

**T.C.  
ERCIYES ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI**

**TEK BİR ZAMANLA-DEĞİŞEN SPEKTRAL NİTELİK  
KULLANILARAK KALP SESLERİNİN HASTALIK  
TANISI AMAÇLI SINIFLANDIRILMASI**

**Hazırlayan  
Pratima UPRETEE**

**Danışman  
Prof. Dr. Mehmet Emin YÜKSEL**

**Yüksek Lisans Tezi**

**Temmuz 2019  
KAYSERİ**



**T.C.  
ERCIYES ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI**

**TEK BİR ZAMANLA-DEĞİŞEN SPEKTRAL NİTELİK  
KULLANILARAK KALP SESLERİNİN HASTALIK  
TANISI AMAÇLI SINIFLANDIRILMASI  
(Yüksek Lisans Tezi)**

**Hazırlayan  
Pratima UPRETEE**

**Danışman  
Prof. Dr. Mehmet Emin YÜKSEL**

**Temmuz 2019  
KAYSERİ**

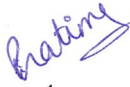
## BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

*Pratima*

Pratima UPRETEE

“Tek bir zamanla-değişen spektral nitelik kullanılarak kalp seslerinin hastalık tanısı amaçlı sınıflandırılması” adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.



Hazırlayan

Pratima UPRETEE



Danışman

Prof. Dr. Mehmet Emin YÜKSEL



Biyomedikal Mühendisliği ABD Başkanı

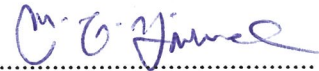
Prof. Dr. Mehmet Emin YÜKSEL

**Prof. Dr. Mehmet Emin YÜKSEL** danışmanlığında **Pratima UPRETEE** tarafından hazırlanan "Tek bir zamanla-değişen spektral nitelik kullanılarak kalp seslerinin hastalık tanısı amaçlı sınıflandırılması" adlı bu çalışma jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü **Biyomedikal Mühendisliği** Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

01/08/2019

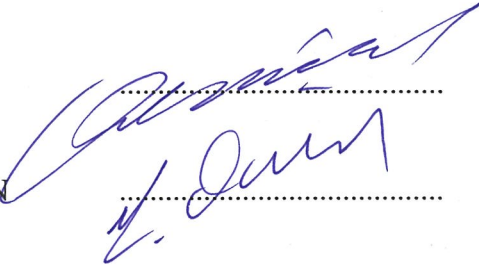
**JÜRİ:**

Danışman : Prof. Dr. Mehmet Emin YÜKSEL

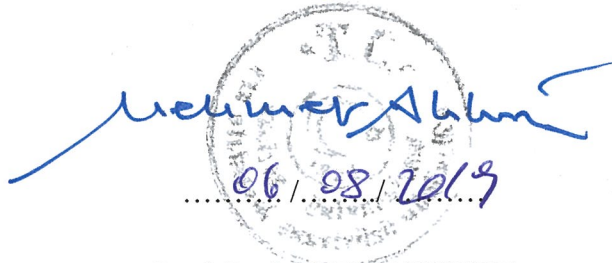


Üye : Doç. Dr. Mahmut TOKMAKÇI

Üye : Dr. Öğr. Üyesi Zeki ORALHAN

**ONAY:**

Bu tezin kabulü Enstitü Yönetim Kurulunun 06/08/2019 tarih ve 2019/47-21 sayılı kararı ile onaylanmıştır.



06 / 08 / 2019

Prof. Dr. Mehmet AKKURT

Enstitü Müdürü

## TEŞEKKÜR

Tez çalışmamda benden desteğini hiçbir zaman esirgemeyen, engin bilgisi ile çalışmalarına yön veren, bana güvenen ve yüreklendiren saygıdeğer hocam Prof. Dr. Mehmet Emin YÜKSEL'e; edindiğim bilgi birikimim için desteklerini esirgemeyen tüm lisans ve yüksek lisanstaki sayın hocalarıma; Türkçe öğrenmemdeki katkıları için Emine KARABIYIK hocama; tez yazmamdaki destekleri için arkadaşlarım Sezin BARIN'a ve Pakize İkra KARAKÖSE'ye; bu süreçte uzaktan da olsa maddi ve manevi desteklerini esirgemeyen, her zaman yanımda olan sevgili annem, babam ve kız kardeşime sonsuz teşekkürlerimi bir borç bilirim.

*Pratima*

Pratima UPRETEE

Temmuz 2019, Kayseri.

# TEK BİR ZAMANLA-DEĞİŞEN SPEKTRAL NİTELİK KULLANILARAK KALP SESLERİNİN HASTALIK TANISI AMAÇLI SINIFLANDIRILMASI

Pratima UPRETEE

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi, Temmuz 2019

Danışman: Prof. Dr. Mehmet Emin YÜKSEL

## ÖZET

Kardiyovasküler hastalıklar (KVH) son yıllarda küresel ölümlerin en yüksek bölümünü oluşturmaktadır. Kardiyak hastalıklardan kaynaklanan ölüm oranını azaltmak için hemen uzun vadeli çözümler bularak bu sorunu küresel olarak ele alma zorunluluğu ortaya çıkmaktadır. KVH tanısı için otomatik kardiyak oskültasyon sistemleri aracılığıyla kalp sesi analizi alternatif bir tanı yöntemi olarak ele alınabilir. Bu teknik non-invaziv, maliyet açısından ucuz, verimli ve tanı açısından umut vericidir.

Uygun nitelik çıkarma tekniklerinin ve sınıflandırıcıların seçimi, kalp ses analizinde çok önemlidir. Bu çalışma temel olarak şu konulara odaklanmaktadır: (1) Hızlı Fourier Dönüşümü (FFT) ve Özbağlanımlı (AR) Model kullanılarak kalp sesinden nitelik çıkarımı ve (2) SVM ve K-NN gibi makine öğrenme yöntemleri ve 1-D CNN ve LSTM gibi derin öğrenme yöntemleri kullanılarak çıkarılan niteliklerin sınıflandırılması. Tezde ikili sınıflamanın yanı sıra çok sınıflı sınıflandırma da ele alınmış ve sınıflandırıcıların performansları ilgili performans metrikleri yardımı ile doğrulanmıştır.

AR yönteminden elde edilen niteliklerin her bir sınıflandırıcı için FFT yönteminden elde edilen niteliklere göre daha iyi sonuçlar verdiği gözlenmiştir. İkili sınıflandırma için, K-NN sınıflandırıcısı, AR nitelik vektörüyle %99.60 doğrulukla en iyi sonucu vermiştir. Çok-sınıflı sınıflandırma için, 1-D CNN sınıflandırıcısı, AR nitelik vektörüyle %97.84 doğrulukla en iyi sonucu vermiştir. Ele alınan ağırlık merkezi frekansının gürbüz olduğu ve AR spektral analiz yöntemiyle gerçekleştirildiği durumda



kalp seslerinin etkin bir şekilde sınıflandırılmasına son derece uygun olduđu sonucuna varılmıştır.

**Anahtar Kelimeler:** Kalp sesleri, spektral kestirme, makine öğrenmesi, derin öğrenme.



# **CLASSIFICATION OF HEART SOUNDS FOR DISEASE DIAGNOSIS BY USING A SINGLE TIME-VARYING SPECTRAL FEATURE**

**Pratima UPRETEE**

**Erciyes University, Graduate School of Natural and Applied Sciences**

**Master Thesis, July 2019**

**Supervisor: Prof. Dr. Mehmet Emin YÜKSEL**

## **ABSTRACT**

Cardiovascular diseases (CVDs) account for the highest portion of global deaths in recent years. There is an urgency to globally address this problem by finding out immediate as well as long term solutions to reduce the mortality rate due to cardiac diseases. A cardiac auscultation aided with automatic heart sound analysis can be taken as an alternative for CVDs diagnosis. This technique is non-invasive, efficient, and less expensive.

The selection of suitable feature extraction techniques and classifiers is very critical in heart sound analysis. This study mainly focuses on: (1) feature extraction from the heart sound using Fast Fourier Transform (FFT) and Autoregressive (AR) Modeling and (2) classification of the extracted features using state-of-art machine learning: SVM and K-NN and deep learning classifiers: 1-D CNN and LSTM. Both binary classification and multi-class classification are performed, and the performances of the classifiers are validated with the help of relevant performance measures.

The features obtained from AR method have outperformed the results from FFT methods for all classifiers included in the study. For binary classification, K-NN classifier performed the best with the accuracy of 99.60% with AR feature vector. And for multi-class classification, 1-D CNN classifier performed the best with the accuracy of 97.84% with AR feature vector. It can be concluded that the extracted centroid frequency is found to be robust and is a suitable feature for efficient heart sound classification when implemented with AR modelling.

**Keywords:** Cardiac sounds, spectral estimation, machine learning, deep learning.



## İÇİNDEKİLER

### TEK BİR ZAMANLA-DEĞİŞEN SPEKTRAL NİTELİK KULLANILARAK KALP SESLERİNİN HASTALIK TANISI AMAÇLI SINIFLANDIRILMASI

BİLİMSEL ETİĞE UYGUNLUK.....	i
YÖNERGEYE UYGUNLUK.....	ii
KABUL VE ONAY .....	iii
TEŞEKKÜR .....	iv
ÖZET.....	v
ABSTRACT .....	vii
İÇİNDEKİLER .....	ix
KISALTMALAR .....	xii
TABLolar LİSTESİ.....	xiv
ŞEKİLLER LİSTESİ.....	xv
GİRİŞ .....	1

## 1. BÖLÜM

### GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. Arkaplan .....	2
1.1.1. Kardiyak Oskültasyonu.....	3
1.1.2. Kalp Sesi.....	4
1.1.3. Kalp Kapak Hastalıkları .....	5
1.1.3.1. Aort Darlığı (AD) .....	5
1.1.3.2. Mitral Yetmezliği (MY) .....	6
1.1.3.3. Mitral Darlığı (MD) .....	7
1.1.3.4. Mitral Kapak Çökmesi (MKÇ).....	7
1.2. Problemin durumu.....	9

1.3. Araştırmanın Amacı .....	12
1.4. Araştırmanın Önemi.....	13

## 2. BÖLÜM

### YÖNTEM

2.1. Veri Tabanı.....	15
2.2. Ön İşleme .....	15
2.2.1. Bölütleme .....	16
2.2.2. Yeniden Örnekleme .....	18
2.2.3. Çerçeve Çıkarımı .....	19
2.3. Nitelik Çıkarma.....	19
2.3.1. Ayrık Fourier Dönüşümü.....	19
2.3.2. Özbağlanımlı Modelleme.....	20
2.3.2.1. Burg Algoritması.....	21
2.3.3. Ağırlık Merkezi Frekansı Hesaplaması .....	23
2.4. Sınıflandırma .....	25
2.4.1. Destek Vektör Makinesi Sınıflandırıcı (Support Vector Machine - SVM) .....	25
2.4.2. K En Yakın Komşu Sınıflandırıcı (K Nearest Neighbor – K-NN) .....	27
2.4.3. Evrişimsel Sinir Ağları (Convolutional Neural Network - CNN).....	28
2.4.4. Uzun Kısa-Sürelili-Bellekli Ağ (Long Short-Term Memory - LSTM).....	32
2.5. Sınıflandırıcı Performanslarının Karşılaştırılması.....	34
2.6. Çapraz Doğrulama.....	37

## 3. BÖLÜM

### BULGULAR

3.1.Bulgular.....	38
-------------------	----

## 4. BÖLÜM

### TARTIŞMA - SONUÇ ve ÖNERİLER

4.1.Tartışma .....	47
4.2. Sonuç ve Öneriler .....	50

<b>KAYNAKÇA .....</b>	<b>52</b>
<b>ÖZGEÇMİŞ.....</b>	<b>58</b>



## KISALTMALAR

KVH: Kardiyovasküler hastalıklar

ECG: Elektrokardiyogram

PCG: Fonokardiyogram

EMG: Elektromiyogram

EEG: Elektroensefalogram

WHO: Dünya Sağlık Örgütü

S1: İlk kalp sesi

S2: İkinci kalp sesi

S3: Üçüncü kalp sesi

S4: Dördüncü kalp sesi

AD: Aort darlığı

MY: Mitral yetmezliği

MD: Mitral darlığı

MKÇ: Mitral kapak çökmesi

N: Normal

MFCC: Mel Frekans Cepstrum Katsayıları

CNN: Evrişimsel sinir ağı

1-D CNN: 1-Boyutlu evrişimsel sinir ağı

LSTM: Uzun kısa - süreli - bellekli ağ

K-NN: K En yakın komşu

SVM: Destek Vektör Makinesi

FFT: Hızlı Fourier Dönüşümü

DFT: Ayrık Fourier Dönüşümü

AR: Özbağlanımlı

HMM: Gizli Markov Modeli

MLP: Çok katmanlı algılayıcı

DWT: Ayrık Dalgacık Dönüşümü

CWT: Sürekli Dalgacık Dönüşümü

MWT: Mel Ölçekli Dalgacık Dönüşümü

STFT: Kısa - süreli Fourier Dönüşümü



## TABLolar LİSTESİ

Tablo 2.1. Veri tabanı ayrıntıları.....	15
Tablo 3.1. İkili sınıflandırma için farklı sınıflandırıcıların performans metriklerinin karşılaştırılması.....	40
Tablo 3.2. Çoklu sınıflandırma için farklı sınıflandırıcıların performans metriklerinin karşılaştırılması.....	46



## ŞEKİLLER LİSTESİ

Şekil 1.1. 2016 yılında yayınlanan başlıca ölüm sebepleri ve oranları. ....	3
Şekil 1.2. Normal kalp sesi. ....	5
Şekil 1.3. Aort daralmasının fonokardiyogramı. ....	6
Şekil 1.4. Mitral yetmezliğin fonokardiyogramı. ....	7
Şekil 1.5. Mitral darlığının fonokardiyogramı. ....	8
Şekil 1.6. Mitral kapak çökmesinin fonokardiyogramı. ....	8
Şekil 2.1. Önerilen yöntemin blok diyagramı. ....	14
Şekil 2.2. Örnek bir kardiyak sinyalinin (a) 1. bölütü, (b) 2. bölütü, (c) 3. bölütü. ....	17
Şekil 2.3. (a) Yeniden örneklemeden önceki kardiyak sinyali. (b) Yeniden örneklendikten sonraki kardiyak sinyali. ....	18
Şekil 2.4. Filtrenin kafes yapısı. ....	22
Şekil 2.5. (a) Kardiyak sinyalin zaman uzayında çerçevelere bölünmesi. (b) (a)'da verilen sinyalin örnek bir sinyal çerçevesi. (c) Örnek çerçeve için AR yöntemi ile elde edilen spektrum ve hesaplanan ağırlık merkezi frekansı. (d) (a)'daki sinyalin bütün çerçevelerinden ağırlık merkezi frekansları hesaplanarak elde edilen nitelik vektörünün değişimi. ....	24
Şekil 2.6. Destek Vektör Makinesi ikili sınıflandırma örneği. ....	26
Şekil 2.7. K-NN ile sınıflandırma örneği. ....	27
Şekil 2.8. Yapay sinir ağının yapısı. ....	28
Şekil 2.9. CNN sınıflandırıcısının yapısı. ....	29
Şekil 2.10. CNN'de evrişim işlemi. ....	29
Şekil 2.11. En büyüğe indirgeme işlemi. ....	30
Şekil 2.12. a) Düzleştirme işlemi, b) Tamamen bağlı katmanda yapılan işlem. ....	31
Şekil 2.13. Önerilen 1-D CNN yapısı. ....	31
Şekil 2.14. LSTM ağının mimarisi. ....	32
Şekil 2.15. Örnek hata matrisi. ....	34
Şekil 2.16. Sınıf 1 için çoklu hata matrisinde TN, TP, FN ve FP değerlerinin pozisyonları. ....	35

Şekil 2.17. Sınıf 2 için çoklu hata matrisinde TN, TP, FN ve FP değerlerinin pozisyonları.....	36
Şekil 2.18. Sınıf 3 için çoklu hata matrisinde TN, TP, FN ve FP değerlerinin pozisyonları.....	36
Şekil 2.19. Sınıf 4 için çoklu hata matrisinde TN, TP, FN ve FP değerlerinin pozisyonları.....	36
Şekil 2.20. Sınıf 5 için çoklu hata matrisinde TN, TP, FN ve FP değerlerinin pozisyonları.....	37
Şekil 3.1. SVM sınıflandırıcısı kullanılarak yapılan ikili sınıflandırma için hata matrisleri, (a) FFT yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma, (b) AR yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma.....	38
Şekil 3.2. K-NN sınıflandırıcısı kullanılarak yapılan ikili sınıflandırma için hata matrisleri, (a) FFT yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma, (b) AR yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma.....	39
Şekil 3.3. LSTM sınıflandırıcısı kullanılarak yapılan ikili sınıflandırma için hata matrisleri , (a) FFT yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma, (b) AR yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma.....	39
Şekil 3.4. 1-D CNN sınıflandırıcısı kullanılarak yapılan ikili sınıflandırma için hata matrisleri, (a) FFT yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma, (b) AR yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma.....	39
Şekil 3.5. FFT yöntemiyle elde edilen nitelik vektörü ile SVM sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.....	41
Şekil 3.6. AR yöntemiyle elde edilen nitelik vektörü ile SVM sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.....	42
Şekil 3.7. FFT yöntemiyle elde edilen nitelik vektörü ile K-NN sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.....	42
Şekil 3.8. AR yöntemiyle elde edilen nitelik vektörü ile K-NN sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.....	43

Şekil 3.9. FFT yöntemiyle elde edilen nitelik vektörü ile LSTM sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.....	43
Şekil 3.10. AR yöntemiyle elde edilen nitelik vektörü ile LSTM sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.....	44
Şekil 3.11. FFT yöntemiyle elde edilen nitelik vektörü ile 1-D CNN sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.....	44
Şekil 3.12. AR yöntemiyle elde edilen nitelik vektörü ile 1-D CNN sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.....	45



## GİRİŞ

Kardiyovasküler hastalıklar (KVH) son birkaç yıldır sürekli büyüyen bir tehdit oluşturmaktadır [1]. Teknolojideki gelişmelere rağmen KVH kaynaklı ölüm oranları giderek artmaktadır. Araştırmalar erken teşhisin, KVH nedeniyle olan ölüm oranını nispeten azaltabileceğini göstermektedir. Bundan dolayı günümüzde, KVH tanısını koymak için uygulanan yöntemlere alternatif olarak otomatik kalp oskültasyonu üzerinde araştırmalar yapılmaktadır. Bu çalışmalar maliyet açısından ucuz, verimli ve tanı açısından umut vericidir.

