdeki yöntemleri aşmıştır.

7.2 Öneriler

Bu tez çalışmasında geliştirilen yöntemlerin sunduğu avantajlar, kardiyak durumların doğru teşhis ve sınıflandırılması açısından önemli bir katkı sunmaktadır. Ancak, bu yöntemlerin daha geniş uygulama alanlarında kullanılabilmesi için çeşitli iyileştirme ve genişletme önerileri bulunmaktadır. Öncelikle, geliştirilen yöntemlerin gerçek zamanlı uygulamalara entegrasyonu yapılmalıdır. Mobil cihazlar veya giyilebilir

teknolojilerde kullanılmak üzere optimize edilen bu modeller, hasta izlemi ve erken teşhis süreçlerini iyileştirebilir.

Gelecekteki çalışmalar için önerilen bir diğer alan, daha geniş ve çeşitli veri setlerinin kullanılmasıdır. Farklı demografik gruplar ve klinik durumlar için genişletilmiş veri setleri ile modellerin genelleştirilebilirliği artırılabilir. Ayrıca, farklı sinyal işleme yöntemleri (örneğin, Fourier veya Hilbert dönüşümleri) ile mevcut yöntemlerin entegrasyonu değerlendirilebilir. Bu tür hibrit yaklaşımlar, öznetelik çıkarımını daha kapsamlı hale getirebilir.

Derin öğrenme modellerinin çeşitlendirilmesi de önemli bir gelişim alanıdır. Özellikle sinyal dönüşümü tabanlı modellerin zaman serisi analizindeki başarısı göz önüne alındığında, bu tür modellerin EKG sinyalleri üzerinde uygulanabilirliği araştırılabilir. Transfer öğrenme yaklaşımlarıyla mevcut modellerin performansı daha da artırılabilir. Ek olarak, klinik uygulamalar için model kararlılığı ve güvenilirliğinin detaylı bir şekilde test edilmesi önemlidir.

Bu çalışmada kullanılan OD-1D-LBP ve CI-1D-LBP yöntemleri, EKG sinyallerindeki lokal ve global örüntüleri belirginleştirerek başarılı sonuçlar elde etmiştir ve bu yaklaşımların diğer biyomedikal sinyallere uygulanabilirliği de değerlendirilmeye açıktır. Özellikle EEG ve EMG gibi zaman serisi sinyallerinde, OD-1D-LBP yöntemi, lokal varyasyonların analiz edilmesinde etkili olabilir. EEG sinyallerinde epileptik nöbetlerin tespiti veya EMG sinyallerinde kas aktivitelerinin ayrıştırılmasında, bu yöntemin ayırt edici öznetelik çıkarma kapasitesi, sinyallerin detaylı bir şekilde analiz edilmesini sağlayabilir.

CI-1D-LBP yöntemi ise, sinyallerdeki tekrarlayan yapıları dokuz referans noktası üzerinden analiz ederek, lokal değişimlerin daha hassas bir şekilde yakalanmasını sağlamaktadır. Bu özellik, EMG sinyallerinde ince motor hareketlerinin veya EEG sinyallerinde uyku evrelerinin sınıflandırılmasında kullanılabilir. Özellikle sinyallerin lokal dinamiklerinin önemli olduğu durumlarda, bu yöntemler yüksek doğruluk oranları ve sınıflandırma başarısı sunabilir.

DenseNet, LSTM ve GRU gibi derin öğrenme modelleriyle entegre edilen bu yöntemlerin başarısı, farklı biyomedikal sinyaller için genelleştirilebilir bir çerçeve sunmaktadır. Örneğin, PPG sinyallerinde oksijen doygunluğu veya kan basıncı tahmininde OD-1D-LBP ve CI-1D-LBP yöntemleri, lokal ve global sinyal özelliklerinin etkili bir şekilde çıkarılmasını sağlayabilir. Ayrıca, EGG gibi sindirim sistemine ait

sinyallerde, bu yöntemler anormal motilite örüntülerinin hassas bir şekilde tespit edilmesine olanak tanıyabilir.

Gelecekteki çalışmalar, OD-1D-LBP ve CI-1D-LBP yöntemlerinin farklı biyomedikal sinyaller üzerindeki etkilerini değerlendirmeye odaklanabilir. Bu yöntemlerin sinyal türüne özgü modifikasyonlarla optimize edilmesi ve geniş veri setleriyle test edilmesi hem sınıflandırma başarısını artırabilir hem de klinik uygulamalarda kullanılabilirliğini destekleyebilir. Özellikle, bu yöntemlerin gerçek zamanlı analiz sistemlerine entegre edilmesi, biyomedikal sinyal işleme alanında yeni standartların belirlenmesine katkı sağlayabilir.

Tek boyutlu zaman serisi verilerinin iki boyutlu algoritmaların sağladığı avantajlarla işlenmesi, EEG, EMG ve EGG gibi diğer biyomedikal sinyallerin zaman-frekans analizinde de etkili bir yöntem olabilir. Örneğin, CWT'nin sürekli analiz kapasitesi, EEG sinyallerinde epileptik nöbetlerin veya EMG sinyallerinde kas aktivitesindeki anormalliklerin hassas bir şekilde tespiti için kullanılabilir. Bu çalışmada sunulan Motif dönüşümü (MD) ile bu sinyallerin tekrarlayan yapıları belirginleştirilerek, daha yüksek ayırt edicilik sağlanabilir.

Sonuç olarak, bu tez çalışmasında geliştirilen yöntemler, kardiyak durumların teşhisinde yenilikçi ve etkili bir çerçeve sunmaktadır. Çalışmanın bulguları, literatürdeki yöntemlerle karşılaştırıldığında daha yüksek doğruluk oranlarına ulaşmış ve sinyal analizine yönelik yeni bir perspektif getirmiştir. Bu yöntemlerin klinik uygulamalarda ve diğer sağlık alanlarında kullanılabilirliğini artırmak, gelecekte yapılacak araştırmalar için önemli bir yol haritası sunmaktadır.

