

**SAYISAL STETOSKOP İLE ELDE EDİLEN KALP SES
(FONOKARDİYOGRAM) SİNYALLERİNİN
BÖLÜTLENMESİ VE SINIFLANDIRILMASI**

**SEGMENTATION AND CLASSIFICATION OF HEART
SOUND (PHONOCARDIOGRAM) SIGNALS OBTAINED
BY DIGITAL STETHOSCOPE**

GÜLŞEN ÇELEBİ

Doç. Dr. ATİLA YILMAZ

Tez Danışmanı

Hacettepe Üniversitesi
Lisansüstü Eğitim - Öğretim ve Sınav Yönetmeliği'nin
Elektrik ve Elektronik Mühendisliği Anabilim Dalı İçin Öngördüğü
YÜKSEK LİSANS TEZİ
olarak hazırlanmıştır.

2017

GÜLŞEN ÇELEBİ'nin hazırladığı Sayısal Stetoskop İle Elde Edilen Kalp Ses (Fonokardiyogram) Sinyallerinin Bölütlenmesi ve Sınıflandırılması adlı bu çalışma aşağıdaki jüri tarafından **ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

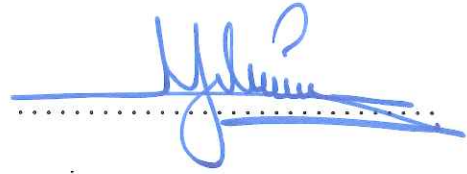
Prof. Dr. OSMAN EROĞUL

Başkan



Doç. Dr. ATİLA YILMAZ

Danışman



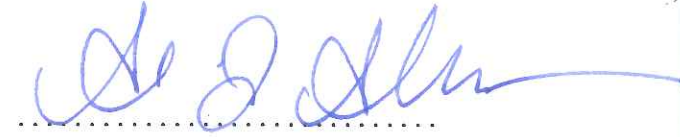
Doç. Dr. BERKAN DÜLEK

Üye



Doç. Dr. ALİ ZİYA ALKAR

Üye



Yrd. Doç. Dr. DERYA ALTUNAY

Üye



Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. MENEMŞE GÜMÜŞDERELİOĞLU

Fen Bilimleri Enstitüsü Müdürü

YAYINLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

- Tezimin/Raporumun tamamı dünya çapında erişime açılabilir ve bir kısmı veya tamamının fotokopisi alınabilir.**

(Bu seçenekle teziniz arama motorlarında indekslenebilecek, daha sonra tezinizin erişim statüsünün değiştirilmesini talep etmeniz ve kütüphane bu talebinizi yerine getirirse bile, tezinin arama motorlarının önbelleklerinde kalmaya devam edebilecektir.)

- Tezimin/Raporumun tarihine kadar erişime açılmasını ve fotokopi alınmasını (İç Kapak, Özet, İçindekiler ve Kaynakça hariç) istemiyorum.**

(Bu sürenin sonunda uzatma için başvuruda bulunmadığım takdirde, tezimin/raporumun tamamı her yerden erişime açılabilir, kaynak gösterilmek şartıyla bir kısmı ve ya tamamının fotokopisi alınabilir)

- Tezimin/Raporumun tarihine kadar erişime açılmasını istemiyorum, ancak kaynak gösterilmek şartıyla bir kısmı veya tamamının fotokopisinin alınmasını onaylıyorum.**

- Serbest Seçenek/Yazarın Seçimi**

06 / 07 / 2017



GÜLŞEN ÇELEBİ

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

06 / 07 / 2017



GÜLŞEN ÇELEBİ

ÖZET

SAYISAL STETOSKOP İLE ELDE EDİLEN KALP SES (FONOKARDİYOGRAM) SİNYALLERİNİN BÖLÜTLENMESİ VE SINIFLANDIRILMASI

GÜLŞEN ÇELEBİ

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Bölümü

Tez Danışmanı: Doç. Dr. ATİLA YILMAZ

Temmuz 2017, 107 sayfa

Dijital bir stetoskop aracılığıyla hastadan elde edilen kalp sesleri ile özellikle birinci basamak hekimlerinin duyulabilir kalp rahatsızlıklarını erken evrede teşhis etmesine katkıda bulunacak karar destek mekanizması geliştirmek bu çalışmanın asıl amacını oluşturmaktadır. Hedef kitledeki hekimlerin kolaylıkla duyamadıkları kalp rahatsızlıklarını bir sistemin duyup tanımalarını sağlayarak hekimler arasındaki bilgi ve tecrübe farklılıklarını kapatmak, tüm hekimlere tecrübeli bir kardiyoloji uzmanı mertebesinde oskültasyon yeteneği kazandıran otomatik bir sistem ortaya çıkarmak önemli bir amaç ve çalışma alanıdır.

Kalp hastalıklarının sınıflandırma başarısı S1 ve S2 segmentlerinin doğru belirlenmesine bağlıdır. EKG referans sinyali kullanılmaksızın bölütleme yöntemleri doğal olarak daha karmaşık olabilmektedir. Hastane ortamında stetoskop ile hastalardan toplanan kalp sesleri ortam gürültüsü, konuşma, hırıltı, sürtünme gibi bir çok çevresel sesi de içerisinde taşımaktadır. Kalp rahatsızlığına bağlı olarak gürültü benzeri üfürüm sesleri de toplanan bu kalp sesleri içerisinde bulunmaktadır. Temel kalp seslerinin bu gürültülü ve riden temizlenmesi için Ayrık Dalgacık Dönüşümü (DWT) ve Mel-Frekans Kepstral Kat-sayıları (MFCC) çözüm olarak kullanılmıştır. S1-S2 yerlerinin belirlenebilmesi için ise sinyal otokorelasyonu kullanılarak kalp atım hızı ve sistol zaman aralığı tespit edilmiştir. Geliştirilen bu algoritma ile hastalık bilgisi taşımayan normal kalp sesleri üzerinden S1

ve S2 sesleri %98,19 kesinlik ve %98,52 hassasiyet ile tespit edilirken, anormal kalp sesleri üzerinde yapılan çalışmada %94,31 kesinlik ve %96,92 hassasiyet ile tespitler yapılmıştır.

Bölütlenen kalp sesleri üzerinden her ses bölgesi için on farklı ayırt edici öznelik çıkarılmıştır. Gözetimli sınıflandırıcılar yardımıyla Aort Darlığı, Mitral Yetmezliği, Aort Yetmezliği, Mitral Darlığı ve Normal kalp ses sinyallerinin kimliklendirilmesi yapılmıştır. Bu çalışmada Destek Vektör Makinaları, K-En Yakın Komşu, Yapay Sinir Ağları ve Karar Ağaçları gözetimli sınıflandırma yöntemleri kullanılarak bu hastalıklar üzerinde sınıflandırma performans karşılaştırması yapılmıştır. Aort Darlığı, Mitral Yetmezliği, Aort Yetmezliği, Mitral Darlığı ve Normal kalp ses sinyallerinin Destek Vektör Makinaları, K-En Yakın Komşu, Yapay Sinir Ağları ve Karar Ağaçları ile sınıflandırma performansı ayrı ayrı raporlanmıştır. Bu sonuçlara bakıldığında farklı sorunlar için farklı sınıflandırıcıların iyi performans gösterdiği anlaşılmıştır.

Anahtar Kelimeler: Kalp Seslerinin Bölütlenmesi; Kalp Seslerinin Sınıflandırılması; Öznelik Çıkarımı; Fonokardiyogram Sinyali; Mel-Frekans Kepstral Katsayıları (MFCC); Ayrık Dalgacık Dönüşümü (DWT); Destek Vektör Makinaları; K-En Yakın Komşu Algoritması; Yapay Sinir Ağları; Karar Ağaçları.

ABSTRACT

SEGMENTATION AND CLASSIFICATION OF HEART SOUND (PHONOCARDIOGRAM) SIGNALS OBTAINED BY DIGITAL STETHOSCOPE

GÜLŞEN ÇELEBİ

**Master of Science, Department of
Electrical and Electronics Engineering**

Supervisor: Doç. Dr. ATILA YILMAZ

July 2017, 107 pages

The main purpose of this work is to develop a decision support mechanism that will contribute to the early diagnosis of extraordinary heart diseases by the help of a digital stethoscope, especially for primary care physicians. It is an important goal and field of study to create an automatic system that gives all physicians the ability to auscultate in an experienced cardiologist's profession by closing the differences of knowledge and experience among the physicians by providing a system to hear and understand the heart diseases that the physicians can not easily hear.

The classification of heart diseases depends on the correct identifications of S1 and S2 segments. Without the ECG reference signal, segmentation methods become naturally more complicated. In the hospital environment, the heart sounds collected from the patients by the stethoscope carry many environmental sounds such as ambient noise, speech, wheezing, and friction. Besides, depending on the heart condition, noise like murmur is also included in these heart sounds. Discrete Wavelet Transform (DWT) and Mel-Frequency Cepstral Coefficient (MFCC) are used as a hybrid solution for the filtering of the noise content of basic heart sounds. In order to determine S1-S2 locations, heart rate and systolic time intervals are determined using signal autocorrelation. As a result of this proposed algorithm, S1 and S2 sounds are detected with 98.19% pre-

cision and 98.52% recall for normal heart sounds, while S1 and S2 are detected with precision of 94.31% and recall of 96.92% for abnormal heart sounds.

Ten different discriminating features are derived for each sound interval from the segmented heart sounds. With supervised classification methods, identification of Aortic Stenosis, Mitral Regurgitation, Aortic Regurgitation, Mitral Stenosis and Normal heart sound signals are performed. In this study, the Support Vector Machines, K-Nearest Neighbor, Artificial Neural Networks and Decision Trees supervised classification methods are compared with respect to the classification performance over these diseases. Classification performance is separately reported for Support Vector Machines, K-Nearest Neighbor, Artificial Neural Networks and Decision Trees of Aortic Stenosis, Mitral Regurgitation, Aortic Regurgitation, Mitral Stenosis and Normal heart sound signals. From these results it can be seen that different classifiers can perform well for different problems.

Keywords: Segmentation of Heart Sounds; Classification of Heart Sounds; Feature Extraction; Phonocardiogram Signal; Mel-Frequency Cepstral Coefficient (MFCC); Discrete Wavelet Transform (DWT); Support Vector Machine; K-Nearest Neighbors Algorithm; Artificial Neural Network; Decision Tree.

TEŐEKKÜR

Bu tez alıőmasında hastalardan toplanan gerek veriler üzerinde kalp hastalıklarının tespiti iin Kalp Ses Sinyallerinin Bölütlenmesi ve Sınıflandırılması amaçlanmıştır. Öncelikle tez konusunun belirlenmesinde ve tez alıőma esnasında birikim ve tecrübeleri ile bana yol gösterici ve destek olan ilaveten gösterdiği anlayış ve sabır dolayısıyla danışmanım Sayın Do. Dr. Atila Yılmaz'a teşekkür ederim.

alıőmalarım boyunca yardım ve destekleri iin deėerli arkadaşlarım Funda Baka ve Göksel Sözeri'e alıőmam süresince bana destek olan deėerli aileme teşekkürlerimi sunarım.

TUBİTAK tarafından desteklenen TEYDEB 1507, 7141460 numaralı - Elektronik Stetoskop ile Ayrıntılı Dinleme (Oskültasyon) ve Kalp Hastalıklarında Tanı Destek Sistemi Geliőtirme (ESDES-G) projesinin veritabanı kullanılmıştır.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ŞEKİLLER	ix
ÇİZELGELER	xii
KISALTMALAR	xiv
SÖZLÜK DİZİNİ	xvi
1. GİRİŞ	1
2. KALBİN YAPISI	5
2.1. Temel Kalp Sesleri	7
2.2. Üfürümler	12
2.2.1. Sistolik Üfürüm	14
2.2.2. Diyastolik Üfürüm	14
2.2.3. Sürekli Üfürüm	15
3. KALP SESLERİNİN ANALİZİ	16
3.1. Veri Seti	16
3.1.1. Aort Darlığı	16
3.1.2. Mitral Yetmezliği	17
3.1.3. Triküspid Yetmezliği	18
3.1.4. Ventriküler Septal Kusur	19
3.1.5. Aort Yetmezliği	19
3.1.6. Mitral Darlığı	21
3.1.7. Patent Ductus Arteriosus	21
3.1.8. Normal Kalp Sesi	22

3.2. Stetoskop Hakkında	23
4. S1 VE S2 SESLERİNİN BÖLÜTLENMESİ	26
4.1. Literatürde S1-S2 Seslerinin Bölütlenmesi	26
4.2. S1-S2 Seslerinin Ayırt Edilmesi	29
4.2.1. Sinyal Ön İşleme	29
4.2.2. MFCC Yöntemi	29
4.2.2.1. Çerçeveleme	30
4.2.2.2. Pencereleme	30
4.2.2.3. Ayırık Fourier Dönüşümü (DFT)	31
4.2.2.4. Mel Filtre Bankası	34
4.2.2.5. Kepstrum Ayırık Dalgacık Dönüşümü	37
4.2.3. Sinyal Analizi	40
4.2.4. Kalp Atım Hızı ve Sistol Süresi Belirleme	46
4.2.5. S1-S2 Yerlerinin Belirlenmesi	48
4.2.6. Bölgelerin Belirlenmesi	50
4.2.7. Performans Sonuçları	51
5. ÖZİNİTELİK ÇIKARIMI	53
5.1. İstatiksel Alan Öznelikleri	54
5.2. Zaman Alanı Öznelikleri	55
5.3. Frekans Alanı Öznelikleri	55
6. SINIFLANDIRMA	56
6.1. Gözetimli Sınıflandırma Yöntemleri	56
6.1.1. Karar Ağaçları	57
6.1.2. Destek Vektör Makinaları	64
6.1.2.1. Doğrusal Destek Vektör Makinaları	66
6.1.2.2. Doğrusal Olmayan Destek Vektör Makinaları	68
6.1.3. K- En Yakın Komşu Algoritması	69

6.1.4. Yapay Sinir Ağları	72
6.1.4.1. Tek Girişli Nöron	73
6.1.4.2. Transfer/Aktivasyon Fonksiyonu	73
6.1.4.3. Çoklu Giriş Nöronu	76
6.1.4.4. Ağ Yapısı	76
6.1.4.4.1 Tek Katmanlı Ağ Yapısı	76
6.1.4.4.2 Çok Katmanlı Ağ Yapısı	77
6.1.4.5. Geri Yayımlı Öğrenme Algoritması	78
6.2. Kalp Ses Sinyallerinin Sınıflandırılması	80
6.2.1. Veri Seti	81
6.2.2. Yaklaşım 1	83
6.2.3. Yaklaşım 2	87
7. SONUÇLAR	94
KAYNAKLAR	98
A. EKLER	102
A.1. Kalp Ses Sinyalleri Veri Tablosu	102
A.2. Kesinlik - Hassasiyet Analizi	103
ÖZGEÇMİŞ	106

ŞEKİLLER

	<u>Sayfa</u>
Şekil 1.1. İş Akış Blok Şeması	3
Şekil 2.1. Kalbin Yapısı [9]	5
Şekil 2.2. EKG ve PCG Sinyali	7
Şekil 2.3. Kalp Dinleme Odakları [11].....	9
Şekil 2.4. Sistol (Ventriküler Ejeksiyon) ve Diyastol (Ventriküler Dolma) Süreleri [13]	10
Şekil 2.5. Kalp Sesleri ve Bileşenleri [5].....	11
Şekil 2.6. Temel Kalp Üfürümleri: A. Mitral veya triküspit stenozun presistolik üfürümü. B. Mitral veya triküspid yetersizlik veya ventriküler septal defektin holosistolik (pansistolik) üfürümü. C. Aortik ejeksiyon üfürümü D. Pulmonik stenozda sistolik üfürüm. E. Aortik veya pulmoner diyastolik üfürüm. F. Mitral darlığı uzun diyastolik üfürümü. G. Üçüncü bir kalp sesi sonrası orta diyastolik kısa akış üfürümü. H. Patent duktus arteriosusunun sürekli üfürümü [14]	13
Şekil 3.1. Aort Darlığı PCG Sinyalinin 4 Adet Kardiyak Döngüsü	17
Şekil 3.2. Mitral Yetmezliği PCG Sinyalinin 4 Adet Kardiyak Döngüsü	18
Şekil 3.3. Triküspid Yetmezliği PCG Sinyalinin 4 Adet Kardiyak Döngüsü	19
Şekil 3.4. VSD PCG Sinyalinin 4 Adet Kardiyak Döngüsü	20
Şekil 3.5. Aort Yetmezliği PCG Sinyalinin 3 Adet Kardiyak Döngüsü	20
Şekil 3.6. Mitral Darlığı PCG Sinyalinin 4 Adet Kardiyak Döngüsü	21
Şekil 3.7. PDA PCG Sinyalinin 3 Adet Kardiyak Döngüsü	22
Şekil 3.8. Normal Kalp PCG Sinyalinin 4 Adet Kardiyak Döngüsü	23
Şekil 3.9. 3M™ Littmann® 3200 Elektronik Stetoskop [15]	24
Şekil 3.10. 3M™ Littmann® StethAssist™ Yazılımı	24
Şekil 4.1. Kalp Sesinin Sınıflandırılması İş Akışı Blok Şeması.....	26
Şekil 4.2. Çerçeve	30
Şekil 4.3. Hamming Pencere	31

Şekil 4.4. Periyodik ve Periyodik Olmayan Sinyaller.....	33
Şekil 4.5. Frekans Mel Dönüşümü	34
Şekil 4.6. Filtre Bankası	36
Şekil 4.7. Kepstral Katsayılarının Akışı.....	37
Şekil 4.8. Bior 2.2 Alçak ve Yüksek Geçiren Filtre	39
Şekil 4.9. Ayrık Dalgacık Ayrışımı	40
Şekil 4.10. Gürültüsüz Normal PCG Sinyali.....	41
Şekil 4.11. Gürültüsüz Normal - MFCC Öznitelik Vektörü	41
Şekil 4.12. Gürültüsüz Normal - MFCC İkinci Öznitelik Vektörü.....	42
Şekil 4.13. Gürültülü Normal PCG Sinyali	43
Şekil 4.14. Gürültülü Normal - MFCC Öznitelik Vektörü	43
Şekil 4.15. Gürültülü Normal - MFCC İkinci Öznitelik Vektörü	44
Şekil 4.16. Hastalıklı PCG Sinyali	45
Şekil 4.17. Hastalıklı - MFCC Öznitelik Vektörü	45
Şekil 4.18. Hastalıklı - MFCC İkinci Öznitelik Vektörü	46
Şekil 4.19. Kalp Atım Hızı ve Sistol Süresi	47
Şekil 4.20. Pencereleme ve Öznitelik Vektörü	49
Şekil 4.21. S1 ve S2 Kalp Seslerinin Yerleri	49
Şekil 4.22. Normal Kalp Sesinin Bölgeleri	50
Şekil 4.23. PDA Rahatsızlığı Kalp Sesinin Bölgeleri	51
Şekil 5.1. Kalp Sesinin Sınıflandırılması İş Akışı Blok Şeması.....	53
Şekil 5.2. Üfürüm Bulunma Bölgeleri [38]	54
Şekil 6.1. Kalp Sesinin Sınıflandırılması İş Akışı Blok Şeması.....	56
Şekil 6.2. Karar Ağacı Düzenleme	57
Şekil 6.3. Karar Bölmesi	58
Şekil 6.4. İki Boyutlu Uzayda A ve B Sınıflarının Yerleşimi	60
Şekil 6.5. Kök Sorusu Belirleme	60

Şekil 6.6. İki Boyutlu Uzayda Geriye Kalan A ve B Sınıflarının Yerleşimi	62
Şekil 6.7. Bagging Öğrenme ve Karar Modeli	64
Şekil 6.8. SVM Karar Düzlemi	65
Şekil 6.9. Doğrusal Olmayan Örnek Uzayı	68
Şekil 6.10. K - En Yakın Komşu	70
Şekil 6.11. Sinir Hücresi(Nöron) ve Yapısı	72
Şekil 6.12. Tek Girişli Nöron	73
Şekil 6.13. Hard Limit Transfer Fonksiyonu	74
Şekil 6.14. Doğrusal Transfer Fonksiyonu	74
Şekil 6.15. Sigmoid Transfer Fonksiyonu	75
Şekil 6.16. Çoklu Giriş Nöronu	76
Şekil 6.17. Tek Katmanlı Ağ Yapısı	77
Şekil 6.18. Çok Katmanlı Ağ Yapısı	78
Şekil 6.19. Yaklaşım 1 - Karar Topolojisi	83
Şekil 6.20. Yaklaşım 2 - Karar Topolojisi	88
Şekil A.1. Karışıklık Matrisi	103
Şekil A.2. Çoklu Karışıklık Matrisi	104
Şekil A.3. Kesinlik-Hassasiyet Eğrisi	105

ÇİZELGELER

	<u>Sayfa</u>
Çizelge 3.1. PCG Veri Seti	16
Çizelge 4.1. S1 ve S2 Ses Yerlerinin Belirlenmesi Performans Sonuçları	52
Çizelge 6.1. Transfer Fonksiyon Listesi ve Gösterimi	75
Çizelge 6.2. Sınıflandırma Veri Seti	82
Çizelge 6.3. Eğitim, Doğrulama ve Test Veri Seti	82
Çizelge 6.4. Normal - Anormal DVM Performansı	84
Çizelge 6.5. Normal - Anormal KNN Performansı	84
Çizelge 6.6. Normal - Anormal Yapay Sinir Ağları Performansı	84
Çizelge 6.7. Normal - Anormal Karar Ağacı Performansı	85
Çizelge 6.8. Hastalık Sınıflandırması DVM Performansı	85
Çizelge 6.9. Hastalık Sınıflandırması KNN Performansı	86
Çizelge 6.10. Hastalık Sınıflandırması Yapay Sinir Ağları Performansı	86
Çizelge 6.11. Hastalık Sınıflandırması Karar Ağacı Performansı	87
Çizelge 6.12. Sistolik - Diyastolik DVM Performansı	89
Çizelge 6.13. Sistolik - Diyastolik KNN Performansı	89
Çizelge 6.14. Sistolik - Diyastolik Yapay Sinir Ağları Performansı	90
Çizelge 6.15. Sistolik - Diyastolik Karar Ağacı Performansı	90
Çizelge 6.16. AD-MY DVM Performansı	91
Çizelge 6.17. AY-MD DVM Performansı	91
Çizelge 6.18. AD-MY KNN Performansı	91
Çizelge 6.19. AY-MD KNN Performansı	91
Çizelge 6.20. AD-MY Yapay Sinir Ağları Performansı	92
Çizelge 6.21. AY-MD Yapay Sinir Ağları Performansı	92
Çizelge 6.22. AD-MY Karar Ağacı Performansı	92
Çizelge 6.23. AY-MD Karar Ağacı Performansı	93

Çizelge 7.1. Kalp Seslerinin S1-S2 Bölütleme Performans Sonuçları	94
Çizelge 7.2. Gözetimli Sınıflandırma Sonuçları	96

KISALTMALAR

AD	Aort Darlığı
ASD	Atriyal Septal Kusur
AY	Aort Yetmezliđi
BOH	Bulaşıcı Olmayan Hastalıklar
CART	Sınıflandırma ve Regresyon Ağaçları
DWT	Ayrık Dalgacık Dönüşümü
DCT	Ayrık Kosinüs Dönüşümü
DFT	Ayrık Fourier Dönüşümü
DVM	Destek Vektör Makinaları
EKG	Elektrokardiyogram
EMD	Amirik Mod Ayrışımı
FFT	Hızlı Fourier Dönüşümü
ICS	İnterkostal Boşluk
IMF	İçkin Mod Fonksiyonları
KNN	K-En Yakın Komşu
MD	Mitral Darlığı
MFCC	Mel Frekans Kepstral Katsayıları
MVP	Mitral Kapak Prolapsusu
MY	Mitral Yetmezliđi
N	Normal
PCG	Fonokardiyogram
PDA	Patent Ductus Arteriosus
PRC	Precision Recall Curve
RMS	Etkin Deđer
STFT	Kısa Zamanlı Fourier Dönüşümü
TÜİK	Türkiye İstatistik Kurumu

TY	Triküspid Yetmezliđi
VSD	Ventriküler Septal Kusur
YSA	Yapay Sinir Ađları

SÖZLÜK DİZİNİ

Ağırlıklandırma Katsayıları	: Weight Coefficient
Alçak Geçiren Filtre	: Lowpass Filter
Alt Örnekleme	: Downsample
Alt Veri Seti	: Subset
Amirik Mod Ayrışımı	: Empirical Mode Decomposition
Ayrık Dalgacık Dönüşümü	: Discrete Wavelet Transform
Ayrıntı Katsayıları	: Detail Coefficient
Ayrık Fourier Dönüşümü	: Discrete Fourier Transform
Ayrık Kosinüs Dönüşümü	: Discrete Cosine Transform
Çerçeveleme	: Frame Blocking
Dalgacık	: Wavelet
Destek Vektör Makinaları	: Support Vector Machine
Devir	: Epoch
Doğrulama	: Validation
Doğrusal	: Linear
Doğrusal Olmayan	: Nonlinear
Eşik Değeri	: Threshold
Etkin Değer	: Root Mean Square
Geri Yayılım	: Backpropagation
Gini indeks	: Gini index
Gizli Katman	: Hidden Layer
Haritalama Fonksiyonu	: Mapping Function
Hassasiyet	: Recall
Hızlı Fourier Dönüşümü	: Fast Fourier Transform
İç Çarpım	: Inner Product
İçkin Mod Fonksiyonları	: Intrinsic Mode Function
Keskinlik	: Precision

İleri Yayılım	: Forwardpropagation
İnterkostal Boşluk	: Intercostal Space
Kapak	: Valve
Karar Ağacı	: Decision Tree
Kardiyak Periyod	: Cardiac Cycle
Karışıklık Matrisi	: Confusion Matrix
K-En Yakın Komşu	: K-Nearest Neighbour
Kepstral Katsayıları	: Cepstral Coefficient
Kesim Frekansı	: Cut-off Frequency
Kısa Zamanlı Fourier Dönüşümü	: Short Time Fourier Transform
Konveks Kuadratik Optimizasyonu	: Convex Quadratic Optimization
Kök Düğüm	: Root Node
Kusur	: Defect
Ortonormal	: Orthonormal
Öz İlinti	: Autocorrelation
Özellik Uzayı	: Feature Space
Öznitelik	: Feature
Pencereleme	: Windowing
Sabit Terim	: Bias
Safsızlık Fonksiyonu	: Impurity Function
Sınıflandırma ve Regresyon Ağaçları	: Classification and Regression Tree
Sıralı Öğrenme	: Online Learning
Temel Fonksiyon	: Basis Function
Toplu Öğrenme	: Batch Learning
Üfürüm	: Murmur
Vektör Uzayı	: Vector Space
Yaklaşık Katsayıları	: Approximate Coefficient
Yapay Sinir Ağları	: Artificial Neural Network
Yüksek Geçiren Filtre	: Highpass Filter

1. GİRİŞ

Dünya genelinde Kalp Damar Hastalıkları ölüm sebeplerinin ilk sırasında yer almaktadır. Dünya Sağlık Örgütü'nün, 2014 Bulaşıcı Olmayan Hastalıklar (BOH) Küresel Durum Raporuna göre; 2012 yılında tüm dünyada 56 milyon ölüm meydana gelmiştir [1]. Bu ölümlerin 38 milyonu BOH'lar, özellikle kalp ve damar hastalıkları, kanserler ve kronik hava yolu hastalıklarına bağlıdır. BOH'lara bağlı ölümlerin yüzde 46,2'si (17,5 milyon) kalp ve damar hastalıklarına bağlıdır [1]. Türkiye İstatistik Kurumunun (TÜİK) ölüm verileri toplam ölümlerin içinde kalp hastalıklarının payının gittikçe artma eğiliminde olduğunu göstermektedir. Kalp hastalıkları 1989'da yüzde 40, 1993'te yüzde 45 [2], 2009'da yüzde 40 [3] ve 2013'te yüzde 39.6, 2014 yılında yüzde 40.4 [4], ile tüm ölüm nedenleri arasında ilk sırada yer almaktadır.

Kalp oskültasyonu, stetoskop aracılığıyla hasta kalbinin ürettiği sesleri dinleme, kalp hastalıklarının tespiti için doktorlar tarafından sıklıkla kullanılan etkili bir yöntemdir. Bu yöntemi etkili kullanabilmek için doktorların belirli bir eğitimden geçmeleri gerektiği gibi deneyim sahibi olmaları da gerekmektedir.

Kalbin çalışması sırasında kalp kapakçıklarının açılıp kapanması (mekanik hareketler) ve kanın kardiyovasküler sistemde hareketi esnasında meydana gelen değişimler sonucu oluşan sesler kalp sesleri olarak adlandırılır. Bir mikrofon vasıtasıyla göğüs üzerinden kaydedilen bu ses ve titreşimler Fonokardiyogram (PCG) sinyalleri olarak tanımlanır. Dinlenen kalp sesleri kalbe giren ve çıkan kanın akışıyla ve bu akışa bağlı olarak oluşan kalp kapakçıklarının hareketleri ile oluşmaktadır. Kan akışı ile oluşan sesler anlamlıdır ve stetoskop aracılığıyla hekimler tarafından dinlenilmektedir. Dinlenen kalp sesleri yorumlanarak hastanın herhangi bir rahatsızlığı olup olmadığı saptanmaktadır. Fakat stetoskop ile dinleme yönteminin birçok kısıtlaması bulunmaktadır. Teşhis becerisindeki eksiklikler, bazı hastaların ciddi kalp rahatsızlıklarına kapılmasına hatta ölüm riski taşımalarına sebep olmakta yada tam tersi olarak masum olan bazı seslerin anlaşılabilmesi nedeni ile gereksiz ve pahalı tahlillerin yapılmasına sebep olmaktadır. Yaşanabilecek benzer sıkıntılardan dolayı stetoskop ile dinleme yani oskültasyon kalp anormalliklerinin incelenmesinde yetersiz kalabilmektedir. Bu nedenle kalp seslerinin doğru bir şekilde yorumlanarak daha hızlı ve etkili teşhis yapabilecek akıllı sistemlere

ihtiyaç duyulmaktadır. Fonokardiyogram analizi gibi uygun maliyetli tanı teknikleri kalp rahatsızlığı olan hastaların yaşam sürelerini arttırabilecektir. Sayısal sinyal işlemedeki gelişmeler ile PCG tabanlı tanı tekniklerinin her doktor tarafından erişilebiliyor olması, hastaların pahalı testler yaptırmasına gerek kalmadan kolay ve doğru teşhis olanağı sağlayabilecektir.

Normal kalp sesinin önemli ses aralıkları birinci kalp sesi S1 ve ikinci kalp sesi S2 olarak adlandırılmaktadır. Birinci kalp sesi ile ikinci ses arasındaki geçen süre sistolü ve ikinci ses ile ardından gelen birinci ses arasında geçen süre diyastolü belirler. Normal bir kardiyak döngü bu iki büyük ses bölgesi oluşmaktadır [4]. Bu tür ses kayıtları gerçekte çok temiz olmayıp sinyal bölütleme ve sınıflandırma aşamasında sorun çıkarabilmektedir. Normalde S1 ve S2 ile S2 ve S1 arası sessizdir. Bu sessiz aralıklarda belirli bazı kalp rahatsızlıklarından dolayı oluşan seslere üfürümler denir. Yüksek frekanslı ve gürültü benzeri bu sesler, kan hızının bir bozukluk yüzünden artması sonucu ortaya çıkmaktadır. Kan akışındaki bu türbülanslara, kalp kapakçıklarındaki bozukluklar ve yetersizlikler sebep olmaktadır [5].