Uygulanan çalışmalarda, kardiyak sesleri kaydetmek için dijital bir stetoskop kullanılmakta ve kaydedilen sinyaller daha ileri analizler için bilgisayar sistemine aktarılmaktadır. Normalde otomatikleştirilmiş oskültasyon sistemi üç fonksiyonel bloktan oluşmaktadır. Bunlar: bölütleme bloğu, nitelik çıkarma bloğu ve sınıflandırıcı bloktur. Bölütleme bloğunda, nitelik çıkarma bloğu için sinyal hazırlanmaktadır. Nitelik çıkarma bloğunda önceden işlenmiş sinyallerin nitelikleri çeşitli yöntemler kullanılarak hesaplanmaktadır. Son aşama olan sınıflandırıcı blokta ise nitelik çıkarma bloğunda elde edilen nitelikler, bir tahmin/karar vermek için uygun bir sınıflandırıcıya gönderilmektedir.

Bu çalışmada temel olarak, spektral kestirimi kullanılarak farklı alanlarda kalp sesinden nitelik çıkarımına odaklanılmakta ve modern makine öğrenme yöntemleri ve derin öğrenme sınıflandırıcıları kullanılarak sinyaller sınıflandırılmaktadır. İkili sınıflandırmanın yanı sıra çok sınıflı sınıflandırma da yapılmaktadır. Uygulanan sınıflandırıcı performansları teknolojide kullanılan ilgili performans ölçütleri yardımıyla doğrulanmaktadır.

# 1. BÖLÜM

## GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

### 1.1. Arkaplan

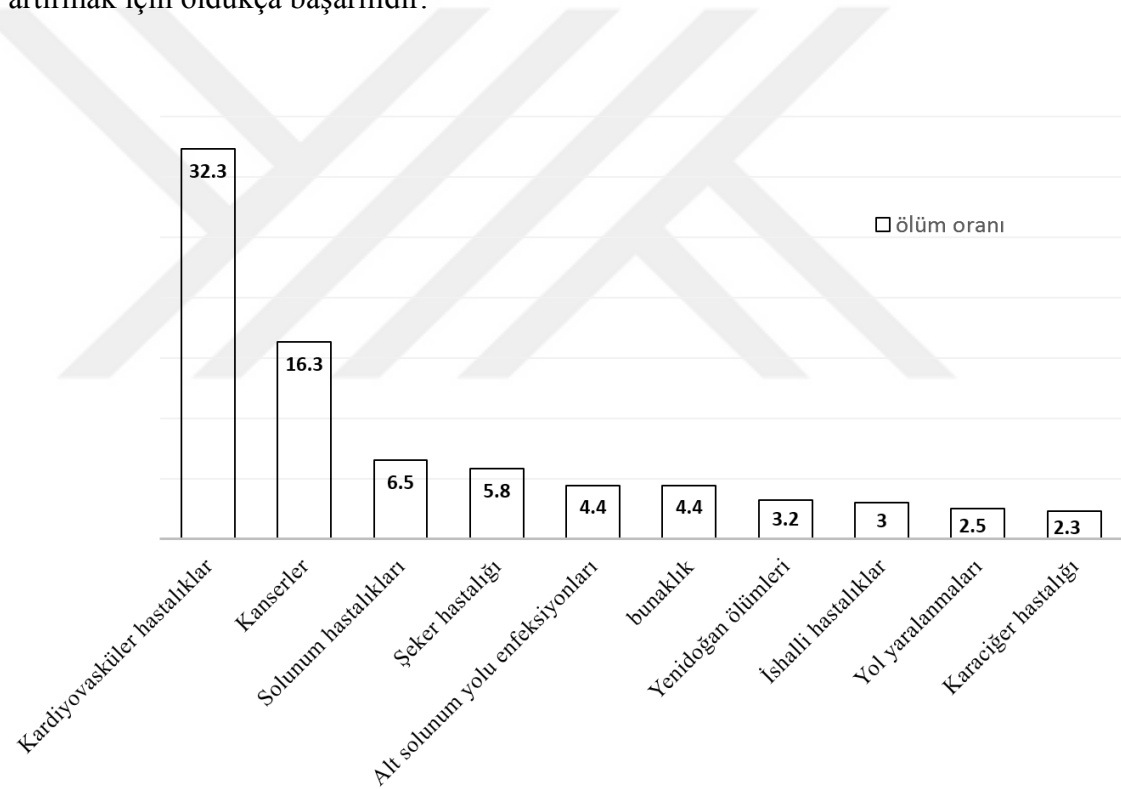
Dünyada birçok insan uygun teşhis hizmetlerinin yetersizliği nedeniyle ölmektedir. Özellikle orta gelirli ve düşük gelirli ülkelerde, uygun teşhis hizmeti giderlerinin karşılanması zor olmaktadır. Bu nedenle insanlar herhangi bir belirti veya ön belirtinin olmadığı durumlarda tıbbi bakım istememektedirler. Bu durum, hastalıkların tedavi süresini uzatmakta ve ölümlerin artmasına yol açmaktadır. Verimli ve ekonomik bir teknik geliştirilmesi, küresel sağlık kalitesinin yükselmesine yardımcı olacaktır.

Elektrokardiyogram (ECG), Fonokardiyogram (PCG), Elektromiyogram (EMG), Elektroensefalogram (EEG) gibi fizyolojik sinyaller insan vücudunda meydana gelen fizyolojik bozuklukların tespiti için oldukça elverişli olmaktadır [2]. Biyomedikal sinyal işleme, bu fizyolojik sinyallerin yardımı ile fizyolojik bozuklukların tanısını otomatikleştirmek için kullanılabilir. İlgili sinyallerden bilgi çıkarımını otomatik hale getirmek için farklı sinyal işleme teknikleri kullanılabilir. Uygulanacak farklı teknikler teşhis işleminin etkinliğini arttırmakta, ayrıca zaman ve maliyeti azaltmaktadır. Bu çalışma için farklı fizyolojik sinyaller arasından, PCG sinyalleri seçilmiştir.

Dünya Sağlık Örgütü'nün (WHO) 2018 yılında yayınladığı istatistiklere göre, 2000-2016 yılları arasında meydana gelen ölümlerin sebepleri arasında kardiyovasküler hastalıklar (KVH) birinci sırada yer almaktadır [3]. Sağlık alanında kaydedilen gelişmelere rağmen, KVH'ye bağlı ölüm oranı hala artış eğilimindedir. Bu sorunu küresel olarak ele almak ve kardiyak hastalıklar nedeniyle meydana gelen ölüm oranını azaltmak için kısa

ve uzun vadeli bir çözüm bulmak oldukça kritik ve aciliyet gerektiren bir problem olarak karşımıza çıkmaktadır.

Hastalıklardan meydana gelen ölümlerin büyük çoğunluğu hastalıkların teşhislerinin geç evrelerde konulmasından kaynaklanmaktadır [4]. Bu nedenle KVH'lerin erken teşhisinin, KVH'ler nedeniyle meydana gelen ölüm oranını önemli oranda azaltması beklenmektedir. Daha önce bahsedildiği üzere kardiyovasküler hastalıkların tanı ve tedavisi alanında yapılan çalışmalarda önemli ilerlemeler kaydedilmiş olsa da yeterli olmamaktadır. Bu çalışmada önerilen yöntem, uygulanan yöntemlerin başarısını artırmak için oldukça başarılıdır.



Şekil 1.1. 2016 yılında yayınlanan başlıca ölüm sebepleri ve oranları [1].

### 1.1.1. Kardiyak Oskültasyonu

KVH'nin ilk teşhis yöntemleri araştırıldığında karşımıza çıkan en eski yöntem kalp seslerinin dinlenmesidir. Genel olarak, kalp hastalığı tanısı için yapılan fiziki

muayenenin ilk adımı kardiyak oskültasyonudur. Kardiyak oskültasyonu, stetoskop yardımıyla kalbin farklı bölgelerinden gelen kalp seslerini dinleme işlemidir.

Kalp seslerinin dinlenmesinde kullanılan stetoskopun ilk ortaya çıkışı günümüzden 200 yıl öncesine dayanmaktadır. İlk araştırmacı doktor Laennec tarafından icat edilen analog stetoskopun kullanımı günümüzde oldukça azalmıştır [5]. Çünkü analog stetoskop, kullanan uzmanın tecrübesinden ve duyma yetisinden doğrudan etkilenmektedir. Ancak elektronik stetoskoplarda elde edilen seslerin hem seviyesinin daha fazla olması hem de kaydedilebilir olmasından dolayı uzmanın tecrübesi ve duyma yetisine bağıllığı azalmıştır. Ayrıca kayıttan elde edilen sinyaller daha sonra araştırma yapmak için çizdirilebilir ve buna fonokardiyogram (PCG) denir. Bu sayede elektronik stetoskopun kullanılmaya başlanması ile kalp sesleri kullanılarak yapılan araştırmalar yeniden ivme kazanmıştır.

### **1.1.2. Kalp Sesi**


Kanın, küçük ve büyük dolaşım sistemini gerçekleştirebilmesi için kalp içerisinde meydana gelen olay dizisine kardiyak döngü denir. Kardiyak döngü sırasında kanın kalp içerisindeki akışı, kan basıncı, kalp kasının kanı iletmek için kasılması ve odacıklara dolması için gevşemesi, kalp kapaklarının açılması ve kapanması gibi fizyolojik olaylar meydana gelirken dokularda toraksın yüzeyine kadar yayılan bir titreşim oluşur. Buna kalp veya kardiyak sesi denir. Meydana gelen bu titreşimler ölçülerek kalp hastalıklarına tanı koyulabilmesi için çalışmalar uzun süredir yapılmaktadır.

Kalp sesleri; ilk kalp sesi (S1), ikinci kalp sesi (S2), üçüncü kalp sesi (S3) ve dördüncü kalp sesi (S4) olarak dörde ayrılır. Her sesin kendine has özellikleri vardır. Kalbin çalışması esnasında kalp kapakları açılıp kapanırken “lub-dub” sesi duyulur. “Lub” sesi triküspid ve mitral kapakların oluşturduğu S1’i ifade ederken “dub” sesi semilunar kapakların (aortik ve pulmoner) kapanmasını ifade eden S2 sesidir. S1 ve S2 sesleri arasındaki temel fark şiddetleri ve gerçekleşme zamanıdır. S1 sesi daha uzun ve daha yumuşak iken S2 sesi daha kısa ancak yüksek enerjilidir [6].

S2 sesinden sonra gelen S3 ve S4 sesleri, S1 ve S2 seslerine göre daha düşük enerjiye sahiptir ve nispeten daha kısa sürelidir. Bu özelliklerinden dolayı, özellikle S3 ve S4



seslerinin tespit edilmesi ve yorumlanması daha zordur [7]. Ancak bu sesler önemlidir ve bazı kalp hastalıklarıyla doğrudan ilişkilidir. Şekil 1.2’de bu çalışmada kullanılan normal kalp ses kayıtlarından biri görülmektedir.



Şekil 1.2. Normal kalp sesi.


### 1.1.3. Kalp Kapak Hastalıkları

Kardiyak muayeneler sırasında hekimin en sık rastladığı kalp hastalıkları arasında kalp kapaklarına ait hastalıklar vardır. Erken tanı konulursa, kardiyak oskültasyonu yardımı ile kapaklarda olan sorunlar tespit edilebilir. Bu çalışmada, dört farklı kapak hastalığını temsil eden kayıtlar ele alınmıştır. Bu dört anormal durum aşağıda kısaca açıklanmıştır:

#### 1.1.3.1. Aort Darlığı (AD)

Aort darlığı (Aortic stenosis), aort kapağının daraldığı ve aort kapağındaki kan akışının engellendiği bir durumdur. Özellikle yaşı 65’in üzerindeki yetişkinlerde, aort darlığı (AD) en yaygın görülen kapak fonksiyon bozukluğudur. Kardiyak oskültasyonu sırasında belli bir üfürüm sesi varlığında AD tespit edilebilir. Aort darlığının en önemli


belirtisi, S1 sesinden sonra gelen sistolik üfürümdür. Aşağıda Şekil 1.3’de, aort daralmasına ait örnek bir fonokardiyogram görülmektedir.



Şekil 1.3. Aort daralmasının fonokardiyogramı.

### 1.1.3.2. Mitral Yetmezliği (MY)

Mitral yetmezliği (Mitral regurgitation), ventriküler sistol sırasında kanın sol ventrikülden sol atriuma geri kaçmasını engelleyen mitral kapağın yetersizliğinin neden olduğu durumdur. İlk kalp sesiyle (S1) başlayan ve sonrasında ikinci kalp sesine (S2) kadar devam eden bir holosistolik üfürüm, mitral yetmezliğin ayırt edici özelliğidir. Bu üfürüm apeksde belirgindir. Kardiyak oskültasyonu sırasında, S1 bazen sesli olabilir ancak genellikle yumuşaktır. S3 sesinin olması ağır durumu temsil eder. Aşağıda Şekil 1.4’de, mitral yetmezliğe ait örnek bir fonokardiyogram görülmektedir.




Şekil 1.4. Mitral yetmezliğin fonokardiyogramı.

### 1.1.3.3. Mitral Darlığı (MD)


Mitral darlığı (Mitral stenosis), mitral açıklığın daralıp sol atriumdan sol ventriküle kan akışının engellendiği durumdur. Kardiyak oskültasyonu sırasında mitral darlığı varlığında ilk ses yüksek, ikinci ses normal diyastolik açılma sesi erken ve ardından şiddeti giderek azalan diyastolik üfürüm görülür. Şekil 1.5'de, mitral darlığa ait örnek bir fonokardiyogram görülmektedir.

### 1.1.3.4. Mitral Kapak Çökmesi (MKÇ)

Mitral kapak çökmesi (Mitral valve prolapse), mitral kapak yaprakçıklarının sistol sırasında tekrar sol atriuma doğru aralandığı durumdur. Bu durum kanın atriuma geri sızmasına neden olur. Oskültasyon sürecinde, orta sistolik kapanmasından önce gelen şiddeti giderek azalan sistolik üfürüm gözlenir. Normalde mitral kapak çökmesi durumunda gözle görülür bir işaret yoktur. Şekil 1.6'da, mitral kapak çökmesine ait örnek bir fonokardiyogram görülmektedir.



Şekil 1.5. Mitral darlığının fonokardiyogramı.



Şekil 1.6. Mitral kapak çökmesinin fonokardiyogramı.

## 1.2. Problemin durumu

Farklı çalışmalardan, kalp sesinin patolojik önemi olan birçok bilgiyi barındırdığı anlaşılmıştır [8]. Ayrıca, yukarıdaki dalga formlarında, her kalp durumunun kendi morfolojisine sahip olduğu açıkça görülmektedir. Bu nedenle, kalp sesi, ilk aşamada düşük maliyetle kalp durumunu değerlendirmek için oldukça uygun bir araçtır. Ayrıca non-invaziv ve az zaman alan bir tekniktir [2, 5].

Her ne kadar kardiyak oskültasyonu ve fonokardiyograf sinyal sesleri çekici ve elde etmesi çok kolay olsa da, durum aslında tam tersidir. Kalp hastalıklarının teşhisi, yalnızca kardiyak oskültasyonunun yardımı ile yapıldığında yüksek uzmanlık gerektirmektedir [2, 5-8].

Kalp sesinin içinde barındırdığı nitelikler yalnızca zaman bölgesi içinde sınırlı değildir; birçok nitelik, frekans bölgesi ve zaman-frekans bölgesi içinde de bulunmaktadır [9, 10]. Tanı koyma prosedürüne yardımcı olmak için bu alanlardan manuel nitelik çıkarımı, zaman alıcı olmasının yanı sıra karmaşıktır [2].