KAYNAKLAR

- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adam, M., Gertych, A., & Tan, R. S. (2017). A deep convolutional neural network model to classify heartbeats. *Computers in Biology and Medicine*, 89, 389–396. <https://doi.org/10.1016/J.COMPBIOMED.2017.08.022>
- Afzal, M. (2021). Recent updates on novel therapeutic targets of cardiovascular diseases. *Molecular and Cellular Biochemistry*, 476(1), 145–155. <https://doi.org/10.1007/S11010-020-03891-8>
- Akdag, S., Kuncan, F., & Kaya, Y. (2022). A new approach for congestive heart failure and arrhythmia classification using downsampling local binary patterns with LSTM. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30(6), 2145–2164. <https://doi.org/10.55730/1300-0632.3930>
- Alboni, A. (2012). *Intraventricular conduction disturbances*. [https://books.google.com/books?hl=tr&lr=&id=Wy37CAAAQBAJ&oi=fnd&pg=PA1&dq=Alboni,+A.+\(2012\).+Intraventricular+conduction+disturbances+\(Vol.+12\).+Springer+Science+%26+Business+Media.&ots=RUmY1NbSlp&sig=69GEss6WxkFP42vknjP0RP5I6zY](https://books.google.com/books?hl=tr&lr=&id=Wy37CAAAQBAJ&oi=fnd&pg=PA1&dq=Alboni,+A.+(2012).+Intraventricular+conduction+disturbances+(Vol.+12).+Springer+Science+%26+Business+Media.&ots=RUmY1NbSlp&sig=69GEss6WxkFP42vknjP0RP5I6zY)
- Ali, Z. S., Bhuiyan, A., Vyas, P., Miranda-Arboleda, A. F., Tse, G., Bazoukis, G., Burak, C., Abuzeid, W., Lee, S., Gupta, S., Meghdadi, A., & Baranchuk, A. (2024). PR prolongation as a predictor of atrial fibrillation onset: A state-of-the-art review. *Current Problems in Cardiology*, 49(4), 102469. <https://doi.org/10.1016/J.CPCARDIOL.2024.102469>
- Althelaya, K. A., El-Alfy, E.-S. M., & Mohammed, S. (2018). Stock market forecast using multivariate analysis with bidirectional and stacked (LSTM, GRU). *2018 21st Saudi Computer Society National Computer Conference (NCC)*, 1–7.
- Alwan, Y., Cvetkovic, Z., & Curtis, M. J. (2018). Methods for improved discrimination between ventricular fibrillation and tachycardia. *IEEE Transactions on Biomedical Engineering*, 65(10), 2143–2151. <https://doi.org/10.1109/TBME.2017.2785442>
- Antman, E. M., Anbe, D. T., Armstrong, P. W., Bates, E. R., Green, L. A., Hand, M., Hochman, J. S., Krumholz, H. M., Kushner, F. G., Lamas, G. A., Mullany, C. J., Ornato, J. P., Pearle, D. L., Sloan, M. A., Smith, S. C., Alpert, J. S., Anderson, J. L., Faxon, D. P., Fuster, V., ... Ornato, J. P. (2004). ACC/AHA Guidelines for the Management of Patients With ST-Elevation Myocardial Infarction: A Report of the American College of Cardiology/American Heart Association Task Force on Practice Guidelines (Committee to Revise the 1999 Guidelines for the Management of Patients With Acute Myocardial Infarction). *Journal of the American College of Cardiology*, 44(3), E1–E211. <https://doi.org/10.1016/J.JACC.2004.07.014>
- Anttonen, O., Junttila, J., Giustetto, C., Gaita, F., Linna, E., Karsikas, M., Seppänen, T., Perkiömäki, J. S., Mäkilä, T. H., Brugada, R., & Huikuri, H. V. (2009). T-Wave morphology in short QT syndrome. *Annals of Noninvasive Electrophysiology*, 14(3), 262–267. <https://doi.org/10.1111/J.1542-474X.2009.00308.X>

- Bacharova, L. (2022). ECG in left ventricular hypertrophy: A change in paradigm from assessing left ventricular mass to its electrophysiological properties. *Journal of Electrocardiology*, 73, 153–156. <https://doi.org/10.1016/J.JELECTROCARD.2022.06.002>
- Baim, D. S., Colucci, W. S., Monrad, E. S., Smith, H. S., Wright, R. F., Lanoue, A., Gauthier, D. F., Ransil, B. J., Grossman, W., & Braunwald, E. (1986). Survival of patients with severe congestive heart failure treated with oral milrinone. *Journal of the American College of Cardiology*, 7(3), 661–670.
- Bakshi, T. K., Choo, M. K. F., Edwards, C. C., Scott, A. G., Hart, H. H., & Armstrong, G. P. (2002). Causes of elevated troponin I with a normal coronary angiogram. *Internal Medicine Journal*, 32(11), 520–525. <https://doi.org/10.1046/J.1445-5994.2002.00270.X>
- Bansal, A., & Joshi, R. (2018). Portable out-of-hospital electrocardiography: A review of current technologies. *Journal of Arrhythmia*, 34(2), 129–138. <https://doi.org/10.1002/JOA3.12035>
- Beca, S., Helli, P. B., Simpson, J. A., Zhao, D., Farman, G. P., Jones, P. P., Tian, X., Wilson, L. S., Ahmad, F., Chen, S. R. W., Movsesian, M. A., Manganiello, V., Maurice, D. H., Conti, M., & Backx, P. H. (2011). Phosphodiesterase 4D regulates baseline sarcoplasmic reticulum Ca²⁺ release and cardiac contractility, independently of L-type Ca²⁺ current. *Circulation Research*, 109(9), 1024–1030. <https://doi.org/10.1161/CIRCRESAHA.111.250464>
- Benitah, J. P., Alvarez, J. L., & Gómez, A. M. (2010). L-type Ca²⁺ current in ventricular cardiomyocytes. *Journal of Molecular and Cellular Cardiology*, 48(1), 26–36. <https://doi.org/10.1016/J.YJMCC.2009.07.026>
- Benjamin, E. J., Muntner, P., Alonso, A., Bittencourt, M. S., Callaway, C. W., Carson, A. P., Chamberlain, A. M., Chang, A. R., Cheng, S., Das, S. R., Delling, F. N., Djousse, L., Elkind, M. S. V., Ferguson, J. F., Fornage, M., Jordan, L. C., Khan, S. S., Kissela, B. M., Knutson, K. L., ... Virani, S. S. (2019). Heart Disease and Stroke Statistics-2019 Update: A Report From the American Heart Association. *Circulation*, 139(10), e56–e528. <https://doi.org/10.1161/CIR.0000000000000659>
- Bhardwaj, A., & Sivaraman, J. (2021). Study of P wave indices in sinus rhythm and tachycardia. *Proceedings of 2021 IEEE 7th International Conference on Bio Signals, Images and Instrumentation, ICBSII 2021*. <https://doi.org/10.1109/ICBSII51839.2021.9445148>
- Bhatia, M., Kumar, M., Dixit, P., Reports, L. D.-P. M., & 2022, undefined. (n.d.). Missed opportunities for initiation of treatment and control of hypertension among older adults in India. *ElsevierM Bhatia, M Kumar, P Dixit, LK DwivediPreventive Medicine Reports, 2022•Elsevier*. Retrieved November 19, 2024, from <https://www.sciencedirect.com/science/article/pii/S2211335522003643>
- Bian, W., Wang, J., Zhuang, B., Yang, J., Wang, S., & Xiao, J. (2019). Audio-based music classification with DenseNet and data augmentation. *PRICAI 2019: Trends in*

