

T.C.  
İNÖNÜ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

KARDİYOYASKÜLER RAHATSIZLIKLARIN YAPAY ÖĞRENME  
YÖNTEMLERİYLE TEŞHİSİ

DOKTORA TEZİ

Ali Fatih GÜNDÜZ

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Muhammed Fatih TALU

TEMMUZ/2023

T.C  
İNÖNÜ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

KARDİYOYASKÜLER RAHATSIZLIKLARIN YAPAY ÖĞRENME  
YÖNTEMLERİYLE TEŞHİSİ

DOKTORA TEZİ

Ali Fatih GÜNDÜZ  
23616190005

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Muhammed Fatih TALU

TEMMUZ/2023

## TEŞEKKÜR VE ÖNSÖZ

Çalışmalarım süresince bana yardımcı olarak benden destek ve tecrübesini esirgemeyen tez danışman hocam Sayın Prof. Dr. Muhammed Fatih TALU'ya öncelikle teşekkürlerimi sunmayı bir borç bilirim. Danışmanlığımı kabul edip tezimin araştırma ve uygulamalarında beni etik kurallar çerçevesinde özgün çalışmalar yapmaya yönlendiren hocama minnettarım.

Tezin daha kapsamlı bir çalışmaya dönüşmesinde etkin tecrübelerine dayanan kıymetli yorumlarıyla beni teşvik eden inceleme komitesinin tüm üyelerine de içtenlikle teşekkür ederim.

Akademik hayatın zorluklarını göğüslemekte bana yardımcı olan, sabırla beni dinleyen, her zorluğun yanında bir kolaylık olduğunu bana gösteren ve desteklerini hep arkamda hissettiğim başta Sayın Prof. Dr. Gökhan TUNCEL ve Sayın Doç. Dr. Ahmet KAZAN olmak üzere mesai arkadaşlarıma da teşekkür ediyorum.

En büyük teşekkürü en yakınlarım olan aileme, anneme, babama ve kız kardeşlerime borçluyum. 6 Şubat 2023 depreminin ardından evlerini bize açan ve her konuda yardımcı olan kaynanam ve kayınbabama da teşekkür ederim. Desteği ve fedakarlıkları için eşim Nur Betül GÜNDÜZ ve kızım Ayşe İkbâl GÜNDÜZ'e minnettarım.

## ONUR SÖZÜ

Doktora tezi olarak sunduđum “Kardiyovasküler Rahatsızlıkların Yapay Öğrenme Yöntemleriyle Teşhisi” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığına ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Ali Fatih GÜNDÜZ



# İÇİNDEKİLER

<b>TEŞEKKÜR VE ÖNSÖZ</b> .....	<b>i</b>
<b>ONUR SÖZÜ</b> .....	<b>ii</b>
<b>İÇİNDEKİLER</b> .....	<b>iii</b>
<b>ÇİZELGELER DİZİNİ</b> .....	<b>v</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>vi</b>
<b>SEMBOLLER VE KISALTMALAR</b> .....	<b>vii</b>
<b>ÖZET</b> .....	<b>viii</b>
<b>ABSTRACT</b> .....	<b>ix</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 Kalp Seslerinin Analizi.....	3
1.2 Literatür İncelemesi .....	6
1.2.1. Literatürde kullanılan veri setleri .....	6
1.2.2 PCG bölümlenme çalışmaları .....	10
1.2.3 PCG kayıtlarından kalp üfürümü tespiti .....	14
1.3 Tezin Amacı .....	18
1.4 Tezin Gerekçesi .....	19
1.5 Tezde Geliştirilen Uygulamalar ve Literatüre Katkısı .....	20
1.6 Tezin Organizasyonu .....	21
<b>2. MATERYAL VE METOT</b> .....	<b>23</b>
2.1 Kullanılan Veri Setleri.....	23
2.1.1 PhysioNet/Computing in Cardiology Challenge 2016 (CinC2016).....	23
2.1.2 CirCor Digiscope Phonocardiogram (CirCor2022).....	24
2.1.3 4th China Physiological Signal Challenge 2021 (CPSC2021).....	25
2.2 Değerlendirme Ölçütleri .....	26
2.3 Ön İşlem .....	28
2.4 Özellik Çıkarımı .....	29
2.4.1 Fourier dönüşümü.....	29
2.4.2 Kısa zamanlı fourier dönüşümü.....	31
2.4.3 Dalgacık dönüşümü .....	32
2.4.4 Ampirik mod ayrıştırma .....	34
2.4.5 Mel-frekans kepstrum katsayıları .....	36
2.4.6 Lineer öngörülü kodlama.....	38
2.4.7 Spektral özellikler.....	38
2.4.8 İstatistiksel özellikler .....	41
2.5 Sınıflayıcılar .....	43
2.5.1 K en yakın komşu algoritması .....	43
2.5.2 C4.5 karar ağacı .....	44
2.5.3 Destek vektör makineleri.....	46
2.5.4 Evrişimsel sinir ağı .....	49
2.5.5 Tekrarlayan sinir ağları.....	52
2.6 Yapay arı kolonisi.....	56
<b>3. YAPILAN UYGULAMA ÇALIŞMALARI</b> .....	<b>58</b>
3.1 Ön İşlem ve Veri Setlerini Dengeleme Aşaması .....	58
3.2 Uygulama 1: Klasik Makine Öğrenmesi Metotlarıyla Sınıflandırma .....	60
3.2.1 Özellik çıkarım aşaması .....	60

3.2.2 Sınıflandırma aşaması.....	61
3.2.3 Performans değerlendirmesi .....	61
3.3 Uygulama 2: Derin Ağın Filtrelenmiş MFKK Değerleriyle Eğitimi .....	63
3.3.1 Filtreleme aşaması ve özellik setinin oluşturulması .....	64
3.3.2 Derin ağ mimarisi .....	66
3.3.3 Performans değerlendirmesi .....	67
3.4 Uygulama 3: ESA ile Spektrogram Sınıflandırma .....	68
3.4.1 YAK tabanlı çerçeve seçimi .....	70
3.4.2 KZFD ile spektrogram oluşturulması .....	71
3.4.3 Derin ağ mimarisi .....	72
3.4.4 Performans değerlendirmesi .....	73
3.5 Uygulama 4: Derin Öğrenmeyle Aritmi Analizi .....	74
3.5.1 Ön işlem aşaması .....	76
3.5.2 Özellik çıkarımı ve sınıflandırma .....	77
3.5.3 Performans değerlendirmesi .....	80
<b>4. SONUÇ VE ÖNERİLER .....</b>	<b>83</b>
<b>KAYNAKLAR.....</b>	<b>87</b>
<b>ÖZGEÇMİŞ .....</b>	<b>97</b>

## ÇİZELGELER DİZİNİ

<b>Çizelge 1.1:</b> Kardiyak döngü bölümleri ve yaklaşık süreleri. Kaynak .....	4
<b>Çizelge 1.2:</b> PCG kaydında bulunan seslerin bileşenlerinin frekans aralığı (Hz).....	5
<b>Çizelge 2.1:</b> CinC2016 veri setini oluşturan eğitim ve test setleri .....	24
<b>Çizelge 2.2:</b> Yaşlarına göre CirCor2022 veri setindeki hastaların sayısı.....	25
<b>Çizelge 2.3:</b> Tezde kullanılan veri setlerindeki örneklerin sınıflara dağılımları.....	26
<b>Çizelge 2.4:</b> İstatistiksel özellikler .....	42
<b>Çizelge 2.5:</b> Aktivasyon fonksiyonları.....	52
<b>Çizelge 3.1:</b> Çerçevelere ayırma aşamasının sonucunda elde edilen veri seti .....	59
<b>Çizelge 3.2:</b> Uygulama 1'de kullanılan özellikler .....	60
<b>Çizelge 3.3:</b> CinC2016 veri seti üzerindeki performans sonuçları .....	61
<b>Çizelge 3.4:</b> CirCor2022 veri seti üzerindeki performans sonuçları.....	62
<b>Çizelge 3.5:</b> Literatürdeki farklı çalışmalarda sunulan performans değerleri.....	63
<b>Çizelge 3.6:</b> Önerilen uygulamada kullanılan derin ağ mimarisi.....	67
<b>Çizelge 3.7:</b> Kullanılan modelin performansı ve doğruluk sonuçları .....	68
<b>Çizelge 3.8:</b> CinC2016 ve CirCor2022 veri setlerini kullanarak yapılan farklı araştırmalarda sunulan benzer çalışmalar .....	68
<b>Çizelge 3.9:</b> YAK algoritması parametreleri .....	71
<b>Çizelge 3.10:</b> Önerilen uygulamada kullanılan ESA mimarisi .....	73
<b>Çizelge 3.11:</b> ESA modelimizin performansı ve doğruluk sonuçları .....	74
<b>Çizelge 3.12:</b> CinC2016 ve CirCor2022 veri setlerini kullanarak yapılan farklı araştırmalar ve bunlarda elde edilen sonuçlar.....	74
<b>Çizelge 3.13:</b> Ön işlemden geçen EKG kompleksinin P dalgasından artefakt temizlenmesinin performans üstünde etkisi.....	77
<b>Çizelge 3.14:</b> EKG sınıflandırmak için önerilen ÇYUKSB tabanlı derin ağ mimarisi .....	78
<b>Çizelge 3.15:</b> [72]'de sunulan ve tez çalışmasında önerilen yöntemi karşılaştırmak için kodlanan derin ağ mimarisi.....	80
<b>Çizelge 3.16:</b> Önerilen yöntemin farklı parametrelerle elde edilen eğitim doğrulukları ....	81
<b>Çizelge 3.17:</b> Önerilen yöntemin test performansı ve diğer yöntemlerle karşılaştırması ...	81

## ŞEKİLLER DİZİNİ

Şekil 1.1: İnsan vücudundaki oskültasyon noktaları.....	2
Şekil 1.2: Eş zamanlı olarak toplanan EKG ve PCG kayıtları örneği.....	4
Şekil 1.3: Çeşitli PCG kayıtları.....	6
Şekil 1.4: Eş zamanlı olarak kaydedilen PCG ve EKG sinyallerini kullanarak yapılan bölümlene çalışması.....	11
Şekil 1.5: Physionet CinC2016 veri setinde birbirine çok benzeyen normal ve anormal PCG kayıtları.....	12
Şekil 2.1: Normal EKG örneği (a), AF (b) ve PAF (c).....	26
Şekil 2.2: Hata matrisi.....	27
Şekil 2.3: Ayrık dalgalık dönüşümü ile detay ve yaklaşım katsayılarının hesaplanması... 34	34
Şekil 2.4: Ampirik mod ayrıştırması.....	35
Şekil 2.5: MFKK özelliklerinin çıkarılma işleminin basamakları.....	37
Şekil 2.6: LÖKK özelliklerinin çıkarılma işleminin basamakları.....	38
Şekil 2.7: DVM parametreleri.....	47
Şekil 2.8: Evrişim katmanından özellik haritası oluşturma.....	50
Şekil 2.9: Evrişimsel sinir ağı modeli.....	50
Şekil 2.10: Havuzlama katman örneği.....	51
Şekil 2.11: Tekrarlayan sinir ağı modeli mimarisi.....	53
Şekil 2.12: Uzun-kısa süreli bellek mimarisine ait bir hücre.....	55
Şekil 2.13: Çift yönlü uzun-kısa süreli bellek mimarisi.....	56
Şekil 2.14: Yapay arı kolonisi.....	57
Şekil 3.1: Ön işlem aşamasında izlenen adımlar.....	59
Şekil 3.2: PCG çerçevelerinden çıkarılan özel frekans bantlarındaki sinyallerin MFKK değerlerinin ESA modeli sınıflandırılması.....	64
Şekil 3.3: Sentetik $X(t)$ sinyalinin FD ile hesaplanan frekans genlik değerleri (solda). $X(t)$ üstünde önerilen AMA tabanlı filtrenin uygulanmasından sonra elde edilen sinyalin FD ile hesaplanan frekans genlikleri (sağda). .....	65
Şekil 3.4: Sentetik $X(t)$ sinyalinin FD ile hesaplanan frekans genlik değerleri (solda). $X(t)$ üstünde önerilen filtrenin uygulanmasından sonra TDD ile elde edilen sinyalin FD ile hesaplanan frekans genlikleri (sağda). .....	65
Şekil 3.5: Önerilen uygulamanın adımları.....	70
Şekil 3.6: 3 saniyelik PCG çerçevesi (a), bölümlene sonrası kırılan 1 saniyelik çerçeve (b) ve KZFD spektrogram (c).....	72
Şekil 3.7: Tek bir kardiyak döngü boyunca gözlemlenen EKG sinyali.....	75
Şekil 3.8: Önerilen yöntemin eğitim aşaması.....	76
Şekil 3.9: EKG kayıtlarının sınıflandırılmasında kullanılan karar alma algoritması.....	79



## SEMBOLLER VE KISALTMALAR

<b>ADD</b>	: Ayrık Dalgacık Dönüşümü
<b>AFD</b>	: Ayrık Fourier Dönüşümü
<b>AKD</b>	: Ayrık Kosinüs Dönüşümü
<b>ÇYUKSB</b>	: Çift Yönlü Uzun-Kısa Süreli Bellek
<b>DD</b>	: Dalgacık Dönüşümü
<b>DDB</b>	: Düzeltilmiş Doğrusal Birim
<b>DVM</b>	: Destek Vektör Makineleri
<b>DSÖ</b>	: Dünya Sağlık Örgütü
<b>FD</b>	: Fourier Dönüşümü
<b>GYMM</b>	: Gizli Yarım Markov Modeli
<b>HFD</b>	: Hızlı Fourier Dönüşümü
<b>KEYK</b>	: K En Yakın Komşu Algoritması
<b>KYÜ</b>	: Kapılı Yinelemeli Üniteler
<b>KZFD</b>	: Kısa Zamanlı Fourier Dönüşümü
<b>LÖK</b>	: Lineer Öngörülü Kodlama
<b>LÖKK</b>	: Lineer Öngörüm Kepstrum Katsayıları
<b>MFKK</b>	: Mel-Frekans Kepstrum Katsayıları
<b>PCG</b>	: Fonokardiyogram
<b>RO</b>	: Rastgele Orman (Sınıflayıcısı)
<b>SDD</b>	: Sürekli Dalgacık Dönüşümü
<b>TDD</b>	: Ters Dalgacık Dönüşümü
<b>TFD</b>	: Ters Fourier Dönüşümü
<b>TSA</b>	: Tekrarlayan Sinir Ağı
<b>UKSB</b>	: Uzun-Kısa Süreli Bellek
<b>ZİGY</b>	: Zaman İçinde Geri Yayılım
<b>μ</b>	: Artimetik Ortalama
<b>Ö</b>	: Özgüllük (Specificity)
<b>H</b>	: Hassaslık (Sensitivity)
<b>D</b>	: Doğruluk (Accuracy)

# ÖZET

Doktora Tezi

## KARDİYOVASKÜLER RAHATSIZLIKLARIN YAPAY ÖĞRENME YÖNTEMLERİYLE TEŞHİSİ

Ali Fatih GÜNDÜZ

İnönü Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Bilgisayar Bilimleri Anabilim Dalı

97+IX sayfa

2023

Danışman: Prof. Dr. Muhammed Fatih TALU

Oskültasyon ve fonokardiyografi kalp seslerinin analizi için uzun yıllardan beri kullanılan yöntemlerdir. Hekimlerin kalp seslerini dinleyerek teşhis yapması ise dinleyicinin yeterli tecrübe ve yeteneğe sahip olmasına bağlıdır. Klinik tecrübeye sahip olmayan stajyerler ve kariyerlerinin başlarında olan hekimler için bu seslerin yüksek doğrulukla ayırt edilip yorumlanması zor bir görevdir. İnsan kulağının dinleme becerisine dayanan oskültasyon subjektif bir konu olup aynı kalp sesleri farklı dinleyenler tarafından değişik şekillerde yorumlanabilir. Ayrıca uzman hekimlerin bulunmadığı veya onlara ulaşmanın zor olduğu kırsal bölgelerde, evde bakım ünitelerinde ve taşradaki sağlık merkezlerinde kalp seslerinden kardiyovasküler hastalıkları tespit etmede yararlanmak için bilgisayar destekli sistemlere ihtiyaç duyulmaktadır.

Bu tez çalışmasında uzman hekimlere kalp seslerinden üfürümlerin teşhis edilmesinde yardımcı olacak bilgisayar destekli yöntemler geliştirilmiştir. Önerilen yöntemlerde veri madenciliği ve yapay zekâ tabanlı yaklaşımlar kullanılmıştır. Bu amaçla öncelikle normal/anormal PCG kayıtlarını sınıflandırmada klasik makine öğrenmesi yaklaşımlarının performansları incelenmiştir. Bu yöntemler, geliştirilen orijinal yöntemlerin performanslarını kıyaslamak için kullanılmıştır. Önerilen ikinci uygulamada kalp sesleri filtrelenerek bunlardan çıkarılan MFKK özellik matrisleriyle evrişim ve çift yönlü uzun-kısa süreli bellek katmanlarına sahip bir derin ağ modeli eğitilmiştir. Gerçekleştirilen üçüncü yöntemde PCG kayıtlarından Yapay Arı Kolonisi algoritmasıyla entropi ve enerji değerlerini optimize ederek çerçeveler çıkarılmıştır. Bu çerçevelerden çıkarılan spektrogramlar, evrişim ve çift yönlü uzun-kısa süreli bellek birleşimi katmanlarına sahip derin ağ modeliyle sınıflandırılmıştır. Son olarak normal ve aritmi içeren EKG kayıtlarını sınıflandırmada çift yönlü uzun-kısa süreli bellek modeliyle uzun-kısa süreli bellek katmanlarıyla desteklenmiş evrişimsel sinir ağı modeli karşılaştırılmıştır.

Önerilen sistemler halka açık veri setleri üzerinde test edilmiş ve performans değerleri karşılaştırılmıştır. Önerilen uygulamalarla yapılan deneylerde alınan performans sonuçları diğer güncel yöntemlerle yarışır düzeydedir. Geliştirilen bu yöntemler karar almada hekimlere yardımcı olabilecek bir düzeydedir.

**Anahtar Kelimeler:** PCG, Kalp Sesleri, Kalp Üfürümü, Oskültasyon

## ABSTRACT

Phd. Thesis

### DIAGNOSIS OF CARDIOVASCULAR DISORDERS BY MACHINE LEARNING METHODS

Ali Fatih GÜNDÜZ

Inonu University  
Graduate School of Nature and Applied Sciences  
Department of Computer Engineering

97+IX papers

2023

Supervisor: Prof. Dr. Muhammed Fatih TALU

Auscultation and phonocardiography are heart sound analyzing methods which have been preferred by clinicians for many years. Physicians make diagnosis by listening to the heart sounds but this task depends on the listeners' having sufficient experience and ability. For interns and young physicians, distinguishing and interpreting these sounds with high accuracy is a difficult task. Auscultation, which is based on the listening ability of the human ear, is a subjective matter and the same heart sounds can be interpreted in different ways by different listeners. In addition, computer aided systems are needed to use heart sounds to detect cardiovascular diseases in rural areas, home care units and rural health centers where specialist physicians are not available or it is difficult to reach them.

In this thesis, computer aided methods have been developed to help specialist physicians in diagnosing murmurs from heart sounds. Data mining and artificial intelligence-based approaches are used in the proposed methods. For this purpose, firstly, the performances of classical machine learning approaches in classifying normal/abnormal PCG records were examined. These methods were used to compare the performances of the original methods developed. In the second proposed application, a deep network model with convolution and bidirectional long-short-term memory layers is trained with MFCC feature matrices extracted by filtering heart sounds. In the third method, frames were extracted from PCG records by optimizing entropy and energy values with the Artificial Bee Colony algorithm. The spectrograms extracted from these frames are classified by the deep network model with convolution and bidirectional long-short-term memory combination layers. Finally, the bidirectional long-short-term memory model and the convolutional neural network model supported by long-short-term memory layers were compared in classifying normal and arrhythmic ECG recordings.

The proposed systems are tested on publicly available datasets and their performance values are compared. The performance results obtained in the experiments with the suggested applications are at the level of competition with other current methods. These developed methods are at a level that can help physicians in decision-making.

**Keywords:** PCG, Heart Sounds, Heart Murmur, Auscultation

## 1. GİRİŞ

Kardiyovasküler sistem, kanın vücutta dolaşarak pek çok görevler yürütmesini sağlar. Merkezde kalbin yer aldığı bu sistem vücudun her tarafına yayılan atar, toplar ve kılcal damarlar ağından oluşur. Kalpten pompalanarak bu damarlarda gezinen kan hücreleri bu sistematik dolaşım işlemi sırasında vücut hücrelerine oksijen, besin maddelerini taşıırken karbondioksit ve hücrenel atık ürünlerin uzaklaştırılmasında görev alır.

Kardiyovasküler sistemin merkezi olan kalp, birbirinden septum adı verilen duvarlarla ayrılmış dört odacıktan oluşur. Bu odacıklar sağ karıncık, sağ kulakçık, sol karıncık ve sol kulakçıktır. Septum, sağ taraftaki odacıklarda bulunan kanın sol taraftaki odacıklarda bulunan kanla karışmasını engeller. Aynı tarafta yer alan karıncık ve kulakçıklar arasında ise kalp kapakçıkları yer alır. Bu kapakçıkların açılıp kapanmasıyla kan bir odacıktan diğerine geçer. Kanın kalp odacıklarının birinden diğerine, oradan da damarlar yoluyla vücuda yayılması, sinoatrial düğümünden tetiklenen elektriksel uyarılarla başlar. Kalbin uyarılmasına bağlı olarak kasılması ve arkasından gevşemesi ritmik olarak gerçekleşir ve bu süreç kardiyak döngü olarak adlandırılır. Sağlıklı yetişkinlerde normal şartlar altında dakikada 60-100 arası kalp atımı (nabız) görülür.

Modern tıbbın günümüz teknolojisini kullanarak pek çok sağlık problemini çözümede büyük gelişmeler gösterdiği bir gerçektir. Buna rağmen Dünya Sağlık Örgütü'ne (DSÖ) göre her yıl 17,9 milyon insan kardiyovasküler hastalıklardan kaynaklı olarak yaşamını yitirmektedir [1]. Ayrıca inme, kalp yetmezliği, kalp krizi ve diğer komplikasyonlar sebebiyle yaşam kalitesini olumsuz etkilemektedir. Dolayısıyla kalp rahatsızlıklarını erkenden teşhis etmek, tanımlamak ve takibini yapmak oldukça önemlidir.

Genetik olarak yatkınlığa sahip bireyler, ailesinde bu tür hastalıklara yakalananlar, sigara/alkol kullananlar, obezite/diyabet hastaları ve yeterli spor yapmayanlar risk grubunu oluşturmaktadır. Özellikle risk grubundaki bireylerin kan basıncı, kan şekeri düzeyi, kolesterol gibi değerleri düzenli olarak kontrol etmeleri tavsiye edilmektedir [2].

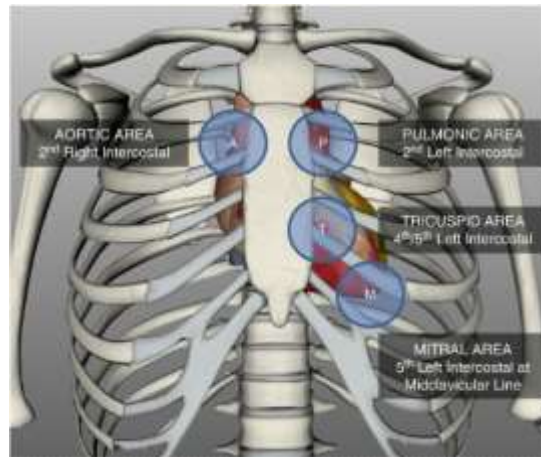
Hastanelerde, aile sağlık merkezlerinde ve evlerde kişisel bakım amacıyla kalp sağlığını ölçmek için kullanılan çeşitli biyolojik verileri kullanan cihazların yanı sıra günümüzde

yapay zeka ile desteklenmiş bilgisayar destekli sistemler de kullanıma sunulmuştur. Makine öğrenimine dayanan bu sistemler doğal olarak alan bilgisine dayalı manuel özellik mühendisliğine gereksinim duyar. Bu sistemlerin geliştirilmesinde uzmanlar tarafından incelenerek etiketlenmiş veri setleri kullanılır.