Çalışma başlangıcında kardiyak oskültasyonunun, tanı prosedüründe yer alan pahalı tekniklere göre daha iyi bir alternatif olduğu sonucuna varılmıştır. Bunun sonucunda farklı alanlardaki kardiyak ses özelliklerini otomatik olarak analiz etmek ve kardiyovasküler hastalıklar için mümkün olan en yüksek doğruluğu sağlamak için sınıflandırma yöntemi geliştirilmiştir. Bu sınıflandırma işleminin ardından gelen özelliklerin otomatik analizi hem doğru bir karar vermesi hem de erken teşhis için hekime yardımcı olmaktadır.

Nitelik çıkarımı, kardiyak ses sınıflandırma sisteminin önemli bir basamağını oluşturmaktadır. Sınıflandırma sırasında daha iyi doğruluk elde etmek için mümkün olan en iyi nitelikleri elde etmek önemlidir. Çünkü sınıflandırıcı performansı büyük ölçüde kullanılan niteliğe bağlıdır. Nitelik çıkarma işlemi için farklı yöntemler kullanılmaktadır. Nitelik çıkarımı için yapılan en yaygın analizler: zaman bölgesi, frekans bölgesi ve zaman-frekans bölgesi analizleridir.

Zaman bölgesinden nitelik belirleme ve çıkarma, nispeten basit bir işlem olarak kabul edilebilir. Örneğin S1 ve S2 seslerinin pozisyonları, tepe noktalarının genlikleri, aralarındaki süre veya aralık vs. gibi nitelikler kalp sesinin özellikleri arasındadır [9-11].

Zaman bölgesi, kardiyak seste bulunan tüm patolojik ve fizyolojik detayları değerlendirmek için yeterli gelmemektedir. Bundan dolayı detaylar, frekans alanındaki analizler ile değerlendirilebilmektedir. Frekans bölgesi analizi çoğunlukla Hızlı Fourier Dönüşümü (FFT), Özbağlanımlı modelleme vb. yöntemler kullanılarak yapılan spektrum analizini içerir [8, 12-13].

Son zamanlarda otomatik kalp sesi analizinde zaman-frekans bölgesi analizinin kullanımına da ağırlık verilmiştir, çünkü bu yöntemler hem zaman hem de frekans bölgesinden niteliklerin eşzamanlı olarak çıkarılmasına imkân sağlamaktadır [14]. Otomatik kardiyak ses analizinde, sinyalin zaman-frekans bölgesinden farklı nitelikleri elde etmek için Fourier Dönüşümü, Kısa-Sürelili Fourier Dönüşümü (STFT), Dalgacık Dönüşümü ve S Dönüşümü gibi farklı dönüşümler uygulanmaktadır [14-19].

Zaman-frekans analizi için popüler yöntemlerden biri de Kısa-Sürelili Fourier Dönüşümüdür (STFT) [6, 20-24]. Fakat sabit, dar genişlikli bir pencere kullanılması nedeniyle nitelik çıkarma işlemi için istenen çözünürlüğü elde etmek zor olmaktadır. STFT’de kullanılan pencerenin genişliğine bağlı olarak elde edilebilecek çözünürlükte değişim meydana gelmektedir. Zaman bölgesinde pencere genişliği dar olduğunda çözünürlük fazladır, ancak pencere genişliği arttıkça çözünürlükte azalma olmaktadır. Bu durum frekans bölgesi için tam tersidir, geniş bir pencere daha yüksek çözünürlük sağlarken, daha dar genişlikteki bir pencere düşük çözünürlük sağlamaktadır [25].

Dalgacık dönüşümü, STFT’nin frekans kaydırma işlemini, zaman veya frekans ölçeklendirme işlemi ile değiştirerek STFT’nin yerine geçmiştir [26]. Dalgacık dönüşümü, frekans içeriği zamanla değişen sinyallerin analizi için uygun olmaktadır. Zaman penceresinin frekansla birlikte ayarlanabildiği çoklu çözünürlük analizleri için literatürde yaygın olarak kullanılmaktadır [20, 22-24, 27]. Ayrıca literatürde daha az sıklıkta Ayrık Dalgacık Dönüşümü (DWT), Sürekli Dalgacık Dönüşümü (CWT) ve Mel

Ölçekli Dalgacık Dönüşümü (MWT) gibi farklı yöntemler kullanılarak kardiyak ses analizi yapılmaktadır [6, 14, 16-17, 20, 22-24, 27-30].

Literatürde, kalp sesi sınıflandırmalarında kullanılan Shannon enerji zarfı, Lineer Tahmin Katsayıları, Fraktal özellikler gibi farklı özellikler de vardır. Bunların yanı sıra Mel Frekans Cepstrum Katsayıları (MFCC) gibi algısal yöntemler, diğer yöntemlerle birlikte kapak disfonksiyonunun sınıflandırılmasında yapılan son çalışmalarda kullanılmışlardır [15, 16, 31-34].

Otomatik kalp oskültasyon sistemindeki son işlem, nitelik çıkarma bloğundan çıkarılan özelliğin uygun bir karar vermek için bir sınıflandırıcıya gönderilmesidir. Kalp sesi sınıflandırma sisteminde farklı sınıflandırma türleri uygulanmaktadır. Kullanılan ana sınıflandırıcılar: Destek Vektör Makinesi (SVM), K En Yakın Komşu (K-NN), Çok Katmanlı Algılayıcı (MLP), özdevinimli kodlayıcı gibi farklı sinir ağı türleridir [8, 10, 14, 21, 34]. Bunların yanı sıra Naive Bayes, karar ağacı, rastgele orman vb. gibi diğer yöntemler de kullanılmaktadır [9, 14, 16, 35]. Son zamanlarda CNN ve LSTM gibi derin sinir ağları birçok sınıflandırma uygulamasında oldukça başarılı sonuçlar vermiştir [2, 15, 16, 30].

Literatürdeki çalışmaların çoğunda, parametrelerin değerindeki farklılıklardan ötürü elde edilen sonuçlarda farklılıklar olması nedeniyle sınıflandırma için SVM kullanılmıştır. Optimum sonuçlar elde etmek için bazılarında sınıflandırıcı parametreleri ayarlanmış, diğerlerinde ise sınıflandırıcıya yeni özellikler eklenmiştir [36-37]. SVM, kalp kapakçığı hastalıkları ve kalp üfürümlerinin sınıflandırılmasında diğer sınıflandırıcılardan daha etkili bulunmuştur [38, 40, 34]. Göreceli olarak düşük örneklem boyutuna rağmen SVM'nin yüksek boyutlu verilerle uyumluluğu ve optimal sonuç elde etmek için kullanılan verilere göre seçilebilecek farklı çekirdek fonksiyonlarının mevcudiyeti kalp sesi sınıflandırma problemlerinde SVM'nin çok sık kullanılmasının nedeni olmaktadır.

Literatürdeki bir diğer popüler sınıflandırıcı ise K en yakın komşudur (K-NN). SVM sınıflandırıcısına benzer şekilde, K-NN sınıflandırıcısı kalp üfürümlerinin saptanmasında ve kalp sesinin normal ve anormal olarak sınıflandırılmasında diğer

sınıflandırıcılara göre oldukça iyi performans göstermektedir [34, 41-43]. K-NN'nin kalp sesi sınıflandırmada diğer sınıflandırıcılara göre avantajları; eğitim için daha az zaman harcaması, gürültülü verilerde dengeli bir şekilde performans göstermesi, uygulanmasının basit ve kolay olmasıdır. Literatürde bahsedildiği gibi, bu sınıflandırıcının dezavantajı, bellekte daha fazla boş alana ihtiyaç duymasındır [44].

Gizli Markov Modeli (HMM); kalp sesinin sınıflandırılmasında da kullanılan, ancak genellikle bölütleme için kalp sesinin bileşenlerini sınıflandırmaya odaklanan bir yöntemdir [31, 45-47]. Sınıflandırma için HMM kullanımı nispeten azdır. Çünkü HMM yöntemi seçilen parametrelerin (oldukça fazla miktarda bulunur) performansına bağımlılığının fazla olması nedeniyle, parametrenin optimize edilmesini zorlaştırmaktadır. Ek olarak, hesaplama maliyeti yüksektir ve sonucu yorumlaması daha uzun sürmektedir.

Sinir ağları ise kalp sesinin sınıflandırılmasında yaygın olarak kullanılmaktadır; ancak büyük veri setleri gerektirirler ve hesaplama maliyetleri yüksektir [48-51]. Son zamanlarda grafik işleme donanımlarının son derece güçlü hale gelmesi ve çoğu medikal alana ait büyük verilerin internette açık olarak bulunabilmesinin bir sonucu olarak hem genel sinyal işleme uygulamalarında hem de biyomedikal uygulamalarda derin öğrenmenin kullanımı popülerlik kazanmıştır [52-53]. Bundan dolayı son yıllarda yapılan çalışmalarda derin öğrenme yöntemi kalp sesinin sınıflandırılması için en gelişmiş yöntem olarak kullanılmaktadır [15-16]. Evrişimsel Sinir Ağı (CNN), Uzun Kısa-Süreli-Bellekli Ağ (LSTM) ve zaman-frekans özelliklerine sahip yığınlanmış özdevinimli kodlayıcı gibi derin sinir ağları kalp sesinin sınıflandırılmasında ümit verici sonuçlar göstermiştir [15-16, 34, 48]. Ancak, bu teknikler hala geliştirilme aşamasındadır ve günlük kullanım için gerçek zamanlı uygulamalara aktarılmaya hazır değildir.

### **1.3. Araştırmanın Amacı**

Bu çalışmanın temel amacı, spektrum analizi kullanarak, fizyolojik sinyaller olan Fonokardiyogram (PCG) sinyallerinin nitelik çıkarımını otomatikleştirmek ve bunları kendi gruplarında sınıflandırmak için derin öğrenme yöntemleri kullanmaktır. Kardiyak



oskültasyonunda, klinik ortamda kalp hastalığı tanı karar sistemine düşük maliyet ve yüksek verimle yardımcı olmak hedeflenmektedir. Kardiyak sağlık durumlarını iyileştirmek için her düzeyde geliri olan bireylere temel kardiyak muayene için gereken kolay bir yaklaşımın sağlanması amaçlanmaktadır.

#### **1.4. Araştırmanın Önemi**


Öncelikle şu soru kesinlikle akla gelecektir: sadece kalp damar hastalıklarının teşhisi için kullanılan birçok gelişmiş ekipman ve teknik varken bu çalışma neden önemli? Cevap, birçoğunun oldukça pahalı, zaman alıcı ve bazılarının da invaziv olmasıdır. İnvaziv olmayan, daha az zaman alan ve maliyeti düşük olmasının yanı sıra aynı veya daha yüksek doğruluk sağlayabilen bir çözüm bulmak önem arz etmektedir.

Kardiyak oskültasyonu bu nedenle gayet iyi bir çözümdür. Tamamen non-invaziv olan muayene sırasında sadece dijital stetoskop kullanılmaktadır. Kardiyak ses kaydını dinlemek ve kaydetmek için sessiz ortam dışında özel bir ortam gerekmemektedir. Stetoskop, KVH teşhisinde yer alan diğer ekipmanlarla karşılaştırıldığında pahalı değildir ve sağlık ocaklarından başlayarak daha büyük hastanelere kadar her sağlık merkezinde kolayca bulunabilmektedir. Önerilen yöntemin yardımıyla, dijital stetoskolla elde edilen kayıtları kullanarak, yüksek doğruluk oranı ile tanı birkaç saniye içinde koyulabilir. Bu da zaman ve maliyet kazancı sağlanmasının yanı sıra hasta için de oldukça büyük kolaylık sağlayacaktır.

## 2. BÖLÜM

### YÖNTEM

Şekil 2.1’de görülen blok diyagramı, önerilen yöntemin bir özetini temsil etmektedir. Önerilen yöntem 3 ana süreç ve bu ana süreci takip eden farklı alt süreçleri içermektedir. Ana süreçler: veri edinme, ön işleme, nitelik çıkarma ve sınıflandırmadan oluşmaktadır.



Şekil 2.1. Önerilen yöntemin blok diyagramı.

Sistemin giriş sinyalleri, dijital stetoskop aracılığıyla elde edilen kardiyak ses kayıtlarından oluşmaktadır. Bu sinyaller, ön işleme bloğunda ön işleme tabi tutulmaktadır. Bu aşamada elde edilen sinyaller nitelik çıkarımı için gerekli adımların gerçekleştirildiği ve her bir ayrı sinyal için nitelik vektörlerinin oluşturulduğu nitelik çıkarma bloğuna uygun hale getirilmektedir. Daha sonra elde edilen nitelik vektörü en doğru sınıflandırmayı yapabilmek için farklı sınıflandırıcılar kullanılan sınıflandırma bloğuna giriş sinyali olarak verilmektedir.

## 2.1. Veri Tabanı

Bu çalışmada Yaseen ve arkadaşları [34] tarafından çeşitli kaynaklardan toplanan herkese açık bir veri tabanı kullanılmıştır. Veri tabanında 1000 adet kardiyak ses kaydı bulunmaktadır. Kayıtların her biri örnekleme frekansı 8 KHz olan 3 kardiyak çevriminden oluşmaktadır. Kayıtlar genel anlamda iki gruba ayrılmaktadır:

1. Normal (N)
2. Anormal (A)

Anormal kayıtlar ise kendi içerisinde 4 alt gruba ayrılabilir:

1. Aort Darlığı (AD)
2. Mitral Yetmezliği (MY)
3. Mitral Darlığı (MD)
4. Mitral Kapak Çökmesi (MKÇ)

Veri tabanının ayrıntıları Tablo 2.1’de gösterilmektedir.

Tablo 2.1. Veri tabanı ayrıntıları.

Sınıflar	Alt Sınıflar	Kayıt Sayısı	Kardiyak Döngü Sayısı
<b>Normal</b>	Normal (N)	200	600
<b>Anormal</b>	Aort Darlığı (AD)	200	600
	Mitral Yetmezliği (MY)	200	600
	Mitral Darlığı (MD)	200	600
	Mitral Kapak Çökmesi (MKÇ)	200	600
<b>Toplam</b>		1000	3000


## 2.2. Ön İşleme

Ön işleme; verileri, bir sonraki bloğa uygun giriş verisi haline getirmek için gerçekleştirilmektedir. Normalde sinyal işlemenin ilk adımı sinyalleri normalize etme ve sinyal filtrelemedir. Bu çalışmada kullanılan veri setinde sinyaller zaten normalize


edilmiş ve filtrelenmiş formdadır. Bu nedenle çalışmada daha çok nitelik çıkarma bloğu için veri ön işlemeye odaklanılmıştır. Uygulanan adımlar aşağıda alt başlıklar halinde açıklanmıştır.

### 2.2.1. Bölütleme


Bölütleme otomatik kardiyak sesi analiz sisteminde önemli süreçlerden biridir. Bölütleme süreçleri bir çalışmadan diğerine farklılık göstermektedir. Bölütler tek kardiyak döngüsünü veya belirli zaman aralığındaki sinyalleri göstermektedir. Bu çalışmada geliştirilen yöntemde, sisteme giriş olarak verilen kalp sesi sinyalinin tek bir kardiyak döngüsü içerdiği varsayılmıştır. Ancak seçilen veri tabanı kayıt başına 3 kardiyak döngü içermektedir. Bu nedenle, tek kardiyak döngüsünü elde etmek için kayıtlar 3 parçaya bölünmektedir. Elde edilen kardiyak döngüleri de tek bir kardiyak ses kaydı olarak kaydedilmektedir. Bu aşamadan sonra kardiyak sinyal terimi her kullanıldığında, tek bir kardiyak döngüsü esnasında oluşan kalp sesi kastedilmiş olacaktır. Aşağıdaki üç şekilde veri tabanındaki bir kardiyak sinyalinin bölütlenmesi yoluyla elde edilen ve her biri bir kardiyak döngüsüne karşı düşen üç bölüt görülmektedir.



(a)



(b)




(c)


Şekil 2.2. Örnek bir kardiyak sinyalinin (a) 1. bölümü, (b) 2. bölümü, (c) 3. bölümü.

### 2.2.2. Yeniden Örnekleme

İkinci varsayım, her kalp sinyalinin eşit sayıda örneğe sahip olacağı yönündedir. Sinyal süresinden bağımsız olarak, her kardiyak sinyalin 1000 örneğe sahip olması gerekmektedir. Bu hedefe ulaşmak için öncelikle tüm sinyaller 1000 faktörü ile interpolasyona tabi tutulmuştur. Daha sonra ilgili kardiyak sinyallerinde mevcut olan orijinal örnek sayısına eşit faktörde desimasyona tabi tutulmuştur. Aşağıda, yeniden örnekleme işleminden önceki ve sonraki kardiyak sinyalini gösteren grafikler yer almaktadır.



(a)



(b)

Şekil 2.3. (a) Yeniden örneklemeden önceki kardiyak sinyali. (b) Yeniden örneklendikten sonraki kardiyak sinyali.