- Artificial Intelligence: 16th Pacific Rim International Conference on Artificial Intelligence, Cuvu, Yanuca Island, Fiji, August 26-30, 2019, Proceedings, Part III* 16, 56–65.
- Björck, S., Palaszewski, B., Friberg, L., & Bergfeldt, L. (2013). Atrial fibrillation, stroke risk, and warfarin therapy revisited: A population-based study. *Stroke*, 44(11), 3103–3108. <https://doi.org/10.1161/STROKEAHA.113.002329/-/DC1>
- Borlaug, B. A., & Kass, D. A. (2006). Mechanisms of Diastolic Dysfunction in Heart Failure. *Trends in Cardiovascular Medicine*, 16(8), 273–279. <https://doi.org/10.1016/J.TCM.2006.05.003>
- Bryant, A. R., Wilton, S. B., Lai, M. P., & Exner, D. V. (2013). Association between QRS duration and outcome with cardiac resynchronization therapy: A systematic review and meta-analysis. *Journal of Electrocardiology*, 46(2), 147–155. <https://doi.org/10.1016/J.JELECTROCARD.2012.12.003>
- Burch, G., & DePasquale, N. (1990). *A history of electrocardiography*. [https://books.google.com/books?hl=tr&lr=&id=_w9v_ZkzTZoC&oi=fnd&pg=PA56&dq=Burch,+G.+E.,+%26+DePasquale,+N.+P.+\(1990\).+A+history+of+electrocardiography+\(No.+1\).+Norman+Publishing.&ots=9qCbRJRG8y&sig=f0P_HkOevREBszlflIIXLeVz-Fio](https://books.google.com/books?hl=tr&lr=&id=_w9v_ZkzTZoC&oi=fnd&pg=PA56&dq=Burch,+G.+E.,+%26+DePasquale,+N.+P.+(1990).+A+history+of+electrocardiography+(No.+1).+Norman+Publishing.&ots=9qCbRJRG8y&sig=f0P_HkOevREBszlflIIXLeVz-Fio)
- Byeon, Y.-H., Pan, S.-B., & Kwak, K.-C. (2020). Ensemble deep learning models for ECG-based biometrics. *2020 Cybernetics & Informatics (K&I)*, 1–5.
- Cardiovascular diseases (CVDs)*. (n.d.). Retrieved November 19, 2024, from [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- Chauhan, T., Palivela, H., & Tiwari, S. (2021). Optimization and fine-tuning of DenseNet model for classification of COVID-19 cases in medical imaging. *International Journal of Information Management Data Insights*, 1(2), 100020.
- Chen, B., Zhao, T., Liu, J., & Lin, L. (2021). Multipath feature recalibration DenseNet for image classification. *International Journal of Machine Learning and Cybernetics*, 12, 651–660.
- Chi, D. J., & Chu, C. C. (2021). Artificial Intelligence in Corporate Sustainability: Using LSTM and GRU for Going Concern Prediction. *Sustainability* 2021, Vol. 13, Page 11631, 13(21), 11631. <https://doi.org/10.3390/SU132111631>
- Chlaihawi, A., Narakathu, B., ... S. E.-S. and bio, & 2018, undefined. (n.d.). Development of printed and flexible dry ECG electrodes. *ElsevierAA Chlaihawi, BB Narakathu, S Emamian, BJ Bazuin, MZ AtashbarSensing and Bio-Sensing Research, 2018•Elsevier*. Retrieved November 19, 2024, from <https://www.sciencedirect.com/science/article/pii/S2214180418300254>
- Chopra, S., & Marfurt, K. J. (2015). *Choice of Mother Wavelets in CWT Spectral Decomposition*. OnePetro. <https://dx.doi.org/>

- Clifford, G., Azuaje, F., & McSharry, P. (2006). *Advanced methods and tools for ECG data analysis*. <https://www.academia.edu/download/100365540/518921182cliff.pdf>
- Cossu, S. F., & Steinberg, J. S. (1998). Supraventricular tachyarrhythmias involving the sinus node: Clinical and electrophysiologic characteristics. *Progress in Cardiovascular Diseases*, 41(1), 51–63. [https://doi.org/10.1016/S0033-0620\(98\)80022-4](https://doi.org/10.1016/S0033-0620(98)80022-4)
- Couceiro, R., Carvalho, P., Henriques, J., & Antunes, M. (2008). On the detection of Premature Ventricular Contractions. *Proceedings of the 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS'08 - "Personalized Healthcare through Technology,"* 1087–1091. <https://doi.org/10.1109/IEMBS.2008.4649349>
- Deo, R. C. (2015). Machine learning in medicine. *Circulation*, 132(20), 1920–1930. <https://doi.org/10.1161/CIRCULATIONAHA.115.001593>
- Dharmarajan, K., & Rich, M. W. (2017). Epidemiology, Pathophysiology, and Prognosis of Heart Failure in Older Adults. *Heart Failure Clinics*, 13(3), 417–426. <https://doi.org/10.1016/J.HFC.2017.02.001/ASSET/36F0AB4A-E255-4C0B-B702-ECD5F1E32E32/MAIN.ASSETS/GR6.SML>
- Di Diego, J. M., & Antzelevitch, C. (2014). Acute myocardial ischemia: Cellular mechanisms underlying ST segment elevation. *Journal of Electrocardiology*, 47(4), 486–490. <https://doi.org/10.1016/J.JELECTROCARD.2014.02.005>
- Dresen, W. F., & Ferguson, J. D. (2018). Ventricular Arrhythmias. *Cardiology Clinics*, 36(1), 129–139. <https://doi.org/10.1016/j.ccl.2017.08.007>
- Duncker, D., Ding, W., Etheridge, S., Sensors, P. N.-, & 2021, undefined. (n.d.). Smart wearables for cardiac monitoring—real-world use beyond atrial fibrillation. *Mdpi.ComD Duncker, WY Ding, S Etheridge, PA Noseworthy, C Veltmann, X Yao, TJ Bunch, D GuptaSensors, 2021•mdpi.Com*. Retrieved November 19, 2024, from <https://www.mdpi.com/1424-8220/21/7/2539>
- El-Sherif, N., & Turitto, G. (2011). Electrolyte disorders and arrhythmogenesis. *Cardiology Journal*, 18(3), 233–245. https://journals.viamedica.pl/cardiology_journal/article/view/21240
- Eltrass, A. S., Tayel, M. B., & Ammar, A. I. (2021). A new automated CNN deep learning approach for identification of ECG congestive heart failure and arrhythmia using constant-Q non-stationary Gabor transform. *Biomedical Signal Processing and Control*, 65, 102326.
- Eren, L., Ince, T., & Kiranyaz, S. (2019). A generic intelligent bearing fault diagnosis system using compact adaptive 1D CNN classifier. *Journal of Signal Processing Systems*, 91, 179–189.
- Erkol, Ü., Mecmuası, İ. A.-A. Ü. T. F., & 2011, undefined. (n.d.). Hastanelerde maliyet analizi ve faaliyet tabanlı maliyetleme. *Dergipark.Org.TrÜ Erkol, İ AğırbaşAnkara*