Bu sistemlerle vücudun sıcaklık, akustik, elektriksel, optik ve radyolojik verileri toplanıp işlenmektedir. Ayrıca bu biyolojik sinyallerin işlenmesiyle gizli özelliklerinin çıkarılması ve otomatik olarak yorumlanabilmesi mümkündür. Bilgisayar destekli sistemler tüm bu özellikleriyle uzman hekimlere teşhis ve tanı sürecinde yardımcı olacak bir araç görevi görmektedir.

Bu amaçla kullanılan sistemlerden birisi de kalp seslerinin incelenmesine dayanan bilgisayar destekli kalp sesi inceleme teknikleridir. Kalp sesi incelemeleri gürültü giderme, bölümlenme, öznelik çıkarma ve sınıflandırmayı içerir. Kardiyak döngü sırasında kalbin kasılıp gevşemesi sonucunda meydana gelen mekanik olaylar göğüs kafesi üstünden duyulabilen sesler oluşturur. Kardiyovasküler hastalıkları teşhis etmek için pek çok alternatif olmasına rağmen, birçok uzman hekimin ilk tercihi stetoskop kullanarak vücut seslerini dinlemek (oskültasyon) olmaktadır çünkü pratik, ucuz ve invaziv olmayan bir yöntemdir.

İnsan vücudunda göğüs kafesi üzerindeki dört belli nokta üstünden oskültasyon yapılır. Bunlar aort, pulmoner, triküspid ve mitral odak noktalarıdır. Bu odak noktaları yakın oldukları kalp kapakçığına göre isimlendirilmişlerdir. Şekil 1.1’de bu dinleme noktaları gösterilmiştir.



**Şekil 1.1:** İnsan vücudundaki oskültasyon noktaları. Kaynak [3]

Anormal sesler duyulduğunda bunlar dinleyen kişi tarafından Levine ölçeği denilen 6 puanlık bir sistemle derecelendirilir [4]. Oskültasyon uygulaması, uygulayıcısı iyi bir

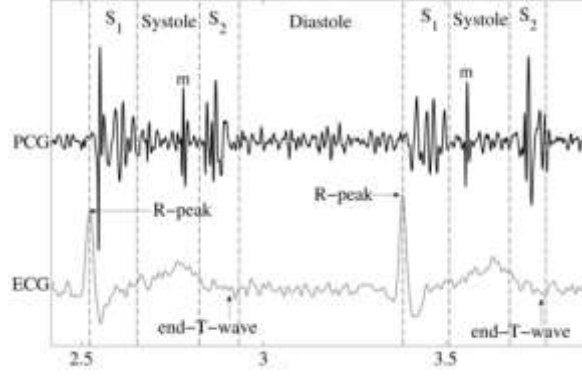
dinleme becerisine ve deneyime sahip olduđu sürece başarılı bir yöntemdir. Ancak insan kulağının fiziksel sınırlamaları ve bahsedilen işlemin subjektif yapısı aynı seslerin farklı dinleyiciler tarafından farklı değerlendirilmesine yol açabilmektedir. Ayrıca yeterli deneyime sahip olmayan klinisyenler için de oskültasyon sonuçlarını yüksek doğrulukla yorumlamak zor bir görevdir. Geleneksel stetoskopların kullanıldığı oskültasyon yönteminin bu dezavantajları modern fonokardiyograf cihazlarının kullanımı ile aşılmıştır.

Fonokardiyografi yöntemiyle kalpten gelen sesler yüksek duyarlılıkla kaydedilip fonokardiyogram (phonocardiogram - PCG) ismindeki kayıtlarda çizelge biçiminde gösterilir. Kalp seslerinin bu yöntemle dijitalleştirilerek kaydedilmesi kayıtların bilgisayar ortamında saklanabilmesine, tekrar tekrar incelenebilmesine, uzun süreli depolamaya, aynı kayıt üstünde farklı uzmanlardan farklı zamanlarda görüş alınabilmesine ve grafiksel olarak görselleştirmeye olanak sağlamıştır.

### **1.1 Kalp Seslerinin Analizi**

Normal şartlar altında sağlıklı bir kalbin çalışması esnasında birbirini takip eden iki ses (S1 ve S2) duyulur. Bunlara temel kalp sesleri denir. S1 ile S2 arasında yer alan kısa süreli sessiz kısım sistol ve S2 ile S1 arasında yer alan kısa süreli sessiz aralığa diyastol denir. Her iki temel kalp sesi de iki bileşenden oluşur. Mitral kapakçığın kapanmasıyla meydana gelen M1 ve triküspit kapakçığın kapanmasıyla meydana gelen T1 sesleri S1'i oluşturur. Benzer şekilde aortik kapakçıktan gelen A2 ve pulmoner kapakçıktan gelen P2 isimli sesler de S2'nin bileşenleridir. Normal şartlar altında hem M1-T1 hem de A2-P2 arasında 30 milisaniyeden daha kısa bir zaman vardır [5] ancak bazı anormal durumlarda bu süre aşılır ve S1/S2 sesleri parçalı sesler gibi duyulabilir.

PCG kayıtlarında temel kalp seslerinin yanında bazen üçüncü ve dördüncü kalp sesleri (S3 ve S4) duyulabilir [6]. S3 ve S4 ekstra kalp sesleri olarak da adlandırılır ve yetişkinlerde çoğunlukla duyulmaz. Mevcut olmaları halinde S3 diyastol başlarında ve S4 ise S1'in başlangıcından hemen önce geç diyastolde gerçekleşir. S3 sesine hamilelerde ve çocuklarda rastlanabilir ancak S4'nin duyulması patolojik bir bulgudur.



**Şekil 1.2:** Eş zamanlı olarak toplanan EKG ve PCG kayıtları örneği. PCG bölümleri (S1, sistol, S2 ve diyastol) kesikli çizgilerle ayrılmıştır. Kaynak [7]

Kardiyak döngü içerisindeki temel kalp seslerinin başlangıç ve bitiş noktalarını tespit etmeye bölümlenme denir. Bölümlenme işleminde PCG kaydındaki ses sinyali S1, onu takip eden sessiz bir aralık olan sistol, S2 ve ikinci bir sessiz aralık olan diyastol olmak üzere dört bölgeye ayrılır [7], [8]. Bölümlenme aşamasında PCG verisinin karakteristik özellikleri kullanılabilir. Bu özelliklerin başında birincil ve ikincil kalp seslerinin sürelerinin tahmini olarak bilinmesi gelmektedir. Schmidt ve diğ. [9] göre bu bölümlerin beklenen süreleri Çizelge 1.1’de verilmiştir.

**Çizelge 1.1:** Kardiyak döngü bölümleri ve yaklaşık süreleri. Kaynak [9]

Bölüm	Ortalama Süre (ms)	%95 Güven Aralığındaki Fark (ms)
<b>S1</b>	122	32
<b>Sistol</b>	208	80
<b>S2</b>	92	28
<b>Diyastol</b>	523	311

Tek parça bir PCG kaydı içerisindeki her bir kardiyak döngüyü tespit etmek için kullanılan yöntemlerden birisi PCG ile senkron bir şekilde ECG kaydı da almaktır. ECG kaydındaki R-R tepeleri arasındaki her bir aralık birer kardiyak döngüye karşılık gelmektedir. Bu yöntem hem zaman hem de maliyet açısından dezavantajlıdır.

Buna karşılık temel kalp seslerinin diğer bir önemli karakteristik özelliği de belli frekans bandında bileşenlerden oluşmalarıdır. S1 ve S2'nin tahmin edilebilen sürelerde olup belli frekans bileşenlerinden oluşmasından yararlanarak da PCG kayıtları bölümlenip içeriden saklı öznelikleri çıkartılabilir. Normal PCG sinyalleri, 50-250Hz’de ağırlıklı olarak bileşenler içermesine karşın çeşitli rahatsızlıklardan ötürü anormal olan PCG kayıtlarında

daha yüksek frekanslı bileşenler görülür. Çizelge 1.2’de bazı araştırmacılar tarafından yayınlanan çalışmalarda belirtilen frekans aralıkları verilmiştir.

**Çizelge 1.2:** PCG kaydında bulunan seslerin bileşenlerinin frekans aralığı (Hz)

Çalışma	S1	S2	S3	S4	Üfürüm
Khan ve diğ. [1]	40-200	50-250	*	*	*
Varghees ve Ramachandran [6]	50-150	50-200	50-90	50-80	200-600
Liu ve diğ. [10]	10-140	10-200	20-70	20-70	*-600
Ren ve diğ. [11]	20-200	20-200	15-65	15-65	*
Sun ve diğ. [12]	50-150	50-200	*	*	*-600
Xu ve diğ. [13]	20-200	20-200	*	*	20-500
Wang ve diğ. [14]	20-60	60-100	*	*	*

Bu dört kalp sesine ek olarak kalp kapakçıklarıyla ilgili doğuştan gelen yapısal bozukluklar, hamilelik, yüksek ateş ve ameliyat sonrası etkiler kalp üfürümleri olarak bilinen hafif bir sese neden olabilir. Kalp üfürümü, kalp kapağı kapanmasına rağmen kanın yanlış yönde akmaya devam etmesiyle meydana gelen hışırtıya benzer gürültülü bir sestir. Çoğunlukla kalp seslerinden daha uzun sürer. Kardiyak döngüdeki zamansal konumuna göre sistolik, diyastolik veya sürekli olarak adlandırılırlar. Şiddetlerine göre derecelendirilip kardiyak döngü içinde ortaya çıkma konumlarına göre tanımlanırlar. Üfürümlerin yoğunluğu 1 ila 6 arasında derecelendirilir. Bu dereceler şunlardır:

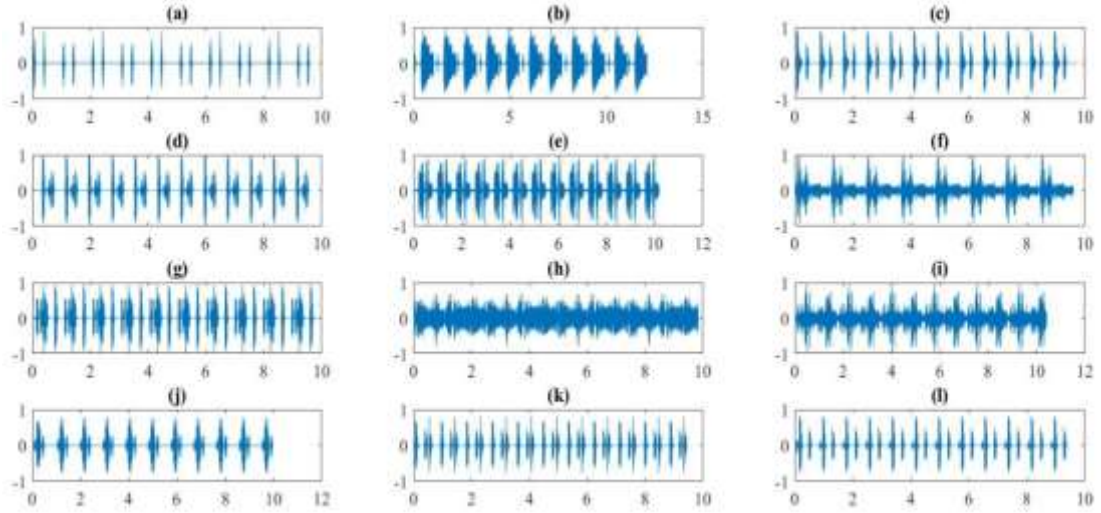
1. Derece: Yalnızca dikkatle dinlerken duyulabilir
2. Derece: Hafif üfürüm, ancak hemen duyulabilir
3. Derece: Yüksek sesli üfürüm, kolayca duyulabilir
4. Derece: Titremeli yüksek sesli üfürüm
5. Derece: Stetoskopun göğse değmesiyle duyulabilecek kadar yüksek üfürüm
6. Derece: Stetoskop göğüsten kaldırılmış haldeyken bile duyulabilecek kadar yüksek ses

Ayrıca kalp üfürümleri, kalp atışında ne zaman ortaya çıktıklarına göre şöyle sınıflandırılır:

- Sistolik: Kalp kası kasıldığında ortaya çıkan üfürüm.
- Diyastolik: Kalp kası gevşediğinde ortaya çıkan üfürüm.
- Sürekli: Kalp kasının hem kasılması hem de gevşemesi sırasında sürekli bir kalp üfürümü olur.

Kalp üfürümlerinin bir kısmı zararsız olup *masum üfürüm* olarak adlandırılır. Bununla birlikte üfürümler çeşitli kardiyovasküler rahatsızlıkların habercisi de olabilirler. Şekil 1.3’te bazı normal ve üfürüm içeren PCG kayıtları gösterilmiştir.





**Şekil 1.3:** Çeşitli PCG kayıtları. Yatay eksen zaman (sn) ve dikey eksen genlik. a: normal, b: aort yetmezliği, c: erken aort darlığı, d: geç aort darlığı, e: kulakçık-septal kusur, f: mitral yetersizlik, g: mitral darlık, h: açık- duktus-arteriozus, i: perikardiyal sürtünme, j: pulmonik-stenoz, k: s3 mevcudiyeti, l: s4 mevcudiyeti. Veriler University of Washington Heart Sound veri tabanından wav formatında elde edilmiş ve MATLAB ortamında grafiğe dönüştürülmüştür.

Herhangi bir ses sinyali gibi, kalp sesleri de zamanda süreklidir. Dijital ortamda ise sürekli sinyaller ile çalışmak sonsuz hafıza gerektireceğinden mümkün değildir. Dolayısıyla incelenmek istenen ses sinyalinden uygun bir çözünürlükte örnekler alınarak ayrık zamanda sinyalin dijital versiyonu üstünde çalışılır. Sinüzoidal bir sinyalin geçmiş değerlerine bakılarak gelecekte alacağı değerler hesaplanabilir. İncelenen küçük bir aralık sinyalin genlik, faz ve frekans bilgilerini doğru bir şekilde kavramak için yeterlidir. Tüm biyolojik sinyaller gibi PCG de sinüzoidal sinyallerin aksine deterministik değildir ve istatistiksel momentleri zamanla değişebilmektedir. Kalbin atışı sırasında heyecan, korku, sevinç gibi faktörlerle atım hızının değişmesi buna sebep olur. Bu karakteristikteki sinyallere *durağan olmayan* sinyaller denir.

## 1.2 Literatür İncelemesi

Bu kısımda çeşitli araştırmalarda kullanılmış olan PCG veri setleri ve bunları kullanarak geliştirilen bölümlenme, sınıflandırma ve gürültü temizleme yöntemlerinden bahsedilmiştir.

### 1.2.1. Literatürde kullanılan veri setleri

PCG araştırmalarında kullanılan veri setlerini iki kategoriye ayırabiliriz. Bunlardan ilki çeşitli organizasyonlar tarafından hazırlanıp, etik izinleri alınmış olarak tüm araştırmacıların

kullanımına açılmış olan umumi veri setleridir. İkinci kategoride yer alan özel veri kümeleri ise araştırmacılara, hastanelere veya küçük topluluklara aittir. Kullanım izinleri diğer araştırmacılara kapalı olup sınırlı sayıda çalışmada kullanılmıştır. Her iki kategoriden değişik büyüklüklerde veri setlerine literatürde rastlanmaktadır. Bu veri setlerinden özellikle eski olanları yeterli sayıda örnek içermedikleri için evrimsel sinir ağlarına dayalı modellerle çalışmak için uygun değildir. Ayrıca PCG kayıtlarının alındığı hasta gruplarının yaş ve cinsiyet gibi özellikleri değişiklik göstermektedir. Çocuklardan ve gençlerden oluşan veri kümelerinin yetişkin hastalardan alınanlara kıyasla daha yüksek kalp ritmi değişkenliği göstermesi beklenmektedir [15]. Birçok çalışmada yüksek doğruluk oranları sunulmasına rağmen özel veri setlerinin kullanılması nedeniyle bu çalışmalar arasında doğrudan bir karşılaştırma yapmak mümkün değildir. Araştırmacıların sadece özgün modeller geliştirmesine ve bunların performanslarını kendi aralarında kıyaslamasına olanak sunmak için çeşitli organizasyonlar yarışmalar düzenlemiş ve veri setlerini paylaşımına sunmuştur. Bu kısımda bu veri setlerinden bahsedilecektir.

### **George B. Moody PhysioNet 2022 Yarışması - CirCor Digiscope PCG Veri Seti (CirCor2022)**

Günümüzdeki en kapsamlı PCG veri tabanı olan CirCor2022 veri seti PhysioNet [16] tarafından 2022’de düzenlenen bir yarışma için paylaşılmıştır [17], [18], [19]. Yarışmanın amacı PCG kayıtlarını doğru yorumlayarak onlardan üfürüm tespiti yapılmasına yardımcı olacak açık kaynak kodlu yöntemlerin geliştirilip orijinal çalışmaların yayınlanmasıdır. Böylelikle klinisyenlere yardımcı olacak bilgisayar destekli otomatik yöntemlerin teşhis sürecindeki potansiyelinin keşfedilmesi hedeflenmektedir.

PCG kayıtları Brezilya’nın kırsal kesimlerinde yaşayan pediatri grubunu oluşturan bebek, çocuk ve genç hastalardan toplanmıştır. Toplamda 1568 kişiden alınan 5272 PCG kaydı uzman hekimler tarafından manuel olarak etiketlenmiştir. Littmann 3200 elektronik bir fonokardiyogram cihazı kullanılarak vücuttaki dört belli dinleme konumundan (aort, pulmoner, triküspid ve mitral odaklardan) kayıt alınmıştır. Her hastadan değişik sayıda kayıt alınmıştır. Örnekleme frekansı 4 kHz’dir. Veri setinin %60’ı eğitim amacıyla halka açılmış olup %30’luk test ve %10’luk doğrulama kısımları yarışmada kullanılmıştır.

Bazı hastalar için verilen dört ölçüm noktasının tamamından dinleme yapılırken bazılarında daha az sayıda PCG kaydı alınmıştır. Kayıt sayısı, lokasyonu ve süresi hastalar arasında değişmektedir. Veri seti ayrıca hastanın cinsiyet, boy, kilo ve yaş gibi istatistiki bilgilerini de içermektedir. Hastalardan alınan veriler uzman pediatri kardiyologları tarafından

incelenerek veri seti **üfürüm içeren, üfürüm içermeyen ve belirsiz** olmak üzere üç sınıfa ayrılmıştır. Kayıtların uzunlukları 4,8 ile 80,4 sn arasında değişmektedir. Sürelerin ortalaması 22,9 saniye ve standart sapması 7,4 saniyedir.

Yarışmacıların MATLAB veya Python'da geliştirilen kodları GitHub/Gitlab depolarından indirilerek Google Cloud ortamında çalıştırılmıştır. Önerilen her çözüm için 52 GB RAM, 8 virtual CPU, 50 GB lokal hafıza ve isteğe bağlı olarak bir GPU (NVIDIA T4 Tensör çekirdek, 16 GB VRAM) sunulmuştur. GPU kullanmayanlar için 72 saatlik ve GPU kullananlar için 48 saatlik bir maksimum eğitim süresi kısıtı uygulanmıştır.

### **PhysioNet Computing in Cardiology 2016 Yarışması Veri Seti (CinC2016)**

CirCor2022'ye benzer şekilde CinC2016 veri seti de PhysioNet [16] tarafından 2016 yılında düzenlenen bir yarışmada paylaşımına açılmıştır [10]. CirCor2022 veri seti online olarak paylaşımına açılmasından önce en kapsamlı veri tabanıydı [10], [20]. Bu veri seti yedi ayrı grup tarafından toplanan dokuz bağımsız PCG veri kümesinin birleşiminden oluşmaktadır. Veriler dünyanın farklı yerlerindeki araştırmacılar tarafından farklı şartlar altında toplanmıştır. Dolayısıyla kullanılan donanım, veri kalitesi, etiketleme detayları ve örnekleme frekansları heterojenlik göstermektedir. CinC2016 veri tabanını meydana getiren bağımsız veri kümeleri şunlardır:

- Massachusetts Institute of Technology heart sounds database (MITHSDB)
- The Aalborg University heart sounds database (AADHSDB)
- The Aristotle University of Thessaloniki heart sounds database (AUTHHSDB)
- Toosi University of Technology heart sounds database (TUTHSDB)
- The University of Haute Alsace heart sounds database (UHAHSDB)
- The Dalian University of Technology heart sounds database (DLUTHSDB)
- The Shiraz University adult heart sounds database (SUAHSDB)
- The Skejby Sygehus Hospital heart sounds database (SSHHSDB)
- The Shiraz University fetal heart sounds database (SUFHSDB)

Dokuz farklı gruptan oluşan verileri homojen bir yapıya dönüştürebilmek için PCG kayıtları 2 kHz'e yeniden örneklenmiştir. PCG kayıtları 5-120 saniye aralığında farklı sürelerle sahiptir. Kayıtlar 16 bit çözünürlükte mono kanal wav dosya formatında paylaşılmıştır. Tüm PCG kayıtları **normal** veya **anormal** olarak etiketlenmiştir. Bununla birlikte emin olunamayan örnekler için **belirsiz** sınıflandırma cevabı da kabul edilmiştir. Yarışma

kapsamında veri kümeleri eğitim/test grupları olarak ayrılarak yarışmacıların erişimine sadece eğitim setleri açılmıştır.

### **Pattern Analysis, Statistical modelling and ComputAtional Learning (PASCAL)**

PASCAL [21] veri tabanı 2011 yılında düzenlenen yarışmalar için paylaşıma açılmıştır. Yarışma hem kalp seslerinin bölütlenmesini hem de sınıflandırılmasını içermektedir. PASCAL veri tabanı A ve B olarak isimlendirilen iki veri setine ayrılmıştır. Birinci grup dört sınıftan oluşurken, ikinci grup sadece üç kalp sesi kategorisine sahiptir. Örnekleme frekansı 44100Hz olup PCG kayıtları wav formatında saklanmıştır. PCG kayıtlarının süreleri 1-30 saniye arasında değişmektedir. PASCAL veri seti geçmişten günümüze çeşitli araştırmalarda kullanılmıştır ve halen kullanılmaktadır [20].

### **E-General Medical**

Veri setinin sahibi olan E-General Medical, iyi bilinen bir tıbbi ekipman ve veri seti satış firmasıdır. PCG veri seti 64 PCG kaydından oluşmaktadır. İçerisinde normal sesler, S3, S4 ve farklı patolojik durumlardan kaynaklanan üfürümler bulunan örnekler mevcuttur [10].

### **Thinklabs Heart Sound Library**

10-50 saniye aralığında 105 PCG kaydından oluşmaktadır. Thinklabs'ın YouTube kanalından erişilebilir: <https://www.youtube.com/c/Thinklabs1>.

### **University of Washington Department of Medicine**

Waveform ses dosya formatında paylaşılan veri seti farklı türden üfürümler, bölünmüş kalp sesleri, normal ve patolojik durumlar içermektedir. <https://depts.washington.edu/physdx/heart/tech1.html> adresinden erişilebilir.

### **Cardiac Auscultatory Recording Database (CARD)**

John Hopkins Ayakta Tedavi Merkezi Pediatrik Kardiyoloji Kliniğine ait bir veri setidir. CARD, gönüllü hastalardan eş zamanlı olarak alınan PCG ve EKG kayıtlarından oluşturulmuştur. CARD ayrıca sorumlu kardiyolog tarafından açıklanan her vaka için klinik verileri içerir. 1200'den fazla hastadan elde edilen 20 saniye süreli kayıt içermektedir [22]. PCG kayıtları wav dosya formatındadır ve örnekleme frekansı 4 kHz'dir.

### **Multiple Features Heart Sound Signal Database (MFHSSD)**

MFHSSD veri seti iki tıp kitabı kaynağında (Auscultation skills CD, Heart sound made easy) ve çeşitli web sitelerinde (Washington, Texas, 3M ve Michigan dahil olmak üzere 48 farklı web sitesi) halka açık olarak paylaşılan PCG kayıtlarının Yaseen ve diğ. [23] tarafından

derlenmesiyle oluşturulmuştur. Github<sup>1</sup> üzerinden online ortamda paylaşımına açılan veri seti pek çok çalışmada kullanılmıştır [24]. Veri seti beş farklı sınıftan (normal (N), aort darlığı (AS), mitral darlığı (MS), mitral yetersizliği (MR) ve mitral kapak prolapsusu (MKP)) PCG örnekleri içermektedir. Her sınıftan 200 kayıt mevcut olup toplam 1000 PCG kaydından oluşmaktadır. Kayıtlar wav formatında mono kanal olup örnekleme frekansı 8000Hz'dir.