Bu tez TÜBİTAK tarafından TEYDEB 1507, 7141460 Numaralı proje [6] ile desteklenen daha geniş bir çalışmanın hedeflerinden bazıları gerçekleştirmektedir. Projeye konu olan hedef ise normal ile bazı önemli sorunları içeren bir veri grubu içinde doktorların sorunsuz kullanabileceği bir karar yardım sistemi oluşturmaktır. Bu proje çerçevesinde geniş bir veri tabanı oluşturulmuş ve düzenlenmiştir [EK-A.1]. Bu geniş veri tabanı içerisinden 8 farklı kalp ses sinyali kullanılacaktır.: Aort Darlığı (AD), Mitral Yetmezliği (MY), Triküspid Yetmezliği (TY), Ventrikuler Septal Defekt (VSD), Aort Yetmezliği (AY), Mitral Darlığı (MD), Patent Duktus Arteriozus (PDA) ve Normal kalp sesi (N).

Bir hastalık ile alakalı bilgiler, bir kardiyak döngü içerisinde bulunabileceğinden analiz işleminin otomatik yapılabilmesi için döngülerin tek tek tespit edilmesi gerekmektedir. Verilerin karar aşamasındaki sınıflandırma başarısı S1, sistol, S2 ve diyastol bölütlerinin doğru belirlenmesine bağlıdır. Bu nedenle bu çalışmada S1 ve S2 segmentleri başta olmak üzere bu önemli aralıkların doğru belirlenmesi üzerine yoğunlaşmakta ve kalp ses sinyallerinin gözetimli sınıflandırıcılar ile hastalık teşhisi yapılabilmesi amaçlanmaktadır.

Teşhis güvenilirliğini arttırabilmek için bir kayıt içerisinde yer alan tüm kardiyak döngüleri tespit edilebilmeli ve bu döngüler içerisinde varsa kalp anormalliklerinin devamlılığı gözlemlenebilmelidir. Kalp anormalliklerinin doğru teşhisi için farklı odaklardan alınmış normal veya anormal kayıtlar içerisinde yer alan tüm kardiyak döngüleri ile S1, sistol, S2, diyastol aralıklarının tespit edilmesi bu çalışmanın birinci ve en önemli adımını oluşturmaktadır. Tespit edilen bu kalp ses bölgeleri üzerinden elde edilecek ve sınıflandırıcılar için kullanılacak olan temel ayırt edici özniteliklerin belirlenmesi ikinci adımı oluşturmaktadır. Son olarak gözetimli sınıflandırma yöntemleri kullanılarak kalp rahatsızlıklarının kimliklendirilmesi hedeflenmektedir. Şekil 1.1 'de yer alan iş akışı takip edilecektir.



Şekil 1.1. İş Akış Blok Şeması

PCG sinyali öncelikle bir ön işleme tabi tutularak normalizasyonu ve filtrelenmesi sağlanmıştır. Normalize edilen sinyaller bölütlere ayrılarak kalp ses bölgeleri tespit edilmiştir. Bu önemli ses bölgeleri üzerinden 10 adet yeni öznitelik tanımlanarak ve sınıflandırıcılara giriş vektörü olarak sunulmuştur. Gözetimli sınıflandırıcılar yardımıyla hastalıklı kalp ses sinyallerinin sınıflandırma performansı farklı topolojiler için raporlanmıştır.

Yapılan kaynak araştırmasında tanımlanan bu problemin tamamı üzerinde çalışmalar bulunmayıp yalnızca bölütleme veya yalnızca sınıflandırma problemine çözüm aranmaktadır. Kalp ses sinyallerinin sınıflandırma problemi için ise maksimum seçilen iki adet sınıflandırıcı ile performans karşılaştırması yapılmaktadır. Bu çalışmamızda resmin tamamı üzerinde çalışılmış problemin her ayağı üzerinde geliştirme ve iyileştirme yapılarak bir platform geliştirilmiştir.

Literatürde kalp sesinin bölütlenmesi amacıyla bir çok çalışmada referans olarak EKG sinyalleri kullanılmıştır [7]. EKG sinyali kullanılmaksızın önerilen Homomorfik Filtreleme, Amprik Mod Ayrışımı, Shannon Enerji Zarfı gibi yöntemlerin ise gürültü içeren verilerde başarımının düşük olduğu çalışmamızda gözlemlenmiştir. Gürültülü verilerde yaşanan bu dezavantajın literatürde yer alan bir çok yöntemin pratikte uygulamalarını sınırlan-

dırdığı görülmektedir. Gürültü ve parazit kalp ses sinyali toplama sürecinde kaçınılmaz olarak ortaya çıkmakta ve sinyali etkilemektedir. Ses tanıma sistemlerinde yaygın olarak kullanılan Mel-Frekans Kepstral Katsayıları yöntemi de kalp ses sinyali bölütleme çalışmasında gürültülü verilerden etkilenmektedir. Mel-Frekans Kepstral Katsayıları yöntemi uyarlanarak Ayrık Dalgacık Dönüşümü ile birlikte kullanımı ayrıntılı analiz edilerek gürültü etkisinin oldukça azaltılabildiği gözlemlenmiştir. Önerilen bu yöntemin detaylı analizi ve başarımı Bölüm 4'de ayrıntılı bir şekilde anlatılmaktadır.

İkinci bölümde kalbin çalışması hakkında kısa bir bilgi verilirken kalp kapakları, temel kalp sesleri, bu seslerin toplandığı kalp odakları, Elektrokardiyogram (EKG) ve Fonokardiyogram kalp sinyalleri, üfürüm ve üfürüm çeşitleri hakkında da bilgi verilmektedir.

Üçüncü bölümde kullanılacak olan geniş veri tabanı ve bu veri tabanında yer alan farklı tip kayıtların ayrı ayrı analizleri yapılmaktadır. Ayrıca kalp ses sinyallerinin toplandığı stetoskop cihazı tanıtılmaktadır.

Dördüncü bölümde S1 ve S2 temel kalp seslerinin bölütleme çalışması anlatılmaktadır. Normalize edilen kalp ses sinyallerinin Mel-Frekans Kepstral Katsayıları elde edilerek ve Ayrık Dalgacık Dönüşümü ile desteklenerek bölütleme sonuçları iyileştirilmesi sunulmaktadır. S1 ve S2 seslerinin belirlenmesi için gürültüden temizlenmiş sinyalin otokorelasyonu üzerinden kalp atım hızı ve sistol sürelerinin belirlenmesi, iki eşik değeri yardımı ile S1, sistol, S2, diyastol aralıklarının tespit edilmesi işlemi anlatılmaktadır. Veri tabanında yer alan kayıtlar üzerinde bölütleme performans sonuçları yine bu bölümde raporlanmaktadır.


Beşinci bölümde bölütleme sonucunda elde edilen her bir kalp ses sinyali bölgesi için kullanılacak olan öznelikler tanımlanmaktadır. Çıkarılan öznelikler kalp sinyallerinin sınıflandırılmasında kullanılmaktadır.

Altıncı bölümde kullanılacak olan sınıflandırıcılar için kısa kuramsal bilgiye yer verilmektedir. Kalp seslerinin hastalık teşhisi için iki adet yaklaşım tanımlanarak bu yaklaşımların sınıflandırma performansları ayrı ayrı raporlanmaktadır.

Son bölümde çalışma sonuçları, ilgili yorumlar ve çıkarımlar yer almaktadır.

2. KALBİN YAPISI

Kalp, insan vücudunun en önemli organlarından biridir. Karbondioksit-oksijen ($CO_2 - O_2$) alışverişinin gerçekleştiği akciğerlere oksijensiz hale getirilmiş kanı pompalamaktan ve vücuda oksijenlenmiş kanı pompalamaktan sorumludur. Anatomik olarak kalbin sağ ve sol kısımları septum ile tamamen ayrılır [8]. Her iki tarafta karıncık ve kulakçık olmak üzere iki bölüm bulunur. Toplar damarların açıldığı kalbin üst kısımlarına kulakçık (atrium), kanı vücuda pompalayan alt kısım boşluklara ise karıncık (ventrikül) denir. Kalbin yapısı Şekil 2.1 'de açıkça görülmektedir.



Şekil 2.1. Kalbin Yapısı [9]

- Sağ kulakçık: Kalbin sağ üst bölümünde bulunur. Yukarıdan üst ana toplardamar, aşağıdan alt ana toplardamar açılır. Bu damarlar ile oksijen bakımından fakir olan kan, kalbe döner.
- Sağ karıncık: Kalbin sağ alt bölümünde bulunur. Oksijen bakımından fakir olan kan bu boşluktan akciğerlere pompalanmaktadır. Sağ ve sol karıncıklar aynı anda kasılır. Kasılan karıncıktan kan akciğer atardamarı yolu ile akciğerlere gönderilir.
- Sol kulakçık : Kalbin sol üst bölümünde bulunur. Akciğerlerde temizlenen kan, akciğer toplardamarı ile sol kulakçığa gelir. Buraya gelen kan, sol karıncığa geçer.

- Sol karıncık: Kalbin sol alt bölümünde bulunur. Sol kulakçıktan gelen temiz kan, aort atardamarı ile vücuttaki hücrelere pompalanır.

Kulakçıklar ile karıncıklar arasında iki adet atrioventriküler kapak, karıncıklar ile kalpten gelen ana arterler arasında iki adet semilunar kalp kapakları bulunur. Bu kapaklar kan akışının sadece bir yönde olmasına izin verir. Bu kapaklar;

- Triküspit kapak: Sağ kulakçık ile sağ karıncık arasında
- Mitral kapak: Sol karıncık ve sol kulakçık arasında
- Pulmoner kapak: Sağ karıncık ile pulmoner arter (akciğer arteri) arasında
- Aort kapak: Sol karıncık ile aort arasında bulunur.

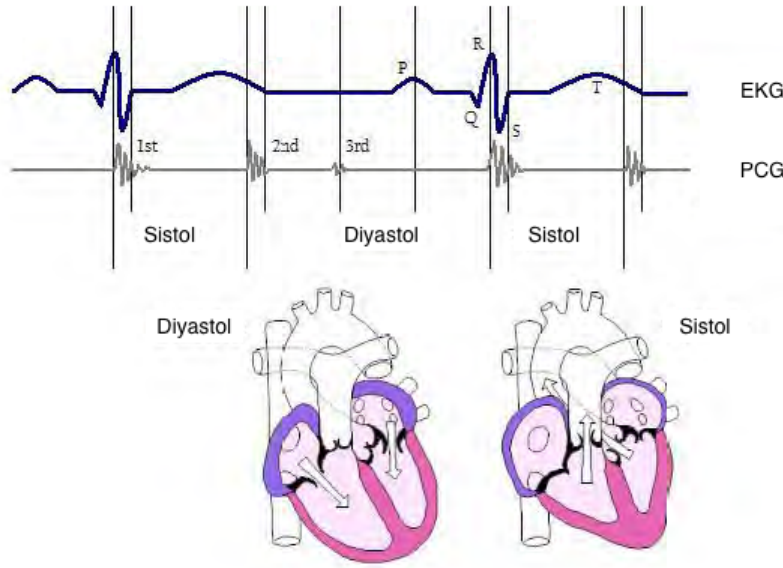
Triküspit ve mitral kapakçıklara çoğunlukla topluca atrioventriküler kapaklar denir, çünkü atriyumlardan ventriküle doğru kan akışını yönlendirirler. Aort ve pulmoner kapakçıklara semilunar kapak denir; çünkü yarım şekilli bir yapıya sahiptir ve aorttan veya pulmoner arterden (akciğer atardamarı) karıncık içine kan akışının geri akışını önler [8].

Sağ kulakçık kanla dolduğunda, sağ kulakçık kasılarak kanın triküspid kapakçıktan sağ karıncığa geçmesini sağlar. Oksijen bakımından fakir olan kan sağ karıncığında kasılmasıyla pulmoner kapakçıkta akciğer atardamarına pompalanır. Akciğerlere gelen kan temizlenir. Akciğer toplar damarı aracılığıyla temizlenen kan kalbin sol kulakçık bölümüne ulaşır. Sol kulakçığın kasılmasıyla temiz kan mitral kapakçıktan geçerek sol karıncığa ulaşır. Sol karıncığa dolan kan, mitral kapağın kapanması ve aort kapakçığının açılması ile aorta pompalanarak vücuda gönderilir. Aynı anda kalbin diğer yarısında pulmoner kapakçık da açılarak, sağ karıncıktaki kirli kan akciğer atardamara basılır [10].

Elektrokardiyogram ve Fonokardiyogram, kalp rahatsızlığı teşhis edilmesinin iki önemli yoludur. EKG, kalp elektriksel aktivitesiyle ilgili kusurları bulabilir, Fonokardiyografi kan akışı yolunda akustik bilgi bulabilir. EKG, belki de en yaygın olarak bilinen, tanınmış ve

kullanılan biyomedikal sinyaldir. Dakikada atım sayısı ile kalbin ritmi kolayca tanımlanabilen dalgaları sayarak tahmin edilebilir. Daha da önemlisi, kardiyovasküler hastalıklar ve/veya anormallikler EKG dalgalanmasında değişikliğe sebep olarak kalp rahatsızlığı hakkında bilgi vermektedir [5].

Kalp kaslarının aynı anda kasılması sonucunda oluşan elektriksel işaret, vücut üzerinden belirli yöntemlerle ölçülebilir. Elektrokardiyogram elektriksel işareti, kalbin çalışma evrelerine ait belirleyici özellikler içerir. Literatürde, QRST dalgası olarak adlandırılır. Bir EKG sinyalinde kalp döngüsünün oluşumları, P dalgası, QRS kompleksi ve T dalgası tarafından tanımlanan üç dalgaya bölünür. P dalgası kulakçıkların kasılmasına, QRS kompleksi karıncıkların depolarize olmasına, ST aralığı ise karıncık kas hücrelerinin repolarize olmasına karşılık gelir [10]. Örnek bir EKG sinyali Şekil 2.2 'de verilmektedir.



Şekil 2.2. EKG ve PCG Sinyali

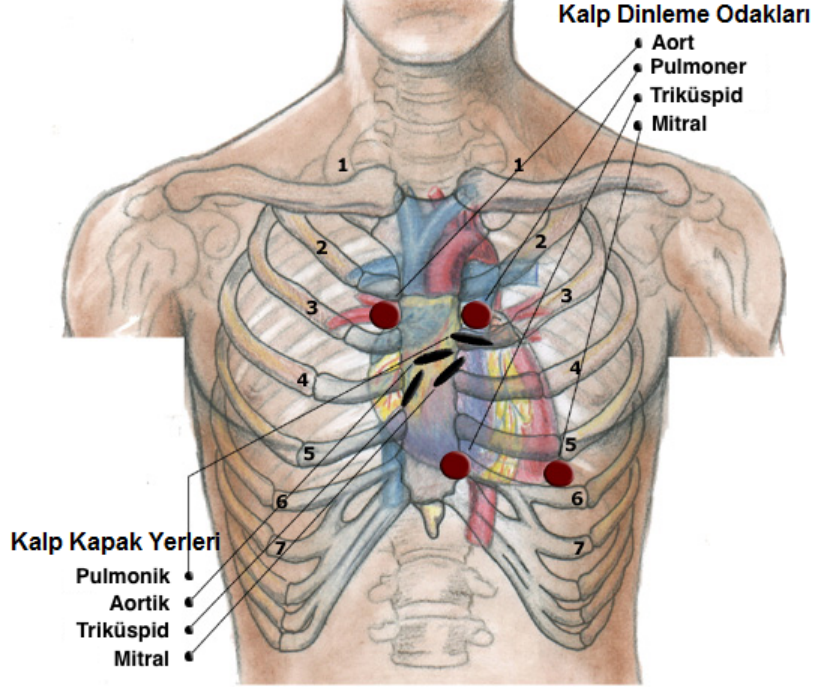
2.1 Temel Kalp Sesleri

Kalbin çalışması sırasında kalp kapakçıklarının açılıp kapanması (mekanik hareketler) ve kanın kardiyovasküler sistemde hareketi esnasında meydana gelen değişimler sonucu oluşan sesler kalp sesleri olarak adlandırılır. Kalp ses sinyali geleneksel bir biyomedikal sinyaldir, stetoskop doktorlar tarafından taşınan ve kullanılan birincil araçtır.

Stetoskopla dinleme (kalp oskültasyonu) doktorlar tarafından kalp fonksiyonlarını deęerlendirmek ve anormallikleri belirlemek amacı ile hastalar üzerinde yaygın bir şekilde kullanılır. Fonokardiyogram en genel anlamda kardiyohemik sistemlerde (kan ve kardiyovasküler sistem) oluşan kasılma aktivitelerine baęlı ses ya da titreşim sinyalleridir. Kalbin pompalama işlemini sürecinde oluşturduğu sesler bir mikrofon vasıtasıyla göęüs üzerinden kaydedilmektedir. Normal kalp sesleri, kalbin genel durumunun ritim ve kasılma açısından bir göstergesidir [5]. PCG; kalp sesleri, üfürümler, kapakçık ve damar sorunları hakkında yararlı bilgiler içeren ve doktor tarafından oskültasyon yoluyla toplanan kalp ses sinyalleridir. Özellikle kalp kapakçıkları ve kalpteki kan akışı ile ilgili olarak sağladığı önemli verilerden dolayı PCG deęişik kalp rahatsızlıklarının teşhisinde kullanılabilir.

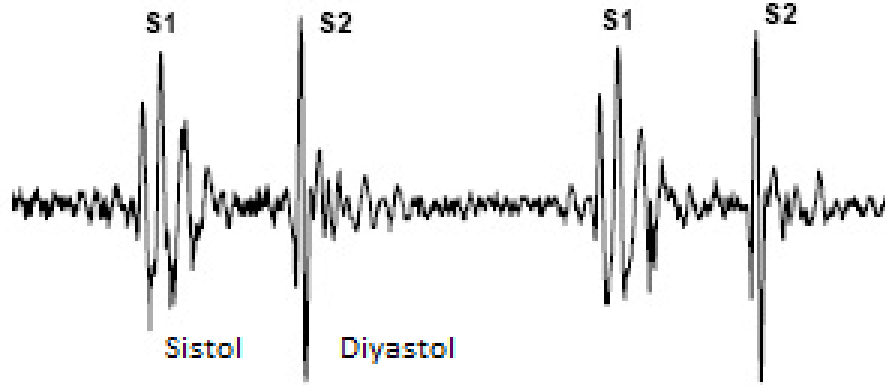
Kalp odakları kalp seslerinin göęüs üzerinden en iyi dinlendikleri yerlerdir. Kalp seslerini analiz edebilmek ve bu sesleri literatürde adlandırabilmek için kalp dört bölüme ayrılmaktadır. Böylece her bölümden sesler dinlenerek, dięer bölümlerle karşılaştırılır, sonuç olarak sorunlu bölge ve sorunun nedeni nispeten tespit edilmiş olur. Bu bölgeler kalp kapaklarının anatomik olarak buldukları yerler deęil, kapaklardan geçen kanın akışı yönündedir. Bu dört dinleme noktası "Z" şeklinde bir örüntü oluşturur ve bölgelerin baş harfleri ile gösterilir (M-Mitral, T-Triküspid, P-Pulmoner ve A-Aort). Kalp sesinin en iyi dinlenebileceği dört odak Şekil 2.3 'te verilmektedir [10] .

- Aort Odağı; ikinci interkostal boşlukta (ICS), kalbin sağ üst tarafında yer alır ve bu bölgede duyulan sesler aort kapakçıkları ile
- Pulmoner Odak; ikinci interkostal boşlukta, kalbin sol üst tarafında yer alır ve bu bölgede duyulan sesler pulmoner kapakçıkları ile
- Triküspid Odak; dördüncü interkostal boşlukta, kalbin sağ tarafında yer alır ve bu bölgede duyulan sesler triküspid kapakçıkları ile
- Mitral Odak; beşinci interkostal boşlukta, kalbin apeks bölümünde yer alır ve bu bölgede duyulan sesler mitral kapakçıklar ve sol ventrikül ile ilgilidir [10].



Şekil 2.3. Kalp Dinleme Odakları [11]

Normal kalbin belli başlı iki sesi "lub dub" şeklindedir. "lub" duyulan ilk sestir ve yaygın olarak S1 olarak tanımlanır ve sistol başlangıcında mitral ve trikuspid kapakların kapanmasının neden olduğu türbülans kaynaklanır. İkinci kalp sesi "dub" veya S2'dir ve sistol sonunda aortik ve pulmonik kapakların kapanmasından kaynaklanır. Birinci kalp sesi ile ikinci ses arasında geçen süre sistolu (ventriküler ejeksiyon) ve ikinci ses ile ardından gelen birinci ses arasında geçen süre diyastolu (ventriküler dolmayı) belirler. S1, S2 sesleri arasındaki sistol ve diyastol sürelerinin konumlanması Şekil 2.4 'de gösterilmektedir. Normal bir kardiyak döngü iki büyük sestem, birinci kalp sesi ve ikinci kalp sesi, oluşur. Kardiyak döngü; kalp atışının başlangıcından bir sonraki kalp atışına kadar geçen ve içerisinde sistol diyastol ve aralardaki bekleme kısımlarını içeren döngüye denir [12]. Birinci ve ikinci kalp sesi ayırt edilerek sistol ve diyastol bölgeleri belirlenir.

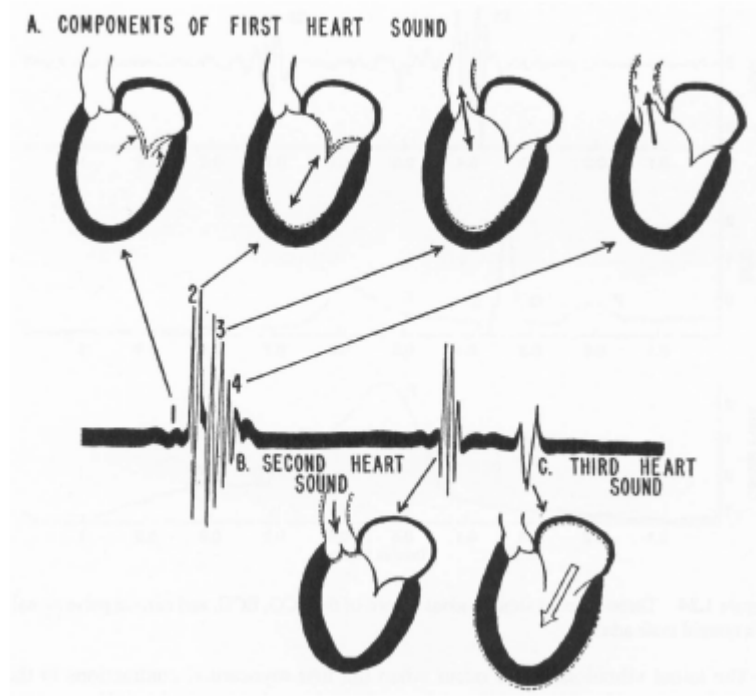


Şekil 2.4. Sistol (Ventriküler Ejeksiyon) ve Diyastol (Ventriküler Dolma) Süreleri [13]

Birinci kalp sesi; uzun ve mat bir sestir. Karakteri "lup" diye ifade edilir. Süresi yaklaşık 0.15sn ve frekansı 25-45 Hz'dir. S1 kalp sesi, kasılma periyodu sırasında, aort kapağının açılması ve ejeksiyonun başlangıcında, mitral kapağın ve triküspit kapağın kapanmasından ise sonra meydana gelir. Bu ses en iyi sol beşinci interkostal aralık ile mitral odaktan dinlenir [8]. EKG R dalgası karıncıkların kasılmasının hemen öncesinde meydana geldiğinden S1 sesi R dalgasının sonra oluşmaktadır (Şekil 2.2). S1'deki ilk titreşimler karıncıklardaki kasılma meydana geldiğinde mitral ve triküspit kapakçıkların kapanması ile oluşur. İkinci kısım ise atriyoventriküler kapakçıkların ani bir şekilde kapanması ve kanın yavaşlaması ile başlar, aort ile pulmoner kapakçıkların açılması ve kanın karıncıkların dışına pompalanması ile devam eder. S1'in üçüncü kısmı ise kanın aort ile karıncıkların arasındaki hareketi ile oluşur. Bu sesi ise aort ve pulmoner damarda kanın hızlı bir şekilde akmasının oluşturduğu titreşimler takip eder (S1'in dördüncü kısmı) [5]. Birinci kalp ses sinyalinin kısımları Şekil 2.5 'de verilmektedir [5].

İkinci kalp sesi; net, tiz ve kısa sürelidir. Karakteri "dup" diye ifade edilir. Süresi yaklaşık 0.12sn ve frekansı 50-70Hz'dir. S2 kalp sesi, aort kapağının kapanması ve pulmoner kapağın kapanması ile ilişkilidir. Bu sesler sağ ikinci veya üçüncü interkostal aralık ile aort odağından dinlenir [8]. EKG T dalgası karıncıkların gevşemesinin hemen öncesinde meydana geldiğinden S2 sesi T dalgasından sonra oluşmaktadır (Şekil 2.2). Normal PCG döngüsünde sistol sonrası sessizliği semilunar kapakçıkların kapanma-

sından oluşan ikinci bir ses (S2) takip eder. S2'nin ilk titreşimleri kanın arterde yavaşlaması ile oluşur. S2 iki parçadan oluşur. Birincisi aort kapakçıklarının kapanmasından(A2) ve ikincisi pulmoner kapakların kapanmasından(P2) dolayı oluşur. Normalde aort kapağı pulmoner kapağından daha önce kapanır. Bu yüzden A2 P2'den birkaç milisaniye önce gerçekleşir. Patolojik sebepler bu ikisi arasındaki süre uzayabilir yada sırasını değiştirebilir. Normal hastalarda bu iki durum arasındaki süre nefes alırken de uzayabilir [5]. İkinci kalp ses sinyalinin kısımları Şekil 2.5 'de verilmektedir.



Şekil 2.5. Kalp Sesleri ve Bileşenleri [5]

Üçüncü kalp sesi (S3); bazı durumlarda karıncıkların kanla dolmasından dolayı kulakçıklardan karıncığa doğru akan kanın ani bir şekilde kesilmesinden kaynaklanan oldukça düşük frekanslı üçüncü bir ses (S3) daha duyulabilir. Diyastol başında, kalbin hızlı dolması sırasında duyulur [5].


Dördüncü kalp sesi (S4); diyastol sonunda birinci sestten önce duyulan patolojik bir kalp sesidir. Bu ses kulakçıkların kasılması ve kanın karıncık tarafından emilmesi sırasında ortaya çıkabilir [5].

2.2 Üfürümler

Kalp yapısındaki anormallikler çoğunlukla kalbin oluşturduğu seslere yansımaktadır. Normalde S1 ve S2 ile S2 ve S1 arası sessizdir. Bu sessiz aralıklarda belirli bazı kalp rahatsızlıklarından dolayı oluşan seslere üfürümler denir. Yüksek frekanslı ve gürültü benzeri bu sesler, kanın hızının bir bozukluk yüzünden artması sonucu ortaya çıkar. Kan akışındaki bu türbülanslara, kalp kapakçıklarındaki bozukluklar ve yetersizlikler sebep olur [5]. Kalp sesleri ve üfürümler genel olarak miyokardiyal duvarların hareketlerinden, kapakların açılma ve kapanmasından, odacıkların dışına ve içine kanın akmasından meydana gelmektedir [8].

Üfürümler geleneksel olarak kardiyak çevrim içindeki zamanlamaları ile tanımlanırlar. Bir kardiyak döngü içerisinde farklı zamanlarda yer alan üfürüm örnekleri Şekil 2.6 'da verilmektedir. Sistolik üfürümler ilk kalp sesiyle veya sonrasında başlar ve ikinci kalp sesinin bileşenlerine veya sonuna kadar devam eder. Diyastolik üfürümler, S2'nin ilgili bileşeni ile veya sonrasında başlar ve sonraki S1'de veya sonrasında sona erer. Sürekli üfürümler kalp döngüsünün her iki fazıyla sınırlı değil, bunun yerine erken sistolde başlar ve S2 boyunca diyastolun tamamına veya bir kısmına geçer. Kalp üfürümlerinin doğru zamanlaması, kimliklerinin belirlenmesindeki ilk adımdır [14]. Üfürümleri en iyi şekilde kimliklendirilmesi için üfürüm yoğunluğu, süresi ve şekli gibi ayırt edici özelliklerinin bilinmesi gerekmektedir.

Kalp üfürümünün süresi, iki kardiyak odacık, sol karıncık ve aort, sağ karıncık ve akciğer atardamar veya büyük damarlar arasında bir basınç farkının bulunduğu süre uzunluğuna bağlıdır. Bu basınç farkının büyüklüğü ve değişkenliği, ilgili odacıkların geometrisi ve uyumu ile birleştiğinde akış hızını, türbülans derecesini ve üfürüm frekansını ve yoğunluğunu belirler. Örneğin, aort yetersizliğinin diyastolik üfürümü yüksek frekanslı iken sol kulakçık ile sol karıncık diyastolik basınç gradiyentinin göstergesi olan mitral darlığı üfürümü düşük frekanslı bir üfürümdür. Bir kalp üfürümünün frekans bileşenleri, oskültasyon odaklarına göre değişiklik gösterebilir. Bir kalp üfürümünün şekli; kreşendo, dekreşendo, kreşendo-dekreşendo veya plato şeklinde tanımlanabilir [14].



Şekil 2.6. Temel Kalp Üfürümleri: A. Mitral veya triküspit stenozun presistolik üfürümü. B. Mitral veya triküspid yetersizlik veya ventriküler septal defektin holosistolik (pansistolik) üfürümü. C. Aortik ejeksiyon üfürümü D. Pulmonik stenozda sistolik üfürüm. E. Aortik veya pulmoner diyastolik üfürüm. F. Mitral darlığı uzun diyastolik üfürümü. G. Üçüncü bir kalp sesi sonrası orta diyastolik kısa akış üfürümü. H. Patent duktus arteriosusunun sürekli üfürümü [14]

Kalp üfürümünün şiddeti 1-6 ölçeğinde derecelendirilir. Birinci dereceden üfürüm çok yumuşaktır ve yalnızca büyük çabayla duyulur. İkinci derece üfürüm kolayca duyulur, ancak özellikle yüksek sesli değildir. Sınıf üç üfürüm yüksek ancak maksimum yoğunluk alanı üzerinde görülmez. Sınıf dört üfürüm çok yüksek bir yoğunluk alanı görülür. Beşinci derece üfürüm, stetoskopun sadece göğüs kenarına dokunan bir sesle duyulurken, altıncı derece üfürüm stetoskopu hafifçe göğsünüzden çıkaracak kadar yüksek sesle duyulur. Üçüncü dereceden veya daha büyük yoğunluklu üfürümler genellikle önemli yapısal kalp hastalıklarını belirtir ve üfürüm oluşması anında yüksek kan akış hızını gösterir. Örneğin, ventriküler septal defektlere, dördüncü dereceden sistolik üfürüm eşlik eder. Bir Atriyal Septal Kusur (ASD) genellikle sessizdir. Kalp üfürümünün şiddeti, obezite, obstrüktif akciğer hastalığı ve büyük bir perikardiyal efüzyon gibi göğüs duvarındaki stetoskop ile intrakardiyak kaynak arasındaki mesafeyi arttıran herhangi bir

işlemlerle de azaltılabilir. Bir üfürümün şiddeti, önemli ölçüde azaltıldığında veya ilgili kardiyak yapılar arasındaki basınç gradyeni düşük olduğunda yanıtıcı derecede yumuşak olabilir [14].

