

**T.C.
MANİSA CELAL BAYAR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ BİLİM DALI**

KALP SESLERİNİN SEGMENTASYONU VE SINIFLANDIRILMASI

CEYDA BOZ

Danışman

Doç. Dr. YÜCEL KOÇYİĞİT

MANİSA 2024

CEYDA BOZ

KALP SESLERİNİN SEGMENTASYONU VE SINIFLANDIRILMASI

2024

H

TAAHHÜTNAME

Bu tezin Manisa Celal Bayar Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Ana Bilim Dalında akademik ve etik kurallara uygun olarak yazıldığını ve kullanılan tüm literatür bilgilerinin referans gösterilerek tezde yer aldığını, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, tezin yazımında akademik ve etik kurallara aykırı herhangi bir yapay zeka ve program kullanmadığımı beyan ederim.

Ceyda BOZ



ÖZET

Yüksek Lisans Tezi

Kalp Seslerinin Segmentasyonu ve Sınıflandırılması

Ceyda BOZ

Manisa Celal Bayar Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik – Elektronik Mühendisliği Anabilim Dalı

Danışman:
Doç. Dr. Yücel KOÇYİĞİT

Kardiyovasküler hastalıklar, dünya çapında önemli sağlık sorunlarından biridir ve erken teşhis, hastaların yaşam kalitesini artırabilirken tedavi süreçlerini de iyileştirebilir. Bu çalışmada, kalp seslerinin derinlemesine analizi ve kardiyovasküler hastalıkların teşhisi için bir yöntem geliştirilmiştir. İki farklı kalp sesleri veri seti üzerinde kapsamlı bir analiz gerçekleştirilmiştir. İlk olarak, veri setleri çentik filtre, eliptik filtre ve normalizasyon gibi ön işleme adımlarından geçirilmiştir. Daha sonra, Otsu eşikleme yöntemi kullanılarak tepe değerleri bulunmuş ve Shannon enerjisi kullanılarak segmentasyon gerçekleştirilmiştir. Elde edilen segmentler üzerinde, Ampirik Kip Ayırımı (EMD) ve Mel Frekansı Kepstrum Katsayıları (MFCC) gibi öznitelik çıkarım yöntemleri uygulanmıştır. Bu öznitelikler, kalp seslerinin zaman – frekans alanında temsil edilmesini sağlamıştır. Son adımda, farklı sınıflandırma algoritmaları (k – En Yakın Komşu, Destek Vektör Makineleri, Yapay Sinir Ağları, Evrişimli Sinir Ağları) kullanılarak, hastalıklı ve sağlıklı kalp seslerinin sınıflandırılması gerçekleştirilmiştir. Yapılan deneysel sonuçlar, önerilen yöntemin yüksek doğruluk oranlarına ve güvenilir sonuçlara sahip olduğunu göstermektedir. Bu çalışma, kalp hastalıklarının erken teşhisinde ve tedavi süreçlerinin izlenmesinde kullanılabilecek etkili bir araç sunmaktadır.

Anahtar Kelimeler: Kalp Sesleri, Sınıflama, Segmentasyon, Ampirik Kip Ayırımı, Mel Frekansı Kepstrum Katsayıları.

2024, 63 sayfa

ABSTRACT

M.Sc. Thesis

Segmentation and Classification of Heart Sounds

Ceyda BOZ

**Manisa Celal Bayar University
Graduate School of Education
Department of Electrical and Electronics Engineering**

Supervisor: Assoc. Prof. Dr. Yücel KOÇYİĞİT

Cardiovascular diseases are significant health issues worldwide, and early diagnosis can improve patients' quality of life and enhance treatment processes. In this study, a method for in – depth analysis of heart sounds and diagnosis of cardiovascular diseases has been developed. A comprehensive analysis was conducted on two different datasets of heart sounds. Initially, the datasets underwent preprocessing steps including notch filtering, elliptic filtering, and normalization. Subsequently, peak values were identified using the Otsu thresholding method, followed by segmentation using Shannon energy. Feature extraction methods such as Empirical Mode Decomposition (EMD) and Mel Frequency Cepstral Coefficients (MFCC) were applied to the obtained segments. These features facilitated the representation of heart sounds in the time – frequency domain. In the final step, various classification algorithms (k – Nearest Neighbors, Support Vector Machines, Artificial Neural Networks, Convolutional Neural Networks) were employed to classify diseased and healthy heart sounds. Experimental results demonstrate that the proposed method achieves high accuracy rates and reliable outcomes. This study presents an effective tool for early diagnosis of cardiovascular diseases and monitoring treatment processes.

Keywords: Heart Sounds, Classification, Segmentation, Empirical Mode Decomposition, Mel Frequency Cepstral Coefficients.

2024, 63 pages

ÖNSÖZ VE TEŞEKKÜR

Kardiyovasküler hastalıklar, günümüzde dünya genelinde en yaygın ve tehlikeli sağlık sorunlarından biri olarak karşımıza çıkmaktadır. Bu hastalıkların erken teşhisi ve tedavi süreçlerinin iyileştirilmesi, hastaların yaşam kalitesini artırmak ve ölüm oranlarını düşürmek açısından büyük bir öneme sahiptir. Bu doğrultuda, kardiyovasküler hastalıkların teşhisinde kullanılabilecek yenilikçi ve etkili yöntemlerin geliştirilmesi, tıbbi araştırmaların önemli bir hedefi haline gelmiştir. Bu tez çalışmasında, kalp seslerinin analizi ve sınıflandırılması üzerine yoğunlaşarak kardiyovasküler hastalıkların erken teşhisinde kullanılabilecek bir yöntem geliştirilmiştir. Çalışma kapsamında, iki farklı kalp sesi veri seti üzerinde kapsamlı analizler gerçekleştirilmiş ve çeşitli ön işleme, öznitelik çıkarımı ve sınıflandırma teknikleri kullanılmıştır. Elde edilen bulgular, geliştirilen yöntemin yüksek doğruluk oranlarına sahip olduğunu ve güvenilir sonuçlar verdiğini göstermektedir.

Çalışma süresince bilgi ve deneyimleriyle bana rehberlik eden danışman hocam Sayın Doç. Dr. Yücel KOÇYİĞİT'e, her zaman yanımda olan ve her türlü soruma sabırla cevap veren Arş. Gör. Burcu ACAR DEMİRCİ'ye en içten teşekkürlerimi sunarım. Bu yorucu ancak tatlı yolda maddi ve manevi desteğini esirgemeyen annem Şükran BOZ'a, babam Necati BOZ'a ve kız kardeşim Dilayda Gamze BOZ'a da tüm kalbimle sonsuz teşekkür ederim. En zor anlarda dahi, yanımda olduklarını hissettiğim başta Arş. Gör. Helin KAHRIMAN'a ve sevgili arkadaşlarıma teşekkürü borç bilirim.

Ceyda BOZ
Manisa, 2024

İÇİNDEKİLER

	Sayfa
ÖZET.....	IV
ABSTRACT	V
ÖNSÖZ VE TEŞEKKÜR.....	VI
SİMGELER VE KISALTMALAR DİZİNİ	IX
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ	XII
1. GİRİŞ	1
2. GENEL BİLGİLER.....	8
2.1. Kalbin Anatomisi ve Çalışma Döngüsü	8
2.2. Kalp Sesleri.....	10
2.2.1. S1 Kalp Sesi	11
2.2.2. S2 Kalp Sesi	11
2.2.3. S3 Kalp Sesi	11
2.2.4. S4 Kalp Sesi	11
2.2.5. Üfürüm (Murmur)	12
2.2.5.1. AS (Aortik Darlığı) Kalp Sesi:	12
2.2.5.2. MS (Mitral Darlık) Kalp Sesi:	13
2.2.5.3. MR (Mitral Yetersizlik) Kalp Sesi:	13
2.2.5.4. MVP (Mitral Kapak Bozukluğu) Kalp Sesi:	14
3. MATERYAL VE YÖNTEMLER.....	15
3.1. Veri Setleri	16
3.1.1. PhysioNet/Computing in Cardiology (CinC) Challenge 2016..	16
3.1.2. Yaseen ve Kwon (Github – PCG)	17
3.2. Ön İşleme	17
3.2.1. Notch (Çentik) Filtre.....	18
3.2.2. Eliptik Filtreleme	19
3.2.3. Normalizasyon	19
3.3. Bölütlenme (Segmentasyon)	20
3.3.1. Shannon Enerji.....	21
3.3.2. Otsu Eşikleme Yöntemi	22
3.4. Öznitelik Çıkarım Yöntemleri	24
3.4.1. Ampirik Kip Ayırışımı (EMD).....	25
3.4.2. Mel Frekansı Kepstrum Katsayıları (MFCC).....	26
3.4.3. Temel Bileşen Analizi (PCA).....	29
3.5. Sınıflama Yöntemleri	29

3.5.1.	k – En Yakın Komşu Algoritması (kNN)	31
3.5.2.	Destek Vektör Makineleri (SVM).....	31
3.5.3.	Yapay Sinir Ağları (ANN)	32
3.5.4.	Evrişimli Sinir Ağları (CNN)	35
3.6.	Sınıflama Metrikleri.....	38
4.	ARAŞTIRMA BULGULARI VE TARTIŞMA.....	39
5.	SONUÇLAR VE ÖNERİLER	57
KAYNAKÇA		59



SİMGELER VE KISALTMALAR DİZİNİ

ANN	Yapay Sinir Ağları
AS	Aort Darlığı
CNN	Evrişimli Sinir Ağları
DT	Karar Ağacı
EMD	Ampirik Kip Ayırımı
FFT	Hızlı Fourier Dönüşümü
kNN	k – En Yakın Komşu Algoritması
LSTM	Uzun Kısa Vadeli Hafıza Ağları
MFCC	Mel Frekansı Kepstrum Katsayıları
MFSC	Mel Frekanslı Spektral Katsayılar
MR	Mitral Yetersizlik
MS	Mitral Darlık
MVP	Mitral Kapak Bozukluğu
PCA	Temel Bileşen Analizi
PCG	Fonokardiyografi
SVM	Destek Vektör Makineleri
WPT	Dalgacık Paket Dönüşümü
WSST	Dalgacık Eşzamanlı Sıkıştırma Dönüşümü
WT	Dalgacık Dönüşümü

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2. 1. Kalbin Yapısı	8
Şekil 2. 2. Kalp Döngüsü	9
Şekil 2. 3. Kalp Sesleri.....	10
Şekil 2. 4. AS Kalp Sesi.....	12
Şekil 2. 5. MS Kalp Sesi	13
Şekil 2. 6. MR Kalp Sesi.....	14
Şekil 2. 7. MVP Kalp Sesi	14
Şekil 3. 1. Kalp Sesi Analizinin Blok Diyagramı	15
Şekil 3. 2. PhysioNet CinC – 2016: (a) Normal Kalp Sesi; (b) Anormal Kalp Sesi; Github – PCG: (c) Normal Kalp Sesi; (d) MVP Hasta Kalp Sesi; (e) AS Hasta Kalp Sesi; (f) MR Hasta Kalp Sesi; (g) MS Hasta Kalp Sesi	22
Şekil 3. 3. MFCC Blok Diyagramı	27
Şekil 3. 4. SVM Ağ Yapısı	32
Şekil 3. 5. Yapay Sinir Ağı Hücresi.....	33
Şekil 4. 1. PhysioNet Veri Seti İçin EMD ile Öznitelikleri Belirlenen Normal Kalp Sesine Ait İlk 4 IMF.....	40
Şekil 4. 2. PhysioNet Veri Seti İçin EMD ile Öznitelikleri Belirlenen Hasta Kalp Sesine Ait İlk 4 IMF.....	40
Şekil 4. 3. Github Veri Seti İçin EMD ile Öznitelikleri Belirlenen Normal Kalp Sesine Ait İlk 4 IMF	41
Şekil 4. 4. Github Veri Seti İçin EMD ile Öznitelikleri Belirlenen AS Hasta Kalp Sesine Ait İlk 4 IMF.....	41
Şekil 4. 5. Github Veri Seti İçin EMD ile Öznitelikleri Belirlenen MR Hasta Kalp Sesine Ait İlk 4 IMF.....	42
Şekil 4. 6. Github Veri Seti İçin EMD ile Öznitelikleri Belirlenen MS Hasta Kalp Sesine Ait İlk 4 IMF.....	42
Şekil 4. 7. Github Veri Seti İçin EMD ile Öznitelikleri Belirlenen MVP Hasta Kalp Sesine Ait İlk 4 IMF.....	43
Şekil 4. 8. Github Veri Setindeki Normal Sesine Ait Mel Frekansı Kepstrumu	44
Şekil 4. 9. Github Veri Setindeki MVP Sesine Ait Mel Frekansı Kepstrumu.....	44
Şekil 4. 10. Github Veri Setindeki MS Sesine Ait Mel Frekansı Kepstrumu.....	45
Şekil 4. 11. Github Veri Setindeki MR Sesine Ait Mel Frekansı Kepstrumu	45
Şekil 4. 12. Github Veri Setindeki AS Sesine Ait Mel Frekansı Kepstrumu	46
Şekil 4. 13. PhysioNet Veri Setindeki Normal Sesine Ait Mel Frekansı Kepstrumu	46
Şekil 4. 14. PhysioNet Veri Setindeki Hasta Sesine Ait Mel Frekansı Kepstrumu...	47
Şekil 4. 15. PhysioNet CinC – 2016 Veri Seti İçin Eğitim Verilerine MFCC Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi	49
Şekil 4. 16. PhysioNet CinC – 2016 Veri Seti İçin Test Verilerine MFCC Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi	49
Şekil 4. 17. Github – PCG Veri Seti İçin Eğitim Verilerine EMD Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi..	50
Şekil 4. 18. Github – PCG Veri Seti İçin Test Verilerine EMD Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi..	51
Şekil 4. 19. Github – PCG Veri Seti İçin Eğitim Verilerine MFCC Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi..	52

Şekil 4. 20. Github – PCG Veri Seti İçin Test Verilerine MFCC Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi.. 53



TABLÖLAR DİZİNİ

	Sayfa
Tablo 1.1 Literatürde Kalp Seslerinin Segmentasyonu ve Sınıflandırılmasıyla İlgili Çalışmaların Özeti.....	7
Tablo 3.1. PhysioNet CinC – 2016 Veri Seti	17
Tablo 3.2. Github – PCG Veri Seti.....	17
Tablo 3.3. Öznitelik Çıkarım Yöntemleri ve Kullanılan Parametreler	24
Tablo 3.4. Sınıflama Yöntemleri ve Kullanılan Parametreler	30
Tablo 4.1. PhysioNet CinC – 2016 Veri Seti İçin EMD Öznitelik Çıkarım ile Eğitim Verilerinin Sınıflama Sonuçları	48
Tablo 4.2. PhysioNet CinC – 2016 Veri Seti İçin EMD Öznitelik Çıkarım ile Test Verilerinin Sınıflama Sonuçları	48
Tablo 4.3. PhysioNet CinC – 2016 Veri Seti İçin MFCC Öznitelik Çıkarım ile Eğitim Verilerinin Sınıflama Sonuçları	48
Tablo 4.4. PhysioNet CinC – 2016 Veri Seti İçin MFCC Öznitelik Çıkarım ile Test Verilerinin Sınıflama Sonuçları	49
Tablo 4.5. Github – PCG Veri Seti İçin EMD ve kNN Kullanılarak Elde Edilen Eğitim Verisi Sonuçları.....	50
Tablo 4.6. Github – PCG Veri Seti İçin EMD ve kNN Kullanılarak Elde Edilen Test Verisi Sonuçları.....	50
Tablo 4.7. Github – PCG Veri Seti İçin EMD ve SVM Kullanılarak Elde Edilen Eğitim Verisi Sonuçları.....	51
Tablo 4.8. Github – PCG Veri Seti İçin EMD ve SVM Kullanılarak Elde Edilen Test Verisi Sonuçları.....	51
Tablo 4.9. Github – PCG Veri Seti İçin EMD ve ANN Kullanılarak Elde Edilen Eğitim Verisi Sonuçları.....	51
Tablo 4.10. Github – PCG Veri Seti İçin EMD ve ANN Kullanılarak Elde Edilen Test Verisi Sonuçları.....	52
Tablo 4.11. Github – PCG Veri Seti İçin MFCC ve kNN Kullanılarak Elde Edilen Eğitim Verisi Sonuçları.....	52
Tablo 4.12. Github – PCG Veri Seti İçin MFCC ve kNN Kullanılarak Elde Edilen Test Verisi Sonuçları.....	53
Tablo 4.13. Github – PCG Veri Seti İçin MFCC ve SVM Kullanılarak Elde Edilen Eğitim Verisi Sonuçları.....	53
Tablo 4.14. Github – PCG Veri Seti İçin MFCC ve SVM Kullanılarak Elde Edilen Test Verisi Sonuçları.....	53
Tablo 4.15. Github – PCG Veri Seti İçin MFCC ve ANN Kullanılarak Elde Edilen Eğitim Verisi Sonuçları.....	54
Tablo 4.16. Github – PCG Veri Seti İçin MFCC ve ANN Kullanılarak Elde Edilen Test Verisi Sonuçları.....	54
Tablo 4.17. PhysioNet CinC – 2016 Veri Seti İçin CNN Elde Edilen Eğitim Verisi Sonuçları	54
Tablo 4.18. PhysioNet CinC – 2016 Veri Seti İçin CNN Elde Edilen Test Verisi Sonuçları	54
Tablo 4.19. Github – PCG Veri Seti İçin CNN Kullanılarak Elde Edilen Eğitim Verisi Sonuçları	55
Tablo 4.20. Github – PCG Veri Seti İçin CNN Kullanılarak Elde Edilen Test Verisi Sonuçları	55

1. GİRİŞ

Küresel sağlık tehditlerinin en önemlilerinden biri olan kardiyovasküler hastalıklar hem ülkemizde hem de dünya genelinde en sık karşılaşılan hastalıklardan biridir. Dünya Sağlık Örgütü'ne göre, her yıl yaklaşık 18 milyon insan kardiyovasküler hastalıklardan dolayı hayatını kaybetmektedir [1]. Bu ölümler, özellikle tıbbi kaynakların yetersiz olduğu düşük ve orta gelirli ülkelerde daha belirgin bir şekilde ortaya çıkmaktadır [2]. Kardiyovasküler hastalıkların erken teşhisi ve etkili tedavisi, yalnızca ölüm oranlarını azaltmakla kalmayıp, aynı zamanda çeşitli komplikasyonların önüne geçerek hastaların yaşam kalitesini önemli ölçüde arttırabilmektedir.