### 2.2.3. Çerçeve Çıkarımı

Bu çalışmada spektral analiz için Ayırık Fourier Dönüşümü (DFT) ve Özbağlanımlı (AR) model kullanılmaktadır. Her iki model de analiz edilen sinyalin durağan olmasını gerektirmektedir. Bu nedenle, PCG sinyalleri gibi durağan olmayan sinyallerde durağanlık elde etmek için sinyali belirli uzunlukta çerçevelere bölmek çok kullanılan bir yöntemdir. Burada kardiyak sinyali, kayma uzunluğu 25 örnek ve çerçeve uzunluğu 150 örnek olan çerçevelere bölünmüştür. İşlem sonucunda her sinyal için 35 çerçeve oluşmuştur. Kayma uzunluğu, sinyaldeki çerçevelerde çakışan örneklerin sayısını temsil etmektedir. Çakışma üst üste gelen iki çerçevenin kenar örnekleri arasında mevcut uyumu korumak amacıyla yapılmaktadır.

### 2.3. Nitelik Çıkarma

Nitelik çıkarımı için, spektral kestirimde kullanılan iki farklı yöntem seçilmiştir. Bunlar Ayırık Fourier Dönüşümü ve Özbağlanımlı Modelleme yöntemleridir.

#### 2.3.1. Ayırık Fourier Dönüşümü

Ayrık Fourier Dönüşümü (DFT), zaman uzayındaki ayırık sinyali frekans uzayına dönüştürmek için kullanılan sinyal işleme tekniğidir. Sinyalin frekans içeriğini, yani verilen zaman serisinin spektrumunu yorumlamada kullanılmaktadır.

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j\frac{2\pi}{N}nk} \quad (k= 0,1,2,\dots,\dots,\dots, n-1) \quad (1)$$

Burada,

n: Sinyal örneklerinin örnek numarası

k: Frekans uzayındaki sinyalin frekans bileşenlerinin numarası

N: Sinyal içerisindeki toplam örnek sayısı

x(n): Zaman uzayındaki sinyal

X(k): Frekans uzayındaki sinyal

Ayrık Fourier Dönüşümü, iyi bilinen bir algoritma olan Hızlı Fourier Dönüşümü (FFT) kullanılarak hesaplanır. FFT, tekrarlanan terimleri kaldırarak normal DFT hesaplamasından elde edilen sonuçla aynı sonucu vermektedir. Bu sayede DFT

hesaplama işlemi sırasında gerekli matematiksel işlemlerin miktarı azaltılmaktadır. DFT'nin normal yöntemle hesaplanma süresi, FFT'nin  $N / (\log_2(N))$  katıdır.

### 2.3.2. Özbağlanımlı Modelleme

Özbağlanımlı (AR) modelleme, spektral kestirmede kullanılan bir diğer popüler yöntemdir. Yüksek spektral çözünürlüğü ve durağan rasgele süreçlerle etkin performansı olması nedeniyle bu çalışmada da AR modeli seçilmiştir. Aynı şekilde, biyomedikal sinyal işleme için diğer yöntemlerden daha iyi performans göstermektedir [54].

Özbağlanımlı model, gelecekteki değer tahmini yalnızca verilen zaman serisinin geçmiş değerlerine dayanan öngörücü bir modeldir. Bu model, verilen zaman serilerinde önceki değerler ile sonraki değerler arasında en azından bir miktar korelasyonun olduğu durumun belirlenmesinde kullanılır. AR modeli için matematiksel ifade:

$$x(n) = -\sum_{k=1}^p a_k x(n-k) + e(n) \quad (2)$$

şeklindedir.

Burada,  $x(n)$  kalp ses sinyali çerçevesi içindeki sinyal örneklerine karşılık gelen modellenecek sinyali;  $a_k$  AR model parametrelerini,  $p$  model derecesini ve  $e(n)$  sıfır ortalama bir beyaz gürültü sürecini temsil etmektedir.

Yukarıdaki denklemden, AR yönteminin,  $x(n)$  sinyalini beyaz gürültü sinyaliyle sürülen doğrusal bir filtrenin çıkış sinyali olarak modellediği kolayca görülmektedir.

Denklem (2)'nin her iki tarafının Z-dönüşümlerini alarak:

$$Z\{x(n)\} = Z\{-\sum_{k=1}^p a_k x(n-k)\} + Z\{e(n)\} \quad (3)$$

ve zaman kaydırma özelliğini kullanılır ve eşitlik düzenlenirse:

$$X(z)[1 + \sum_{k=1}^p a_k z^{-k}] = E(z) \quad (4)$$



ve sonrasında

$$H(z) = \frac{X(z)}{E(z)} = \frac{1}{[1 + \sum_{k=1}^p a_k z^{-k}]} \quad (5)$$

elde edilir.

$z \rightarrow e^{j\Omega}$  koyulursa (5) denklemi, ayrık frekans uzayında aşağıdaki gibi gösterilebilir:

$$H(e^{j\Omega}) = \frac{X(e^{j\Omega})}{E(e^{j\Omega})} = \frac{1}{[1 + \sum_{k=1}^p a_k e^{-jk\Omega}]} \quad (6)$$

AR model parametrelerinin belirlenmesinde kullanılan muhtelif yöntemler vardır. Bunlar arasında en küçük kareler tahmini, maksimum olabilirlik tahmini, Yule - Walker yöntemi, Burg yöntemi sayılabilir. Bu yöntemler arasında Burg yönteminin uygun bir model verdiği ve yüksek doğruluk sağladığı tespit edilmiştir. [54]

### 2.3.2.1. Burg Algoritması

Model katsayıları ( $a_k$ ), beyaz gürültünün toplam enerjisini ( $E = \sum_n e(n)^2$ ) en aza indirerek hesaplanmaktadır [55]. Aşağıdaki eşitlikten beyaz gürültü sinyalinin ( $e(n)$ ),  $x(n)$  sinyalinden hesaplanabileceği kolayca görülebilmektedir.


$$e(n) = x(n) + \sum_{k=1}^p a_k x(n-k) = \sum_{k=0}^p a_k x(n-k) \quad (7)$$

Burada  $a_0 = 1$ 'dir. Sinyal çerçevesi  $N$  örnekten oluşuyorsa  $x(0)$ ,  $x(1)$ , . . . ,  $x(N-1)$ , beyaz gürültü sinyali örnekleri  $e(p)$ ,  $e(p+1)$ , . . .  $e(N-1)$  sonlu bir dürtü yanıtı (FIR) tahmin hatası filtresinin çıktısı olarak kabul edilebilmektedir. Bu FIR filtresi, Şekil 2.4'de görülen kafes yapısı vasıtasıyla uygulanabilmektedir.

Kafes filtresinin denklemleri:

$$f_n^{(l)} = f_n^{(l-1)} + g_l b_{n-1}^{(l-1)} \quad (8)$$

$$b_n^{(l)} = b_n^{(l-1)} + g_l f_n^{(l-1)} \quad (9)$$



Şekil 2.4. Filtrenin kafes yapısı.

Burada  $f_n^{(l)}$  ve  $b_n^{(l)}$  ileri ve geri tahmin hataları ve  $g_l$ ,  $l$  evresinin yansımaya katsayılarıdır. Kalanlar için başlangıç değerleri  $f_n^{(0)} = b_n^{(0)} = x(n) = y_n$ 'dir. Burg algoritması,  $g_l$  yansımaya katsayılarını hesaplamakta, böylece ileri ve geri hataların toplamını minimize etmektedir. Bu, aynı AR katsayılarının sinyali ileri ve geri hatalardan kalanı tahmin edebileceğini varsaydığı anlamına gelmektedir. 1. evrede kalan enerjilerin toplamı:

$$E_l = \sum_{n=l}^{N-1} (f_n^{(l)})^2 + (b_n^{(l)})^2 \quad (10)$$

Yansımaya katsayısı  $g_l$  verimine göre  $E_l$ 'in minimize edilmesi:

$$\frac{\partial E_l}{\partial g_l} = 2 \sum_{n=l}^{N-1} \left\{ (f_n^{(l-1)} + g_l b_{n-1}^{(l-1)}) b_{n-1}^{(l-1)} + (b_{n-1}^{(l-1)} + g_l f_{n-1}^{(l-1)}) f_{n-1}^{(l-1)} \right\} = 0 \quad (11)$$

Buradan yansımaya katsayıları çözülebilmektedir.

$$g_l = \frac{-2 \sum_{n=l}^{N-1} f_n^{(l-1)} b_{n-1}^{(l-1)}}{\sum_{n=l}^{N-1} (f_n^{(l-1)})^2 + (b_{n-1}^{(l-1)})^2} \quad (12)$$

AR katsayıları  $a_k$ , Levinson - Durbin algoritması yoluyla  $g_l$  yansımaya katsayılarından elde edilebilmektedir. Özyineleme  $a_0^{(0)} = 1$  ile başlar ve

$$a_k^{(l)} = a_k^{(l-1)} + g_l a_{l-k}^{(l-1)} \quad k = 1, 2, \dots, l-1 \quad (13)$$

$$a_l^{(l)} = g_l \quad (14)$$

$l = 1, 2, \dots, p$  için yinelenir. Yinelemelerin sonunda,  $a_k^{(p)}$ , Denklem 8'in istenen tahmin hata filtre katsayılarını ( $a_k$ ) vermektedir. Denklem (12)  $|g_l| < 1$  koşulunu sağlar ve bu nedenle Burg yöntemi istikrarlı bir model sağlamak için elverişli olmaktadır [55].

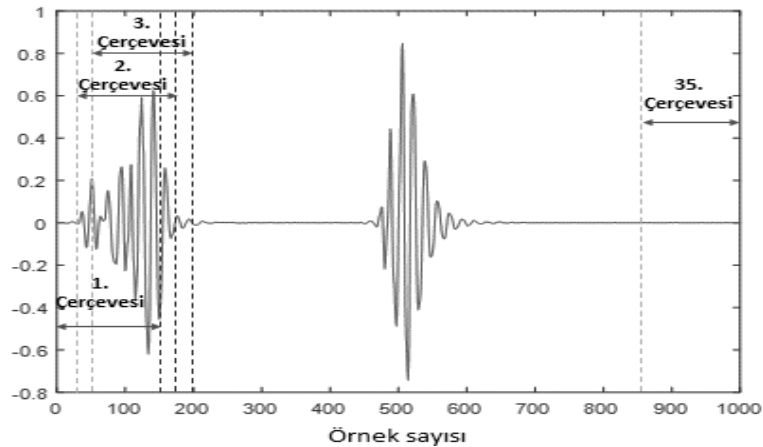
### 2.3.3. Ağırlık Merkezi Frekansı Hesaplaması

Her iki yöntemle (DFT ve AR) elde edilen frekans tepkisi  $H_i$  ve frekans noktalarından oluşan fiziksel vektör  $f_i$ 'nin yardımıyla bir çerçeve için ağırlık merkezi frekansı aşağıdaki gibi hesaplanabilmektedir:


$$f_c = \frac{\sum_{i=1}^N H_i f_i}{\sum_{i=1}^N H_i} \quad (15)$$

N: toplam frekans noktalarının sayısı


Tek bir kalp döngüsünü kapsayan bir kalp sesi sinyalinin ardışık çerçeveleri için hesaplanan merkezi frekans değerleri, o kalp döngüsünü temsil eden sonuçta ortaya çıkan nitelik vektörünün elemanlarını oluşturmaktadır. Her kardiyak döngü için 35 sinyal çerçevesi oluşturduğumuzdan, çalışmada kullanılan her kayıt için oluşan nitelik vektörlerinin boyutu 35'dir.




(a)



(b)



(c)



(d)

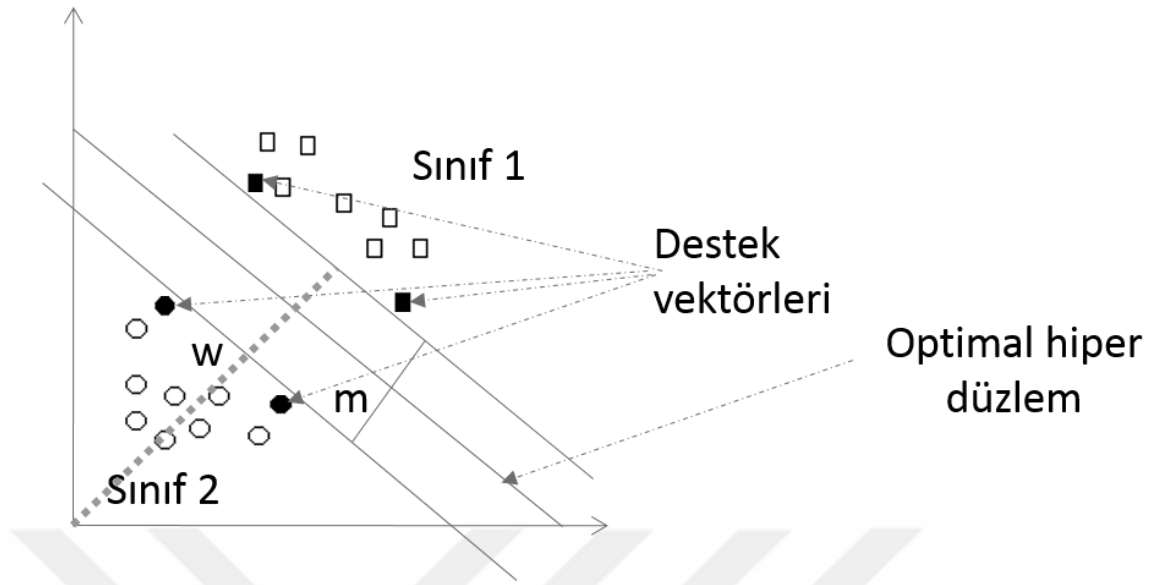
Şekil 2.5. (a) Kardiyak sinyalin zaman uzayında çerçevelere bölünmesi. (b) (a)'da verilen sinyalin örnek bir sinyal çerçevesi. (c) Örnek çerçeve için AR yöntemi ile elde edilen spektrum ve hesaplanan ağırlık merkezi frekansı. (d) (a)'daki sinyalin bütün çerçevelerinden ağırlık merkezi frekansları hesaplanarak elde edilen nitelik vektörünün değişimi.

## 2.4. Sınıflandırma

Son aşama, kardiyak döngüye karşılık gelen bir kaydın spektral içeriğinin zamanla değişimini temsil eden nitelik vektörünün, bir sınıflandırıcı tarafından işlendiği ve senaryoya bağlı olarak veri tabanı içindeki mevcut sınıflardan biriyle ilişkisinin kurulduğu sınıflandırma aşamasıdır. Bu çalışmada dört farklı sınıflandırıcı kullanılmıştır. Bunlar, K en yakın komşu sınıflandırıcısı (K-NN), destek vektör makinesi sınıflandırıcısı (SVM), uzun kısa-süreli-bellekli ağ sınıflandırıcısı (LSTM) ve bir boyutlu evrişimsel sinir ağı sınıflandırıcısıdır (1-D CNN). Bu sınıflandırıcılar farklı popüler sınıflandırma yaklaşımlarını temsil etmek üzere seçilmiştir ve aşağıda kısaca açıklanacaktır.

### 2.4.1. Destek Vektör Makinesi Sınıflandırıcı (Support Vector Machine - SVM)

Destek Vektör Makinesi (SVM), verilerin aşırı uyumunu önlemek için makine öğrenme teorisini uygulayan ve verilen görevi öngörmek için maksimum doğruluk sağlayan sınıflandırma için en yaygın kullanılan yöntemlerden biridir. Destek Vektör Makinesi, verileri yüksek boyutlu bir nitelik uzayına eşlemek ve varsayımsal bir doğrusal işlevler alanı oluşturmak için çekirdek hilesi (Kernel trick) kullanmaktadır [56]. Bu varsayımsal uzay, doğrusal olarak ayrılamayacak verileri sınıflandırmaya yardımcı olmaktadır. Sınıflandırma sırasında, kullanılan veriler noktalarla temsil edilmekte ve nitelik uzayında çizilmektedir. Genellikle hiper düzlem olarak adlandırılan farklı çizgiler, noktaları kendi sınıflarında bölmek için noktalar arasında çizilmektedir. İdeal olarak, aynı sınıfa atanan noktaların, hiper düzlem tarafından yapılan bölünmeden sonra aynı düzlemde durması gerekmektedir. Bu hiper düzlemler arasında, tüm sınıflara aynı anda maksimum mesafeyi koruyan ve kendi sınıflarındaki maksimum noktaları bölen hiper düzlem en uygun hiper düzlem olarak seçilmektedir. Bu optimal hiper düzlem sahip olduğu maksimum geometrik uyum nedeniyle yanlış sınıflandırma olasılığını en aza indirmektedir. Dolayısıyla bu hiper düzlem sınıfların sınırlarını tanımlamaktadır. Hiper düzleme en yakın olan noktalar destek vektörleri olarak bilinmektedir ve karar sınırını belirlemede çok önemli olmaktadır.



Şekil 2.6. Destek Vektör Makinesi ikili sınıflandırma örneği.

Şekil 2.6'da SVM kullanılarak yapılan ikili sınıflandırma örneği görülmektedir. İki sınıfı tam olarak bölen üç hiper düzlem vardır, ancak ortadaki hiper düzlem, iki sınıf arasındaki maksimum marja sahip olduğundan en uygun hiper düzlem olacaktır. Maksimum marjlı hiper düzlem kullanımı nedeniyle, SVM, Maksimum Marj Sınıflandırıcı olarak da bilinmektedir. Şekildeki boyalı elemanlar destek vektörleridir.