2.2.1 Sistolik Üfürüm

Erken sistolik üfürümler S1 ile başlar ve S2'den önce değişen bir periyot boyunca uzar. Üfürüm nedeni az sayıdadır. Doğuştan gelen, küçük kaslı ventriküler septal kusur, erken sistolik üfürüm ile ilişkili olabilir.

Ventriküler Septal Kusur, septal kasılma sırasında kademeli olarak kapanır ve bu nedenle üfürüm erken sistol ile sınırlıdır. Genellikle dördüncü veya beşinci sınıf üfürüm şiddetindedir. Normal pulmoner arter basıncına sahip triküspit yetersizliği de erken sistolik üfürüm üretebilir. Üfürüm şiddeti birinci veya ikinci sınıf olabilmektedir.

Orta sistolik üfürümler S1'den sonra kısa bir aralıkla başlar, S2'den önce biter ve şekli genellikle kreşendo ve dekresendo'dur. Aort darlığı erişkenlerde orta sistolik üfürümün en sık nedenidir. Aort darlığı üfürümü genellikle ikinci interkostal boşlukta (aort odağı) göğüs kafesinin sağ tarafında en yüksek sesle duyulur. Aort darlığı sistolik üfürümünün mitral yetmezliği üfürümünden ayırımı zor olabilmektedir. Aort darlığı üfürümü ön vuruştan sonra yoğunluğu artarken (elmas), buna karşılık mitral yetmezliği üfürümü yoğunluğu değişmeden devam eder. Üfürüm şiddetinin dördüncü veya üst sınıfları ciddi aort darlığını işaret etmektedir.

Geç sistolik üfürüm genellikle mitral kapak rahatsızlığına (MVP) bağlıdır. Sol ventrikül apeksinden en iyi duyulan bu üfürüm bir veya daha fazla tıklama ile ortaya çıkmaktadır. Holosistolik üfürümler S1 ile başlar ve sistol boyunca S2'ye kadar devam eder. Genellikle kronik mitral yetmezliği ve triküspit kapak yetmezliğinin göstergesidir. Mitral yetmezliği holosistolik üfürümü en iyi sol ventrikül apeksinde duyulur.

2.2.2 Diyastolik Üfürüm

Erken diyastolik üfürüm S2'den hemen sonra başlar. Kronik aort yetmezliği erken üfürüm ile sonuçlanmaktadır. İkinci sağ interkostaldan en iyi duyulan bu üfürüm dekres-

şendo şeklidir. Şiddetli aort yetmezliđi birinci veya ikinci derece diyastolik üfürüm üretebilmektedir.

Orta diyastolik üfürümler, mitral veya triküspit kapak seviyesinde tıkanıklıktan kaynaklanır. Mitral darlıđı üfürümü düşük tonludur ve bu nedenle en iyi stetoskop çanı ile duyulur. Sol ventrikül apeksinde en yüksek ses seviyesinde dinlenebilir. Üfürüm şiddeti genellikle birinci ve ikinci seviyededir.

2.2.3 Sürekli Üfürüm

Sürekli üfürümler sistolde başlar, ikinci kalp sesinin yakınında tepe yapar ve diyastolün tamamında veya bir kısmında devam eder. Kalp döngüsü boyunca varlıkları hem sistolde hem de diyastolde devam eder. Patent ductus arteriosus ile ilişkili olan bu sürekli üfürüm en iyi sol üst sternal sınırda duyulur.

3. KALP SESLERİNİN ANALİZİ

3.1 Veri Seti

Litmann 3200 stetoskop ile hastane ortamında Begüm Yetiş Sayın, Sercan Okutucu, Ali Oto, Hakan Aksoy ve Bünyamin Yavuz tarafından 261 farklı hasta üzerinden PCG sinyali toplanmıştır. Aort Darlığı, Mitral Yetmezliği, Triküspid Yetmezliği, Ventrikuler Septal Kusur, Aort Yetmezliği, Mitral Darlığı, Patent Ductus Arteriosus ve Normal kalp sesi olmak üzere 8 ayrı tip kalp sesi bu çalışmada incelenmektedir.

	Kayıt Sayısı	Kardiyak Periyot Sayısı
Aort Darlığı	39	1060
Mitral Yetmezliği	31	856
Triküspid Yetmezliği	2	76
Ventrikuler Septal Kusur	1	46
Aort Yetmezliği	3	95
Mitral Darlığı	20	567
Patent Ductus Arteriosus	4	90
Normal	161	4603
Toplam Kayıt	261	7393

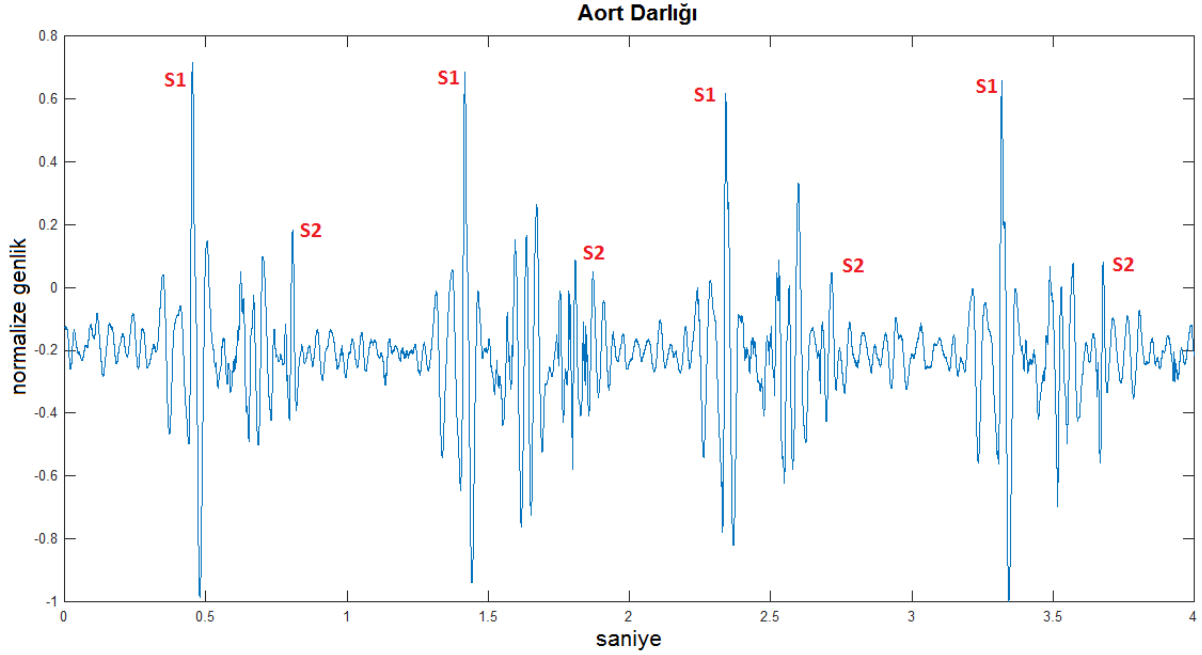
Çizelge 3.1. PCG Veri Seti

Mitral, Trisküpid, Pulmoner ve Aort odaklarından toplanan bu PCG sinyalleri bluetooth aracılığı ile Litmann SteethAssist Yazılımına gönderilerek wav dosyası olarak kaydedilmiştir. Hastalar üzerinden 10sn ile 30sn arasında farklı sürelerde kayıtlar toplanarak zengin bir veri tabanı oluşturulmuştur [EK-A.1]. Bu kayıtlardan elde edilen toplam kardiyak period sayısı her veri tipi için Çizelge 3.1'de verilmektedir.

3.1.1 Aort Darlığı

En sık görülen patolojik sistolik üfürümlerden biri Aort darlığıdır. Aort kapağının darlığı veya sol karıncık aort girişindeki daralma nedeniyle meydana gelir. Aort darlığı tipik olarak sağ ikinci interkostal üzerinde elmas şeklinde orta sistolik üfürümdür.

Sayın Begüm Yetiş Sayın tarafından 9 Aralık 2015 tarihinde sağ ikinci interkostal aort odağından 30sn boyunca alınan ve Aort Darlığı olarak etiketlenen PCG sinyalinin 4sn'lik kısmı Şekil 3.1 'de verilmektedir.




Şekil 3.1. Aort Darlığı PCG Sinyalinin 4 Adet Kardiyak Döngüsü

3.1.2 Mitral Yetmezliği

Mitral kapak yetersizliğinin neden olduğu tipik bir üfürüm örneğidir. Mitral kapak yetersizliği çoğunlukla doğuştan gelen bir durumdur. Romatizmal kalp rahatsızlığının da bir sonucu olarak meydana gelebilmektedir. Mitral kapak sistolik dönem boyunca karıncık içerisindeki kanın kulakciğe geçmesini engelleyemediğinden holosistolik bir üfürümdür.

Sayın Begüm Yetiş Sayın tarafından 29 Şubat 2016 tarihinde 60 yaşında erkek bir hastadan, beşinci interkostal apex odağından yaklaşık 27sn boyunca alınan ve Mitral Yetmezliği olarak etiketlenen PCG sinyalinin 3sn'lik kısmı Şekil 3.2 'de verilmektedir.

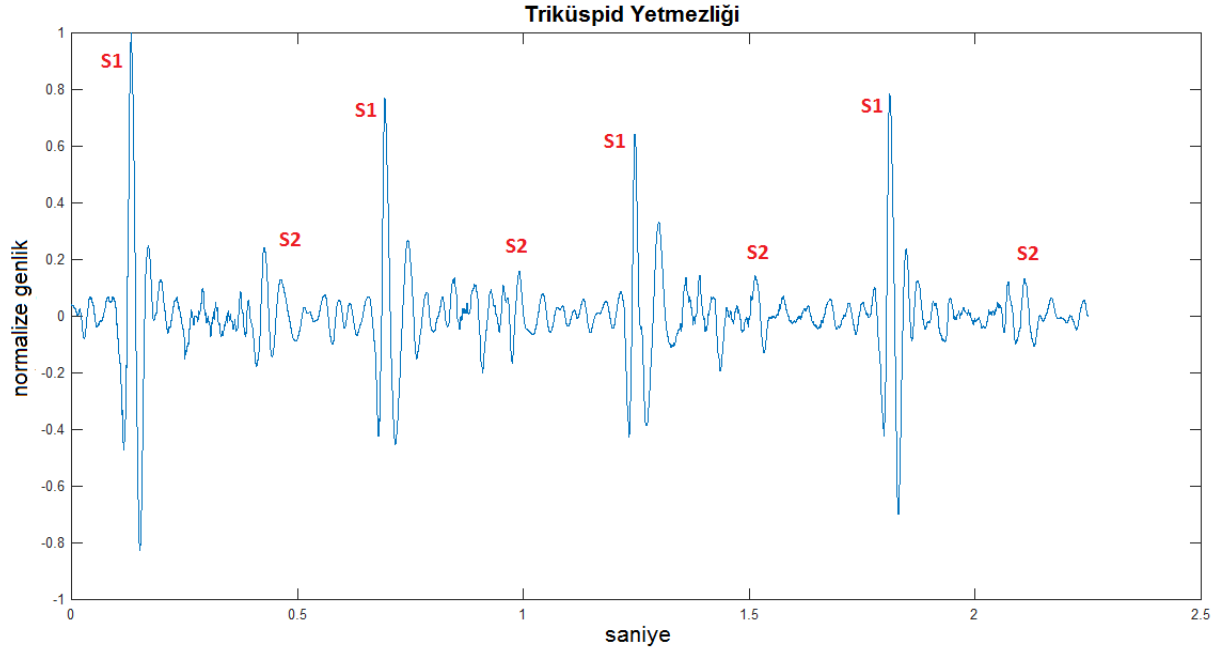


Şekil 3.2. Mitral Yetmezliđi PCG Sinyalinin 4 Adet Kardiyak Döngüsü

3.1.3 Triküspid Yetmezliđi

Triküspid yetmezliđi nadir görölen bir üfürümdür. Romatizmal kalp hastalıkları en sık gösterilen nedenler arasındadır. Triküspit yaprakçıklarının tam kapanamaması ile kanın sağ kulakçıđa geri kaçması durumudur. Birinci veya ikinci derece şiddete sahip sistolik bir üfürüm olabildiklerinden steteskop ile duyulması oldukça zordur.

Sayın Begüm Yetiş Sayın tarafından 11 Ağustos 2016 tarihinde 65 yaşında erkek bir hastadan, dördüncü sol interkostal odađından yaklaşık 24sn boyunca alınan ve Triküspid Yetmezliđi olarak etiketlenen PCG sinyalinin 2.5sn'lik kısmı Şekil 3.3 'de verilmektedir.



Şekil 3.3. Triküspid Yetmezliği PCG Sinyalinin 4 Adet Kardiyak Döngüsü

3.1.4 Ventriküler Septal Kusur

Kalbin sağ karıncık ile sol karıncığını birbirinden ayıran septum üzerinde delik bulunması durumunda ortaya çıkan üfürüm tipidir. Holosistolik üfürüm gibi başlar fakat sistolün tam ortasında aniden kesilebilir.

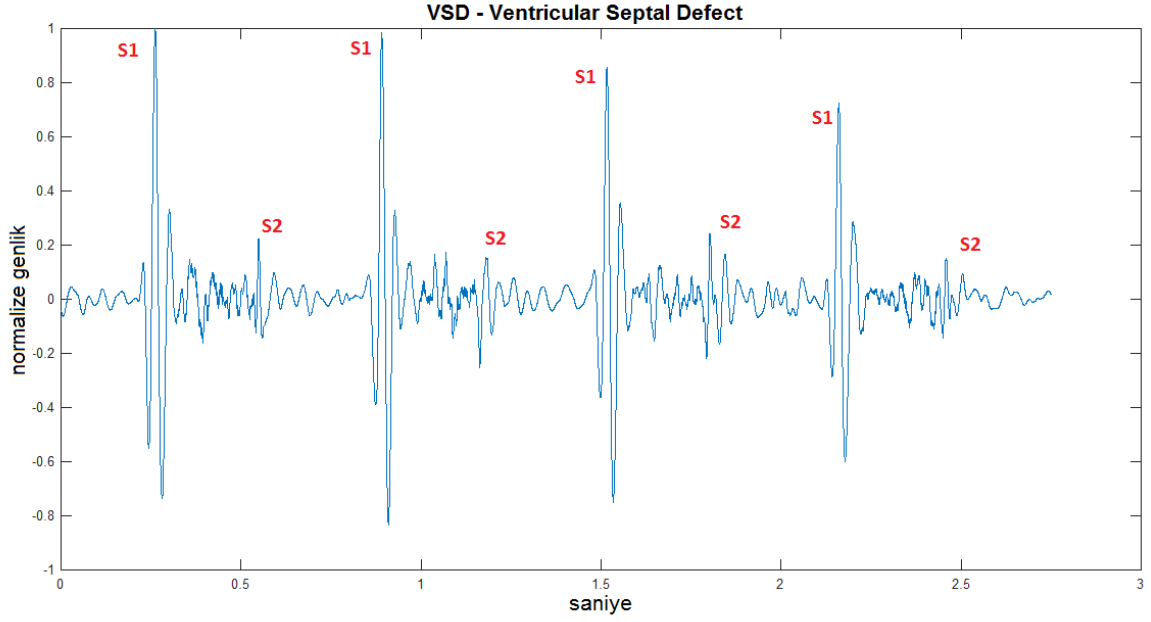
Sayın Begüm Yetiş Sayın tarafından 8 Ekim 2015 tarihinde 34 yaşında kadın bir hastadan, dördüncü sol interkostal odağından 30sn boyunca alınan ve VSD olarak etiketlenen PCG sinyalinin 2.75sn'lik kısmı Şekil 3.4 'de verilmektedir.

3.1.5 Aort Yetmezliği

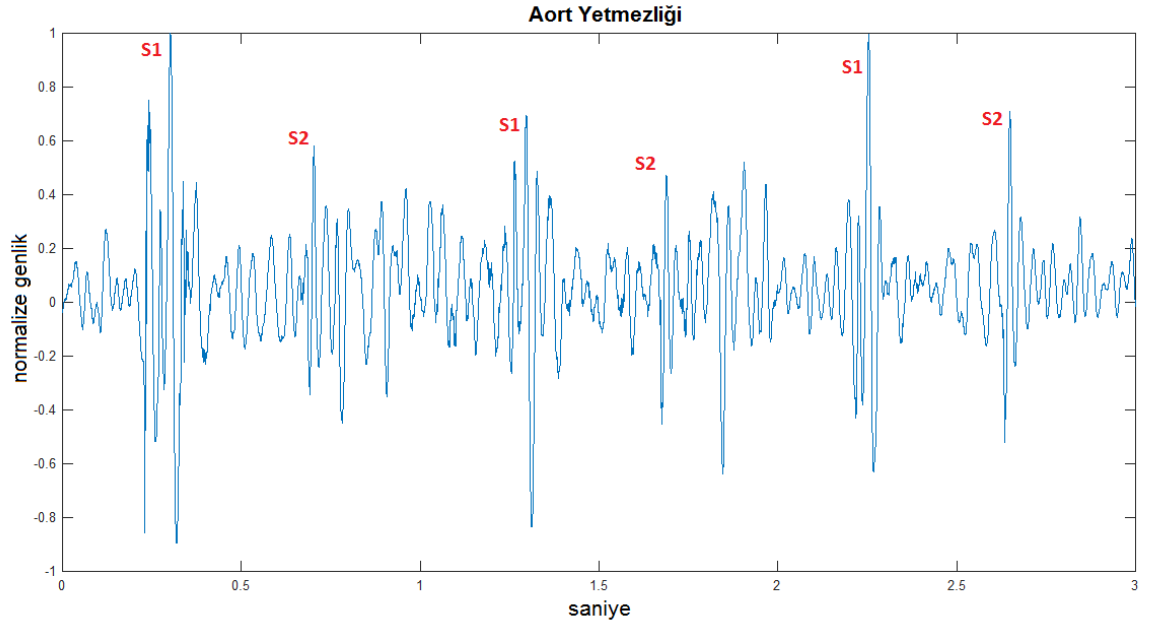
Diyastolun başında başlayan bir dekreşendo üfürüm tipidir. Diyastol sırasında aort kapığının yetersizliği ile kanın sol karıncığa geri akması olarak tanımlanır.

Sayın Begüm Yetiş Sayın tarafından 9 Şubat 2016 tarihinde 50 yaşında kadın bir hastadan, ikinci sağ interkostal odağından 30sn boyunca alınan ve Aort Yetmezliği olarak

etiketlenen PCG sinyalinin 3sn'lik kısmı Şekil 3.5 'de verilmektedir.



Şekil 3.4. VSD PCG Sinyalinin 4 Adet Kardiyak Döngüsü

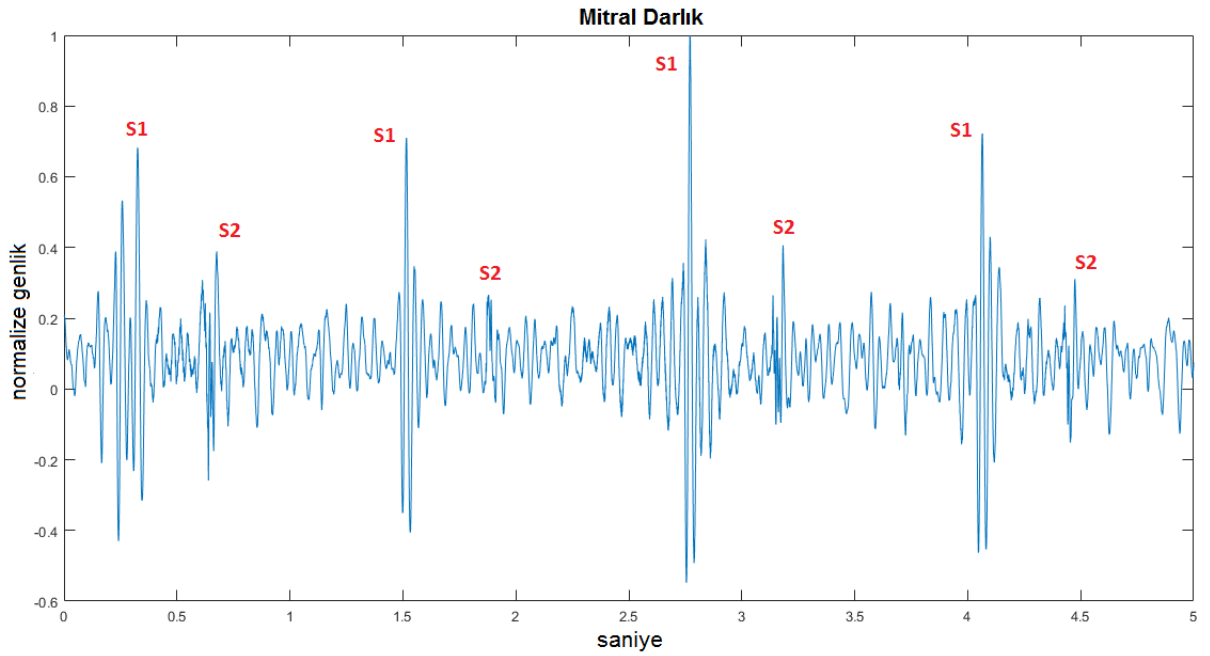


Şekil 3.5. Aort Yetmezliği PCG Sinyalinin 3 Adet Kardiyak Döngüsü

3.1.6 Mitral Darlığı

Mitral kapak darlığı diyastolik üfürüm örneğidir. Sol kulakçıktan sol karıncığa doğru kan akışını engelleyen bu sebepten türbülanslı kan akışına sebep olan durumdur. Diyastolik üfürüm ile birlikte sistolde erken üfürüm de yer almaktadır.

Sayın Begüm Yetiş Sayın tarafından 12 Eylül 2015 tarihinde, beşinci interkostal apex odağından 30sn boyunca alınan ve Mitral Darlık olarak etiketlenen PCG sinyalinin 5sn'lik kısmı Şekil 3.6 'de verilmektedir.



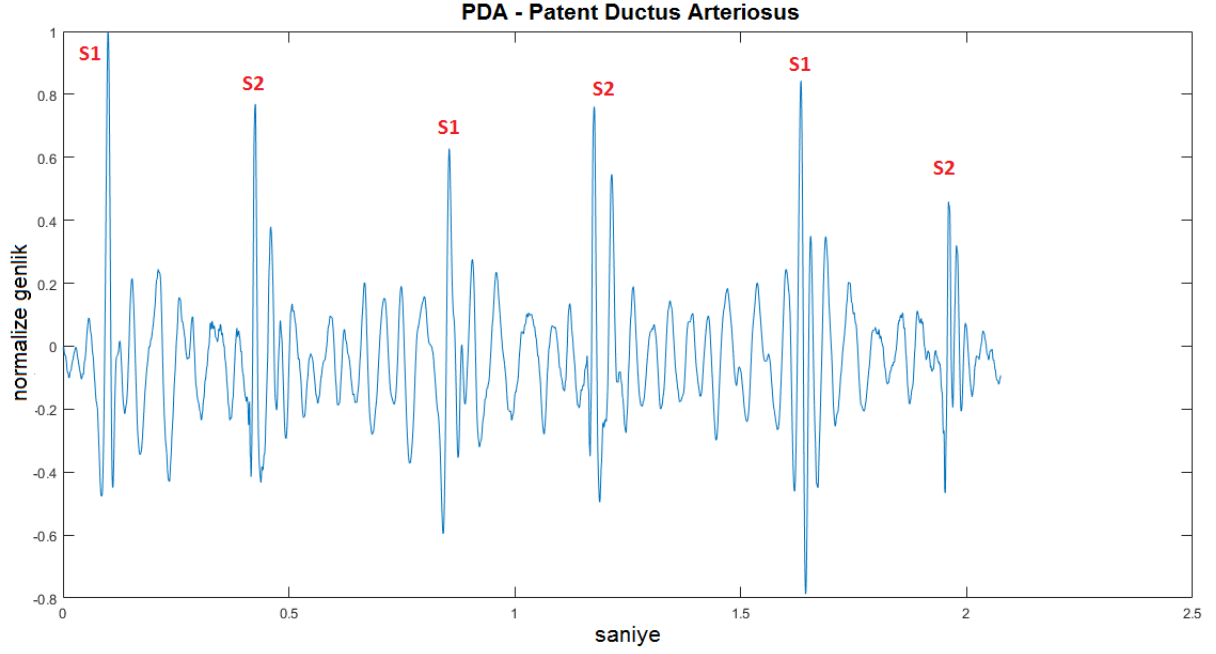
Şekil 3.6. Mitral Darlığı PCG Sinyalinin 4 Adet Kardiyak Döngüsü

3.1.7 Patent Ductus Arteriosus

Sürekli üfürüm, kardiyovasküler oskültasyonu nadir görülen, kompleks kardiyovasküler hastalıkları gizleyen bir durumdur. Aort ile sol pulmoner arter arasındaki kanalın kalıcı olarak açık kalması ile aort ile pulmoner arter arasında kan düzensiz iletilir.

Sayın Ali Oto tarafından 24 Aralık 2015 tarihinde yaklaşık 28sn boyunca alınan ve PDA

olarak etiketlenen PCG sinyalinin yaklaşık 2sn'lik kısmı Şekil 3.7 'de verilmektedir.

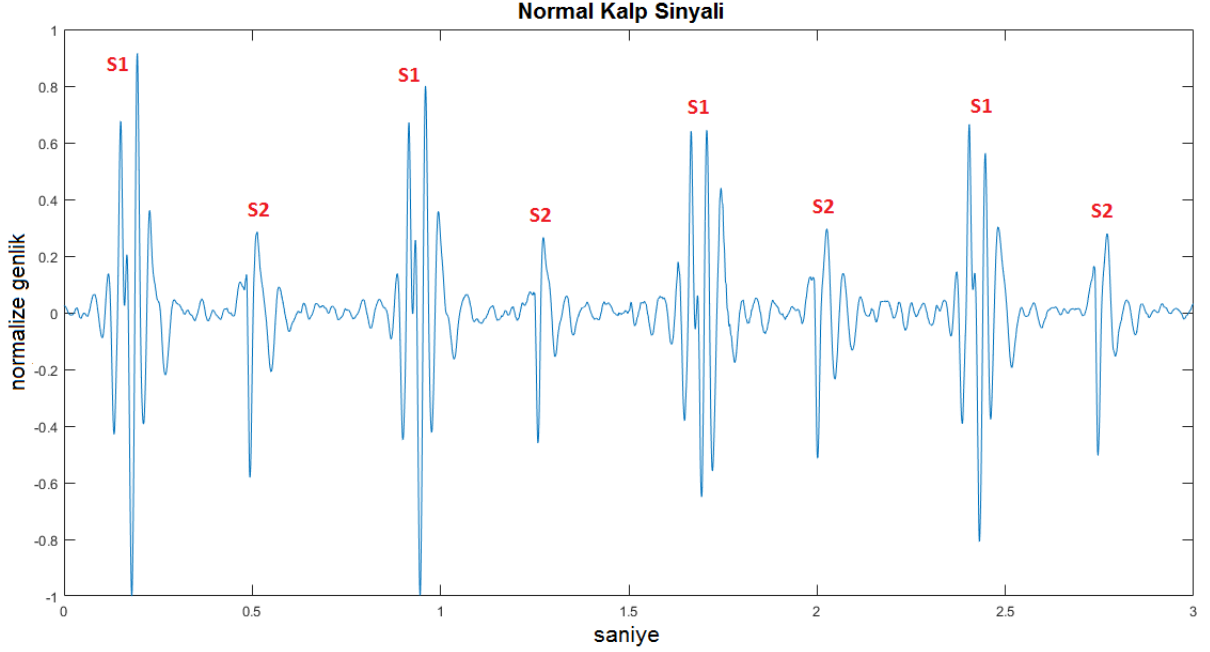


Şekil 3.7. PDA PCG Sinyalinin 3 Adet Kardiyak Döngüsü

3.1.8 Normal Kalp Sesi

Normal bir kardiyak döngü yalnızca iki büyük sestem, birinci kalp sesi ve ikinci kalp sesi, oluşur. Sistolik ve diyastolik dönemleri sessizdir.

Sayın Begüm Yetiş Sayın tarafından 20 Ağustos 2015 tarihinde, beşinci interkostal apex odağında 30sn boyunca alınan ve normal kalp ses sinyali olarak etiketlenen PCG sinyalinin 3sn'lik kısmı Şekil 3.8 'de verilmektedir.



Şekil 3.8. Normal Kalp PCG Sinyalinin 4 Adet Kardiyak Döngüsü

3.2 Stetoskop Hakkında

Bu çalışmada kullanılan kalp ses sinyalleri 3M™ Littmann® 3200 stetoskobu kullanılarak kaydedilmiştir. 3M™ Littmann® 3200 elektronik stetoskop olma özelliği ile her biri maksimum 30sn olmak üzere toplam 12 hastanın kalp ses kaydını yapabilmektedir [15]. Kullanılan stetoskop Şekil 3.9 'da verilmektedir.

Elektronik stetoskop üzerinde kayıtlı olan sinyaller anlık (çevrim içi) veya çevrim dışı olarak Bluetooth teknolojisi ile bilgisayar ortamına aktarılır. 3M™ Littmann® StethAssist™ Yazılımı ile stetoskop belleğinde veya çevrim içi doğrudan stetoskop üzerinde yer alan ses kayıtları görüntülenebilmekte ve/veya geri oynatılabilmektedir [15]. Yazılım arayüzü Şekil 3.10 'da verilmektedir [15]. Yazılım kalp ses sinyalini "bell", "diaphragm" ve "extend" mod olmak üzere ayrı filtrelerden birinden geçirerek istenilen kullanıcı dizinine wav ses dosyası olarak çıkarabilmektedir. Örnekleme frekansı 4kHz olan kayıtlı wav ses dosyaları bu çalışmada ham veri olarak kullanılacaktır.



Şekil 3.9. 3M™ Littmann® 3200 Elektronik Stetoskop [15]



Şekil 3.10. 3M™ Littmann® StethAssist™ Yazılımı

Geleneksel bir stetoskop bell(çan) ve diyafram olmak üzere çift taraflı bir yapıdan oluşmaktadır. Oskültasyon sırasında düşük frekanslı sesleri duymak için çan kısmı kullanılırken yüksek frekanslı sesler için diyafram kullanılmaktadır. Litmann 3200 stetoskunda çan ve diyafram tek yapı altında toplanmış ve modlar arasındaki geçiş basınç farkı ile sağlanmıştır. Düşük frekanslı sesler için vücuda yerleştirilen kısım hafifçe tutulur. Böylelikle zar düşük frekanslı sesler için titreşirken bell modunda kullanılmış olur. Yüksek frekanslı sesler için ise vücuda yerleştirilen kısım vücuda bastılır. Böylelikle zarın titreşimi kısıtlanarak diyafram modunda kullanılmış olur. Diyafram ile nefes sesi, normal kalp sesleri gibi yüksek frekansdaki sesleri duymak daha kolayken, bell ile kalp

üfürümleri ve mide sesleri gibi düşük frekanslı sesleri dinlemek daha kolaydır. Kardiyak muayene sırasında önce diyafram ile sonra bell ile dinleme yapılmaktadır.

Bu çalışmada, 3M™ Littmann® StethAssist™ Yazılımı ile diyafram mod seçilerek kaydedilen wav ses dosyaları, kalp seslerinin bölütlenmesi ve sınıflandırması çalışmalarında veri kaynağı olarak kullanılmaktadır.