Üniversitesi Tıp Fakültesi Mecmuası, 2011•*dergipark.Org.Tr*. Retrieved November 19, 2024, from <https://dergipark.org.tr/en/download/article-file/38657>

- Ezzat, A., Omer, O. A., Mohamed, U. S., & Mubarak, A. S. (2024). ECG signal reconstruction from PPG using a hybrid attention-based deep learning network. *EURASIP Journal on Advances in Signal Processing* 2024 2024:1, 2024(1), 1–18. <https://doi.org/10.1186/S13634-024-01158-8>
- Friberg, L., & Bergfeldt, L. (2013). Atrial fibrillation prevalence revisited. *Journal of Internal Medicine*, 274(5), 461–468. <https://doi.org/10.1111/JOIM.12114>
- Gala, D., Behl, H., Shah, M., Healthcare, A. M.-, & 2024, undefined. (n.d.). The role of artificial intelligence in improving patient outcomes and future of healthcare delivery in cardiology: a narrative review of the literature. *Mdpi.ComD Gala, H Behl, M Shah, AN MakaryusHealthcare*, 2024•*mdpi.Com*. Retrieved November 19, 2024, from <https://www.mdpi.com/2227-9032/12/4/481>
- Galderisi, M. (2005). Diastolic dysfunction and diastolic heart failure: Diagnostic, prognostic and therapeutic aspects. *Cardiovascular Ultrasound*, 3. <https://doi.org/10.1186/1476-7120-3-9>
- Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C. K., & Stanley, H. E. (2000a). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, 101(23). <https://doi.org/10.1161/01.CIR.101.23.E215>
- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K., & Stanley, H. E. (2000b). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, 101(23), e215–e220.
- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K., & Stanley, H. E. (2000c). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, 101(23), e215–e220.
- Greff, K., Srivastava, R. K., Koutnik, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222–2232. <https://doi.org/10.1109/TNNLS.2016.2582924>
- Gruebl, T., Ploeger, B., Wranze-Bielefeld, E., Mueller, M., Schmidbauer, W., Kill, C., & Betz, S. (2021). Point-of-care testing in out-of-hospital cardiac arrest: a retrospective analysis of relevance and consequences. *Scandinavian Journal of Trauma, Resuscitation and Emergency Medicine*, 29(1). <https://doi.org/10.1186/S13049-021-00943-W>
- Guo, W., Xu, Z., & Zhang, H. (2019). Interstitial lung disease classification using improved DenseNet. *Multimedia Tools and Applications*, 78, 30615–30626.

- Hannun, A. Y., Rajpurkar, P., Haghpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P., & Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine* 2019 25:1, 25(1), 65–69. <https://doi.org/10.1038/s41591-018-0268-3>
- HELTON, M. R. (2015). Diagnosis and Management of Common Types of Supraventricular Tachycardia. *American Family Physician*, 92(9), 793–802. <https://www.aafp.org/pubs/afp/issues/2015/1101/p793.html>
- Hlaing, T., DiMino, T., Kowey, P. R., & Yan, G. X. (2005). ECG repolarization waves: Their genesis and clinical implications. *Annals of Noninvasive Electrocardiology*, 10(2), 211–223. <https://doi.org/10.1111/J.1542-474X.2005.05588.X>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/NECO.1997.9.8.1735>
- Hsieh, T.-H., & Kiang, J.-F. (2020). Comparison of CNN algorithms on hyperspectral image classification in agricultural lands. *Sensors*, 20(6), 1734.
- Hu, X., Yuan, S., Xu, F., Leng, Y., Yuan, K., & Yuan, Q. (2020). Scalp EEG classification using deep Bi-LSTM network for seizure detection. *Computers in Biology and Medicine*, 124, 103919.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4700–4708.
- Hurst, J. W. (1998). Naming of the waves in the ECG, with a brief account of their genesis. *Circulation*, 98(18), 1937–1942. <https://doi.org/10.1161/01.CIR.98.18.1937>
- Jahmunah, V., Oh, S. L., Wei, J. K. E., Ciaccio, E. J., Chua, K., San, T. R., & Acharya, U. R. (2019). Computer-aided diagnosis of congestive heart failure using ECG signals – A review. *Physica Medica*, 62, 95–104. <https://doi.org/10.1016/J.EJMP.2019.05.004>
- John, R. M., & Kumar, S. (2016). Sinus node and atrial arrhythmias. *Circulation*, 133(19), 1892–1900. <https://doi.org/10.1161/CIRCULATIONAHA.116.018011>
- Joukar, S. (2021). A comparative review on heart ion channels, action potentials and electrocardiogram in rodents and human: extrapolation of experimental insights to clinic. *Laboratory Animal Research*, 37(1). <https://doi.org/10.1186/S42826-021-00102-3>
- Kaouter, K., Mohamed, T., Sofiene, D., Abbas, D., & Fouad, M. (2019). Full training convolutional neural network for ECG signals classification. *AIP Conference Proceedings*, 2190(1), 020055.
- Kashani, A., & Barold, S. S. (2005). Significance of QRS complex duration in patients with heart failure. *Journal of the American College of Cardiology*, 46(12), 2183–2192. <https://doi.org/10.1016/J.JACC.2005.01.071>