Varsayalım ki  $P = \{(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_n, y_n)\}$ , iki sınıfın (1 ve 2) olduğu bir eğitim setindeki veri noktalarını temsil etsin;  $x_n$  nitelik vektörünü temsil etsin,  $y_n$  sınıfı temsil etsin ve  $n$  gözlem sayısını temsil etsin. SVM'deki hiper düzlem aşağıdaki matematiksel ifade ile temsil edilmektedir:

$$w^T \cdot x + b = 0 \quad (16)$$

Burada  $w$ , hiper düzlemin normalidir (ağırlık),  $x$  eğitim veri noktasıdır ve  $b$  bir skaler ofset parametresidir.  $B$  değeri ayarlanarak marj artırılabilir. Hiper düzlem ile destek vektörünün arasındaki mesafenin maksimum genişliği aşağıdaki matematiksel ifade ile temsil edilmektedir:

$$m = \frac{2}{|w|} \quad (17)$$

$|w|$  değerini azaltmak için, her  $n$  için, ya  $(w \cdot x_n - b \geq 1)$  ya da  $(w \cdot x_n - b \leq -1)$  olması gerekmektedir.

#### 2.4.2. K En Yakın Komşu Sınıflandırıcı (K Nearest Neighbor – K-NN)

K en yakın komşu sınıflandırıcısı da makine öğrenmesinde kullanılan popüler sınıflandırma algoritmalarından biridir. Genellikle çıktıyı yorumlama kolaylığı ve düşük hesaplama maliyeti nedeniyle kullanılmaktadır. Adından da anlaşılacağı gibi, bu algoritma birbirine komşu noktalar arasındaki mesafeye bağlı olarak tahmin yapmaktadır. En yakın komşu belirli fonksiyonlar kullanılarak hesaplanmaktadır.

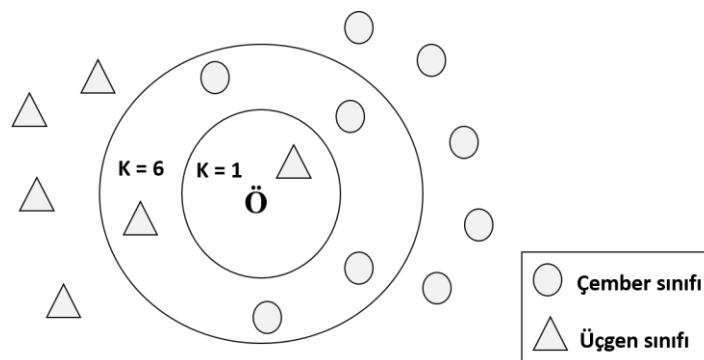
K-NN, nitelik uzayındaki en yakın eğitim örneklerine göre nesnelere sınıflandıran bir yöntemdir. K-NN, fonksiyonun sadece tahminen hesaplandığı ve tüm hesaplamaların sınıflandırmaya kadar ertelendiği, örnek tabanlı öğrenme türüdür. K-NN algoritmasında yer alan adımlar şunlardır:

1. K (en yakın komşu sayısı) değeri belirlenir.
2. Mesafe hesaplanır (Öklid mesafesi).

$P (P_1, P_2, \dots, P_n)$  ve  $Q (q_1, q_2, \dots, Q_n)$  İki nokta arasındaki Öklid mesafesi aşağıdaki denklem ile gösterilmiştir.

$$d(P, Q) = \sum_{i=1}^n (P_i - Q_i)^2 \quad (18)$$

3. K-minimum mesafe komşuları belirlenir.
4. En yakın komşuların Y kategorisi değerleri toplanır.
5. Sorgulama örneğinin değerini tahmin etmek için en yakın komşuların basit çoğunluğu kullanılır.

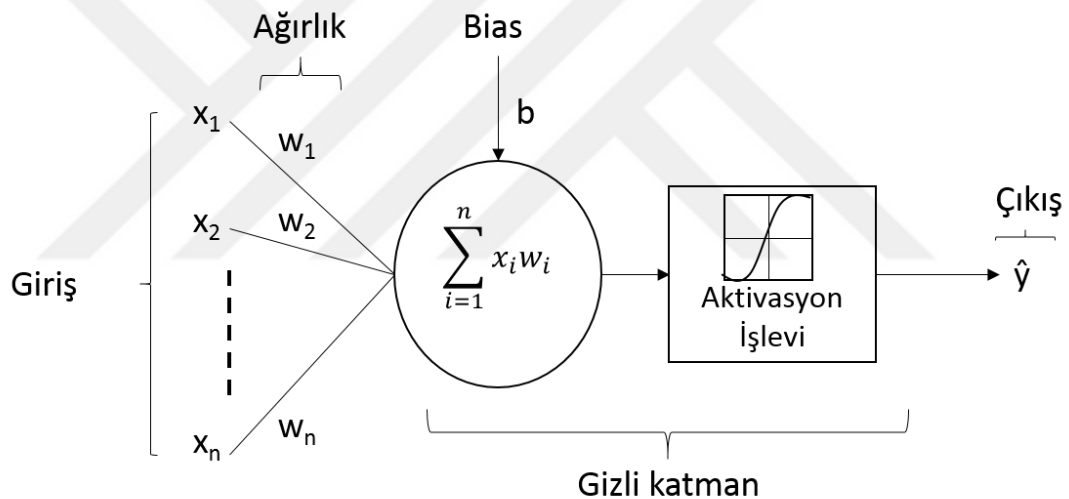


Şekil 2.7. K-NN ile sınıflandırma örneği.

Şekil 2.7'de, en yakın komşu sayısı 1 olarak seçildiğinde bir üçgen, en yakın komşu sayısı 6 olarak seçildiğinde bir daire olarak sınıflandırılan Ö örneği vardır. Bu şekilde olmasının sebebi  $k = 1$  olduğunda, sahip olduğu tek komşunun bir üçgen olması sebebiyle üçgen sınıfına atanmıştır.  $k=6$  olduğunda ise 4 çember, 2 üçgen komşusu olması sebebiyle en yakın komşunun çoğunluğu göz önüne alındığında, Ö için yeni örnek sınıfı çember sınıfı olarak belirlenmiştir.

En yakın komşu sayısının seçimi K-NN sınıflandırmasında çok önemlidir, çalışmada seçim sezgisel olarak belirlenmesine rağmen, deneysel olarak doğrulanmıştır.

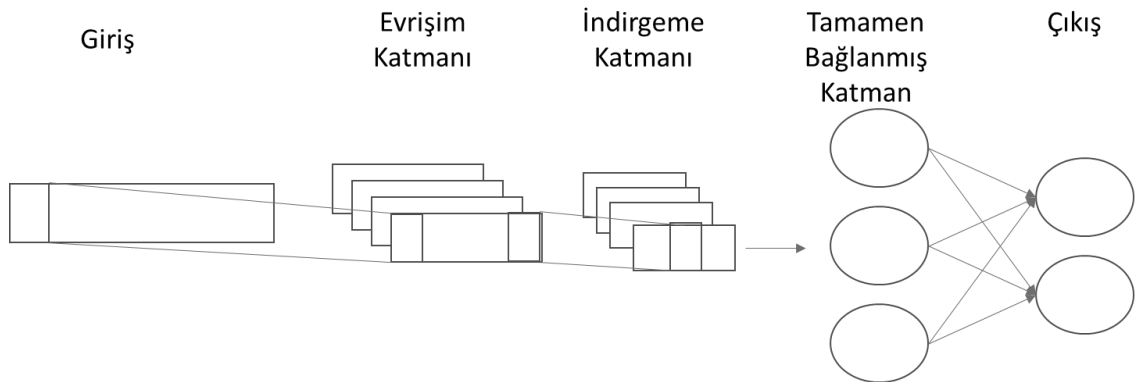
### 2.4.3. Evrişimsel Sinir Ağları (Convolutional Neural Network - CNN)



Şekil 2.8. Yapay sinir ağının yapısı.

Son yıllarda, derin öğrenme yöntemlerinin popülerliği artmıştır. Derin öğrenme yöntemi, makine öğrenim ailesinin içindedir. Derin sinir ağları, en az iki gizli katmanı olan yapay sinir ağlarıdır. Yapay sinir ağlarının temel birimlerine nöron denir ve bunlar insan beynindeki nöronların işlevlerini taklit etmeyi amaçlayan basit matematiksel modellerdir. Sinir ağının giriş katmanı dendrit olarak işlev görür, ağırlıklar sinapstır, gizli katman hücre gövdesine eşittir ve çıktı aksondur. Sinir ağının çekirdeği bir aktivasyon işlevidir.






Şekil 2.9. CNN sınıflandırıcısının yapısı.

Evrşimsel (Konvolüsyonel) Sinir Ağı, geleneksel yapay sinir ağlarında karşılaşılan yetersizlikleri gidermek için sunulan genişletilmiş bir yapay sinir ağıdır. CNN normalde giriş ve çıkış katmanları arasında üç ana katmandan oluşan bir ileri besleme ağı olarak tanımlanabilir [2]. En çok kullanılan üç CNN katmanı, aşağıdaki bölümde kısaca tarif edilmiştir.

1. Evrşimsel Katman: “Evrşimsel sinir ağı” adı bu katmandan gelir. Bu katman ağda bulunmalıdır, aksi takdirde CNN olmayacaktır. Bu katmanda, giriş ve filtre (çekirdek olarak da bilinir) arasında bir evrşim işlemi gerçekleştirilmektedir. Bu işlem verilen girişten özniteliği çıkarır ve bu katmanın çıktısı öznitelik haritası olarak bilinir. Bu katmanda gerçekleştirilen evrşim işlemi Şekil 2.10’da görülmektedir.



Şekil 2.10. CNN’de evrşim işlemi.

Verilen giriş  $i$  ve çekirdek  $k$  için çıktı  $o$  aşağıdaki hesaplama ile elde edilmektedir:

$$o(1) = 1x2 + 0x1 + 2x5 = 12$$

$$o(2) = 0x2 + 2x1 + 4x5 = 22$$


$$o(3) = 2x2 + 4x1 + 1x5 = 13$$

$$o(4) = 4x2 + 1x1 + 6x5 = 39$$

$$o(5) = 1x2 + 6x1 + 3x5 = 23$$

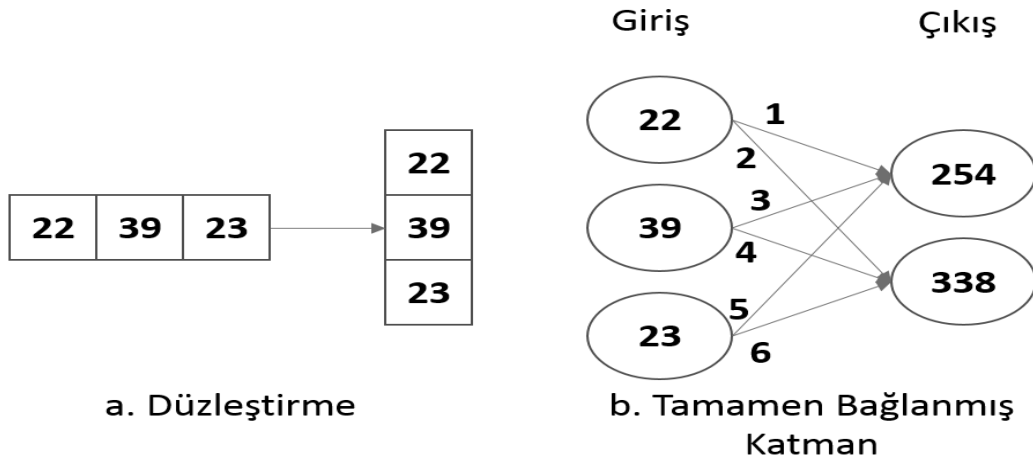
$$o(6) = 6x2 + 3x1 + 0x5 = 15$$

2. İndirgeme Katmanı: İndirgeme katmanının işlevi gereksiz özellikleri kaldırmak ve evrişimsel katmandan elde edilen nitelik haritasının boyutunu azaltmaktır. Verilerin aşırı uyumlu olmasını önlemektedir. En büyüğe indirgeme, en küçüğe indirgeme ve ortalamaya indirgeme gibi farklı türlü indirgeme işlemleri vardır. CNN’de normalde en yükseğe indirgeme kullanılır. En büyüğe indirgeme işleminde, seçilen adım büyüklüğü arasındaki en büyük değer seçilir ve kalanlar nitelik haritasından çıkarılır. En büyüğe indirgeme işlemi Şekil 2.11’de görülmektedir.




Şekil 2.11. En büyüğe indirgeme işlemi.

3. Tamamen Bağlı Katman: Tamamen bağlanmış katman, sinir ağının gizli katmanına benzer, sadece farkı her zaman bir sonraki katmana tam olarak bağlanmasıdır. Tam olarak bağlanmış katmanın girişi sütun vektörü olacaktır. Tam bağlı katmanı beslemeden önce, önceki nitelik haritasını sütun vektörüne dönüştürme işlemi düzleştirme olarak bilinir. Son tamamen bağlı katmandaki nöron sayısının seçimi, sınıflandırmada kullanılan etiket sayısına eşit olmalıdır. İki nöron arasındaki bağlantı belirli bir ağırlıkla sağlanmaktadır, giriş ve ağırlıklar arasında çaprazlama yapıp bu çaprazlama sonuçlarının toplanmasıyla çıktı elde edilmektedir.



Şekil 2.12. a) Düzleştirme işlemi, b) Tamamen bağlı katmanda yapılan işlem.



Şekil 2.13. Önerilen 1-D CNN yapısı.

Şekil 2.13'de önerilen 1-D CNN modelinin yapısı görülmektedir. Görüntü işlemede kullanılan normal CNN modellerinin aksine, 1-D CNN hiçbir indirgeme katmanına sahip değildir. Normalde indirgeme katmanları, verilerin tekrarlayan öz niteliklerini azaltmak için kullanılmaktadır; ancak bu çalışmada, çok küçük boyutta olan bir nitelik vektörü girdi olarak kullanılmaktadır.

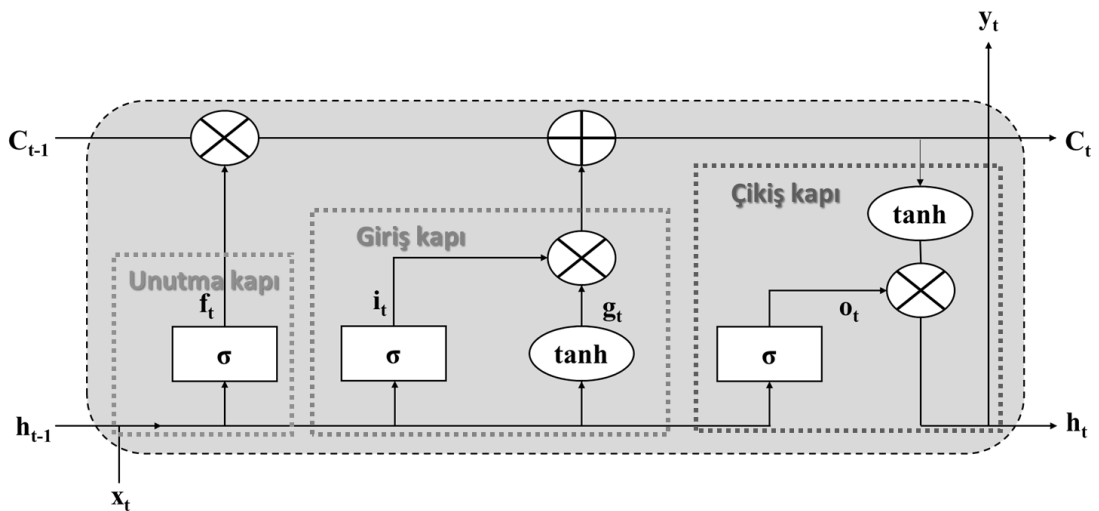
Her biri, yiğın normalizasyon katmanı ve doğrultulmuş doğrusal birim (Rectified Linear Unit - ReLU) katmanını izleyen toplam dört evrişimsel katman vardır. İç normal değişken kayma problemini çözmek için yiğın normalizasyon katmanı kullanılmaktadır [57]. Bu katmanda, her bir mini yiğın standardize edilmiştir. Yiğın normalizasyon katmanı, ağır öğrenme sürecini dengelemekte ve eğitim için gereken süreyi azaltarak eğitim süresini hızlandırmaktadır. ReLU katmanı, bir aktivasyon fonksiyonu olup

parçalı doğrusal bir ReLU fonksiyonuna sahiptir. ReLU işlevi birçok sinir ağında ağırlık hızını artırmak için kullanılır.

Bu mimaride tamamen birbirine bağlı iki katman vardır: FC-1 ve FC-2. Son ReLU katmanı FC-1'e ve ardından FC-2'ye bağlanmaktadır. Sınıflandırma görevi, FC-2'nin çıkışı ile beslenen softmax katmanında gerçekleştirilmektedir. FC-2'deki nöronların sayısı, kullanılan verilerde mevcut olan sınıfların sayısına eşittir. İkili sınıflandırma için Lojistik fonksiyon kullanılabilir ancak çoklu sınıflandırma için uygun değildir. Bu çalışmada softmax fonksiyonunun sınıflandırma için kullanılmasının nedeni budur.