4. S1 VE S2 SESLERİNİN BÖLÜTLENMESİ

Bu tez çalışmasında kalp ses sinyali hastalık sınıflandırılması karar destek sistemi için stetoskopa elde edilen PCG sinyaline belli başlı sinyal işleme aşamaları uygulanarak hastalık etiketi verilmiştir. Bu aşamalardan birincisi bir kayıt içerisindeki tüm kardiyak döngülerin ve temel kalp sesleri olan S1 ve S2 seslerinin bölütlenmesi işlemidir. Belirlenen bu temel ses bölgelerinin her biri için ayırt edici öznelik vektörlerinin elde edilmesi ikinci bir aşamayı oluştururken son aşama olarak bu öz niteliklerin giriş vektörü olarak kullanılmasıyla ve gözetimli sınıflandırıcılar yardımıyla hastalık kararı verebilme aşamasından oluşturmaktadır. Bu bölümde ilk aşama olan S1 ve S2 seslerinin bölütlenmesi anlatılacaktır. Kalp ses sinyalinin sınıflandırma akış blok şeması Şekil 6.1 'de verilmiştir.



Şekil 4.1. Kalp Sesinin Sınıflandırılması İş Akışı Blok Şeması

4.1 Literatürde S1-S2 Seslerinin Bölütlenmesi

Kalp rahatsızlıkları ile ilgili bilgilerin, bir kardiyak döngü içerisinde bulunabileceğinden S1 ve S2 kalp seslerinin belirlenmesi büyük önem taşımaktadır. Kalp ses sinyalinin sınıflandırılmasında yani hastalık teşhisinde temel kalp seslerinin otomatik bölütlenmesi en önemli adımı oluşturmaktadır. Üfürümlerin sınırlarını belirleyebilmek için, S1 ve S2 kalp seslerinin kusursuz olarak belirlenmesi gerekmektedir. Literatürde farklı sinyal işleme teknikleri ile bölütleme çalışmasının örnekleri mevcuttur. Birçok çalışmada kalp sesinin bölütlenmesi amacı ile referans olarak EKG sinyalleri kullanılmaktadır. M. El-Segaier ve arkadaşları birinci ve ikinci kalp seslerini otomatik algılamak için elektrokardiyografide R ve T dalgalarını referans olarak kullanmışlardır [7]. Kalp ses sinyalinin analizi için kısa zamanlı fourier dönüşümü gerçekleştirerek R dalgası referansı ile S1 sesi, T dalgası referansı ile S2 sesinin otomatik belirleme performansını yaptıkları çalışmada raporlamışlardır.

Cota Navin Gupta ve arkadaşları kalp seslerinin otomatik bölütleme algoritması için ho-

momorfik filtrelemeye dayalı bir çözüm önerirken kardiyak periyodun belirlenmesi için k-ortalama algoritması kullanılmışlardır [16]. Temel kalp sesleri olan S1 ve S2 seslerinin tepe noktalarını bulmak için önerilen homomorfik filtreleme temelde doğrusal olmayan bir kombinasyonu logaritmik bir dönüşüm kullanarak doğrusal kombinasyona dönüştürmeyi hedefler. Bir kalp ses sinyalinin temel kalp sesleri ve üfürüm sesleri yavaş $a(n)$ ve hızlı değişen $f(n)$ parçaların kombinasyonu olarak düşünerek kalp ses sinyali Denklem 4.1' deki gibi ifade etmişlerdir.

$$\begin{aligned} x(n) &= a(n)f(n) \\ \log x(n) &= \log a(n) + \log f(n) \end{aligned} \quad (4.1)$$

Kalp ses sinyalinden hızlı değişen $f(n)$ parçasını uzaklaştırmak için alçak geçiren bir filtre kullanılarak yalnızca temel kalp seslerini içeren $a(n)$ sinyalini elde etmişlerdir. Kalp ses sinyalinden elde edilen tepe noktaları tipik kalp ses sinyali parametrelerine uygunluğuna göre S1 ve S2 bölütleme işlemi tamamlamışlardır.

Kourosh Bajelani ve arkadaşları kalp ses sinyalini Ampirik Mod Ayrışımı (EMD) adı verilen bir teknik ile İçkin Mod Fonksiyonları (IMFs) olarak adlandırılan ayrı bileşenlere dönüştürmüşlerdir [17]. İlk olarak IMF zarflarını kullanarak ses bölgeleri belirlenmiş S1 ve S2 kalp sesleri bu bölgelere üzerinden tespt edilmiştir. Bu çalışmada temel kalp seslerinin üfürümlerden uzaklaştırması temel olarak amaçlanmıştır. EMD, kalp ses sinyalinin temel fonksiyonlar halinde bir dizi IMF bileşeni ile yazılmasını sağlamaktadır. Bir $x(t)$ kalp ses sinyalinin yerel maksimum ve yerel minimumları üzerinden elde edilen zarflarının ortalaması $m_1(t)$ olarak ifade edilmiş ve Denklem 4.2 ile yeni $h_1(t)$ sinyali tanımlanmıştır.

$$x(t) - m_1(t) = h_1(t) \quad (4.2)$$

IMF bileşen kriteri sağlanana kadar Denklem 4.2 sürekli tekrar edilmiş ve ilk IMF fonksiyonu $c_1(t)$ sinyali hesaplanmıştır. Denklem 4.3 ile $r_1(t)$ kalıntı fonksiyonu tanımlanmıştır.

$$r_1(t) = x(t) - c_1(t) \quad (4.3)$$

Bu süreç $r_k(t)$ kalıntı sinyali tekil bir fonksiyon haline gelene kadar her bir IMF bileşenini hesaplamak için sürdürülmüştür. $x(t)$ fonksiyonu daha fazla IMF bileşinine ayıramaya-

cağı anlamına geldiği ifade Denklem 4.4 ile tanımlanmıştır.

$$x(t) = \sum_{i=1}^k c_i(t) + r_k(t) \quad (4.4)$$

H. Liang ve arkadaşları kalp ses sinyalinin normalize edilmiş ortalama Shannon enerjisine dayanan bir yöntem önermişlerdir [18]. Birinci ve ikinci kalp seslerinin yerlerini belirlemişler ve daha sonra bu bilgiye dayanarak sistol ve diyastol periyot aralıklarını tanımlamışlardır.

Yukarıda belirtilen yöntemlerin ortak sorunu gürültü içeren sinyallerde performans sonuçlarının iyi olmamasıdır. Bu dezavantaj ilgili yöntemlerin pratikte uygulamalarını sınırlandırmaktadır. Çünkü gürültü ve parazit kalp ses sinyallerini toplama sürecinde kaçınılmaz olarak ortaya çıkmakta ve sinyali etkilemektedir.

D. Kumar ve arkadaşları S1 ve S2 seslerini üfürüm seslerinden uzaklaştırarak bölütleme işlemini tamamlamak için Ayrık Dalgacık Dönüşümü yöntemini kullanmışlardır. Geliştirdikleri bu yöntemi aort, mitral, pulmoner ve triküspid yetersizliği gibi hastalık sinyalleri üzerinde test etmişlerdir [19]. Farklı bir çalışmada yine D. Kumar ve arkadaşları kalp ses sinyalinin Ayrık Dalgacık Dönüşümü katsayılarının Shannon enerjisini kullanarak S1, sistol, S2, diyastol ses bölgelerine kesin olarak karar vermeye çalışmışlardır [20]. Kalp sesinin yüksek frekans işaretine dayanan bir çözüm sunmuşlardır. Bir $x[n]$ sinyalinin Shannon enerjisini Denklem 4.5'de verildiği gibi hesaplamışlardır.

$$E(x[n]) = -\frac{1}{N} \sum_{n=1}^N (x[n])^2 \log(x[n])^2 \quad (4.5)$$

Önerilen bu algoritmada, kalp atım hızı ve sistol zaman aralığı hızlı dalgacık ayrıştırması kullanılarak çıkarılan yüksek frekans işaretine dayanılarak tahmin edilmiş ve protez/mekanik kalp ses kayıtları üzerinde bölütleme performansı raporlanmıştır. Bu bölütleme çalışmasını temel alan bir başka çalışmalarında ise Mel-Frekans Kepstral Katsayılarını kullanarak elde ettikleri öznelikleri kullanarak mekanik kalp kapağı sesleri üzerinde sınıflandırma çalışmalarını sunmuşlardır [21].

4.2 S1-S2 Seslerinin Ayırt Edilmesi

Kalp seslerinin bölütlenmesinde farklı yöntemler kaynaklarda yer almaktadır. Bu çalışmada bilinen yöntemlerin önemli katkıları aşağıda tanımladığımız bir çerçeve içinde karma olarak kullanılacak ve ortak bir başarı arttırımı hedeflenecektir. Bu bölümde bölütleme çalışmasının önemli basamakları alt bölümde sunulmaktadır.

4.2.1 Sinyal Ön İşleme

Bölütleme işlemine başlamadan önce orijinal kalp ses sinyaline ön bir işlem uygulanmalıdır. Normalizasyon işlemi toplanan verilerin nasıl toplandığından ve ölçüldüğünden bağımsızlaştıran bir adımdır. Kalp seslerinin zaman alanında karşılaştırmasını standartlaştırabilmek için Denklem A.1'da verildiği gibi sinyalin genliği normalize edilir.

$$x_{norm}(t) = \frac{x(t)}{\max(abs(x(t)))} \quad (4.6)$$

Normal ve anormal kalp seslerinin frekans aralığı 50-700Hz arasındadır[22]. Analiz ve teşhis için daha yüksek frekanslı seslerin önemi yoktur. Bu nedenle sinyalde yer alan gürültülerden ve dc sinyallerden kurtulmak için kesim frekansı 5-750Hz olan butterworth bant geçirimli filtre (4. seviye) kullanılarak kalp ses sinyallerinin her biri filtrelenmektedir.

4.2.2 MFCC Yöntemi


Otomatik ses tanıma ve ayırt etme sistemlerinde ilk adım olarak kullanılan Mel-Frekans Kepstral Katsayıları, ses sinyali bileşenlerini en iyi şekilde tanımlarken ortam gürültülerini sinyalden uzaklaştırma görevini yerine getirmektedir. MFCC, otomatik konuşma ve konuşma tanımadada yaygın olarak kullanılan bir özelliktir. 1980'lerde Davis ve Mermelstein tarafından geliştirilen bu yöntem insan kulağının frekans seçiciliğini taklit ederek ses ayırt edici öznelik değerlerini sunabilmektedir [23]. Spektral özellikleri çıkarmak için kullanılan yaygın ve baskın yöntem olan MFCC frekans etki alanı özelliklerini kullandığından zaman etki alanı özelliklerine göre çok daha dayanıklıdır. MFCC, insan kulağının kritik bant genişliğinin frekansı ile bilinen varyasyonuna dayanır. İşitsel sistemin davranışına yaklaşan doğrusal olmayan bir frekans ölçeği kullanılır. 1000 Hz'in altındaki düşük frekansta doğrusal, 1000 Hz'nin üstündeki frekanslara logaritmik ölçek-

ler vermektedir [24].

MFCC sinyal deęişimlerinden ve ses dalga yapısından oldukça az etkilenmektedir. Bu nedenle, bu çalışmada ortam gürültüsü barındıran bir kalp ses sinyal kaydı içerisinde S1 ve S2 seslerinin bölütlemesinde MFCC yöntemi kullanılmaktadır. Öznitelik çıkarma yöntemi olarak kullanılan MFCC ana hedefi, ses örneğindeki yüklü miktardaki veriyi özetlemek, bu sayede tanıma işlemi kolaylaştırarak daha verimli olabilmektir. MFCC beş hesaplamalı adımdan oluşmaktadır. Her aşamanın, işlev ve matematiksel yaklaşımları bulunmaktadır.

4.2.2.1 Çerçeveleme

Ses zamanla deęişen bir sinyal olduğu için kısa zaman aralıklarında sinyal incelenmeli ve bunun için çerçeveleme gereklidir. Ancak yeterince kısa sürede incelendiğinde karakteristięi duraęandır. Genellikle, ses sinyali 20-40 milisaniyelik küçük zaman aralıklarına bölünerek işlenir [25]. Çoęu sistemde pencereden pencereye geçişin yumuşatılması için çerçevelerin çakışması (her pencerenin kendinden bir önceki pencerenin bir kısmı ile örtüşmesi) kullanılır. PCG sinyali için 20 milisaniyelik çerçeveler ile 10 milisaniyelik örtmeler seçilmektedir (Şekil 4.2). Bir çerçeve için örnek sayısı $N = 80$ ($0.02 * Fs$) olarak hesaplanır. ($Fs = 4000Hz$)



Şekil 4.2. Çerçeve

4.2.2.2 Pencereleme


Yukarıdaki çerçevelerin her biri, bir pencere fonksiyonu ile çarpılır. Aslında en basit pencere dikdörtgen penceredir. Ancak pencere sınırlarında aniden sinyali keser ve bu

süreksizlikler Fourier analizinde problemlere neden olur. Bu nedenle MFCC yönteminde yaygın olarak kullanılan sinyallerin değerlerini pencere sınırlarında sıfıra doğru çeken ve süreksizlikleri önleyen Hamming penceresidir [26]. Temel amaç, her çerçevenin başlangıcında ve sonunda yer alan ses örneklerini sıfıra indirerek spektral bozulmaları en aza indirmektir. Hamming pencere örneği Şekil 4.3 'de verilmiştir. Hamming penceresi Denklem 4.7'de tanımlanmaktadır [27][28]:

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

$$W(n) = 0.54 - 0.46 \times \cos\left(\frac{2\pi n}{N-1}\right) \quad 0 \leq n \leq N-1 \quad (4.7)$$

Hamming pencere $W(n)$ olarak ifade edilirken, n indisi 0 ile $N-1$ arasında tanımdır. Denklem 4.7'de her bir çerçeve $X(n)$ giriş sinyali olarak, her bir pencere $Y(n)$ çıkış sinyali olarak tanımlanmaktadır.



Şekil 4.3. Hamming Pencere

4.2.2.3 Ayrık Fourier Dönüşümü (DFT)

Zaman alanını frekans alanına dönüştürme işlemidir. Her pencerenin frekans tepkisini elde edebilmek için bu dönüşüm uygulanmaktadır. Dönüşümün sonuçları, her frekans bandındaki enerji miktarı hakkında bilgi sağlayacaktır. Herhangi bir periyodik sürekli $x(t)$ fonksiyonu, cosinus ve sinus fonksiyonlarının ağırlıklı toplamı olarak ifade edilebilmektedir [29]. Bu tanıma göre bir periyodik fonksiyonu Denklem 4.8'de verildiği gibi ifade

etmek mümkündür.

$$\begin{aligned}
 x(t) &= \sum_{n=0}^{\infty} [\alpha_n \cos(n\omega t) + \beta_n \sin(n\omega t)] \\
 &= \alpha_0 + \sum_{n=1}^{\infty} [\alpha_n \cos(n\omega t) + \beta_n \sin(n\omega t)]
 \end{aligned} \tag{4.8}$$

Yukarıda verilen seri açılımı sürekli $x(t)$ fonksiyonuna yakınsarken, α_n ve β_n katsayıları Fourier katsayıları olarak tanımlanır [29]. Formülde yer alan $\omega = 2\pi/T$, $x(t)$ fonksiyonunun temel frekansını ifade etmektedir. $x(t) = x(t + T)$ eşitliğini sağlayan 0'dan büyük en küçük T aralığı $x(t)$ fonksiyonunun periyodunu vermektedir. Euler eşitlikleri yardımı ile fourier serileri kompleks formda Denklem 4.9'de verildiği gibi ifade edilebilmektedir [29].

$$x(t) = \sum_{-\infty}^{\infty} [c_n e^{jn\omega t}] \tag{4.9}$$


Serinin katsayıları elde edilmek istenirse Denklem 4.10'de verilen ifade kullanılmaktadır [29].

$$c_n = \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} x(t) e^{-jn\omega t} dt, \forall n \tag{4.10}$$

Ancak Fourier serileri sonsuz uzunluktaki sürekli fonksiyonlar için tanımlı olduğundan, gerçek hayattaki sınırlı sayıda dizilerin ifade edilebilmesi için periyodik olmayan sinyallere Fourier dönüşümü tanımlanmaktadır [29]. $x(t)$ fonksiyonunun T periyodunun sonuza yakınsadığını varsayarsak Denklem 4.11'da tanımlanan $\tilde{x}(t)$ fonksiyonu elde edilir.

$$\tilde{x}(t) = \lim_{T \rightarrow \infty} x(t) \tag{4.11}$$

$\tilde{x}(t)$ ve $x(t)$ sinyallerinin örnek bir görüntüsü Şekil 4.4 'de verilmektedir.



Şekil 4.4. Periyodik ve Periyodik Olmayan Sinyaller

Fonksiyonun bu hali ile seri katsayıları Denklem 4.12'de verildiği gibi ifade edilmektedir.

$$c_n = \frac{1}{T} \int_{-\infty}^{\infty} \tilde{x}(t) e^{-jn\omega t} dt \quad (4.12)$$

Periyodik olmayan sınırlı uzunluktaki sürekli $\tilde{x}(t)$ fonksiyonun Fourier dönüşümü Denklem 4.13'de verildiği gibi gerçekleşmiş olur. Fourier dönüşümü Fourier serilerinin özelleşmiş halidir. Periyodik olmayan bir fonksiyonun periyodunu sonsuzmuş gibi ele alarak dönüşüm gerçekleştirilir.

$$X(\omega) = \int_{-\infty}^{\infty} \tilde{x}(t) e^{-j\omega t} dt \quad (4.13)$$

Sürekli $\tilde{x}(t)$ fonksiyonu sonsuz uzunlukta noktadan oluşan bir işareti temsil etmektedir. Ancak sayısal sistemlerde eşit aralıklı frekansların örnekleri alınarak bu işaretler elde edilmektedir. Sayısal sistemlerde fourier dönüşümünü hesaplayabilmek için Ayrık Fourier Dönüşümü tanımlanmaktadır [29]. Eşit aralıklı örneklerden oluşan N-noktalı $x(n)$ fonksiyonu için Ayrık Fourier Dönüşümü Denklem 4.14'deki gibi ifade edilir.

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j\frac{2\pi kn}{N}} \quad k = 0, 1, 2, 3, \dots, N-1 \quad (4.14)$$


Ayrık Fourier Dönüşümü, hem zaman hem frekans alanında sonlu ve sınırlı sayıda işaret üzerinde çalıştığından sayısal sistemlerde yaygın olarak kullanılmaktadır. Yüklü miktardaki bu dönüşüm hesaplamalarını hızlı gerçekleştirebilmek için Cooley-Tukey algoritması gibi Hızlı Fourier Dönüşümü (FFT) algoritmaları geliştirilmiştir.

4.2.2.4 Mel Filtre Bankası

MFCC yöntemi temel olarak farklı bant geçiren filtreler kullanarak sinyalin her frekans bandının gücünü hesaplayarak kepsral katsayıları üretmektedir. Mel ölçekleme insan kullağının tepkisine benzer bir şekilde 1kHz altındaki frekanslara doğrusal, üzerindeki frekanslara logaritmik ölçekler vermektedir. Mel filtre bankası içiçe geçmiş üçgen filtrelerden oluşmaktadır. Filtre bankası 13 doğrusal aralıklı, 27 logaritmik aralıklı filtreden oluşmaktadır [30]. Frekans(f) hertz değerini Mel(m) ölçeğine çevirmek için kullanılan yaygın Denklemler 4.15'de verilmektedir [31].

$$m = 2595 \log_{10}\left(1 + \frac{f}{700}\right)$$
$$f = 700\left(10^{\frac{m}{2595}} - 1\right) \quad (4.15)$$

Mel-frekans dönüşümü Şekil 4.5 'de verildiği gibi kolayca uygulanabilir.



Şekil 4.5. Frekans Mel Dönüşümü

Mel filtre bankası için tanımlanan parametreler aşağıda listelenmektedir.

- Mel filtrelerinin sayısı (F)
- Minimum frekans (ℓ_{fmin})
- Maksimum frekans (ℓ_{fmax})

Kalp ses sinyalleri için filtre sayısı $F=21$ olarak seçilirken filtre bankasının başlayacağı minimum frekans $\ell_{fmin} = 0$, filtre bankasının sonlanacağı maksimum frekans ise örnekleme hızının yarısı olan $\ell_{fmax} = 2kHz$ seçilecektir. Konuşma sinyalleri için Nyquist frekansından düşük frekanslar maksimum frekans olarak seçilmesi önerilmektedir [32].

Mel ölçeğinin sabit frekans çözünürlüğü Denklem 4.16 ile hesaplanırken seçilen minimum ve maksimum doğrusal frekansların Mel ölçek karşılıkları sırasıyla M_{fmin} ve M_{fmax} olarak tanımlanmaktadır [32].


$$\delta_{M_f} = \frac{(M_{fmax} - M_{fmin})}{F + 1} \quad (4.16)$$

Mel ölçeğinin merkez frekansları $\phi_{M_{fc}} = m \cdot \delta_{M_f}$ şeklinde hesaplanır. m indisi 1'den filtre sayısına F 'e kadar tanımlıdır. Mel ölçeği merkez frekansları $\phi_{M_{fc}}$ Denklem 4.15 kullanılarak Hertz alanındaki üçgen Mel-filtrelerinin merkezlerine $\ell_{fc}(k)$ dönüştürülür. F adet filtre için üçgen filtre bankaları Denklem 4.17 verilmektedir [32].

$$M(m, k) = \begin{cases} 0 & \ell_f(k) < \ell_{fc}(m-1) \\ \frac{\ell_f(k) - \ell_{fc}(m-1)}{\ell_{fc}(m) - \ell_{fc}(m-1)} & \ell_{fc}(m-1) \leq \ell_f(k) < \ell_{fc}(m) \\ \frac{\ell_{fc}(m) - \ell_f(k)}{\ell_{fc}(m) - \ell_{fc}(m+1)} & \ell_{fc}(m) \leq \ell_f(k) < \ell_{fc}(m+1) \\ 0 & \ell_f(k) \geq \ell_{fc}(m+1) \end{cases} \quad (4.17)$$

Denklem 4.17'ye göre Mel filtre banka boyutu $F \times N$ olacaktır. Şekil 4.6 'de Mel filtre bankası örneği verilmektedir.

Seçilen bir pencereye DFT uygulandıktan sonra işaret frekans düzlemine geçmiş olurken DFT çıkış verisi merkezine göre simetrik olduğundan frekans düzleminin yarısı kullanılacaktır. Filtre banka boyutunda tanımlanan N bu nedenle DFT çıkışının yarısından bir fazla yani $N=41$ olacaktır.



Şekil 4.6. Filtre Bankası

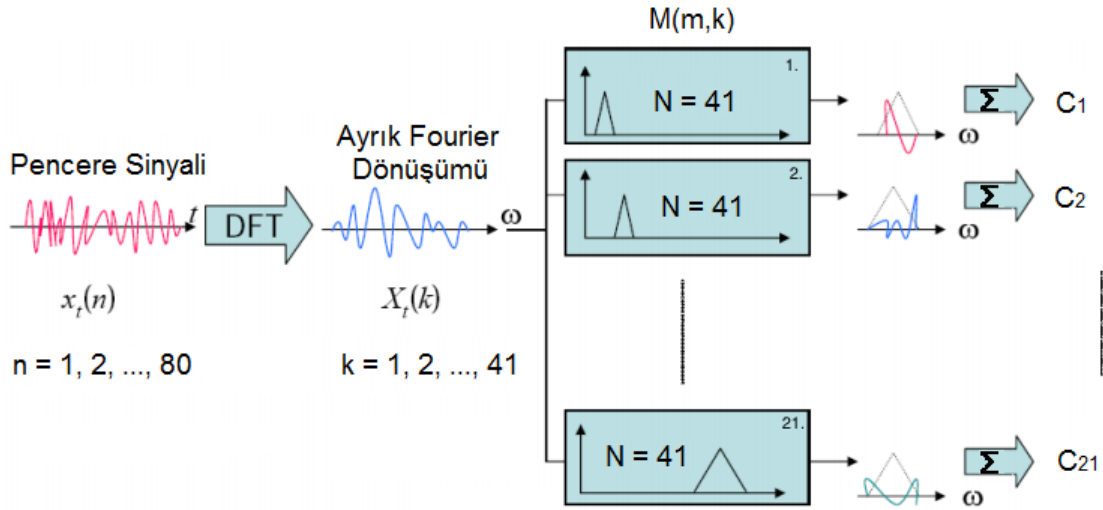
Her bir pencere Ayırık Fourier Dönüşümü sonrasında Denklem 4.18'de sunulduğu gibi Mel filtre bankasından geçirilmektedir.

$$c_m = \sum_{k=1}^{\frac{N}{2}+1} x_t(k)M(m, k) \quad m = 1, 2, 3, \dots, 21 \quad (4.18)$$

Bir pencere içindeki örnekleme nokta sayısı $N=80$ olarak ifade edilirken, Fourier dönüşümü alınmış olan pencere $x_t(k)$ ile ifade edilmiştir. 21 adet farklı bant geçirimli filtre olarak $M(m,k)$ ifadesi kullanılmış ve her frekans bandının gücü olarak 21 adet c_m kepstral katsayıları Şekil 4.7 'deki gibi hesaplanmaktadır. Ayrıca bu kepstral katsayıları öznitelik vektörleri olarak da kullanılmaktadır.

Literatürde, MFCC yönteminin son aşaması olarak Mel filtreleme sonuçlarının logaritmik enerjilerinin Ayırık Koninüs Dönüşümü (DCT) kullanılarak Mel spectrumu frekans alanından zaman etki alanına dönüştürülür [25]. Bu dönüşüm sonucunda Mel-Frekans Kepstral Katsayıları elde edilir.

Gürültü içermeyen bir kalp ses sinyalinin özniteliklerini çıkarmak için kullanılan bu MFCC yöntemi başarılı sonuçlar vermektedir. Ancak kalp ses sinyalinin kaydı, frekans tepkisine duyarlı olduğundan ve gürültülü bir ortamdan elde edildiğinden MFCC performansının iyi olmadığı anlaşılmış P. Wang ve ark. son adımda kullanılan DCT yerine, Mel-Kepstral Katsayıları gürültünün etkisini azaltmak için Ayırık Dalgacık Dönüşümü kullanmayı önermişlerdir [33].



Şekil 4.7. Kepstral Katsayılarının Akışı

4.2.2.5 Kepstrum Ayrık Dalgacık Dönüşümü

Kalp ses sinyalleri durağan olmayan özellikler içerdiğinden tek başına zaman ve frekans etki alanlarından öznelilik çıkarmak yetersiz kalmaktadır. Kaydedilen kalp seslerini karakterize etmek için bir zaman-frekans gösterim tekniği olan ayrık dalgacık dönüşümü bir kardiyak döngü boyunca fonokardiyogramın zaman-frekans içeriği hakkında bilgi sağlayabilmektedir [33].

Fourier Dönüşümü, sinyalin frekans bileşenlerini analiz etmek için yararlı bir araçtır. Ancak durağan sinyallerde bütün zaman eksenini boyunca Fourier dönüşümü yapıldığından belirli bir frekansın hangi zaman alanına denk geldiği kaybedilir. Kısa Zamanlı Fourier Dönüşümü (STFT) ile hem zaman hem frekans bilgisi veren spektrogramı bulmak için kayan pencereler kullanarak çözüm bulmaya çalışılmıştır [34]. Ancak pencere uzunluğunun seçimi zaman ve frekans çözünürlüklerini sınırlamaktadır. Pencere uzunluğunun fazla olması frekansta çözünürlüğü artırırken zamanda çözünürlük azalmasına, aksi durumda pencere uzunluğunun az olması zamanda çözünürlüğü artırırken frekansta çözünürlük azalmasına neden olmaktadır. Dalgacık dönüşümü değişen ölçekli dalgacıklarla bu soruna bir çözüm sunmaktadır. STFT her zaman sabit bir çözünürlük verirken, DWT

değişken bir çözünürlük vermektedir.

Bir sinyal, temel (basis) fonksiyonlarının oluşturduğu bir uzayın içerisinde ise bu sinyal uzayı oluşturan temel fonksiyonlarının ağırlıklandırılmış kombinasyonları Denklem 4.19'da verildiği gibi ifade edilebilir. Fourier seri açılımı $\phi_k(t) = \exp(j\frac{2\pi kt}{T})$ temel fonksiyonunun özel bir durumu şeklinde ifade edilebileceği Denklem 4.20'de tekrar verilmiştir.

$$f(t) = \sum_k \alpha_k \phi_k(t) \quad (4.19)$$

$$x(t) = \sum_{k=-\infty}^{\infty} \alpha_k \exp(j\frac{2\pi kt}{T}) \quad (4.20)$$

Bu formülde periyodik bir $x(t)$ sinyalinin $\exp(j\frac{2\pi kt}{T})$ temel fonksiyonlarının doğrusal kombinasyonları ile ifade edilebileceği görülmüştür.

V vektör uzayının bir alt kümesi $[v_1, v_2, \dots, v_k]$ olarak tanımlansın. Bu alt küme içerisindeki her bir vektör için $i \neq j$ koşulu ile $\langle v_i, v_j \rangle$ iç çarpımları sıfır olarak hesaplanıyorsa bu vektörlerin herbiri birbirine diktir, yani ortonormaldir. Bu ortonormal fonksiyon setleri temel fonksiyonlar olarak tanımlanmaktadır [34]. $f[n]$ sinyali ϕ ve ψ temel fonksiyonlarının ağırlıklandırılmış kombinasyonu olarak ifade edilebilir. Bu ağırlıklandırma katsayıları $W_\phi[j_0, k]$ ve $W_\psi[j, k]$ dalgacık katsayıları olarak Denklem 4.21 tanımlanmaktadır [34].

$$f[n] = \frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n] \quad 0 \leq n \leq M-1 \quad (4.21)$$

$f[n]$, $\phi_{j_0, k}[n]$ and $\psi_{j, k}[n]$ fonksiyonları $[0, M-1]$ aralığında tanımlanmış fonksiyonlardır. $\{\phi_{j_0, k}[n]\}_{k \in \mathbb{Z}}$ and $\{\psi_{j, k}[n]\}_{(j, k) \in \mathbb{Z}^2, j \geq j_0}$ temel setleri birbirlerine dik olduğundan iç çarpım (inner product) yardımıyla Denklem 4.22'de verilen dalgacık katsayıları elde edilmektedir [34].

$$\begin{aligned} W_\phi[j_0, k] &= \frac{1}{\sqrt{M}} \sum_n f[n] \phi_{j_0, k}[n] \\ W_\psi[j, k] &= \frac{1}{\sqrt{M}} \sum_n f[n] \psi_{j, k}[n] \quad j \geq j_0 \end{aligned} \quad (4.22)$$

$W_\phi[j_0, k]$ yaklaşık katsayılar olarak ifade edilirken, $W_\psi[j, k]$ ayrıntılı katsayılar olarak ifade edilmektedir. Dalgacık fonksiyonlarının bütün bir ailesi, ana dalgacığın kaydırıl-

ması ve ölçeklendirilmesi ile aşağıdaki gibi elde edilebilir:

$$\begin{aligned}\phi_{j,k}[n] &= 2^{j/2}\phi[2^j n - k] \\ \psi_{j,k}[t] &= 2^{j/2}\psi[2^j t - k]\end{aligned}\quad (4.23)$$


Burada ϕ ve ψ temel fonksiyonları h ve g filtre fonksiyonları olarak Denklem 4.24'de ifade edilebilir.

$$\begin{aligned}\phi_{i,l}(k) &= 2^{i/2}h_i(k - 2^i l) \\ \psi_{i,l}(k) &= 2^{i/2}g_i(k - 2^i l)\end{aligned}\quad (4.24)$$

Denklem 4.24'de belirtilen dalgacık ve ölçek temelli fonksiyonlar Denklem 4.22 içerisine birleştirildiğinde yaklaşık ve ayrıştırma katsayıları, $f[n]$ sinyalinin alçak $h[n]$ ve yüksek $g[n]$ geçiren filtreye ait çıktıları olduğu Denklem 4.25'de görülmektedir [34].


$$\begin{aligned}W_\phi[j, k] &= h_\phi[-n] * f[n] \\ W_\psi[j, k] &= g_\psi[-n] * f[n]\end{aligned}\quad (4.25)$$

Bu çalışmada kalp ses sinyali içerisindeki gürültü ve üfürümleri bastırabilmek için kepst-ral katsayıların Şekil 4.8 'de verilen "bior 2.2" dalgacığı kullanılarak yaklaşık katsayıları elde edilmektedir.