Kalbin kasılması ve gevşemesi sırasında meydana gelen titreşimlerin bir sonucu olarak ortaya çıkan kalp sesleri, kardiyovasküler sistemdeki işleyişin önemli biyolojik yansımalarıdır ve farklı bileşenlere sahiptir. Kalp sesi bileşenlerinin doğru bir şekilde tespiti, özellikle sistolik veya diyastolik (örneğin S1 ve S2) bölgelerin doğru bir şekilde tanımlanması açısından son derece önemlidir [3]. Kardiyak hastalıkların ilk tanısında kullanılan en yaygın yöntemlerden biri, hastanın kalp seslerinin dinlenmesidir. Klinik bir hastalık belirtisi oluşmadan önce, kalp seslerindeki gürültü veya bozulmaların tespiti, insan kalbindeki kapakların ve arterlerin durumu hakkında önemli bilgiler sağlamaktadır [4]. Bu bağlamda, büyük veri ve makine öğrenmesi alanındaki gelişmeler, bilgisayar destekli kalp sesi tanıma teknolojisinin önemli bir araştırma odak noktası haline gelmesine yol açmaktadır [5].

Kalp sesi sinyallerinin doğru bir şekilde bölütlenmesi (segmentasyon), kalp sesi modellemesindeki temel ve en önemli adımdır. Segmentasyonun ana görevleri, kalp sesi bileşenlerinin sınırlarını belirlemek ve S1, S2, S3 ve S4 olarak adlandırılan bileşen türlerini tanımlamaktır [6]. Ancak, geleneksel yöntemlerle elde edilen sonuçlarda bazı zorluklarla karşılaşmaktadır. Bu zorlukların üstesinden gelmek ve daha doğru sonuçlar elde etmek için, teknolojik gelişmelerden yararlanılmaktadır. Özellikle, elektronik stetoskoplar gibi cihazlar, gürültüyü en aza indirgeyerek duyulması zor olan kalp seslerini net bir şekilde kaydetme imkânı sağlamaktadır. Böylece kalp sesleri daha hassas bir şekilde analiz edilebilmektedir.

Kalp seslerinin segmentasyonundan elde edilen bileşenlerin doğru bir şekilde tanımlanması ve bu bileşenlerin özneteliklerinin çıkarılması gerekmektedir.

Özniteliklerin seçimi, kalp seslerinin doğru analizi ve sınıflandırılması için hayati öneme sahiptir. Literatürde, öznitelik seçimi için birçok farklı yöntem bulunmaktadır. Bu yöntemlerin başında zaman, frekans ve zaman – frekans eksenlerinden seçilen öznitelikler gelmektedir.

Ampirik Kip Ayrışımı (EMD) yöntemi kalp seslerinin zaman ekseninde analiz edilmesine imkân sağlarken, Mel Frekansı Kepstrum Katsayıları (MFCC) ve Hızlı Fourier Dönüşümü frekans ekseninde analizini sağlamaktadır. Dalgacık Paket Dönüşümü (WPT) ve Dalgacık Dönüşümü (WT) yöntemleri ise zaman ve frekans eksenindeki öznitelikleri aynı anda analiz eden etkili yöntemlerdir. Tüm bu yöntemlerin amacı, kalp seslerinin karmaşıklığını azaltmak ve kalp hastalıklarının doğru bir şekilde teşhisi için en uygun öznitelikleri belirlemektir. Elde edilen öznitelikler kullanılarak makine öğrenimi veya derin öğrenme algoritmalarıyla bir sınıflama modeli oluşturulmaktadır. Doğru sınıflama algoritması seçimi, kalp hastalıklarının teşhisi ve tedavisi için doğru kararların verilmesinde kritik öneme sahiptir. Literatürde, kalp seslerinin sınıflandırılması için birçok farklı makine öğrenimi ve derin öğrenme algoritması kullanılmaktadır.

Bu algoritmalar arasında k En Yakın Komşu Algoritması (kNN), veri noktalarının çevresindeki komşuların sınıflandırılmasında kullanılan basit ancak etkili bir algoritmadır. Destek Vektör Makineleri (SVM), veri noktalarını sınıflandırmak amacıyla bir hiper düzlem oluşturur ve hem doğrusal hem de doğrusal olmayan ayrımlar yapabilme kapasitesine sahiptir. Yapay Sinir Ağları (ANN) ve Derin Öğrenme Algoritmaları, karmaşık kalp sesi verilerinden anlamlı desenler çıkararak sınıflandırma performansını arttırabilmektedir. Özellikle, Evrişimli sinir ağları (CNN) ve uzun – kısa vadeli hafıza ağları (LSTM), zaman serisi verilerini başarılı bir şekilde işleyebilmekte ve kalp seslerinin sınıflandırılmasında kullanılabilmektedir.

Literatürdeki sınıflamaların başarısını değerlendirmek için çeşitli performans ölçütleri kullanılmaktadır. Tıbbi testlerde sonuçlar pozitif veya negatif olarak gruplandırıldığında, doğru ve yanlış sınıflandırmaları belirlemek önemlidir. Bir örnek pozitif olup model tarafından da pozitif olarak etiketlenirse Doğru Pozitif (DP) olarak adlandırılmaktadır. Eğer pozitif bir örnek model tarafından negatif olarak etiketlenirse bu Yanlış Negatif (YN) olmaktadır. Benzer şekilde, negatif bir örnek doğru bir şekilde negatif olarak etiketlenirse Doğru Negatif (DN) olarak sınıflandırılmaktadır. Negatif

bir örnek model tarafından pozitif olarak etiketlenirse bu durum Yanlış Pozitif (YP) olarak adlandırılmaktadır. Bu sınıflandırmalar temel alınarak performans ölçütleri hesaplanarak sınıflandırma tabloları oluşturulmaktadır [7].

Kalp seslerinin segmentasyonu ve sınıflandırılmasıyla ilgili birçok çalışma literatürde yer almaktadır. Bu çalışmalar, yöntem ve veri çeşitliliğini göstermektedir. Tablo 1.1’de farklı segmentasyon teknikleri, öznitelik çıkarımı yöntemleri ve sınıflandırıcılar kullanılarak elde edilen sonuçları karşılaştırılmaktadır.

2016 yılında Nilanon ve ark., PhysioNet/Computing in Cardiology (CinC) Challenge 2016 veri setini kullanarak normal ve anormal Fonokardiyografi (PCG) kayıtlarının otomatik sınıflandırılması üzerine çalışmışlardır. Bu çalışmada, kayıtlar 5 saniyelik segmentlere bölünmüş ve sınıflandırıcılar bu segmentleri sınıflandırmak için eğitilmiştir. Mel Frekanslı Kepstrum Katsayıları (MFCC) özelliklerini Evrişimli Sinir Ağı (CNN) kullanarak sınıflandırarak %85,3 test doğruluğu elde etmişlerdir [8].

2016 yılında Koçyiğit çalışmasında kalp seslerinin sınıflandırılmasında, öznitelik vektörleri, destek vektör makineleri, doğrusal diskriminant analizi ve saf bayes (NB) gibi sınıflandırıcıları kullanmıştır. Bağımsız Bileşen Analizi (ICA), NB ile birleştirildiğinde en yüksek ortalama performansı elde etmiştir; %98,53 duyarlılık, %99,89 özgüllük, %99,21 g – ortalama ve %99.79 doğruluk sağlanmıştır [9].

Maknickas ve ark. (2017) yaptığı çalışmada veri seti olarak PhysioNet/CinC – 2016 kullanılmıştır ve segmentasyon işlemi yapılmamıştır. Öznitelik tespiti MFCC ve sınıflandırma işlemi olarak CNN kullanılmıştır. Bu çalışma %84,15 doğruluk oranı ile sonuçlanmıştır [10].

2018 yılında Yaseen ve ark. yaptığı çalışmada kendilerinin oluşturduğu ve Github’ta da erişime açık olan veri seti kullanılmıştır ancak segmentasyon işlemi yapılmamıştır. Öznitelik çıkarım olarak MFCC ve Ayrık Dalgacık Dönüşümleri kullanılmıştır. Bu çalışmada toplam 5 sınıf bulunmakta olup, sınıflandırma işlemi SVM ile %97,9 doğruluk ve %98,2 duyarlılık oranı ile gerçekleştirilirken, kNN ile %97,4 doğruluk ve %99,2 duyarlılık oranı elde edilmiştir [11].

Upreti ve ark. (2019) yaptığı çalışmada veri seti olarak çoklu sınıfa ait olan Yaseen ve Kwon (Github – PCG) kullanılmıştır ve segmentasyon işlemi olarak her

kaydın üç ayrı kalp döngüsü segmentine bölündüğü belirtilmektedir. Her bir kayıt başlangıçtan sona kadar taranmış ve her biri bir kalp döngüsüne tekabül eden üç ayrı parçaya ayrılmıştır. Bu segmentler daha sonra tek bir kayıt olarak saklanmıştır. Bu çalışmada SVM ile %95,07 doğruluk ve %95,07 duyarlılık oranı bulunurken, kNN ile %96,50 doğruluk ve %96,50 duyarlılık oranı ile sonuçlanmıştır [12].

2019 yılında Deperlioğlu yaptığı çalışmada PhysioNet A eğitim veri setinde bulunan normal ve anormal kalp seslerini CNN kullanarak sınıflamıştır. Kalp seslerinin S1 ve S2 kısımları, yeniden örneklenmiş enerji yöntemi ile segmente edilmiştir. CNN ile yapılan sınıflamada, %97,21 doğruluk, %94,78 duyarlılık ve %99,65 özgüllük oranlarına ulaşılmıştır [13].

Ghosh ve ark. (2019) yaptığı çalışmada veri seti olarak çoklu sınıfa ait olan Github – PCG kullanılmıştır. Segmentasyon işleminde kalp sesi sinyallerinin Shannon enerji tabanlı zarf formülasyonu ve kalp sesi döngüsü çıkarma yaklaşımlarına dayanarak çerçevelere veya döngülere bölündüğü belirtilmektedir. Ardından zaman – frekans analizi için kullanılan Dalgacık Eşzamanlı Sıkıştırma Dönüşümü (WSST) yöntemiyle analiz edilmiştir. Rastgele Orman (Random Forest) algoritması ile sınıflama yapılarak %95,13 doğruluk oranı elde edilmiştir [14].

Milani ve ark. (2019) yaptığı çalışmada PhysioNet/CinC – 2016 veri setini kullanarak normal ve anormal PCG sinyallerinin otomatik segmentasyonu için bir yöntem sunmuştur. Bu çalışmada, belirgin tepe noktalarının mesafeleri, genlikleri, alanı ve kalp döngüsü süreleri analiz edilmiştir. Hesaplanan belirgin tepe oranlarının boyutları Temel Bileşen Analizi (PCA) ile azaltılmıştır. Ardından, Yapay Sinir Ağları (ANN) kullanılarak normal ve anormal kalp sesleri arasındaki sınır belirlenmiştir. Segmentasyon sonuçları, normal ve anormal kalp sesi sinyallerini ayırt etmek amacıyla kullanılmış ve normal ile anormal kalp seslerinin tanımlanmasında %90 doğruluk elde edilmiştir [15].

Deng ve ark. (2020) yaptığı çalışmada, geleneksel öznitelik yöntemlerin aksine kalp sesi sinyallerinin segmentasyonu yapılmaksızın MFCC'lerin hesaplanması önerilmiştir. PhysioNet/CinC – 2016 veri tabanındaki kalp sesleri Evrişimli Sinir Ağı (CNN) ve Tekrarlayan Sinir Ağı (RNN) ile sınıflanmıştır. Hasta ve sağlıklı kalp

seslerinin ikili sınıflandırma görevinde %98 sınıflandırma doğruluk oranına ulaşmıştır [16].

Shu Lih Oh ve ark. (2020) yaptığı çalışmada 5 farklı sınıfı olan Github – PCG veri seti kullanılmış ve segmentasyon işlemi yapılmamıştır. Otomatik sınıflandırılma için bir iç yapısı olan Tek Boyutlu (1D) CNN WaveNet modeli geliştirilmiştir. Beş farklı kalp sesi türünün sınıflandırılması için %97 eğitim doğruluğu elde edilmiştir. Normal sınıf için en yüksek sınıflandırma doğruluğu %98,20 olarak belirlenmiştir [17].

Khan ve ark. (2020) yaptığı çalışmada PhysioNet/CinC – 2016 veri seti üzerinde ilk kez kullanılan Karar Ağacı (DT) sınıflandırıcısının performansı değerlendirilmiştir. DT sınıflandırıcısı, %86,35 doğruluk ve %78,31 genel skor ile dikkate değer bir başarı göstermiş ve bu sonuçlarla, KNN ve LSTM sınıflandırıcılarına göre daha iyi performans sergilediğini ileri sürmüşlerdir [18].

Shuvo ve ark. (2021) yaptığı çalışmada CardioXNet adı verilen yeni bir hafif ve uçtan uca bir sinir ağı mimarisi kullanılmıştır. CardioXNet modelinde, %99,60 doğruluk, %99,56 kesinlik, %99,52 duyarlılık ve %99,68 F1 skoru gibi yüksek performans sonuçları elde edilmiştir. Github – PCG veri seti ile PhysioNet veri setinin birleştirilmiş veri setinde %88,09 doğruluk oranına ulaşmıştır [19].

Rishal ve ark. (2022) yaptığı çalışma, kalp kapak hastalıklarının sınıflandırılması için sekiz öznitelik çıkarım yöntemi, varyans analizi (ANOVA) – tabanlı öznitelik seçimi ve üç farklı türde denetimli öğrenme algoritması (SVM, kNN ve rastgele ormanlar) kullanan bir yöntemi içermektedir. Çalışmada, Github – PCG veri setinden alınan beş farklı kalp kapak hastalığı sınıfında değerlendirilmiş ve %99,50 doğruluk elde edilmiştir. Ayrıca, PhysioNet/CinC – 2016 veri setinde normal/hasta ikili sınıflandırmada da değerlendirilmiş ve %98,67 doğruluk oranı elde edilmiştir [20].

Zhu ve ark. (2022) çalışmasında, veri seti olarak PhysioNet/CinC – 2016 ve sınıflandırma algoritması olarak da CNN modeli ve klasik Kalan Ağ (ResNet) ile Uzun Kısa Süreli Hafıza (LSTM) yöntemlerini birleştiren bir algoritma kullanılmıştır. Filtre bankası katsayılarından dört öznitelik çıkarılmıştır, bunlar arasında Filterbank (Fbank), Mel Frekanslı Spektral Katsayılar (MFSC'ler) ve MFCC'ler bulunmaktadır. Yapılan deneysel sonuçlar, önerilen CNN modelinde MFSC'ler özelliğinin diğerlerine

göre daha iyi performans gösterdiğini ortaya koymuştur. Önerilen modelin test setindeki performansı, %84,3'lük F1 skoru, %84,4'lük doğruluk, %84,3'lük duyarlılık ve %85,6'luk özgüllük oranlarıyla belirlenmiştir [21].

Fauzi ve ark. (2023) yaptığı çalışmada, PhysioNet/CinC – 2016 veri seti kullanılmıştır ve istatistiksel öznitelikler, Ampirik Kip Ayrışımı (EMD) ile optimize edilmiş ve beş birinci dereceden parametre kullanılarak hesaplanmıştır. Sınıflandırma sistemi, sistem performansını artırmak için öznitelik seçimi için karşılıklı bilgi algoritması ile optimize edilmiştir. Test sonuçlarına dayanarak, kNN yöntemi ile elde edilen en yüksek doğruluk oranı %98,2 olarak bulunmuştur [22].

Gharehbaghi ve ark. (2023) yaptığı çalışmada, geleneksel bir CNN'in performansı, Gated Recurrent Network (GRN) ve LSTM ile birleştirilmiş farklı mimarileri PhysioNet/CinC – 2016 veri seti üzerinden değerlendirilerek karşılaştırılmıştır. Sonuçlar, LSTM – CNN paralel mimarisinin %98,0 doğruluk ve %87,2 duyarlılıkla diğer tüm birleşik mimarileri geride bıraktığını göstermiştir [23].

Bu tezin temel amacı, kalp seslerini otomatik olarak bölütleyip sınıflandırarak kardiyovasküler hastalıkların teşhisini desteklemektir. Çalışma kapsamında:

- Kalp seslerinin çeşitli veri setlerinden toplanması ve ön işleme teknikleri kullanılarak gürültülerden arındırılması.
- Öznitelik çıkarımı süreçlerinde kullanılacak yöntemlerin araştırılması ve değerlendirilmesi.
- Farklı makine öğrenmesi ve derin öğrenme algoritmalarının performanslarının karşılaştırılması ve en uygun yöntemlerin tespiti.

Bu çalışmanın, kalp sesi analizi ve segmentasyonunda yeni bir perspektif sunarak, kardiyovasküler hastalıkların tanı ve tedavi süreçlerinde önemli katkılar sağlayacağı düşünülmektedir.