#### 2.4.4. Uzun Kısa-Sürel-Bellekli Ağ (Long Short-Term Memory - LSTM)

LSTM ağı, tekrarlayan sinir ağında (RNN) meydana gelen uzun vadeli bağımlılık problemini çözmek için ortaya atılmıştır [58]. LSTM ağları, bilgiyi diğer sinir ağlarına kıyasla daha uzun süre hafızasında tutma yeteneğine sahiptir ve bu da dizi tahmin sorunlarının çözülmesine yardımcı olmaktadır. LSTM ağının hafızasını geliştirmek için dört ana bileşen bir araya gelmektedir: hafıza hücresi, unutma kapısı, giriş kapısı ve çıkış kapısı. Üç kapı, bellek hücresine gelecek adım için hangi bilgilerin kaydedilmesi ve hangilerinin silinmesi gerektiğine karar verilmesine yardımcı olur. LSTM ağının benzersiz mimarisi Şekil 2.14'de görülmektedir. LSTM ağının farklı kapılarını içeren işlemler aşağıdaki bölümde kısaca açıklanmaktadır.



Şekil 2.14. LSTM ağının mimarisi [59].

Unutma Kapısı: Bir unutma kapısının işlevi, fazlalıktan kaçınmak ve performansı optimize etmek için bilgileri hücre durumundan çıkarmaktır. İki girişi vardır: (1)  $h_{t-1}$ ,  $t-1$  basamağında meydana gelen hücrenin çıktısı, (2)  $x_t$ , geçerli zaman basamağı  $t$ 'nin girişi. Girişlerin ağırlık vektörleri ile çarpılması sonucu elde edilen çarpma ve biasların toplamı sigmoid fonksiyonu ile uygulanmaktadır. Çıktı, aralığı 0 ila 1 olan bir vektör şeklindedir. Sigmoid, bilgiyi hücre durumunun içinde / dışında tutmak ya da silme kararı vermekten sorumludur. Çıktı 0 ise, kapı çıktı bilgisini tamamen kaldırırken, çıktı 1 için tüm bilgiyi hücre durumuna kaydetmektedir. Unutma kapısının çıkışı daha sonra, önceki hafıza durumu ile çarpılır.

Giriş Kapısı: Giriş kapısının işlevi, verilen bilgilerin önemi ve fazlalığına ilişkin bir karar vermek ve önemliyse bu bilgiyle birlikte bellek durumunu depolamak ve güncellemektir. Bu giriş kapısı ayrıca unutma kapısı ile aynı iki girişe sahiptir. Girişlerin ağırlık vektörleri ile çarpılmasıyla elde edilen çarpma ve biasların toplamı sigmoid ve tanh fonksiyonu ile uygulanmaktadır. Tanh işleminde, çıktı -1 ile 1 arasındadır. Sigmoid işleminde çıktı, hangi bilgilerin unutulacağına karar vermekte, tanh çıktısı ise hangi bilgilerin ekleneceğini seçmektedir. İşlemler sonucunda bu iki çıkış çarpılıp başlangıçtaki mevcut bellek durumuna eklenmektedir.

Çıkış Kapısı: Bir çıkış kapısının işlevi, mevcut bellek durumunda hangi bilgilerin yararlı olduğuna karar vermek ve bunları bir çıkış olarak seçmektir. Yine, önceki kapıya benzer şekilde iki giriş ağırlık vektörleriyle çarpılır. Çıktıların toplamı ve bias sigmoid işlevi ile uygulanır. Tanh fonksiyonu, mevcut hafıza durumuna ( $C_t$ ) uygulanır ve çıkış, mevcut katmanın son çıkışını ( $h_t$ ) veren sigmoid fonksiyonunun çıkışı ile çarpılır. Softmax katmanına gönderilecek olan çıkış nihai çıkış olabilir ya da bir sonraki gizli katmana giriş olabilir.

Bu çalışmada, 5 katmanlı LSTM sinir ağı uygulanmıştır. Birinci katman giriş, ikincisi 100 gizli birimden oluşan (100 bellek bloğu) iki yönlü LSTM'dir. Üçüncü katman tamamen bağlı katmandır, dördüncü katman sınıflandırma için softmax katmanıdır ve son katman çıkış katmanıdır. Tek yönlü LSTM'den farklı olarak, iki yönlü LSTM hem geçmişten hem gelecekte olan bilgiyi koruyabilmektedir [60]. Bu çalışmada iki yönlü

LSTM'nin seçilmesinin sebebi, tek yönlü LSTM'den daha iyi performans göstermesidir.

## 2.5. Sınıflandırıcı Performanslarının Karşılaştırılması

Kullanılan sınıflandırıcıların karşılaştırmasını yapabilmek için kullanılan performans parametreleri hata matrisindeki bilgiler yardımıyla hesaplanır. Şekil 2.15'de örnek bir hata matrisi verilmiştir.

		Öngörülen sınıf	
		Anormal	Normal
Gerçek Sınıf	Anormal	TP	FN
	Normal	FP	TN

Şekil 2.15. Örnek hata matrisi.

Burada, TP (Doğru Pozitif) = Hasta olan vakanın doğru bir şekilde hasta olarak sınıflandırılmasını temsil eder.

FP (Yanlış Pozitif) = Sağlıklı bir vakanın yanlış bir şekilde hasta olarak sınıflandırılmasını temsil eder.

TN (Doğru Negatif) = Sağlıklı bir vakanın doğru bir şekilde sağlıklı olarak sınıflandırılmasını temsil eder.

FN (Yanlış Negatif) = Hasta bir vakanın yanlış bir şekilde sağlıklı olarak sınıflandırılmasını temsil eder.

Performans parametrelerini hesaplamak için aşağıdaki formüller kullanılmıştır:

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (21)$$

$$\text{Hassasiyet} = \frac{TP}{TP+FN} \text{ [doğru pozitif sınıflandırılmış pozitif olguların oranı]} \quad (22)$$

$$\text{Özgüllük} = \frac{TN}{FP+TN} \text{ [dođru negatif olarak sınıflandırılmış negatif olguların oranı]} \quad (23)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \text{ [pozitif tahmin oranı]} \quad (24)$$

$$\text{F1 Puanını} = \frac{2*(\text{hassasiyet}*\text{kesinlik})}{(\text{hassasiyet}+\text{kesinlik})} \quad (25)$$

Çok sınıflı sınıflandırma için, performans parametreleri yine hata matrislerinin yardımıyla hesaplanmıştır ancak 5 sınıf için kullanılan hata matrislerinin düzenlenmesi, ikili sınıftan daha farklı olmaktadır. Bu nedenle 5 sınıf için kullanılan hata matrislerinin şablonları aşağıda ayrıca Şekil 2.16, 2.17, 2.18, 2.19 ve 2.20’de ayrı ayrı verilmiştir. Ayrıca çok sınıflı sınıflandırmada TP, TN, FP ve FN değerleri farklı olmaktadır. Bu nedenle her sınıf için hassasiyet, özgüllük ve kesinlik değerleri hesaplanırken öncelikle her sınıf için denklem 22, 23 ve 24 kullanılarak bireysel hassasiyet, özgüllük ve kesinlik hesaplanır, daha sonra ortalamaları alınarak genel hassasiyet, özgüllük ve kesinlik değerleri hesaplanmaktadır. F1 puanı, denklem 25 kullanılarak genel hassasiyet ve kesinliğin yardımıyla tahmin edilmektedir.

Çok sınıf için doğruluk aşağıdaki formül kullanılarak hesaplanmaktadır.

$$\text{Dođruluk} = \frac{\text{toplam dođru tahmin olan vakalar}}{\text{toplam vakalar}} \quad (26)$$

		Öngörülen sınıf				
		Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4	Sınıf 5
Gerçek Sınıf	Sınıf 1	TP	FN	FN	FN	FN
	Sınıf 2	FP	TN	TN	TN	TN
	Sınıf 3	FP	TN	TN	TN	TN
	Sınıf 4	FP	TN	TN	TN	TN
	Sınıf 5	FP	TN	TN	TN	TN

Şekil 2.16. Sınıf 1 için çoklu hata matrisinde TN, TP, FN ve FP değerlerinin pozisyonları.

		Öngörülen sınıf				
		Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4	Sınıf 5
Gerçek Sınıf	Sınıf 1	TN	FP	TN	TN	TN
	Sınıf 2	FN	TP	FN	FN	FN
	Sınıf 3	TN	FP	TN	TN	TN
	Sınıf 4	TN	FP	TN	TN	TN
	Sınıf 5	TN	FP	TN	TN	TN

Şekil 2.17. Sınıf 2 için çoklu hata matrisinde TN, TP, FN ve FP değerlerinin pozisyonları.

		Öngörülen sınıf				
		Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4	Sınıf 5
Gerçek Sınıf	Sınıf 1	TN	TN	FP	TN	TN
	Sınıf 2	TN	TN	FP	TN	TN
	Sınıf 3	FN	FN	TP	FN	FN
	Sınıf 4	TN	TN	FP	TN	TN
	Sınıf 5	TN	TN	FP	TN	TN

Şekil 2.18. Sınıf 3 için çoklu hata matrisinde TN, TP, FN ve FP değerlerinin pozisyonları.

		Öngörülen sınıf				
		Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4	Sınıf 5
Gerçek Sınıf	Sınıf 1	TN	TN	TN	FP	TN
	Sınıf 2	TN	TN	TN	FP	TN
	Sınıf 3	TN	TN	TN	FP	TN
	Sınıf 4	FN	FN	FN	TP	FN
	Sınıf 5	TN	TN	TN	FP	TN

Şekil 2.19. Sınıf 4 için çoklu hata matrisinde TN, TP, FN ve FP değerlerinin pozisyonları.



		Öngörülen sınıf				
		Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4	Sınıf 5
Gerçek Sınıf	Sınıf 1	TP	TN	TN	TN	FP
	Sınıf 2	TN	TN	TN	TN	FP
	Sınıf 3	TN	TN	TN	TN	FP
	Sınıf 4	TN	TN	TN	TN	FP
	Sınıf 5	FN	FN	FN	FN	TP

Şekil 2.20. Sınıf 5 için çoklu hata matrisinde TN, TP, FN ve FP değerlerinin pozisyonları.

## 2.6. Çapraz Doğrulama

Çapraz doğrulama, modelin performans ölçütlerinin değerlendirilmesinde kullanılan bir yöntemdir. Çapraz doğrulama sırasında, veri kümesi normalde iki alt gruba ayrılmaktadır: eğitim seti ve test seti. Eğitim seti, önerilen modeli eğitmek için kullanılmakta ve test seti modelin eğitim veri kümesi dışındaki yeni veri kümesiyle performansını değerlendirmek için kullanılmaktadır. Çapraz doğrulama esnasında, verilen model ile birçok kez test yapılmakta ve ilgili modelin gerçek performans ölçümlerini değerlendirmek için elde edilen değerlerin ortalaması hesaplanmaktadır. Çapraz doğrulama gerçekleştirmek için k katlamalı çapraz doğrulama, holdout yöntemi, tek çıkışlı çapraz doğrulama vb. çeşitli yöntemler mevcuttur. Bu çalışmada, kullanılan sınıflandırıcının performansını değerlendirmek için k katlamalı çapraz doğrulama yöntemi seçilmiştir.

K katlamalı çapraz doğrulama yönteminde, veri kümeleri rastgele  $k$  tane alt gruba bölünür.  $K$  altkümesi içinde, bir alt küme test seti olarak alınmakta ve geri kalan  $k-1$  alt küme, eğitim seti olarak kullanılmaktadır. İşlem  $k$  kez tekrarlanmaktadır. Her iterasyonda, test seti değişmekte ve bir iterasyona ait test setinin elemanları başka bir iterasyondaki test setinde yer almamaktadır.

Bu çalışma için  $k$ 'nin değeri 5 olarak seçilmiştir. Katsayı seçiminde kesin bir kural yoktur. Fakat  $k$  değerinin, veri kümesinden eşit sayıda örnekler içeren  $k$  tane alt kümesine bölünecek şekilde seçilmesi önerilmektedir.  $K$ 'nin her alt kümede örneklerin eşit dağılımını sağlayamadığı durumda,  $k-1$  katları içlerinde eşit sayıda örneğe sahiptir ve geri kalan bir kat diğer alt gruplardan biraz daha az sayıda örneğe sahiptir.

## 3. BÖLÜM

### BULGULAR

#### 3.1.Bulgular

Başlangıçta, her biri üç kalp döngüsüne sahip olan kardiyak ses kayıtları alınmıştır. Ön işleme sırasında, her kayıt tek kalp döngüsünden oluşan 3 bölüme ayrılmıştır. Daha sonra önceki bölümde açıklandığı gibi spektral kestirme yöntemleri (FFT ve AR yöntemleri) kullanılarak kalp seslerine ait nitelik vektörleri elde edilmiştir. Bu nitelik vektörleri ayrı ayrı dört farklı sınıflandırıcıya verilmiştir. Sınıflandırma işlemi hem ikili sınıf (normal ve anormal) hem de çoklu sınıf (5 farklı sınıf) için gerçekleştirilmiştir. Tüm sınıflandırıcıların performans metriklerini doğrulamak için beş kat çapraz doğrulama yapılmıştır. Sınıflandırıcılardan elde edilen sonuçlar hata matrisleri kullanılarak gösterilmiştir.

Aşağıda iki farklı nitelik vektörü (AR ve FFT yöntemleri kullanılarak elde edilmiş) kullanılarak SVM, K-NN, LSTM ve 1-D CNN sınıflandırıcıları ile ikili sınıflandırmalardan elde edilen 8 hata matrisi verilmiştir (Şekil 3.1, Şekil 3.2, Şekil 3.3 ve Şekil 3.4).

		Öngörülen sınıf	
		Anormal	Normal
Gerçek sınıf	Anormal	2380	20
	Normal	26	574

(a)

		Öngörülen sınıf	
		Anormal	Normal
Gerçek sınıf	Anormal	2392	8
	Normal	13	587

(b)

Şekil 3.1. SVM sınıflandırıcısı kullanılarak yapılan ikili sınıflandırma için hata matrisleri, (a) FFT yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma, (b) AR yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma.

		Öngörülen sınıf	
		Anormal	Normal
Gerçek sınıf	Anormal	2377	23
	Normal	16	584

(a)

		Öngörülen sınıf	
		Anormal	Normal
Gerçek sınıf	Anormal	2395	5
	Normal	7	593

(b)

Şekil 3.2. K-NN sınıflandırıcısı kullanılarak yapılan ikili sınıflandırma için hata matrisleri, (a) FFT yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma, (b) AR yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma.

		Öngörülen sınıf	
		Anormal	Normal
Gerçek sınıf	Anormal	2358	42
	Normal	78	522

(a)

		Öngörülen sınıf	
		Anormal	Normal
Gerçek sınıf	Anormal	2379	21
	Normal	51	549

(b)

Şekil 3.3. LSTM sınıflandırıcısı kullanılarak yapılan ikili sınıflandırma için hata matrisleri, (a) FFT yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma, (b) AR yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma.

		Öngörülen sınıf	
		Anormal	Normal
Gerçek sınıf	Anormal	2380	20
	Normal	30	570

(a)

		Öngörülen sınıf	
		Anormal	Normal
Gerçek sınıf	Anormal	2388	12
	Normal	9	591

(b)

Şekil 3.4. 1-D CNN sınıflandırıcısı kullanılarak yapılan ikili sınıflandırma için hata matrisleri, (a) FFT yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma, (b) AR yönteminden elde edilen nitelik vektörü kullanılarak yapılan sınıflandırma.

Önceki sayfadaki hata matrislerinde, boyalı kutular doğru sınıflandırılmış durumların sayısını temsil etmektedir. Bu hata matrislerine bakıldığında, AR yönteminden elde edilen niteliklerin FFT yönteminden elde edilen niteliklere göre daha iyi olduğu gözlenmektedir. Uygulanan bu iki yöntem de sınıflandırıcıların daha iyi performans göstermesine katkıda bulunmuştur. Sınıflandırıcılar arasında karşılaştırma yapıldığında; K-NN sınıflandırıcısı her iki nitelik çıkarma yöntemiyle de en iyi sınıflandırmayı yaparken, LSTM yöntemi bu deney seti için en kötü sonucu vermiştir.

Tablo 3.1’de sınıflandırıcıların performanslarını değerlendirmek için kullanılan ve matematiksel formülleri daha önce yöntem bölümünde verilen performans metriklerinin değerleri sunulmaktadır.

Tablo 3.1. İkili sınıflandırma için farklı sınıflandırıcıların performans metriklerinin karşılaştırılması.