- Kashou, A., Basit, H., & Chhabra, L. (2017). *Physiology, sinoatrial node*. <https://europepmc.org/article/nbk/nbk459238>
- Katrtsis, D. G., & Becker, A. (2007). The atrioventricular nodal reentrant tachycardia circuit: A proposal. *Heart Rhythm*, 4(10), 1354–1360. <https://doi.org/10.1016/J.HRTHM.2007.05.026>
- Kaya, Y., & Ertuğrul, Ö. F. (2019). Estimation of neurological status from non-electroencephalography bio-signals by motif patterns. *Applied Soft Computing*, 83, 105609.
- Kaya, Y., Kuncan, F., & Tekin, R. (2022). A New Approach for Congestive Heart Failure and Arrhythmia Classification Using Angle Transformation with LSTM. *Arabian Journal for Science and Engineering*, 47(8), 10497–10513. <https://doi.org/10.1007/S13369-022-06617-8>
- Keller, S. P., & Halperin, H. R. (2015). Cardiac Arrest: the Changing Incidence of Ventricular Fibrillation. *Current Treatment Options in Cardiovascular Medicine*, 17(7). <https://doi.org/10.1007/S11936-015-0392-Z>
- Kingsbury, N., & Magarey, J. (1998). *Wavelet Transforms in Image Processing*. 27–46. https://doi.org/10.1007/978-1-4612-1768-8_2
- Kiranyaz, S., Ince, T., & Gabbouj, M. (2016). Real-Time Patient-Specific ECG Classification by 1-D Convolutional Neural Networks. *IEEE Transactions on Biomedical Engineering*, 63(3), 664–675. <https://doi.org/10.1109/TBME.2015.2468589>
- Klabunde, R. E. (2017). Cardiac electrophysiology: Normal and ischemic ionic currents and the ECG. *Advances in Physiology Education*, 41(1), 29–37. <https://doi.org/10.1152/ADVAN.00105.2016/ASSET/IMAGES/LARGE/ZU10011730740016.JPEG>
- Koplan, B. A., & Stevenson, W. G. (2009). Ventricular Tachycardia and Sudden Cardiac Death. *Mayo Clinic Proceedings*, 84(3), 289–297. <https://doi.org/10.4065/84.3.289>
- Koshy, A. O., Gallivan, E. R., McGinlay, M., Straw, S., Drozd, M., Toms, A. G., Gierula, J., Cubbon, R. M., Kearney, M. T., & Witte, K. K. (2020). Prioritizing symptom management in the treatment of chronic heart failure. *ESC Heart Failure*, 7(5), 2193–2207. <https://doi.org/10.1002/EHF2.12875>
- Kucia, A. M. (2022). Arrhythmias. *Cardiac Care: A Practical Guide for Nurses*, 139–172. <https://doi.org/10.1002/9781119117810.CH11>
- Kumar, A., & Lloyd-Jones, D. M. (2007). Clinical significance of minor nonspecific ST-segment and T-wave abnormalities in asymptomatic subjects: A systematic review. *Cardiology in Review*, 15(3), 133–142. <https://doi.org/10.1097/01.CRD.0000249382.65955.14>

- Kutlu, Y., & Kuntalp, D. (2012). Feature extraction for ECG heartbeats using higher order statistics of WPD coefficients. *Computer Methods and Programs in Biomedicine*, 105(3), 257–267. <https://doi.org/10.1016/J.CMPB.2011.10.002>
- Landi, F., Baraldi, L., Cornia, M., & Cucchiara, R. (2021). Working memory connections for LSTM. *Neural Networks*, 144, 334–341.
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/NATURE14539>
- Lee, W. K., Ratnam, M. M., & Ahmad, Z. A. (2017). Detection of chipping in ceramic cutting inserts from workpiece profile during turning using fast Fourier transform (FFT) and continuous wavelet transform (CWT). *Precision Engineering*, 47, 406–423.
- Lei, M., Wu, L., Terrar, D. A., & Huang, C. L. H. (2018). Modernized classification of cardiac antiarrhythmic drugs. *Circulation*, 138(17), 1879–1896. <https://doi.org/10.1161/CIRCULATIONAHA.118.035455>
- Liang, F., & Wang, Y. (2021). Coronary heart disease and atrial fibrillation: A vicious cycle. *American Journal of Physiology - Heart and Circulatory Physiology*, 320(1). <https://doi.org/10.1152/AJPHEART.00702.2020>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88. <https://doi.org/10.1016/J.MEDIA.2017.07.005>
- Lo, R., & Hsia, H. H. (2008). Ventricular Arrhythmias in Heart Failure Patients. *Cardiology Clinics*, 26(3), 381–403. <https://doi.org/10.1016/J.CCL.2008.03.009>
- Lotfollahi-Yaghin, M. A., & Koohdaragh, M. (2011). Examining the function of wavelet packet transform (WPT) and continues wavelet transform (CWT) in recognizing the crack specification. *KSCE Journal of Civil Engineering*, 15(3), 497–506. <https://doi.org/10.1007/S12205-011-0925-2/METRICS>
- Lynn, H. M., Pan, S. B., & Kim, P. (2019). A deep bidirectional GRU network model for biometric electrocardiogram classification based on recurrent neural networks. *IEEE Access*, 7, 145395–145405.
- Madan, P., Singh, V., Singh, D. P., Diwakar, M., Pant, B., & Kishor, A. (2022). A hybrid deep learning approach for ECG-based arrhythmia classification. *Bioengineering*, 9(4), 152.
- Malik, M., & Batchvarov, V. N. (2000). Measurement, interpretation and clinical potential of QT dispersion. *Journal of the American College of Cardiology*, 36(6), 1749–1766. [https://doi.org/10.1016/S0735-1097\(00\)00962-1](https://doi.org/10.1016/S0735-1097(00)00962-1)
- Malik, M., & Camm, A. J. (2001). Evaluation of drug-induced QT interval prolongation: Implications for drug approval and labelling. *Drug Safety*, 24(5), 323–351. <https://doi.org/10.2165/00002018-200124050-00001>