Tablo 1.1 Literatürde Kalp Seslerinin Segmentasyonu ve Sınıflandırılmasıyla İlgili Çalışmaların Özeti


Ref. No	Veri Seti	Segmentasyon	Öznitelik Çıkarımı	Sınıflandırıcı	Sonuçlar
[8]	PhysioNet/CinC – 2016	✓	MFCC	CNN	%85,3 Doğruluk
[10]	PhysioNet/CinC – 2016	✗	MFCC	CNN	%84,15 Doğruluk
[11]	Kendi veri seti (Github)	✗	MFCC, DWT	SVM, kNN	SVM: %97,9 Doğruluk, %98,2 Duyarlılık kNN: %97,4 Doğruluk, %99,2 Duyarlılık
[12]	Yaseen ve Kwon (Github – PCG)	✓	–	SVM, kNN	SVM: %95,07 Doğruluk, %95,07 Duyarlılık
[13]	PhysioNet A	✓	–	CNN	%97,21 Doğruluk, %94,78 Duyarlılık, %99,65 Özgüllük
[14]	Github – PCG	✓	WSST	Random Forest	%95,13 Doğruluk
[15]	PhysioNet/CinC – 2016	✓	PCA	ANN	%90 Doğruluk
[16]	PhysioNet/CinC – 2016	✗	MFCC	CNN, RNN	%98 Doğruluk
[17]	Github – PCG	✗	–	1D CNN WaveNet	%97 Eğitim Doğruluğu; Normal Sınıf: %98,20 Doğruluk
[18]	PhysioNet/CinC – 2016	✗	–	DT	%86,35 Doğruluk, %78,31 Genel Skor
[19]	Github – PCG, PhysioNet	–	–	CardioXNet	%99,60 Doğruluk, %99,56 Kesinlik, %99,52 Duyarlılık, %99,68 F1 Skoru
[20]	Github – PCG, PhysioNet/CinC – 2016	✗	–	SVM, kNN, Random Forest	Github – PCG: %99,50 Doğruluk; PhysioNet: %98,67 Doğruluk
[21]	PhysioNet/CinC – 2016	✗	Fbank, MFSC, MFCC	CNN, ResNet, LSTM	%84,3 F1 Skoru, %84,4 Doğruluk, %84,3 Duyarlılık, %85,6 Özgüllük
[22]	PhysioNet/CinC – 2016	✗	EMD	kNN	%98,2 Doğruluk
[23]	PhysioNet/CinC – 2016	✗	–	CNN, GRN, LSTM	LSTM – CNN: %98,0 Doğruluk, %87,2 Duyarlılık
TÇ	Github – PCG, PhysioNet/CinC – 2016	✓	EMD, MFCC	CNN, kNN, SVM, ANN	Github – PCG: %99,99 Doğruluk; PhysioNet: %99,99 Doğruluk

TÇ: Tez Çalışması

2. GENEL BİLGİLER

2.1. Kalbin Anatomisi ve Çalışma Döngüsü

Kalp, vücuttaki tüm dokulara kanın ulaşmasını sağlayan hayati bir organdır ve adeta bir pompa gibi işlevi görmektedir. Bu kaslı yapı, göğsün ortasında, akciğerlerin arasında sola yatık şekilde yer almaktadır. Şekil 2.1'de gösterildiği gibi, kalbin temel bileşenleri iki üst odacık sağ ve sol atrium (kulakçık) ile iki alt odacık sağ ve sol ventrikül (karıncık) şeklinde adlandırılmaktadır [24] Sol atrium, vücuttan oksijenli kanı toplar ve sol ventriküle pompalar. Sol ventrikül, bu kanı vücuda pompalamak üzere aort damarına ileterek büyük dolaşımı başlatır. Sağ atrium, vücuttan oksijensiz kanı toplar ve sağ ventriküle pompalar. Sağ ventrikül ise bu kanı akciğerlere pompalayarak küçük dolaşımı başlatır. Bu süreç, kanın oksijenlenmesi ve vücuttaki hücrelere dağıtılması için gereklidir [25].



Şekil 2. 1. Kalbin Yapısı [24]

Kalpte toplamda dört valf bulunmaktadır; bunlar sağ ve sol tarafta eşit olarak yerleştirilmişlerdir ve kalp odacıkları içinde kanın tek yönlü akışını sağlarlar. Atriyumlar ile ventriküller arasında bulunanlara AV (atriyoventriküler) valf denir, ventrikül ile çıkış damarları arasında bulunanlara ise yarımay (semilunar) valf adı verilmektedir [26].


Triküspit valf, kalbin sağ tarafındaki üç yaprakçıktan oluşan bir valftir. Bu yaprakçıklar, sağ atrium ile sağ ventrikül arasındaki geçişi kontrol etmektedir. Ventrikül kasıldığında kanın pompalanmasına izin verirken, atriuma geri dönmesini önlemektedir.

Pulmoner valf, sağ ventrikül ile akciğer arteri arasındaki geçişi düzenlemekte ve sağ ventrikül kan pompalandığında açılmaktadır. Akciğerlere giden kanın yola girmesine izin verdikten sonra ventrikül gevşediğinde kapanarak kanın geri gitmesini engellemektedir.

Mitral valf, sol atrium ile sol ventrikül arasındaki geçişi kontrol etmektedir. Sol ventrikül kasıldığında açılır ve oksijenlenmiş kanın vücuda pompalanmasına izin vermektedir. Daha sonra, ventrikül gevşediğinde kapanır ve kanın geri dönmesini önlemektedir.

Aort valf, sol ventrikül ile aort arteri arasındaki geçişi düzenlemektedir. Sol ventrikül kanı ana atardamara pompalandığında açılır ve oksijenlenmiş kanın vücuda dağılmasına izin vermektedir. Daha sonra, ventrikül gevşediğinde kapanır ve kanın geri gitmesini engellemektedir [26, 27]. Bu valfler, kanın kalbin odacıkları arasında tek yönlü hareket etmesini sağlayarak kalbin etkili bir şekilde çalışmasına yardımcı olmaktadır.

Kalbin çalışması, kompleks bir süreçtir ve döngüsel bir modelde gerçekleşmektedir. Bu süreç, kalbin dört odacığının (iki atrium ve iki ventrikül) koordineli olarak kasılarak kanın dolaşımını sağladığı bir dizi adımdan oluşmaktadır.



Şekil 2. 2. Kalp Döngüsü [28]

Kalp döngüsü Şekil 2.2’de gösterildiği gibi, sistol ve diyastol olmak üzere iki ana aşamaya ayrılır;


Sistol aşamasında, kalp kasları kasılarak kanı arterlere pompalamaktadır. Sağ atriumdan gelen oksijen açısından fakir kan, sağ ventriküle geçer ve sağ ventrikül

kasıldığında, bu kanı akciğerlere pompalamaktadır. Akciğerlerde, kan oksijenle doyurulur ve karbon dioksitinden arındırılır.

Diyastol aşamasında ise kalp kasları gevşer ve dolayısıyla kanın kalbe geri dönmesine izin verir. Oksijenlenmiş kan, sol atriuma geri dönerek sol atrium kasıldığında, kan sol ventriküle geçmektedir. Sol ventrikül kasıldığında, bu oksijenlenmiş kan, büyük arter olan aortaya pompalanır. Aorta, vücut boyunca dallanarak kanın tüm dokulara ve organlara taşınmasını sağlamaktadır. Bu süreç, kalbin sürekli olarak atması ve dolaşımın devam etmesiyle gerçekleşmektedir. Kalp döngüsü, bu temel aşamaların sürekli tekrarıyla vücudun ihtiyaçlarına uygun bir şekilde düzenlenir, bu da sağlıklı bir dolaşım sistemi için kritik öneme sahiptir [29].

2.2. Kalp Sesleri

Kalp sesleri, kalp döngüsü sırasında kalp kapakçıklarının açılıp kapanmasıyla kalp odalarından akan kanın oluşturduğu seslerdir [30]. Genellikle, bir kalp döngüsünde Şekil 2.3'te gösterildiği gibi dört kalp sesinden oluşmaktadır.



Şekil 2. 3. Kalp Sesleri [31]

Normal kalp sesleri S1 ve S2 olarak adlandırılan iki temel ses içermektedir. Anormal kalp sesleri ise ek sesler (S3 ve S4) ve üfürümler olarak adlandırılan hışırtı veya sıyrma sesleri şeklinde ortaya çıkmaktadır. Sistolik üfürümler, kalbin kasılma sırasında, diyastolik üfürümler ise kalbin gevşeme sırasında oluşmaktadır. Ek sesler, büyük miktarda kanın hızla ventriküllere dolması veya atriyumların kanı itmesi sırasında meydana gelmektedir [11].

2.2.1.S1 Kalp Sesi

Birinci kalp sesi (S1) aynı zamanda Lub sesi olarak bilinen bir sestir, mitral (M1) ve triküspit (T1) kapakları kapanırken duyulmaktadır [32]. M1 kapanması, T1 kapanmasından 20 – 30 ms önce gerçekleşir ve sol ventrikül ilk kasıldığından dolayı, M1 bileşeni T1 bileşeninden daha erken meydana gelmektedir. Diğer kalp seslerinden daha belirgin bir ses özelliğine ve uzun bir süreye sahiptir. S1'in ortalama süresi 100 ms ile 200 ms arasındadır ve frekans bileşenleri 10–200 Hz aralığındadır [33]. Bir S1 ayrılması, gecikme süresi 30 ms'nin üzerinde ise patolojik olarak kabul edilmektedir.

2.2.2.S2 Kalp Sesi

İkinci kalp sesi (S2) olarak bilinen 'Dub', aort (A2) ve pulmoner (P2) kapakların kapanmasıyla meydana gelmektedir. S2, S1'den daha kısa süreli ve daha yüksek frekansta (50–250 Hz aralığında) bir ses özelliğine sahiptir [34,35]. Aortta, pulmoner arterden daha yüksek bir basınç olduğundan, aort kapağının pulmoner kapağa göre kapanma eğilimi vardır, bu da ikinci kalp sesinde duyulabilir bir ayrılmaya neden olabilmektedir [33]. Soluk verme sırasında gecikme 30 ms'den azdır. S1 ayrılması gibi, eğer aralık 30 ms'nin üzerinde ise, bu patolojik bir durum olarak kabul edilmektedir.

2.2.3.S3 Kalp Sesi

Kalpten gelen üçüncü ses (S3), diyastolün başlangıcında, ikinci sestten 0.1 ile 0.2 saniye sonrasında, hızlı ventriküller dolma aşamasının sonunda meydana gelmektedir. Genellikle düşük frekansta (25 Hz ile 75 Hz arasında) olup normal olarak çocuklarda veya 30 yaşın altındaki yetişkinlerde duyulabilmektedir. Ancak bu yaşın üzerinde, varlığı genellikle patolojik bir durumu ifade eder ve genellikle kalp yetmezliğinin bir belirtisi olan "protodiastolik gallop" olarak adlandırılmaktadır [35].

2.2.4.S4 Kalp Sesi

Dördüncü ses olan S4, normal koşullarda asla duyulmayan bir ses olup, grafik üzerinde 15 Hz ile 75 Hz arasında küçük, düşük frekanslı salınımlarla kendini göstermektedir [35]. Aynı zamanda "atrial gallop" olarak bilinir ve atriyumların kanı sol ventriküle itmek için kasıldığı S1'den hemen önce meydana gelmektedir [36].

2.2.5. Üfürüm (Murmur)


Kalp sesleri, "lub – dub" olarak ifade edilen düzenli ritimlerle birlikte duyulan seslerden ibarettir; ancak, bazı durumlarda bu seslere ek olarak "üfürüm" olarak adlandırılan gürültülü sesler de duyulabilmektedir. Üfürümler, kanın kalp kapakları üzerinde düzensiz akışı sonucu oluşan titreşimlerdir ve bazen bu sesler normal olabilir, bazen ise ciddi bir sağlık sorununu işaret edebilmektedir.

Normal üfürümler genellikle bebeklerde, çocuklarda ve egzersiz sırasında yetişkinlerde duyulabilmektedir. Bunlar genellikle birinci kalp sesi sırasında ortaya çıkmaktadır. Ancak, Anormal üfürümler genellikle kalp kapak defekti olan stenoz (sıkışmış kalp kapakları) ve regürjitasyon (kan sızıntısı olan kalp kapakları) belirtisi olan kalp hastalarında bulunmaktadır [11, 32].

Anormal sesleri de kendi aralarında AS, MS, MVP ve MR kalp sesleri olarak 4'e ayrılmaktadır.

2.2.5.1. AS (Aortik Darlığı) Kalp Sesi:


Aort kapağının daralması, kalbin sol ventrikülünden çıkan kanın düzgün bir şekilde akmasını engellemektedir. Böylece, aort kapağı tam olarak kapanamaz ve sol ventrikül kasıldığında bir miktar kan geriye kaçmaktadır. Bu rahatsızlıkta duyulan kalp sesi, "diastolik üfleme" olarak adlandırılmaktadır ve genellikle aortik bölgede, kalp dinlenme halindeyken duyulan üfleme tarzında bir sestir.



Şekil 2. 4. AS Kalp Sesi

2.2.5.2. MS (Mitral Darlık) Kalp Sesi:


Mitral kapak darlığı, kalbin sol atriyumu ile sol ventrikülü arasındaki mitral kapakta daralma veya sertleşme ile karakterizedir. Bu durumda, sol atriyumdan sol ventriküle kan geçişinde kısıtlama olduğu için, bu daralmadan kaynaklanan özgül bir kalp sesi ortaya çıkmaktadır. Mitral kapak darlığında dinlenen kalp sesi genellikle "diastolik gıcırtı" olarak tanımlanmaktadır.



Şekil 2. 5. MS Kalp Sesi

2.2.5.3. MR (Mitral Yetersizlik) Kalp Sesi:


Mitral yetersizlik, sol atriyumdan sol ventriküle kanın geri kaçtığı bir durumdur. Bu durumda, sol ventrikül kasıldığında, mitral kapak yetersiz olarak kapanır ve kanın bir kısmı geriye kaçmaktadır. Dinlenen kalp sesi genellikle "sistolik üfleme" olarak adlandırılmaktadır.



Şekil 2. 6. MR Kalp Sesi

2.2.5.4. MVP (Mitral Kapak Bozukluğu) Kalp Sesi:

Mitral kapak bozukluğu, mitral kapak yapısının anormal bir biçimde sol atriyum içine doğru sarkması durumudur. Dinleme sırasında “sistolik üfleme” olarak ifade edilen bir kalp sesi duyulabilmektedir. Çoğu zaman zararsız olan bu durum, genellikle tedavi gerektirmemektedir.




Şekil 2. 7. MVP Kalp Sesi

3. MATERYAL VE YÖNTEMLER

Kalp sesleri, kalp kapakçıklarının hareketlerinden kaynaklanan dinamik seslerdir ve bu seslerin özellikleri, hastalıkların tanımlanması ve tedavi yöntemlerinin geliştirilmesi için önemli bir kaynak teşkil etmektedir. Kalp seslerinin hastalıkların teşhisindeki önemi göz önüne alındığında, başarılı bir sınıflandırma modeli geliştirmek için ilk adım, uygun bir veri tabanının oluşturulması veya mevcut veri tabanlarının incelenmesidir. Elde edilen kalp sesleri, öncelikle ön işleme adımlarından geçirilerek normalleştirilmiş ve öznitelik çıkarımı için hazırlanmıştır. Bu çalışma iki farklı veri setini kullanarak bir sınıflandırma modeli geliştirmeyi amaçlamaktadır.

Veri setleri, sağlıklı ve hastalıklı bireylerin kalp seslerini içeren kayıtlardan oluşmaktadır. Metodoloji, veri ön işleme adımları ve sınıflandırma algoritmalarının detaylı bir şekilde açıklanmasıyla birlikte sunulmaktadır.



Şekil 3. 1. Kalp Sesi Analizinin Blok Diyagramı

Şekil 3.1’de verilen kalp seslerinin analizine yönelik blok diyagramında iki farklı veri seti kullanılmıştır. Kullanılan veri setleri, öncelikle çentik filtre ile parazitlerinden arındırılmış, sonrasında eliptik filtre ile filtrelenerek normalizasyon işlemine tabi tutulmuştur. Bu işlemlerin ardından segmentasyon aşamasına geçilmiştir. Segmentasyon aşamasında, normalize edilen seslerin zarfları Shannon enerji yöntemi ile çıkarılmış ve Otsu eşikleme yöntemi ile tepe değerleri belirlenmiştir. Her bir S1 ve S2 sesi bölütlenerek kaydedilen sesler öznelilik çıkarım aşamasına aktarılmıştır.

Öznelilik çıkarımı aşamasında Ampirik Kip Ayrışımı (EMD) ve Mel Frekansı Kepstrum Katsayıları (MFCC) yöntemleri kullanılmıştır. Elde edilen öznelilikler çeşitli makine öğrenmesi modellerine beslenerek analiz edilmiştir. Evrimsel Sinir Ağları (CNN), seslerin segmente edilip spektrogramlarının çıkarılmasıyla doğrudan öznelilik çıkarımı yapmaktadır. Bu çalışmada kullanılan makine öğrenmesi modelleri ise şunlardır: k – En Yakın Komşu (kNN), Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (YSA) ve Evrimsel Sinir Ağları (CNN).

3.1. Veri Setleri

PhysioNet/CinC Challenge 2016 ve Yaseen ile Kwon veri setleri, bu çalışmada kullanılan iki temel veri setidir. Bu iki veri setinin seçimi, geniş çeşitlilikte veri sunmaları, yüksek kaliteli kayıtlar içermeleri, kamuya açık ve erişilebilir olmaları ve literatürde yaygın olarak kabul görmüş olmaları nedeniyle yapılmıştır.

3.1.1. PhysioNet/Computing in Cardiology (CinC) Challenge 2016

PhysioNet/CinC Challenge 2016, yedi bağımsız grup tarafından altı kaynaktan toplanan, 764 sağlıklı birey ve farklı patolojilere sahip hastalardan elde edilen kalp seslerinin en büyük genel kamuya açık veri tabanıdır. Toplamda 3240 kayıt bulunmaktadır. Bu kayıtlar, klinik ve klinik olmayan ortamlarda farklı yaş gruplarından insanlardan alınmıştır [37, 38]. Tüm kaydedilen kalp sesleri normal veya anormal olarak etiketlenmiştir.