### 1.2.2 PCG bölümlenme çalışmaları

PCG kayıtları üzerinde yapılan çalışmalardan birisi de kalp seslerinin bölümlenmesidir. Bölümlenme başlı başına bağımsız bir çalışma olarak yapılabildiği gibi ayrıca sınıflandırma çalışmalarından önce bir ön işlem olarak da kullanılabilir. Temel kalp sesleri olan S1 ve S2'nin yüksek doğrulukla birbirlerinden ayrılmasıyla sistolik ve diyastolik zaman aralıkları ortaya çıkarılmaktadır. PCG kaydında duyulan kalp sesleri farklı kaynaklardan gelen ve dolayısıyla anlamsal olarak farklı yorumlanan zamansal bileşenler içerir. Tüm sağlıklı insanlarda duyulması beklenen S1, S2 sesleri ve bunlar arasında yer alan sessiz aralık, PCG analizinde sık kullanılan işitsel bölgeleri tanımlar.

Pek çok çalışmada PCG kaydındaki sinyal bir bütün olarak işlenmektense ilk aşamada S1, sistol, S2 ve diyastol isimli bölümlere ayrılır [25]. Bununla birlikte üfürüm içeren PCG kayıtlarını otomatik olarak bölümlenmek zor bir görev olup S1, sistol, S2 ve diyastol bölümlerinin başarılı bir şekilde ayrılabilmesi bu basamağa dayalı olarak geliştirilen sınıflama metodlarının genel başarısını olumsuz etkiler [26].

Literatürdeki çalışmaların bir kısmı bölümlenme için PCG ile eş zamanlı olarak kaydedilen EKG verisini kullanmıştır [27], [28]. S1, sistolün başlangıcında atriyoventriküler kapakların kapanmasıyla başlar ve EKG'de R tepesi ile işaretlenen ventriküler depolarizasyondan hemen sonra ortaya çıkar. PCG kaydına ek olarak kardiyak döngünün başlangıç ve bitişinin kolayca ayırt edilebildiği EKG verisini bölümlenmede kullanmak büyük bir kolaylıktır. Çünkü PCG verisinde EKG'ye kıyasla gürültü potansiyeli daha fazladır [29].


El-Segaier ve diğ. [30] çalışmalarında PCG ile senkron olarak toplanmış EKG verisini kullanmıştır. EKG sinyalini düşük frekansa sahip artefakt etkisinden kurtarmak için yüksek geçiren filtre ile filtrelemişlerdir. Ardışık R-R tepeleri arasındaki süreleri hesaplayıp, bunlardan kendinden öncekinden %60 kadar farklılık gösterenleri göz ardı etmişlerdir. PCG sinyalindeki S1 olarak 0,05 R-R ila 0,2 R-R kadar aralık içindeki en yüksek spektral güce

---

<sup>1</sup> <https://github.com/yaseen21khan/Classification-of-Heart-Sound-Signal-Using-Multiple-Features-/blob/master/README.md>

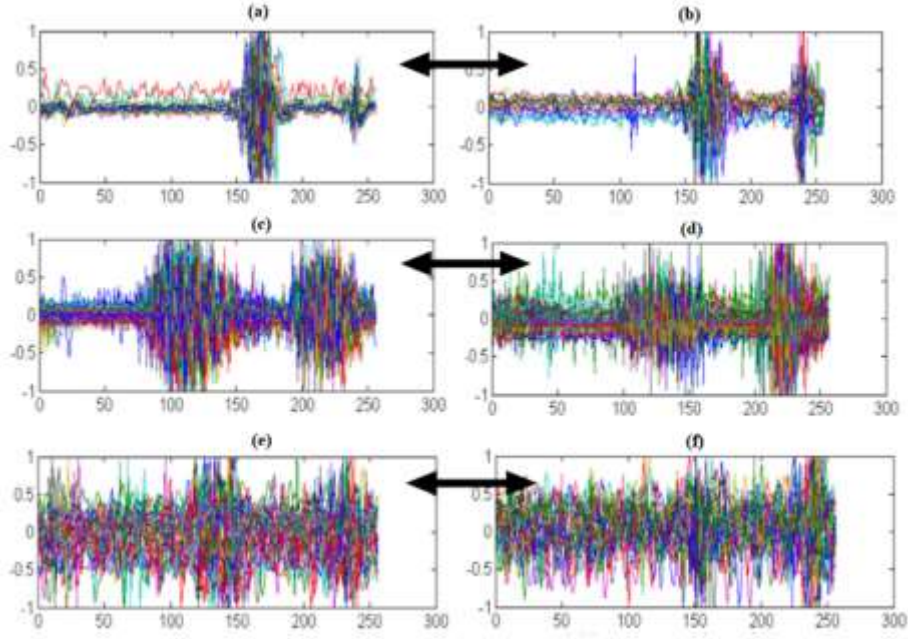
sahip olan tepe formasyonuna sahip bölgeyi seçmişlerdir. S2'nin tespiti de benzer şekilde 1,2 R-T ile 0,6 R-R aralığında R-dalgaları ve T-dalgalarının tepeleri referans olarak kullanılarak gerçekleştirilmiştir.

Bir başka çalışmada Safara ve diğ. [31] EKG ve PCG sinyalleri arasındaki korelasyonu PCG sinyallerini bölümlere ayırmak için kullanmıştır. EKG içerisinde yer alan ve QRS yapısı olarak adlandırılan kısım sinyalin geri kalanından daha fazla enerjiye sahiptir. Bir EKG'de işaretlenen R tepesi senkron olarak kaydedilmiş bir PCG sinyalinde S1'e referans olmaktadır. Buradan da örnekleme frekansını ve temel kalp seslerinin ortalama sürelerini göz önünde bulundurarak bölümlenme yapılmıştır.



**Şekil 1.4:** Eş zamanlı olarak kaydedilen PCG ve EKG sinyallerini kullanarak yapılan bölümlenme çalışması. Kaynak [31]

Uzun zamandan beri kullanılan bir yöntem olmasına rağmen bölümlenme için eş zamanlı olarak kaydedilmiş EKG verisi kullanmak maliyetli ve zaman alıcıdır. Bunun yerine doğrudan doğruya PCG kullanarak yapılan bölümlenme çalışmaları da literatürde mevcuttur. Sadece PCG kullanarak geliştirilen bölümlenme uygulamalarından doğru sonuçlar alabilmek için çözülmesi gereken bazı problemler vardır. Bu yöntemlerin karşılaştığı başlıca zorluklar ortam sesleri, hastanın nefes alışverişi ve bağırsak hareketlerinden gelen gürültülerin etkisi, T1-M1 ve A2-P2'nin parçalı sesler olarak kayda girmesi, S3, S4 ve kalp üfürümlerinin bulunması olarak sıralanabilir. Ayrıca, normal ve anormal PCG kayıtları arasındaki yapısal benzerlikler, sınıflandırma görevini daha zorlu hale getirir. Şekil 1.5'te CinC2016 veri setinde birbirine çok benzemesine rağmen biri normal diğeri anormal olarak etiketlenmiş bazı kayıtlar gösterilmiştir.



**Şekil 1.5:** Physionet CinC2016 veri setinde birbirine çok benzeyen normal ve anormal PCG kayıtları. Normal PCG kayıtları: a, c ve e. Anormal PCG kayıtları: b, d ve f. Benzer kayıtlar oklarla gösterilmiştir. Kaynak [32]

Bölümlenme amacıyla S1 ve S2'nin başlangıç ve bitişlerini belirlemek için kullanılmakta olan pratik yöntemlerden biri de sinyallerin enerjisini ölçmektir. Bu yaklaşımda belli bir eşik değerinin üstünde kalan alan sesli, altında kalanlar ise sessiz kısımlar olarak belirlenmektedir. Bir  $S$  sinyalinin enerjisini ölçmek için kullanılan bazı yöntemler şunlardır:

$$E = \sum_{i=1}^N \log S(i)^2 \quad (1.1)$$

$$E = \sum_{i=1}^N S(i)^2 \quad (1.2)$$

$$E = \sum_{i=1}^N |S(i)| \quad (1.3)$$

$$E = - \sum_{i=1}^N S(i)^2 \log S(i)^2 \quad (1.4)$$

Ari ve Saha. [33] temel kalp seslerinin maksimum enerjilerinin 100Hz altında olduğundan ötürü S1 ve S2 dışında kalan her şeyi filtrelemek için PCG sinyaline 10. dereceden ve 150Hz alçak geçiren butterworth filtre uygulamıştır. Elde edilen sinyale eşikleme (ortalamanın üçte biri büyüklüğünde) uygulayıp 10 ms büyüklüğünde parçalara ayırdıkları çerçevelerin Shannon enerjilerini hesaplamışlardır. Bu aşamadan sonra S1, S2 ve üfürüm içeren

lokasyonlar tepeler olarak ortaya çıkmıştır. S1 ve S2'yi ayırt etmek içinse biyomedikal sinyalin şu karakteristik bilgilerini kullanmışlardır:

1. Diyastol periyodu sistolden daha uzundur.
2. Sistol periyodu genellikle diyastol periyoduna göre daha sabittir.
3. Minimum sistol süresi, tam kalp döngüsü süresinin yaklaşık %30'udur.

34 patolojik ve normal PCG kaydından oluşan bir veri seti üzerinde uyguladıkları algoritmanın genel doğruluğunu %95,5 olarak sunmuşlardır.

Papadaniil ve Hadjileontiadis [34] ampirik mod ayrışımı (AMA) kullanarak bölümlene yapmıştır. S1 ve S2'nin alçak frekansta olmasından ötürü 150Hz seviyesinde alçak geçiren 10. dereceden Butterworth filtre ile filtreledikleri sinyali AMA ile IMF bileşenlerine ayırmışlardır. IMF bileşenlerini de içerdikleri frekans olarak S1/S2'ye yakınlık ve enerjiye dayalı kriterlere bakarak elemişlerdir. Kalan IMF'leri kullanarak oluşturdukları sinyalden kurtosis değerindeki değişimi gözlemleyerek bölümlerin başlangıç ve bitiş noktalarını belirlemişlerdir.

S1 ve S2 temel kalp seslerini PCG kaydı içerisinde saptamak için Sun ve diğ. [12] AMA ile ADD tekniklerinden yararlanarak bir yöntem geliştirmişlerdir. Öncelikle AMA ile çıkardıkları IMF bileşenlerinden yüksek frekanslı olan ilk sıradakileri seçmişlerdir. Seçilen IMF'ler en fazla gürültü içeren bileşenlerdir. Bunlara daubechies-7 ADD uygulanarak elde edilen katsayılar Sun ve arkadaşları tarafından belirlenen eşik değerine göre eşiklemeye tabi tutulmuş ve arkasından ters dalgacık dönüşümü (TDD) ile gürültüden temizlenen IMF'ler yeniden oluşturulmuştur. Elde edilen yeni IMF'ler ile düşük frekansa sahip orijinal IMF'ler toplanarak PCG sinyali yeniden oluşturulmuştur. PCG sinyalinden 20 milisaniye genişliğinde normalize edilmiş Shannon enerjileri hesaplanmış ve bu sinyalin zarfı çıkarılmıştır. Zarfta 20 milisaniyeden yakın olan tepeler birleştirilerek tek bir ses olayı olarak algılanmıştır. Elde edilen zarftan S1 ve S2'nin ortalama sürdüğü zaman bilgisinden yararlanılarak bölümlene yapılmıştır.

Schmidt ve diğ. [9] S1, sistol, S2 ve diyastol durumlarını modelledikleri Gizli Yarım Markov Modeli'ni (GYMM – Hidden Semi Markov Model (HSMM)) bunların sürelerini kullanarak desteklemiştir. Her bir PCG için referans olarak kullandıkları süreler EKG'de hesaplanan R tepe noktası konumlarından yararlanarak hesaplanmıştır. Springer ve diğ. [9]'da sunulan çalışmaya özgün katkılarda bulunarak GYMM tabanlı bir bölümlene algoritması sunmuştur [7]. GYMM'de kullanılan Viterbi algoritmasına belli bir durumda tanımlı bir süre kadar



kalma olasılığını eklemişlerdir. CinC2016 yarışmasında bu çalışmanın kaynak kodları resmi olarak paylaşılarak katılımcıların kullanımına açılmıştır.

### 1.2.3 PCG kayıtlarından kalp üfürümü tespiti

Kardiyak döngü sırasında, kalbin elektriksel bir sinyalle uyarılıp bunun tetiklemesiyle sırasıyla atriyal ve ventriküler kasılmalarla devam eder. Kulakçık ve karıncıkların kasılıp gevşemesi sırasında kan kalbin odaları arasında ve vücudun etrafında dolaşıma geçer. Bu işlemlerin gerçekleşebilmesi kalp kapakçıklarının açılıp kapanması ve kanın belli bir doğrultuda akışına bağlıdır. Periyodik olarak tekrarlanan kardiyak döngü içerisinde yer alan bu aktiviteler kardiyovasküler yapıda titreşimlere ve dolayısıyla ses sinyallerine (kalp sesleri ve üfürümler) neden olur.

PCG kayıtlarından kalp üfürümü tespiti için 2016 yılında PhysioNet tarafından düzenlenen yarışmada birinci olan Potes ve diğ. [35] ön işlem aşamasında PCG kayıtlarını 1000Hz seviyesine yeniden örneklemiş ve Springer ve diğ. [7] tarafından önerilen bölümlenme yöntemiyle dört bölgeye (S1, sistol, S2 ve diyastol) ayırmıştır. AdaBoost sınıflayıcısı ile Evrişimsel Sinir Ağı (ESA) modelinin birleşiminden oluşan bir yöntem sınıflandırma yapmak için kullanılmıştır. AdaBoost sınıflayıcısının eğitimi için zaman-frekans alanından 124 özellik seçilmiştir. Diğer taraftan PCG verisi dört frekans bandına (25-45Hz, 45-80Hz, 80-200Hz ve 200-400Hz) ayrıştırılmış ve bunlar da bölümlere ayrılarak 2,5 saniye uzunluğunda tam bir kardiyak döngü her bir PCG frekans bandı içerisinde seçilmiştir. Kardiyak döngünün 2,5 saniyeden kısa olması durumlarında serinin sonuna sıfır eklenerek tamamlanmıştır. ESA modeli bu şekilde elde edilen 2,5 saniyelik çerçeveler ile eğitilmiştir. Bu iki sınıflayıcının en az birinin kendileri hakkında belirlenen eşik değeri ve üstünde sonuç vermesi halinde PCG kayıtları anormal (üfürüm içeren) olarak belirlenmiştir.

Rubin ve diğ. [36] PhysioNet 2016 yarışmasında sundukları çözüm üç aşamadan oluşmaktadır. Öncelikle değişken uzunlukta PCG kayıtları içeren CinC2016 veri setinden hepsi S1 ile başlayacak şekilde zamansal olarak hizalanmış 3 saniye uzunluğunda kesitler çıkarmışlardır. Arkasından bu kesitlerden 25 milisaniyelik pencere boyutu ve 10 milisaniyelik çakışma miktarıyla MFKK değerlerini elde etmişlerdir. MFKK filtre bankalarını ısı haritası şekline getirerek frekansların enerjilerini spektrogram formatına çevirmişler ve bunu 2 boyutlu ESA modelleri ile sınıflandırmışlardır.

Nilanon ve diğ. [37] CinC2016 veri setinden kayan pencere yöntemiyle 1 saniyelik adım boyutu ve 5 saniye pencere boyutuyla çerçeveler elde etmişlerdir. Bu yöntemle çalışılacak

örnek sayısını 3000'lerden 60000'lere kadar çoğaltarak aşırı uyum ve gürültülü kesitlerin olumsuz etkilerinden kaçınmayı amaçlamışlardır. Elde ettikleri çerçevelerden güç spektral yoğunluğunu çıkartarak bununla hem ESA modellerini hem de Destek Vektör Makineleri (DVM) sınıflandırıcısını eğitmişlerdir. Bir PCG kaydının normal/anormal olarak sınıflandırılan çerçevelerinin sayısına bakarak da o kaydı çoğunluğun durumuna göre sınıflandırmışlardır.

Tschannen ve diğ. [38] benzer şekilde PhysioNet 2016 yarışmasında kullanılan veri setini Springer ve diğ. [7] tarafından sunulan bölümlene yöntemiyle bölümlere ayırmış ve bunlardan yararlanarak kardiyak döngüleri belirlemişlerdir. Bunları ortak bir boyuta (1024 örnek) getirerek ESA modelleri ile özellik çıkarmışlardır. Ayrıca güç spektral yoğunluğundan ve bölümlerin istatistiklerinden elde edilen öznitelikleri de özellik setine katmışlardır. DVM sınıflayıcısını eğitmek için kullandıkları özelliklerle her biri birer kardiyak döngü içeren pencereleri sınıflandırmış ve çoğunluk kuralına uygun olarak genel sınıf etiketlendirmesini yapmışlardır.

Munia ve diğ. [39] tarafından CinC2016 veri setindeki PCG kayıtlarını normal ve anormal sınıflara ayırmak için beş farklı kernel ile DVM kullanılmıştır. İlk olarak [7]'de sunulan metotla bölümlere ayrılan sinyalden birer kardiyak döngüden oluşan çerçeveler çıkarılmıştır. Daubechies-2 ana dalgacıyla ADD uyguladıkları çerçevelerin sadece 2. seviyedeki detay katsayılarını kullanarak sinyalleri TDD ile yeniden oluşturmuşlardır. Elde edilen sinyallere yeniden bölümlene uygulanarak S1, sistole, S2 ve diyastol olmak üzere dört parçaya sinyaller bölünmüştür. Elde edilen parçalardan morfolojik, istatistiksel ve zaman alanı özellikleri çıkarılarak sınıflandırıcı eğitilmiştir.

Kay ve Agarwal [40] özellik çıkarımı için SDD ve MFKK kullanarak Yapay Sinir Ağı (YSA) tabanlı bir yöntem önermiştir. Özellik vektörlerinde ayrıca, bölümlenmiş sinyalden elde edilen ortalama, standart sapma ve bölümler arası oranlar gibi istatistiksel özellikler kullanılmıştır. Kullandıkları özellikler bir kalp döngüsünün uzunluğu, S1'in uzunluğu, sistol uzunluğu, S2'nin uzunluğu, diyastol uzunluğu, bunların tüm kalp döngüsü uzunluğuna oranları, sistol/diyastol oranı, S1'in ortalama genliği, S2'nin ortalama genliği, sistolün ortalama genliği, diyastolün ortalama genliği ve bunların standart sapmalarını içermektedir. Özellik çıkarımı aşamasında 600'den fazla öznitelik hesaplanmış olup bunlar Temel Bileşenler Analizi (Principal Component Analysis - (PCA)) yöntemiyle 70 özelliğe dönüştürülerek PCG kayıtları sınıflandırılmıştır.

PhysioNet 2016 yarışmasında 2. olan yöntemi öneren Zabihi ve diğ. [41] ön işlem aşamasında bölümlenme yapmamayı tercih etmiştir. Zaman, frekans ve zaman-frekans alanından çıkardıkları 18 özniteliği bütün PCG kayıtlarından çıkartarak kullanmışlardır. Önerdikleri metod iki aşamadan oluşmaktadır. İlk aşamada yer alan sınıflayıcı girdi verisinin kalitesini değerlendirerek yüksek gürültü içeren PCG kayıtlarını belirsiz olarak elemektedir. İkinci aşamada önerilen sınıflayıcı ise 20 YSA ensemble modelidir. Bu ensemble sınıflayıcı PCG kaydını nihai olarak normal veya anormal olarak sınıflandırmaktadır.

Önerdikleri çözümde bölümlenme kullanmayan başka bir yarışmacı grubu olan Langley ve Murray [42] ise CinC2016 veri seti üzerinde sabit uzunlukta sinyallerle çalışmak için PCG kayıtlarının ilk 5 saniyesini kırpılmış ve sadece bu kısmı kullanmıştır. Önerdikleri metotta Gaus-4 ana dalgacığı ile SDD uyguladıkları 5 saniyelik çerçevenin entropi ve enerji değerlerine bakarak sınıflandırma yapmışlardır. Aynı araştırmacılar başka bir çalışmalarındaysa [43] bir PCG kaydının en temiz bölümünü otomatik olarak seçmek için, tüm kayıt boyunca 1 saniyelik artışlarla 5 saniyelik dilimler için dalgacık entropisi hesaplamış ve en yüksek entropiyi sağlayan bölümü en düşük gürültülü bölüm olarak seçip PCG kaydının bu kısmını kırpmıştır. PCG kayıtlarının özellikle ilk birkaç saniyesinde hastanın nefes alışverişi ve mikrofon hareketi gibi nedenlerden gürültüye rastlanabilmektedir. Bu duruma karşı araştırmacılar, önerdikleri yeni kırpma yöntemiyle sınıflandırma doğruluğunu %76'dan %80'e çıkarabilmiştir.

CirCor2022 veri setini kullanarak kalp üfürümünün şiddetli, yumuşak veya mevcut olup olmadığını inceleyen çalışmalarında Elola ve diğ. [26] PCG kayıtlarını 3 saniyelik çerçevelere bölmüş ve bunlardan 32x239 boyutlu Mel-spektrogramları çıkartmıştır. Elde edilen bu eğitim verileri ayrıca hasta bazında toplam 15 gruba ayrılmış ve aynı katmanları fakat farklı rastgele eğitim parametrelerine sahip ensemble ESA modelleri ile çalıştırılmıştır. Bu modellerin topluluk kararı ile genel sınıflandırma yapılmıştır. Bu aşamada en az bir modelin şiddetli olarak karar verdiği PCG kayıtları şiddetli olarak sınıflandırılırken tüm modellerin üfürüm tespit etmediği kayıtlar normal olarak sınıflandırılmıştır. Diğer durumlarda ise yumuşak üfürüm kararı verilmiştir. Araştırmacılar çalışmalarında veri setinin mobil ortamlarda toplanmasından kaynaklı olarak çeşitli ortam gürültüleri içerdiğini belirterek bu durumdan ötürü özellikle bölümlenme uygulamadıklarını ifade etmişlerdir.

Fuadah ve diğ. [44] CinC2016 ve CirCor2022 veri setlerinden elde ettikleri 5 saniye uzunluğundaki PCG çerçevelerini kullandıkları çalışmada k En Yakın Komşu (KEYK), DVM, Rastgele Orman algoritması ve YSA sınıflayıcılarını denemişlerdir. Özellik olarak

söz konusu çalışmada, yüksek hesaplama karmaşıklığı gerektiren 2D MFKK ısı haritası yerine girdi olarak doğrudan MFKK özellikleri kullanılmıştır. DVM kerneli olarak lineer, RBF ve polinomial fonksiyonları incelenmiştir. Bir başka hiperparametre analizi olarak da KEYK için k değerleri (1, 3, 5, ..., 31) aralığında test edilmiştir. YSA ise her biri yüzer nörondan oluşan iki gizli katmanla çalıştırılmıştır.

McDonald ve diğ. [45] PhysioNet 2022 yarışmasında önerdikleri yöntemde çoklu GYMM kullanarak birden fazla muhtemel bölümlenme varsayımı yapmıştır. Klasik bölümlenme algoritmalarının aksine araştırmacılar PCG kayıtlarının sağlıklı temel kalp seslerinden oluşmak yerine ses sinyalinin yapısına üfürümlerin de dahil olma ihtimalini göz önünde bulundurmışlardır. Sundukları yöntem 50 saniye genişliğinde 20 saniye çakışma boyutunda pencerelere ayırdığı PCG kaydından spektrogram çıkarmaktadır. Üç katmanlı çift yönlü Kapalı Yinelemeli Üniteler (KYÜ - Gated Recurrent Unit (GRU)) kullanarak eğitilen ESA modeli ile birlikte Springer ve diğ. [7] tarafından geliştirilen Viterbi algoritmasına dayanan 4 farklı GYMM ortak karar alarak bölümlenme ve sınıflandırmayı birlikte yapmıştır. Ayrıca bu aşamada elde edilen bilgiler yarışmada sağlanan diğer klinik verilerle (yaş, cinsiyet, kilo, boy, hamilelik durumu vb.) sonucu tahmin etmek üzere gradyan destekli bir karar ağacında özellik olarak birlikte kullanılmıştır.