- Mateo, C., & Talavera, J. A. (2020). Bridging the gap between the short-time Fourier transform (STFT), wavelets, the constant-Q transform and multi-resolution STFT. *Signal, Image and Video Processing*, 14(8), 1535–1543.
- Miranda, C., Taqatqa, A., Sosnowski, C., Alsaleh, L., & Abdulla, R. I. (2016). Cellular electrophysiology and electrocardiography. *Pediatric Electrocadiography: An Algorithmic Approach to Interpretation*, 13–18. https://doi.org/10.1007/978-3-319-26258-1_2
- Mirvis, D., disease, A. G.-H., & 2001, undefined. (n.d.). Electrocardiography. *Doctor33.ItDM Mirvis, AL GoldbergerHeart Disease, 2001•doctor33.It*. Retrieved November 19, 2024, from <https://www.doctor33.it/cont/download-center-files/17519/cap-electrocardiography-x20968allp1.pdf>
- Mittal, S. (2023). The P Wave and the PR Segment. *Insights into Electrocardiograms with MCQs*, 27–43. https://doi.org/10.1007/978-981-99-0127-2_3
- Mohebbanaaz, Kumari, L. V. R., & Sai, Y. P. (2022). Classification of ECG beats using optimized decision tree and adaptive boosted optimized decision tree. *Signal, Image and Video Processing*, 16(3), 695–703. <https://doi.org/10.1007/S11760-021-02009-X>
- Moody, G. B., & Mark, R. G. (2001). The impact of the MIT-BIH arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3), 45–50.
- Nabar, A., Rodriguez, L. M., Timmermans, C., Kattenbeck, K., & Wellens, H. J. (2000). Capture and fusion beats during atrial fibrillation and ventricular tachycardia. *Heart*, 84(1), e1–e1. <https://doi.org/10.1136/HEART.84.1.E1>
- Nanni, L., Lumini, A., & Brahnam, S. (2010). Local binary patterns variants as texture descriptors for medical image analysis. *Artificial Intelligence in Medicine*, 49(2), 117–125. <https://doi.org/10.1016/J.ARTMED.2010.02.006>
- Narin, A. (2022). Detection of focal and non-focal epileptic seizure using continuous wavelet transform-based scalogram images and pre-trained deep neural networks. *Irbm*, 43(1), 22–31.
- Nerbonne, J. M., & Kass, R. S. (2005). Molecular physiology of cardiac repolarization. *Physiological Reviews*, 85(4), 1205–1253. <https://doi.org/10.1152/PHYSREV.00002.2005>
- Nlker, G., Gutleben, K. J., Asbach, S., Ritscher, G., Marschang, H., Sinha, A. M., Boileau, P., Benser, M. E., Hallier, B., Hmmer, A., & Brachmann, J. (2011). Dynamic ventricular overdrive stimulation in atrial fibrillation: effects on ventricular rate irregularity, ventricular pacing, and fusion beats. *EP Europace*, 13(12), 1688–1694. <https://doi.org/10.1093/EUROPACE/EUR243>

- Ojala, T., Pietikäinen, M., & Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29(1), 51–59. [https://doi.org/10.1016/0031-3203\(95\)00067-4](https://doi.org/10.1016/0031-3203(95)00067-4)
- Parikh, M. G. (2022). Fundamentals of Electrophysiology: Basic Science and Ion Channels. *Cardiac Electrophysiology*, 1–25. https://doi.org/10.1007/978-3-030-75326-9_1
- Patil, S., Gandhi, S., Prajapati, P., ... S. A.-I. J. of, & 2016, undefined. (n.d.). A study of electrolyte imbalance in acute myocardial infarction patients at a tertiary care hospital in western Maharashtra. *Academia.EduS Patil, S Gandhi, P Prajapati, S Afzalpurkar, O Patil, M KhatriInternational Journal of Contemporary Medical Research*, 2016•academia.Edu. Retrieved November 19, 2024, from https://www.academia.edu/download/104887652/ijcmr_1155_jan_18.pdf
- Peretto, G., Durante, A., Limite, L. R., & Cianflone, D. (2014). Postoperative arrhythmias after cardiac surgery: Incidence, risk factors, and therapeutic management. *Cardiology Research and Practice*, 2014. <https://doi.org/10.1155/2014/615987>
- Pfob, A., Lu, S. C., & Sidey-Gibbons, C. (2022). Machine learning in medicine: a practical introduction to techniques for data pre-processing, hyperparameter tuning, and model comparison. *BMC Medical Research Methodology*, 22(1), 1–15. <https://doi.org/10.1186/S12874-022-01758-8/FIGURES/6>
- Plappert, F., Engström, G., Platonov, P. G., Wallman, M., & Sandberg, F. (2024). ECG-based estimation of respiration-induced autonomic modulation of AV nodal conduction during atrial fibrillation. *Frontiers in Physiology*, 15. <https://doi.org/10.3389/FPHYS.2024.1281343/FULL>
- Platonov, P. G. (2012). P-Wave Morphology: Underlying Mechanisms and Clinical Implications. *Annals of Noninvasive Electrocardiology*, 17(3), 161–169. <https://doi.org/10.1111/J.1542-474X.2012.00534.X>
- Podder, P., Hasan, Md. M., Islam, Md. R., & Sayeed, M. (2020). *Design and Implementation of Butterworth, Chebyshev-I and Elliptic Filter for Speech Signal Analysis*. <https://doi.org/10.5120/17195-7390>
- Porthan, K., Viitasalo, M., Jula, A., Reunanen, A., Rapola, J., Väänänen, H., Nieminen, M. S., Toivonen, L., Salomaa, V., & Oikarinen, L. (2009). Predictive value of electrocardiographic QT interval and T-wave morphology parameters for all-cause and cardiovascular mortality in a general population sample. *Heart Rhythm*, 6(8), 1202–1208.e1. <https://doi.org/10.1016/J.HRTHM.2009.05.006>
- Quin, E. M., Wharton, J. M., & Gold, M. R. (2011). Bradyarrhythmias. *Management of Cardiac Arrhythmias*, 305–319. https://doi.org/10.1007/978-1-60761-161-5_14
- Rafie, N., Kashou, A. H., & Noseworthy, P. A. (2021). ECG Interpretation: Clinical Relevance, Challenges, and Advances. *Hearts 2021, Vol. 2, Pages 505-513*, 2(4), 505–513. <https://doi.org/10.3390/HEARTS2040039>