Genel olarak, 2575 normal kayıt sağlıklı bireylerle ilişkilendirilirken, 665 anormal ses farklı kardiyovasküler hastalıklardan etkilenen hastalardan kaydedilmiştir. Tüm kayıtların örnekleme frekansı 2000 Hz’dir ve kayıtların süresi 5 saniye ile 120 saniye arasında değişmektedir. Bu veri tabanı ile ilgili daha fazla ayrıntı [39]’da sunulmuştur.

Tablo 3.1. PhysioNet CinC – 2016 Veri Seti

Veri Tabanı	Kaydedilen Sesler		
	Abnormal	Normal	Toplam
Training – a	292	117	409
Training – b	104	386	490
Training – c	24	7	31
Training – d	28	27	55
Training – e	183	1958	2141
Training – f	34	80	114
Toplam	665	2575	3240

3.1.2. Yaseen ve Kwon (Github – PCG)

Yaseen ve arkadaşlarının oluşturduğu veri setidir [11]. Github'ta erişime açık olan bu veri seti, mitral kapak bozukluğu (MVP), mitral kapak darlığı (MS), mitral yetersizlik (MR), aort kapak darlığı (AS) ve Normal olmak üzere beş sınıf için 1000 kayıt içermektedir. Her sınıf için 200 kayıt bulunmakta olup, her kaydın süresi yaklaşık 3 saniyedir. Tüm kayıtların örnekleme frekansı 8000 Hz'dir.

Tablo 3.2. Github – PCG Veri Seti

	Sınıflar	Kayıt Sayısı
Normal	N	200
Abnormal	AS	200
	MR	200
	MS	200
	MVP	200
Toplam		1000

3.2. Ön İşleme

Ön işleme aşaması, biyomedikal sinyal işleme çalışmalarında büyük öneme sahiptir. Bu aşama, verilerin doğru analiz edilebilmesi için gürültüyü azaltma, istenmeyen frekans bileşenlerini filtreleme ve sinyal gücünü dengeleme gibi adımları

içermektedir. Bu süreç, başlangıçta çentik filtre uygulamasıyla başlar, ardından eliptik filtre kullanımıyla devam eder ve son olarak normalizasyon adımıyla tamamlanmaktadır.

3.2.1. Notch (Çentik) Filtre

Notch filtreler, özellikle kalp seslerinin analizi sırasında sıkça karşılaşılan güç hatlarının neden olduğu istenmeyen frekans bileşenlerini etkili bir biçimde filtrelemek amacıyla kullanılmaktadır. Bu filtreleme süreci, sinyalin arka plan gürültüsünü azaltarak temizlenmesine önemli katkıda bulunmaktadır [40].

Notch filtrelerinin temel amacı, belirli frekanslardaki girişimleri bastırmak veya ortadan kaldırmaktır. Özellikle, dar bant veya sinüzoidal girişimler gibi belirli frekanslardaki istenmeyen bileşenleri filtrelemek için kullanılmaktadırlar. Bu, sinyaldeki istenmeyen bileşenleri azaltarak, temel sinyalin daha net bir şekilde analiz edilmesine ve yorumlanmasına olanak tanımaktadır. Güçlü elektriksel etkileşimlerden kaynaklanan güç hatlarının elektrokardiyogram (EKG) gibi biyomedikal sinyal işleme uygulamaları için notch filtrelerinin kullanımı yaygındır. Bu filtreler, özellikle kalp atışlarının kaydedilmesi sırasında güç hatlarının neden olduğu istenmeyen elektriksel etkileşimleri ortadan kaldırmak için önemli bir araçtır.

Notch filtrelerinin tasarımı ve performans analizi için çeşitli yöntemler literatürde incelenmiştir [40]. İki boyutlu durumda, istikrarlı bir IIR (Infinite Impulse Response) iki boyutlu notch filtresinin tasarımının birkaç basit tek boyutlu IIR filtresinin tasarımına indirgenebileceği gözlemlenmiştir. Özellikle, IIR ve FIR (Finite Impulse Response) notch filtrelerinin tasarımı ve performans analizi için birçok yöntem geliştirilmiştir. IIR notch filtresi, dar bant genişliği gerektiren durumlarda tercih edilir, çünkü FIR filtrelerine kıyasla daha az hesaplama yükü gerektirir.

Bu filtreler, biyomedikal sinyal işleme uygulamaları da dahil olmak üzere çeşitli alanlarda kullanılmaktadır ve sinyalin kalitesini arttırarak analiz ve yorumlama süreçlerine önemli katkılar sağlamaktadır.

$$H(z) = \frac{1 - 2 \cos(\omega_0) z^{-1} + z^{-2}}{1 - 2 r \cos(\omega_0) z^{-1} + r^2 z^{-2}} \quad (3.1)$$

Denklem 3.1.'de verilen ω_0 belirli frekans, r ise filtre genişliği kontrol etmek için kullanılan bir parametredir.

3.2.2. Eliptik Filtreleme

Eliptik filtreler, dijital sinyal işleme alanında önemli bir yer tutar ve genellikle alçak geçiren, yüksek geçiren, bant geçiren veya bant söndüren filtreler olarak kullanılmaktadır. Bu filtreler, belirli frekans bantlarını geçiren veya engelleyen elektronik devrelerdir. Özellikle, tıbbi uygulamalarda kalp sesleri gibi düşük frekanslı sinyallerin analizinde sıklıkla kullanılmaktadır.

Eliptik filtrelerin temel özelliklerinden biri, geçirme ve durdurma bantlarında sayıları birbirinden bağımsız olarak değişebilen eş dalga şekilleri içermeleridir. Bu özellik, eliptik filtrelerin diğer yaygın filtre türleri olan Butterworth ve Chebyshev filtrelerinden farklı olmalarını sağlamaktadır [41]. Geçirme bandının daha kısa olması, ideal filtreye daha yakın olmalarını sağlamaktadır.

Eliptik filtrelerin frekans yanıtı, geçirme bandındaki dalga karakteristiği sıfıra yaklaştıkça 2. Tip Chebyshev filtrelerine, durdurma bandındaki dalga karakteristiği sıfıra yaklaştıkça ise 1. Tip Chebyshev filtrelerine benzerlik göstermektedir. Her iki banttaki dalga karakteristiği sıfıra yaklaştığında ise, Butterworth filtrelerine dönüşmektedir [42]. Matematiksel tanım olarak Denklem 3.2’de, eliptik filtrelerin kazanç fonksiyonu üzerinden tanımlandığı görülmektedir.

$$G = \frac{1}{\sqrt{1^2 + \varepsilon^2 + R_n^2(\xi, (\omega/\omega_0))}} \quad (3.2)$$

Bu denklem, kesim frekansını, dalga karakteristiğini ve diğer parametreleri içermektedir. Özellikle, ε dalga katsayısı, geçirme bandındaki dalga karakteristiğini belirlerken, ξ seçicilik katsayısı, durdurma bandındaki dalga karakteristiğini belirlemektedir.

Eliptik filtrelerin kalp sesleri gibi düşük frekanslı sinyallerin analizinde etkili bir şekilde kullanılabileceği görülmektedir. Bu, filtrelerin istenilen özellikleriyle uyumlu olmasını sağlamak ve elde edilen sonuçların güvenilirliğini artırmaktadır.

3.2.3. Normalizasyon

Normalizasyon, veri setindeki değerlerin belirli bir aralığa veya dağılıma ölçeklendirilmesi işlemidir. Bu işlem, veri setinin daha kolay anlaşılmasını,

işlenmesini ve karşılaştırılmasını sağlamaktadır. Genellikle, veri setinin ortalaması sıfır ve standart sapması bir olacak şekilde ölçeklendirilmektedir. Böylece, veri setindeki farklı özelliklerin doğru bir şekilde karşılaştırılması ve analiz edilmesi mümkün olmaktadır [43, 44].

Kalp sesi sinyalleri için normalizasyon, bölütlenme işlemine başlamadan önce filtrelenmiş kalp sesi sinyaline ön bir işlem uygulanması gereken bir adımdır. Normalizasyon işlemi, toplanan verilerin nasıl toplandığı ve ölçüldüğünden bağımsız bir adımdır ve kalp seslerinin zaman alanında karşılaştırılabilir hale getirilmesine yardımcı olmaktadır. Bu işlemi, sinyalin genliğini, sinyalin maksimum mutlak değerine bölerek gerçekleştirilmektedir. Denklem 3.3'te olduğu gibi:

$$x_{norm}[filtrelenen_ses] = \frac{x[filtrelenen_ses]}{\max(|x[filtrelenen_ses]|)} \quad (3.3)$$

Burada $x_{norm}[filtrelenen_ses]$ normalize edilmiş sinyali, $x[filtrelenen_ses]$ ise eliptik filtre ile filtrelenmiş sinyali temsil etmektedir. Normalizasyon işleminde her bir zaman noktasındaki sinyal değerini, sinyalin maksimum mutlak değerine bölerek sinyali 1 veya -1 arasında bir aralığa normalleştirir. Bu sayede, farklı kaynaklardan gelen veya farklı ölçeklerde kaydedilmiş kalp sesi sinyalleri karşılaştırılabilir hale gelmektedir [45].

3.3. Bölütlenme (Segmentasyon)

Segmentasyon işlemi, veri setlerini, görüntüleri veya sinyalleri daha anlamlı ve işlenebilir parçalara ayırarak verinin daha iyi anlaşılmasını ve analiz edilmesini sağlayan bir yöntemdir. Bu teknik, belirli analizler yapmak, nesneleri tanımlamak veya problemlere çözümler geliştirmek için yaygın olarak kullanılmaktadır. Özellikle tıbbi alanlarda, örneğin kalp rahatsızlıklarının incelenmesinde, segmentasyonun önemi büyüktür.

Kalp sesi sinyalinin analizi, özellikle hastalık teşhisinde kritik bir rol oynamaktadır. Kardiyak döngü içinde yer alan S1 ve S2 kalp seslerinin doğru bir şekilde belirlenmesi, temel kalp seslerinin otomatik tanımlanması açısından hayati öneme sahiptir. Üfürüm sınırlarının net bir şekilde tespit edilebilmesi için, S1 ve S2 kalp seslerinin kesin olarak belirlenmesi gerekmektedir [45].

Bu çalışmada, Shannon enerji tabanlı ve Otsu eşikleme yöntemleri kullanılarak bir segmentasyon yöntemi uygulanmıştır. Shannon enerji yaklaşımı, kalp seslerinin enerjisini analiz ederek, S1 ve S2 seslerinin daha doğru bir şekilde segmentasyonunu sağlamaktadır. Böylece, kalp sesi sinyallerinin ayrıntılı bir analizini mümkün kılarak, hastalık teşhisinde önemli bir katkı sunmaktadır.

3.3.1. Shannon Enerji


Shannon enerjisi, sinyalin anlık genlik değerlerinin mutlak değeri olarak hesaplanmaktadır ve bu sayede yüksek yoğunluktaki alanlardaki vurguyu artırarak düşük değerli gürültünün etkisini azaltmaktadır [46]. PhysioNet CinC – 2016 veri seti ve Github – PCG üzerinde hesaplanan Shannon enerjisinin zarfı (envelope) Şekil 3.2’de gösterilmektedir. Shannon enerjisi hesaplaması aşağıdaki Denklem 3.4 ile gerçekleştirilmektedir:

$$E(t) = -s(t)^2 \cdot \log s(t)^2 \quad (3.4)$$

Denklem 3.4’te $E(t)$ sinyalin Shannon enerjisini temsil ederken, $s(t)$ ise normalize edilmiş kalp sesini ifade etmektedir. Denklem, sinyalin negatif y eksenini boyunca doğrultulması ve ardından karesinin alınmasıyla başlamakta ve sinyalin karesinin logaritması alınarak işlem tamamlanmaktadır.

İşlem sonucunda elde edilen değer, sinyalin enerji dağılımını yansıtan bir ölçüdür. Bu formülasyon, sinyalin özelliklerini vurgulamak ve gürültüyü bastırmak için etkili bir yöntem olarak bilinmektedir.

Shannon enerjisi, orta enerjili sinyali daha etkin bir şekilde vurgulamaktadır, düşük ve yüksek yoğunluktaki sinyalleri zayıflatmaktadır, bu da gürültüyü bastırmaya yardımcı olur; bu nedenle gelecekteki çoğu uygulama tarafından kullanılmaktadır [46, 47].



Şekil 3. 2. PhysioNet CinC – 2016: (a) Normal Kalp Sesi; (b) Anormal Kalp Sesi; Github – PCG: (c) Normal Kalp Sesi; (d) MVP Hasta Kalp Sesi; (e) AS Hasta Kalp Sesi; (f) MR Hasta Kalp Sesi; (g) MS Hasta Kalp Sesi

3.3.2. Otsu Eşikleme Yöntemi

Otsu'nun yöntemi, bilgisayar görüşü ve görüntü işleme alanında yaygın olarak kullanılan bir otomatik histogram tabanlı görüntü eşikleme yöntemidir. Bu yöntem, Nobuyuki Otsu tarafından geliştirilmiştir [47]. Otsu eşikleme yöntemi, bir veri kümesini iki sınıfa bölmek için eşik seçmektedir ve böylece sınıf içi varyansı minimize etmektedir. Bu eşikleme yönteminin diğer yöntemlerden farkı segmentasyon algoritmasını basitleştirir ve önerilen algoritmanın hesaplama karmaşıklığını azaltmaktadır [48].

Shannon enerji ile zirveler tespit edildikten sonra, yanlış tespit edilen zirveler ve gürültülü zirveler varsa, bunlar daha fazla analiz için elenmektedir. Son aşamada, tanımlanan zirveler, her birinin enerjisine dayalı olarak S1 ve S2 olarak sınıflandırılmaktadır.

Otsu eşikleme yöntemine göre, bir sinyalin veri noktaları L farklı seviyede temsil edilmektedir $[1, 2, \dots, L]$. L , sinyalin maksimum değerinden daha büyüktür [48]. Her seviyede bulunan veri noktalarının sayısı n_i olarak gösterilmektedir ve toplam veri noktalarının sayısı Denklem 3.5'teki gibidir.

$$N = n_1 + n_2 \dots + n_L \quad (3.5)$$

Ardından, sinyal K değerinde bir eşikle iki sınıfa C_0 ve C_1 bölünür; C_0 , seviyeleri $[1, \dots, k]$ olan verileri ifade ederken, C_1 , seviyeleri $[k+1, \dots, L]$ olan verileri ifade etmektedir. K değerini elde etmek için aşağıdaki adımlar izlenir:

1. Her yoğunluk seviyesinin histogramı Denklem 3.6'da verilmiştir. Bu denklem her bir yoğunluk seviyesi p_i için, veri setindeki toplam veri noktalarına oranını temsil etmektedir; bu oran, veri noktalarının belirli bir yoğunluk seviyesine sahip olma olasılığını ifade etmektedir. N ise toplam veri noktalarının sayısını temsil etmektedir.

$$p_i = \frac{n_i}{N} \quad i = 1, 2, \dots, L \quad (3.6)$$

2. Denklem 3.7 ve Denklem 3.8'de sınıf olasılıklarının ve ortalama seviyelerin hesaplanması gösterilmiştir. Sınıf oluşum olasılıklarını ve sınıf ortalamalarını hesaplamak için kullanılmaktadır $\omega_{\mu,v}$, μ ve v sınıflarının oluşum olasılıklarını ifade ederken, $\omega_{\mu,v,T}$, ilgili sınıfların ortalama seviyelerini belirtmektedir. $n_{\mu,v}$ ilgili sınıflardaki veri noktalarının sayısını,

$$\omega_{\mu,v} = \frac{n_{\mu,v}}{N} \quad (3.7)$$

$$\omega_{\mu,v,T} = \sum_{i=1}^L i \cdot p_i \quad (3.8)$$

3. Sınıf varyansları Denklem 3.9'daki gibi belirlenmektedir ve $\sigma_{\mu,v}^2$ ilgili sınıfların varyanslarını temsil ederken, σ_{ω}^2 sınıfların iç varyansını ağırlıklı toplam olarak belirtmektedir. σ_{μ}^2 ve σ_v^2 sırasıyla μ ve v sınıflarının varyanslarını ifade etmektedir.

$$\sigma_{\omega}^2 = \omega_{\mu} \sigma_{\mu}^2 + \omega_v \sigma_v^2 \quad (3.9)$$

4. Sınıflar arasındaki farklılık veya ayrılığı ölçmek için Denklem 3.10 kullanılmaktadır. σ_B^2 , sınıflar arasındaki ortalama farklarının karelerini, ilgili sınıfların oluşum olasılıklarıyla çarparak hesaplanmaktadır. $\mu_{v,T}$ ve $\mu_{\mu,T}$ ilgili sınıfların ortalamalarını ifade etmektedir.

$$\sigma^2_B = \omega_\mu \omega_v (\mu_{v,T} - \mu_{\mu,T})^2 \quad (3.10)$$

5. Optimal eşik değerinin bulunması ise tüm olası eşik değerleri K_i adım adım geçilir ve maksimum yoğunluk σ^2_B 'ı güncellenerek bulunmaktadır.

3.4. Öznitelik Çıkarım Yöntemleri

Kalp seslerinin segmentasyonundan elde edilen ses sinyallerinin özellikleri, zaman, frekans ve zaman – frekans eksenlerinde eş zamanlı olarak incelenmek üzere öznitelik çıkarım yöntemleriyle analiz edilmiştir. Öznitelik çıkarım yöntemleri, giriş verisini minimum sayıda öznitelikle yüksek doğrulukla tanımlamayı hedefler [41, 49]. Bu çalışmada kullanılan öznitelik çıkarım yöntemleri ve öznitelik vektörlerinin boyutunu azaltmak için kullanılan Temel Bileşen Analizi (PCA) yöntemi aşağıda detaylı olarak açıklanmıştır. Tablo 3.3'te bu çalışmada kullanılan öznitelik çıkarım yöntemleri ve kullanılan parametreler detaylı olarak sunulmuştur.