CirCor2022 veri setinin kullanıldığı başka bir çalışmada Monteiro ve diğ. [46] 4 saniye uzunluğunda çerçeveler ile çalışmıştır. Ön işlem aşamasında bölümlenme yapılmamıştır ama 2. dereceden 25-400Hz aralığında bant geçiren filtre ile ses sinyalleri filtrelenmiştir. Sinyal özellikleri olarak homomorfik, Hilbert, güç spektral yoğunluğu ve dalgacık zarfları kullanılmıştır. Çift yönlü uzun kısa süreli bellek (ÇYUKSB - Bidirectional Long Short Term Memory (BiLSTM)) katmanı içeren ESA modelleri ile sınıflandırma yapılmıştır.

Çalışmalarında CinC2016 ve CirCor2022 veri setlerini kullanan Ballas ve diğ. [47] veri setlerinin aynı örnekleme frekansına sahip olması için ön işlem aşamasında kayıtları 2000Hz'e yeniden örneklendirmiştir. Her kaydın ilk ve son 2 saniyesi gürültü artefaktları içerebileceğinden atılmış ve geri kalan sinyal 5 saniye pencere boyutunda 2,5 saniye çakışma miktarında çerçevelere ayrılmıştır. Kendi Kendine Gözetimli Öğrenme (KKGÖ - Self Supervised Learning (SSL)) tekniğini kullanarak veri kümesini çeşitli transformasyonlarla (filtrelenmiş versiyonlar, ölçekleme ve -1 ile çarparak ters çevirme gibi) çoğaltıp, kendi kendine etiketlendirme yapmışlardır. Mimari detayları [48]'de sunulan ESA modelini alıp, KKGÖ ile zenginleştirilmiş veri kümesini kullanarak eğitmiş ve son aşamada kat bağlı katmanların çıktısını göz ardı ederek en son Evrişimsel katmanın çıktılarını kullanarak

çerçeveler için olasılıksal sınıf değerleri elde etmişlerdir. PCG kaydının bütünü için karar alırken bu olasılıkları toplamış ve içinde en az bir tane üfürüm içeren kayıtları anormal ve tamamı temiz olan kayıtları normal olarak sınıflandırmışlardır.

Walker ve diğ. [49] derin öğrenme tabanlı Dual Bayesian ResNet (DBRes) ve XGBoost sınıflayıcılarının kalp üfürüm tespitinde birleşiminden oluşan bir yaklaşım geliştirmişlerdir. Veri setindeki kayıtlardan 4 saniye uzunluğunda çerçevelerinin 25 milisaniye uzunluk, 10 milisaniye çakışma boyutundaki spektrogramları DBRes eğitiminde kullanılmıştır. Üç sınıftan oluşan veri seti anormal/diğerleri ve belirsiz/diğerleri şekillerinde ikili olarak ele alınarak problem ikili sınıflandırmaya indirilmiştir. DBRes ile ikili sınıflandırma yapılmış ve buradan elde edilen çıktı hastaların demografik verileri (yaş, cinsiyet, boy, kilo, vb.) ve sinyal özellikleriyle (spektral ağırlık merkezi, roll off noktası, bant genişliği vb) eğitilen XGBoost sınıflayıcıyla PCG kayıtları sınıflandırılmıştır.

PhysioNet 2022 yarışmasında birinci olan yöntemi öneren Xu ve diğ. [13] üfürümlerin 20-500HZ aralığında frekans bileşenleri olduğunu belirterek CirCor2022 veri setindeki ses sinyallerini 4kHz'den 2kHz'e yeniden örneklemiştir. PCG kayıtlarından 3 saniye uzunluğunda pencereler 1 saniyelik adım boyutuyla çıkarılmıştır. Önerdikleri hiyerarşik çoklu-ölçekli spektrogram işleyen ESA modellerinde üç farklı ölçek değerleriyle elde edilen spektrogramlar eğitim için kullanılmıştır. Evrişim katmanlarından işlenerek elde edilen katsayılar hiyerarşik bir sırayla dizilmiş katmanlarda birbirlerine eklenerek tam bağlı katmanlara ulaştığında hastaların demografik verileriyle (yaş, cinsiyet, boy, kilo, vb.) de desteklenerek sınıflandırma yapılmıştır. Genel sınıflandırma aşamasındaysa çerçevelerin %80'i belirsiz olması durumunda PCG kaydı belirsiz olarak etiketlenmiştir. Belirsiz çerçevelerin oranı %80'den az olması durumunda normal ve anormal çerçeve sayısına bakılarak fazla olan kategorinin lehine PCG kaydının genel sınıflandırılması yapılmıştır.

### **1.3 Tezin Amacı**

Kalp sesleri kardiyovasküler rahatsızlıkları tanımda kilit bir rol oynamaktadır. İnvazif olmaması, pratik, yaygın ve kolayca uygulanabilmesi nedeniyle kalp seslerini dinleyerek teşhis yaparak ön tanı koymak klinisyenler tarafından tercih edilmektedir. Çeşitli rahatsızlıkların göstergesi olarak kalp seslerine üfürüm adı verilen hışırtıya benzer bir gürültü karışabilmektedir. Sağlık çalışanlarının ve stajyerlerin üfürümleri dinleyerek yorumlaması ve ayırt etmesi uzun tecrübeler gerektirmektedir. PCG kayıtlarından kalp

üfürümünü tespit eden bilgisayar destekli sistemler hem uzmanlara yardımcı olmakta hem de hastalar için zaman tasarrufuna olanak sağlamaktadır.

Bu tez kapsamında yürütülen çalışmalarımızla gerekli tıbbi, teknolojik ve algoritmik altyapıyı oluşturarak özgün yaklaşımlar sunarak bu alanda tecrübe paylaşımı yapmaktır. Çalışmamızın temel amacı PCG kayıtlarından kalp üfürümünü tespit etmede uzman hekimlerin başvurabileceği güvenilir ve başarılı algoritmalar sunmaktır. Bu amaç doğrultusunda yürütülen çalışmalar şunları kapsamaktadır:

- Kalp seslerinin çerçevelere ayrılması
- Kalp seslerinden zaman, frekans ve zaman-frekans alanında özelliklerin çıkarılması
- Kalp seslerinin klasik makine öğrenmesi yöntemleriyle sınıflandırılarak karşılaştırma yapmada altın standardının oluşturulması
- Kalp seslerinin filtrelenmesi
- PCG kayıtlarındaki seslerin içermesi muhtemel ortam gürültüsünün etkisinden kurtarılarak verimli bir şekilde kırılabilmesi
- Kalp seslerinin bölümlenmesi ve buna dayanarak çerçevelerin hizalanması
- Kalp seslerinden spektrogram elde edilerek sınıflandırılması
- Normal ve aritmi içeren EKG kayıtlarını kullanarak eğitilen derin ağ modeliyle paroksizmal kayıtların saptanması
- Ardışık verileri işlemede farklı derin ağ modellerinin performanslarının incelenmesi

Bu amaçlar doğrultusunda kalp seslerini çerçevelere ayırarak bu çerçevelerden dengeli veri setleri oluşturan, AMA ve ADD yöntemleriyle PCG kayıtlarını filtreleyen, entropi ve enerji tabanlı bir optimizasyon uygulaması ile kalp seslerini kırpan yöntemler geliştirilmiştir. Çift yönlü uzun-kısa süreli bellek ile evrimsel sinir ağları karşılaştırılmıştır. Önerilen yöntemlerin performansları uluslararası yarışmalarda kullanılan, halka açık ve güvenilir veri setleri kullanılarak ölçülmüştür.

#### **1.4 Tezin Gerekçesi**

Bu tez çalışmasında PCG kayıtlarından kalp üfürümünün tespit edilmesi ve makine öğrenmesi yöntemleriyle kalp seslerinden elde edilen özelliklerin kullanılarak bu kayıtların normal/anormal olarak sınıflandırılması için metotlar önerilmiştir. Tezin gerekçeleri aşağıdaki gibi sıralanabilir:

- PCG kaydından çeşitli uzunlukta kırılan parçaları kullanan yaklaşımlar literatürde mevcuttur. Bunlar sinyalin başından alarak veya ilk birkaç saniyelik kısmı atlayarak kırma yapan naif yaklaşımlardır. Sinyalin içinden parça seçimine odaklanan bir çalışma bildiğimiz kadarıyla mevcut değildir.
- Oskultasyon sırasında kaydedilen seslere cihaz gürültüsü, hastanın konuşması ve ortam sesleri karışarak bu alanda yapılan çalışmaların başarısını düşürmektedir.
- Düşük kaliteli PCG kayıtlarının tümünden özellik çıkarmanın gürültülü kısımların etkisiyle kalp sesi analizi olumsuz olarak etkilenmektedir.
- Düşük kaliteli PCG kayıtlarını tespit ederek veri setinden çıkarmanın veri kaybına yol açmakta ve ekstra hesaplama maliyeti ortaya çıkarmaktadır.
- Kalp sesleri dört farklı sesli ve sessiz bölümden oluşmaktadır. PCG kaydından çıkarılan kesitlerde başlangıç bölümlerinin farklı olması sınıflandırıcıların eğitimini zorlaştırmaktadır.
- Temel kalp sesleriyle benzer frekans bandında bileşenlere sahip olan üfürümlerin ayırt edilmesinin zordur.
- Birden fazla derivasyona sahip EKG kayıtlarını incelerken farklı derivasyonlardaki uyumsuz göstergeler ortak karar almayı zorlaştırmaktadır.
- Seri olarak ele alınıp yorumlanması gereken PCG ve EKG gibi verilerin işlenmesinde farklı derin öğrenme yaklaşımlarının performansını ölçmek

Bu bölümde bahsedilen eksikliklerin giderilme ihtiyacı bu tezin gerekçesini oluşturmaktadır. Ayrıca literatürde çıkan yayınlar, düzenlenen uluslararası katılım sağlanan yarışmalar ve çeşitli enstitülerin veri setleri hazırlayarak paylaşması dikkate alındığında tezde ele alınan konunun önemi görülmektedir. Tez konusunun literatürün ilgi odağında yer alması ve bu konuda araştırmacıların özgün çalışmalar geliştirme arayışında olması bu tez konusuna odaklanmamıza yol açmıştır.

### **1.5 Tezde Geliştirilen Uygulamalar ve Literatüre Katkısı**

Tez kapsamında PCG kayıtlarını sınıflandırma temelli çeşitli çalışmalar yürütülmüş ve birçok uygulama geliştirilmiştir. Kalp üfürümlerinin tespiti, kalp seslerinin bölümlenmesi, PCG kayıtlarının gürültüden arındırılması ve içlerinden uygun kesitlerin bulunup çıkarılması başlıca çalışma konularıdır. Geliştirilen uygulamaların yanında yeni yayınlar yazılarak literatüre katkıda bulunulmuştur. Önerilen uygulamalar ve yazılan bilimsel yayınlar şu şekilde özetlenebilir:

1. Uygulama: Bu çalışmada PCG kayıtlarından zaman, frekans ve zaman-frekans alanlarından çıkarılan özelliklerle klasik makine öğrenmesi yöntemleri ve bunların ensemble modelleri eğitilerek performansları karşılaştırılmıştır. Çalışmanın detayları ve elde edilen sonuçlar bir makalede sunulmuştur.  
**Gündüz, A. F., & KARCI, A. (2020).** Heart Sound Classification for Murmur Abnormality Detection Using an Ensemble Approach Based on Traditional Classifiers and Feature Sets. *Computer Science*, 5(1), 1-13.
2. İnceleme makalesi: Literatürde yaygın olarak kullanılan veri setleri ve çeşitli araştırmacıların bunları kullanarak geliştirdiği özgün yöntemler incelenmiş ve derlenerek yayınlamıştır.  
**Gündüz, A. F., (2022).** Review of Heart Sound Analyses from Phonocardiogram Records, *Romanian Biotechnological Letters*, 27(1), 3167-3183.
3. Uygulama: Yapılan çalışmada kalp sesleri 1 saniyelik çerçevelere ayrılmış, bu çerçevelerden MFCC özellikleri, spektral özellikler ve ESA modelinin aktivasyon katsayıları çıkarılarak özellik seti oluşturulmuştur. Klasik makine öğrenmesi yöntemleri bu özelliklerle eğitilerek sınıflandırma yapılmıştır.  
**Gündüz, A. F., & TALU, M. F. (2022).** PCG Frame Classification by Classical Machine Learning Methods Using Spectral Features and MFCC Based Features. *Avrupa Bilim ve Teknoloji Dergisi*, (42), 77-82.
4. Uygulama: Atriyal fibrilasyon içeren EKG kayıtlarının derin öğrenme modellerinde P dalgalarının, R-R arası mesafelerinin ve spektral özelliklerinin kullanılarak sınıflandırılması yapılmıştır. Bu çalışmadan özgün bir araştırma makalesi çıkarılmıştır.  
**Gündüz, A. F., & TALU, M. F. (2023).** Atrial fibrillation classification and detection from ECG recordings. *Biomedical Signal Processing and Control*, 82, 104531.
5. Uygulama: PCG çerçevelerinin özel filtrelerden geçirilerek bunlardan MFCC katsayıları çıkarılmıştır. Elde edilen MFCC katsayıları üzerinden çerçeveler ESA modeli ile normal/anormal olarak sınıflandırılmıştır.
6. Uygulama: Yapay arı kolonisi optimizasyon algoritması ile PCG kayıtlarından gürültünün etkisinin en düşük olduğu çerçeveler kırılarak bölümlere ayrılmıştır. Bölümlerin başlangıç noktalarını kullanarak zamanda hizalanan PCG çerçevelerinden KZFD ile spektrogram çıkarılarak ESA modeli ile sınıflandırılmıştır.

## 1.6 Tezin Organizasyonu



Tezin birinci bölümünde tezde ele alınan problemin tanımı yapılmış, literatürdeki veri setleri ve bunlar üzerindeki çalışmalardan bahsedilmiştir. Ayrıca tez hakkında genel bilgiler verilerek tezin amacı ve gerekçesi açıklanmıştır.

Bölüm 2’de tezde kullanılan materyal, metottan ve değerlendirme ölçütlerinden bahsedilmiştir.

Bölüm 3’te yapılan uygulamalar detaylı bir şekilde sunulmuştur.

Bölüm 4’te geliştirilen uygulamaların sonuçları karşılaştırılmış, tezin akademik katkıları açıklanmıştır. Ayrıca bu bölümde teze ilgili gelecekte yapılması planlanan çalışmalara değinilmiştir.



## 2. MATERYAL VE METOT

### 2.1 Kullanılan Veri Setleri

Bu tezde yürütülen çalışmalarda PhysioNet [16] tarafından halka sunulan PCG ve EKG veri setleri kullanılmıştır. Bunlar 2016 ve 2022 yıllarında paylaşılan iki PCG ve 2021 yılında paylaşılan bir EKG veri setidir. Tüm veri setleri, gerekli etik izinleri altında çeşitli hastane ve enstitüler tarafından toplanarak halka sunulmuştur. Bu veri setleri PhysioNet tarafından düzenlenen yarışmalarda kullanılmıştır. PCG ve EKG biyomedikal sinyallerini işleyen bilgisayar destekli özgün sistemlerin geliştirilmesi, bunların sınıflandırmalarını yapan orijinal yöntem ve algoritmaların geliştirilmesi amacıyla düzenlenen yarışmalara pek araştırmacı katılmış ve birçok bilimsel yayında bunlardan yararlanılmıştır. Bu bölümde tezde kullanılan veri setleri hakkında detaylı bilgiler verilmiştir.

#### 2.1.1 PhysioNet/Computing in Cardiology Challenge 2016 (CinC2016)

PhysioNet/Computing in Cardiology Challenge 2016 (CinC2016) [10] PCG veri setinin halka açık olan kısmı bu tez çalışmalarında kullanılmıştır. CinC2016 veri seti 2016 yılında PhysioNet tarafından düzenlenen bir yarışma için paylaşılmıştır. Birbirinden bağımsız dokuz araştırma grubunun topladığı verilerin bir araya getirilmesiyle oluşturulmuştur. PCG kayıtları farklı donanımlarla elde edilmiş olmasına rağmen yeniden örneklenerek 2 kHz ortak örnekleme frekansına getirilmiştir.

PCG kayıtları farklı ortamlarda (hastanelerde ve evde bakım/ziyaret servislerinde) hastalardan toplanmıştır. Kayıt esnasında hastaların sabit bir durumda dinlenmesi zorunlu tutulmayıp hastanın hareketleri, bağırsak ve akciğer seslerinden kaynaklı gürültüler PCG kayıtlarına girmiştir.

CinC2016 veri setinde üfürümler mitral kapak yetersizliği, aort darlığı ve kapak cerrahisi gibi çeşitli kardiyak rahatsızlıklardan kaynaklanmaktadır. Bununla birlikte veriler patolojik üfürüm türüne ve masum/tehlikeli durumlarına bakılmaksızın sadece ikiye ayrılarak uzman klinisyenler tarafından **normal (üfürüm içermeyen)** ve **anormal (üfürüm içeren)** olarak etiketlenmiştir.

Yarıřmada veri setinin bir kısmı eğitim amacıyla halka açılırken bir bölümü gizli tutulmuş ve sadece katılımcıların performansını ölçerken test sürecinde kullanılmıştır. Halka açık olan eğitim setinde 665 üfürüm içeren ve 2575 normal olmak üzere toplam 3240 kayıt bulunmaktadır. Bu kayıtların hangi odak noktasından alındığına dair bir bilgi mevcut değildir. Çizelge 2.1’de veri setini kayıtların sayısı ve bunların alındığı hasta sayısı verilmiştir.

**Çizelge 2.1:** CinC2016 veri setini oluşturan eğitim ve test setleri

Veri Kümesi	Hasta Sayısı	PCG	Anormal	Normal	Belirsiz
<b>Train-A</b>	121	409	292	117	0
<b>Train-B</b>	106	490	104	386	0
<b>Train-C</b>	31	31	24	7	0
<b>Train-D</b>	38	55	28	27	0
<b>Train-E</b>	356	2141	183	1958	0
<b>Train-F</b>	112	114	34	80	0
<b>Toplam (Eğitim)</b>	764	3240	665	2575	0
<b>Test-B</b>	45	205	32	100	73
<b>Test-C</b>	14	14	9	4	1
<b>Test-D</b>	17	24	11	11	2
<b>Test-E</b>	153	883	59	763	61
<b>Test-G</b>	44	116	21	95	0
<b>Test-I</b>	35	35	21	12	2
<b>Toplam (Test)</b>	308	1277	153	985	139

### 2.1.2 CirCor Digiscope Phonocardiogram (CirCor2022)

CirCor Digiscope Phonocardiogram (CirCor2022) tez kapsamında kullanılan diğeri bir PCG veri setidir [18]. CirCor2022 veri seti 2022’de düzenlenen bir yarışma için paylaşılmış olup pediatri hastaları olan bebek, çocuk ve genç bireylerden temin edilen PCG kayıtlarından oluşmaktadır. Dört farklı oskültasyon noktasından (pulmoner kapakçık, triküspit kapakçık, aortik kapakçık ve mitral kapakçık civarı) dinleme yapılmasına göre PCG kayıtları ayrılmıştır. Veri seti ayrıca hastanın cinsiyet, boy, kilo ve yaş gibi istatistiki bilgileri ile zenginleştirilmiştir. Toplamda 1568 hastadan alınan 5282 PCG kaydı uzman hekimler tarafından **üfürüm içeren, üfürüm içermeyen ve belirsiz** olarak üç farklı şekilde etiketlenmiştir.

Tüm veri setinin sadece %60’ı yarışmacıların eğitim amacıyla kullanması için paylaşımına açılmıştır. Söz konusu eğitim seti 942 hastadan alınan verileri içermektedir. Bunların

yaklaşık %74'ü sağlıklı, %19'u hasta ve %7 kadarı bilinmeyen sınıflarına aittir. PCG kayıtları Littmann 3200 elektronik bir oskültasyon cihazı kullanılarak vücuttaki dört belli dinleme konumundan (aort, pulmoner, triküspid ve mitral odaklardan) kaydedilmiştir. Her hastadan eşit sayıda kayıt alınmamış, bazılarında verilen dört ölçüm noktasının bir kısmından PCG kaydı alınarak veri setine eklenmiştir. Dolayısıyla kayıt sayısı, yeri ve süresi hastalar arasında değişmektedir [19]. Kayıtların uzunlukları 4,8 ile 80,4 sn arasındadır ve örnekleme frekansı 4 kHz'dir.


**Çizelge 2.2:** Yaşlarına göre CirCor2022 veri setindeki hastaların sayısı

Yaş Grubu	Normal	Bilinmeyen	Anormal	Toplam
Yenidoğan(0-3 ay)	4	1	1	6
Bebek (3-12 ay)	76	25	25	126
Çocuk (1-10 yaş)	495	37	132	664
Ergen (10-19 yaş)	53	3	16	72
Bilinmeyen	67	2	5	74
<b>Toplam</b>	695	68	179	942

### 2.1.3 4th China Physiological Signal Challenge 2021 (CPSC2021)

2021 yılında düzenlenen bir yarışma kapsamında sunulan CPSC2021 veri seti iki derivasyonlu EKG kayıtlarından meydana gelmektedir [50]. Veri setindeki EKG kayıtları normal, inatçı atriyal fibrilasyon (AF) ve paroksizmal atriyal fibrilasyon (PAF) olmak üzere üç farklı sınıfa aittir. EKG kayıtlarının örnekleme frekansı 200Hz'dir. Veri seti iki kümeden oluşmaktadır. İlk veri kümesi 730 ve ikinci veri kümesi 706 EKG kaydı içermektedir. Birinci veri kümesi; 12 AF, 5 PAF hastası ve 42 normal bireyden Holter cihazı kullanılarak alınan kayıtlarından oluşmaktadır. İkinci veri kümesi; 37 AF hastası, 18 PAF hastası ve 14 sağlıklı bireyden alınan kayıtlardan oluşmaktadır. CPSC2021 veri seti PhysioNet tarafından WFDB formatında kullanıma sunulmaktadır.

EKG kayıtlarından AF saptanırken en önemli ve ayırt edici faktörlerden birisi birbirini izleyen iki R-R tepeleri arasındaki mesafelerin düzensizliğidir. Normal EKG kayıtlarında R-R arası mesafeler düzenliken AF içeren EKG kayıtlarında tepeler arası mesafenin daraldığı gözlenir. PAF olarak tanımlanan EKG kayıtlarında ise genellikle 48 saatten kısa süreli aritmiler gözlemlenir. Holter cihazıyla 7 gün süreli yapılan takipte kısmi düzensizlik gösteren EKG kayıtları PAF olarak tanımlanmaktadır. Şekil 2.1'de normal, AF ve PAF EKG kayıtları gösterilmiştir.



**Şekil 2.1:** Normal EKG örneği (a), AF (b) ve PAF (c)

Toplamda iki EKG veri kümesinden oluşan CPSC2021 veri seti bu tezde kullanılmıştır. Tez çalışmalarında kullanılan tüm veri setlerinin sahip olduğu sınıflar ve örnek sayılarına ait detaylar Çizelge 2.3'te verilmiştir.

**Çizelge 2.3:** Tezde kullanılan veri setlerindeki örneklerin sınıflara dağılımları

Veri Seti	Örnekleme Frekansı (Hz)	Sınıfların Dağılımı	Toplam Örnek
<b>CinC2016</b>	2000	665 anormal 2575 normal	3240
<b>CirCor2022</b>	4000	156 belirsiz 604 anormal 2358 normal	3118
<b>CPSC2021 Set-1</b>	200	153 AF 96 PAF 481 Normal	730
<b>CPSC2021 Set-2</b>	200	319 AF 137 PAF 250 Normal	706

## 2.2 Değerlendirme Ölçütleri

Bu tez çalışmasında önerilen uygulamaların performanslarını ölçüp, bunları güncel yöntemlerle karşılaştırabilmek için çeşitli bilimsel değerlendirme ölçütleri kullanılmıştır. Bu ölçütler Doğruluk ((D)-Accuracy), Hassaslık ((H)-Recall/Sensitivity), Kesinlik ((K)-Precision/Positive Predictive Value), Negatif Tahmin Değeri ((NTD)-Negative Predictive Value), F1-skoru (F1-score), Özgüllük ((Ö)-Specificity) ölçütleridir. Bunların hesaplanabilmesi için Hata Matrisi'nde (Confusion Matrix) yer alan *Doğru Pozitif* (True Positive (TP)), *Doğru Negatif* (True Negative (TN)), *Yanlış Pozitif* (False Positive (FP)) ve

*Yanlış Negatif* (False Negative (FN)) değerlerinin bilinmesi gereklidir. Hata matrisinin burada bahsedilen değerlere karşılık gelen konumları Şekil 2.2’de gösterilmiştir.