Şekil 4.8. Bior 2.2 Alçak ve Yüksek Geçiren Filtre

MFCC ve Ayrık dalgacık dönüşümü yaklaşımı ile kalp ses sinyali üzerinden alınmış bir pencere için 13 adet kepsral katsayısı elde edilmektedir. Her bir pencere için hesaplanmış olan kepsral katsayıları ayrı ayrı yüksek ve alçak geçiren filtrelerden geçirilerek gürültülere ve üfürümlere dayanıklı hale getirilmiştir. Denklem 4.18’de bir pencere için elde edilmiş olan c_m kepsral katsayıları Şekil 4.8 ’de belirtilen alçak ve yüksek filtreler ile konvolüsyon işlemine tabi tutulduktan sonra düşük örnekleme (downsample) tabi tutulmaktadır. $N= 21$ elemanlı c_m vektörleri ile 6 elemanlı h ve g filtre fonksiyonlarının konvolüsyonu ile $M= 26$ elemanlı bir vektör elde edilir. Elde edilen vektör iki ile alt örnekleme yapılarak $L= 13$ elemanlı bir vektör elde edilmesini sağlayacaktır. Şekil 4.9 ’da c_m vektörlerinin Ayrık Dalgacık Ayrışımı blok şeması verilmektedir.




Şekil 4.9. Ayrık Dalgacık Ayrışımı


4.2.3 Sinyal Analizi

Gürültüsüz ortamda kalp rahatsızlığı olmayan normal bir hastaya ait, gürültülü ortamda kalp rahatsızlığı olmayan normal bir hastaya ait ve mitral yetmezliği bulunan bir hastaya ait kalp ses sinyali üzerinde MFCC öznitelik vektörlerini örnek olarak incelenecektir. MFCC ve Ayrık Dalgacık Dönüşüm yaklaşımının temel kalp seslerini gürültü ve üfürümlerden temizleme performans gösterimleri verilecektir. Kalp seslerini bölütleme çalışmasında enerjisi en yüksek frekans bandı, ikinci öznitelik vektörü, S1 ve S2 seslerinin yerlerini belirlemek üzere seçilmiştir.

İnceleme 1: Sayın Begüm Yetiş Sayın tarafından 20 Ağustos 2015 tarihinde, beşinci interkostal apex odağından 30sn boyunca gürültüsüz ortamda toplanan ve normal kalp ses sinyali olarak etiketlenen PCG sinyalinin yaklaşık 13.5sn’lik kısmı Şekil 4.10 ’de , bu sinyal üzerinden elde edilmiş MFCC öznitelik vektörleri Şekil 4.11 ’de verilmektedir.




Şekil 4.10. Gürültüsüz Normal PCG Sinyali




Şekil 4.11. Gürültüsüz Normal - MFCC Öznitelik Vektörü

MFCC yöntemi ile sistol ve diyastol bölgelerindeki gürültüler tamamen temizlenmiş S1 ve S2 merkezlerinin yerleri daha belirgin hale geldiği görülmektedir. İkinci öznelik vektörü, temel kalp seslerinin yerlerini belirlemek üzere seçilmiştir. Gürültü içermeyen normal kalp ses sinyalinin ikinci öznelik vektörü Şekil 4.12'da verilmektedir.




Şekil 4.12. Gürültüsüz Normal - MFCC İkinci Öznelik Vektörü

İnceleme 2: Sayın Begüm Yetiş tarafından 17 Şubat 2016 tarihinde, beşinci interkostal apex odağından 28 yaşında erkek bir hastadan 30sn boyunca gürültülü ortamda toplanan ve normal kalp ses sinyali olarak etiketlenen PCG sinyalinin yaklaşık 9sn'lik kısmı Şekil 4.13 'da, bu sinyal üzerinden elde edilmiş MFCC öznelik vektörleri Şekil 4.14 'de verilmektedir.




Şekil 4.13. Gürültülü Normal PCG Sinyali




Şekil 4.14. Gürültülü Normal - MFCC Öz nitelik Vektörü

MFCC ve Ayrık Dalgacık Dönüşüm yaklaşımının gürültülü sinyaller üzerinde dahi dayanıklılığını sürdürebilmekte, S1 ve S2 temel seslerinin yerlerinin ayırt edebilme performansını güçlü bir şekilde devam ettirebilmektedir. Ortam gürültüsü içeren normal kalp ses sinyalinin ikinci öznelik vektörü Şekil 4.15 'de verilmektedir.




Şekil 4.15. Gürültülü Normal - MFCC İkinci Öznelik Vektörü

İnceleme 3: Sayın Sercan Okutucu tarafından 16 Aralık 2015 tarihinde, sol ikinci interkostal odağından yaklaşık 11.5sn kaydedilen ve Mitral Yetmezliği olarak etiketlenen PCG sinyalinin yaklaşık 6sn'lik kısmı Şekil 4.16 'de, bu sinyal üzerinden elde edilmiş MFCC öznelik vektörleri Şekil 4.17 'de verilmektedir.




Şekil 4.16. Hastalıklı PCG Sinyali



Şekil 4.17. Hastalıklı - MFCC Öz nitelik Vektörü

Hem sistol hem diyastol bölgesinde üfürüm içeren bir kayıta dahi MFCC ve Ayrık Dalgacık Dönüşümü yaklaşımı S1 ve S2 seslerinin yerlerinin yüksek performansta ayırt edebilmeye devam edebilmektedir. Önerilen yöntem kalp ses sinyalini gürültülerden temizlemenin yanı sıra kalp rahatsızlığına bağlı olan üfürümleri de kalp sinyalinden uzaklaştırmaktadır. Kalp rahatsızlığına bağlı olarak sistol ve diyastol bölgelerinde üfürüm içeren Mitral Yetmezliği kalp ses sinyalinin ikinci öznelik vektörü Şekil 4.18 'de verilmektedir.



Şekil 4.18. Hastalıklı - MFCC İkinci Öznelik Vektörü


4.2.4 Kalp Atım Hızı ve Sistol Süresi Belirleme

Enerjisi en yüksek frekans bandı, ikinci öznelik vektörü, S1 ve S2 seslerinin merkezleri belirlenmek üzere kullanılacaktır. Seçilen bu öznelik vektörüne özilinti işlemi uygulanarak kalp atım hızı ve sistol süresi her bir hasta kaydı için hesaplanacaktır. Özilinti işlemi bir sinyali kendisinin zaman gecikmeli bir versiyonu ile karşılaştırmak için kullanılır. Tekrarlayan sinyalleri bulmak için yaygın olarak kullanılan bu yöntem, gürültü ile perdelenmiş periyodik bir sinyalin temel periyodunun belirlenmesini sağlamaktadır. Sinyalin zaman gecikmesi bir tam periyod olduğu takdirde $x(t)$ sinyal ile $x(t-T)$ gecikmeli sinyal örtüşmesi maksimum olmaktadır. Denklem 4.26'da $x(t)$ sinyalinin otokorelasyon

ifadesi verilmektedir.

$$R_{xx}(l) = \sum_t x(t)x(t - T) \quad (4.26)$$

Sinyalin ilk andaki korelasyonu maksimumdur ve bu andan itibaren elde edilen en yüksek değer bize kalp sinyalinin periyodu yani kalp atım hızını verir. Apex odağından alınan bir sinyal için bir periyod içerisinde bulunan en yüksek seviye bize sistol zaman aralığı değerini, ikinci en yüksek seviye ise diyastol zaman aralığı değerini verecektir. Kalp rahatsızlığı bulunmayan bir hastaya ait normal kalp ses sinyali kullanılarak MFCC ikinci öznitelik vektörü özilinti sonucu ile kalp atım hızı ve sistol süresi Şekil 4.19 'da verilmektedir.



Şekil 4.19. Kalp Atım Hızı ve Sistol Süresi


Normal bir kalp atım hızı dakikada 60-100 atım arasındadır [35]. Çocuklarda ve yetişkinlerde sakin veya heyecanlı durumlarda atım hızı 50-140 atım arasında değişebilmektedir. Bu da dinlenme durumunda bir kardiyak sürenin en az 0.4sn en çok 1.2sn olabileceğini ifade etmektedir. Bu bilgiler ışığında kardiyak süresi, özilintinin 0.4sn-1.2sn arasında maksimum olduğu andaki değer olarak belirlenmektedir. Bir kardiyak süre içerisinde sistol süresi, diyastol süresinden daha kısadır [35]. Bu da sistol süresinin bir kardiyak süresinin yarısından fazla olamayacağı anlamına gelmektedir. Sistol süresi, apex

odağından alınan bir sinyal için bir kardiyak süre içindeki özilintinin en yüksek değeri olarak da belirlenebilmektedir.

4.2.5 S1-S2 Yerlerinin Belirlenmesi


Öznitelik vektörü içerisinde yer alan tepe noktaları PCG sinyali içerisinde yer alan gü-rültü harici seslerin yerlerini göstermektedir. Her kalp ses sinyalinin kendisine ait he-saplanan kardiyak periyod ve sistol süresi ile kalp sinyalinin MFCC çıktısı ikinci öznite-lik vektörü üzerinde S1 ve S2 seslerinin yerleri kolaylıkla belirlenebilir. S1 kalp sesinin süresi ortalama 150ms, S2 kalp sesinin süresi ortalama 120ms'dir. Kalp ses sinyalinin kendi kardiyak periyodu, kendi sistol zaman aralığı ve ortalama S1-S2 süreleri kullanı-larak bir adet pencere oluşturulmaktadır. MFCC çıktısı ikinci öznitelik vektörü üzerinde bu pencere kaydırılarak tüm kayıt içerisinde yer alan S1 ve S2 seslerinin yerleri tepe noktaları yardımı ile belirlenmektedir. Kayan pencere, öznitelik vektörü ile pencere sin-yalinin en iyi örtüştüğü anda durdurulur, bu andaki pencere içerisindeki tepe noktaları S1 ve S2 olarak işaretlenir. Bu kayma işlemi kalp ses sinyalinin sonuna kadar tekrarlı bir şekilde devam eder. Yaklaşık 3sn'lik bir kalp ses sinyalinin öznitelik vektörü, pencere sinyali ve tepe noktaları Şekil 4.20 'de verilmektedir.

Bir pencere içerisinde iki adet tepe noktası bulunması durumunda ve bu iki ses arasın-daki sürenin 50ms altında olması seste çatallaşma olduğunu ifade etmektedir[35]. Tepe noktaları arasındaki uzaklık 50ms altında olması durumunda yüksek enerjili tepe nok-tası temel sesi ifade ediyor olacaktır ve düşük olan tepe noktası işaretlenmeyecektir. Şekil 4.20 'de ikinci S2 sesi bu durum için bir örnek oluşturmaktadır.



Şekil 4.20. Pencereleme ve Öznitelik Vektörü

Sayın Ali Oto tarafından 24 Aralık 2015 tarihinde, PDA olarak etiketlenen kalp ses sinyalinin 3sn'lik kısmı, bu sinyal üzerinden elde edilmiş MFCC öznitelik vektörü ve geliştirilen algoritma tarafından otomatik tespit edilen S1 ve S2 temel seslerinin yerleri Şekil 4.21'de verilmektedir.



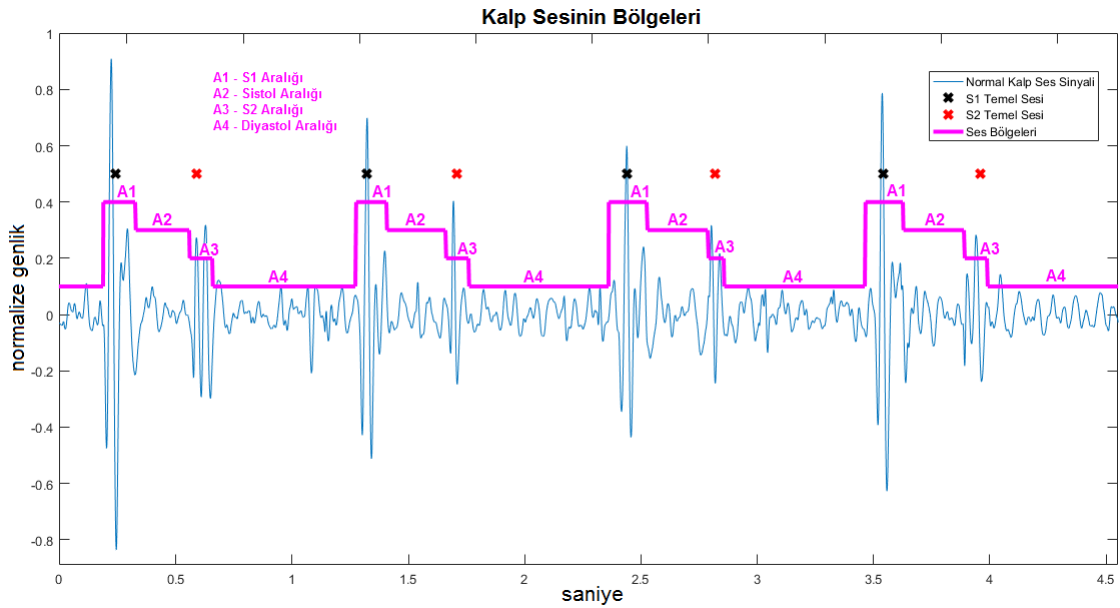
Şekil 4.21. S1 ve S2 Kalp Seslerinin Yerleri

4.2.6 Bölgelerin Belirlenmesi

Kalp sesindeki başlıca aktif bölgeler S1, sistol, S2 ve diyastol aralıklarıdır. S1 ve S2 temel seslerinin sürelerini tespit etmek bu aralıkların tamamının belirlenmesini sağlayacak ilk adımdır. Temel seslerin başlama ve bitme anlarının tespiti için iki adet eşik değeri kullanılmaktadır. MFCC yöntemi ile S1 ve S2 ses yerlerinin belirlenmesinin ardından bu seslerinin başlama ve bitme anları eşik değerlerine uygun olarak karar verilecektir.


Birinci eşik değeri sinyal zarfının ortalama değeridir. Sinyal zarfı basitçe sinyal içerisinde yer alan tepe noktaları birleştirilerek elde edilmektedir. Temel ses bölgeleri çoğunlukla bu ortalama değer üzerinde kalmaktadır. S1 ve S2 ses bölgeleri çoğunlukla belirlenen bu eşik değerinin üzerinde kalsa da S2 sesinin enerjisinin düşük olduğu durumlarda, S2 sesi belirlenen eşik değerinin altına düştüğü gözlemlenmektedir. Bu sorunu aşmak için ikinci bir eşik değeri tanımlanacaktır. İkinci eşik değeri ise sinyal türevinin zarfının ortalaması olarak seçilmektedir ve sinyalin türevinin zarfına uygulanmaktadır.

Sistol ve diyastol aralığı sessiz olan normal kalp sesinin S1, sistol, S2, diyastol aralıkları örnek sinyal olarak bölütlenmiştir. Normal olarak etiketlenen kalp ses sinyalinin S1, sistol, S2, diyastol aralıkları program çıktısı Şekil 4.22 'de verilmektedir.



Şekil 4.22. Normal Kalp Sesinin Bölgeleri

Benzer şekilde sistol ve diyastol aralığında üfürüm içeren PDA rahatsızlığı kalp sesinin S1, sistol, S2, diyastol aralıkları program çıktısı Şekil 4.23 'de verilmektedir. En üst basamak S1 temel sesi, ikinci alt basamak sistol bölgesi, üçüncü alt basamak S2 temel sesi ve en alt basamak diyastol bölgesi olarak belirlenebilmektedir.



Şekil 4.23. PDA Rahatsızlığı Kalp Sesinin Bölgeleri

4.2.7 Performans Sonuçları

Ses tanıma sistemlerinde yaygın olarak kullanılan Mel-Frekans Kepstral Katsayıları bu çalışmada Ayrık Dalgacık Dönüşümü ile birlikte S1 ve S2 kalp seslerinin gürültülerden ve üfürümlerden ayırt edilmesi amacı ile kullanılmaktadır. Hastalık bilgisi taşıyan ve taşımayan, Bölüm 3.1'de listelenen tüm kayıtlar üzerinde S1 ve S2 ses yerlerinin belirlenme performans sonuçları Çizelge 4.1'de verilmektedir.

Geliştirilen yöntem ile hastalık bilgisi taşımayan normal kalp sesleri üzerinden S1 ve S2 sesleri %98,19 kesinlik ve %98,52 hassasiyet ile tespit edilirken, anormal kalp sesleri üzerinde yapılan çalışmada %94,31 kesinlik ve %96,92 hassasiyet ile tespitler elde edilmektedir. Kesinlik-hassasiyet analizi [EK - A.2]'de detaylı olarak anlatılmıştır.

Kayıt	Kardiyak Periyod Sayısı	Kesinlik (%)	Hassasiyet (%)
Normal	4603	98,19	98,52
MD	567	92,78	97,53
MY	856	96,55	98,07
AD	1060	94,26	96,70
PDA	90	92,94	94,05
TY	76	90,28	94,20
AY	95	88,51	92,77
VSD	46	92,86	90,70

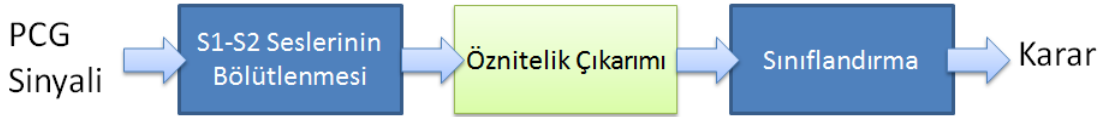
Çizelge 4.1. S1 ve S2 Ses Yerlerinin Belirlenmesi Performans Sonuçları

S1 ve S2 seslerinin yerlerinin doğru belirlenmesi S1, sistol, S2, diyastol ses bölgelerinin belirlenme başarımını doğrudan etkilemektedir. Kaydedilen kalp sesinin sistolik ve/veya diyastolik üfürüm taşımasından öte hangi hastalığa işaret ettiğini tespit edebilmek S1, sistol, S2, diyastol aralıklarının doğru belirlenmesine bağlıdır.

Kaynaklarda yapılan genelde durağan sistolik ve diyastolik üfürüm belirleme çalışmalarına ek olarak sinyal değişiminin izlenebildiği ve dinamik bu tür hastalıkların daha ayrıntılı ve doğru bir şekilde izole edilebilen S1, sistol, S2, diyastol aralıklarının başlangıç ve bitiş noktalarının zamansal akışta daha doğru belirlenmesi ile bu aralıklarda oluşan hastalık bilgisinin elde edilmesi, dinamik sınıflandırıcılar için önemli bir ön işleme safhasını oluşturmaktadır.

5. ÖZNETELİK ÇIKARIMI

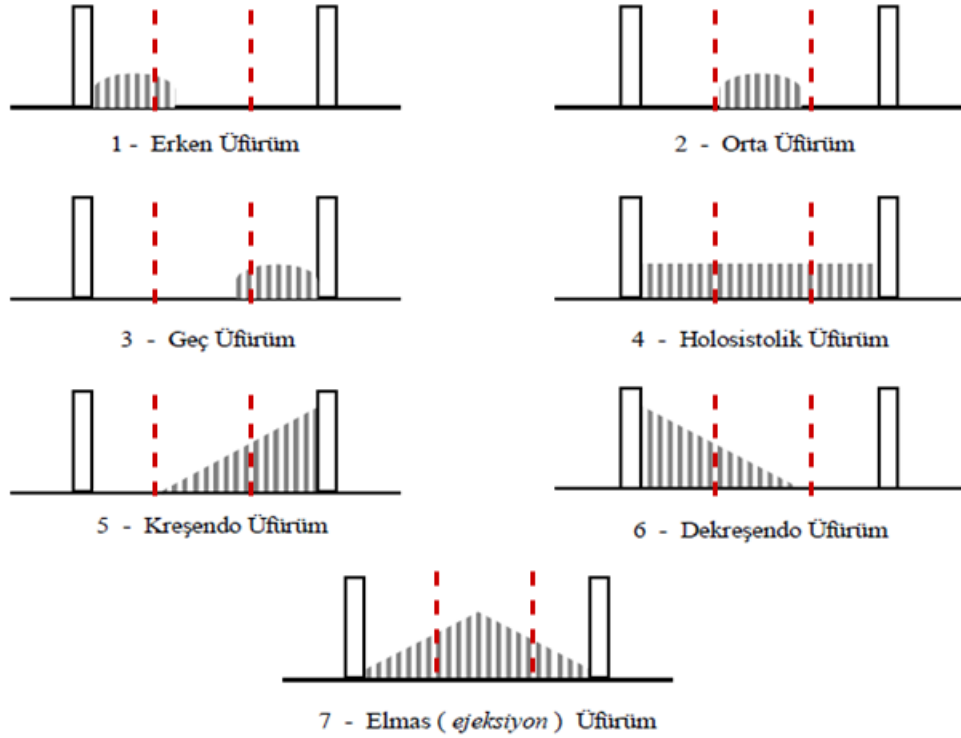
Kalp ses sinyalindeki herhangi bir anormallik kalpteki bazı rahatsızlıkların göstergesidir [36]. PCG sinyali üzerinden elde edilecek olan ayırt edici öznitelikler bu kalp sinyallerinin sınıflandırılmasına kullanılmaktadır. Literatürde kalp ses sinyali için ayırt edici öznitelikler araştırılmış olup yüksek ayırt edici potansiyeli olanlar seçilerek sınıflandırıcılara gönderilmiştir [36][37]. Şekil 5.1 'de kalp seslerinin sınıflandırılma aşamaları gösterilmiştir.



Şekil 5.1. Kalp Sesinin Sınıflandırılması İş Akışı Blok Şeması

Üfürümler bir kardiyak döngü içerisinde erken, orta, geç gibi farklı şekillerde bulunabildiğinden Şekil 5.2 'de verildiği gibi sistol bölgesi kendi içinde üç eşit parçaya ve diyastol bölgesi yine üç eşit parçaya bölünmüştür. Elde edilen bu altı parça ve S1 ? S2 temel ses bölgesi üzerinden elde edilen iki adet ses parçası ile toplamda sekiz adet ses bölgesi üzerinden öznitelikler çıkarılmıştır. Her bir parça için öznitelik değerleri sınıflandırma için kullanılmak üzere kaydedilmiştir.

Ayırt edici öznitelikler zaman alanından, frekans alanından ve/veya istatistiksel alandan elde edilen parametreler olabilmektedir. Sınıflandırma için farklı alanlardan toplam 10 adet öznitelik bu çalışmada kullanılacaktır. PCG sinyali üzerinden hesaplanan aşağıdaki öznitelikler sınıflandırıcıların giriş öznitelik vektörü olarak kullanılmak üzere kaydedilecektir. N boyutlu ve $x[n]$ olarak tanımlanan bir kalp ses sinyalinin öznitelik vektörü çıkarımı aşağıda anlatılacaktır.



Şekil 5.2. Üfürüm Bulunma Bölgeleri [38]

5.1 İstatiksel Alan Özellikleri

Mutlak Ortalama Değer: $x[n]$ vektörünün mutlak değerlerinin elemanları toplamının vektör uzunluğuna bölünmesi ile Denklem 5.1 elde edilmektedir.

$$\frac{1}{N} \sum_{n=1}^N |x[n]| \quad (5.1)$$

Varyans: $x[n]$ vektöründe yer alan elemanların uzaydaki yayımlarının bir ölçümüdür. Varyans $x[n]$ vektöründeki her bir elemanın ortalamadan (μ) ne kadar uzakta olduğunu ölçmektedir. Denklem 5.2 'de $x[n]$ vektörünün varyansı ifade edilmektedir.

$$\sigma^2 = \frac{1}{N} \sum_{n=1}^N (x[n] - \mu)^2$$

$$\mu = E(x[n]) \quad (5.2)$$

Standart Sapma: $x[n]$ vektöründe yer alan elemanların ortalamadan ne kadar dağıldığını bir ölçüsüdür. $x[n]$ içerisinde yer alan elemanlar ortalamadan uzakta yüksek sapma

olduğu anlamına gelmektedir. Varyans'ın karekök değerine eşittir. Denklem 5.3 'de $x[n]$ vektörünün standart sapması ifade edilmektedir.

$$std(x) = \sqrt{\sigma^2} \quad (5.3)$$

Kurtosis: $x[n]$ vektörünün ortalama değer etrafında dağılımını tanımlamak için kullanılan istatistiksel bir ölçüttür. Denklem 5.4 'de $x[n]$ vektörünün kurtosis ölçüsü tanımlanmaktadır.

$$kurtosis(x) = \left[\left(\frac{x - \mu}{\sigma} \right)^4 \right] \quad (5.4)$$

5.2 Zaman Alanı Öznitelikleri

Etkin Değer (RMS): $x[n]$ vektöründeki tüm elemanlarının karelerinin aritmetik ortalaması ile elde edilmektedir. Denklem 5.5 'de $x[n]$ vektörünün etkin değeri ifade edilmektedir.

$$\sqrt{\frac{1}{N} \sum_{n=1}^N x[n]^2} \quad (5.5)$$

Maksimum Genlik: $x[n]$ vektörünün sahip olduğu maksimum değerdir.

Minimum Genlik: $x[n]$ vektörünün sahip olduğu minimum değerdir.

Enerji: $x[n]$ vektöründe yer alan elemanların karelerinin toplamı ile elde edilmektedir. Bir vektörün enerjisi Denklem 5.6 ile elde edilmektedir.

$$\sum_{n=1}^N x[n]^2 \quad (5.6)$$

Dinamik Aralık: $x[n]$ vektörünün sahip olduğu maksimum değer ile minimum değer arasındaki fark ile elde edilmektedir.

5.3 Frekans Alanı Öznitelikleri

Maksimum Frekans: $x[n]$ vektörünün frekans alanında maksimum aldığı değer in indisi olarak ölçülmektedir.

6. SINIFLANDIRMA

Kalp ses sinyali hastalık sınıflandırılması iş akışının son adımı olan sınıflandırma aşaması bu bölümde anlatılacaktır. İlk olarak kullanılacak olan sınıflandırıcılar için kısa kurumsal bilgiye yer verilecektir. PCG sinyallerinde yer alan anormalliklerin hangi hastalığa ait olduğunun belirlemek için gözetimli sınıflandırma yöntemleri üzerinde çalışılmıştır. Farklı karar topolojileri için hastalık sınıflandırma performansları yine bu bölümde sunulacaktır. Kalp ses sinyalinin sınıflandırma akış blok şeması Şekil 6.1 'de verilmiştir.



Şekil 6.1. Kalp Sesinin Sınıflandırılması İş Akışı Blok Şeması

6.1 Gözetimli Sınıflandırma Yöntemleri

Gözetimli öğrenme, etiketli eğitim verisi üzerinden bir işlevi öğrenme olarak tanımlanır. Gözetimli öğrenmede her eğitim verisi örneği bir giriş nesnesi (tipik olarak bir vektör) ve bir çıkış değeri içeren çiftten oluşur. Giriş nesnesinden çıkış değerine öyle bir haritalama fonksiyonu (f) tanımlanır ki yeni bir test giriş nesnesi (x) verildiğinde çıkış değeri (y) öngörülebilir.

$$y = f(x) \quad (6.1)$$

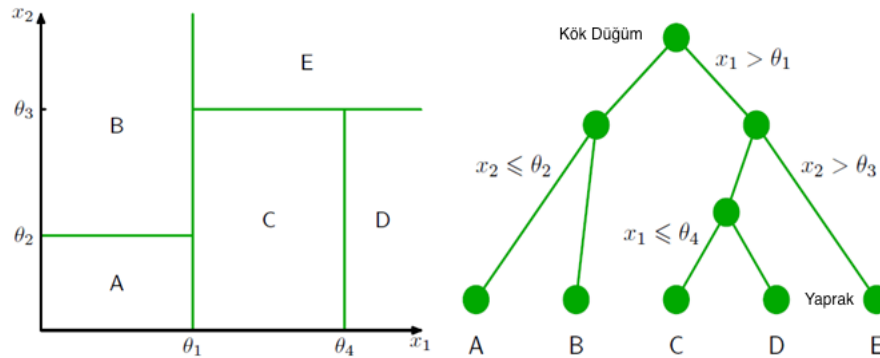
Eğitim veri seti üzerinde gözetimli öğrenme, algoritma öğrenme sürecini denetleyen bir öğretmen olarak düşünebilir. Eğitim verileri algoritmaya giriş nesnesi olarak verilip çıkış değerleri yinelemeli olarak tahmin edilir ve bir öğretmen tarafından düzeltilir. Öğrenme süreci kabul edilebilir düzeyde bir performans elde ettiğinde durdurulur. Bu çalışmada kalp ses sinyali sınıflandırılma performansları Karar Ağaçları, Destek Vektör Makinaları (DVM), K - En Yakın Komşu (KNN) ve Yapay Sinir Ağları (YSA) sınıflandırma yöntemlerinin her biri ile değerlendirilecektir.

6.1.1 Karar Ağaçları

Bir paterni bir dizi soru ile sınıflandırmak doğaldır ve sezgiseldir; bir sonraki sorunun sorulması şu andaki sorunun cevabına bağlıdır. Bu soru yaklaşımı metrik olmayan veriler için özellikle yararlıdır çünkü tüm sorular bir "evet / hayır" veya "doğru / yanlış" veya "değer kıyaslama" tarzında sorulabilir diğer bir deyişle herhangi bir metrik kavramı gerektirmez [39].

Bir soru dizisi bir karar ağacında basitçe görüntülenebilir. Burada kural, kök düğümün (root node) birinci veya en üstte görüntülenmesi ve diğer düğümlere ardışık bağlantılar veya dallar ile bağlanmasıdır [39].

Belirli bir modelin sınıflandırılması, modelin belirli bir özelliğinin değerini soran kök düğümden başlar. Kök düğümdeki farklı bağlantılar, olası farklı değerlere karşılık gelir. Yanıt temel alınarak uygun olan alt düğüme bağlantı kurulur. Bağlantılar birbirinden ayrı ve kapsamlı olmalıdır. Sonraki adım uygun olan bir sonraki düğüme karar vermektir. Daha fazla soru olmayan bir yaprak düğümüne varana kadar bu şekilde devam edilir. Her yaprak kategori etiketi taşır ve yaprağa ulaşan test örneğine yaprağın kategorisi atanır [39]. Şekil 6.2 'de örnek bir problem ve ilgili karar ağacı verilmektedir.