Tablo 3.3. Öznitelik Çıkarım Yöntemleri ve Kullanılan Parametreler

Öznitelik Çıkarım Yöntemleri	Kullanılan Parametreler
Mel Frekansı Kepstrum Katsayıları	PhysioNet CinC – 2016: Mel Frekansı Kepstrum Katsayılarını elde ederken kullanılan ön vurgu katsayısı $\alpha=0,97$ olarak belirlenmiştir. Analiz pencere uzunluğu 50 ms ve pencere kaydırma miktarı ise 10 ms şeklinde Hamming pencereleri kullanılmıştır. 13 tane Kepstral Katsayısı ise sınıflama da kullanılmıştır.
	Github – PCG: Mel Frekansı Kepstrum Katsayılarını elde ederken kullanılan ön vurgu katsayısı $\alpha=0,97$ olarak belirlenmiştir. Analiz pencere uzunluğu 24 ms ve pencere kaydırma miktarı ise 10 ms şeklinde Hamming pencereleri kullanılmıştır. 13 tane Kepstral Katsayısı ise sınıflama da kullanılmıştır.
Ampirik Mod Ayrışımı	Kullanılan iki veri setinde de öznitelik çıkarım için IMF kat sayısı 5 olarak kullanılmıştır. Durdurma kriteri $SD= 0,25$ olarak belirlenmiştir.

3.4.1. Ampirik Kip Ayrışımı (EMD)

Doğrusal olmayan ve durağan olmayan doğal sinyallerin analizinde kullanılan bir adapte yöntemdir. Fourier Analizi ve dalgacık dönüşümü gibi zaman ekseninden ayrılmadan sinyalin yüksek ve düşük frekanslı bileşenlerini tespit etmektedir [50]. Bu yöntem, Fourier ve dalgacık dönüşümlerinden daha etkili bir analiz sağlamaktadır; çünkü yüksek frekanslı bileşenlerden düşük frekanslı bileşenlere doğru sıralanan farklı frekanslardaki İçsel Mod Fonksiyonlarına (IMF) ayrıştırılmaktadır. Bir IMF aşağıdaki iki temel koşulu sağlamalıdır:

1. Uç noktasının (Ekstremler) sayısı ve sıfır geçiş sayısı, birbirine eşit veya 1 farkla farklı olmalıdır.
2. Yerel maksimumlar tarafından tanımlanan zarf ve yerel minimumlar tarafından tanımlanan zarfın ortalama değeri, herhangi bir noktada sıfır olmalıdır [51]. Böylece, bir IMF, sinyale gömülü basit bir salınımlı modu temsil etmektedir.

IMF'ler, sinyaldeki bileşenlerin eleme (shifting) işlemiyle elde edilmektedir. Bir $x(t)$ sinyali eleme işlemi aşağıdaki adımlardan oluşmaktadır [41]:

1. $x(t)$ sinyalinin tüm yerel minimum ve yerel maksimum noktaları belirlenir.
2. Eğri ara değerlendirme (Kübik spline interpolasyon) kullanılarak, yerel maksimum noktalarıyla üst $e_{max}(t)$ ve yerel minimum noktalarıyla alt zarf $e_{min}(t)$ hesaplanır.
3. Yerel maksimum noktası olan üst zarf ve yerel minimum noktası olan alt zarf ortalaması $m_1(t) = [e_{min}(t) + e_{max}(t)]/2$ olarak hesaplanır.
4. Giriş sinyalinden çıkarılarak $h_1(t) = x(t) - m_1(t)$ bulunur.
5. $h_1(t)$ 'nin IMF olma şartlarını sağlama durumu kontrol edilir. Eğer sağlanıyorsa, $IMF_1(t) = h_1(t)$ olarak kabul edilir.
6. Eğer $h_1(t)$ yukarıda belirtilen IMF olma şartlarını sağlamazsa, yeni bir sinyal olarak kabul edilir ve adım 1 – 5'te $h_2(t)$ oluşturmak için $h_1(t)$ üzerinden yeniden hesaplanır. Eğer $h_2(t)$ IMF olma şartlarını sağlamazsa, eleme işlemini durdurmak için bir standart sapma olan durdurma kriteri Denklem 3.11'deki gibi hesaplanır.

$$Standart\ Sapma(i) = \sum_{t=0}^N \frac{|h_{i-1}(t) - h_i(t)|^2}{h_{i-1}^2(t)} \quad (3.11)$$

Standart sapma değeri genellikle 0,2 ile 0,3 arasında bir değere sahiptir. Eğer $h_2(t)$ standart sapma kriterini sağlarsa, $IMF_1(t) = h_2(t)$ olur. Eğer $h_2(t)$ IMF veya standart sapma kriterlerini sağlamazsa, $h_2(t)$ yeni bir sinyal olarak kabul edilir. Ardından, adım 1 – 6 boyunca, $h_i(t)$ IMF veya standart sapma kriterlerini sağlayıncaya kadar $h_i(t)$ oluşturmak için $h_2(t)$ üzerinden işlemler tekrarlanır ve $IMF_1(t) = h_i(t)$ olarak hesaplanır.

7. $IMF_1(t)$ elde edildikten sonra, bu bileşen $x(t)$ sinyalinden çıkarılarak artık $r_1(t)$ elde edilir. Daha sonra, $r_1(t)$ orijinal sinyal olarak kabul edilir ve adım 1 – 6 tekrar edilir. Bu tekrarlar sonucunda artık sinyaller, $r_n(t) = r_{n-1}(t) - IMF_n(t)$ şeklinde monoton bir dizi olarak ifade edilir. Eleme işlemi tamamlandığında, orijinal sinyalde bulunan birçok IMF bileşeni ve artık sinyalden oluşan $r_n(t)$ şu şekilde ifade edilebilir;


$$x(t) = \sum_{i=1}^n IMF_i(t) + r_n(t) \quad (3.12)$$

3.4.2. Mel Frekansı Kepstrum Katsayıları (MFCC)

Ses, insanlar için iletişimin temel taşlarından biridir ve çağdaş teknolojinin birçok alanında önemli bir rol oynamaktadır. Sesin dijital olarak analizi ve işlenmesi, konuşma tanıma, müzik sınıflandırma, ses tabanlı güvenlik sistemleri gibi birçok uygulama için kritik öneme sahiptir. Bu ses analizi işlemlerinde kullanılan temel araçlardan biri de Mel frekansı kepstrum katsayıları olarak adlandırılan bir yöntemdir. MFCC, ses sinyallerinin temsil edilmesi ve analiz edilmesi için sıklıkla kullanılan bir öznetelik çıkarım yöntemidir. Bu yöntem, insan kulağının ses frekanslarını algılama biçimine dayanarak tasarlanmaktadır. Şekil 3.3'te Mel frekansı kepstrum katsayılarının tespiti için izlenen adımlar blok diyagram ile gösterilmektedir.

MFCC metodu, öncelikle ses sinyalindeki önemli özellikleri vurgulayan bir ön işlem olan ön vurgulama, ardından sinyalin parçalara bölünüp frekans alanına dönüştürülmesini sağlayan Hızlı Fourier Dönüşümü (FFT) gibi adımları içermektedir. Daha sonra, Mel filtre bankasından geçirilerek sinyalin frekans bileşenleri insan işitme sisteminin algılamasına daha uygun bir biçimde temsil edilmektedir ve bu temsil logaritmik ölçeğe işlenmektedir.

Son olarak, DCT ile sinyal yeniden zaman alanına çevrilerek Mel frekansı kepsral katsayıları elde edilmektedir [46].



Şekil 3. 3. MFCC Blok Diyagramı

Ön vurgulama işlemi, spektral düzleştirmeyi ve olası etkilere duyarlılığın azaltılmasını amaçlayarak sinyalin çerçeveleme öncesi işaretini düzenlemektedir. Bu adım, segmente edilen giriş sinyalini Eliptik filtreden geçirerek gerçekleştirilmektedir. Ön vurgulama işleminin matematiksel denklemi Denklem 3.13'te tanımlanmaktadır.

$$y(t) = x(t) - \alpha * x(t - 1) \quad (3.13)$$

$y(t)$ ön vurgulama sonrası çıkış sinyalini, $x(t)$ ise giriş sinyalini temsil etmektedir. α ön vurgulama katsayısı olup 0,9 ile 1 arasında değişiklik göstermektedir [52]. Bu çalışmada α katsayısının değeri 0,97 olarak seçilmiştir.

Çerçeveleme işlemi, sürekli bir ses sinyalini sabit zaman aralıklarında örneklenmiş küçük parçalara bölmektedir. Belirli bir süre boyunca ses sinyalinin bir kesitini temsil etmektedir ve ses sinyalinin zaman – frekans özelliklerini analiz etmek için daha uygun hale getirilmesini sağlamaktadır. Ayrıca, bu işlem sonraki adımlar için sinyalin daha küçük ve yönetilebilir parçalara ayrılmasını kolaylaştırmaktadır. Genellikle, çerçeveler 20 ila 40 milisaniye (ms) arasında bir uzunluğa sahiptir ve ardışık çerçeveler birbirleriyle örtüşmektedir. Örtüşme oranı çerçeve uzunluğunun %50'si ile %75'i arasında değişmektedir [41,46].

Pencereleme işlemi, her bir çerçevenin belirli bir pencere işlevi ile çarpılarak sinyalin kenar efektlerinin azaltılmasını sağlamaktadır. Bu yöntem, spektral bozulmaları azaltarak doğru sonuçların elde edilmesine katkıda bulunmaktadır. Yaygın olarak kullanılan pencere fonksiyonları arasında Hamming, Hanning, Blackman – Harris, Gauss, dikdörtgen ve üçgen gibi çeşitli seçenekler bulunmaktadır. Bu çalışmada kalp sesleri PhysioNet veri seti için 50 ms, Github veri seti için 24 ms uzunluklu Hamming pencere fonksiyonu kullanılarak pencerelenmiştir. Hamming pencere fonksiyonu Denklem 3.14 ve 3.15'te tanımlanmıştır.

$$Y(n) = X(n) \times W(n) \quad (3.14)$$

$$W(n) = 0.54 - 0.46 \times \cos\left(\frac{2\pi n}{N-1}\right) \quad (3.15)$$

$Y(n)$ çıkış sinyalini, $X(n)$ giriş sinyalini ve $W(n)$ ise Hamming penceresini temsil etmektedir. Hamming penceresi, sinyal değerlerini 0.54 ve 0.46 katsayıları ile ağırlıklı olarak sıfıra doğru çekmektedir [41].

Hızlı Fourier Dönüşümü (FFT) ile zaman eksenindeki pencerelenen bir sinyal frekans eksinine dönüştürülmektedir. FFT işlemi matematiksel olarak Denklem 3.16'da ifade edilmektedir.

$$X(k) = \sum_{n=0}^{N-1} x_w[n] * e^{-\frac{2\pi jkn}{N}}, \quad k = 0, 1, 2, \dots, N-1 \quad (3.16)$$

Pencereleme adımından sonra elde edilen çerçeve, $x[n]$ olarak ifade edilmekte ve burada $n = 0, 1, 2, \dots, N-1$ çerçevenin zaman içindeki örnekleme noktalarını temsil etmektedir. Her çerçeve $w[n]$ pencereleme işleviyle çarpılarak pencerelenmiş çerçeve $x_w[n]$ elde edilmektedir. $X(k)$ FFT sonucu olan frekans bileşenlerini, N çerçevenin uzunluğunu, e Euler sabitini ve j kompleks sayı birimini ifade etmektedir.

Mel filtre bankası işlemi, pencerelenmiş çerçevelerin FFT ile elde edilen genlik spektrumuna bir dizi üçgen filtre uygulanmasıdır. Üçgen filtreler ile güç spektrumunu belirli frekans bant aralıklarına dönüştürülür ve her bant aralığına düzgün bir şekilde dağılmış üçgen filtreler eklenerek bu filtreler mel filtre bankasına eşlenmektedir. Bu işlem ile sinyalin Mel spektrumu elde edilmektedir. Mel ölçeği, frekansı 1 kHz olan bir sesi 1000 mel olarak tanımlamaktadır ve 1 kHz'ye kadar doğrusal, sonrasında ise logaritmik olarak değişen aralıklardan oluşmaktadır. Bu sayede Mel ölçeğiyle

belirlenen kepstum katsayıları elde edilmektedir. Mel ölçeğinin matematiksel denklem karşılığı Denklem 3.17’de verilmiştir.

$$Mel(f) = 2595 \log\left(1 + \frac{f}{700}\right) \quad (3.17)$$

Ayrık kosinüs dönüşümü (DCT) işlemi, logaritmik mel ölçeğindeki veriler zaman ortamına aktarılması ile gerçekleşmektedir. Bu işlem sonucunda Mel Frekansı Kepstrum Katsayıları elde edilmektedir ve MFCC katsayıları, elde edilen sinyalin logaritması alınarak belirlenen filtre sayısı ve çerçevelerin üzerine uygulanmaktadır.

3.4.3. Temel Bileşen Analizi (PCA)

PCA, çok değişkenli istatistik alanında yaygın olarak kullanılan bir yöntemdir. Veri setinin varyansını en yüksek olan değişkenleri belirleyerek, bu değişkenler arasındaki ilişkileri ifade eden temel bileşenler bulunur. Bulunan temel bileşenler orijinal veri setinin çeşitli boyutlarını temsil etmektedir ve verinin içerdiği ana yapıyı açıklamak için kullanılmaktadır.

PCA'nın temel amacı, yüksek boyutlu veri setlerinde verinin karmaşıklığını azaltmak ve verinin önemli özelliklerini vurgulayarak daha az değişkenle ifade edebilmektir. PCA, verinin özünü yakalamak için veri setinin kovaryans matrisini kullanmaktadır. İlk adımda, veri seti merkezlenir, yani her bir değişkenin ortalaması sıfıra getirilmektedir. Daha sonra, kovaryans matrisinin özdeğerleri ve özvektörleri hesaplanmaktadır. Bu özvektörler, yeni koordinat sisteminin yönlerini temsil ederken, özdeğerler bu yönlerdeki veri varyansını ifade etmektedir. En yüksek özdeğere sahip özvektörler, verinin en büyük varyansını açıklayan temel bileşenlerdir.

3.5. Sınıflama Yöntemleri

Kalp seslerinin sınıflandırılması, makine öğrenimi ve derin öğrenme tekniklerinin kullanımıyla gerçekleştirilen önemli bir alandır. Tablo 3.4’te bu çalışmadaki, k – En Yakın Komşu (kNN), Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (ANN) ve Evrişimli Sinir Ağları (CNN) gibi çeşitli sınıflandırma yöntemleri ve kullanılan parametreler gösterilmiştir.

Tablo 3.4. Sınıflama Yöntemleri ve Kullanılan Parametreler

Sınıflama Yöntemleri	Kullanılan Parametreler
CNN	Segmente edilen seslerin spektrogram görüntüleri kaydedilerek 227x227 boyutuna dönüştürülmüştür. Bu sınıflama yönteminde, önceden eğitilmiş AlexNet mimarisi temel alınarak özelleştirilmiş ve eğitilmiştir. Eğitim sürecinde, adam optimizasyon algoritması kullanılmıştır.
ANN	İki veri seti için Esnek Geri Yayılımlı (RPROP) öğrenme algoritması ve üç gizli katman kullanılmıştır. Her iki öznitelik çıkarım için de gizli katmanlardaki nöron sayısı sırasıyla 45, 60 ve 30 olarak belirlenmiştir. Her katmanda aktivasyon fonksiyonu olarak tanjant sigmoid fonksiyon kullanılmıştır. Verilerin %80'i eğitim %20'si ise test kümesi olarak seçilmiştir.
SVM	PhysioNet CinC – 2016: EMD öznitelikleri için doğrusal Kernel fonksiyonu kullanılırken, MFCC öznitelikleri için 2. Dereceden Polinom Kernel fonksiyonu kullanılmıştır. Verilerin %80'i eğitim %20'si ise test kümesi olarak seçilmiştir.
	Github – PCG: Bu sınıflama yönteminde çoklu sınıflama metodu ile her iki öznitelik çıkarım için 3. Dereceden Polinom Kernel fonksiyonuna sahip SVM sınıflandırıcısı kullanılmıştır.
kNN	PhysioNet CinC – 2016: İlk olarak, EMD ile çıkarılan öznitelikler PCA kullanılarak boyut indirgemeye tabi tutulmuş ve %95 varyansı açıklayan 8 bileşen seçilmiştir. Bu bileşenler k=3 ve kfold=10 katlı çapraz doğrulama parametreleri kullanılmıştır. Benzer şekilde, MFCC ile çıkarılan öznitelikler PCA ile %90 varyansı açıklayan 6 bileşene indirgenmiş ve aynı kNN parametreleri kullanılmıştır.
	Github – PCG: EMD ile çıkarılan öznitelikler PCA kullanılarak boyut indirgemeye tabi tutulmuş ve %95 varyansı açıklayan 17 bileşen seçilirken MFCC ile çıkarılan öznitelikte 19 bileşen seçilmiştir. Bu bileşenler k=3 ve kFold=10 katlı çapraz doğrulama parametreleri kullanılmıştır.

3.5.1.k – En Yakın Komşu Algoritması (kNN)

Kalp seslerini sınıflandırmak için basit ancak etkili olan bir yöntemdir. kNN algoritması, birbirine yakın olan örnekleri sınıflandırmayı temel almaktadır. Algoritmanın amacı, daha önce sınıflandırılmış örnekleri kullanarak yeni bir örneği sınıflandırmaktır. kNN sınıflandırma algoritması sürecindeki adımlar;

1. k değeri belirlenerek,
2. Her bir test veri noktası için tüm eğitim veri noktalarına olan yakınlık mesafesi hesaplanmaktadır.
3. Ardından, k en yakın veri noktası incelenip en sık görülen sınıflar belirlenir,
4. Yeni veri o sınıfa atanmaktadır.