<b>Hata Matrisi (Confusion Matrix)</b>		<b>Gerçek Değerler</b>	
		Pozitif	Negatif
<b>Tahmin Edilen</b>	Pozitif	TP	FP
	Negatif	FN	TN

**Şekil 2.2:** Hata matrisi

Kalp üfürümü içeren PCG kayıtları anormal olarak etiketlenmişken sağlıklı olan kayıtlar normal olarak etiketlenmiştir. Hata matrisinde anormal PCG kayıtları pozitif olarak ifade edilirken normal olanlar ise negatif gerçek değerlerine sahiptir. Gerçek pozitif örnekleri doğru tahmin eden modeller bunları doğru pozitif (TP) olarak belirler. Benzer şekilde gerçek negatif örnekleri doğru tahmin eden modeller de bu örnekleri doğru negatif (TN) olarak işaretler. Gerçekte pozitif oldukları halde yanlışlıkla negatif olarak tahmin edilenler yanlış negatiflerdir (FN). Gerçekte negatif oldukları halde pozitif olarak tahmin edilenlerse yanlış pozitiflerdir (FP). Hata matrisinin elemanlarını kullanarak ifade edilen değerlendirme ölçütlerinin matematiksel ifadeleri sırasıyla Eşitlik 2.1 ile Eşitlik 2.6 arasında verilmiştir.

$$\text{Doğruluk } (D) = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.1)$$

$$\text{Hassaslık } (H) = \frac{TP}{TP + FN} \quad (2.2)$$

$$\text{Özgüllük } (\ddot{O}) = \frac{TN}{TN + FP} \quad (2.3)$$

$$\text{Kesinlik } (K) = \frac{TP}{TP + FP} \quad (2.4)$$

$$\text{Negatif Tahmin Değeri (NTD)} = \frac{TN}{TN + FN} \quad (2.5)$$

$$\text{F1 skoru} = \frac{2 * H * K}{H + K} \quad (2.6)$$

### 2.3 Ön İşlem

PCG analizi sırasında kalp sesi sinyalleri öncelikle bir takım ön işlemlerden geçirilmektedir. Bu aşamada sıklıkla başvurulan bazı işlemler yeniden örnekleme, normalizasyon, filtreleme, kırpma, çerçeveleme ve bölümlenmedir. Farklı kaynaklardan toplanmış geniş veri setlerinin örnekleme frekansı değişik olabilmektedir. Bu tür veri setlerinin kullanıldığı çalışmalarda ön işlem aşamasında yeniden örnekleme yapılarak kalp sesi sinyallerinin ortak bir örnekleme frekansına getirilmesi gereklidir. Ayrıca PCG kayıtlarında rastlanması muhtemel üfürümler 500-600Hz aralığında frekanslara sahiptir. Nyquist teoremine göre bu bileşenlerin kayıpsız incelenebilmesi için 1000-1200Hz örnekleme frekansı yeterlidir. Literatürdeki bazı veri setleri bunun çok üstünde örnekleme frekansına sahiptir. Bu tür veri setleriyle çalışan araştırmacılar da zaman ve kaynakları daha verimli kullanmak adına veri setlerindeki kayıtları bahsedilen değerlerde örnekleme frekansına sahip olacak şekilde yeniden örnekleymektedir. Daha güvenilir ve sağlamcı bir yaklaşımla oskültasyon sırasında dinlenen seslerin frekansının üst limiti olarak 1000Hz ve dolayısıyla örnekleme frekansı da minimum 2000Hz kabul edilebilir [27], [51], [52].

Ön işlem aşamasında başvurulan bir diğer adım verilerin normalize edilmesidir. Bu amaçla z-skoru standartlaştırması, min-max normalizasyonu ve örnekleri en büyük mutlak değerle bölmek gibi yöntemlerle sinyalin örnekleri belirli aralıklara normalize edilir. Bu normalizasyon fonksiyonlarının matematiksel ifadeleri sırasıyla Eşitlik 2.7 ile Eşitlik 2.9 arasında verilmiştir.

$$S_{norm}(i) = \frac{S(i)}{\max(|S|)} \quad (2.7)$$

$$S_{norm}(i) = \frac{S(i) - \mu}{\sigma} \quad (2.8)$$

$$S_{norm}(i) = \frac{S(i) - \min(S)}{\max(S) - \min(S)} \quad (2.9)$$

Temel kalp sesleri 10-250Hz aralığında bileşenlerden oluşmaktadır. En yoğun enerjiye sahip oldukları aralıksa 100-200Hz bandı olarak kabul görmektedir. Temel kalp seslerinin kalp üfürümlerinden ayırt edilerek bölümlere ayrılabilmesi ve doğru bir şekilde sınıflandırılabilmesi için ön işlem aşamasında sıklıkla başvurulan yöntemlerden birisi de filtrelemektir. Filtreleri dürtü yanıtına göre ve genlik cevabına göre sınıflandırmak mümkündür. Dürtü yanıtına göre filtreler sonlu dürtü yanıtı (FIR) ve sonsuz dürtü yanıtı

(IIR) filtrelerdir. Genlik cevabına göre ise alçak geçiren, yüksek geçiren, bant geçiren ve bant durduran filtreleri sayabiliriz. Hem yüksek frekanslı hem de alçak frekanslı gürültüleri yatıştırabilmelerinden ötürü bant geçiren filtreler tercih edilmektedir. Örneğin Butterworth filtresini Singh ve diğ. [53] 4. dereceden 25-400Hz aralığında, Li ve diğ. [54] 5. dereceden 25-500Hz aralığında ve Ibrahim ve diğ. [55] 6. dereceden 50-950Hz aralığında kullanmışlardır. Ayrıca Chebyshev alçak geçiren filtre [56], Savitzky-Golay filtresi [57], [58] ve Notch filtresi [59] de bu aşamada araştırmacılar tarafından uygulanmıştır.

Bu aşamada uygulanan bir diğer işlem de değişik uzunluklarda ses sinyalleri içerebilen veri setlerinden standart uzunlukta çerçeveler çıkarmaktır. Bazı çalışmalarda PCG kaydının tamamından yararlanarak da sınıflandırma yapılmasına karşın özellikle ESA girdisi olarak bu verileri kullanan çalışmalar [35], [36], [60] için veri boyutu standardizasyonu şarttır. Eşit uzunlukta kalp sesi sinyalleri, kayıtların standart ölçülerde kırılması elde edilebilir. Bu yöntemin dezavantajıysa sinyalin geri kalan kısmının atılarak kullanılmamasıdır. Bu yöneme alternatif olarak PCG kayıtlarından kayan pencereler algoritmasıyla eşit uzunlukta ve istenen ölçüde çakışan genişliklerde çerçeveler çıkarılmaktadır.

## **2.4 Özellik Çıkarımı**

Veri madenciliğinde, girdi uzayındaki verilerin kendilerini oluşturan öz niteliklere ayrılmasına özellik çıkarımı denir. Bütün olarak ele alındığında veri karmaşık ve gizli bir yapı gibi gözükürken, onu temsil eden öz niteliklerin veriden süzülüp çıkarılmasıyla odaklanan alan sadeleşir ve problemin çözümü kolaylaşır. Özellik çıkarımı, kullanılan sınıflandırma yöntemleri kadar önemlidir. Seçilen öz niteliklerin veriyi temsil etmedeki başarısı sistemin başarısını doğrudan etkiler. İncelenen verinin türüne göre farklı özellikler ön plana çıkmaktadır.

Kalp seslerinden zaman, frekans ve zaman-frekans alanlarında özellikler çıkarılabilir. Bu amaçla özellik çıkarımı aşamasında kullanılan bazı önemli yöntemler bu kısımda anlatılmıştır.

### **2.4.1 Fourier dönüşümü**

Sinyali zaman alanından frekans alanına taşıyan Fourier Dönüşümü (FD – Fourier Transform (FT)), en eski yöntemlerden birisidir. FD ile zaman alanındaki örüntünün ölçülmesi mümkün olan her bir frekans bileşenin genlik ve faz değerleri hesaplanır. Herhangi bir periyodik fonksiyon, sinüzoid denilen belirli genlik, faz ve frekansa sahip olan



sonsuz sayıda sinüs ve kosinüs dalgalarının toplamları ile ifade edilebilir. Bu şekilde sinüzoidlerin toplamı ile fonksiyon gösterimine Fourier serisi denir. FD ile dalga formları kendilerini oluşturan periyodik sinüzoidlere ayrılırlar. FD uygulama alanı ise sürekli, periyodik ve durağan fonksiyonlarda kullanmak için idealdir. Bununla beraber keskin uçlara sahip, ani iniş-çıkışlar yapan sinyalleri incelemede yetersiz kalır. Astronomide, görüntü sıkıştırma, konuşma tanımada, sismik sinyal incelemesinde, müzik prodüksiyonunda ve benzeri sinyal işleme gerektiren pek çok konuda kullanılmaktadır.

$$x(t) = a_0 + \sum_{n=1}^{\infty} \left( a_n \cos \frac{2\pi nt}{T} + b_n \sin \frac{2\pi nt}{T} \right) \quad (2.10)$$

Fourier serisi, teorikte sürekli bileşenlerden oluşan bir seri olmasına rağmen sınırlı kapasiteye sahip olan bilgisayar ortamında ayrık olarak ifade edilip işlenmek durumundadır çünkü sürekli fonksiyonlar sonsuz sayıda örnekten oluşur. Euler eşitliğinden yararlanarak bir  $x(t)$  fonksiyonun Fourier dönüşümleri aşağıdaki şekillerde hesaplanır:

$$e^{it} = \cos(t) + i * \sin(t) \quad (2.11)$$

$$X(w) = \int_{-\infty}^{\infty} x(t)e^{-iwt} dt \quad ; w = 2\pi f \quad (2.12)$$

$$X(k) = X(e^{i2\pi k/T}) = \sum_{n=-\infty}^{\infty} x(n) e^{\frac{-i2\pi kn}{T}} \quad (2.13)$$

Pratik kullanımda sonlu sayıda örnekle çalışmak bir zorunluluk olduğundan Ayrık Fourier Dönüşümü (AFD) tanımlanmıştır. AFD için periyodu  $T$  olan bir sinyalden eşit zaman aralıklarıyla örnekler alınarak sinyal oluşturulur. Sinyal sabit bir pencere içerisinde ayrık olarak tanımlanır. AFD kullanışlı bir sinyal işleme yöntemi olmasına rağmen sonlu  $N$  tane örnek içeren bir sinyal için  $O(N^2)$  olan algoritma karmaşıklığı yüzünden yeterince hızlı değildir. Onun yerine hızlı bir metot olan Hızlı Fourier Dönüşümü (HFD) ise  $N$  elemandan oluşan bir veriyi  $O(N \log(N))$  hesaplama karmaşıklığı ile çözer. AFD ile hesaplanan frekans değerlerinin genlik ve faz değerleri Eşitlik 2.14'de ifade edilen fonksiyonla elde edilir.

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{\frac{-i2\pi kn}{N}} \quad ; k = 1,2,3, \dots, N - 1 \quad (2.14)$$

Eşitlik 2.14'te gösterilen  $X(k)$  ifadesinde belirli bir  $k$  frekans bileşeninin genlik ve faz değerleri incelenerek sinyalin spektrumunda var olup olmadığına karar verilir. Nyquist Teoremine göre tüm frekans bileşenlerinin doğru bir şekilde ölçülebilmesi için örnekleme frekansının kalp sesi sinyallerinin frekansının iki katından büyük veya eşit olması gerekir. FD ile elde edilen frekans bileşenleri birbirinin simetriği olan iki parça halinde çıkacaktır. Dolayısıyla anlamlı frekans aralığı çerçeve genişliğinin yarısından bir fazlasıdır.

$$\text{Anlamlı frekans aralığı} = \frac{N}{2} + 1 \quad (2.15)$$

Ters Fourier Dönüşümü (TFD) ile frekans alanındaki  $X(k)$  ifadesinden zaman alanındaki  $x(n)$  sinyalini Eşitlik 2.16'daki gibi geri elde etmek mümkündür.

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{\frac{i2\pi kn}{N}} \quad (2.16)$$

#### 2.4.2 Kısa zamanlı fourier dönüşümü

FD ile belirli bir sinüzoid bileşeninin sinyal içerisinde mevcut olup olmadığı incelenebilir ama durağan olmayan bir sinyalin zamanla değişkenlik gösteren frekans bilgisi kestirilemez. Çünkü FD'nün farklı frekanstaki bileşenlerin zamansal konumlarını tespit etme kabiliyeti yoktur. FD sonucunda elde edilen veriden frekans-zaman bilgisi kaybedilir.

Farklı frekansta bileşenlerin hangi zamanda ortaya çıktığını ölçebilmek için Kısa Zamanlı Fourier Dönüşümü (KZFD – Short Time Fourier Transform (STFT)) kullanılan yöntemlerden birisidir. Bu yöntem, seçilen bir büyüklükteki pencerenin sinyal üzerinde gezdirilmesi ve pencere içerisindeki sinyal parçasına FD uygulanması ile gerçekleştirilir. Pencere büyüklüğünün dar seçilmesi durumunda seçilen zaman aralığı yüksek çözünürlükte tespit edilirken frekans çözünürlüğü azalacaktır. Tam tersine pencere büyüklüğü geniş seçilirse zaman çözünürlüğü düşerken frekans çözünürlüğü yüksek olur. Eşitlik 2.17'de  $x(n)$  orijinal sinyali,  $w$  seçilen pencere fonksiyonunu,  $f$  frekansı ve  $m$  de zamandaki öteleme miktarını göstermektedir.

$$X_{KZFD}(m, f) = \sum_{n=0}^{N-1} [x(n + m)w(n)] e^{\frac{-i2\pi nf}{N}} \quad (2.17)$$

PCG içeriğinde durağan olmayan kalp seslerinin hangi aralıkta başlayıp bittiğini ölçebilmek için FD yerine KZFD tercih edilmelidir. Sinyalin zamana göre değişen frekanslarının

enerjisinin görsel olarak ifade edildiği spektrogram, KZFD frekans-genlik değerlerinin mutlak değerlerinin karesi alınarak Eşitlik 2.18'deki gibi elde edilir.

$$Y(m, f) = |X_{KZFD}(m, f)|^2 \quad (2.18)$$

### 2.4.3 Dalgacık dönüşümü

Değişik ve zamansal olarak ortaya çıkma anları farklı olan frekans bileşenlerine sahip sinyallerle çalışmak için kullanılan bir başka yöntem dalgacık dönüşümüdür. KZFD kullanarak sabit bir pencere büyüklüğü ile analiz yapabilirken pencere büyüklüğünün ayarlanması bir sorun olarak karşımıza çıkmaktadır. Sinyalin hangi anında yüksek frekans bileşenlerin bulunacağı ve hangi anında düşük frekans bileşenlerin bulunacağı önceden bilinemez. Durağan olmayan birçok biyomedikal sinyal analizinde hassas frekans-zaman ölçümü için pencere büyüklüğünü sürekli değiştirmek gerekir.

1980'li yıllarda Jean Morlet ve Alex Grossmann'ın öncülüğünü yaptığı çalışmaların sonucunda bulunan Dalgacık Dönüşümü (DD – Wavelet Transform (WT)) ile durağan olmayan sinyallerin frekans karakteristiği zaman ölçekli olarak başarıyla incelenebilir. Değişen pencere büyüklüğüne sahip olması avantajıyla DD durağan olmayan sinyaller için optimal zaman-frekans çözünürlüğünü sunar.

DD algoritmasında ana dalgacık adı verilen belirli bir prototip fonksiyonu ile sinyal çarpılır. Ana dalgacığın farklı ölçeklerde sıkıştırılıp genişletilmesiyle pencereler üretilir. Bu pencereler KZFD'de olduğu gibi sinyal üstünde gezdirilerek zaman bilgisi doğrudan elde edilir. Her bir spektral bileşen farklı genişlikteki bir pencere ile hesaplanabilir. KZFD'nin aksine doğrudan bir frekans parametresi yoktur ama bunun yerine  $s = \frac{1}{\text{frekans}}$  tanımlanan ölçek parametresi mevcuttur. Ölçekleme işlemi dalganın genişletilip daraltılması anlamına gelirken dalganın zaman ekseninde sinyal üzerinde gezdirilmesi öteleme işlemi olarak ifade edilir. DD, bir sinyali birim dik olan vektörler grubuna ayırır ve bu birimler sinyali sınıflandırmak veya filtrelemek için kullanılabilir.

Ana dalgacığın ortalama değeri sıfırdır ve standart bir sinüs dalgasının aksine süresi sınırlıdır. Sinyalin bileşenlerinin yapısına uygun bir ana dalgacık seçilmesi durumunda bunun yüksek ölçekli versiyonuyla düşük frekanslar ve düşük ölçekli versiyonuyla da yüksek frekanslar yakalanır. En çok kullanılan dalgacık ailelerinden bazıları şunlardır: Morlet, Haar, Daubechies, Symlets, Gaussian.

DD, Sürekli Dalgacık Dönüşümü (SDD – Continuous Wavelet Transform (CWT)) ve Ayrık Dalgacık Dönüşümü (ADD – Discrete Wavelet Transform (DWT)) olmak üzere iki şekilde uygulanır. Her iki metot da isimlendirmelerinin aksine sınırlı sayıda olan ayrık örneklerle çalışır. Ancak SDD ölçeği ADD'den daha hassas bir şekilde ayırklaştırır. SDD, ana dalgacığın ölçeğini değiştirerek, ölçeklenmiş dalgacığı zamanda kaydırarak, sinyalle çarparak ve tüm zamanlarda integral alarak hesaplanır.

KZFD gibi, SDD de bir sinyal ile bir analiz fonksiyonu arasındaki benzerliği ölçmek için iç çarpım kullanır. Fakat SDD'de kompleks bir üstel terim yerine pencere fonksiyonu ( $\psi$ ) bir dalgacıktır. SDD, bir dalgacığın sıkıştırılmış veya uzatılmış biçimlerinin sinyal üstünde kaydırılmasıyla çalışır. Bir fonksiyonun genişletilmesi veya sıkıştırılması ölçeklendirme olarak adlandırılır ve fiziksel ölçek kavramına karşılık gelir.

SDD ile sinyal ile dalgacık arasındaki farklı ölçeklerdeki korelasyon elde edilir. Bir  $x(t)$  fonksiyonun  $s$  ölçeğinde ve  $\tau$  öteleme değerindeki SDD gösterimi Eşitlikte 2.19'daki gibidir.

$$SDD_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-\tau}{s}\right) dt \quad (2.19)$$


ADD ise her zaman tabanı 2'ye eşit olan üstel ölçekler kullanır. Böylelikle SDD'yle karşılaştırıldığında hesap yükünün azalmasına karşılık orijinal sinyalin analizi için yeterli seviyede bilgiyi sunabilmektedir. Birçok doğal sinyalin önemli özellikleri, tipik olarak orijinal sinyalden çok daha küçük olan ADD katsayılarının bir alt kümesi tarafından yakalanır. Bu şekilde sinyal sıkıştırılabilir, filtrelenebilir ve sinyalin öz nitelikleri çıkarılabilir.

ADD çalışması sırasında sinyal öncelikle alçak geçiren ve yüksek geçiren filtrelerden geçirilerek spektral bileşenler yarı yarıya azaltılır. Ortaya çıkan veriler 2 ile aşağı örneklenir. Filtreleme sırasında spektral bileşenlerin yarısının çıkarılması dolayısıyla alt örnekleme herhangi bir veri kaybına yol açmaz. Böylelikle ölçek iki katına çıkar. Arkasından alçak frekanslı alt bant, daha dar alçak ve yüksek alt bantlar elde etmek için aynı şema tarafından yinelemeli olarak filtrelenir.

$$y_{alçak} = \sum_n x(n) h(2k - n) \quad (2.20)$$

$$y_{yüksek} = \sum_n x(n) g(2k - n) \quad (2.21)$$

Eşitlik 2.20’de verilen alçak geçiren filtre çıkışında elde edilen yaklaşım (approximation, A) katsayıları ve Eşitlik 2.21’de verilen yüksek geçiren filtre çıkışında elde edilen detay (detail, D) katsayıları ADD metodunun çıktısıdır. Şekil 2.3'te gösterildiği gibi kademeli bir yaklaşım kullanılarak sinyalin yaklaşım ve detay katsayılarını dalgacık ayrışım ağacı oluşturur. Dalgacık ayrışım ağacı zaman-frekans yerelleştirmesine sahip bir alt uzayı temsil eden düğümlere sahip ikili bir ağaç olup bir filtre bankası olarak da bilinir. Detay ve yaklaşım katsayılarına uygulanan eşikleme işleminin arkasından TDD ile yeniden oluşturulan sinyal özel amaçlarla filtrelenebilir. Örneğin insan sesinden alçak frekansa sahip yaklaşım bileşenleri filtrelenerek çıkarılırsa içerik anlaşılmaz. Ancak yüksek frekanslı değerlerin katsayıları olan detay değerlerinin filtrelenmesi durumunda ses tonu değişse de içerik bozulmaz.



**Şekil 2.3:** Ayrık dalgacık dönüşümü ile detay ve yaklaşım katsayılarının hesaplanması

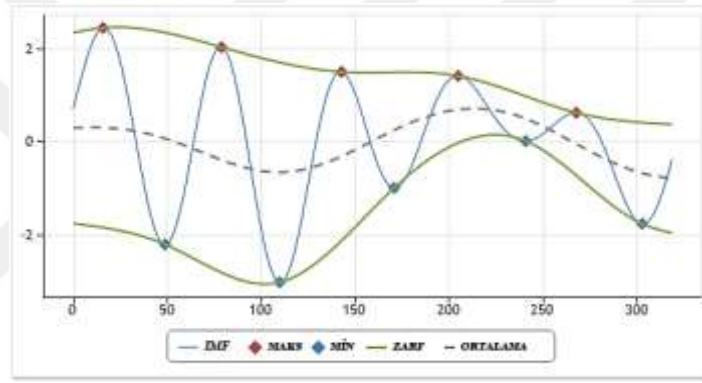
#### 2.4.4 Ampirik mod ayrıştırma

Ampirik Mod Ayrıştırma (AMA – Empirical Mode Decomposition (EMD)) yöntemi FD ve DD gibi sinyali frekans alanında bileşenlerine ayıran yöntemlerin aksine zaman alanında bir ayrıştırma yapmaya yarar. Huang ve arkadaşları [61] tarafından geliştirilen AMA ile durağan olmayan ve lineer olmayan sinyaller bir ön bilgiye ihtiyaç duyulmadan sıfır-ortalama genlikli ve frekans modülasyonlu bileşenlerine ayrıştırılıp bunlardan bozulma olmaksızın geri elde edilebilir [62]. AMA yöntemi Hilbert spektral dönüşümü ile beraber kullanıldığında birlikte Hilbert Huang Dönüşümü (HHD - Hilbert Huang Transform (HHT)) olarak adlandırılır.

AMA dekompozisyonunda amaç içsel özellikleri anlamaya ve analiz etmeye yardımcı olan veri bileşenlerini elde etmektir. Bu veri bileşenlerine içsel mod fonksiyonları (IMF – Intrinsic Mode Functions (IMF)) denir. Orijinal sinyal ile aynı uzunlukta ve sonlu olan IMF

bileşenleri genellikle az sayıda olurlar. Bu bileşenler, orijinal sinyal için tam ve neredeyse ortogonal bir temel oluşturur. Bunların incelenmesi sinyalin doğal özelliklerinin anlaşılmasına yardımcı olmaktadır.

IMF'lerin sağlamaları gereken bazı kurallar vardır. İlk olarak yerel ekstremum nokta sayısı ile sıfır kesiş sayısı arasındaki farkın sıfır veya en fazla bir olması gereklidir. Böylece sıfır noktası üzerinde herhangi bir yerel minimum ve sıfır noktası altında herhangi bir yerel maksimum bulunmaz. Bir IMF bileşeninin birbirini takip eden iki sıfır kesme noktası arasında sadece bir tane lokal ekstremum noktası bulunur. İkinci kural ise yerel maksimumlardan geçen zarf ile yerel minimumlardan geçen zarfın ortalama değerinin sıfır olması gerekliliğidir. Bu koşulları sağlayan IMF'ler iteratif olarak sinyal içerisinde hesaplanarak çıkarılırlar.