- Rafie, N., Kashou, A., Hearts, P. N., & 2021, undefined. (n.d.). ECG interpretation: clinical relevance, challenges, and advances. *Mdpi.Com* Rafie, AH Kashou, PA NoseworthyHearts, 2021•mdpi.Com. Retrieved November 19, 2024, from <https://www.mdpi.com/2673-3846/2/4/39>
- Rahman, Ö. F., & Özkısacık, E. A. (2024). Patency and Survival in Patients Undergoing Revascularization for Peripheral Arterial Disease. *Value in Health Sciences*, 14(2), 215–223. <https://doi.org/10.33631/SABD.1401456>
- Rajpurkar, P., Hannun, A. Y., Haghpanahi, M., Bourn, C., & Ng, A. Y. (2017). *Cardiologist-Level Arrhythmia Detection with Convolutional Neural Networks*. <http://arxiv.org/abs/1707.01836>
- Ramani, G. V., Uber, P. A., & Mehra, M. R. (2010). Chronic Heart Failure: Contemporary Diagnosis and Management. *Mayo Clinic Proceedings*, 85(2), 180–195. <https://doi.org/10.4065/MCP.2009.0494>
- Roberts-Thomson, K. C., Kistler, P. M., & Kalman, J. M. (2005). Atrial Tachycardia: Mechanisms, Diagnosis, and Management. *Current Problems in Cardiology*, 30(10), 529–573. <https://doi.org/10.1016/J.CPCARDIOL.2005.06.004>
- Rosiak, M., Bolinska, H., & Ruta, J. (2002). P wave dispersion and P wave duration on SAEKG in predicting atrial fibrillation in patients with acute myocardial infarction. *Annals of Noninvasive Electrocardiology*, 7(4), 363–368. <https://doi.org/10.1111/J.1542-474X.2002.TB00186.X>
- Sagris, M., Vardas, E. P., Theofilis, P., Antonopoulos, A. S., Oikonomou, E., & Tousoulis, D. (2021). Atrial Fibrillation: Pathogenesis, Predisposing Factors, and Genetics. *International Journal of Molecular Sciences* 2022, Vol. 23, Page 6, 23(1), 6. <https://doi.org/10.3390/IJMS23010006>
- Sahoo, S., Dash, M., Behera, S., & Sabut, S. (2020). Machine learning approach to detect cardiac arrhythmias in ECG signals: A survey. *Irbm*, 41(4), 185–194.
- Saputra, A. D., Hindarto, D., & Santoso, H. (2023). Disease Classification on Rice Leaves using DenseNet121, DenseNet169, DenseNet201. *Sinkron: Jurnal Dan Penelitian Teknik Informatika*, 8(1), 48–55.
- Savarese, G., Becher, P. M., Lund, L. H., Seferovic, P., Rosano, G. M. C., & Coats, A. J. S. (2023). Global burden of heart failure: a comprehensive and updated review of epidemiology. *Cardiovascular Research*, 118(17), 3272–3287. <https://doi.org/10.1093/CVR/CVAC013>
- Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11), 2673–2681. <https://doi.org/10.1109/78.650093>
- Shewakramani, S., & Gorder, K. (2020). ECG Differential Diagnosis of T Wave and QT Interval Abnormalities. *Electrocardiogram in Clinical Medicine*, 421–431. <https://doi.org/10.1002/9781118754511.CH40>

- Silverman, M. E., & Willis Hurst, J. (1992). Willem einthoven—the father of electrocardiography. *Clinical Cardiology*, 15(10), 785–787. <https://doi.org/10.1002/CLC.4960151020>
- Singh, P. K., Akhtar, S., Gupta, A., & Singh, S. (2024). The Clinical Relevance of ECG Parameters in the Prediction of Cardiac Mortality: A Comprehensive Review. *The Open Bioinformatics Journal*, 17(1). <https://doi.org/10.2174/0118750362295563240620111209>
- Smagulova, K., & James, A. P. (2019a). A survey on LSTM memristive neural network architectures and applications. *European Physical Journal: Special Topics*, 228(10), 2313–2324. <https://doi.org/10.1140/EPJST/E2019-900046-X>
- Smagulova, K., & James, A. P. (2019b). A survey on LSTM memristive neural network architectures and applications. *The European Physical Journal Special Topics*, 228(10), 2313–2324.
- Snellen, H. (1994). *Willem Einthoven (1860–1927) Father of electrocardiography: Life and work, ancestors and contemporaries*. [https://books.google.com/books?hl=tr&lr=&id=Lp7ZbACFAI4C&oi=fnd&pg=PA5&dq=Snellen,+H.+A.+\(1994\).+Willem+Einthoven+\(1860%E2%80%931927\)+Father+of+electrocardiography:+Life+and+work,+ancestors+and+contemporaries.+Springer+Science+%26+Business+Media.&ots=ZZVUYS0qkL&sig=DgujRkKzW2GBzoBn1qs47qWvXI](https://books.google.com/books?hl=tr&lr=&id=Lp7ZbACFAI4C&oi=fnd&pg=PA5&dq=Snellen,+H.+A.+(1994).+Willem+Einthoven+(1860%E2%80%931927)+Father+of+electrocardiography:+Life+and+work,+ancestors+and+contemporaries.+Springer+Science+%26+Business+Media.&ots=ZZVUYS0qkL&sig=DgujRkKzW2GBzoBn1qs47qWvXI)
- Sohinki, D., & Obel, O. A. (2014). Current Trends in Supraventricular Tachycardia Management. *Ochsner Journal*, 14(4).
- StudMed. (2024). Conduction velocities and action potentials in various parts of the heart. https://studmed.uio.no/elaring/fag/hjertesykdommer/celle_papir_en/dell/basal_elfys.html
- Sundnes, J., Lines, G., Cai, X., Nielsen, B., & Mardal, K. (2007). *Computing the electrical activity in the heart*. [https://books.google.com/books?hl=tr&lr=&id=MCfh_FnHpgIC&oi=fnd&pg=PA1&dq=Sundnes,+J.,+Lines,+G.+T.,+Cai,+X.,+Nielsen,+B.+F.,+Mardal,+K.+A.,+%26+Tveito,+A.+\(2007\).+Computing+the+electrical+activity+in+the+heart+\(Vol.+1\).+Springer+Science+%26+Business+Media.&ots=Uq4m6rHDh2&sig=EToDhRkP9yxqa-jzI11bfpe305Q](https://books.google.com/books?hl=tr&lr=&id=MCfh_FnHpgIC&oi=fnd&pg=PA1&dq=Sundnes,+J.,+Lines,+G.+T.,+Cai,+X.,+Nielsen,+B.+F.,+Mardal,+K.+A.,+%26+Tveito,+A.+(2007).+Computing+the+electrical+activity+in+the+heart+(Vol.+1).+Springer+Science+%26+Business+Media.&ots=Uq4m6rHDh2&sig=EToDhRkP9yxqa-jzI11bfpe305Q)
- Tan, N. S., Goodman, S. G., Yan, R. T., Elbarouni, B., Budaj, A., Fox, K. A. A., Gore, J. M., Brieger, D., López-Sendón, J., Langer, A., Van De Werf, F., Steg, P. G., & Yan, A. T. (2013). Comparative prognostic value of T-wave inversion and ST-segment depression on the admission electrocardiogram in non–ST-segment elevation acute coronary syndromes. *American Heart Journal*, 166(2), 290–297. <https://doi.org/10.1016/J.AHJ.2013.04.010>
- Tekin, H., & Kaya, Y. (2024). A new approach for heart disease detection using Motif transform-based CWT's time-frequency images with DenseNet deep transfer