Yakınlık hesabı için farklı metrikler arasında Manhattan, Hamming, Öklid ve Minkowski gibi uzaklık denklemleri bulunmaktadır. İki nokta arasındaki doğrusal uzaklığı hesaplamayı sağlayan Öklid uzaklığı, genellikle en çok tercih edilen uzaklık denklemdir. Öklid uzaklığı Denklem 3.18'deki gibi formülize edilmektedir.

$$d(x_0, x_i) = \sum_{i=1}^k (x_0 - x_i)^2 \quad (3.18)$$


Burada $d(x_0, x_i)$, x_0 'ın sınıflandırılacak yeni bir örneği ve x_0 'ın en yakın k komşularından olan x_i 'nin arasındaki Öklid mesafesidir.

3.5.2. Destek Vektör Makineleri (SVM)

Destek Vektör Makineleri, Vladimir Vapnik tarafından 1992 yılında geliştirilen bir makine öğrenimi yöntemidir [53]. Bu denetimli öğrenme algoritması, sınıflandırma problemlerini çözmek için kullanılmaktadır. Giriş verileri, her bir öznelik boyutuna uygun olarak bir n boyutlu uzayda konumlandırılmaktadır. Sonrasında, iki sınıfı net bir şekilde ayıran bir düzlemle sınıflandırma işlemi gerçekleştirilmektedir.

Bu düzlem, karar düzlemi olarak adlandırılmakta ve farklı sınıf üyelerini birbirinden ayırmaktadır. Sınıfları ayıran birçok olası lineer düzlem bulunmasına rağmen, SVM en yakın veri noktaları arasındaki mesafeyi maksimize eden tek bir ayırıcı düzlem belirlemektedir. Sınıf üyelerinin arasındaki maksimum mesafeyi belirlemek amacıyla bir karar düzlemi tespit etmektedir. Eğitim verileri analiz edilerek ortaya çıkarılan bu düzlemler, test verilerinin hangi bölümünde yer aldığına bağlı

olarak veri sınıflandırmasını sağlamaktadır. Şekil 3.4'te Destek Vektör Makinelerinin genel yapısı verilmektedir.



Şekil 3. 4. SVM Ağ Yapısı [41]

Destek Vektör Makineleri, veri setinin doğrusal olarak ayrılabilir olup olmadığına bağlı olarak doğrusal ve doğrusal olmayan sınıflandırıcılar olarak iki kategoriye ayrılmaktadır.


Doğrusal SVM'ler, veri setinin hiper – düzlem ile doğrusal olarak ayrılabilir olduğu durumlar için kullanılmaktadır. Bu durumda, veri noktaları bir düzlemde veya uzayda bir doğruyla ayrılabilir. SVM, bu doğruyu bulmak için veri noktaları arasındaki maksimum marjı optimize ederek, sınıflar arasında net bir ayrım yapılabilir.

Doğrusal olmayan SVM'ler, veri setinin doğrusal olarak ayrılabilir olmadığı veya doğrusal bir sınırın veri setini doğru şekilde ayıramayacağı durumlarda kullanılmaktadır. Doğrusal, polinom, sigmoid ve radyal tabanlı fonksiyon gibi farklı Çekirdek (Kernel) fonksiyonları mevcuttur. Kernel fonksiyonları kullanarak veri uzayını daha yüksek boyutlara genişleterek veri setini daha iyi ayıran karmaşık ve eğri bir sınır oluşturmaktadır.

3.5.3. Yapay Sinir Ağları (ANN)

Yapay Sinir Ağları, biyolojik sinir ağlarının yapısal ve işlevsel özelliklerinden ilham alarak tasarlanmış bilgisayar sistemleridir. Bu sistemler, çeşitli karmaşıklıkta problemleri öğrenme ve tanıma kapasitesiyle ele alabilen, geniş bir uygulama yelpazesine sahip karmaşık ve esnek yapılardır. ANN'ler, veri analitiği, desen tanıma,

sınıflandırma, tahmin, optimizasyon ve kontrol gibi disiplinlerde kullanılmaktadır. Katmanlar halinde örgütlenen ANN'ler, birbirleriyle etkileşimli bir şekilde çalışan yapay sinir hücrelerinden meydana gelmektedirler.



Şekil 3. 5. Yapay Sinir Ağı Hücresi


Sinir ağları, dış ortamdan ya da diğer sinir hücrelerinden alınan verileri taşıyarak nöronlara girişler ($x_1, x_2, \dots, x_n$) olarak iletilmektedir. Girişlerin sinir hücresi üzerindeki etkisi, her bir girişin önemine göre değişen ağırlık ($w_{1j}, w_{2j}, \dots, w_{nj}$) katsayılarıyla belirlenmektedir. Bu ağırlıklar, toplama işlemi sırasında her girişle çarpılarak toplanır ve belirli bir eşik değeriyle (b_j) toplanarak aktivasyon işlemine tabi tutulmaktadır. Ardından, ağırlıklandırılmış girişler, çıkışa iletilmeden önce belirli bir aktivasyon fonksiyonundan geçirilmektedir. Bu aktivasyon fonksiyonu, ağın özelliklerine bağlı olarak değişiklik gösterebilir; tanjant hiperbolik, parçalı lineer veya logaritmik gibi çeşitli fonksiyonlar kullanılabilir.

Yapay Sinir Ağları, temel olarak ileri beslemeli ve geri beslemeli yapılar olmak üzere ikiye ayrılmaktadır. İleri beslemeli ağlarda, veriler sadece giriş hücrelerinden çıkış hücrelerine tek yönlü olarak aktarılmaktadır. Bu ağ yapısında gecikme olmaz ve doğrusal olmayan eşlemeler için tahmin yapmak amacıyla kullanılmaktadır. İleri beslemeli yapay sinir ağında, hedeflenen çıkış değeri ile ağın ürettiği çıkış değeri karşılaştırılır ve bu karşılaştırmanın sonucu olarak elde edilen hata verisi ile sistemin ağırlıkları güncellenmektedir.

Geri beslemeli ağlarda ise, çıkış ve gizli katmanlardaki çıkışlar giriş katmanına veya önceki gizli katmanlara geri beslenmektedir. Bu modelde geri besleme, ağın eğitimini geciktirmektedir. Hopfield, Kohonen ve Anderson ağları geri beslemeli ağlara örnek olarak gösterilebilir.

Yapay sinir ağlarında öğrenme süreci, ağdaki sinir hücreleri arasındaki bağlantı güçlerini soruna uygun çözümler üretecek şekilde ayarlanmasıdır. Bu süreçte, istenilen çözüme ulaşmak için sinir hücreleri arasında yeni bağlantılar kurulabilir, mevcut bağlantılar kaldırılabilir veya var olan bağlantıların ağırlıkları değiştirilebilir.

Şekil 3.6’da verildiği gibi Yapay Sinir Ağları genellikle üç tip katmandan oluşur: giriş katmanı, gizli katmanlar ve çıkış katmanı.




Şekil 3. 6. Çok Katmanlı Yapay Sinir Ağı

Her bir sinir hücresi bir sonraki katmandaki tüm sinir hücreleriyle bağlantılıdır. Giriş katmanı, dış çevreden gelen giriş verilerini alırken, çıkış katmanı ise sistemin son çıktısını dış çevreye aktarır. Bu iki katman arasında bir veya daha fazla gizli katman bulunabilmektedir. Giriş ve çıkış katmanlarındaki sinir hücrelerinin sayısı genellikle uygulanacak probleme göre belirlenirken, gizli katmandaki sinir sayısı ağın yapısına bağlı olarak seçilmektedir.

Bu çalışmada Esnek Geri Yayılımlı (RPROP) öğrenme algoritması kullanılmıştır. Esnek geri yayılımlı öğrenme algoritması, klasik geri yayılımlı algoritmaya kıyasla daha hızlı bir eğitim süreci sağlar ve daha karmaşık veri kümeleri üzerinde daha iyi performans göstermektedir. Bu algoritma, çeşitli yapay sinir ağı modellerinde başarıyla uygulanabilmekte ve özellikle büyük veri kümeleri ve derin öğrenme uygulamaları için uygundur.

3.5.4. Evrişimli Sinir Ağları (CNN)

CNN, özellikle görüntü tanıma ve sınıflandırma alanlarında önemli bir derin öğrenme modelidir. CNN'ler, katmanlı yapıları ve evrişimsel işlemler aracılığıyla ham veriden karmaşık özellikleri otomatik olarak öğrenme yeteneğine sahiptir [54]. CNN'lerin sınıflandırma görevlerindeki başarısı, temel olarak ağın yapı taşları olan evrişim (convolution), aktivasyon ve havuzlama (pooling) katmanlarının etkileşimine dayanmaktadır. CNN'lerin sınıflandırma süreci Şekil 3.7'de de belirtildiği gibi birkaç temel katmanlardan oluşmaktadır.



Şekil 3. 7. CNN Katmanları

Evrişimli sinir ağları, giriş verilerini öznitelik haritaları aracılığıyla katmanlar boyunca işleyerek sınıflandırma için yüksek seviyeli öznitelikler oluşturmaktadır. Bu katmanlar aşağıda sırasıyla verilmiştir.

- **Giriş Katmanı (Input Layer)**

Giriş katmanı, modelin işleme aldığı veriyle başlamaktadır. Görüntü işleme görevlerinde genellikle bir görüntü matrisidir. Tipik olarak, bir RGB görüntüsü üç renk kanalı (kırmızı, yeşil, mavi) içermektedir ve bu nedenle giriş, yüksekliği, genişliği ve renk kanallarını temsil eden üç boyutlu bir tensör olarak modellenmektedir. Giriş katmanı, veriyi sonraki katmanlara ileterek ağın derinliklerinde işlenmesini sağlamaktadır.

- **Evrişim Katmanı (Convolutional Layer)**

Evrişim katmanı, CNN'lerin temel yapı taşıdır ve giriş verisinden öznitelik çıkarımı gerçekleştirmektedir. Bu katmanda, küçük boyutlu filtreler giriş görüntüsü üzerinde kaydırılarak işlem sonucunda öznitelik haritaları (feature maps) oluşturulmaktadır. Her bir öznitelik haritası, görüntüde belirli özniteliklerin varlığını göstermektedir. Matematiksel olarak, evrişim işlemi Denklem 3.19'da ifade edilmektedir:

$$y_{ij} = \sum_m \sum_n x_{i+m,j+n} w_{mn} + b \quad (3.19)$$

Burada x giriş verisini, w filtre ağırlıklarını ve b ötelemeyi temsil etmektedir.

- **Aktivasyon Katmanı (Activation Layer)**

Evrişim katmanlarının ardından doğrusal olmayan aktivasyon fonksiyonları uygulanmaktadır. En yaygın kullanılan aktivasyon fonksiyonu ReLU (Rectified Linear Unit) fonksiyonudur. ReLU, negatif değerleri sıfıra çekerken pozitif değerleri olduğu gibi bırakır ve modelin doğrusal olmayan öznelikleri öğrenmesini sağlamaktadır. Böylece doğrusal olmayan, modelin karmaşık verileri daha etkili bir şekilde işlemesine olanak tanımaktadır.

- **Havuzlama Katmanı (Pooling Layer)**

Havuzlama katmanı, uzaysal boyutları azaltarak hesaplama maliyetlerini düşürerek modelin aşırı öğrenme (overfitting) riskini azaltmaktadır. Maksimum havuzlama (Max pooling) en yaygın kullanılan havuzlama yöntemidir ve belirli bir alandaki en yüksek değeri seçerek öznelik haritasının boyutlarını küçültmektedir. Bu işlem, modelin en önemli öznelikleri koruyarak daha düşük boyutlu bir temsil elde etmesini sağlamaktadır.

- **Tam Bağlantılı Katman (Fully Connected Layer)**

Tam bağlantılı katmanlar, sinir ağının son aşamasında yer almaktadır ve sınıflandırma görevini gerçekleştirmektedir. Bu katmanlar, kendisinden önce gelen katmandaki verileri tek boyutlu bir matris şekline dönüştürmektedir. Nöronlar bu katmanda tamamen bağlantılı bir yapı oluşturmaktadır. Her bir nöron, sonraki katmandaki her bir nöronla bağlantı kurmaktadır. Bu nedenle, bu katman 'tam bağlantılı katman' olarak adlandırılmaktadır [55]. Evrişim ve havuzlama katmanlarından elde edilen öznelikler, düzleştirilerek (flattening) bir vektör haline getirilir ve bu vektör tam bağlantılı katmanlara girerek sınıf tahminleri yapmaktadır.

- **Çıkış Katmanı (Output Layer)**

Çıkış katmanı, sınıflandırma problemlerinde genellikle softmax aktivasyon fonksiyonunu kullanır. Softmax fonksiyonu, Denklem 3.20'deki gibi modelin her sınıfa ait olasılıklarını hesaplar ve toplamaları 1 olacak şekilde normalleştirir:

$$P(y = j/x) = \frac{e^{z_j}}{\sum_k e^{z_k}} \quad (3.20)$$

Burada z_j , j sınıfı için tam bağlantılı katmandan gelen çıktıdır. Bu modelin her sınıfa ait tahmin olasılığını ifade etmektedir.

CNN'lerin sınıflandırma performansı, veri büyüklüğü ve çeşitliliği, ağ derinliği ve hiper parametre ayarları gibi birçok faktöre bağlıdır. İyi bir performans elde etmek için, genellikle büyük ve dengeli bir veri seti, dikkatli bir ağ tasarımı ve uygun hiper parametre ayarları gerekmektedir. CNN mimarileri, derin öğrenme alanında önemli bir ilerleme sağlamış ve görüntü sınıflandırma, nesne tespiti, yüz tanıma gibi birçok görsel görevde çığır açan sonuçlar elde etmektedir. LeNet – 5'ten başlayarak, AlexNet, VGGNet, ResNet, MobileNet ve EfficientNet gibi birçok farklı mimari geliştirilmektedir. Bu çalışmada AlexNet kullanılmıştır.

AlexNet, 2012 yılında Alex Krizhevsky tarafından tasarlanan ve ImageNet Large Scale Visual Recognition Challenge (ILSVRC) 2012 yarışmasını önemli bir farkla kazanan bir CNN modelidir. ILSVRC, her yıl düzenlenen ve büyük ölçekli nesne algılama ve görüntü sınıflandırma algoritmaları için bir platform sağlayan prestijli bir yarışmadır. ImageNet veri tabanı, WordNet hiyerarşisine göre düzenlenmiş ve her bir düğümü yüzlerce ve binlerce görüntüyle temsil edilen bir görüntü veri tabanıdır [56].

AlexNet, diğer modellerden önemli ölçüde daha derin bir mimariye sahiptir. Toplamda 8 katmandan oluşmaktadır; 5 evrişim (konvolüsyon) katmanı ve 3 tam bağlantılı katmanı vardır. Modelin giriş katmanı, genişlik, yükseklik ve derinlik (RGB) için $227 \times 227 \times 3$ boyutlarında filtrelenmiş bir görüntü girişi almaktadır. Son tam bağlantılı katman, 1000 tane bağlı katmanı birbirine bağlayarak ve geri kalan katmanları öznetelik çıkarıcı olarak kullanmaktadır.

AlexNet'in başarısı, seyreltme ve veri artırma teknikleriyle aşırı uyum (overfitting) sorununu azaltmasından gelmektedir. Ayrıca, hızlı ve etkili performansı da dikkat çekmektedir. Bu model, derin öğrenme alanında önemli bir dönüm noktası olmuş ve CNN'lerin araştırma ve uygulamalardaki yaygın kullanımını teşvik etmektedir.

3.6. Sınıflama Metrikleri

Sınıflandırma performansının değerlendirilmesi, çeşitli performans ölçütleri kullanılarak gerçekleştirilmektedir. Bu performans ölçütleri, sınıflandırma algoritmasının ne kadar başarılı olduğunu değerlendirmek için önemlidir.

Tıbbi testlerde, sonuçların pozitif veya negatif olarak 2 farklı kategoride, Doğru Pozitif (*DP*), Doğru Negatif (*DN*), Yanlış Pozitif (*YP*) ve Yanlış Negatif (*YN*) olarak 4 farklı değer almaktadır.

Doğruluk oranı (accuracy rate), sınıflandırma modelinin doğru bir şekilde sınıflandırdığı örneklerin oranını belirtmektedir.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.21)$$

Duyarlılık oranı (sensitivity rate), hasta sınıfların doğru bir şekilde tanımlandığını göstermektedir.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3.22)$$

Özgüllük oranı (specificity rate), sağlıklı sınıfların doğru bir şekilde tanımlandığını göstermektedir.

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (3.23)$$

G – Ortalama (G – means) metriği, duyarlılık ve özgüllük oranlarının geometrik ortalamasını alarak, modelin hem pozitif hem de negatif sınıfları ne kadar iyi ayırt edebildiğini göstermektedir.

$$G - \text{means} = \sqrt{\text{Duyarlılık} * \text{Özgüllük}} \quad (3.24)$$

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu tez çalışmasında, PhysioNet CinC – 2016 ve Github – PCG'den elde edilen kalp sesleri kullanılarak kalp hastalıklarının teşhisi amaçlanmaktadır. Bu çalışma kapsamında çeşitli veri tabanlarından sağlıklı bireylere ve çeşitli kalp hastalıklarına sahip bireylere ait kalp sesleri toplanmaktadır. Toplanan bu kalp sesleri, dijital formatta kaydedilmiş ve analiz edilmek üzere hazırlanmıştır.


Kaydedilen kalp sesleri içerisinde sağlıklı kalp sesleri ve çeşitli patolojik kalp sesleri bulunmaktadır. Patolojik sesler arasında AS, MS, MR ve MVP gibi anormal kalp sesleri yer almaktadır. Toplamda, sağlıklı ve patolojik olmak üzere çeşitli gruplara ait kalp sesleri analiz edilmiştir.