**Şekil 2.4:** Ampirik mod ayrıştırması

Orijinal sinyal, Eşitlik 2.22'de ifade edilen şekilde IMF'ler ve kalıntı (residual) sinyalden oluşmaktadır. Bu denklemde  $x$  orijinal sinyali,  $r$  kalıntıyı ve  $h_k$  de  $k$  sırasındaki IMF bileşenidir. Toplam IMF bileşen sayısı  $m$  ile verilmiş olup bu sayı her  $x$  sinyali için değişkenlik gösterebilir.

$$x(t) = \sum_{k=1}^m h_k(t) + r(t) \quad (2.22)$$

AMA ile IMF bileşenlerini elde etmek için sinyal üstünde kullanılan algoritmaya *Sifting işlemi* denir. Sifting işleminin sonucunda iteratif olarak elde edilen IMF'ler sıralarına göre yüksekten alçağa frekanslı bileşenler içerir. İlk IMF en yüksek frekansa sahipken en sonuncusu en düşük frekanslıdır. Sifting algoritmasının başlıca adımları şunlardır:

Başla

1.  $x(t)$  sinyalinden tüm yerel minimum ve maksimumların hesaplanır.
2.  $z_{\min}(t)$  ve  $z_{\max}(t)$  zarflarını elde etmek için yerel minimum ve maksimumlara kübik spline interpolasyonu uygulanır.
3. Üst ve alt zarfların ortalaması Eşitlik 2.23'e göre hesaplanır.

$$a(t) = \frac{z_{\min}(t) + z_{\max}(t)}{2} \quad (2.23)$$

4. IMF  $h_i(t)$ 'yi elde etmek için Eşitlik 2.24 ve 2.25'e göre  $a(t)$  ortalama zarfı  $x(t)$  sinyalinden çıkarılır.

$$h_i(t) = x(t) - a(t) \quad (2.24)$$

$$r_i(t) = x(t) - h_i(t) \quad (2.25)$$

5. IMF içermeye devam etmesi durumunda  $r_i(t)$  yeni sinyal olarak kabul edilip  $x(t)$  yerine kullanılarak 1-4 adımları tekrarlanır.
6.  $r_i(t)$  hiç IMF içermiyorsa kalıntı olarak kalır ve algoritma sonlandırılır.

Bitir

#### 2.4.5 Mel-frekans kepstrum katsayıları

Mel-frekans ölçeği ses frekanslarının değişimini incelemeye yarayan bir ölçektir. Mel-Frekans Kepstrum Katsayıları (MFKK – Mel Frequency Cepstrum Coefficients (MFCC)) da ses sinyalinin güç spektrumunun mel ölçeği üzerindeki ifadesidir. Ses sinyallerinin analizinde, müziksel bilgi ediniminde, konuşmacı tanımda ve bunların yanında biyomedikal seslerin incelenmesinde sıklıkla kullanılan özelliklerden birisidir [63]. MFKK özelliklerinin değerli bulunmasının bir sebebi sesleri frekanslarına göre ayırt etmede insanların işitsel yaklaşımını taklit etmesidir. İnsan kulağı duyduğu sesi tanımda oldukça üstündür. İnsanlar, 1KHz'e kadar olan sesleri lineer olarak algılamakta bunun üstünde frekansa sahip olanlar logaritmik ölçekte algılanır [8], [64].

MFKK özelliklerini elde etmek için öncelikle ön vurgulama aşamasında yüksek frekanslı bileşenlerin genlikleri yükseltilir. Böylelikle genellikle düşük frekanslı bileşenlere kıyasla küçük genliklere sahip olan yüksek frekanslı bileşenlerin spektrumdaki dengeleri sağlanırken sinyal gürültü oranı (SNR) iyileştirilir. Ön vurgulamada Eşitlik 2.26'da ifade edilen fonksiyonda  $\alpha$  değeri 0,9 ila 1 arasında alınır.

$$y(t) = x(t) - \alpha x(t - 1) \quad (2.26)$$

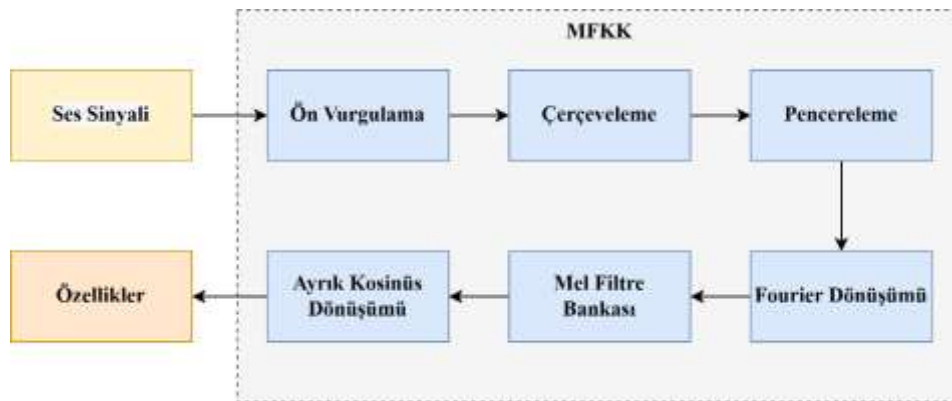
Arkasından durağan olmayan sinyal, belirli uzunlukta küçük çerçevelere bölünür. Çerçevenenerek bölünmüş sinyal parçalarının durağan olduğu kabul edilir. Genellikle birbirini takip eden çerçevelerin önceden tanımlanmış bir ölçüde çakışması istenir. Çerçevelerin üstünde Hamming, Hanning, Barlet, Gauss ve Blackman gibi fonksiyonlar ile pencereleme uygulanır. Böylelikle çerçevelerin başlarındaki ve sonlarındaki süreksizlik problemi ortadan kaldırılır ve kenarlar yumuşatılır. Eşitlik 2.27’de Hamming pencere fonksiyonu verilmiştir.

$$h(n) = 0,54 - 0,46 \cos\left(\frac{2\pi n}{N-1}\right) \quad (2.27)$$

Pencereleme uygulanan çerçevelerin üzerinde AFD uygulanarak zaman alanından frekans alanına geçilir. Bu aşamadan sonra sinyal Mel ölçeğine dönüştürülürken 1kHz’in altındaki frekans bileşenleri lineer olarak alınırken bunun üstündekileri logaritmik olarak Mel ölçeğine dönüştürülür.

$$F_{MEL} = \begin{cases} 2595 * \log\left(1 + \frac{f}{700}\right), & f > 1000Hz \\ f, & f \leq 1000Hz \end{cases} \quad (2.28)$$

Logaritmik formata oturtulan Mel spektrumunda sinyalle ilgili bilginin büyük bir bölümü ilk birkaç katsayıda saklıdır. Bu ölçek insan kulağının yaptığı gibi düşük frekansları lineer olarak birimlerken yüksek frekanstakileri logaritmik olarak algılar. Son olarak üzerinde ayrık kosinüs dönüşümü uygulanan veri kepsrum katsayıları adındaki özelliklere dönüşür.



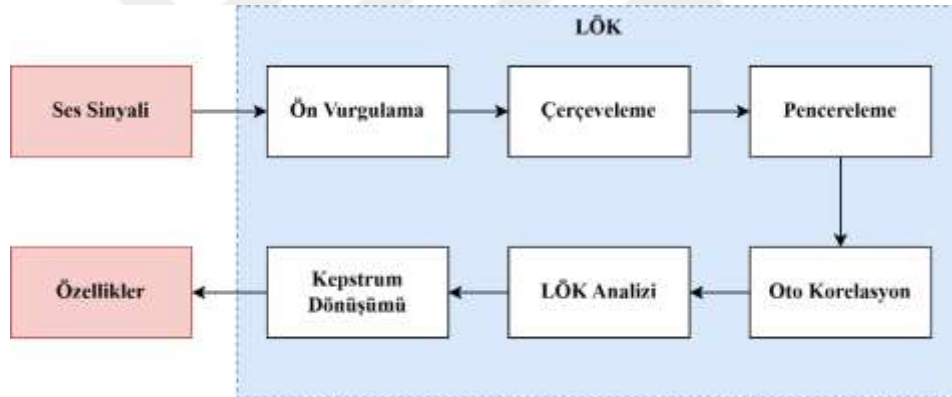
**Şekil 2.5:** MFKK özelliklerinin çıkarılma işleminin basamakları



## 2.4.6 Lineer öngörülü kodlama

Lineer Öngörülü Kodlama (LÖK – Linear Predictive Coding (LPC)) ses sinyallerinin veri transferi ve saklanması süreçlerinde sıkıştırılması amacıyla başvurulan bir yöntemdir. LÖK, yüksek sıkıştırma oranı ile ses sinyalinin analiz ve sentezini yapan diğer metotlar arasında önde gelen bir yere sahiptir. Ancak diğer ses kodlayıcılar gibi sesin kodlanması kaçınılmaz olarak kalitesinde kayba yol açar. LÖK işleminin devamında FD ile elde edilen Lineer Öngörüm Cepstrum Katsayıları (LÖKK - Linear Predictive Cepstrum Coefficients (LPCC)) sınıflandırma algoritmalarının eğitiminde özellik setleri olarak da kullanılabilir [65].

LÖK yöntemi, MFKK özelliklerinin çıkarılması sırasında izlenen ön vurgulama, çerçeveleme ve pencereleme adımlarını içermektedir. Pencereleme ayrılmış sinyale otokorelasyon uygulanır. Otokorelasyon değerlerinden elde edilen LÖK parametre kümesine FD uygulanarak LÖKK dönüşümü gerçekleştirilir. LÖKK özelliklerinin hesaplanması sırasında izlenen işlemlerin basamakları Şekil 2.6’da gösterilmiştir.



Şekil 2.6: LÖKK özelliklerinin çıkarılma işleminin basamakları

## 2.4.7 Spektral özellikler

Bir kaynaktan çıkan mekanik etkiyle katı, sıvı ve gaz ortamlarında iletilen basınç değişikliği ses dalgalarını oluşturur. Sesin saniyedeki titreşim sayısına frekans denir ve Hertz (Hz) ile ölçülür. Sesi oluşturan bir asal dalganın üstüne farklı frekanslardaki yan titreşimlerin (harmonik) binmesiyle karmaşık tınılarda sesler meydana gelir. İnsanlar tarafından işitilebilen sesler 20Hz-20 kHz frekans aralığında bir spektrum tayfidir. Bir  $x(n)$  sinyalinden elde edilen  $X(m)$  spektrum tayfindan frekans genlikleri Eşitlik 2.29’deki verilen şekilde elde edilir. Ses sinyalinden çıkarabilecek bazı spektral özellikler bu bölümde başlıklar halinde sunulmuştur.

$$A(f) = |X(f)| \quad f = 1, 2, \dots, m \quad (2.29)$$

### Spektral Ağırlık Merkezi

Spektral ağırlık merkezi (spectral centroid) spektrumun kütle merkezinin nerede olduğunu ifade eder. Enerjinin en fazla konsantre olduğu frekans bandını gösterir. Frekansların ağırlıklı ortalamasıdır. Frekansların genlikleri belirlenen sinyalde bulunan her bir frekansın genliğinin oranının söz konusu frekans değeriyle çarpılmasıyla hesaplanır.

$$p(f) = \frac{A(f)}{\sum_i A(i)} \quad (2.30)$$

$$\text{Spektral Ağırlık Merkezi} = \mu = \sum_f p(f) \cdot f \quad (2.31)$$

### Spektral Krest

Spektral krest'in (spectral crest) diğer bir ismi krest faktörüdür. Sinyaldeki tepe noktalarının bir dalga içinde ne kadar aşırı olduğunu gösterir. Yüksek olması sinyalin çokça tepe içermesi anlamına gelir. Tepe içermeyen sinyallerde (doğru akım, kare dalga gibi) ise değeri 1 olur. Dalganın tepe genliğinin gene dalganın karekök ortalamasına bölünmesiyle hesaplanır.

$$\text{Spektral Krest} = \frac{\text{Tepe Genliği}}{RMS} \quad (2.32)$$

### Spektral Entropi

Bir sinyalin spektral entropisi (spectral entropy), spektral güç dağılımının bir ölçüsüdür. Bir sinyalin frekans alanındaki normalleştirilmiş güç dağılımını bir olasılık dağılımı olarak ele alıp bundan Shannon entropisini hesapladığımızda spektral entropiyi elde ederiz. Frekans spektrumundan olasılık yoğunluk fonksiyonu  $P(m)$  hesaplanır. Buradan da spektral entropi  $H$  Eşitlik 2.35'teki gibi hesaplanır.

$$A(f) = |X(f)| \quad (2.33)$$

$$P(m) = \frac{A(m)}{\sum_i S(i)} \quad (2.34)$$

$$H = - \sum_{m=1}^N P(m) \log_2(P(m)) \quad (2.35)$$

### Spektral Akı

Spektral akı (spectral flux), bir sinyalin güç spektrumunun ne kadar hızlı değiştiğinin bir ölçüsüdür. Bir çerçevenin spektrumunun bir sonraki çerçevenin spektrumuyla karşılaştırılmasıyla hesaplanır.

### **Spektral Yayılma**

Spektral yayılma (spectral spread), hesaplanan spektral ağırlık merkezi etrafındaki spektrumun varyansının bir ölçüsüdür.

$$\sigma^2 = \sum_f (f - \mu)^2 p(f) \quad (2.36)$$

### **Spektral Çarpıklık**

Spektral çarpıklık (spectral skewness), bir sinyalin frekans alanındaki bileşenlerinin çarpıklığıdır. Çarpıklık, ortalama değer etrafındaki dağılımın asimetrisinin bir ölçüsüdür. Sinyalin spektrumunun üçüncü momentidir.

$$m_3 = \sum_f (f - \mu)^3 p(f) \quad (2.37)$$

### **Spektral Basıklık**

Spektral basıklık (spectral kurtosis), bir sinyalin frekans alanındaki bileşenlerinin basıklığıdır. Sinyalin spektrumunun dördüncü momentidir. Enerji dağılımının sivriliği veya düzlüğünü ifade eder. Durağan sinyaller için sıfıra yakındır.

$$m_4 = \sum_f (f - \mu)^4 p(f) \quad (2.38)$$

### **Spektral Yuvarlanma Noktası**

Spektral yuvarlanma noktası (spectral roll off point), bir sinyalin belirli bir eşik değeri için aldığı bir frekans değeridir. Bu eşik değeri yüzde cinsindedir. Sinyalin toplam spektral enerjisinin yüzdesinin altında olduğu frekans bu noktayı tanımlar. Spektral yuvarlanma noktası olarak tanımlanan frekans değerinin altında toplam spektral enerjinin belirli bir yüzdesi yatar.

### **Spektral Eğim**

Spektral eğim (spectral slope),  $A(f)$  genliğinin azalma hızının bir göstergesini verir. Bu değer, doğrusal bir regresyon kullanılarak hesaplanan, bir sesin spektrumunun yüksek frekanslara doğru ne kadar hızlı azaldığının bir ölçüsüdür.

#### 2.4.8 İstatistiksel özellikler

PCG kayıtlarındaki kalp sesi sinyallerinden çok sayıda istatistiksel öznitelik çıkarılabilir. Bunlar zaman alanı perspektifinden gözlemlenebilen çeşitli morfolojik özellikleri yansıtmaktadır. Bu özniteliklerin sinyalden çıkarılıp anlamlı bir şekilde yorumlanması PCG kayıtlarından bilgisayar destekli sistemlerle üfürüm tespiti yapan yöntemlerin başarısını doğrudan etkileyebilmektedir.

Ortalama, standart sapma, medyan, sinyal enerjisi, maksimum, minimum ve sıfır geçiş oranı gibi en sık kullanılan zaman alanı özellikleri, doğrudan sinyalin kendisinden hesaplanır. Ayrıca, sinyaller olasılık yoğunluk fonksiyonlarına dönüştürülebilir ve entropileri farklı yöntemlerle hesaplanabilir. S1, sistol, S2 ve diyastol bölümlerin maksimum, minimum ve ortalama süreleri özellik olarak kullanılabilir.

Araştırmalarda yaygın olarak kullanılan zaman alanı özelliklerinden bazıları Çizelge 2.4'te verilmiştir.

**Çizelge 2.4: İstatistiksel özellikler**

Özellik	Formül	
<b>Ortalama</b>	$\bar{\mu} = \frac{1}{N} \sum_{i=1}^N S(i)$	(2.39)
<b>Standart sapma</b>	$\sigma^2 = \sqrt{\frac{\sum_i^N (S(i) - \bar{\mu})^2}{N}}$	(2.40)
<b>Çarpıklık</b>	$\left[ \frac{1}{N} \sum_i^N (S(i) - \bar{\mu})^3 \right] / \sigma^3$	(2.41)
<b>Basıklık</b>	$\left[ \frac{1}{N} \sum_i^N (S(i) - \bar{\mu})^4 \right] / \sigma^4$	(2.42)
<b>Bölümlerin ortalaması</b>	$\mu_j = \frac{1}{n} \sum_{i=1}^n S_{ij}$	(2.43)
<b>Bölümlerin ortalamalarının varyansı</b>	$\frac{1}{k} \sum_j^k (\mu_j - \bar{\mu})^2$	(2.44)
<b>Bölümlerin varyanslarının ortalaması</b>	$\frac{1}{k} \sum_j^k \frac{1}{n} \sum_i^n (S_{ij} - \bar{\mu})^2$	(2.45)
<b>F oranı</b>	$\frac{1/k \sum_j^k (\mu_j - \bar{\mu})^2}{1/k \sum_j^k 1/n \sum_i^n (S_{ij} - \bar{\mu})^2}$	(2.46)
<b>Çerçeve k'nin ortalama enerjisi</b>	$E(k) = \frac{1}{N} \sum_{i=1}^N  S[k, i] ^2$	(2.47)
	$x(i) = \begin{cases} 1, & S(i+1) > S(i) \\ 0, & \text{diğer durumlar} \end{cases}$	(2.48)
<b>Lempel-Ziv Skoru</b>	$LZS(S) = \frac{\sum x(i) * \log(n)}{n}$	(2.49)
<b>Maksimum-minimum farkı</b>	$\max(S) - \min(S)$	(2.50)
<b>Ortalama Shannon enerjisi</b>	$-\frac{1}{N} \sum_{n=1}^N S^2(n) \log(S^2(n))$	(2.51)
<b>RMS</b>	$\sqrt{\frac{1}{N} \sum_{n=1}^N S^2(n)}$	(2.52)
<b>Sıfır geçme oranı</b>	$\frac{1}{2N} \sum_{i=1}^N  sgn[x(i)] - sgn[x(i-1)] $	(2.53)
<b>Entropi</b>	$\sum p_{S(i)} \log(p_{S(i)})$	(2.54)

## 2.5 Sınıflayıcılar

Mevcut verilerden çıkarılan özellikleri kullanarak sınıfları bilinmeyen verilerin eğitim ve test aşamalarıyla kategorize edilerek sınıf etiketlerinin tahmin edilmesine sınıflandırma denilir. Sınıflandırmada çıktı, verinin önceden tanımlı olan kategorilerle etiketlenmesidir. Çıktıyı tanımlayan etiketlere sınıf ve bu işlemi yapan fonksiyona da sınıflayıcı denilir. Bu süreçte sınıfların sayısı ve isimleri önceden belirli olduğu için sınıflama işlemi denetimli (supervised) bir öğrenmedir.

İnsanların doğadaki canlı ve cansız nesnelere baktığında bunları yorumlarken ilk başvurduğu yöntemlerden birisi sınıflandırmadır. Bilimsel bir bakış açısıyla objeler; canlı/cansız, katı/sıvı/gaz, insan/hayvan/bitki vb. gibi şekillerde kategorize edilir ve farklı sınıflara ayrılır. Sınıflayıcıların kullanıldığı uygulama alanları elektronik ticaretten sigortacılığa, sağlık ve ilaç sektöründen pazarlama ve satış-tahmin analizine kadar genişir.

Eğitim aşamasında sınıflayıcı modeli oluşturulurken girdi olarak verilen parametrelerin yanında eğitim kümesindeki değişkenlerin etiketleri de denetim amacıyla verilir. Bu girdiler yardımıyla oluşturulan sınıflayıcı modelinin veri setini en optimal şekilde tanıması beklenir. Eğitim kümesinden ayrı tutulan değişkenler ile validasyon kümesi oluşturulur. Sınıflayıcı modeli validasyon kümesi üzerinde çalıştırılarak değişkenleri tanımadaki performansı test edilir. Bu aşama nihai test olmayıp doğrulama amacıyla yapılır. Bu aşamada elde edilen sonuçlara göre modelde kullanılan hiper-parametreler ayarlanabilir (tuning). Son aşama olarak ise test kümesinde bulunan ve sınıflayıcının önceden görmediği değişkenler model tarafından tanınmaya çalışılır. Bu aşamada elde edilen performans sınıflayıcının test performansısıdır.

### 2.5.1 K en yakın komşu algoritması

K En Yakın Komşu (KEYK – k Nearest Neighbor (kNN)) algoritması örnekler üzerinden öğrenme yoluyla çözüm sunan bir metottur. Bütün verilerin veri uzayında saklanmasına ve yeni bir örneğin test aşamasında değerlendirilmesi sırasında buradaki verilerin hepsinin yeni örnekle benzerliğinin incelenmesine dayanır. Bir diğer ifadeyle sınıfının tahmin edilmesi istenen değişkene en yakın olan komşuların hangi sınıflara ait olduğuna bakılarak en çok benzerliğin olduğu sınıfın türüyle değişken etiketlenir. KEYK algoritmasının bir özelliği, verilerin yerel yapısına duyarlı olmasıdır.

KEYK algoritması oldukça sade ve anlaşılırdır. Eğitim aşamasında herhangi bir işlem yaparak zaman harcamaz. Eğitim verilerinden ayırt edici bir işlev öğrenmez, bunun yerine eğitim veri setindeki değişkenleri basitçe ezberler. Fakat bu özelliği onu en yavaş çalışan sınıflayıcılardan birisi yapar [66] ve tembel olarak tanımlanan bir sınıflayıcıdır. Üstelik veri seti büyüdükçe KEYK algoritmasının çalışma süresi lineer olarak artar.

KEYK çalışması sırasında en önemli faktör zengin bir örnek uzayına sahip olmaktır. Bununla birlikte uzaklık hesabını yapmada kullanılan ölçü ve k hiper-parametresinin seçimi performansı etkileyen faktörlerdir. Değişkenler arasındaki uzaklıkların tutulduğu matrisi oluştururken Öklid, Manhattan, Minkowski vb. mesafe hesaplamaları kullanılabilir. Buna göre test edilen değişkenin en yakın k tane komşusu bulunur ve bunlara bakılarak değişken uygun sınıfa atanır.

$$\text{Öklid Mesafesi} = \sqrt{\sum_{i=1}^d (x_i - y_i)^2} \quad (2.55)$$

$$\text{Manhattan Mesafesi} = \sum_{i=1}^d |x_i - y_i| \quad (2.56)$$

$$\text{Minkowski Mesafesi} = \left( \sum_{i=1}^d (|x_i - y_i|^q) \right)^{1/q} \quad (2.57)$$

### 2.5.2 C4.5 karar ağacı

Sınıflandırma ve regresyon problemlerinin çözümünde kullanılan ağaç tabanlı bir algoritmadır. Karar ağaçları kök, düğüm, dal ve yapraklardan oluşur. Ağacın ilk düğümü onun köküdür. Diğer düğümler ise kökten dallarla ayrılırlar. Bir düğüm alt düğümlere yol verecek şekilde bölünebiliyorsa karar düğümü olarak adlandırılır. Bölünmeyen ve ağacın terminal noktalarını oluşturan düğümlere ise yaprak denir. Karar ağaçları verileri sınıflandırırken bunu hangi kurallara göre yaptığını sade ve net bir şekilde ortaya koyar. Sınıflandırma bir dizi kurala göre yapılır ve bu kurallar hem nominal hem de sayısal girdilere göre oluşturulabilir. Karar ağacı eğitim aşamasında bir kere oluşturulduktan sonra test aşamasında çok fazla işlem yapmadan değişkenleri sınıflandırır.

ID3 karar ağacı algoritmasının geliştirilmiş bir versiyonu olan C4.5, entropi ve bilgi kazancı kavramları ile yakından ilişkilidir. Bilgi entropisi, bir veri kümesindeki saf olmama (heterojenlik) durumunun ölçütüdür. Veri setindeki değişkenlerin tahmin edilebilirliği yükseldikçe entropi değeri de sifra yaklaşır. Bilgi kazancı ise veri seti üstünde yapılan bir

transformasyonun entropi deęişikliğine bakılarak ne kadar olumlu olduğunu gösterir. Bu özellikler karar ağaçlarında özellik seçimi sırasında göz önünde bulundurulur.