Şekil 6.2. Karar Ağacı Düzenleme

Şekil 6.2 'deki örnekte ilk adım, girdi alanının tamamını $x_1 < \theta_1$ veya $x_1 > \theta_1$ olup olmadığına göre iki bölgeye ayırılır. Bu ayırım, her biri bağımsız alt bölümlere ayrılabilir iki alt bölge oluşturur. Örneğin, $x_1 < \theta_1$ bölgesi, $x_2 < \theta_2$ veya $x_2 > \theta_2$ 'ye göre daha da alt bölümlere ayrılır ve A ve B olarak belirtilen bölgeleri oluşturur.

Yeni bir x test girişi için, kök düğümdeki ağacın başından başlayarak her düğümdeki karar kriterine göre belirli bir yaprak düğümüne kadar uygun bir yol izlenir ve x girişinin hangi bölgeye düştüğü belirlenerek sınıfa karar verilir. Herhangi bir karar ağacı, eğitim verilerini daha küçük ve daha küçük alt gruplara aşamalı olarak böler. Her bir alt kümedeki tüm verilerin aynı kategori etiketine sahip olması ideal olandır ki bu durumda her alt kümenin saf olduğu ve ağacın sonlandırılması gerektiği açıktır. Ancak genellikle her bir alt kümede saf olmayan bir etiket karışımı olabilmektedir. Bu aşamada ya bölünme durdurup kusurlu bir karar kabul edilir yada alt kümelere bölünmeyi sağlayacak başka özellikler bulunarak ağaç büyümeye devam eder.

Sınıflandırma ve Regresyon Ağaçları (CART), karar ağacı bölünme problemine genel bir çözüm sunar. CART metodolojisi 80'li yıllarda Breiman, Freidman, Olshen, Stone tarafından geliştirilmiştir (1984). CART algoritması, en iyi bölünmeyi bulmak için tüm muhtemel değişkenleri ve olası tüm değerleri arar ve maksimum homojenliğe sahip olan verileri iki parçaya böler (Şekil 6.3). CART hem sayısal hem de kategorik değişkenleri kolayca işleyebilir ve aykırı değerlere (outlier) karşı dayanıklıdır. CART'ın önemli bir pratik özelliği ise sınıflandırma ya da regresyon ağaçlarının yapısının bağımsız değişkenlerin monoton dönüşümlerine göre değişmez olmasıdır. Örneğin, herhangi bir değişken logaritma veya karekök değeri ile değiştirebilir, ancak ağacın yapısı değişmez [40].



Şekil 6.3. Karar Bölmesi

Kök düğümlerinin maksimum homojenliği safsızlık fonksiyonu (impurity function) $i(t)$ ile ifade edilir. Sağ ve sol düğümlerin maksimum homojenliği; safsızlık fonksiyonu değişti-

minin ($\Delta i(t)$) maksimize edilmesine eşit olacaktır. Sağ ve sol düğümlerin olasılıklarını sırasıyla P_l , P_r varsayılırsa safsızlık fonksiyonunun değişimi Denklem 6.2'de verilmektedir.

$$\Delta i(t) = i(t_p) - P_\ell i(t_\ell) - P_r i(t_r) \quad (6.2)$$

Her düğümde CART yöntemi Denklem 6.3'de tanımlanan maksimizasyon problemini çözer.

$$\arg \max_{x_j \leq x_j^f, j=1, \dots, M} [i(t_p) - P_\ell i(t_\ell) - P_r i(t_r)] \quad (6.3)$$

Teorik olarak birçok safsızlık fonksiyonu vardır ancak bunlardan sadece ikisi, Gini bölme kuralı ve iki bölme kuralı, pratikte kullanılmaktadır. Gini bölme kuralı (veya Gini dizini) en çok kullanılan kuraldır. Bu kuralın safsızlık fonksiyonunu Denklem 6.4'de verildiği gibi tanımlanır.

$$i(t) = \sum_{k \neq \ell} p(k | t) p(\ell | t) \quad (6.4)$$


Denklem 6.4'de sınıf indeksleri k ve ℓ olarak ifade edilirken, $p(k | t) - t$ düğümünde k sınıfının koşullu olasılığı ve $p(\ell | t) - t$ düğümünde ℓ sınıfının koşullu olasılığı olarak ifade edilmektedir. CART'ın maksimizasyon problemine, Gini safsızlık fonksiyonu uygulanırsa Denklem 6.5 elde edilmektedir.

$$\begin{aligned} i(t_p) &= 1 - \sum_{k=1}^K p^2(k | t_p) \\ i(t_\ell) &= 1 - \sum_{k=1}^K p^2(k | t_\ell) \\ i(t_r) &= 1 - \sum_{k=1}^K p^2(k | t_r) \\ 1 - \sum_{k=1}^K p^2(k | t_p) - P_\ell + P_\ell \sum_{k=1}^K p^2(k | t_\ell) - P_r + P_r \sum_{k=1}^K p^2(k | t_r) \\ \underbrace{1 - P_\ell - P_r}_0 - \sum_{k=1}^K p^2(k | t_p) + P_\ell \sum_{k=1}^K p^2(k | t_\ell) + P_r \sum_{k=1}^K p^2(k | t_r) \\ \Delta i(t) &= - \sum_{k=1}^K p^2(k | t_p) + P_\ell \sum_{k=1}^K p^2(k | t_\ell) + P_r \sum_{k=1}^K p^2(k | t_r) \end{aligned} \quad (6.5)$$

Gini algoritması Denklem 6.6'da verilen maksimizasyon problemini çözecektir.


$$\arg \max_{x_j \leq x_j^f, j=1, \dots, M} \left[- \sum_{k=1}^K p^2(k | t_p) + P_\ell \sum_{k=1}^K p^2(k | t_\ell) + P_r \sum_{k=1}^K p^2(k | t_r) \right] \quad (6.6)$$

Gini algoritması eğitim veri setinde en büyük homojen sınıfı arayacak ve bu verileri ayırt edecektir. Bu özelliği ile gürültülü veriler içerisinde dahi başarılı çalışabilmektedir. Şekil 6.4 'de iki boyutlu bir uzayda sınıflandırma problemi için kök sorusu aşağıdaki şekilde belirlenecektir. Birinci kök sorusu olarak seçilecek kural Gini kuralı ile belirlenecektir.




Şekil 6.4. İki Boyutlu Uzayda A ve B Sınıflarının Yerleşimi

Birinci kök sorusunun Var1>0.5 (yeşil çizgi) veya Var2>20 (mavi çizgi) olmasına Gini indeks değerine bakılarak karar verilecektir. Şekil 6.5 'de bu soruların ayırdığı bölümler veri uzayında gösterilmektedir.



Şekil 6.5. Kök Sorusu Belirleme

Var1>0.5 kök sorusu olarak seçilirse; Gini indeks değeri 0.0836 olarak hesaplanmaktadır.



$$i(t_\ell) = 1 - p^2(\text{Sinif} = A \mid \text{Var1} > 0.5) - p^2(\text{Sinif} = B \mid \text{Var1} > 0.5)$$

$$i(t_\ell) = 1 - \frac{3^2}{4^2} - \frac{1^2}{4^2} = 0.375$$

$$P_\ell = \frac{4}{10}$$

$$i(t_r) = 1 - p^2(\text{Sinif} = A \mid \text{Var1} < 0.5) - p^2(\text{Sinif} = B \mid \text{Var1} < 0.5)$$

$$i(t_r) = 1 - \frac{2^2}{6^2} - \frac{4^2}{6^2} = 0.444$$

$$P_r = \frac{6}{10}$$


$$i(t_p) = 1 - p^2(\text{Sinif} = A) - p^2(\text{Sinif} = B)$$

$$i(t_p) = 1 - \frac{5^2}{10^2} - \frac{5^2}{10^2} = 0.5$$

$$\Delta i(t) = i(t_p) - P_\ell i(t_\ell) - P_r i(t_r)$$

$$\Delta i(t) = 0.5 - 0.4 * 0.375 - 0.6 * 0.444 = 0.0836 \quad (6.7)$$

Var2>20 kök sorusu olarak seçilirse; Gini indeks değeri aşağıda olduğu gibi 0.125 olarak hesaplanmaktadır.



$$i(t_\ell) = 1 - p^2(\text{Sınıf} = A \mid \text{Var2} < 20) - p^2(\text{Sınıf} = B \mid \text{Var2} < 20)$$

$$i(t_\ell) = 1 - \frac{2^2}{2^2} - 0^2 = 0$$

$$P_\ell = \frac{2}{10}$$

$$i(t_r) = 1 - p^2(\text{Sınıf} = A \mid \text{Var2} > 20) - p^2(\text{Sınıf} = B \mid \text{Var2} > 20)$$

$$i(t_r) = 1 - \frac{3^2}{8^2} - \frac{5^2}{8^2} = 0.46875$$

$$P_r = \frac{8}{10}$$


$$i(t_p) = 1 - p^2(\text{Sınıf} = A) - p^2(\text{Sınıf} = B)$$

$$i(t_p) = 1 - \frac{5^2}{10^2} - \frac{5^2}{10^2} = 0.5$$

$$\Delta i(t) = i(t_p) - P_\ell i(t_\ell) - P_r i(t_r)$$

$$\Delta i(t) = 0.5 - 0.2 * 0 - 0.8 * 0.46875 = 0.125 \quad (6.8)$$

Gini indeks değeri yüksek olan Var2>20 kuralı kök düğümü olarak belirlenmelidir. Böylece CART algoritması maksimum homojenlikte problemi cevap bulmuş olacaktır. Karar ağacı Şekil 6.6 'deki sınıfları belirlemek için çalışmaya devam edecek ve son ayrılacak sınıf kalmayana kadar devam edecektir.




Şekil 6.6. İki Boyutlu Uzayda Geriye Kalan A ve B Sınıflarının Yerleşimi

Literatürde karar ağaçları ile elde edilen tahminlerin doğruluğunu arttırmak için 'Bagging' gibi yöntemler önerilmektedir [41]. Bagging, 1994 yılında Breiman tarafından ortaya atılan, istatistiksel sınıflandırma yöntemlerinin doğruluğunu arttıran makine öğrenmesi temelli bir grup algoritmasıdır. Temelde bu yöntem herhangi bir modelden daha doğru tahminler yapmak için çoklu makine öğrenme algoritmalarının tahminlerini bir araya getiren bir tekniktir. Veri setinin farklı kombinasyonları (rastgele seçim) ile alt eğitim setleri oluşturulur. Böylelikle elde edilen alt eğitim setlerinde bazı örnekler yer almazken, bazıları birden fazla yer alır. Eğitim setlerinin her biri için karar ağacı oluşturulur ve sonuçlar tahminlerin ortalaması ile elde edilir. Bu yöntem varyansı düşürdüğü için aşırı öğrenmenin engellenmesine yardımcı olur. Kararsız öğrenme algoritmalarında iyi çalışan bu yöntem eğitim kümesindeki küçük değişikliklerin tahminlerde büyük değişiklikler yaratmasına engel olmaktadır. Elimizde 1000 örnekten oluşan bir veri grubu olduğunu ve CART algoritmasını kullanarak sınıflandırma yaptığımızı varsayalım. Algoritma şu şekilde çalışmaktadır:

- Veri seti içerisindeki veriler yer değiştirilerek çok sayıda (ör. 100) rastgele alt örnekler oluşturulur.
- Her bir örnek grubu için bir sınıflandırma modeli (kara ağacı) eğitilir.
- Yeni bir veri kümesi (test kümesi) için her bir modelin tahmini üzerinden ortalama sonuç hesaplanır.

Öğrenme ve karar modeli örnek bir veri seti eşliğinde Şekil 6.7 'de verilmektedir.




Şekil 6.7. Bagging Öğrenme ve Karar Modeli

6.1.2 Destek Vektör Makinaları

Destek Vektör Makinesi, sınıflandırma problemi için kullanılabilen denetimli bir makine öğrenme algoritmasıdır. Giriş verilerinin her biri kendi özellik değerlerine uygun olarak n

(sahip olunan özellik sayısı) boyutlu bir uzaya yerleştirilir. Ardından, iki sınıfı oldukça iyi ayıran bir düzlem yardımı ile sınıflandırma işlemi tamamlanır. Bu ayırıcı düzlem karar düzlemi olarak anılır. Karar düzlemi, farklı sınıf üyelerine sahip nesnelere birbirinden ayıran bir ayırıcıdır. Sınıfları birbirinden ayıran birçok olası lineer düzlem vardır. Ancak marjini, her sınıfın en yakın veri noktası arasındaki mesafe, maksimize eden tek bir ayırıcı düzlem vardır. Genel amaç, sınıf üyelerinin birbirlerine en uzak yerden ayıran karar düzlemi belirleyebilmektir. Eğitim verileri kullanılarak belirlenen karar düzlemleri bulunduğundan sonra giriş verisi olarak verilecek olan test verileri düzlemin hangi yarısında kaldığına uygun olarak veri sınıfına karar verilir.



Şekil 6.8. SVM Karar Düzlemi

Eğitim verilerinin doğrusal olarak ayrılabilmesi durumunda Doğrusal Destek Vektör Makinaları kullanılırken doğrusal olarak ayrılmayan durumlarda Doğrusal Olmayan Destek Vektör Makinaları kullanılmaktadır.

6.1.2.1 Doğrusal Destek Vektör Makinaları

Her bir eğitim örneği n adet özniteliğe sahip $x_i \in R^n$ vektörü ve örneklerin ait olduğu $z_i \in \{1, -1\}$ sınıfı ifade eden (x_i, z_i) ikilisinden oluşmaktadır. Pozitif ve negatif sınıf örneklerini birbirinden ayıran bir düzleme sahip olduğumuzu varsayalım. Ayırıcı düzlem üzerinde yer alan x noktaları Denklem 6.9'daki eşitliği sağlamaktadır.

$$g(x) = \omega^T \cdot x_i + \omega_0 = 0 \quad (6.9)$$

Burada ω ayırıcı düzlemin normalini ifade ederken, ω_0 düzlem sabit olarak tanımlanmaktadır. Ayırıcı düzleme en yakın ve her iki sınıfa ait olan eğitim örnekleri "destek vektörleri" olarak tanımlanmaktadır. Bu destek vektörleri sınır düzlemlerini belirlemektedir ve ayırıcı düzleme eşit uzaklıkta paralel düzlemlerdir. Sınır düzlemleri arasındaki uzaklık "marjin" olarak tanımlanmaktadır. Doğrusal Destek Vektör Makinaları en büyük marjinli ayırıcı düzlemi bulmayı amaçlamaktadır. Tüm eğitim verilerinin Denklem 6.10'daki sınırlamaları sağladığını varsayalım:

$$\begin{aligned} \omega^T \cdot x_i + \omega_0 &\geq 1 & x_i \in \text{Sınıf 1} & z_i = +1 \\ \omega^T \cdot x_i + \omega_0 &\leq -1 & x_i \in \text{Sınıf 2} & z_i = -1 \end{aligned} \quad (6.10)$$

Denklem 6.10'daki eşitsizlikler Denklem 6.11'deki gibi tek bir eşitsizlikle birleştirilebilir.

$$z_i * (\omega^T \cdot x_i + \omega_0) \geq 1 \quad \forall i \quad (6.11)$$

Herhangi bir eğitim örneği x ile sınır düzlemi arasındaki uzaklık Denklem 6.12 ile hesaplanır.

$$d = \frac{|\omega^T \cdot x + \omega_0|}{\|\omega\|} \quad (6.12)$$

Sınır düzlemine en yakın x_i örneği $|\omega^T \cdot x + \omega_0| = 1$ eşitliğini sağlarken x_i örneği ile ayırıcı düzlem arasındaki mesafe $1/\|\omega\|$ olmaktadır. O halde sınır düzlemleri arasındaki uzaklık "marjin" $2/\|\omega\|$ olarak hesaplanacaktır. Marjini maksimum veren ayırıcı düzlem için minimum $\frac{1}{2}\|\omega\|^2$ değeri Denklem 6.11 koşulu altında sağlanmalıdır. Optimal ayırıcı düzlem probleminin çözümü için Lagrange metodundan yararlanılmaktadır. Lagrange metodu, bir fonksiyonun maksimum veya minimum değerini bulabilmek için problemi

dual probleme dönüştürerek analitik olarak çözülmesine imkan tanımaktadır. İlkel bir optimizasyon problemi Denklem 6.13'deki gibi tanımlanır [42] ise

$$\begin{aligned} \min_{\omega} \quad & f(\omega) \\ \text{koşulu altında} \quad & g_i(\omega) \leq 0 \quad , i = 1, \dots, k \\ & h_i(\omega) = 0 \quad , i = 1, \dots, l \end{aligned} \quad (6.13)$$

Bu ilkel optimizasyon probleminin Lagrange fonksiyonu Denklem 6.14'deki gibi ifade edilir.

$$L(\omega, \alpha, \beta) = f(\omega) + \sum_{i=1}^k \alpha_i g_i(\omega) + \sum_{i=1}^l \beta_i h_i(\omega) \quad (6.14)$$

Maksimum marjlinli ayırıcı düzlem belirleme problemi Lagrange metodu ile Denklem 6.15'de verildiği gibi ifade edilebilir.

$$\begin{aligned} \min \quad & \frac{1}{2} \|\omega\|^2 \\ \text{k.a.} \quad & z_i(\omega^T \cdot x_i + \omega_0) \geq 1 \quad \forall i \\ L(\omega, \omega_0, \alpha) = \quad & \frac{1}{2} \|\omega\|^2 - \sum_i^n \alpha_i \cdot [z_i(\omega^T \cdot x_i + \omega_0) - 1] \end{aligned} \quad (6.15)$$

Tanımlanan $L(\omega)$ fonksiyonu ω ve ω_0 'ya göre minimize edilir. Fonksiyonda yer alan tüm α_i değeri $\alpha_i \geq 0$ koşulunu sağlamaktadır. Bu konveks kuadratik optimizasyon problemi çözümü optimal ayırıcı düzlemini belirleyecektir. Denklem 6.16'da olduğu gibi ilk olarak Lagrange fonksiyonu ω ve ω_0 'a göre kısmi türevleri alınarak sıfıra eşitlenir.

$$\begin{aligned} \frac{\partial L_p(\omega, \beta, \alpha)}{\partial \omega} = 0 \quad & \Rightarrow \quad \omega - \sum_i^n z_i \alpha_i x_i = 0 \quad \Rightarrow \quad \omega = \sum_i^n z_i \alpha_i x_i \\ \frac{\partial L_p(\omega, \beta, \alpha)}{\partial \omega_0} = 0 \quad & \Rightarrow \quad \sum_i^n z_i \alpha_i = 0 \end{aligned} \quad (6.16)$$

Eşitlikler Lagrange fonksiyonu Denklem 6.15 içerisine yazılırsa Denklem 6.17 da verilen optimizasyon problemi elde edilir [43]:

$$L(\omega, \omega_0, \alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n z_i z_j \alpha_i \alpha_j (x_i)^T x_j \quad (6.17)$$


Maksimum marjınlı düzlem Denklem 6.18 'deki gibi ifade edilirken ayırıcı düzlemi giriş öznitelik vektörünün iç çarpımları şeklinde yazılabildiği görülmektedir.

$$g(x) = \sum_i^n (\alpha_i \cdot z_i \cdot x_i)^T \cdot x_i + \omega_0 \quad (6.18)$$

$$\text{k.a. } \sum_i^n \alpha_i z_i = 0 \quad \text{ve} \quad \forall \alpha_i$$

6.1.2.2 Doğrusal Olmayan Destek Vektör Makineleri

Eğitim verisinin doğrusal bir ayırıcı düzlem ile ayrılamadığı durumlara (Şekil 6.9) çözüm olarak tanımlanan doğrusal olmayan destek vektör makineleri temelde giriş verilerini daha yüksek boyutlu bir uzaya haritalayarak doğrusal ayırımın gerçekleşmesini sağlamaktadır [43].



Şekil 6.9. Doğrusal Olmayan Örnek Uzayı

Giriş verilerini ϕ olarak tanımladığımız bir haritalama fonksiyonu ve H ile tanımladığımız bir öklid uzayına taşıdığımızı varsayalım. Tanımlanan bu H uzayında ayırıcı düzlem bulma problemi devam etmektedir. Doğrusal ayırıcı düzlemin normalini ω Denklem 6.18'de olduğu gibi giriş vektörlerinin iç çarpımı olarak tanımlandığından H özellik uza-

yında bu iç çarpımlar Denklem 6.19'da verildiği gibi ifade edilir [43].

$$K(x, x_i) = \phi(x) \cdot \phi(x_i) \quad (6.19)$$

Denklemden x_i destek vektörlerini ifade ederken K kernel fonksiyonu olarak ifade edilmektedir. Kernel fonksiyonu, özellik uzayında verilerin koordinatlarının tek tek hesaplanmasına gerek kalmadan direkt olarak ihtiyacımız olan verilerin iç çarpımlarını hesaplayarak yüksek boyutlu uzayda rahatça çalışılmasına olanak tanır. Bu iç çarpım Denklem 6.18 içerisinde yazılırsa ayırıcı düzlem fonksiyonu Denklem 6.20'deki gibi ifade edilir.

$$g(x) = \sum_{i=1}^n \alpha_i z_i \Phi(x) \Phi(x_i) + \omega_0 = \sum_{i=1}^n \alpha_i z_i K(x, x_i) + \omega_0 \quad (6.20)$$

En yaygın kullanılan Kernel fonksiyonları; polinom fonksiyonu, sigmoid fonksiyonu ve radyal temel fonksiyonudur.

- Polinom Kernel Fonksiyonu: (Quadratic $p=2$, Kubik $p=3$)

$$K(x, x_i) = (\langle x, x_i \rangle + 1)^p \quad (6.21)$$

- Sigmoid Kernel Fonksiyonu:

$$K(x, x_i) = \tanh(\langle x, x_i \rangle + 1) \quad (6.22)$$

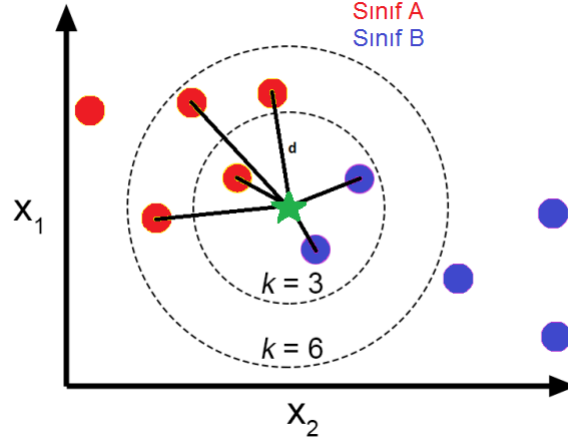
- Radyal Temel Kernel Fonksiyonu:

$$K(x, x_i) = \exp\left(-\frac{|x - x_i|^2}{2\sigma^2}\right) \quad (6.23)$$

6.1.3 K- En Yakın Komşu Algoritması

En basit örnek tabanlı gözetimli öğrenme algoritması olarak bilinen K- En Yakın Komşu algoritması, sınıflandırılmamış bir örneğin, önceden sınıflandırılmış örneklere uzaklığına bakarak karar verme kuralına dayanır. Tüm giriş eğitim örnekleri n boyutlu uzayda karşılık geldikleri noktalara yerleştirilir ve rastgele seçilen bir test örneği x_a bu n boyutlu uzaya yerleştirilerek en yakın k tane örneğe benzerliğine göre sınıf ataması yapılır. Şekil 6.10 iki boyutlu bir örnek uzayında x_a örneğinin atama örneği gösterilmektedir.

Örnek benzerliği x_a test verisinin belirlenen k tane komşu eğitim örneğine olana uzaklığı ile belirlenir. x_a test versinin sınıf etiketi, k en yakın komşusunun sınıf etiketinin çoğunluk oylamasına göre atanır [44].



Şekil 6.10. K - En Yakın Komşu

Uzaklık metrikleri, yeni bir veri noktası ile mevcut eğitim örneği arasındaki mesafeyi bulmak için yaygın olarak kullanılır. Genel olarak Denklem 6.24'deki gibi formülize edilebilir [45].

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (a_r(x_i) - a_r(x_j))^2} \quad (6.24)$$

Herhangi bir x örneğinin r . öznelik değeri olarak $a_r(x)$ ifadesi kullanılırken x_i ile x_j örneği arasındaki mesafe $d(x_i, x_j)$ olarak tanımlanmaktadır. Yaygın olarak kullanılan bazı uzaklık metrikleri:

- Minkowski Uzaklığı
- Manhattan Uzaklığı
- Öklid Uzaklığı
- Chebyshev Uzaklığı
- Mahalanobis Uzaklığı

Minkowski Uzaklığı: Normalleştirilmiş bir vektör uzayındaki mesafeyi bulmak için kullanılan bu teknik hem Öklid uzaklığının hem de Manhattan uzaklığının genelleşmiş halidir. $X = (x_1, x_2, \dots, x_n)$ ve $Y = (y_1, y_2, \dots, y_n)$ olmak üzere X ve Y noktası arasındaki uzaklık Denklem 6.25'deki gibi hesaplanır [46].

$$\left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \quad (6.25)$$

Manhattan Uzaklığı: İki nokta arasındaki uzaklık, noktaların kartezyen koordinatlarının mutlak farklarının toplamı olarak hesaplanır. Minkowski uzaklığının $p=1$ özel durumudur [46]. X ve Y noktası arasındaki mesafe Denklem 6.26'deki gibi hesaplanır.

$$\left(\sum_{i=1}^n |x_i - y_i| \right) \quad (6.26)$$

Öklid Uzaklığı: İki nokta arasındaki uzaklık, noktaların kartezyen koordinatlarının farklarının kareleri toplamının karekökü olarak hesaplanır. Doğrusal uzaklık olarak bilinen Öklid uzaklığı Minkowski uzaklığının $p=2$ özel durumudur [46]. X ve Y noktası arasındaki mesafe Denklem 6.27'deki gibi hesaplanır.

$$\left(\sqrt{\sum_{i=1}^n (x_i - y_i)^2} \right) \quad (6.27)$$

Chebyshev Uzaklığı: Noktaların kartezyen kordinatlarının mutlak farklarının maksimumu olarak hesaplanır. Minkowski uzaklığının $p=\infty$ özel durumudur [46]. X ve Y noktası arasındaki mesafe Denklem 6.28'deki gibi hesaplanır.

$$\max_{i=1}^n |x_i - y_i| \quad (6.28)$$

Mahalanobis Uzaklığı: İki nokta arasındaki mesafeyi ölçerken tüm noktalardan hesaplanan kovaryans matrisini de hesaba katar. Geometrik olarak noktalar standartlaştırılarak yani birbirlerinden ilişkisiz hale getirilerek yine öklid uzaklığı ölçümü yapmaktadır [46]. X ve Y noktası arasındaki mesafe Denklem 6.29'deki gibi hesaplanır.

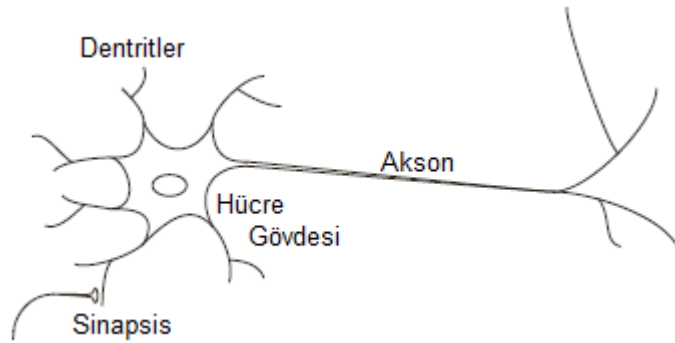
$$\sqrt{(X - Y)'C^{-1}(X - Y)} \quad (6.29)$$

K - En Yakın Komşu algoritma performansı uzaklık fonksiyonuna ve k komşu sayısına bağlıdır. Öklid metriği uzaklık fonksiyonu için en popüler seçenektir. Ancak noktaların

koordinat eksenlerindeki dağılımları karşılaştırabilir değilse Öklid uzaklığını kullanmadan önce dağılım matrisinin standartlaştırılan Mahalanobis metriğide yaygın olarak kullanılır. Komşuluk hacmini kontrol eden k parametresi sınıflandırma performansı üzerinde önemli bir rol oynamaktadır [47]. Optimum k değeri veri kümesine göre daima değişiklik göstermektedir. Gürültünün sınıflandırma üzerine etkisini azaltmak için k değeri genellikle büyük seçilirken sınıflar arasındaki belirginlik daha az hale gelmektedir. Şekil 6.10 'da yer alan dağılımda bilinmeyen bir x örneği k=3 ve k=6 seçimi ile farklı sınıf etiketi alabilmektedir. Bilinmeyen bir veriyi en yakın komşusunun ait olduğu sınıf etiketi ile sınıflandırmak için k=1 alınırken, k değeri tüm örnekleri kapsayacak şekilde büyük seçilirse sınıflama çoğunluk sınıfına göre gerçekleşecektir.

6.1.4 Yapay Sinir Ağları

Beyin, nöronlar olarak adlandırılan çok sayıda elemandan (yaklaşık 10^{11}) ve her bir eleman arasındaki bağlantıdan (yaklaşık 10^4) oluşmaktadır [48]. Nöronların temel üç bileşeni vardır; dendritler, hücre gövdesi ve akson. Dendritler, hücre gövdesine elektrik sinyalleri taşıyan ağaç benzeri sinir liflerinin alıcı ağlarıdır. Hücre gövdesi, gelen sinyalleri etkili bir şekilde toplar ve toplam genliği sınırlandırır. Akson, hücre gövdesindeki sinyali diğer nöronlara taşıyan tek uzun bir lifdir. Bir hücrenin aksonu ile başka bir hücrenin dendriti arasındaki temas noktasına sinapsis denir. Şekil 6.11 'da bir sinir hücre (nöron) yapısı verilmektedir [48].




Şekil 6.11. Sinir Hücresi(Nöron) ve Yapısı

Yapay sinir ağları beynin karmaşıklığına yaklaşmazlar ancak bununla birlikte, biyolojik ve yapay sinir ağları arasında iki temel benzerlik vardır. Birincisi hesaplama elemanla-

rından oluşmaları, ikincisi nöronlar arasındaki bağlantıların ağırlık işleyişini belirlemesidir. Biyolojik nöronlar (10^{-3} sn) elektrik devreleriyle (10^{-10} sn) karşılaştırıldığında çok yavaş olsalar da beyin herhangi bir bilgisayardan çok daha hızlı bir şekilde birçok görevi yerine getirebilmektedir [48]. Bu biyolojik sinir ağlarında tüm nöronların aynı anda paralel olarak çalışabilme yeteneğinden kaynaklanır. Yapay sinir ağlarında ise paralel yapılar VLSI, optik cihazlar ve paralel işlemciler kullanarak ideal bir şekilde uygulanmaya çalışılır.

6.1.4.1 Tek Girişli Nöron

Şekil 6.12 'de tek girişli bir nöron yapısı gösterilmektedir [48]. Burada p girişi w ağırlığı ile çarpılarak b sabit terimi ile toplanır. Bu toplayıcı çıktısı bir transfer/aktivasyon fonksiyonuna gönderilir. Fonksiyon çıktısı a nöron çıktısı olmaktadır. Bu basit modeli biyolojik nörona uygun olarak tanımlarsak, w ağırlığı sinapsislerin kuvvetine karşılık gelirken, hücre gövdesi toplam ve f transfer fonksiyonu olarak tanımlamak mümkündür. Nöron çıkışı a ise akson üzerindeki sinyali temsil eder.