Veri setinden alınan “.wav” ses dosyaları bu tez kapsamında analiz edilmek üzere kullanılmıştır. Sesler, öncelikle gürültü giderme, filtreleme ve segmentasyon işlemlerine tabi tutulmuş, ardından öznitelik çıkarma ve sınıflandırma adımlarına geçilmiştir. Öznitelik çıkarım için Ampirik Mod Ayırımı ve Mel Frekansı Kepstrum Katsayıları metotları kullanılmıştır.


Çıkarılan öznitelik vektörlerine Temel Bileşen Analizi (PCA) uygulanarak boyutları küçültülmüştür. PCA, veri kümesindeki en önemli varyasyonları koruyarak, öznitelik sayısını azaltmış ve sınıflandırma algoritmaları için veri setini optimize etmiştir.

Boyutları azaltılmış öznitelik vektörleri kullanılarak, kNN, SVM, ANN ve CNN sınıflandırma algoritmaları ile analiz yapılmıştır. Bu sınıflandırıcılar, farklı kalp seslerinin doğru bir şekilde tanımlanmasında kullanılmıştır. Her bir algoritmanın performansı, doğruluk, özgüllük ve duyarlılık gibi metriklerle değerlendirilmiştir.


Bu çalışmada ilk 4 IMF katsayısı kullanılarak öznitelik çıkarımı gerçekleştirilmiştir. Şekil 4.1. ve Şekil 4.2.'de PhysioNet CinC – 2016 veri setinden alınmış normal kalp sesi ve hasta kalp sesinin EMD yöntemi ile elde edilen ilk 4 IMF'si gösterilmiştir. Şekil 4.3, Şekil 4.4, Şekil 4.5, Şekil 4.6. ve Şekil 4.7.'de ise Github – PCG veri setinden alınmış normal kalp sesi, AS, MVP, MS ve MR kalp seslerinin EMD yöntemi ile elde edilen ilk 4 IMF'si gösterilmiştir.




Şekil 4. 1. PhysioNet Veri Seti İçin EMD ile Öznitelikleri Belirlenen Normal Kalp Sesine Ait İlk 4 IMF




Şekil 4. 2. PhysioNet Veri Seti İçin EMD ile Öznitelikleri Belirlenen Hasta Kalp Sesine Ait İlk 4 IMF




Şekil 4. 3. Github Veri Seti İçin EMD ile Öznitelikleri Belirlenen Normal Kalp Sesine Ait İlk 4 IMF




Şekil 4. 4. Github Veri Seti İçin EMD ile Öznitelikleri Belirlenen AS Hasta Kalp Sesine Ait İlk 4 IMF



Şekil 4. 5. Github Veri Seti İçin EMD ile Öznitelikleri Belirlenen MR Hasta Kalp Sesine Ait İlk 4 IMF




Şekil 4. 6. Github Veri Seti İçin EMD ile Öznitelikleri Belirlenen MS Hasta Kalp Sesine Ait İlk 4 IMF




Şekil 4. 7. Github Veri Seti İçin EMD ile Öznitelikleri Belirlenen MVP Hasta Kalp Sesine Ait İlk 4 IMF

Mel Frekanslı Kepstrum Katsayıları öznitelik çıkarım yöntemi için bu çalışmada PhysioNet CinC – 2016 ve Github – PCG veri seti için ayrı ayrı 13 Kepstral Katsayı kullanılarak öznitelikler elde edilmiştir ve Şekil 4.8’den Şekil 4.14’e kadar farklı kalp seslerine ait Mel Frekanslı Kepstrumu verilmiştir.


Özellikle, sağlıklı bireylerin kalp sesleri ile çeşitli kalp hastalıklarına sahip bireylerin kalp sesleri arasında belirgin farklar olduğu gözlemlenmiştir. MFCC yöntemi ile elde edilen kepstral katsayıların dağılımları, kalp seslerinin karakteristik özelliklerini ortaya koymakta ve sınıflandırma algoritmalarının bu özellikleri kullanarak hastalıklı ve sağlıklı kalp seslerini ayırt etmesine olanak tanımaktadır.




Şekil 4. 8. Github Veri Setindeki Normal Sesine Ait Mel Frekans Kepstrumu




Şekil 4. 9. Github Veri Setindeki MVP Sesine Ait Mel Frekans Kepstrumu




Şekil 4. 10. Github Veri Setindeki MS Sesine Ait Mel Frekansı Kepstrumu




Şekil 4. 11. Github Veri Setindeki MR Sesine Ait Mel Frekansı Kepstrumu



Şekil 4. 12. Github Veri Setindeki AS Sesine Ait Mel Frekansı Kepstrumu



Şekil 4. 13. PhysioNet Veri Setindeki Normal Sesine Ait Mel Frekansı Kepstrumu



Şekil 4. 14. PhysioNet Veri Setindeki Hasta Sesine Ait Mel Frekanslı Kepstrumu

Bu çalışmada, sınıflama metotlarının incelenmesi ve kullanılan parametrelerin detaylı bir şekilde açıklanmasının ardından, her bir yöntemin performansını değerlendirmek için doğruluk, özgüllük, duyarlılık ve g – means gibi kritik metriklerin kullanılması gerekmektedir. Tablo 4.1 – 4.20’de elde edilen sınıflama sürecindeki sonuçlar yer almaktadır. Bu tablolar, EMD ve MFCC öznitelik çıkarım yöntemleri ile kullanılan kNN, SVM, ANN ve CNN sınıflama metotlarının her biri için eğitim ve test verileri üzerindeki performans ölçümlerini içermektedir.

PhysioNet CinC – 2016 veri seti için MFCC öznitelik çıkarım yöntemi ile k – NN sınıflama yöntemi kullanılarak elde edilen eğitim verilerine ait karışıklık matrisi Şekil 4.15’te ve test verilerine ait karışıklık matrisi Şekil 4.16’da gösterilmiştir. Benzer şekilde, Github – PCG veri seti için EMD ve k – NN kullanılarak elde edilen karışıklık matrisi Şekil 4.17 ve Şekil 4.18’de verilmiştir.

Tablo 4.1. PhysioNet CinC – 2016 Veri Seti İçin EMD Öznitelik Çıkarım ile Eğitim Verilerinin Sınıflama Sonuçları


EMD Öznitelik Çıkarım				
Sınıflama Yöntemi	Doğruluk	Özgüllük	Duyarlılık	G – Ortalama
kNN	99,85	99,78	99,86	99,81
SVM	99,70	99,32	99,79	99,55
ANN	94,09	96,45	83,79	89,89

Tablo 4.2. PhysioNet CinC – 2016 Veri Seti İçin EMD Öznitelik Çıkarım ile Test Verilerinin Sınıflama Sonuçları

EMD Öznitelik Çıkarım				
Sınıflama Yöntemi	Doğruluk	Özgüllük	Duyarlılık	G – Ortalama
kNN	99,78	99,24	99,90	99,56
SVM	99,67	99,39	99,73	99,55
ANN	93,98	96,46	83,09	89,52

Tablo 4.3. PhysioNet CinC – 2016 Veri Seti İçin MFCC Öznitelik Çıkarım ile Eğitim Verilerinin Sınıflama Sonuçları


MFCC Öznitelik Çıkarım				
Sınıflama Yöntemi	Doğruluk	Özgüllük	Duyarlılık	G – Ortalama
kNN	99,96	99,99	99,95	99,97
SVM	99,30	99,99	99,21	99,59
ANN	99,93	99,81	99,99	99,89



Şekil 4. 15. PhysioNet CinC – 2016 Veri Seti İçin Eğitim Verilerine MFCC Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi

Tablo 4.4. PhysioNet CinC – 2016 Veri Seti İçin MFCC Öznitelik Çıkarım ile Test Verilerinin Sınıflama Sonuçları


MFCC				
Sınıflama Yöntemi	Doğruluk	Özgüllük	Duyarlılık	G – Ortalama
kNN	99,95	99,99	99,93	99,96
SVM	99,63	99,99	99,55	99,76
ANN	99,91	99,89	99,99	99,93



Şekil 4. 16. PhysioNet CinC – 2016 Veri Seti İçin Test Verilerine MFCC Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi

Tablo 4.5. Github – PCG Veri Seti İçin EMD ve kNN Kullanılarak Elde Edilen Eğitim Verisi Sonuçları


EMD ve kNN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G – Ortalama
Normal	97,84	98,84	99,83	99,33
AS	99,23	99,93	99,79	99,85
MR	97,57	97,76	99,95	98,84
MS	99,30	99,82	99,86	99,84
MVP	99,01	99,85	99,71	99,77



Şekil 4. 17. Github – PCG Veri Seti İçin Eğitim Verilerine EMD Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi

Tablo 4.6. Github – PCG Veri Seti İçin EMD ve kNN Kullanılarak Elde Edilen Test Verisi Sonuçları

EMD ve kNN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G – Ortalama
Normal	98,94	99,99	99,91	99,94
AS	99,99	99,99	99,99	99,99
MR	97,96	97,96	99,99	98,96
MS	99,99	99,99	99,99	99,99
MVP	98,89	99,99	99,62	99,80



Şekil 4. 18. Github – PCG Veri Seti İçin Test Verilerine EMD Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi

Tablo 4.7. Github – PCG Veri Seti İçin EMD ve SVM Kullanılarak Elde Edilen Eğitim Verisi Sonuçları

EMD ve SVM				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G – Ortalama
Normal	73,92	76,45	99,44	87,19
AS	86,44	98,74	95,86	97,28
MR	90,82	94,44	99,11	96,74
MS	95,78	97,09	99,64	98,35
MVP	95,67	98,77	98,94	98,85

Tablo 4.8. Github – PCG Veri Seti İçin EMD ve SVM Kullanılarak Elde Edilen Test Verisi Sonuçları

EMD ve SVM				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G – Ortalama
Normal	75,84	77,14	99,75	87,71
AS	87,91	99,13	95,87	97,48
MR	93,67	96,34	99,39	97,85
MS	96,56	97,90	99,64	98,76
MVP	97,79	98,88	99,62	99,24

Tablo 4.9. Github – PCG Veri Seti İçin EMD ve ANN Kullanılarak Elde Edilen Eğitim Verisi Sonuçları

EMD ve ANN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G – Ortalama
Normal	96,19	75,57	99,55	86,73
AS	94,58	93,79	94,81	94,29


MR	94,65	88,02	96,13	91,98
MS	95,40	91,28	96,47	93,83
MVP	97,86	92,44	99,62	95,96

Tablo 4.10. Github – PCG Veri Seti İçin EMD ve ANN Kullanılarak Elde Edilen Test Verisi Sonuçları

EMD ve ANN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G – Ortalama
Normal	95,89	76,00	98,71	86,61
AS	92,85	91,30	93,35	92,31
MR	89,38	63,82	94,77	77,77
MS	91,36	87,46	92,36	89,87
MVP	95,82	86,63	98,96	92,58

Tablo 4.11. Github – PCG Veri Seti İçin MFCC ve kNN Kullanılarak Elde Edilen Eğitim Verisi Sonuçları


MFCC ve kNN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G – Ortalama
Normal	99,86	99,86	100	99,92
AS	99,68	99,84	99,95	99,89
MR	100	100	100	100
MS	99,74	99,91	99,95	99,93
MVP	100	100	100	100



Şekil 4. 19. Github – PCG Veri Seti İçin Eğitim Verilerine MFCC Öznelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi

Tablo 4.12. Github – PCG Veri Seti İçin MFCC ve kNN Kullanılarak Elde Edilen Test Verisi Sonuçları

MFCC ve kNN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G–Ortalama
Normal	99,51	99,99	99,91	99,94
AS	99,40	99,40	99,99	99,69
MR	100	100	100	100
MS	99,99	99,99	99,99	99,99
MVP	99,71	100	99,90	99,94



Şekil 4. 20. Github – PCG Veri Seti İçin Test Verilerine MFCC Öznitelik Çıkarım Yöntemi ve kNN Sınıflama Yöntemi Uygulanarak Elde Edilen Karışıklık Matrisi

Tablo 4.13. Github – PCG Veri Seti İçin MFCC ve SVM Kullanılarak Elde Edilen Eğitim Verisi Sonuçları

MFCC ve SVM				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G–Ortalama
Normal	99,22	99,74	99,91	99,82
AS	88,83	89,24	99,86	94,40
MR	98,26	99,69	99,61	99,64
MS	91,22	99,91	97,49	98,69
MVP	99,06	99,92	99,71	99,81

Tablo 4.14. Github – PCG Veri Seti İçin MFCC ve SVM Kullanılarak Elde Edilen Test Verisi Sonuçları

MFCC ve SVM				
-------------	--	--	--	--

Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G–Ortalama
Normal	98,97	99,48	99,91	99,69
AS	95,28	96,19	99,72	97,93
MR	96,83	99,19	99,48	99,33
MS	99,64	99,99	99,91	99,94
MVP	98,94	99,99	9,61	99,79

Tablo 4.15. Github – PCG Veri Seti İçin MFCC ve ANN Kullanılarak Elde Edilen Eğitim Verisi Sonuçları

MFCC ve ANN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G–Ortalama
Normal	99,96	100	99,96	99,98
AS	99,79	99,62	99,84	99,72
MR	99,88	99,51	99,96	99,73
MS	99,91	99,74	99,96	99,84
MVP	100	100	100	100

Tablo 4.16. Github – PCG Veri Seti İçin MFCC ve ANN Kullanılarak Elde Edilen Test Verisi Sonuçları

MFCC ve ANN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G–Ortalama
Normal	99,58	100	99,51	99,75
AS	99,08	96,51	99,82	98,15
MR	99,50	99,19	99,57	99,37
MS	99,99	99,99	99,99	99,99
MVP	100	100	100	100

Tablo 4.17. PhysioNet CinC – 2016 Veri Seti İçin CNN Elde Edilen Eğitim Verisi Sonuçları

CNN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G–Ortalama
Normal	100	100	100	100
Hasta	100	100	100	100

Tablo 4.18. PhysioNet CinC – 2016 Veri Seti İçin CNN Elde Edilen Test Verisi Sonuçları

CNN				
-----	--	--	--	--

Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G–Ortalama
Normal	99,99	99,99	100	99,99
Hasta	99,99	100	99,99	99,99

Tablo 4.19. Github – PCG Veri Seti İçin CNN Kullanılarak Elde Edilen Eğitim Verisi Sonuçları

CNN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G–Ortalama
Normal	100	100	100	100
AS	100	100	100	100
MR	100	100	100	100
MS	100	100	100	100
MVP	100	100	100	100

Tablo 4.20. Github – PCG Veri Seti İçin CNN Kullanılarak Elde Edilen Test Verisi Sonuçları

CNN				
Sınıflar	Doğruluk	Duyarlılık	Özgüllük	G–Ortalama
Normal	100	100	100	100
AS	100	100	100	100
MR	99,99	100	99,96	99,96
MS	99,92	99,71	100	99,71
MVP	100	100	100	100

Tablolar, PhysioNet CinC – 2016 veri seti ve Github – PCG veri seti üzerinde yapılan çalışmaların sonuçlarını detaylandırmaktadır.

PhysioNet CinC – 2016 veri seti için yapılan çalışmalarda, EMD öznitelik çıkarımıyla kNN sınıflandırma yöntemi en yüksek doğruluk oranına sahip olmaktadır (%99,85 eğitim verileri için, %99,78 test verileri için). Ancak, ANN yöntemi düşük duyarlılık oranlarıyla dikkat çekmektedir.

Diğer yandan, MFCC öznitelik çıkarımıyla elde edilen sonuçlar daha dengeli görünmektedir. Özellikle kNN sınıflandırma yöntemi, yüksek doğruluk oranlarına sahiptir ve diğer yöntemlere göre daha tutarlı sonuçlar vermektedir (%99,96 eğitim verileri için, %99,94 test verileri için).

Github–PCG veri seti için ise EMD ve kNN yöntemi ile yapılan çalışmalarda, farklı kalp hastalıklarının sınıflandırılmasında yüksek doğruluk oranları elde edilmiştir (%98,94 ile %100 arasında değişen doğruluk oranları). MFCC ve SVM yöntemi ile yapılan çalışmalarda da benzer şekilde yüksek doğruluk oranları gözlemlenmiştir (%98,97 ile %99,64 arasında değişen doğruluk oranları).

Tablo 4.17’den Tablo 4.20’ye kadar görüldüğü gibi CNN algoritması, kalp seslerinin sınıflandırılmasında üstün performans sergilemiştir. PhysioNet CinC – 2016 ve Github – PCG veri seti için CNN kullanılarak, eğitim verileri %100 doğruluk, %100 duyarlılık ve %100 özgüllük değerleri elde edilmiştir. Test verileri için de benzer şekilde yüksek performans değerleri gözlemlenmiştir.

Bu çalışmada elde edilen bulgular, öznitelik çıkarım yöntemlerinin ve sınıflama algoritmalarının performansını kapsamlı bir şekilde karşılaştırmaktadır. Elde edilen sonuçlar, MFCC öznitelik çıkarımı ve CNN sınıflama yöntemlerinin üstün performans sergilediğini göstermektedir. Özellikle CNN, her iki veri setinde de en yüksek doğruluk, duyarlılık ve özgüllük değerlerine ulaşmıştır. Bu durum, derin öğrenme yöntemlerinin, özellikle karmaşık ve büyük veri setlerinde güçlü bir araç olduğunu ortaya koymaktadır.

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, kalp sesleri iki ayrı veri seti üzerinde farklı öznitelik çıkarım yöntemleri ve sınıflama algoritmalarının performanslarını karşılaştırarak, en yüksek doğruluk, duyarlılık ve özgüllük değerlerine ulaşan yöntemleri belirlemeyi amaçladık. Çalışmamızda, normalizasyon ve eliptik filtre kullanılarak veriler işlenmiş, Shannon Enerji ve Otsu eşikleme ile segmentasyon yapılarak sınıflandırma algoritmaları için uygun hale getirilmiştir.

Normalizasyon ve eliptik filtre kullanımı, verilerin daha iyi analiz edilmesini sağlamış ve sınıflandırma algoritmalarının performansını artırmıştır. Shannon Enerji ile segmentasyon, kalp seslerinin belirli özelliklerini daha iyi ortaya çıkararak sınıflandırma doğruluğunu arttırmıştır.