Bir kümedeki tüm deęişkenler aynı sınıfla etiketlenene kadar veri seti iteratif olarak küçük kümelere ayrılır. ID3 karar ağaçlarında bu bölünmelerin en verimli şekilde gerçekleştirilebilmesi için bölünmüş grupların entropi deęerleri karşılaştırılır. Bilgi kazancı yüksek olan bir özellik seçilerek veri seti bölünürse daha homojen ve dolayısıyla entropisi düşük alt kümeler elde edilir. Fakat bilgi kazancı, fazla kategoriye sahip özellikleri daha düşük entropiye sahip olmaları sebebiyle tercih etme eğilimindedir. Bu durum eğitim setinin aşırı öğrenimine yol açabilir. Bu durumla başa çıkacak şekilde modifiye edilen C4.5 karar ağaçlarında doğrudan bilgi kazancının kullanılması yerine kazanç oranı kullanılır. Kazanç oranı kullanımında daha fazla kategoriye sahip olan özellikler cezalandırılarak tercih edilme şansları azaltılır.

Toplam sınıf sayısı  $n$  ve bir sınıfa ait deęişken sayısı  $C_i$  olmak üzere bir sınıfın olasılık deęeri  $P_i$  Eşitlik 2.58'deki gibi hesaplanır.

$$P_i = \frac{C_i}{\sum_j^n C_j} \quad (2.58)$$

Toplam  $n$  tane sınıftan deęişkenler içeren  $T$  kök düęümüne sahip veri setinin entropisi  $H$  ise Eşitlik 2.59'daki gibi hesaplanır.

$$H(T) = - \sum_i^n P_i \log(P_i) \quad (2.59)$$

Veri seti  $f$  özellięi kullanılarak bölündüğünde  $A$  ata düęümü ve  $C_i$  çocuk düęümleri olmak üzere bilgi kazancı Eşitlik 2.60'da verilen şekilde elde edilir.

$$\text{Bilgi Kazancı}(f, A) = H(A) - \sum_i^{|A|} H(C_i) \quad (2.60)$$

Bilgi kazancı ve bölünme bilgisinden bilgi kazancı oranı Eşitlik 2.61'de ifade edilen şekilde hesaplanır. Eşitlik 2.62'de  $A_{f,v}$  ile  $A$  veri setinin  $f$  özellięi  $v$  deęerine sahip olan deęişkenler gösterilmiştir.

$$\text{Bilgi Kazancı Oranı}(f, A) = \frac{\text{Bilgi Kazancı}(f, A)}{\text{Bölünme Bilgisi}(f, A)} \quad (2.61)$$



$$Bölünme\ Bilgisi(f, A) = - \sum_{v \in A_f} \frac{|A_{f,v}|}{|A_f|} \log\left(\frac{|A_{f,v}|}{|A_f|}\right) \quad (2.62)$$

#### C4.5 Kaba kodu

Temel Durumlar:

- Listedeki tüm örnekler aynı sınıfa aittir. Bu olduğunda, C4.5 ağacın o sınıfı seçmesini söyleyen bir yaprak düğüm oluşturur.
- Özelliklerin hiçbiri herhangi bir bilgi kazancı sağlamaz. Bu durumda C4.5, sınıfın beklenen değerini kullanarak ağacın yukarısında bir karar düğümü oluşturur.
- Daha önce görülmemiş bir sınıftan örnekle karşılaşılması durumunda C4.5 beklenen değeri kullanarak ağacın yukarısında bir karar düğümü oluşturur.

Başla

1. Temel durumlar kontrol edilir ve gerekliyse prosedür bitirilir
2. Her a özelliği için, a'dan bölünen ağaçtan elde edilen normalleştirilmiş bilgi kazanç oranı bulunur.
3. a\_best en yüksek normalleştirilmiş bilgi kazancına sahip özellik olsun.
4. a\_best üzerinde bölünmeyle bir karar düğümü (n\_best) oluşturulur.
5. Elde edilen altkümeler üzerinde prosedür yinelenir ve elde edilen yeni düğümler n\_best'in çocukları olarak eklenir.

Bitir

#### 2.5.3 Destek vektör makineleri

1990'lı yıllarda Vapnik ve arkadaşları [67] tarafından geliştirilen Destek vektör makineleri (DVM – Support Vector Machine (SVM)) istatistiksel öğrenme tabanlı bir sınıflayıcıdır. Diğer bir ismi de Destek Vektör Ağları'dır (Support Vector Network). Özellik seti n boyutlu bir uzay oluşturan değişkenlerin hem regresyon analizinde hem de sınıflandırmasında kullanılabilir.

DVM algoritması ikiden çok sınıfa ait değişkenleri sınıflandırmada kullanılabilir ama sınıflandırma algoritması bir seferde veriyi iki sınıfa ayıracak şekilde çalışır. Eğitim seti k tane eleman içeren veri kümesini  $\{x_i, y_i\}; i = 1, 2, 3, \dots, k$  olarak tanımlarsak  $x_i \in R^n$  n boyutlu özellik vektörlerini ve  $y_i \in \{-1, 1\}$  de etiket değerlerini tanımlar. İki sınıfı birbirinden ayırmak için eğitim aşamasında bu sınıflara ait değişkenlerin arasından geçen bir karar sınırı belirler. Değişkenlerin özellik sayısına göre bu sınır; tek boyutlu bir doğru, iki


boyutlu bir düzlem veya çok boyutlu bir hiper düzlemdir. Bu hiper düzlem sınırı veri seti uzayının bir alt düzlemidir. Ayrıcı hiper düzlem üstündeki herhangi bir nokta  $x$ , hiper düzlem normali  $w$  ve sapma (bias) da  $b$  olmak üzere ayırıcı hiper düzlem denklemi Eşitlik 2.63'teki gibi olur.

$$h_{w,b}(x) = g(w^T x + b) = 0 \quad (2.63)$$

Hiper düzlem bulunurken buna paralel olan ve sınırlarını belirleyen iki hiper düzlem daha belirlenir. Destek vektörleri bu düzlemlerin üstünde yer alır. Bunlar şöyle tanımlanabilir:

$$H_{1,2} = \begin{cases} w^T x + b \geq +1, & y_i = +1 \\ w^T x + b \leq -1, & y_i = -1 \end{cases} \quad (2.64)$$

DVM sınıflayıcısının üstün bir özelliği eğitim aşamasında gördüğü veri setinin bir alt kümesini kullanarak karar fonksiyonunu tanımlayabilmesidir. Böylelikle hafıza kullanımı daha az olur. DVM sınıflayıcısının kullanmak için seçtiği ve hiper düzleme en yakın olan bu değişkenler destek vektörleri olarak adlandırılır. Bunlarla marjinin sınırları belirlenir. DVM, sınıfları ayırırken destek vektörleri ile hiper düzlem arasındaki marjin mesafesini maksimize edecek optimal bir düzlem bulmaya çalışır.



**Şekil 2.7:** DVM parametreleri.  $w$ : hiper düzlemin normali,  $A$ : pozitif sınıfa ait bir destek vektörü,  $A'$ :  $A$  vektörünün hiper düzlem üzerine izdüşümü,  $d$ : marjin uzaklığı,  $m$ : normu  $d$  olan ve  $w$  ile aynı yönlü bir vektör

Verilerin doğrusal olarak sınıflandırılabilmesi veya sınıflandırılmaması DVM için sorun teşkil etmektedir. Doğrusal olarak sınıflandırılmayan veri setlerini incelediğimizde DVM tarafından çözüm için doğrudan bir hiper düzlem bulunamadığını görürüz. Çünkü veriler uzayda doğrusal olarak dağılmadığı durumlarda doğrusal bir hiper düzlem ile bunları ayırmak da mümkün değildir. Bu tür durumlarda DVM, çekirdek numarası (Kernel trick) kullanarak çözüm sunabilir. Doğrusal olarak ayrılmayan sınıflandırma problemlerinde DVM, çekirdek numarasıyla veri setini daha yüksek dereceli bir uzaya taşır ve burada veri

setini ayırabildiği bir hiper düzlem bulmaya çalışır. Kullanılan bazı çekirdek fonksiyonları şunlardır:

- Doğrusal fonksiyon
- Polinomial fonksiyon
- Radyal tabanlı fonksiyon
- Sigmoid fonksiyon

Şekilde verilen ve doğrusal olarak ayrılan örnek veri setinde  $\langle w, A' \rangle + b = 0$  olmak üzere pozitif sınıf için  $\langle w, x_i \rangle + b \geq 1$  ve negatif sınıfa ait bir değişken için  $\langle w, x_i \rangle + b \leq -1$  uygun alanları ifade eder. Eşitlik 2.65 ile gösterilen fonksiyonel marjin bu iki ifadenin tek bir denklemlerle ifade edilmiş halidir.

$$y_i(\langle w, x_i \rangle + b) \geq 1 \quad (2.65)$$

İki sınıf değişkenleri arasında sonsuz farklı hiper düzlem çizilebilir. Veri setini iki sınıfa en iyi şekilde ayıran hiper düzlemi bulmak için destek vektörleri ile karar sınırı arasındaki  $d$  uzunluğundaki marjinlerin en büyük olmasını hedefleriz. Dolayısıyla optimal hiper düzlem bulunurken  $2d$  değeri maksimize edilirken Eşitlik 2.65'te verilen koşul sağlanmalıdır.

$$m = d \cdot \frac{w}{\|w\|} \quad (2.66)$$

$$A' = A - m = A - d \cdot \frac{w}{\|w\|} \quad (2.67)$$

$$\langle w, A' \rangle + b = 0 \quad (2.68)$$

$$\langle w, A - d \cdot \frac{w}{\|w\|} \rangle + b = 0 \quad (2.69)$$

$$\langle w, A \rangle - \langle w, d \cdot \frac{w}{\|w\|} \rangle + b = 0 \quad (2.70)$$

$$\langle w, A \rangle - d \langle \frac{w, w}{\|w\|} \rangle + b = 0 \quad (2.71)$$

$$\langle w, A \rangle - d \frac{\|w\|^2}{\|w\|} + b = 0 \quad (2.72)$$

$$d = \frac{|\langle w, A \rangle + b|}{\|w\|} = \frac{1}{\|w\|} \quad (2.73)$$

Maksimize edilmek istenen  $2d$  ifadesi  $2d = \frac{2}{\|w\|}$  yerine türevinin alınması daha kolay olan ve aynı sonucu verecek olan  $\frac{1}{2} \langle w, w \rangle = \frac{\|w\|^2}{2}$  ifadesi minimize edilebilir. Eşitlik 2.65'te verilen koşulla birlikte bu minimizasyon problemi Lagrange çarpanları yöntemiyle çözülebilir.

$$L = \frac{\|w\|^2}{2} - \sum_i \alpha_i (y_i (wx_i + b) - 1) \quad (2.74)$$

$$\frac{\partial L}{\partial w} = w - \sum_i \alpha_i y_i x_i = 0 \quad (2.75)$$

$$w = \sum_i \alpha_i y_i x_i; \exists i, \alpha_i = 0 \quad (2.76)$$

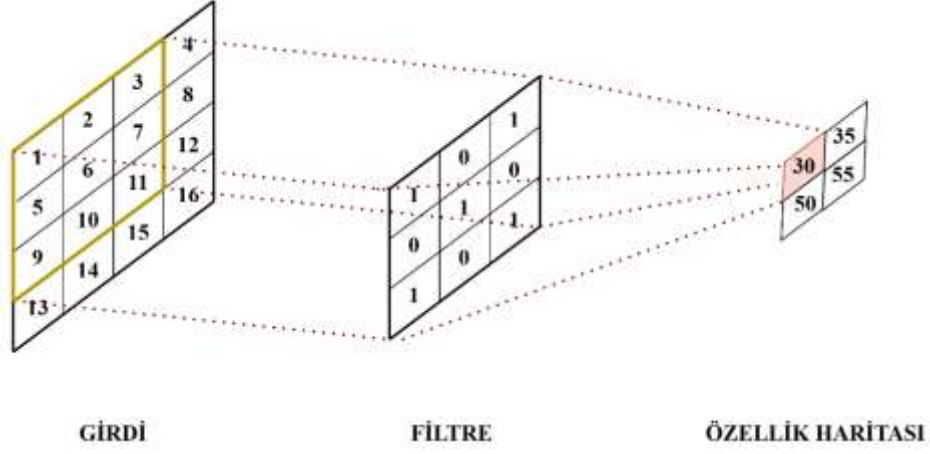
$$\frac{\partial L}{\partial b} = - \sum_i \alpha_i y_i = 0 \quad (2.77)$$

Çözümde elde edilen Lagrange çarpanlarının bir kısmının sıfır olduğu görülecektir. Bunlar  $H_1$  ve  $H_2$  düzlemlerinin arkasında kalan değişkenlerdir. Değeri sıfırdan büyük olan az sayıdaki  $\alpha_i$  çarpanlarına karşılık gelen  $x_i$  değişkenleri de bu iki düzlemin üstünden geçtiği destek vektörleridir.

#### 2.5.4 Evrişimsel sinir ağı

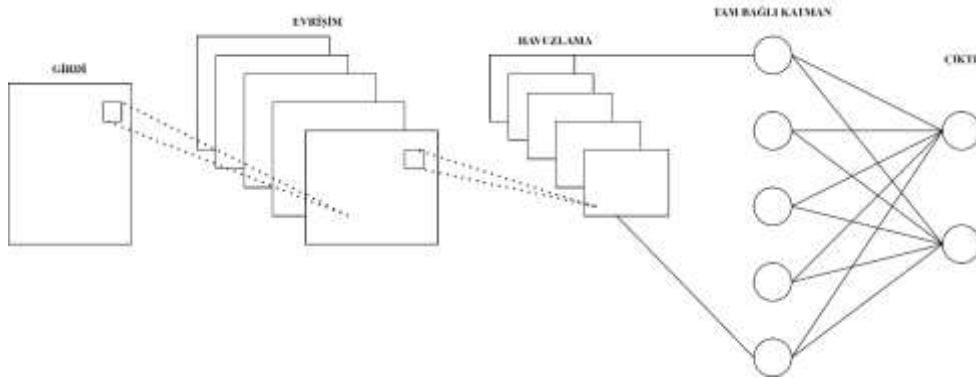
Evrişimsel sinir ağı ((ESA) - Convolutional Neural Network (CNN)) temeli derin öğrenmeye dayanan bir yapay sinir ağı modelidir. Görüntü tanıma, video inceleme, medikal görüntü analizi, kalp sesi sınıflandırma, doğal dil işleme, öneri sistemleri vb. birçok alanda yüksek başarı oranlarıyla kullanılmaktadır. ESA modellerini YSA modellerinden ayıran özellik en az bir tane evrişim katmanına (konvolüsyon) sahip olmasıdır. LeCun ve diğ. [68] tarafından geliştirilen ESA mimarisi, çoğunlukla uygulandığı görüntü analizinde öteleme ve dönme nedeniyle karşılaşılan problemlere karşı toleranslı bir yapıya sahiptir.

ESA modelinde evrişim katmanı filtre gibi girdi üzerinde lineer bir matris işleminin gerçekleşmesinde kullanılarak çıktı olarak yine bir matris üretir. Filtre ile evrişim işleminin sonucunda bir özellik haritası oluşturulmuş olur. Elde edilen özellik haritası kullanılan filtre sayısına, filtrenin adım büyüklüğüne (stride) ve taşma olması durumunda kenarların sıfırla doldurularak genişletilmesine (padding) bağlı olarak değişiklik gösterir.



**Şekil 2.8:** Evrişim katmanından özellik haritası oluşturma

Klasik makine öğrenmesi metotlarının önemli bir aşaması özellik çıkarımıdır. Ele alınan probleme göre anlamlı özniteliklerin çıkarılması ve gereksiz olanlarla sistemin yüklenmemesi sınıflayıcıların başarısını oldukça etkileyen bir faktördür. Buna karşılık ESA modelleri özellik çıkarımının model içerisinde gerçekleştiği bir yapı sunar. ESA modelleri lokal filtreler, havuzlama yöntemi ve evrişim algoritması ile klasik YSA modellerinden ayrılmaktadır. Katmanların seçimi, sayısı ve hiyerarşisi çözülmek istenen probleme göre değişiklik gösterir. ESA modelinin eğitimi boyunca katmanlarda yer alan nöronların uygun ağırlıkları bulmaları için binlerce parametreleri içeren hesaplamalar yapılması gerekmektedir. Katmanların sayısı ve çeşitliliği bu hesapsal yükü artırmaktadır. Günümüzdeki bazı ESA modellerinin milyonlara varan işlem yükü, GPU donanımına dayanan hızlı hesaplama teknolojileri ile çözülmektedir.

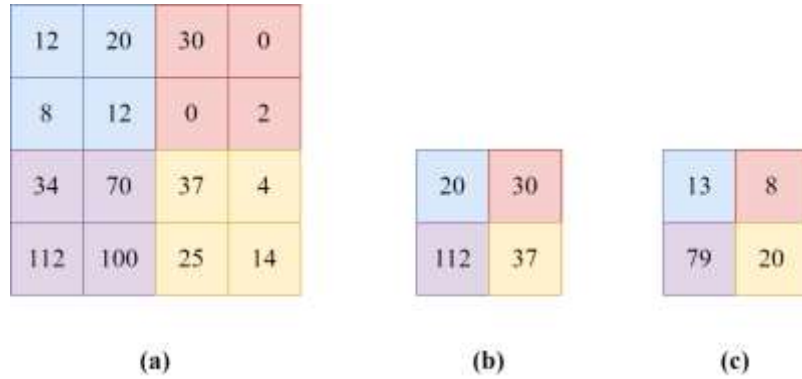


**Şekil 2.9:** Evrişimsel sinir ağı modeli

Girdi katmanından alınan veriler, evrişim ve havuzlama katmanlarından geçirilip tam bağlantılı sınıflandırma katmanlarıyla çıktıya dönüştürülür. Her bir katman girdi olarak bir önceki katmanın çıktısıyla beslenir. Evrişim katmanında filtre, bir önceki katmandan gelen

verinin üzerinde gezdirilerek filtrenin boyutlarıyla orantılı olarak genişlik, yükseklik ve derinlikte özellik haritaları oluşturulur. Evrişim katmanında oluşturulan özellik haritalarının yüksek olan boyutları havuzlama katmanlarında işlenerek küçültülür. Havuzlama işleminde filtre içine alınan matrisin ortalaması veya en büyük değeri alınabilir. Tam bağlı katman ESA mimarisinin en sonunda yer alır. Tam bağlı katman YSA benzeri bir yapıda olup birbirleriyle tam bağlı nöronlardan oluşur. Özellik haritaları tek boyutlu bir vektöre çevrilerek tam bağlı katmanlarca işlenir. Modelin veriyi ezberlemesinin önüne geçmek için bu katmanda seyreltme katmanları kullanılır. Seyreltme katmanı 0 ile 1 arasında bir değer alarak bu aldığı değere göre rastgele bazı nöronları iptal eder. Tam bağlı katmanların arkasından yumuşak bağlı (softmax) katmanla çıktı [0-1] arasına normalize edilir ve en yüksek değere sahip sınıf, model tarafından tahmin edilir.

ESA modelinin eğitimi önceden tanımlanmış bir tur sayısı kadar veya sonuçlar yeterince iyileşinceye kadar sürer. Her bir eğitim turunda model, kullanılan hata fonksiyonuyla tahmin ettiği değerlerin gerçek sonuçlara ne ölçüde yaklaştığını kontrol eder. Daha sonra bir optimizasyon fonksiyonu yardımıyla hata değerini azaltmak için model parametreleri güncellenir. Vanilla Stochastic Descent (VSD), Stochastic Gradient Descent with Momentum (SGDM), RMSProp ve ADAM bu amaçla kullanılan bazı optimizasyon fonksiyonlarıdır.



**Şekil 2.10:** Havuzlama katman örneği (a) özellik haritası, (b) maksimum havuzlama sonucu, (c) ortalama havuzlama sonucu

Evrişim katmanından elde edilen özellik haritalarının basit bir doğrusal fonksiyon olmaması için çeşitli aktivasyon fonksiyonları kullanılır. Böylelikle modelin öğrenme gücü doğrusal olmayan durumları da kapsayacak şekilde güçlendirilmiş olur. Ağırlıklarla çarpılıp, bias eklenen sonucun üzerinde aktivasyon fonksiyonu uygulanarak çıktı elde edilir. Sıklıkla kullanılan bazı aktivasyon fonksiyonları Çizelge 2.5'te verilmiştir.

**Çizelge 2.5:** Aktivasyon fonksiyonları

Aktivasyon Fonksiyonu	Tanımı	
<b>Sigmoid</b>	$f(x) = \frac{1}{1 + e^{-x}}$	(2.78)
<b>Hiperbolik tanjant</b>	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	(2.79)
<b>ReLU</b>	$f(x) = \max(0, x)$	(2.80)
<b>Basamak fonksiyonu</b>	$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$	(2.81)

### 2.5.5 Tekrarlayan sinir ağırları


Bir görüntünün benzerlerini bulmak veya görüntü içerisinde nesne aramak gibi makine öğrenmesi problemleri genellikle konvolüsyon katmanlarına sahip olan ESA mimarilerinin kullanıldığı derin öğrenme ağlarıyla çözülmektedir. Buna karşılık sesin metne dönüştürülmesi, sentetik metin oluşturulması, hisse senedi değeri tahmini, bir dildeki metnin başka bir dile tercümesi gibi seri-seri dönüşümüne dayanan problemler için Tekrarlayan Sinir Ağları (TSA - Recurrent Neural Network (RNN)) tercih edilmektedir.

Klasik YSA modellerinde çıktılar önceki girdilerden bağımsız hesaplanır. TSA mimarisinin arkasında yatan fikirse girdiler arasındaki ardışık ilişkiyi kullanmaktır. TSA modelleri çıktıyı hesaplarken bir önceki adımda kullanılan girdiyi ezberler ve hesaplamalarında ondan yararlanır. Giriş ve çıkış dizilerinin uzunluğuna bağlı olarak TSA modelleri bire bir, bire çok, çoktan bire veya çoktan çoğa olarak kategorize edilebilir. Eşitlik 2.5.5-1 ve 2.5.5-2’de TSA katmanlarında kullanılan tekrarlamalı formül verilmiştir.

$$h_t = \phi_h(W_h x_t + U h_{t-1}) \quad (2.82)$$

$$y_t = \phi_y(V_y h_t + b) \quad (2.83)$$

Eşitlikler 2.82 ve 2.83’te  $h_t$  ile t anındaki durum,  $x_t$  ile t anındaki girdi vektörü,  $W_h$  ile girdi vektörünün ağırlığı,  $U$  ile  $h_{t-1}$  bir önceki durumunun ağırlığı,  $y_t$  ile çıktı,  $V_y$  ile çıktının hesaplanmasında durumun ağırlığı,  $b$  ile bias ve  $\phi$  ile aktivasyon fonksiyonları ifade edilmektedir. Aktivasyon fonksiyonu sigmoid, tanh gibi bir eşikleme fonksiyonudur ve toplamın iraksamasının önüne geçmek için kullanılması gerekmektedir.



**Şekil 2.11:** Tekrarlayan sinir ağı modeli mimarisi

TSA modelleri çıktıda alınan hatayı azaltmak için eğitimleri sırasında Zaman İçinde Geri Yayılım (ZİGY - Backpropagation Throgh Time (BPTT)) yöntemiyle ağırlıkları güncellerler. Ağırlıkların değerlerini hatanın kısmi türevlerini hesaplayarak ayarlayan TSA modelleri minimuma ulaşabilir. Bu süreçte uygulanan işlemin ismi gradyan iniştir. Ancak basit nöronlara sahip TSA modelleri kaybolan/patlayan gradyan problemini çözmekte yetersiz kalır çünkü uzun geçmişte olan bağımlılıkların kaybolmasına engel olamaz. Kaybolan/patlayan gradyan problemini çözmek için başvurulan bir yöntem daha kompleks nöronlardan oluşan TSA temelli ağlar kullanmaktır.