- learning methods. *Biomedizinische Technik*, 69(4), 407–417.
<https://doi.org/10.1515/BMT-2023-0580/HTML>
- Teymouri, N., Mesbah, S., Navabian, S. M. H., Shekouh, D., Najafabadi, M. M., Norouzkhani, N., Poudineh, M., Qadirifard, M. S., Mehrtabar, S., & Deravi, N. (2022). ECG frequency changes in potassium disorders: a narrative review. *American Journal of Cardiovascular Disease*, 12(3), 112.
<https://pmc.ncbi.nlm.nih.gov/articles/PMC9301030/>
- Thygesen, K., Alpert, J., ... A. J.-T. K., & 2013, undefined. (n.d.). Üçüncü evrensel miyokart enfarktüsü tanımı. *Jag.Journalagent.Com* K Thygesen, JS Alpert, AS Jaffe, ML Simoons, BR Chaitman, HD White Türk Kardiyoloji Derneği Arşivi, 2013•*jag.Journalagent.Com*. Retrieved November 19, 2024, from https://jag.journalagent.com/tkd/pdfs/TKDA_41_70_129_145.pdf
- TÜİK Kurumsal. (n.d.). Retrieved November 19, 2024, from <https://data.tuik.gov.tr/Bulten/Index?p=Olum-ve-Olum-Nedeni-Istatistikleri-2022-49679>
- Vijayvargiya, A., Kumar, R., & Dey, N. (2021). Voting-based 1D CNN model for human lower limb activity recognition using sEMG signal. *Physical and Engineering Sciences in Medicine*, 44, 1297–1309.
- Vogel, B., Claessen, B. E., Arnold, S. V., Chan, D., Cohen, D. J., Giannitsis, E., Gibson, C. M., Goto, S., Katus, H. A., Kerneis, M., Kimura, T., Kunadian, V., Pinto, D. S., Shiomi, H., Spertus, J. A., Steg, P. G., & Mehran, R. (2019). ST-segment elevation myocardial infarction. *Nature Reviews Disease Primers* 2019 5:1, 5(1), 1–20.
<https://doi.org/10.1038/s41572-019-0090-3>
- Wang, J., Zhu, H., Wang, S. H., & Zhang, Y. D. (2021). A Review of Deep Learning on Medical Image Analysis. *Mobile Networks and Applications*, 26(1), 351–380.
<https://doi.org/10.1007/S11036-020-01672-7>
- Wang, T., Lu, C., Sun, Y., Yang, M., Liu, C., & Ou, C. (2021). Automatic ECG Classification Using Continuous Wavelet Transform and Convolutional Neural Network. *Entropy* 2021, Vol. 23, Page 119, 23(1), 119.
<https://doi.org/10.3390/E23010119>
- Wellens, H. J. J. (2007a). Broad QRS Tachycardias. *Cardiovascular Medicine*, 2007–2018. https://doi.org/10.1007/978-1-84628-715-2_99
- Wellens, H. J. J. (2007b). Supraventricular Tachycardias. *Cardiovascular Medicine*, 1943–1953. https://doi.org/10.1007/978-1-84628-715-2_94
- Whinnett, Z. I., Afzal Sohaib, S. M., & Davies, D. W. (2012). Diagnosis and management of supraventricular tachycardia. *BMJ*, 345(7887).
<https://doi.org/10.1136/BMJ.E7769>
- Williams, S. E., O'Neill, M., & Kotadia, I. D. (2020). Supraventricular tachycardia: An overview of diagnosis and management. *Clinical Medicine*, 20(1), 43–47.
<https://doi.org/10.7861/CLINMED.CME.20.1.3>

- World Health Survey Plus* - WHO. (n.d.). Retrieved November 19, 2024, from <https://www.who.int/data/data-collection-tools/world-health-survey-plus>
- Zhang, X. D., Thai, P. N., Lieu, D. K., & Chiamvimonvat, N. (2021). Cardiac small-conductance calcium-activated potassium channels in health and disease. *Pflugers Archiv European Journal of Physiology*, 473(3), 477–489. <https://doi.org/10.1007/S00424-021-02535-0>
- Zhang, Y., Wei, S., Zhang, L., & Liu, C. (2019). Comparing the Performance of Random Forest, SVM and Their Variants for ECG Quality Assessment Combined with Nonlinear Features. *Journal of Medical and Biological Engineering*, 39(3), 381–392. <https://doi.org/10.1007/S40846-018-0411-0>
- Zhou, Z., Huang, K., Qiu, Y., Shen, H., & Ming, Z. (2021). Morphology extraction of fetal electrocardiogram by slow-fast LSTM network. *Biomedical Signal Processing and Control*, 68, 102664.
- Zihlmann, M., Perekrestenko, D., & Tschannen, M. (2017). Convolutional recurrent neural networks for electrocardiogram classification. *Computing in Cardiology*, 44, 1–4. <https://doi.org/10.22489/CINC.2017.070-060>
- Zyout, A., Alquran, H., Mustafa, W., Diagnostics, A. A.-, & 2023, undefined. (n.d.). Advanced time-frequency methods for ecg waves recognition. *Mdpi.Com* A Zyout, H Alquran, WA Mustafa, AM AlqudahDiagnostics, 2023•mdpi.Com. Retrieved November 19, 2024, from <https://www.mdpi.com/2075-4418/13/2/308>