		<b>Doğruluk (%)</b>	<b>Hassasiyet (%)</b>	<b>Özgüllük (%)</b>	<b>F1 puanı (%)</b>
<b>SVM</b>	<b>AR</b>	99.30	99.67	97.83	99.56
	<b>FFT</b>	98.47	99.17	95.67	99.04
<b>K-NN</b>	<b>AR</b>	<b>99.60</b>	<b>99.79</b>	<b>98.83</b>	<b>99.75</b>
	<b>FFT</b>	98.70	99.04	97.33	99.19
<b>LSTM</b>	<b>AR</b>	97.60	99.12	91.50	98.51
	<b>FFT</b>	96.00	98.25	87.00	97.52
<b>1-D CNN</b>	<b>AR</b>	99.30	99.50	98.50	99.56
	<b>FFT</b>	98.33	99.17	95.00	98.96

Elde edilen sonuçlara göre sınıflandırıcıların performansları oldukça benzerdir. Performans metriklerinin değerleri arasında büyük farklılıklar olmasa da AR yönteminden elde edilen sonuçlar, her bir sınıflandırıcı için FFT yönteminden elde edilenlerden daha iyi durumdadır. AR yöntemi, spektral kestirim için FFT yöntemine göre daha iyi durumda olduğunu ortaya koymaktadır. LSTM sınıflandırıcısı, FFT nitelik vektörünü kullanarak %96.00, AR nitelik vektörünü kullanarak %97.60 doğrulukla tüm sınıflandırıcılar arasında en düşük doğruluk oranına sahiptir. K-NN sınıflandırıcısı ise FFT nitelik vektörü ile %98.70, AR nitelik vektörü ile %99.60 doğruluk oranı vererek iki sınıf için yapılan sınıflandırmada en iyi performansı göstermiştir.

Aynı şekilde; AR ve FFT yöntemleri kullanılarak elde edilen iki farklı nitelik vektörünün SVM, k-NN, LSTM ve 1-D CNN sınıflandırıcılarına giriş olarak verilmesi ile 5 sınıf için sınıflandırma yapılmış ve elde edilen hata matrisleri Şekil 3.5, Şekil 3.6, Şekil 3.7, Şekil 3.8, Şekil 3.9, Şekil 3.10, Şekil 3.11, ve Şekil 3.12'da verilmiştir.

		Öngörülen sınıf				
		AD	MY	MD	MKÇ	N
Gerçek Sınıf	AD	560	15	10	14	1
	MY	22	542	18	16	2
	MD	13	34	529	16	8
	MKÇ	19	21	18	535	7
	N	5	3	4	8	580

Şekil 3.5. FFT yöntemiyle elde edilen nitelik vektörü ile SVM sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.

		Öngörülen sınıf				
		AD	MY	MD	MKÇ	N
Gerçek Sınıf	AD	568	10	9	12	
	MY	10	561	9	19	1
	MD	7	7	572	10	4
	MKÇ	8	18	4	567	3
	N	3	2	4	3	588

Şekil 3.6. AR yöntemiyle elde edilen nitelik vektörü ile SVM sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.

		Öngörülen sınıf				
		AD	MY	MD	MKÇ	N
Gerçek Sınıf	AD	572	12	6	8	2
	MY	18	541	21	16	4
	MD	24	24	531	13	8
	MKÇ	16	35	19	522	8
	N	5	1	7	5	582

Şekil 3.7. FFT yöntemiyle elde edilen nitelik vektörü ile K-NN sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.

		Öngörülen sınıf				
		AD	MY	MD	MKÇ	N
Gerçek Sınıf	AD	572	9	9	9	1
	MY	4	572	9	13	2
	MD	3	2	587	5	3
	MKÇ	6	20	2	572	0
	N	3	1	3	1	592

Şekil 3.8. AR yöntemiyle elde edilen nitelik vektörü ile K-NN sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.

		Öngörülen sınıf				
		AD	MY	MD	MKÇ	N
Gerçek Sınıf	AD	504	44	23	29	0
	MY	29	503	33	34	1
	MD	7	34	494	56	9
	MKÇ	26	60	41	470	3
	N	5	23	16	22	534

Şekil 3.9. FFT yöntemiyle elde edilen nitelik vektörü ile LSTM sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.

		Öngörülen sınıf				
		AD	MY	MD	MKÇ	N
Gerçek Sınıf	AD	534	24	11	31	0
	MY	24	529	20	21	6
	MD	7	21	551	10	11
	MKÇ	16	26	12	541	5
	N	0	1	9	1	589

Şekil 3.10. AR yöntemiyle elde edilen nitelik vektörü ile LSTM sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.

		Öngörülen sınıf				
		AD	MY	MD	MKÇ	N
Gerçek Sınıf	AD	566	17	7	9	1
	MY	10	546	22	20	2
	MD	2	9	573	11	5
	MKÇ	12	21	14	549	4
	N	3	1	6	6	584

Şekil 3.11. FFT yöntemiyle elde edilen nitelik vektörü ile 1-D CNN sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi



		Öngörülen sınıf				
		AD	MY	MD	MKÇ	N
Gerçek Sınıf	AD	584	6	3	7	0
	MY	7	578	3	11	1
	MD	2	1	592	4	1
	MKÇ	6	7	0	587	0
	N	0	2	3	1	594

Şekil 3.12. AR yöntemiyle elde edilen nitelik vektörü ile 1-D CNN sınıflandırıcısı kullanılan çoklu sınıflandırma için hata matrisi.

Sonuçlar çok sınıflı sınıflandırma için, AR yönteminin daha etkili olduğunu ortaya koymaktadır. Çok sınıf için gösterilen hata matrislerinde renkli kutular doğru sınıflandırılmış durumları temsil etmektedir. Matrislerde görüldüğü üzere, dört sınıflandırıcı arasından 1D-CNN sınıflandırıcısı vakaları daha doğru bir şekilde sınıflandırırken, LSTM yöntemi en düşük doğruluğu vermiştir.

Tablo 3.2’de sınıflandırıcıların performanslarını değerlendirmek için kullanılan ve matematiksel formülleri daha önce yöntem bölümünde verilen performans metriklerinin değerleri verilmiştir.

Tablo 3.2. Çoklu sınıflandırma için farklı sınıflandırıcıların performans metriklerinin karşılaştırılması.

		Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	F1 puanı (%)
SVM	AR	95.20	95.20	98.80	95.20
	FFT	91.53	91.53	97.88	91.54
K-NN	AR	96.50	96.50	99.12	96.50
	FFT	91.60	91.60	97.90	91.60
LSTM	AR	91.47	91.47	97.87	91.45
	FFT	83.50	83.50	95.87	83.90
1-D CNN	AR	<b>97.84</b>	<b>97.84</b>	<b>99.46</b>	<b>97.84</b>
	FFT	93.93	93.93	98.48	93.94

Performans metrik tablosunda görüldüğü üzere çok sınıf için sınıflandırmada, AR yöntemi FFT yönteminden daha iyi performans göstermiştir. 1-D CNN, AR yönteminden elde edilen nitelik vektörleri sayesinde %97.84 doğruluk oranı ile en yüksek doğruluğu gösterirken, FFT nitelik vektörü kullanılarak %93.93 doğruluk elde edilmiştir. LSTM sınıflandırıcısı FFT nitelik vektörü kullanılarak %83.50 doğrulukla en düşük performansı gösterirken, AR nitelik vektörü kullanılarak %91.47 doğruluk elde edilmiştir. Bu sonuçlara göre çok sınıf için yapılan sınıflandırmada kullanılacak en iyi yöntem AR nitelik vektörünün giriş olarak 1-D CNN sınıflandırıcısına uygulanması olacaktır.

## 4. BÖLÜM

### TARTIŞMA - SONUÇ ve ÖNERİLER

#### 4.1.Tartışma

Bu çalışmada gerçekleştirilen sınıflandırmalar temelde iki kategoriye ayrılmaktadır: ikili sınıflandırma ve çoklu sınıflandırma. Bu iki sınıflandırma işlemi dört farklı tür sınıflandırıcı ile yapılmıştır. Önerilen nitelik çıkarma yöntemlerinin etkinliğinin değerlendirilmesini kolaylaştırmak için daha sonra farklı nitelik çıkarma yöntemlerinden elde edilen iki nitelik vektörü birer birer her bir sınıflandırıcıya girdi olarak verilmiştir.

Farklı nitelik vektörlerinin kullanımına dayanan ikili sınıflandırma için sınıflandırma işleminin performansının karşılaştırılmasında, AR yöntemi kullanılarak elde edilen nitelik vektörünü kullanan sınıflandırıcıların daha iyi performans gösterdiği görülmüştür. Sınıflandırıcıların performans ölçütlerinin değerleri arasındaki fark büyük olmasa da AR yönteminden elde edilen nitelik vektörü ile FFT yönteminden elde edilen nitelik vektörü karşılaştırıldığında tüm performans ölçütlerinin değerleri (doğruluk, duyarlılık, özgüllük ve F1 puanı) AR yöntemi ile elde edilen nitelik vektörü kullanıldığında daha yüksek bulunmuştur.

İkili sınıflandırma için sınıflandırıcıların performansı karşılaştırıldığında K-NN sınıflandırıcısı, her iki nitelik vektörü için de daha iyi performans göstermiştir. K-NN sınıflandırıcısının elde ettiği doğruluklar AR temelli nitelik vektörü kullanıldığında %99.60, FFT temelli nitelik vektörü kullanıldığında %98.70 olmuştur. SVM ve 1-D CNN sınıflandırıcılarının doğruluğu, AR yönteminden elde edilen nitelik vektörü kullanıldığında %99.30 değeri ile aynı iken, FFT yönteminden elde edilen nitelik

vektörü kullanıldığında çok küçük bir değişiklik görülmüştür (SVM: %98.47 ve 1-D CNN: %98.33). LSTM sınıflandırıcısı ise AR temelli nitelik vektörü ile %97.60 ve FFT temelli nitelik vektörü ile %96.00 doğruluk oranlarını vererek dört sınıflandırıcı arasında en az başarı gösteren sınıflandırıcı olmuştur.

Sınıflandırma deneylerine ait sonuçlar incelendiğinde dikkat çeken en önemli sonuçlardan birisi tüm sınıflandırıcıların, ikili sınıflandırma için veri setinin (2400:600) dengesiz dağılımına rağmen oldukça iyi bir performans göstermesidir. Normalde dengesiz veriler, genellikle daha az sayıda veri içeren grubun yanlış sınıflandırılmasına neden olur. Bu çalışmada, sınıflandırıcıların performansı dengesiz dağılımdan etkilenmemiştir ve elde edilen yüksek doğruluk sadece daha fazla sayıda veri içeren grubun doğru sınıflandırılmasından dolayı değil az sayıda veri içeren grubun da doğru sınıflandırılmasından dolayı elde edilmiştir. Bu durum diğer performans parametreleri (özgüllük, duyarlılık ve F1 puanı) ile de doğrulanmıştır. K-NN sınıflandırıcısı ile elde edilen %99.60'lık maksimum doğruluk için özgüllük %98.30, duyarlılık %99.79 ve F1 puanı %99.75 olarak hesaplanmıştır. Bu sonuçlar az sayıda veri içeren normal, yani hasta olmayan grubun da yüksek doğrulukta sınıflandırıldığını göstermektedir. Bu nedenle, bu çalışmada sunulan bütün sınıflandırma deneylerinde temel alınan niteliğin gürbüz (robust) olduğu anlaşılmaktadır.

Benzer şekilde, seçilen farklı nitelik vektörlerine bağlı olarak aynı sınıflandırıcıların çoklu sınıflandırma performansları karşılaştırılmıştır. Sonuç ikili sınıflandırma için elde edilene benzerdir. Çoklu sınıflandırma için, AR yönteminden elde edilen nitelik vektörü, FFT yönteminden elde edilen nitelik vektörünün performans metriklerinin değerlerini her yönüyle geride bırakmıştır. Ancak çoklu sınıflandırma için performans ölçütlerinin değerleri arasındaki fark daha belirgindir.

Her bir sınıflandırıcı için, AR yöntemine ait nitelik vektörü kullanıldığında performans metrikleri daha yüksek elde edilmiştir. FFT yöntemi kullanılarak elde edilen maksimum doğruluk, %93.93'tür. Bu, AR nitelik vektörüyle elde edilen en yüksek doğruluk olan %97.84'ten oldukça düşüktür. AR tabanlı nitelik vektörü kullanılarak elde edilen en düşük doğruluk değeri %91.47 iken, FFT'den türetilmiş nitelik vektörünün girdi olarak uygulanmasıyla %83.50 oranında doğruluk elde edilmiştir. Her iki durumda da 1-D

CNN sınıflandırıcısının uygulanmasıyla en yüksek doğruluk değerleri, LSTM sınıflandırıcısının uygulanmasıyla da en düşük doğruluk değerleri elde edilmiştir.

Farklı nitelik vektörlerinin, aynı sınıflandırıcı ile kullanılması durumunda elde edilen performans farkının nitelik vektörünü elde etmek için uygulanan AR ve FFT yöntemlerinin spektral çözünürlüğündeki farktan kaynaklandığı düşünülebilir. Çünkü AR modelinin diğer spektrum kestirim yöntemlerinden daha yüksek spektral çözünürlüğe sahip olduğu bilinen bir gerçektir [50].

Literatürde bulunan derin öğrenme yöntemlerinin kalp sesi sınıflandırmalarında etkinliğini test etmek için bu çalışmada LSTM ve 1-D CNN sınıflandırıcıları seçilmiştir. Bunlardan LSTM'nin performansı tatmin edici olmamıştır. Bunun nedeni kullanılan veri setinin büyüklüğü olabilir. Normalde derin öğrenme yöntemleri çok büyük veri setleriyle kullanılmaktadır. 1-D CNN yöntemi ise veri seti yeterince büyük olmamasına rağmen oldukça iyi bir performans göstermiştir. Öte yandan sınıflandırma problemlerindeki üstün performanslarının bir bedeli olarak derin öğrenme tabanlı yöntemlerin eğitim süreleri diğer yöntemlere göre nispeten daha uzun olmaktadır.

Bu tez çalışmasının temel hedefi kalp seslerinin hastalık tanısı açısından yüksek bir doğrulukla sınıflandırılmasına imkan sağlayacak tek bir nitelik ortaya koymaktır. Literatürde aynı hedefe yönelik benzeri çalışmaların sonuçlarıyla kıyaslandığında bu hedefe ulaşıldığı gözlenmektedir. Örneğin literatürde yer alan çalışmalar arasında bu tezde temel alınan aynı veri setini kullanan bir çalışmayla [34] kıyaslandığında tek nitelik üzerinden yapılan çok sınıflı sınıflandırma deneyinde bu tezde sunulan sonuçlar diğer çalışmada sunulan sonuçlardan çok daha iyidir.

Daha detaylı bir kıyaslama yapacak olursak; tek nitelik kullanılarak yapılan çok sınıflı sınıflandırmalar arasında bu tezde sunulan en iyi sonuç 1-D CNN sınıflandırıcısı kullanılarak %97.84 olarak elde edilmiş ve bu sonucun diğer çalışmada SVM sınıflandırıcısı kullanılarak elde edilen en iyi sonuç olan %92.30 değerinden çok daha yüksek olduğu görülmüştür. Tek nitelik kullanılarak yapılan çok sınıflı sınıflandırmalar için bu iki çalışmada ortak olarak kullanılan SVM ve K-NN sınıflandırıcılarını kendi aralarında kıyaslayacak olursak; bu tezde elde edilen en yüksek SVM sonucu olan

%95.20'nin, diğer çalışmada elde edilen en yüksek SVM sonucu olan %92.30' dan daha yüksek olduğu görülmüştür. K-NN sonuçlarını kıyaslayacak olursak da bu tezde elde edilen en yüksek K-NN sonucu olan %96.50'in, diğer çalışmada elde edilen en yüksek K-NN sonucu olan %91.80'dan daha yüksek olduğu görülmüştür.

Öte yandan çalışmalarda elde edilen sonuçlara bakılacak olursa; diğer çalışmada iki nitelik kullanılarak ulaşılan en yüksek doğruluk değeri olan %97.90 değerine bu çalışmada tek nitelik kullanılarak (%97.84) ulaşılabilmektedir. Bu durum da bu tez çalışmasında ele alınan niteliğin kalp seslerinin zamana göre değişen spektral özelliklerini temsil etmede ne kadar güçlü olduğunu bir kez daha ortaya koymaktadır.

#### **4.2. Sonuç ve Öneriler**

Daha önce de açıklandığı gibi; bu tez çalışmasında durağan olmayan fizyolojik sinyallerin tek nitelik kullanılarak sınıflandırılmasında oldukça yüksek performans gösteren ve ağırlık merkezi frekansı adı verilen zamanla değişen bir spektral nitelik tanımlanmıştır. Bu niteliğin AR spektral analiz yöntemi ile hesaplanması yoluyla elde edilen nitelik vektörü üzerinden sınıflandırma yapılması durumunda hem iki grup için hem de beş grup için yapılan sınıflandırma işlemlerinde çok iyi performans elde edilmiştir. Elde edilen sonuçlar literatürde yer alan benzeri çalışmalarda sunulandan çok daha iyi durumdadır. Bu sonuçlar, önerilen nitelik çıkarma yönteminin başarısını kanıtlamaktadır. Ayrıca nitelik çıkarma işlemi için önerilen AR yönteminin kalp sesinin otomatik analizinde rahatlıkla kullanılabilmesi sonucuna varılmıştır.