Şekil 6.12. Tek Girişli Nöron


Nöron çıktısı doğrudan aktivasyon fonksiyonuna bağlıdır. w ve b her nöronun ayarlanabilir sayısal parametreleridir. Öğrenme kurallına bağlı olarak ayarlanır ve nöronun giriş-çıkış ilişkisini tanımlar.

6.1.4.2 Transfer/Aktivasyon Fonksiyonu

Biyolojik bir nöron modeline göre; nöron bir dereceye kadar her zaman aktiftir [49]. Nöronların giriş değerlerinin tepkileri aktivasyon fonksiyonuna bağlıdır. Aktivasyon fonksiyonu doğrusal veya doğrusal olmayan bir fonksiyon olabilir. Yaygın olarak kullanılan


aktivasyon fonksiyonları bu bölümde anlatılacaktır [49].

Hard Limit Fonksiyonu; girdileri kesin olarak iki ayrı kategoriye ayıran nöronlar elde etmek için kullanılan bir aktivasyon fonksiyonudur. Fonksiyonun argümanı sıfırdan küçükse nöronun çıktısı 0'a, sıfırdan büyük ise nöronun çıktısı 1'e eşit olacaktır. Şekil 6.13 'de $a = \text{hardlim}(n)$ transfer fonksiyonu gösterilmektedir [48].




Şekil 6.13. Hard Limit Transfer Fonksiyonu

Doğrusal Transfer Fonksiyonu; çıkış değeri giriş argümanına eşit olan bir aktivasyon fonksiyonudur. Bu aktivasyon fonksiyonuna sahip nöronlar "Adaline" ağlarında kullanılmaktadır. Şekil 6.14 'de $a = \text{purelin}(n)$ transfer fonksiyonu gösterilmektedir [48].



Şekil 6.14. Doğrusal Transfer Fonksiyonu

Sigmoid Fonksiyonu; artı ve eksi sonsuz arasında herhangi bir giriş argümanını 0 ile 1 arasında bir çıktıya eşleyen aktivasyon fonksiyonudur. Şekil 6.15 'de $a = \text{logsig}(n)$ transfer fonksiyonu gösterilmektedir [48].



Şekil 6.15. Sigmoid Transfer Fonksiyonu


Yaygın olan kullanılan transfer fonksiyonları; girdi-çıkıtlı ilintileri, sembolleri ve Matlab fonksiyonları Çizelge 6.1 'de tablo olarak verilmektedir [48].

Transfer Fonksiyonu	Girdi-Çıktı İlintisi	Sembol	MATLAB
Hard Limit	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$		hardlim
Simetrik Hard Limit	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$		hardlims
Doğrusal	$a = n$		purelin
Satüre Doğrusal	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$		satlin
Simetrik Satüre Doğrusal	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = 1 \quad n > 1$		satlins
Sigmoid	$a = \frac{1}{1 + e^{-n}}$		logsig
Hiperbolik Tanjant	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		tansig
Positif Doğrusal	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$		poslin

Çizelge 6.1. Transfer Fonksiyon Listesi ve Gösterimi

6.1.4.3 Çoklu Giriş Nöronu

Tipik olarak bir nöronun birden fazla girişi bulunabilir. R girişli bir nöron Şekil 6.16 'de verilmiştir [48]. p_1, p_2, \dots, p_R girişlerinin herbiri W ağırlık matrisinin $\omega_{1,1}, \omega_{1,2}, \dots, \omega_{1,R}$ ilgili elemanları tarafından ayrı ayrı ağırlıklandırılır. Burada $\omega_{1,2}$ ile birinci nöron ile ikinci kaynak arasındaki ağırlık temsil edilmektedir.



Şekil 6.16. Çoklu Giriş Nöronu

Ağ girişini oluşturmak için ağırlıklandırılmış girdiler Denklem 6.30'de verildiği gibi bir sabit terim ile toplanır.


$$n = \omega_{1,1}p_1 + \omega_{1,2}p_2 + \dots + \omega_{1,R}p_R + b \quad (6.30)$$

6.1.4.4 Ağ Yapısı

Genel olarak, birden fazla giriş için tek bir nöron yetersiz kalmaktadır. Katman olarak adlandırdığımız paralel yapılara ihtiyaç vardır.

6.1.4.4.1 Tek Katmanlı Ağ Yapısı

Tek katmanlı ağ yapısında p_1, p_2, \dots, p_R girişlerinin herbiri W ağırlık matrisinin $\omega_{1,1}, \omega_{1,2}, \dots, \omega_{S,1}, \dots, \omega_{S,R}$ ilgili elemanları aracılığıyla her bir nörona bağlanır. Katman; W ağırlık matrisi, toplayıcılar, b sabit vektörü, f transfer fonksiyonları ve a çıkış vektöründen oluşmaktadır. Herbir nöronun kendisine ait yine bir sabit parametresi, toplayıcısı ve transfer fonksiyonu ile bir çıktı değeri a vardır. Bu çıktı değerlerinin her biri a vektörünü oluşturmaktadır. Şekil 6.17 'da tek katmanlı bir ağ yapısı gösterilmektedir [48].




Şekil 6.17. Tek Katmanlı Ağ Yapısı

6.1.4.4.2 Çok Katmanlı Ağ Yapısı

Çok katmanlı ağ yapısında her katman kendi W ağırlık matrisi, b sabit vektörü, transfer fonksiyonu n giriş vektörü ve a çıkış vektörüne sahiptir. Birinci katmanı sigmoid transfer fonksiyonuna sahip, ikinci katmanı doğrusal transfer fonksiyonuna sahip iki katmanlı bir ağ yapısı bir çok girdi uzayını eğitebilme yeteneğine sahiptir. Tek katmanlı bir yapı ile karmaşık bir girdi uzayı çoğu zaman eğitilemez. Çok katmanlı ağlar tek katmanlı ağlardan oldukça güçlüdür. Şekil 6.18 'de çok katmanlı bir ağ modeli verilmektedir [48].

Ağın eğitilmesinde yapılacak seçimlerin önemi büyüktür. Öncelikle ağ girişinin sayısı yani R girdi uzayının öznitelik adedi kadar olmalıdır. Benzer şekilde ağ çıkışı sınıf sayısı kadar nöron içermelidir. Son olarak ağ çıkış değeri 0 ya da 1 olması isteniyorsa çıkış katmanında yer alan transfer fonksiyonu hard limit transfer fonksiyonu benzeri bir transfer fonksiyonu seçilmesine dikkat edilmelidir. Tek katmanlı bir ağın mimarisi, belirli sayıda giriş, çıkış nöronları ve belirli transfer fonksiyonu da dahil olmak üzere problem özelliğine göre belirlenebilir.



Şekil 6.18. Çok Katmanlı Ağ Yapısı

Çok katmanlı bir ağ mimarisinde gizli katmanlarda gereken nöron sayısı tek katmanlı yapıların aksine doğrudan söylenemez. Katman sayısı olarak birçok pratik yapay sinir ağı mimarisinde iki yada üç gizli katman yer almaktadır. Giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmanlı bir ağ yapısı en karmaşık problemlerde dahi çözüm olmaktadır. Nadiren dört veya daha fazla katman kullanılmaktadır [48].

6.1.4.5 Geri Yayımlı Öğrenme Algoritması

Gözetimli sınıflandırma yöntemlerinde ağa her giriş için istenen bir çıktı verilir. Öğrenme sırasında ağ tarafından üretilen çıktı (y), beklenen çıktıya (d) eşit olmayabilir. Hata düzeltme, öğrenme kuralının temel ilkesi, hatayı kademeli olarak azaltmaktır. Hata sinyali ($d-y$) kullanılarak bağlantı (w) ağırlıkları güncellenir böylelikle hata ağa yayılarak en aza indirgenir. Tüm girdi uzayını beklenen çıkış uzayına eşleyen optimum bir fonksiyon bulunmuş olacaktır. Örneğin, kontrol sistemlerinde ölçülen çıktılardan kontrol girişlerine eşlenen uygun bir geribildirim fonksiyonu bulmak benzer bir amaç olarak değerlendirilebilir. Bir ağın hata fonksiyonu Denklem 6.31'de tanımlanmaktadır.

$$e_j(n) = d_j(n) - y_j(n) \quad (6.31)$$

Bir giriş katmanı, iki gizli katman ve bir çıktı katmanına sahip Şekil 6.18 'daki mimaride ağ üzerinde akış soldan sağa doğru ilerlediği görülmektedir. Ağın giriş ucundan ağ

üzerinden öne doğru her bir nöron üzerinden yayılım yapan ve ağın çıkış ucundan elde edilen sinyal "fonksiyon sinyali" olarak tanımlanmaktadır. Ağın çıkış nöronu ile beklenen çıktı arasındaki hata ağ üzerinden geriye doğru "hata sinyali" olarak iletilir. Algoritmanın ilk adımı ileri besleme de herhangi bir öğrenme gerçekleşmeyip ağ hatalı bir çıktı olan fonksiyon sinyalini üretir. İleri besleme sonucunda elde edilen çıktı ile beklenen çıktı karşılaştırılarak ağın hatası hesaplanır. Algoritmanın ikinci adımı olan geri yayılım bu hatayı ağırlık vektörlerinin güncellemek için Denklem 6.32'de verildiği gibi "delta kuralı" ile ağa tekrar yayar.

$$\begin{aligned}\omega_{ji}(n+1) &= \omega_{ji}(n) + \Delta\omega_{ji}(n) \\ \Delta\omega_{ji}(n) &= -\eta \cdot \frac{dE(n)}{d\omega_{ji}(n)} \\ E(n) &= \frac{1}{2} \sum e_j^2\end{aligned}\quad (6.32)$$

Geri yayılımda öğrenme işlemi başlamış olur. Bu adımlar defalarca tekrarlanarak hata sinyali belirlenen seviyeye düşene kadar devam eder. Ağdaki ağırlık değişimleri $\Delta\omega_{ji}$ 'in ağda yer alan her ağırlık için ve eğitim setindeki her eğitim örneği için art arda uygulanması gerekir. Bütün ağırlıkların tüm eğitim seti için güncellenmesine bir eğitim devri (epoch) olarak tanımlanır [50]. Tüm eğitim setinin ağa tek seferde verilerek ağırlık değişimlerini yapılmasına "toplu öğrenme", her bir eğitim verisini ağa tek tek vererek tüm ağırlıkların güncellenmesine ise "sıralı öğrenme" tanımı yapılmaktadır. Geri yayılım öğrenme algoritmasının temeli; bir giriş çıkış haritalamasını, çok katmanlı bir ağın sinaptik ağırlıklarına ve sabit terimlerine kodlamaktır. Ağın genelleme yaparak öğrenme işlemini gerçekleştirmesi asıl amaçtır. Ağın bu genellemeyi sağlaması için çapraz geçerlilik olarak bilinen bir istatistiksel standart kullanılmaktadır [50]. Veri seti rastgele seçim ile eğitim ve test verisi olmak üzere ikiye bölünür. Eğitim verisi de birbirinden ayrık iki alt küme halinde bölünür.

- Eğitim Veri Seti
 - Tahmin alt kümesi; ağ modelini seçmek ve eğitmek için kullanılır.
 - Doğrulama alt kümesi; ağı doğrulamak için kullanılır.
- Test Veri Seti

Eđitim veri setinin blnmesindeki asıl ama ađın ađırlıklarını ve sabit terimlerini belirlemek iin kullanan tahmin veri setinden bađımsız bir set zerinde dođrulama yapmaktır. Bylelikle ađın eđitim verisini ezberleyerek ađırı đrenme olasılıđı en aza indirgenmiř olur. Ađın genelleme performansı dođrulama alt kmesinden farklı olan test kmesi zerinden yapılır. Ađın đrenme srecinde ileriye ve geriye dođru ařamalarını ieren geri yayılımlı đrenme algoritma adımları:

1. İklendirme: Herhangi bir n bilginin mevcut olmadığı varsayılarak, sinaptik ađırlıklar ve sabit terimler dzgn dađıtılmıř rastgele sayı setinden seilir.
2. Eđitim Setinin Belirlenmesi: Veri setinde yer alan verilerden rastgele bir seim ile eđitim seti belirlenir. Eđitim setinde yer alan her bir rnek iin adım 3 ve 4'de anlatılan ileri ve geri yayılım hesaplamaları gerekleřtirilir.
3. İleri Yayılım: Eđitim veri setinde yer alan rneklerin her biri mevcut sinaptik ađırlıkların ve sabit terimlerin yardımıyla her katman iin fonksiyon sinyali hesaplanarak ilerlenir. Sunulan eđitim veri seti iin ađın ıktı deđerleri bu yolla hesaplanır.
4. Geri Yayılım: Adım 3 de elde edilen ıktı deđerleri ile beklenen sonu deđerleri karřılařtırılarak ađın hata deđerleri hesaplanır. Bu hata deđerleri sinaptik ađırlıkların gncellenmesi iin hata sinyali halinde geriye dođru beslenir.
5. Sinaptik Ađırlıkların Gncellenmesi: Delta kuralına gre sinaptik ađlar gncellenir.
6. Yineleme (iterasyon): Adım 3'den adım 5' e kadar olan ileri geri hesaplamalar belirlenen durma kriterine kadar tekrarlanır. Durma kriteri kimi zaman hata eřik deđerleri kimi zaman yineleme sayısı olarak belirlenebilmektedir.

6.2 Kalp Ses Sinyallerinin Sınıflandırılması

Hastane ortamında toplanan PCG sinyalleri zerinden MFCC yntemi ile S1 ve S2 seslerinin yerleri belirlenerek, eřik deđerleri yardımı ile S1, sistol, S2, diyastol blgelerine karar verilmiřtir. Hastalık/frm bilgisi, sistol ve diyastol blgesinde eřitli Őekillerde yer aldıđından bu blgelerin znelik vektrleri hesaplanmıřtır. Sınıflanma iin 10 adet

öznitelik kullanılmıştır. Üfürümler bu bölgeler içerisinde erken, orta, geç gibi farklı şekillerde bulunabildiğinden sistol bölgesi kendi içinde üç eşit parçaya bölünerek ve bu parçalar üzerinden öznitelikler çıkarılmaktadır. Benzer şekilde diyastol bölgesi de üç eşit parçaya bölünerek her bir bölge için ayrı ayrı öznitelik vektörleri elde edilecektir. Bir kardiyak periodun öznitelik vektörü S1, sistol, S2, diyastol olmak üzere 8 ayrı parçadan üretilen 80x1 boyutlu bir vektör ile ifade edilecektir.

6.2.1 Veri Seti

Bir kalp ses sinyali içerisinde yer alan tüm kardiyak döngüler yani S1 ve S2 sesleri doğru tahmin edildiği takdirde bu kalp ses sinyali içerisinde yer alan tüm S1, sistol, S2, diyastol bölgeleri ardışıl olarak belirlenebilirken, herhangi bir periyotta S1 sesinin belirlenememesi kendisinden önceki diyastol bölgesinin nerede sonlandığının belirlenememesine benzer şekilde S2 sesinin belirlenememesi kendisinden önceki sistol bölgesinin nerede sonlandığının belirlenememesine sebep olmaktadır. Dolayısıyla S1 ve S2 bölütleme işleminde kesin olarak belirlenemeyen bir kardiyak periyot kendisinden önceki kardiyak periyodunda tam olarak belirlenememesine sebep olmaktadır. Bir PCG kaydı içerisinde bir sistol ve diyastol süresi bir kardiyak periyottan daha uzun olamayacağına göre sistol ve diyastol sürelerinin bir kardiyak döngüden fazla olması halinde yukarıda bahsedilen durum gerçekleşmiş olup bu kardiyak döngü geçersiz sayılarak sınıflandırma için kullanılacak olan veri setine dahil edilmemektedir. Kalp rahatsızlığı ile ilgili bilgi bir kardiyak döngü içerisinde tespit edilebildiğinden kesin olarak emin olunan kardiyak periyotlar üzerinden sınıflandırma işlemi yapılmaktadır. Aksi halde belirlenemeyen bir S1 ve S2 sesi sistol veya diyastol bölgesinde üfürüm gibi davranarak yanlış sınıflandırmaya/teşhise sebep olacaktır. Normal, AD, MY, AY ve MD hastalıkları için bölütleme algoritması tarafından belirlenen veri seti Çizelge 6.2'de sunulmaktadır. Bu veri seti üzerinde hastalık sınıflandırma çalışması yapılacaktır.

	Kardiyak Periyod Sayısı
Aort Darlığı	900
Mitral Yetmezliği	754
Aort Yetmezliği	77
Mitral Darlığı	478
Normal	4409

Çizelge 6.2. Sınıflandırma Veri Seti

Tüm sınıflandırma modellerinde Normal, AD, MY, AY ve MD hastalık kayıtlarının her biri için toplam kardiyak periyodlarının %70'i eğitim veri seti, %15'i doğrulama veri seti için kullanılırken %15'i test verisi seti için kullanılmıştır. Veri tablosu Çizelge 6.3'de sunulmaktadır.

	Eğitim	Doğrulama	Test
Aort Darlığı	630	135	135
Mitral Yetmezliği	528	113	113
Aort Yetmezliği	54	11	12
Mitral Darlığı	335	71	72
Normal	3086	661	662


Çizelge 6.3. Eğitim, Doğrulama ve Test Veri Seti

Eğitim verisinde yer alan hastalıklı verilerinin her sınıf için yaklaşık aynı çoğunlukta olması ağın hastalıklar için genelleme yapmasında bir ihtiyaç unsurudur. Veri setinde yer alan her bir hastalık için %85 eğitim ve doğrulama verisi olarak kullanılacaktır. AD verisi için 765 (630+135) adet eğitim ve doğrulama verisi bulunurken AY verisi için 65 (54+11) adet eğitim ve doğrulama verisi elde edilmektedir. Veriler arasındaki bu fark ağın genelleme yaparak öğrenmeyi tamamlamasını engellemektedir. AY verisine 40dB SNR ile "Gaussian Beyaz Gürültü" eklenerek eğitim veri seti çoğaltılacak ve veri setleri arasındaki sayısal çoğunluk farkı giderilecektir. Bu yöntemle ağların genelleme yapabilecek şekilde eğitilmesi hedeflenmektedir. Sınıflandırma performansı için iki ayrı yaklaşım iz-

lenecek olup bu yaklaşımların performansları ayrı ayrı gözlemlenecektir.

6.2.2 Yaklaşım 1

Kalp ses sinyalleri ilk seviyede normal ve anormal olarak sınıflandırılacak ardından hastalık teşhisi için ikinci bir alt seviyede AD, MY, AY, MD hastalık sınıflandırılması yapılacaktır. Yaklaşımın karar topolojisi Şekil 6.19 'de verilmektedir.



Şekil 6.19. Yaklaşım 1 - Karar Topolojisi

Toplam 2209 anormal ve 4409 normal veri setinin %15'i eğitilen ağın performansı için rastgele seçilmiş olup her bir sınıflandırıcı için test performansı ve sınıflandırma parametresi anlatılacaktır.

Seviye 1:

AD, MY, AY, MD olarak etiklenen kardiyak periyotlarının tamamı anormal kalp ses sinyali başlığı altında tek bir veri kümesi oluşturmaktadır. Bu seviyede yalnızca kalp ses sinyalinde herhangi bir rahatsızlık olup olmadığı anlaşılmaya çalışılacaktır. Normal ve anormal kalp ses sinyalleri sınıflandırması hedeflenmektedir.

1. Destek Vektör Makinaları; Bölüm 6.1.2'de anlatılan kernel polinom derecesi 3 olarak belirlenen ağın test veri seti üzerinde sınıflandırma performansı %85,0 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.4'de yer almaktadır.

	Anormal	Normal	Total
Tahmin Edilen Anormal	256	73	%77,8
Tahmin Edilen Normal	76	588	%88,6
	%77,1	%89,0	%85,0

Çizelge 6.4. Normal - Anormal DVM Performansı

2. K-En Yakın Komşu; Bölüm 6.1.3'de anlatılan öklid uzaklığı kullanılarak $k=3$ en yakın komşuluk için eğitilen ağın test veri seti üzerinde sınıflandırma performansı %79,8 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.5'de yer almaktadır.

	Anormal	Normal	Total
Tahmin Edilen Anormal	270	139	%66,0
Tahmin Edilen Normal	62	522	%89,4
	%81,3	%79,0	%79,8

Çizelge 6.5. Normal - Anormal KNN Performansı

3. Yapay Sinir Ağları; bir giriş katmanı, bir gizli katman ve bir çıkış katmanı ile modellenen bir ağda 407 adet gizli katman nöronu ile transfer fonksiyonu 'tansig' ve çıkış transfer fonksiyonu 'purelin' kullanılarak 100 iterasyon sonucunda eğitilen ağın test veri seti üzerinde sınıflandırma performansı %74,0 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.6'de yer almaktadır.

	Anormal	Normal	Total
Tahmin Edilen Anormal	243	169	%59,0
Tahmin Edilen Normal	89	492	%84,7
	%73,2	%74,4	%74,0

Çizelge 6.6. Normal - Anormal Yapay Sinir Ağları Performansı

4. Karar Ağacı; Bölüm 6.1.1'de anlatılan bagging yöntemi kullanılarak eğitilen ağın test veri seti üzerinde sınıflandırma performansı %81,0 olarak hesaplanırken her

bir sınıf için detaylı performans sonucu Çizelge 6.7'de yer almaktadır.

	Anormal	Normal	Total
Tahmin Edilen Anormal	246	103	%70,5
Tahmin Edilen Normal	86	558	%86,6
	%74,1	%84,4	%81,0

Çizelge 6.7. Normal - Anormal Karar Ağacı Performansı

Seviye 2:

Normal ve anormal olarak sınıflandırılan kardiyak periyotları bu seviyede; hastalık etiketi sınıflandırması hedeflenmektedir. Anormal olarak etiketlenen veriler bu defa AD, MY, AY ve MD olarak hastalık sınıflandırması yapılacaktır.

1. Destek Vektör Makinaları; Bölüm 6.1.2'de anlatılan kernel polinom derecesi 3 olarak belirlenen ağın test veri seti üzerinde hastalık sınıflandırma performansı %77,1 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.8'de yer almaktadır.

	AD	MY	AY	MD	Total
Tahmin Edilen AD	102	14	2	6	%82,3
Tahmin Edilen MY	21	87	1	6	%75,7
Tahmin Edilen AY	1	2	9	2	%64,3
Tahmin Edilen MD	11	10	0	58	%73,4
	%75,6	%77,0	%75,0	%80,6	%77,1

Çizelge 6.8. Hastalık Sınıflandırması DVM Performansı

2. K-En Yakın Komşu; Bölüm 6.1.3'de anlatılan öklid uzaklığı kullanılarak k= 3 en yakın komşuluk için eğitilen ağın bir test veri seti üzerinde hastalık sınıflandırma performansı %77,4 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.9'de yer almaktadır.

	AD	MY	AY	MD	Total
Tahmin Edilen AD	109	22	0	7	%79,0
Tahmin Edilen MY	20	85	2	10	%72,6
Tahmin Edilen AY	1	3	9	1	%64,3
Tahmin Edilen MD	5	3	1	54	%85,7
	%80,7	%75,2	%75,0	%75,0	%77,4

Çizelge 6.9. Hastalık Sınıflandırması KNN Performansı

3. Yapay Sinir Ağları; bir giriş katmanı, bir gizli katman ve bir çıkış katmanı ile modellenen bir ağda 407 adet gizli katman nöronu ile transfer fonksiyonu 'tansig' ve çıkış transfer fonksiyonu 'purelin' kullanılarak 139 iterasyon sonucunda eğitilen ağın test veri seti üzerinde hastalık sınıflandırma performansı %66,9 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.10'da yer almaktadır.

	AD	MY	AY	MD	Total
Tahmin Edilen AD	94	26	2	9	%71,8
Tahmin Edilen MY	27	68	0	7	%66,7
Tahmin Edilen AY	9	8	10	6	%30,3
Tahmin Edilen MD	5	11	0	50	%75,8
	%69,6	%60,2	%83,3	%69,4	%66,9

Çizelge 6.10. Hastalık Sınıflandırması Yapay Sinir Ağları Performansı

4. Karar Ağacı; Bölüm 6.1.1'de anlatılan bagging yöntemi kullanılarak eğitilen ağın test veri seti üzerinde hastalık sınıflandırma performansı %76,2 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.11'da yer almaktadır.

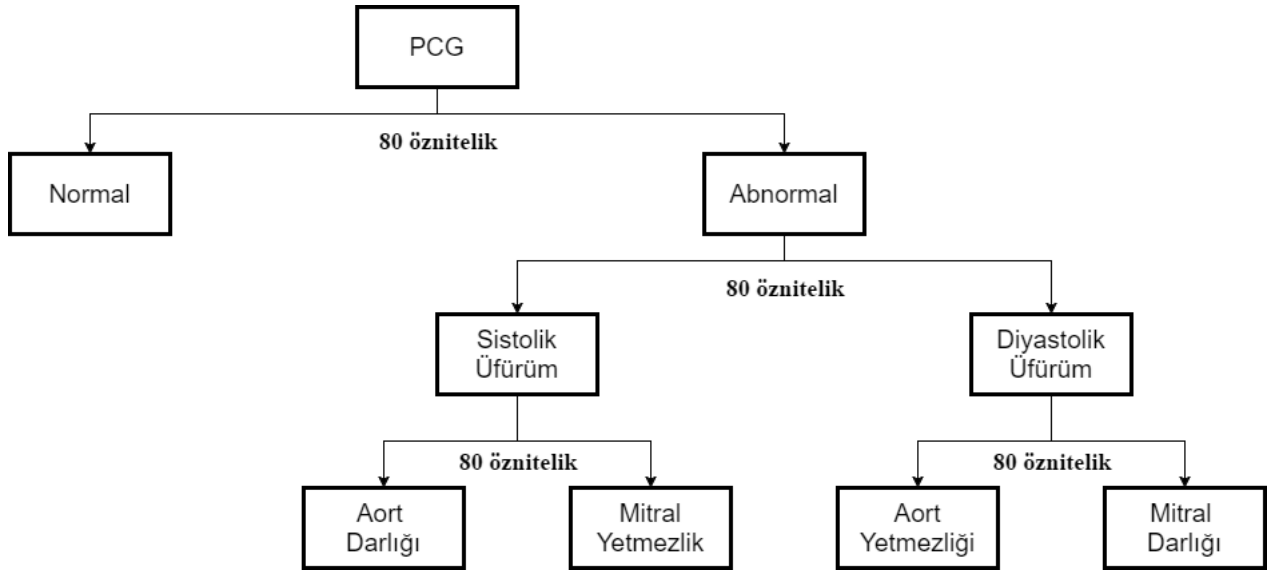
	AD	MY	AY	MD	Total
Tahmin Edilen AD	107	22	3	10	%75,4
Tahmin Edilen MY	16	83	0	6	%79,0
Tahmin Edilen AY	1	0	8	1	%80,0
Tahmin Edilen MD	11	8	1	55	%73,3
	%79,3	%73,5	%66,7	%76,4	%76,2

Çizelge 6.11. Hastalık Sınıflandırması Karar Ağacı Performansı

AD, MY, AY, MD gibi hastalık etiketlerini tek bir seviyede sınıflandırıldığında performans sonuçlarının oldukça düşük olduğu gözlemlenmektedir. Performanslar incelendiğinde bazı ufak iyileştirmeler olsa da ayrışımın belli bir düzeyde kaldığı anlaşılmaktadır. TY, PDA gibi diğer anormal hastalıklarında ilerideki çalışmalarda ekleneceğini düşünülürse sınıf sayısı oldukça artacak buda sınıflandırıcıların karmaşıklığını arttıracak olup elde edilen bu performanslar giderek düşmeye başlayacaktır. Bu nedenle modüler bir yapı ile kararın bir karar topolojisi içinde verilmesi durumundaki başarı karşılaştırmaları ele alınacaktır. Karar topolojisi öncelikle sorunlu ve normal verileri ayırarak işe başlanmaktadır. Daha sonra bu ayırım sistolik ve diyastolik üfürüm ayrıştırması ile devam etmektedir. Bu yolla sınıf kararı daraltılarak performans iyileştirimi amaçlanmıştır.

6.2.3 Yaklaşım 2

Sınıflandırma işlemi mantıksal adımlara bölünerek karmaşıklık azaltılarak, hastalık etiketleme performansı arttırımı hedeflenmektedir. İlk olarak normal ile anormal PCG sinyali ayrımı üzerine yoğunlaşılacak, PCG sinyalinin anormal bir kayıt olduğu anlaşılmasının akabinde sistolik üfürüm veya diyastolik üfürüm kararı verilmeye çalışılacaktır. Bu adımın devamında sistolik üfürümler kendi içlerinde diyastolik üfürümler kendi içlerinde sınıflandırılarak hastalık etiketleme performansı gözlemlenecektir. Yaklaşımın karar topolojisi Şekil 6.20 'da sunulmaktadır.



Şekil 6.20. Yaklaşım 2 - Karar Topolojisi

Yaklaşımların performans karşılaştırmasını sağlıklı bir şekilde yapabilmek için eğitim, doğrulama ve test veri setleri için rastgele seçim yapılmayacak olup Yaklaşım 1' de seçilen eğitim, doğrulama ve test veri seti aynen kullanılacaktır.

Seviye 1:

Yaklaşım-1 Seviye-1 de olduğu gibi bu seviyede kalp ses sinyalleri normal ve anormal olarak sınıflandırılacaktır. AD, MY, AY, MD olarak etiklenen kardiyak periyotlarının tamamı anormal kalp ses sinyali başlığı altında bir veri kümesi olacak ve normal kalp ses sinyali veri kümesi ile birlikte sınıflandırma yapılacaktır. Yaklaşım 1-Seviye-1 de yer alan sınıflandırma performansı bu seviyede tekrarlanmaktadır.

Seviye 2:

Normal ve anormal olarak sınıflandırılan kardiyak periyotları bu seviyede; sistolik veya diyastolik etiketi sınıflandırması hedeflenmektedir. Anormal olarak etiketlenen veriler bu defa sistolik veya diyastolik üfürüme sahip olarak hastalık sınıflandırması yapılacaktır. AD ve MY kayıtları literatürde sistolik üfürüm olarak değerlendirilmekte olduğundan sistol veri seti için Aort Darlığı ve Mitral Yetmezliği kayıtları kullanılırken AY ve MD kayıtları

ları literatürde diyastolik üfürüm olarak değerlendirilmekte olduğundan diyastol veri seti için Aort Yetmezliği ve Mitral Darlığı kayıtları kullanılmaktadır. Anormal bir PCG kaydı içerisinde sistolik üfürüm veya diyastolik üfürüm test performansı ve sınıflandırma parametresi her bir sınıflandırıcı için anlatılacaktır.

1. Destek Vektör Makinaları; Bölüm 6.1.2'de anlatılan kernel polinom derecesi 3 olarak belirlenen ağın test veri seti üzerinde sistolik/diyastolik üfürüm sınıflandırma performansı %85,8 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.12'de yer almaktadır.

	Sistolik Üfürüm	Diyastolik Üfürüm	Total
Tahmin Edilen Sistolik	223	22	%91,0
Tahmin Edilen Diyastolik	25	62	%71,3
	%89,9	%73,8	%85,8

Çizelge 6.12. Sistolik - Diyastolik DVM Performansı

2. K-En Yakın Komşu; Bölüm 6.1.3'de anlatılan öklid uzaklığı kullanılarak 3 en yakın komşuluk için eğitilen ağın test veri seti üzerinde sistolik/diyastolik üfürüm sınıflandırma performansı %90,1 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.13'de yer almaktadır.