MFCC öznitelik çıkarımı, sınıflama performansını genel olarak artırmış ve en yüksek doğruluk, duyarlılık ve özgüllük değerlerine ulaşılmasını sağlamıştır. EMD öznitelik çıkarımı da başarılı sonuçlar vermiş, ancak MFCC'nin gerisinde kalmıştır.

CNN sınıflama, tüm sınıflar için %99'un üzerinde doğruluk, duyarlılık ve özgüllük değerlerine ulaşarak en yüksek performansı göstermiştir.

kNN sınıflama, özellikle EMD ve MFCC öznitelikleriyle kullanıldığında yüksek doğruluk ve duyarlılık değerleri sağlamıştır, ancak CNN kadar etkili olmamıştır.

SVM sınıflama, bazı sınıflarda yüksek duyarlılık ve özgüllük değerlerine ulaşsa da genel doğruluk açısından geride kalmıştır.

ANN sınıflama, diğer yöntemlere kıyasla daha düşük performans göstermiştir, bu da daha karmaşık sınıflandırma problemlerinde yetersiz kalabileceğini göstermektedir.

CNN sınıflamasında, özellikle büyük ve karmaşık veri setlerinde güçlü performans sergilediği görülmüştür. Bu nedenle, gelecekteki çalışmalar için derin öğrenme tekniklerinin kullanılması önerilmektedir. Derin öğrenme modellerinin optimize edilmesi ve daha büyük veri setleri ile eğitilmesi, daha yüksek doğruluk ve güvenilirlik sağlayabilir.

MFCC ve EMD gibi öznitelik çıkarım yöntemlerinin kombinasyonu, daha iyi sonuçlar elde edilmesine yardımcı olabilir. Yeni ve gelişmiş öznitelik çıkarım tekniklerinin araştırılması, sınıflandırma performansını daha da arttırabilir.

Normalizasyon ve filtreleme tekniklerinin optimize edilmesi, verilerin daha iyi işlenmesine ve analiz edilmesine yardımcı olabilir. Farklı segmentasyon tekniklerinin denenmesi, özellikle kalp sesleri gibi sinyallerde daha hassas ve doğru analizler yapılmasını sağlayabilir.

Farklı sınıflandırma algoritmalarının performanslarını kapsamlı bir şekilde karşılaştırmak, hangi yöntemin belirli veri setleri ve problemler için en uygun olduğunu belirlememize yardımcı olabilir.

Birden fazla makine öğrenimi algoritmasının kombinasyonunu içeren hibrit modellerin kullanılması, sınıflandırma doğruluğunu arttırabilir. Bu modeller, farklı algoritmaların güçlü yönlerini birleştirerek daha üstün performans sağlayabilir. Birden fazla modelin tahminlerinin birleştirilmesi yöntemi, çeşitli modellerin sonuçlarını bir araya getirerek daha sağlam ve güvenilir tahminler elde edilmesini sağlar. Bu yöntem, tek bir modelin sınırlamalarını aşarak genel performansı iyileştirir.

Bu çalışma, kalp seslerinin sınıflandırılması konusunda önemli bulgular ortaya koymuş ve gelecekteki çalışmalar için önemli öneriler sunmuştur. Elde edilen sonuçlar, sağlık alanında daha doğru ve güvenilir teşhis sistemlerinin geliştirilmesine katkı sağlayabilir. Özellikle, derin öğrenme yöntemlerinin kullanımı, karmaşık ve büyük veri setlerinde güçlü bir araç olduğunu kanıtlamıştır. Bu durum, gelecekteki araştırmalarda daha büyük veri setleri ve daha sofistike modellerle çalışmanın önemini vurgulamaktadır.

KAYNAKÇA

- [1] “Cardiovascular diseases, 2022”. Erişim: 29 Eylül 2023. [Çevrimiçi]. Erişim adresi: <https://www.who.int/health-topics/cardiovascular-diseases>
- [2] S. Yuenyong, A. Nishihara, W. Kongprawechnon, and K. Tungpimolrut, “A framework for automatic heart sound analysis without segmentation”, *Biomed. Eng. Online*, 2011, doi: 10.1186/1475–925X–10–13.
- [3] S. W. Deng, and J. Q. Han, “Towards heart sound classification without segmentation via autocorrelation feature and diffusion maps”, *Future Generation Computer Systems*, 60, 13–21, 2016, doi: 10.1016/j.future.2016.01.010.
- [4] W. Zhang, J. Han, and S. Deng, “Heart sound classification based on scaled spectrogram and partial least squares regression”, *Biomed. Signal Process Control*, 32, 20–28, 2017, doi: 10.1016/j.bspc.2016.10.004.
- [5] P. K. Jain, and A. K. Tiwari, “An algorithm for automatic segmentation of heart sound signal acquired using seismocardiography”, *2016 International Conference on Systems in Medicine and Biology (ICSMB)*, 157-161, 2016.
- [6] M. Nath, and S. Srivastava, “4th Order Shannon Energy Envelope Approach for Localization of S1 and S2 for Early–Stage Detection of Heart Valve Dysfunction”, *Traitement du Signal*, 40(2), 479–490, 2023, doi: 10.18280/ts.400207.
- [7] T. Fawcett, “An introduction to ROC analysis”, *Pattern Recognit Lett*, 27(8), 861–874, 2006, doi: 10.1016/j.patrec.2005.10.010.
- [8] T. Nilanon, J. Yao, J. Hao, S. Purushotham, and Y. Liu, “Normal / abnormal heart sound recordings classification using convolutional neural network”, *Computing in Cardiology*, IEEE Computer Society, 585–588, 2016, doi: 10.22489/cinc.2016.169–535.
- [9] Y. Koçyiğit, “Heart sound signal classification using fast independent component analysis”, *Turkish Journal of Electrical Engineering and Computer Sciences*, 24(4), 2949–2960, 2016, doi: 10.3906/elk–1409–123.
- [10] V. Maknickas, and A. Maknickas, “Recognition of normal–abnormal phonocardiographic signals using deep convolutional neural networks and mel–frequency spectral coefficients”, *Physiol. Meas.*, 38(8), 1671–1684, 2017, doi: 10.1088/1361–6579/aa7841.
- [11] Yaseen, G. Y. Son, and S. Kwon, “Classification of heart sound signal using multiple features”, *Applied Sciences (Switzerland)*, 8(12), 2344, 1-14, 2018, doi: 10.3390/app8122344.
- [12] P. Upreti, and M. E. Yüksel, “Accurate Classification of Heart Sounds for Disease Diagnosis by A Single Time–Varying Spectral Feature: Preliminary Results”, *2019 Scientific Meeting on Electrical–Electronics & Biomedical Engineering and Computer Science (EBBT)*, 1–4, 2019.

- [13] O. Deperlioglu, “Classification of Segmented Phonocardiograms by Convolutional Neural Networks”, *Brain Broad Research in Artificial Intelligence And Neuroscience*, 10(2), 5-13, 2019.
- [14] S. K. Ghosh, R. K. Tripathy, R. N. Ponnalagu, and R. B. Pachori, “Automated Detection of Heart Valve Disorders from the PCG Signal Using Time–Frequency Magnitude and Phase Features”, *IEEE Sens. Lett.*, 3(12), 1-4, 2019, doi: 10.1109/LENS.2019.2949170.
- [15] M. G. M. Milani, P. E. Abas, and L. C. De Silva, “Identification of normal and abnormal heart sounds by prominent peak analysis”, *ACM International Conference Proceeding Series*, Association for Computing Machinery, 31–35, 2019, doi: 10.1145/3364908.3364924.
- [16] M. Deng, T. Meng, J. Cao, S. Wang, J. Zhang, and H. Fan, “Heart sound classification based on improved MFCC features and convolutional recurrent neural networks”, *Neural Networks*, 130, 22–32, 2020, doi: 10.1016/j.neunet.2020.06.015.
- [17] S. L. Oh, V. Jahmunah, C. P. Ooi, Ru-Su Tan, E. J. Ciaccio, T. Yamakawa, M. Tanabe, M. Kobayashi, and U. R. Acharya, “Classification of heart sound signals using a novel deep WaveNet model”, *Comput. Methods Programs Biomed.*, 196, 105604, 1-9, 2020, doi: 10.1016/j.cmpb.2020.105604.
- [18] F. A. Khan, A. Abid, A. Abid, M. S. Khan, and M. S. Khan, “Automatic heart sound classification from segmented/unsegmented phonocardiogram signals using time and frequency features”, *Physiol. Meas.*, 41(5), 055006, 1-13, 2020, doi: 10.1088/1361-6579/ab8770.
- [19] S. B. Shuvo, S. N. Ali, S. I. Swapnil, M. S. Al-Rakhami, and A. Gumaedi, “CardioXNet: A Novel Lightweight Deep Learning Framework for Cardiovascular Disease Classification Using Heart Sound Recordings”, *IEEE Access*, 9, 36955–36967, 2021, doi: 10.1109/ACCESS.2021.3063129.
- [20] S. P. Rishal ve U. Satija, “An Effective Heart Valve Disorder Classification Technique Using Phonocardiograms”, *2022 IEEE 19th India Council International Conference (INDICON)*, 1-6, 2022. doi: 10.1109/INDICON56171.2022.10039770.
- [21] L. Zhu, K. Qian, Z. Wang, B. Hu, Y. Yamamoto, and B. W. Schuller, “Heart Sound Classification based on Residual Shrinkage Networks”, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2022, 4469–4472, 2022, doi: 10.1109/EMBC48229.2022.9871640.
- [22] H. Fauzi, A. Rizal, A. Oktariato, and Z. Said, “Classification of Normal and Abnormal Heart Sounds Using Empirical Mode Decomposition and First Order Statistic”, *Journal of Electronics, Electromedical Engineering, and Medical Informatics*, 5(2), 82–88, 2023, doi: 10.35882/jeemi.v5i2.286.
- [23] A. Gharehbaghi, E. Partovi, and A. Babic, “Recurrent vs Non–Recurrent Convolutional Neural Networks for Heart Sound Classification”, *Studies in*

Health Technology and Informatics, IOS Press BV, 436–439, 2023, doi: 10.3233/SHTI230525.

- [24] Dr. Hakan Gerçekoğlu, “Kalbin Yapısı”. Erişim Tarihi: 26 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://drhakangercekoglu.com/hastaliklar/kalbin-yapisi>
- [25] M. Litviňuková vd., “Cells of the adult human heart”, *Nature*, 588(7838), 466–472, 2020, doi: 10.1038/s41586-020-2797-4.
- [26] M. M. Madani, and E. Golts, “Cardiovascular Anatomy”, *Reference Module in Biomedical Sciences*, Elsevier, 2014. doi: 10.1016/b978-0-12-801238-3.00196-3.
- [27] “Structure of the Heart”. Erişim Tarihi: 26 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://training.seer.cancer.gov/anatomy/cardiovascular/heart/structure.html>
- [28] Dr. Osman Özdemir, “Kalbin Konumu ve Yapısı”. Erişim Tarihi: 26 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://drosmanozdemir.com/kalbin-yapisi-ve-calismasi/>
- [29] J. D. Pollock, and A. N. Makaryus, “Physiology, Cardiac Cycle”, 2022. Erişim Tarihi: 26 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://www.ncbi.nlm.nih.gov/books/NBK459327/>
- [30] S. Dornbush, and A. E. Turnquest, “Physiology, Heart Sounds”, Erişim Tarihi: 26 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://www.ncbi.nlm.nih.gov/books/NBK541010/>
- [31] V. N. Varghees, and K. I. Ramachandran, “A novel heart sound activity detection framework for automated heart sound analysis”, *Biomed. Signal Process Control*, 13(1), 174–188, 2014, doi: 10.1016/j.bspc.2014.05.002.
- [32] S. R. Thiagaraja, R. Damtu, P. L. Shrestha, A. Chitnis, M. A. Thompson, P. T. Anumandla, T. Sarma, and S. Dantu, “A novel heart–mobile interface for detection and classification of heart sounds”, *Biomed. Signal Process Control*, 45, 313–324, 2018, doi: 10.1016/j.bspc.2018.05.008.
- [33] Y. T. Zhang, G. Chan, X. Y. Zhang, and Y. Lung, “Heart Sounds and Stethoscopes”, *Wiley Encyclopedia of Biomedical Engineering*, 2006.
- [34] S. M. Debbal, and F. Bereksi Reguig, “Computerized heart sounds analysis”, *Comput. Biol. Med.*, 38(2), 263–280, 2008, doi: 10.1016/J.COMPBIOMED.2007.09.006.
- [35] H. K. Walker, W. D. Hall, and J. W. Hurst, “Clinical Methods: The History, Physical, and Laboratory Examinations”, 1990. Erişim Tarihi: 26 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/21250045/>
- [36] P. Busono, S. Karim, A. Kamaruddin, and I. P. A. Yogiswara, “Heart Sound Signal Analysis for Digital Auscultation”, *Journal of Physics: Conference Series*, Institute of Physics, 2377(1), 012024, 1–8, 2022. doi: 10.1088/1742-6596/2377/1/012024.

- [37] P. Sadeghi Nia, and H. Danandeh Hesar, “Abnormal Heart Sound Detection using Time–Frequency Analysis and Machine Learning Techniques”, *Biomed Signal Process Control*, 90, 105899, 1-12, 2024, doi: 10.1016/j.bspc.2023.105899.
- [38] Chengyu Liu vd., “Classification of Heart Sound Recordings: The PhysioNet/Computing in Cardiology Challenge 2016”, 2016, Erişim Tarihi: 26 Mayıs 2024. [Çevrimiçi]. Erişim adresi: <https://PhysioNet.org/content/challenge-2016/1.0.0/#files-panel>
- [39] C. Liu vd., “An open access database for the evaluation of heart sound algorithms”, *Physiol Meas*, 37(12), 2181–2213, 2016, doi: 10.1088/0967–3334/37/12/2181.
- [40] C. C. Tseng, and S. C. Pei, “Stable IIR Notch Filter Design with Optimal Pole Placement”, *IEEE Transactions on Signal processing*, 49(11), 2673-2681, 2001, doi: 10.1109/78.960414.
- [41] B. Acar Demirci, “Solunum Sesleri ile Göğüs Hastalıklarının Teşhisi”, Yüksek Lisans Tezi, Celal Bayar Üniversitesi, Manisa, 2019.
- [42] E. A. Açoğlu, “Sayısal Süzgeç Tasarımı ve Uygulamaları”, Yüksek Lisans Tezi, Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 2008.
- [43] E. Jallow, “Heart Attack Prediction Using Machine Learning”, Yüksek Lisans Tezi, Gaziantep Üniversitesi, Gaziantep, 2023.
- [44] D. Singh, and B. Singh, “Investigating the impact of data normalization on classification performance”, *Appl Soft Comput*, 97, 105524, 1-23, 2020, doi: 10.1016/J.ASOC.2019.105524.
- [45] G. Çelebi, “Sayısal Stetoskop ile Elde Edilen Kalp Ses (Fonokardiyogram) Sinyallerinin Bölütlenmesi ve Sınıflandırılması”, Yüksek Lisans Tezi, Ankara, 2017.
- [46] M. E. Arar, “Akciğer Seslerinin Makine Öğrenmesi Yöntemleri ile Sınıflandırılması”, Doktora Tezi, Yıldız Teknik Üniversitesi, İstanbul, 2024.
- [47] S. L. Bangare, A. Dubal, P. S. Bangare, and S. T. Patil, “Reviewing otsu’s method for image thresholding”, *International Journal of Applied Engineering Research*, 10(9), 21777–21783, 2015, doi: 10.37622/ijaer/10.9.2015.21777–21783.
- [48] C. Boz, ve Y. Koçyiğit, “Kalp Seslerinin Segmentasyonu İçin Etkili Eşikleme Yöntemi”, *Balkan 9th International Conference On Applied Sciences Proceeding Book*, 344–350, 2023.
- [49] H. Chen, and R. Gururajan, “Otsu’s Threshold Selection Method Applied in De-noising Heart Sound of the Digital Stethoscope Record”, *Advances in Information Technology and Industry Applications*, Springer Berlin Heidelberg, 239–244, 2012, https://doi.org/10.1007/978-3-642-26001-8_31.

- [50] M. S. Çavdar, “Biyolojik İşaret İşlemede Donanım Tabanlı TBA: EKG İşaretlerine Uygulanması”, Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü , Kayseri, 2011.
- [51] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N. C. Yen, C. C. Tung, and H. H. Liu, “The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis”, *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 454(1971), 903–995, 1998, <https://doi.org/10.1098/rspa.1998.0193>.
- [52] E. T. Görmüş, N. Canagaraja, and A. Achim, “Ampirik Kip Ayrışımı ve Dalgacık Dönüşümü Canagarajah Hiperspektral Görüntülerin Boyutlarının Azaltılması”, *IX. TUFUAB Teknik Sempozyumu Türkiye Ulusal Fotogrametri Ve Uzaktan Algılama Birliği*, 17(4), 204-214, 2017.
- [53] B. R. Wildermoth, “Text-Independent Speaker Recognition Using Source Based Features”, Master of Philosophy, Griffith University, Australia, 2001.
- [54] B. K. Gülay, “A Novel Hybrid Feature Extraction Method for Classification of Chemosensory EEG Signals”, Doktora Tezi, Dokuz Eylül Üniversitesi, İzmir, 2023.
- [55] Y. Lecun, E. Bottou, Y. Bengio, and P. Haffner, “Gradient-Based Learning Applied to Document Recognition”, *Proceedings of the IEEE*, 86(11), 2278–2324, 1998, doi: 10.1109/5.726791.
- [56] E. Çiçek, “Kardiyovasküler Hastalıkların Teşhisine Yönelik Kalp Seslerinin Sınıflandırılması”, Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 2023.
- [57] B. Çetin Söylemez, “EEG Sinyallerinden Şizofreni Hastalarının Derin Öğrenme Yöntemleri İle Belirlenmesi”, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ, 2023.