Çalışmada ayrıca literatürde birçok sınıflandırma probleminde yaygın olarak kullanılan SVM ve K-NN sınıflandırıcılarının kalp sesi sınıflandırma probleminde de kullanılmaya uygun olduğu ortaya koyulmuştur. Ancak özellikle nispeten daha zor bir problem olan çok sınıflı sınıflandırma probleminde en yüksek doğruluk oranı %97.84 ile derin öğrenme tabanlı bir sınıflandırıcı olan 1-D CNN kullanılarak elde edilmiştir. Elde edilen bu sonuç kalp sesi analiz sistemlerinde derin öğrenme sınıflandırıcılarının daha başarılı olabileceğini göstermiştir ve bu da derin öğrenme tabanlı sınıflandırıcıların önümüzdeki yıllarda daha da yaygınlaşacağını göstermektedir.

Literatürde sınıflandırıcıların performanslarını bir miktar daha iyileştirmek için kullanılabilirler değişik yöntemler mevcuttur. Bunlar arasında özellikle asıl bileşen analizi (principal component analysis) ve yığılanmış özdevimli kodlayıcılar (stacked autoencoders) doğru kullanıldığında kayda değer performans artışları sağlayabilmektedir. Fakat özellikle yığılanmış özdevimli kodlayıcıların eğitimi başlı başına uzmanlık gerektiren bir süreç olup veri tabanının boyutunun yeterince büyük olmasını gerektirmektedir.

Bu tezde ve literatürdeki benzeri çalışmalarda ortaya koyulan yöntemlerin nihai amacı tam otomatik bir kalp oskültasyon sisteminin tasarlanmasıdır. Bu tezde sunulan yöntem tek bir nitelik üzerinden çok yüksek bir sınıflandırma başarımı sağladığı için bu türden bir sistemin ortaya koyulma sürecine önemli bir katkı sağlamaktadır.

Tezde sunulan ağırlık merkezi frekansı tabanlı nitelik vektörü burada kalp seslerinin sınıflandırılması amacıyla kullanılmış ve oldukça yüksek bir sınıflandırma başarımı sağlamıştır. Burada elde edilen performansın hem ikili hem de çoklu sınıflandırma durumunda yüksek oluşu aynı nitelik vektörünün başka fizyolojik sinyallerin sınıflandırılması amacıyla kullanılması durumunda da sınıflandırma başarımının yüksek olacağını akla getirmektedir. Bu yönüyle, tezde tanıtılan yaklaşımın [61] fizyolojik sinyal işlemede oldukça geniş bir kullanım alanı bulacağı düşünülmektedir.

Bu çalışmanın devamında çalışmada elde edilen sonuçlar ve literatürde mevcut olan diğer yaklaşımlardan yararlanılarak tam otomatik bir kalp sesi sınıflandırma sistemi tasarlanması söz konusu olabilir. Bu türden bir sistemin başarımının olabildiğince artırılması adına literatürde mevcut diğer nitelik çıkarma yöntemleri ve sınıflandırıcılar sisteme entegre edilebilir. Buna ek olarak, öznelik vektörlerinin sinyali temsil etme başarımının artırılması için farklı boyut indirgeme yöntemleri test edilebilir.

## KAYNAKÇA

1. Ritchie, H., 2019. What do the people of the world die from?. (Web sayfası: <https://www.bbc.com/news/health-47371078>), (Erişim tarihi: Nisan 2019).
2. Faust, O., Hagiwara, Y., Tan, J.H., Oh, S.L., Acharya, U.R., 2018. Deep learning for healthcare applications based on physiological signals: A review. **Computer Methods and Programs in Biomedicine**, **161**: 1-13.
3. World Health Organization, 2018. The top 10 causes of death. (Web sayfası: <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>), (Erişim tarihi: Nisan 2019).
4. World Health Organization, 2017. Cardiovascular diseases (CVDs). (Web sayfası: [https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))), (Erişim tarihi: Nisan 2019).
5. Montinari, M.R., Minelli, S., 2019. The first 200 years of cardiac auscultation and future perspectives. **Journal of Multidisciplinary Healthcare**, **12**: 183-189.
6. Anas, M.N., Shadi, M.F., 2014. The heart auscultation: from sound to graphical. **ARPJ Journal of Engineering and Applied Sciences**, **9**: 1924-1929.
7. Chizner, M.A., 2008. Cardiac auscultation: rediscovering the lost art. **Current Problems in Cardiology**, **33** (7): 326-408.
8. Uguz, H., 2012. A biomedical system based on artificial neural network and principal component analysis for diagnosis of the heart valve diseases. **Journal of Medical System**, **36** (1): 61-72.
9. Singh, M., Cheema, A., 2013. Heart sounds classification using feature extraction of phonocardiography signal. **International Journal of Computer Applications**, **77**: 13-17.
10. Tang, H., Dai, Z., Jiang, Y., Li, T., Liu, C., 2018. PCG classification using multidomain features and svm classifier. **BioMed Research International**, **2018**: 4205027.
11. Gomes, E.F., Bentley, P.J., Pereira, E., Coimbra, M.T., & Deng, Y., 2013. Classifying heart sounds - approaches to the PASCAL challenge. **Proceedings of the International Conference on Health Informatics (HEALTHINF-2013)**, 337-340.



12. Sharif, Z., Zainal, M. S., Sha'ameri, A. Z., Salleh, S. H. S., 2000. Analysis and classification of heart sounds and murmurs based on the instantaneous energy and frequency estimations, pp: 130-134. *TENCON, IEEE Region 10 International Conference*, September 24-27, 2000, Kuala Lumpur, Malaysia.
13. Roy J.K., Roy T.S., Mukhopadhyay S.C., 2019. Heart sound: detection and analytical approach towards diseases, pp. 103-145. In: *Modern Sensing Technologies* ( Eds: S., Mukhopadhyay, K., Jayasundera, O., Postolache). Springer, Germany.
14. Koçyiğit, Y., 2016. Heart sound signal classification using fast independent component analysis. **Turkish Journal of Electrical Engineering and Computer Science**, **24** (4): 2949-2960.
15. Bozkurt, B., Germanakis I., Stylianou, Y., 2018. A study of time-frequency features for CNN-based automatic heart sound classification for pathology detection. **Computers in Biology and Medicine**, **100**: 132-143.
16. Noman, F., Ting, C., Salleh S., Ombao, H., 2019. Short-segment heart sound classification using an ensemble of deep convolutional neural networks, pp: 1318-1322. *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, May 12 - 17, 2019, Brighton, United Kingdom.
17. Yuenyong, S., Nishihara, A., Kongprawechnon, W., Tungpimolrut, K., 2011. A framework for automatic heart sound analysis without segmentation. **BioMedical Engineering OnLine**, **10** (13): 1-23.
18. Moukadem, A., Dieterlen, A., Hueber, N., Brandt, C., 2013. A robust heart sounds segmentation module based on S-transform. **Biomedical Signal Processing & Control**, **8** (3): 273-281
19. Soeta, Y., Bito, Y., 2015. Detection of features of prosthetic cardiac valve sound by spectrogram analysis. **Applied Acoustics**, **89**: 28-33.
20. Nazeran, H., 2007. Wavelet-based segmentation and feature extraction of heart sounds for intelligent PDA-based phonocardiography. **Methods of Information in Medicine**. **46**: 135-41.
21. Kao, W., Wei, C., Liu J., Hsiao, P., 2009. Automatic heart sound analysis with short-time Fourier transform and support vector machines, pp: 188-191. *52nd*

- IEEE International Midwest Symposium on Circuits and Systems*, August 2-5, 2009, Cancun, Mexico.
22. Vikhe, P.S., Nehe, N.S., Thool, V.R., 2009. Heart sound abnormality detection using short time fourier transform and continuous wavelet transform, pp: 50-54. *Second International Conference on Emerging Trends in Engineering and Technology, ICETET-09*, December 16- 18, 2009, Maharashtra, India.
  23. Millette, V., Baddour, N., 2011. Signal processing of heart signals for the quantification of non-deterministic events. **BioMedical Engineering OnLine**, **10** (10).
  24. Nogata, F., Yokota, Y., Kawanura, Y., Morita, H., Uno, Y., Walsh, W.R. , 2012. audio-visual based recognition of auscultatory heart sounds with fourier and wavelet analyses. **Global Journal of Technology and Optimization**, **3**: 42-48.
  25. Kehtarnavaz, N., 2008. *Digital Signal Processing System Design (Second Edition)* Academic Press, United States, 334 pp.
  26. Rioul, O., Flandrin, P., 1992. Time-scale energy distributions: A general class extending wavelet transforms. **IEEE Transactions on Signal Processing** **40** (7): 1746-1757.
  27. Karar, M.E., El-Khafif, S.H., El-Brawany, M.A., 2017. Automated diagnosis of heart sounds using rule-based classification tree. **Journal of Medical System**, **41**: 60.
  28. Debbal, S. M., Bereksi-Reguig, F., 2013. Detection of differences of the phonocardiogram signals by using the continuous wavelet transform method. **International Journal of Biomedical Soft Computing & Human Sciences**, **18** (2): 73-81.
  29. Debbal, S. M., Tani, A. M. , 2016. Heart sounds analysis and murmurs. **Interantional Journal of Medical Engineering & Informatics**, **8** (1): 49-62.
  30. Meintjes, A., Lowe, A., Legget, M., 2018. Fundamental heart sound classification using the continuous wavelet transform and convolucional neural networks, pp: 409-412. *40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, July 17-21, 2018, Honolulu.
  31. Yildiz, O., Arslan, A., 2018. Automated auscultative diagnosis system for evaluation of phonocardiogram signals associated with heart murmur diseases. **Gazi University Journal of Science**, **31** (1): 112-124.

32. Ortiz, J. J. G., Phoo C. P., Wiens J., 2016. Heart sound classification based on temporal alignment techniques, pp: 589-592. *2016 Computing in Cardiology Conference (CinC)*, September 11-14,2016, Vancouver, Canada.
33. Hamidi, M., Ghassemian, H., Imani, M., 2018. Classification of heart sound signal using curve fitting and fractal dimension. **Biomedical Signal Processing and Control**, **39**: 351-359.
34. Yaseen, Gui-Young, S., Soonni, K., 2018. Classification of heart sound signal using multiple features. **Applied Sciences**. **8** (12): 2344.
35. Balili, C.C., Sobrepena, M.C.C., Naval, P.C., 2015. Classification of heart sounds using discrete and continuous wavelet transform and random forests, pp: 655-659, *2015 3rd IAPR Asian Conference on Pattern Recognition (ACPR)*, November 3-6, 2015, Kuala Lumpur, Malaysia.
36. Redlarski, G., Gradolewski, D., Palkowski, A., 2014. A system for heart sounds classification. **PloS One**, **9** (11): e112673.
37. Shervegar, M. V., Bhat, G.V., 2018. Heart sound classification using gaussian mixture model. **Porto Biomedical Journal**, **3** (1): e4.
38. Kang, S., Doroshov, R., McConnaughey, J., Shekhar, R., 2017. Automated identification of innocent Still's murmur in children. **IEEE Transaction on Biomedical Engineering**, **6** (6): 1326-1334.
39. Mubarak,Q., Akram, M.U, Shaukat, A.,Hussain,F., Khawaja S.G., Butt, W.H., 2018. Analysis of PCG signals using quality assessment and homomorphic filters for localization and classification of heart sounds. **Computer Methods and Programs in Biomedicine**, **164**: 143-157.
40. Maglogiannis, I., Loukis, E., Zafiropoulos, E., Stasis, A., 2009. Support vectors machine-based identification of heart valve diseases using heart sounds. **Computer Methods and Programs in Biomedicine**. **95**: 47-61.
41. Delgado-Trejos, E. , Quiceno-Manrique, A. F. , Godino-Llorente, J. I., Blanco-Velasco, M., Castellanos-Dominguez, G., 2009. Digital auscultation analysis for heart murmur detection. **Annals of Biomedical Engineering**, **37** (2): 337-353.
42. Quiceno-Manrique, A. F., Godino-Llorente, J. I., Blanco-Velasco, M., Castellanos-Dominguez, G., 2010. Selection of dynamic features based on time-frequency representations for heart murmur detection from phonocardiographic signals. **Annals of Biomedical Engineering**, **38** (1): 118-137.

43. Yıldız, A., Zan H., 2018. Segmantasyon yapmadan patolojik kalp sesi kayıtlarının tespiti için bir örüntü sınıflandırma algoritması. **DÜMF Mühendislik Dergisi** **10:1** (2019): 77-91.
44. Wang, Z., Yang, Z. , Dong, T., 2017. A review of wearable technologies for elderly care that can accurately track indoor position, recognize physical activities and monitor vital signs in real time. **Sensors**, **17** (2): 341.
45. Schmidt, S.E., Holst-Hansen, C., Graff, C., Toft.E., Struijk J.J., 2010. Segmentation of heart sound recordings by a duration-dependent hidden markov model. **Physiological Measurement**, **31** (4): 513-529.
46. Springer, D.B., Tarassenko L., Clifford,G.D., 2016. Logistic Regression-HSMM-Based Heart Sound Segmentation. **IEEE Transactions on Biomedical Engineering**, **63** (4): 822-832.
47. Alexander, B., Nallathambi, G., Selvaraj, N., 2018. Screening of heart sounds using hidden markov and gammatone filterbank models, pp: 1460-1465. *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, December 17-20 ,2018 Orlando, Florida, USA.
48. Hu, W., Lv, J., Liu, D., Chen, Y., 2018. Unsupervised feature learning for heart sounds classification using autoencoder. **Journal of Physics: Conference Series**, **1004**.
49. Nabih-Ali, M.,El-Dahshan, E.S.A., Yahia, A.S., 2017. Heart diseases diagnosis using intelligent algorithm based on PCG signal analysis. **International Journal of Biology and Biomedicine**, **2**: 81-85.
50. Deperliđlu, Ö., 2018. Classification of segmented heart sounds with artificial neural networks. **International Journal of Applied Mathematics Electronics and Computers**, **6** (4): 39-44.
51. Güraksın, G.E., Ergün, U., Deperliođlu, Ö., 2009. Classification of the Heart Sounds via Artificial Neural Network, pp: 507-511. *International Symposium on Innovations in Intelligent Systems and Applications*, June 29- July 1, 2009, Trabzon, Turkey.
52. Şeker, A., Diri, B., Balık, H.H., 2017. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, **Gazi Mühendislik Bilimleri Dergisi**, **3** (3): 47-64.
53. Keleş, A., 2018. Derin öğrenme ve sağlık alanındaki uygulamaları. **Turkish Studies Information Technologies & Applied Sciences**, **13** (21): 113-127.

54. Takalo, R., Hytti, H., Ihalainen, H., 2005. Tutorial on univariate autoregressive spectral analysis. **Journal of Clinical Monitoring & Computing**, **19**: 401-410.
55. Roth, K., Kauppinen, I., Esquef, P.A.A., Valimaki, V., 2003. Frequency warped Burg's method for AR-modeling, pp: 5-8. *2003 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (IEEE Cat. No.03TH8684)*, October 19-22, 2003, New Paltz, USA.
56. Jegan, C., 2013. Classification of diabetes disease using support vector machine. **International Journal of Engineering Research and Applications**, **3**: 1797 - 1801.
57. Ullah, I., Hussain, M., Qazi, E., Aboalsamh, H. 2018. An automated system for epilepsy detection using EEG brain signals based on deep learning approach. **Expert Systems with Applications**, **107**: 61-71.
58. Kumar, J., Goomer, R. Singh, A., 2018. Long short term memory recurrent neural network (LSTM-RNN) based workload forecasting model for cloud datacenters. **Procedia Computer Science**, **125**: 676-682.
59. Srivastava, P., 2017, Essentials of deep learning: Introduction to long short term memory, (Web sayfası: <https://www.analyticsvidhya.com/blog/2017/12/fundamentals-of-deep-learning-introduction-to-lstm/>), (Erişim tarihi: Ocak 2019).
60. Lee, C., 2017, Understanding bidirectional RNN in PyTorch, (Web sayfası: <https://towardsdatascience.com/understanding-bidirectional-rnn-in-pytorch-5bd25a5dd66>), (Erişim tarihi: Mayıs 2019).
61. Upretee P., Yüksel M. E., 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'2019)*, April 24-26 2019 Istanbul, Turkey.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı:** Pratima UPRETEE  
**Uyruğu:** Nepal  
**Doğum Tarihi ve Yeri:** 14.02.1993 - Dolakha  
**Medeni Durum:** Bekar  
**e-mail:** [purpypraty@gmail.com](mailto:purpypraty@gmail.com)  
**Telefon:** +905379450993  
**Yazışma Adresi:** Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Bölümü, 38039, Kayseri.

### EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	Erciyes Üniversitesi, Biyomedikal Müh.	Devam
Lisans	Purbanchal Üniversitesi, Biyomedikal Müh.	2014
Lise	The Times Higher Secondary School, Nepal	2010

### ANA DİL

Nepalce

### YABANCI DİL

İngilizce

Türkçe

Hintçe

### YAYINLAR

1. Upretee P., Yüksel M. E., 2019. "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'2019), Istanbul, Turkey, 24-26 April 2019