	Sistolik Üfürüm	Diyastolik Üfürüm	Total
Tahmin Edilen Sistolik	235	20	%92,2
Tahmin Edilen Diyastolik	13	64	%83,1
	%94,8	%76,2	%90,1

Çizelge 6.13. Sistolik - Diyastolik KNN Performansı

3. Yapay Sinir Ağları; bir giriş katmanı, bir gizli katman ve bir çıkış katmanı ile modellenen bir ağda 807 adet gizli katman nöronu ile transfer fonksiyonu 'tansig' ve çıkış transfer fonksiyonu 'purelin' kullanılarak 62 iterasyon sonucunda eğitilen ağın test veri seti üzerinde sistolik/diyastolik üfürüm sınıflandırma performansı %76,5 ola-

rak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.14'de yer almaktadır.

	Sistolik Üfürüm	Diyastolik Üfürüm	Total
Tahmin Edilen Sistolik	194	24	%89,0
Tahmin Edilen Diyastolik	54	60	%52,6
	%78,2	%71,4	%76,5

Çizelge 6.14. Sistolik - Diyastolik Yapay Sinir Ağları Performansı

4. Karar Ağacı; Bölüm 6.1.1'de anlatılan bagging yöntemi kullanılarak eğitilen ağın test veri seti üzerinde sistolik/diyastolik üfürüm sınıflandırma performansı %88,9 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.15'de yer almaktadır.

	Sistolik Üfürüm	Diyastolik Üfürüm	Total
Tahmin Edilen Sistolik	234	23	%91,1
Tahmin Edilen Diyastolik	14	61	%81,3
	%94,4	%72,6	%88,9

Çizelge 6.15. Sistolik - Diyastolik Karar Ağacı Performansı

Seviye 3:

Sistolik ve diyastolik olarak sınıflandırılan kardiyak periyotları bu seviyede; AD ile MY, AY ile MD olarak hastalık etiketi sınıflandırması hedeflenmektedir.

1. Destek Vektör Makinaları; Bölüm 6.1.2'de anlatılan kernel polinom derecesi 3 olarak belirlenen ağın test veri seti üzerinde hastalık sınıflandırma performansı %84,3 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.16 ve Çizelge 6.17'da yer almaktadır.

	AD	MY	Total
Tahmin Edilen AD	106	16	%86,9
Tahmin Edilen MY	29	97	%77,0
	%78,5	%85,8	%81,9

Çizelge 6.16. AD-MY DVM Performansı

	AY	MD	Total
Tahmin Edilen AY	12	7	%63,2
Tahmin Edilen MD	0	65	%100,0
	%100,0	%90,3	%91,7

Çizelge 6.17. AY-MD DVM Performansı

2. K-En Yakın Komşu; Bölüm 6.1.3'de anlatılan öklid uzaklığı kullanılarak 3 en yakın komşuluk için eğitilen ağın test veri seti üzerinde hastalık sınıflandırma performansı %85,2 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.18 ve Çizelge 6.19'de yer almaktadır.

	AD	MY	Total
Tahmin Edilen AD	108	18	%85,7
Tahmin Edilen MY	27	95	%77,9
	%80,0	%84,1	%81,9

Çizelge 6.18. AD-MY KNN Performansı

	AY	MD	Total
Tahmin Edilen AY	11	3	%78,6
Tahmin Edilen MD	1	69	%98,6
	%91,7	%95,8	%95,2

Çizelge 6.19. AY-MD KNN Performansı

3. Yapay Sinir Ağları; bir giriş katmanı, bir gizli katman ve bir çıkış katmanı ile modellenen bir ağda 807 adet gizli katman nöronu ile transfer fonksiyonu 'tansig' ve çıkış transfer fonksiyonu 'purelin' kullanılarak 34 iterasyon sonucunda eğitilen ağın test veri seti üzerinde hastalık sınıflandırma performansı %79,8 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.20 ve Çizelge 6.21'de yer almaktadır.

	AD	MY	Total
Tahmin Edilen AD	105	27	%79,5
Tahmin Edilen MY	30	86	%74,1
	%77,8	%76,1	%77,0

Çizelge 6.20. AD-MY Yapay Sinir Ağları Performansı

	AY	MD	Total
Tahmin Edilen AY	10	8	%55,6
Tahmin Edilen MD	2	64	%97,0
	%83,3	%88,9	%88,1

Çizelge 6.21. AY-MD Yapay Sinir Ağları Performansı

4. Karar Ağacı; Bölüm 6.1.1'de anlatılan bagging yöntemi kullanılarak eğitilen ağın test veri seti üzerinde hastalık sınıflandırma performansı %84,9 olarak hesaplanırken her bir sınıf için detaylı performans sonucu Çizelge 6.22 ve Çizelge 6.23'de yer almaktadır.

	AD	MY	Total
Tahmin Edilen AD	121	29	%80,7
Tahmin Edilen MY	14	84	%85,7
	%89,6	%74,3	%82,7

Çizelge 6.22. AD-MY Karar Ağacı Performansı

	AY	MD	Total
Tahmin Edilen AY	9	4	%69,2
Tahmin Edilen MD	3	68	%95,8
	%75,0	%94,4	%91.,7

Çizelge 6.23. AY-MD Karar Ağacı Performansı

7. SONUÇLAR

Kalp ses sinyallerinin bölütlenmesi ve sınıflandırılması amacıyla gerçekleştirilen bu çalışma genel olarak üç ana parçaya ayrılabilir. Birincisi kalp seslerinin bölütlenmesi işlemi, ikincisi kalp sesleri üzerinden ayırt edici özniteliklerin çıkarılması ve son olarak dört ayrı gözetimli sınıflandırma yöntemi ile hastalık kimliklendirme çalışması oluşturmuştur.

Bölütleme işlemi kimliklendirme başarımına etki eden en önemli bölümdür. Ses tanıma sistemlerinde yaygın olarak kullanılan Mel-Frekans Kepstral Katsayıları bu çalışmada Ayrık Dalgacık Dönüşümü ile birlikte S1 ve S2 kalp seslerinin gürültülerden ve üfürümlerden ayırt edilmesi amacı ile kullanılmıştır. Hastalık bilgisi taşıyan ve taşımayan tüm kayıtlar üzerinden S1 ve S2 kalp seslerinin bölütlenmesi performans sonuçları Çizelge 7.1'de verilmektedir.

Kayıt	Kesinlik %	Hassasiyet %
Normal	98,19	98,52
Abnormal	94,31	96,92

Çizelge 7.1. Kalp Seslerinin S1-S2 Bölütleme Performans Sonuçları

Bölütleme işlemi sınıflandırıcılar için önemli bir ön işleme safhasını oluşturmaktadır. Aralıkların belirlenme başarımı doğrudan S1 ve S2 ses yerlerinin doğru belirlenmesine bağlıdır.

Kalp sesleri hakkında en doğru bilgiyi elde edebilmek için hem zaman hem frekans hem de istatistiksel alanda öznitelikler çıkarılmıştır. Mutlak ortalama değer, varyans, standart sapma, kurtosis, etkin değer, enerji, dinamik aralık, maksimum frekans, maksimum ve minimum genlik kalp ses sinyalinin öznitelik uzayını oluşturmak üzere seçilmiştir. Ayırt edilebilme performansı yüksek olan bu öznitelikler sınıflandırıcılar için giriş vektörünü oluşturmuştur.

Çalışmanın son bölümünde Destek Vektör Makinaları, Yapay Sinir Ağları, K-En Yakın Komşu Algoritması ve Karar Ağaçları kullanılarak Normal, AD, MY, AY ve MD kayıtları-

nın sınıflandırma performansları iki ayrı yaklaşımla ele alınmıştır. Birinci yaklaşımda tüm hastalıklı sinyaller tek seviyede sınıflandırılmış ancak özellikle veri sayısı diğer hastalıklarına göre oldukça az olan AY sınıfı için sınıflandırma performansının düşük kaldığı görülmüştür. Performanslar incelendiğinde bazı ufak iyileştirmeler olsa da ayrışımın belli bir düzeyde kalacağı anlaşılmıştır. Diğer anormal hastalıklarında (TY, PDA gibi) ilerideki çalışmalarda ekleneceği düşünülürse sınıf sayısı oldukça artacak olup bu durumun sınıflandırıcıların karmaşıklığını arttıracığı ve elde edilen performansların giderek düşmeye başlayacağı öngörülmektedir. Bu nedenle modüler bir yapı olan ikinci yaklaşım önerilmiştir. Sınıflandırma işlemi mantıksal adımlara bölünerek karmaşıklık azaltılmış, hastalık etiketleme performansının yükseldiği görülmüştür. Her iki yaklaşım ile Normal, AD, MY, AY ve MD kayıtlarının her bir sınıflandırma yöntemi için performans sonuçları Çizelge 7.2'de verilmektedir. Hassasiyet, gerçek pozitif sonuçların gerçek pozitif ve yanlış negatif toplamına oranı $Tp / (Tp+Fn)$ ile belirlenirken kesinlik, gerçek pozitif sonuçların gerçek pozitif ve yanlış pozitif toplamına oranı $Tp / (Tp+Fp)$ ile belirlenmiştir. Sınıflandırma kesinlik-hassasiyet analizi [EK - A.2]'de detaylı olarak anlatılmıştır.

DVM Yaklaşım 1	Hassasiyet %	Kesinlik %
Normal	89,0	88,6
AD	75,6	82,3
MY	77,0	75,7
AY	75,0	64,3
MD	80,6	73,4

DVM Yaklaşım 2	Hassasiyet %	Kesinlik %
Normal	89,0	88,6
AD	78,5	86,9
MY	85,8	77,0
AY	100	63,2
MD	90,3	100

KNN Yaklaşım 1	Hassasiyet %	Kesinlik %
Normal	79,0	89,4
AD	80,7	79,0
MY	75,2	72,6
AY	75,0	64,3
MD	75,0	85,7

KNN Yaklaşım 2	Hassasiyet %	Kesinlik %
Normal	79,0	89,4
AD	80,0	85,7
MY	84,1	77,9
AY	91,7	78,6
MD	95,8	98,6

YSA Yaklaşım 1	Hassasiyet %	Kesinlik %
Normal	74,4	84,7
AD	69,6	71,8
MY	60,2	66,7
AY	83,3	30,3
MD	69,4	75,8

YSA Yaklaşım 2	Hassasiyet %	Kesinlik %
Normal	74,4	84,7
AD	77,8	79,5
MY	76,1	74,1
AY	83,3	55,6
MD	88,9	97,0

Karar Ağacı Yaklaşım 1	Hassasiyet %	Kesinlik %
Normal	84,4	86,6
AD	79,3	75,4
MY	73,5	79,0
AY	66,7	80,0
MD	76,4	73,3

Karar Ağacı Yaklaşım 2	Hassasiyet %	Kesinlik %
Normal	84,4	86,6
AD	86,6	80,7
MY	74,3	85,7
AY	75,0	69,2
MD	94,4	95,8

Çizelge 7.2. Gözetimli Sınıflandırma Sonuçları

Kalp seslerinin doğru bir şekilde yorumlanarak hızlı ve etkili teşhis yapabilecek destek sistemlerine ihtiyaç her geçen gün daha da artmaktadır. Sinyal işlemedeki gelişmeler hastaların pahalı testler yapmasına gerek kalmadan kolay ve doğru teşhis olanağı sağlayabilmektedir. Oskültasyon anında eş zamanlı olarak S1, sistol, S2, diyastol aralıklarını belirleyerek hastalık sınıflandırması yapabilmek yapılan bu çalışmalarla mümkün olabilmektedir. Oskültasyon işlemi tamamlanmadan veya bitiminin akabinde dinlenen kalp sesinin sistolik ve/veya diyastolik üfürüm taşımasından öte hangi hastalığa işaret ettiğini tespit edebilmek doktorlar tarafından hem kolay erişilebilir ve hem teşhis desteği sağlayabilir bir kabiliyet olacaktır.

TY, PDA, VSD gibi bazı kalp rahatsızlıklarının toplumda nadir görülmesi sebebi ile bu hastalıklara ait PCG kayıt sayısı bir gözetimli sınıflandırma uygulaması için yeterli ol-

madıđından bu hastalık kayıtları sınıflandırma alıřmalarına dahil edilememiřtir. Doktorların kullanımına sunulması amalanan bir karar destek sistemi iin ok fazla sayıda hastaya ulařılması ve sınıflandırmada kullanılacak veri tabanının geniřletilmesi gerekmektedir.

KAYNAKLAR

- [1] T.C. Sağlık Bakanlığı Temel Sağlık Hizmetleri Genel Müdürlüğü, Türkiye Kalp ve Damar Hastalıklarını Önleme ve Kontrol Programı 2010-2014, Basım Ankara **2010**.
- [2] Devlet İstatistik Enstitüsü, Turkey in Statistics. 132. Ankara, DİE Matbaası **2001**.
- [3] Ölüm İstatistikleri İl ve İlçe Merkezleri 2008, TÜİK. Ankara **2009**.
- [4] Türkiye İstatistik Kurumu, Ölüm Nedeni İstatistikleri, <http://www.tuik.gov.tr/> **2014**.
- [5] Rangaraj M. Rangayyan, "Biomedical Signal Analysis A Case-Study Approach", IEEE, **2002**.
- [6] TUBİTAK - TEYDEB 1507, 7141460 numaralı - Elektronik Stetoskop ile Ayrıntılı Dinleme (Oskültasyon) ve Kalp Hastalıklarında Tanı Destek Sistemi Geliştirme (ESDES-G) projesi.
- [7] M. El-Segaier, O. Lilja, L. Sörnmo, R. Sepponen and E. Pesonen, "Computer-Based Detection and Analysis of Heart Sound and Murmur", Annals of Biomedical Engineering, Vol. 33, No.7, July **2005**.
- [8] Abbas K. Abbas, Rasha Bassam, "Phonocardiography Signal Processing", Synthesis Lectures on Biomedical Engineering, John D. Enderle, Series Editor, April **2009**.
- [9] Prof. Dr. Ünal Açikel, Web Sitesi, <http://www.unalacikel.com.tr/kalp-damar-cerrahi.asp?alt=1> (Nisan **2017**).
- [10] Mustafa Yamaçlı, "Fonokardiyogram Kayıtlarındaki S1-S2 seslerinin Dalgacık Enerjileri ile Bölütlenmesi", Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Haziran **2008**.
- [11] Auscultatory Sites, <http://www.stethographics.com/heart/main/sites.htm> (Nisan **2017**).
- [12] Wang Xinpei, et al. Heart sound segmentation algorithm based on high-order Shannon entropy. Journal of Jilin University (Engineering and Technology Edition), 40(5): 1433-1437, **2010**.
- [13] Computer and Information Science, Numerical Analysis and Scientific Computing, Discrete Wavelet Transforms-Biomedical Applications, Chapter 5 - Computerized Heart Sound Analysis, By S.M. Debbal, **2011**.
- [14] Patrick T. O'Gara, Joseph Loscalzo, "Approach to the Patient With a Heart Murmur", Harrison's Principles of Internal Medicine, Chapter 13, Edition 18, **2011**.
- [15] Littmann Stethoscopes Web Page, <http://www.littmann.com> (Nisan **2017**).

- [16] Cota N. Gupta, R. Palaniappan, S. Rajan, S. Swaminathan, S.M. Krishnan, "Segmentation and Classification of Heart Sounds", Canadian Conference on Electrical and Computer Engineering, pages:1674-1677, **2005**.
- [17] K. Bajelani, M. Navidbakhsh, H. Bahnam, J. D. Doyle, K. Hassani, "Detection and Identification of First and Second Heart Sounds using Empirical Mode Decomposition", Journal of Engineering In Medicine, 227(9) 976-987, **2013**.
- [18] H. Liang, S. Lukkarinen, I. Hartimo, "Heart Sound Segmentation Algorithm Based on Heart Sound Envelopogram", Computers in Cardiology, 24:105-108, **1997**.
- [19] D. Kumar, P. Carvalho, M. Antunes, J. Henriques, M. Maldonado, R. Schmidt, J. Habetha, "Wavelet Transform And Simplicity Based Heart Murmur Segmentation", Computers in Cardiology, pages:173-176, **2006**.
- [20] D. Kumar, P. Carvalho, M. Antunes, J. Henriques, M. Maldonado, R. Schmidt, J. Habetha, "Detection of S1 and S2 Heart Sounds by High Frequency Signatures", 2006 International Conference of the IEEE Engineering in Medicine and Biology Society, pages: 6469-6472, , **2006**.
- [21] D. Kumar, P. Carvalho, M. Antunes, P. Gil, J. Henriques, L. Eugenio, "A New Algorithm for Detection of S1 and S2 Heart Sounds", 2006 IEEE International Conference on Acoustics Speech and Signal Processing Proceedings, **2006**.
- [22] Cota Navin Gupta, Ramaswamy Palaniappan, Sundaram Swaminathan, Shankar M. Krishnan, "Neural Network Classification of Homomorphic Segmented Heart Sounds" Applied Soft Computing 7, 286-297, **2007**.
- [23] Davis, S. B. and P. Mermelstein, "Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences". IEEE Transactions on Acoustics, Speech and Signal Processing, vol. ASSP-28, p. 389-397, **1980**.
- [24] Van-Lan Dao, Van-Danh Nguyen, Hai-Duong Nyguyen and Van-Phuc Hoang, "Hardware Implementation of MFCC Feature Extraction for Speech Recognition on FPGA" , Advances in Information and Communication Technology, ICTA **2016**.
- [25] Lindasalwa Muda, Mumtaj Begam and I. Elamvazuthi "Voice Recognition Algorithms using Mel Frequency Cepstral Coefficient (MFCC) and Dynamic Time Warping (DTW) Techniques", Journal of Computing, Volume 2, Issue3, ISSN 2151-9617, March **2010**.
- [26] Parwinder Pal Singh, Pushpa Rani, "An Approach to Extract Feature using MFCC", IOSR Journal of Engineering (IOSRJEN), Vol. 04, Issue 08, PP 21-25, August **2014**.
- [27] Ramesh Babu.N "Speech Recognition using MFCC and DTW", DOI: 10.1109/ICAEE.2014.6838564, January **2014**.

- [28] Namrata Dave, "Feature Extrax-ction Methods LPC, PLP and MFCC InSpeech Recognition", International Journal for Advance Research in Engineering and Technology, July **2013**.
- [29] Alan V. Oppenheim, Alan S. Willsky, "Signals and Systems", Second Edition, **1996**.
- [30] Wireless Mobile Communication and Healthcare: Third International Conference, Mobil Health 2012, Paris, France, November **2012**.
- [31] Tze Fen Li, Shui-Ching Chang, "Speech Recognition of Mandarin Syllables Using Both Linear Predict Coding Cepstra and Mel Frequency Cepstra", **2007**.
- [32] Kiran Kumar Bhuvanagiri, Sunil Kumar Kopparapu, "Modified Mel Filter Bank to Compute MFCC of Subsampled Speech", 25 Oct. **2014**.
- [33] Karim Courtemanche, Veronique Millette, Natalie Baddour, "Heart Sound Segmentation Based on Mel-Scaled Wavelet Transform", Canadian Medical and Biological Engineering Society Conference,Canada, May **2008**.
- [34] Chun-Lin,Liu, "Tutorial of the Wavelet Transform", February 23, **2010**.
- [35] Yiqi Deng, Peter J Bentley, "A Robust Heart Sound Segmentation and Classification Algorithm using Wavelet Decomposition and Spectrogram", Dept. of Computer Science, UCL Malet Place, London, **2012**.
- [36] Simarjot Kaur Randhawa and Mandeep Singh, "Classification of Heart Sound Signal Using Multi-modal Features", Procedia Computer Science 58, 165-171, **2015**.
- [37] Mandeep Singh, Amandeep Cheema, "Heart Sounds Classification using Feature Extraction of Phonocardiography Signal", International Journal of Computer Applications, Volume 77-No.4, September **2013**.
- [38] Özgür Say, "Kalp Seslerinin Analizi ve Yapay Sınır Ağları ile Sınıflandırılması", Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Haziran **2002**.
- [39] Richard O. Duda, Peter E. Hart, David G. Stork, "Pattern Classification", Second Edition, **2001**.
- [40] Roman Timofeev, "Classification and Regression Trees (CART) Theory and Applications" Berlin, December 20, **2004**.
- [41] Clifton D. Sutton, "Classification and Regression Trees, Bagging, and Boosting", Handbook of Statistics, Vol. 24 ISSN: 0169-7161, **2005**.
- [42] Andrew Ng, "Support Vector Machines", Stanford University, Machine Learning CS229, <http://cs229.stanford.edu/materials.html>, (Nisan **2017**).

- [43] Christopher J.C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition", Kluwer academic Publishers, Boston, Data Mining and Knowledge Discovery 2, 121-167, **1998**.
- [44] Erdal Taşçı, Aytuğ Onan, "K-En Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi" AB2016 Akademik Bilisim Konferansı, Bildiri 102, **2016**.
- [45] Mitchell, T., "Machine Learning", McGraw Hill, New York, **1997**.
- [46] Kittipong C., Pasapitch C., "An Empirical Study of Distance Metrics for k-Nearest Neighbor Algorithm", Proceedings of the 3rd International Conference on Industrial Application Engineering **2015**.
- [47] Anil K. Ghosh, "On Optimum Choice of k in Nearest Neighbor Classification" Computational Statistics & Data Analysis 50, 3113 - 3123, **2006**.
- [48] Martin T. Hagan, Howard B. Demuth, "Neural Network Design", 2nd Edition, eBook, **2002**.
- [49] David Kriesel, "A Brief Introduction to Neural Networks", eBook, **2007**.
- [50] Simon Haykin, "Neural Networks and Learning Machines", Third Edition, eBook, **2008**.
- [51] Takaya Saito, Marc Rehmsmeier, "The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets", PLOS ONE DOI:10.1371/journal.pone.0118432, March **2015**.

A. EKLER

A.1 Kalp Ses Sinyalleri Veri Tablosu

	PCG Sinyalleri	Kayıt	Sistol Aralığı	Diyastol Aralığı
Normal	N - Normal	360		
	Aritmik	19		
	Taşikardik	6		
	Atrial Fibrilasyon	9		
	Sinüs Aritmisi	0		
	S1 - Sert	3		
	S2 - Sert	7		
	Mitral Valve Replacement	13		
	Aortic Valve Replacement	7		
	Sistolik Ejeksiyon Üfürümü	0		
Ek Ses	S3	3		
	S4	3		
	S1 Çiftleşmesi	0		
	S2 Çiftleşmesi	8		
	Mitral Açılma Sesi	7		
	Aortik Ejeksiyon Kliği	2		
Sistolik Üfürüm	Aort Darlığı	67	Orta Sistolik (Elmas) ve Aortik Ejeksiyon	S4 Ek Sesi
	Mitral Yetmezlik	47	Holosistolik	Orta Diyastolik ve S3
	Triküspit Yetmezliği	4	Holosistolik	
	VSD	1	Holosistolik	Orta Diyastolik ve S3
	Mitral Valve Prolapse	1	Geç Sistolik	
Diyastolik Üfürüm	Aort Yetmezliği	9		Erken Diyastolik (Dekreşendo)
	Pulmoner Yetmezliği	0	Erken Sistolik	
	Mitral Darlık	28	Erken Sistolik	Orta Diyastolik ve Açılma Sesi
	Trisküpit Darlığı	0	Orta Sistolik	
Sürekli Üfürüm	PDA	5	Geç Sistolik (Kreşendo)	Erken Diyastolik (Dekreşendo)

A.2 Kesinlik - Hassasiyet Analizi

Teşhis testlerinin değerlendirilmesinde yalnızca doğru etiketlerin belirlenebilmesi başarı göstergesi gibi görülmekte özellikle çağdaş tıpta hastalıklı bir kişiye sağlıklı veya sağlıklı bir kişiye hastalıklı etiketi vermek oldukça endişe vericidir. Hastalık sınıflandırma performansları kesinlik ve hassasiyet analizini aynı anda gerektirmektedir.

Makine öğrenimi alanında ve özellikle istatistiksel sınıflandırma probleminde, bir hata matrisi olarak bilinen karışıklık matrisi (confusion matrix), bir algoritmanın performansını görselleştirmeyi sağlayan tipik bir tablo düzenidir. Matrisin her satırı, tahmin edilen bir sınıftaki örnekleri gösterirken, her bir sütun gerçek bir sınıftaki örnekleri temsil eder. İkili sınıflandırıcıların karışıklık matrisi (confusion matrix), gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) olmak üzere dört sonuca sahiptir. Şekil A.1 'de karışıklık matrisinin bu dört bölgesi gösterilmiştir.

		Gerçek		
		Sınıf A	Sınıf B	
Tahmin	Sınıf A	TP	FP	Kesinlik (Precision) $TP/(TP+FP)$
	Sınıf B	FN	TN	
		Hassasiyet (recall / Sensitivity) $TP/(TP+FN)$		Doğruluk (Accuracy) $(TP+TN)/(TP+TN+FP+FN)$

Şekil A.1. Karışıklık Matrisi

İkili sınıflandırıcılar, hassasiyet ve kesinlik (duyarlılık) gibi performans ölçütleriyle rutin olarak değerlendirilmektedir. Kesinlik / hassasiyet (precision /recall) grafikleri pozitif tahminler arasında doğru pozitiflerin oranını değerlendirdikleri için izleyiciye gelecekteki sınıflandırma performansını doğru bir şekilde öngörebilme imkanı sunarlar [51].

Bir örüntü tanımada, bir sınıfın kesinlik (precision) değeri (duyarlılık), gerçek pozitif sınıfa ait olarak etiketlenmiş elemanların, toplam pozitif sınıf olarak etiketlenmiş eleman sayısına oranı olarak hesaplanmaktadır. Bahsi geçen gerçek pozitif sınıf eleman sayısı; doğru olarak etiketlenmiş öğelerin sayısı iken toplam pozitif sınıf eleman sayısı;

gerçek pozitiflerin ve yanlış pozitiflerin yani yanlış bir sınıfa ait olarak etiketlenmiş öğelerin toplamına eşittir. Hassasiyet (recall/sensitivity) değeri ise gerçek pozitif sayılarının pozitif sınıfa ait toplam eleman sayısına bölünmesiyle tanımlanır. Bahsi geçen pozitif sınıf eleman sayısı; pozitif sınıfa ait olarak etiketlenmemiş maddeler olan gerçek pozitif ve yanlış negatiflerin toplamı olarak ifade edilir.


Çoklu sınıflandırma problemleri için karışıklık matrisinin (Şekil A.2) tüm satır ve sütunları toplanarak işleme alınır. Çoklu sınıflar için kesinlik, hassasiyet ve doğruluk performansı Denklem A.1’de verildiği gibi hesaplanmaktadır.

$$Precision_i = \frac{M_{ii}}{\sum_j M_{ji}} \quad Recall_i = \frac{M_{ii}}{\sum_j M_{ij}} \quad Accuracy_i = \frac{\sum_i M_{ii}}{\sum_i \sum_j M_{ij}} \quad (A.1)$$

		Gerçek		
		Sınıf 1	Sınıf 2	Sınıf 3
Tahmin	Sınıf 1	M₁₁	M₂₁	M₃₁
	Sınıf 2	M₁₂	M₂₂	M₃₂
	Sınıf 3	M₁₃	M₂₃	M₃₃

Şekil A.2. Çoklu Karışıklık Matrisi

Kesinlik-hassasiyet eğrisi (PRC - precision recall curve), her olası kesme için kesinlik (pozitif öngörme değeri) ve hassasiyet arasındaki ilişkiyi gösterir. Bu egride x eksenini hassasiyeti gösterirken y eksenini kesinliği göstermektedir. Mükemmel bir test ile sırasıyla hastalıklı ve hastalısız kişiler için herhangi bir hatanın bulunmadığı durumda %100 duyarlılık ve %100 hassasiyet ile kişiler arasında ayırım yapabilir. Bu mükemmel testin kesinlik-hassasiyet eğrisi Şekil A.3 ’deki gibi olacaktır.



Şekil A.3. Kesinlik-Hassasiyet Eğirisi

Amaç, bir modelin sağ üst köşede olmasını sağlamaktır; bu, temelde yalnızca yanlış pozitif ve yanlış negatif olmayan gerçek pozitifleri elde etmektedir (mükemmel bir sınıflandırıcı). Eğri altında kalan (AUC - area under curve) yani hassas-kesinlik alanı ne kadar yüksekse, örüntü modeli de o kadar iyi olmaktadır [51].

Özgüllük (Specificity), sınıflandırıcının olumsuz sonuçları tanımlama yeteneği ile ilgilidir. Belirli bir hastalığı tanımlamak için kullanılan tıbbi test örneğini göz önünde bulundurulursa testin özgüllüğü, hastalığı olmayan hastaların başarı oranıdır. Diğer bir deyişle; Aort Darlığı olan bir sınıf ile Aort Darlığı olmayan (sağlıklı) bir sınıfın karşılaştırma başarımını ifade etmektedir. Bir testin özgüllük değeri gerçek negatif sonuçların gerçek negatif ve yanlış pozitif sonuçların toplamına oranı $TN / (TN+FP)$ ile elde edilmektedir [51].

Hastalıklı/sağlıklı sınıflandırmasından öte farklı hastalıklar içerisinde "doğru sınıfın tespit edilebilmesi" çalışmalarında yani makine öğrenimi alanında tercih edilen yöntem olan kesinlik hassasiyet analizi tercih edilmiştir .

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı: Gülşen ÇELEBİ

Doğum Yeri: Ankara

Medeni Hali: Bekar

E-posta: gulsen.celebi@hacettepe.edu.tr

Adresi: Ege Mahallesi Natoyolu Caddesi 797. Sokak No:10/15 Mamak / ANKARA

Eğitim

Lisans: Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü, ANKARA

Yüksek Lisans: Hacettepe Üniversitesi Elk. ve Elkt. Mühendisliği Bölümü, ANKARA

Yabancı Dil ve Düzeyi

İngilizce : İyi

İş Deneyimi

12.2012 - 09.2016 : MilSOFT Yazılım Teknolojileri A.Ş. , ANKARA, Sistem Mühendisi

09.2016 - : ESEN Sistem Entegrasyon Ltd. Şti. , ANKARA, Uzman Sistem Mühendisi

Deneyim Alanları

-

Tezden Üretilmiş Projeler ve Bütçesi

-

Tezden Üretilmiş Yayınlar

-

Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar

Karar Destek Sistemi İçin Mel-Frekans Kepstral Tabanlı Kalp Ses Sinyali Bölütleme Çalışması, *G. Çelebi, A. Yılmaz, G. Sözeri, D. Katırcıođlu, S. Okutucu, B.Y. Sayın, H. Aksoy, A. Oto*, SİU 2017, Sinyal İşleme Kurultayı, Antalya, Türkiye



HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS/DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI BAŞKANLIĞINA

Tarih: 06/07/2017

Tez Başlığı / Konusu: Sayısal Stetoskop İle Elde Edilen Kalp Ses Sinyallerinin (Fonokardiyogram) Bölütlenmesi ve Sınıflandırılması

Yukarıda başlığı/konusu gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler d) Sonuç kısımlarından oluşan toplam 97 sayfalık kısmına ilişkin, 06/07/2017 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 7 'tür.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç/dâhil
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orjinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

06.07.2017


Tarih ve İmza

Adı Soyadı: Gülşen Çelebi

Öğrenci No: N13223668


Anabilim Dalı: Elektrik - Elektronik Mühendisliği

Programı: Yüksek Lisans

Statüsü: Y.Lisans Doktora Bütünleşik Dr.

DANIŞMAN ONAYI

UYGUNDUR.


Doç. Dr. AYŞE YILMAZ
(Unvan, Ad Soyad, İmza)