TSA ailesinden olan Uzun-Kısa Süreli Bellek (UKSB – Long-Short Term Memory (LSTM)) kaybolan/patlayan gradyan problemine karşı etkili bir çözüm sunmaktadır. Hochreiter ve Schmidhuber [69] tarafından 1997 yılında geliştirilen UKSB zaman serisi içerisinde ele alınan problemlerle çalışmak üzere tasarlanmıştır. Meteorolojik sıcaklık tahminleri, borsadaki hisse senedi hareketleri, biyomedikal sinyal analizi, konuşma tanıma, doğal dil işleme, otomatik çeviri gibi birçok problemin çözümünde yaygın bir şekilde kullanılmaktadır [70].

TSA modelleri uzun verilerde gördüklerini unutabilirken UKSB mimarisindeki hücreler önemli verileri hatırlayıp önemsiz olanları unuttur [71]. Bu görevi yerine getirmek için özel olarak tasarlanan UKSB hücre birimleri; hücre durumu, gizli durum, giriş kapısı, çıkış kapısı ve unut kapısı olmak üzere adlandırılan kısımlardan meydana gelir [72].

Hücre durumu, işlenen tüm önceki zaman adımlarından gelen bir tür uzun-süreli hafıza kodlamasıdır. Gizli durumsa bir önceki zaman adımında işlenen verilerin bir tür ifadesi olan kısa-süreli hafızaya karşılık gelir. Giriş, çıkış ve unutma kapıları, UKSB biriminin sıra formatında verilen girdiye karşı zamana bağlı yanıtlarını kontrol eder. UKSB birimleri arasındaki bağlantı, ağ içinde geri bildirim göndererek modelin girişteki zamansal



bağlantıları tanımasına ve gecikmeden etkilenmeden önemli olayları tanımasına olanak tanır ve bu şekilde UKSB modeli, verilerdeki uzun vadeli bağımlılıkları yakalayabilir.


$$\begin{pmatrix} g_t \\ i_t \\ f_t \\ o_t \end{pmatrix} = \begin{pmatrix} \tanh \\ \sigma \\ \sigma \\ \sigma \end{pmatrix} \cdot \begin{pmatrix} W_g & U_g \\ W_i & U_i \\ W_f & U_f \\ W_o & U_o \end{pmatrix} \cdot \begin{pmatrix} x_t \\ h_{t-1} \end{pmatrix} \quad (2.84)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot g_t \quad (2.85)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (2.86)$$

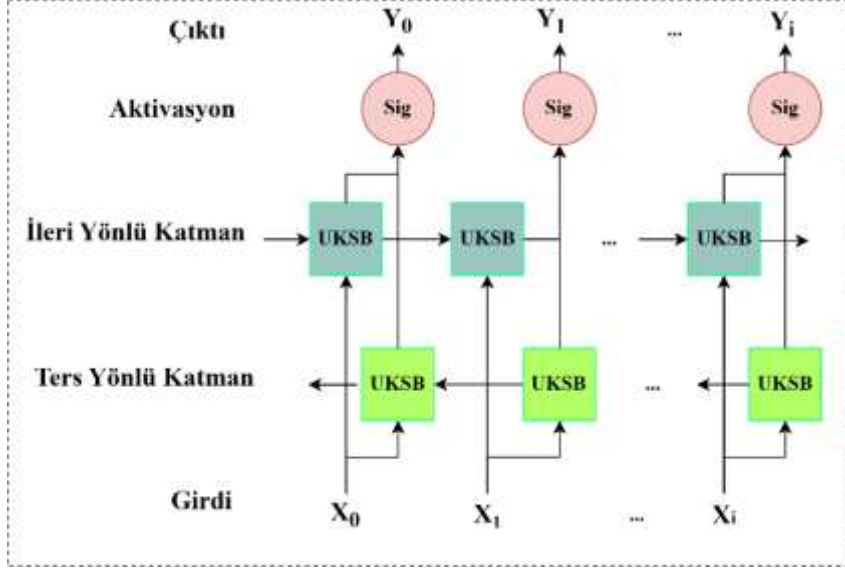
Eşitlikler 2.84'te  $g_t$  hesaplanırken  $W_g$  ve  $U_g$  ağırlıklarıyla çarpılarak toplanan girdi  $x_t$  ve hücrenin bir önceki gizli durumu  $h_{t-1}$ ,  $\tanh$  aktivasyonu ile  $[-1, 1]$  aralığına sıkıştırılmaktadır. Girdi kapısı ( $i_t$ ), unutma kapısı ( $f_t$ ) ve çıkış kapısı ( $o_t$ ) değerleriyse  $x_t$  ve  $h_{t-1}$  değerlerinin kendilerine karşılık gelen ağırlıklarla çarpıldıktan sonra toplanıp sigmoid aktivasyonu ile  $[0, 1]$  aralığına sıkıştırılmasıyla elde edilmektedir. Eşitlik 2.85'te ifade edilen  $C_t$  hücre durumu, hücrenin bir önceki durumunun unutma kapısıyla çarpılması ve giriş kapısından gelen değerle  $g_t$  değerinin çarpılıp toplanmalarıyla hesaplanır. Eşitlik 2.86'da hücrenin yeni kısa süreli hafıza değeri çıkış kapısından gelen değer  $o_t$  tanh aktivasyonuna uğrayan hücre durumuyla çarpılmasıyla hesaplanır.

Şekil 2.12'de gösterilen bir UKSB hücresi, hücre durumuyla tahmin yapmak için anlamlı olan bilgileri tüm hücreler boyunca taşır. Bu hafıza birimi eski verilerin ağ zinciri boyunca unutulmadan taşınmasında görev alır. Hücre durumunda saklanacak olan bilgi, kapılardan gelen verilerin noktasal çarpım ve toplanmasıyla hesaplanır. Hücrenin gizli durumu da çıktı olarak dönlür.



**Şekil 2.12:** Uzun-kısa süreli bellek mimarisine ait bir hücre

UKSB mimarisini bir üst seviye taşıyarak geliştirilen Çift Yönlü Uzun-Kısa Süreli Bellek (ÇYUKSB - Bidirectional Long Short Term Memory (BiLSTM)) modelinde veri hem ileri yönde hem de geri yönde işlenir. Özellikle doğal dil işleme gibi alanlarda tercih edilen ÇYUKSB modelleri girdi dizisinin her iki yönündeki kelimeler ve kelime öbekleri arasındaki sıralı bağımlılıkları yakalamada başarılı sonuçlar verir. UKSB modelleri ise ÇYUKSB modellerinin aksine zamana bağlı girdinin sadece bir yöndeki ilişkilerini yakalama yeteneğine sahiptir. Bu nedenle ileri ve geri çalışan iki UKSB’i üst üste bindiren ÇYUKSB modelleri verilerdeki gelecek ve geçmiş ilişkilerini ortaya çıkarmak için kullanılır. İleri ve geri yönlü çalışan UKSB katmanlarının çıktıları toplama, ortalama veya birleştirme gibi işlemlerle ÇYUKSB modelinin genel çıktısını oluşturur. Şekil 2.13’te ÇYUKSB mimarisi gösterilmiştir.



Şekil 2.13: Çift yönlü uzun-kısa süreli bellek mimarisi

## 2.6 Yapay arı kolonisi

Derviş Karaboğa tarafından 2005 yılında geliştirilen Yapay Arı Kolonisi (YAK) algoritması [73] doğada arıların yiyecek araması esnasında sergiledikleri davranışı taklit eden popülasyon tabanlı bir optimizasyon algoritmasıdır. YAK ile kombinatoriyal optimizasyon problemleri de dahil olmak üzere birçok problem alanında kısmi çözümler oluşturmak için uyarlanmıştır. Genetik algoritma (GA), diferansiyel evrim (DE) ve parçacık sürüsü optimizasyonuna (PSO) kıyasla fonksiyon optimizasyon problemlerinde daha iyi performans gösterir [74].

YAK optimizasyon algoritması bir arı yuvasında faaliyet gösteren işçi, gözcü ve kaşif arıları temsil eden koloni elemanlarından oluşur. Arıların üstünde çalıştığı yiyecek kaynakları de aday çözümleri temsil etmektedir. Algoritmanın bel kemiğini oluşturan işçi arılara başlangıçta rastgele yiyecek kaynakları atanır. Her adımda işçi arılar açgözlü bir yaklaşımla üzerinde çalıştıkları yiyecek kaynağının komşuluğunda daha yüksek fitness değerine ulaşmaya çalışır.

$$V_{i,j} = X_{i,j} + rand[-1, 1] * abs(X_{i,j} - X_{k,j}) \quad (2.87)$$

Eşitlik 2.87’de  $X_i$  olarak verilen yiyecek kaynağının komşusu  $X_k$  ile ifade edilmektedir. Rastgele seçilen  $j$  parametresi üstünde değişiklik yapılarak yeni  $V_{i,j}$  sonucu elde edilmektedir. Burada  $i = 1, 2, \dots, N$  yiyecek kaynakları sayısını ve  $j = 1, 2, \dots, D$  parametre sayısını ifade etmektedir. Bu işlem sırasında üretilen bir parametre değeri önceden

belirlenmiş limiti aşarsa kontrol edilerek söz konusu parametreye kabul edilebilir bir değer atanabilir. Bu işlem sırasında elde edilen  $V_{i,j}$  kaynağının fitness değeri eğer  $X_i$ 'den yüksekse hafızada saklanır. Aksi takdirde işçi arı eski çözümle çalışmasına devam eder.

Diğer taraftan kaşif arılarsa serbest olarak dolaşarak rastgele yiyecek kaynakları arar. Tüm arılar kovanda dans ederek iletişim kurarak buldukları yiyeceğin fitness değerini ve konumunu anlatır. İşçi ve kaşif arılardan en iyi yiyecek kaynaklarının bilgilerini alan gözcü arılar bu kaynaklara Eşitlik 2.88'de verilen rulet tekerleği seçimiyle yönelirler.

$$p_i = \frac{fitness_i}{\sum_j^N fitness_j} \quad (2.88)$$

Burada  $p_i$  ile ifade edilen  $i$ 'inci kaynağın seçilme olasılığı, onun fitness değerinin  $N$  adet yiyecek kaynağının fitness değerlerinin toplamına bölünmesiyle hesaplanmaktadır. [0-1] aralığında rastgele üretilen bir sayı ile her gözcü arı için bir seçim yapılır. Rulet tekerleğinde yüksek fitness değerine sahip yiyecek kaynaklarının bu yöntemle seçilmesi daha yüksek olasılığa sahiptir. Her iterasyonun sonunda ayrıca en düşük fitness değerine sahip yiyecek kaynakları terk edilir ve bunlarla çalışan işçi arılara da yeni yiyecek kaynakları verilir. İterasyonlar optimal çözümü bulana kadar veya önceden belirlenen sayıya ulaşına kadar devam eder. En optimal sonucun bulunmaması durumunda en yüksek fitness değerine sahip olan sonuç dönülür.



Şekil 2.14: Yapay arı kolonisi

### 3. YAPILAN UYGULAMA ÇALIŞMALARI

Bu tez kapsamında PCG kayıtlarının üfürüm sesi içerip içermemesine göre sınıflandırılmasına çalışılmıştır. PCG kayıtlarından kalp üfürümü tespiti, temel kalp seslerinin ve aralarında yer alan sessiz kısımların ayırt edilmesi ve kalp seslerinin gürültüden arındırılması araştırmacıların ilgi odağında yer alan ilginç bir konudur. Tezimiz kapsamında bu konularda yürüttüğümüz üç farklı uygulama bu bölümde sunulmuştur. Dördüncü bir uygulamada da farklı derin ağ mimarilerinin EKG verileri üstündeki sınıflandırma başarısı ölçülmüştür. Bu uygulamalarla ilgili olarak yapılan çalışmalar, bunların sonucunda elde edilen bulgular, performans değerleri ve karşılaşılan problemler ifade edilmiştir.

Çalışmalarımızı yürüttüğümüz bilgisayar 64 bit Windows 10 işletim sisteminde 7476MB kullanılabilir RAM belleğe ve Intel i7-8550U 1.80GHz işlemciye sahiptir. Derin öğrenme deneylerimiz de dahil olmak üzere sadece CPU işlemciden yararlanılmış olup GPU desteği kullanılmamıştır. Çalışma kapsamında MATLAB ve Java ortamlarında kodlar geliştirilmiştir. Klasik makine öğrenmesi metotları için WEKA (Waikato Environment for Knowledge Analysis) uygulama program arabiriminden yararlanılmıştır [75].

#### 3.1 Ön İşlem ve Veri Setlerini Dengeleme Aşaması

Çalışmalarımızda kullandığımız veri setlerinde örnekleme frekansı, kayıt süresi ve sınıf sayısındaki farklılıklar uyum problemleri oluşturmaktadır. Öncelikle ön işlem aşamasında, kullanılan veri setlerindeki PCG kayıtları uyumlu bir yapıya dönüştürülmüştür. CinC2016 veri setinin örnekleme frekansı 2000Hz ve CirCor2022 veri setindeki 4000Hz'dir. İkinci olarak her iki veri seti içinde değişken uzunluklarda PCG kayıtları bulunmaktadır. Ayrıca CinC2016 veri seti iki sınıftan (normal ve anormal) örneklere sahip olmasına karşın CirCor2022 üçüncü bir sınıftan (belirsiz) 156 örnek içermektedir.

Bu uyum problemlerini çözerek üstünde sınıflayıcıları çalıştırabileceğimiz standart formatta bir veri seti elde etmek için öncelikle kullanılan veri setlerindeki sinyaller maksimum mutlak değerlerine bölünerek [-1,1] aralığına normalize edildi. Ön işlem aşamasında bilinmeyen sınıfa ait örnekler CirCor2022 veri setinden çıkarılarak sınıf sayısı iki olacak şekilde ayarlandı. Veri setlerindeki sinyallerin ortak bir örnekleme frekansına sahip olmaları için 1

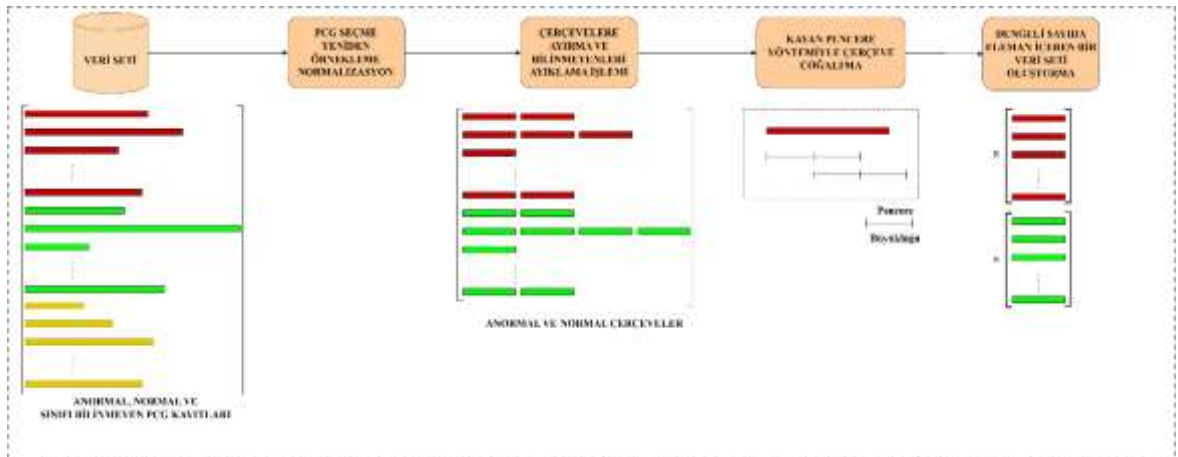
kHz'de sinyaller yeniden örneklendi. Normalize edilmiş sinyaller 1 saniye uzunluğundaki çerçevelere bölündü.

**Çizelge 3.1:** Çerçevelere ayırma aşamasının sonucunda elde edilen veri seti

Veri Seti	Çerçeve Sayısı	Anormal		Normal	
		Sayı	Oran (%)	Sayı	Oran (%)
<b>CinC2016</b>	71344	16687	23,4	54657	76,6
<b>CirCor2022</b>	66300	13070	19,7	53230	80,3

Bu işlemlerin sonucunda CinC2016 veri seti 71344 çerçeveden ve CirCor2022 veri seti de 66300 çerçeveden oluşan yeni birer veri setine dönüştürüldü. Veri setlerinin içerdiği çerçeve sayısı ve bunların normal/anormal sınıf dağılımı Çizelge 3.1’de verilmiştir. Çizelge 3.1’de görüldüğü üzere veri setlerinin normal/anormal sınıflarından örnekleri eşit olmayıp dengesiz bir yapıdadır. Eşit olmayan oranlarda farklı sınıflardan örnek içeren veri setlerimizin eğitim performansını olumsuz etkilememesi için daha az örneğe sahip sınıfın örnekleri çoğaltıldı.

Ön işlem aşamasının son basamağı olan bu adımda anormal sınıftan %50 oranında çakışma yapacak şekilde 1 saniye uzunluğunda kaydırılan bir pencere ile yeni çerçeveler üretildi ve veri setlerine eklendi. Böylelikle eşit sayıda normal ve anormal PCG çerçevelerinden oluşan dengeli veri setleri elde edildi. Sonuç olarak CinC2016 veri setinden 109314 adet 1 saniyelik çerçeve ve CirCor2022 veri setinden 106460 adet 1 saniyelik çerçeve içeren veri setleri elde edilmiştir. Ön işlem aşamasının sonunda elde edilen veri setleri tez çalışmamızda sunulan Uygulama 1 ve 2’de kullanılmıştır. Uygulama 3’te ise farklı bir ön işlem yaklaşımı sunulmuştur. Şekil 4.1’de ön işlem aşamasında izlenen adımlar gösterilmiştir.



**Şekil 3.1:** Ön işlem aşamasında izlenen adımlar

### 3.2 Uygulama 1: Klasik Makine Öğrenmesi Metotlarıyla Sınıflandırma

Bu çalışmada, klasik makine öğrenmesi yöntemlerini kullanarak PCG kayıtlarının ön işlem aşamasından geçirilerek elde edilen 1 saniye uzunluğundaki çerçevelerini sınıflandırmayı amaçladık. Tezimizde önerilen diğer yöntemler ve literatürdeki benzer çalışmaların kıyaslanmasında bir kalite ölçütü olması için C4.5 karar ağacı, DVM ve KEYK sınıflayıcılarını test ettik.

Özellik olarak PCG çerçevelerinin zaman alanından çıkarılan özellikler, spektral öznitelikleri, MFKK ve LÖK değerlerinden elde edilen katsayılar kullanıldı. Bu özelliklerle C4.5 karar ağacı, DVM ve KEYK sınıflayıcıları eğitildi ve bunların sınıflandırma performansları karşılaştırıldı. Eğitim ve test aşamasında 10 katlı çapraz doğrulama yöntemi kullanılarak performans ölçütleri hesaplandı. Performans değerlendirmesi doğruluk, hassaslık, özgüllük, negatif tahmin değeri ve F1 skoru kullanılarak yapılmıştır. Bu uygulamanın amacı makine öğrenmesinde çok sık kullanılan bu sınıflayıcıların PCG sınıflandırmasındaki başarısını göstermek ve bunu bir ölçüt olarak kullanarak önerilen metotları değerlendirmektir.

#### 3.2.1 Özellik çıkarım aşaması

Ön işlem aşamasıyla elde edilen veri setlerindeki her 1 saniyelik PCG çerçevesinden 62 adet morfolojik ve istatistiksel özellik çıkarılmıştır. Bunlardan zaman alanında çıkarılan istatistiksel özellikler momentler, RMS, Lempel-Ziv skoru, sıfır geçme oranı, maksimum/minimum farkı, ortalama Shannon enerjisi ve entropisidir. Bu özniteliklerin tanımları Çizelge 2.4'te verilmiştir. PCG çerçevelerinden 20 ms genişlikte ve 10 ms çakışma büyüklüğünde pencerelerle MFKK özellikleri oluşturulmuştur. Her pencerede 5 katsayı olmak üzere elde edilen MFKK değerlerinin ilk üç momentleri hesaplanmıştır ve özellik setine eklenmiştir. Ayrıca onuncu dereceden LÖK uygulanarak elde edilen 10 adet LÖKK değeri de özellik setine eklenmiştir. Son olarak 11 adet spektral özellik (spektral ağırlık merkezi, spektral krest, spektral entropi, spektral akı, spektral çarpıklık, spektral basıklık, spektral yuvarlanma noktası, spektral yayılma ve spektral eğim) bu özellik setine eklenmiştir. Çıkarılan özellikler [0-1] aralığına normalize edilerek sınıflandırıcıların eğitiminde kullanılmıştır. Bu uygulamada kullanılan özellikler Çizelge 3.2'de verilmiştir.

Çizelge 3.2: Uygulama 1'de kullanılan özellikler

Özellik Numarası	Özellik Boyutu	Özellik
1	1	RMS

2	1	Lempel-Ziv skoru
3	1	Sıfır geçme oranı
4	1	Maksimum-minimum farkı
5	1	Ortalama Shannon enerji
6	1	Shannon entropi
7-26	20	Momentler
27-41	15	MFKK momentleri
42-51	10	LÖKK katsayıları
52-62	11	Spektral özellikler

### 3.2.2 Sınıflandırma aşaması

Özellik çıkarımı aşamasında oluşturulan 62 öznelikten yararlanılarak KEYK, DVM ve C4.5 karar ağacı sınıflayıcıları 10 katlı çapraz doğrulama yöntemiyle eğitilmiştir. Sınıflandırma problemi iki sınıflı olup her bir çerçeve normal veya anormal olmak üzere iki sınıftan birisiyle etiketlenmiştir.

KEYK sınıflayıcısı için Öklit yöntemiyle mesafe ölçümü yapılmış ve k komşu sayısı hiper parametresi olarak 51 değeri kullanılmıştır. DVM sınıflayıcısı için WEKA uygulama arabiriminde weka.classifiers.functions.SMO ismiyle yer alan Jon Platt'ın [76] Sıralı Minimum Optimizasyon (SMO-Sequential Minimal Optimization) implemetasyonu polinomiyal kernel ile kullanılmıştır. C4.5 karar ağacı algoritmasında her bir yaprakta olması beklenen minimum örnek sayısı 2 ve dalların budanması için güven faktörü 0,25 seçilmiştir.

### 3.2.3 Performans değerlendirilmesi

Bu bölümde uygulamanın sağlamlığı ve başarısı doğruluk (D), hassaslık (H), özgülük (Ö), negatif tahmin değeri (NTD) ve F1 skoru metrikleriyle ölçülerek literatürdeki benzer çalışmalarla karşılaştırılmıştır. CinC2016 veri setinde elde edilen sonuçlar Çizelge 3.3'te verilmiştir. Çizelge 3.4'te CirCor2022 veri seti üstünde yapılan çalışmaların sonuçları verilmiştir. Çizelge 3.5'te ise literatürde araştırmacıların benzer yaklaşımlarla sunduğu çözümler ve aldıkları sonuçlar gösterilmiştir. Her iki veri seti için de en yüksek başarı C4.5 karar ağacı sınıflayıcısıyla elde edilmiştir.

**Çizelge 3.3:** CinC2016 veri seti üzerindeki performans sonuçları

Sınıflayıcı	D (%)	H (%)	Ö (%)	K (%)	NTD (%)	F1skoru (%)
KEYK	89,9	93,9	85,9	86,9	9,33	90,3
DVM	85,0	89,6	80,4	82,1	88,5	85,7
C4.5	92,3	94,5	90,0	90,5	94,3	92,5



**Çizelge 3.4:** CirCor2022 veri seti üzerindeki performans sonuçları

Sınıflayıcı	D (%)	H (%)	Ö (%)	K (%)	NTD (%)	F1skoru (%)
<b>KEYK</b>	72,9	76,3	69,5	71,5	74,6	73,8
<b>DVM</b>	67,7	63,2	72,2	69,4	66,2	66,2
<b>C4.5</b>	81,8	88,7	74,8	77,9	86,9	82,9

Çizelge 3.3 ve 3.4’de verilen doğruluk sonuçları arasındaki %10 ila %20 arasındaki fark CirCor2022 veri setinin CinC2016 veri setinden daha zor örnekler içerdiğini göstermektedir. Bu fark her üç sınıflayıcı için de CinC2016 veri setinin daha yüksek doğrulukla sonuçlar vermesinden kaynaklanmaktadır. Benzer şekilde Çizelge 3.5’te verilen diğer sonuçlar da bunu doğrulayarak iki veri seti arasındaki farkı ortaya koymaktadır.

**Çizelge 3.5:** Literatürdeki farklı çalışmalarda sunulan performans değerleri

Referans	Veri seti	Yöntem	D (%)	H (%)	Ö (%)
[37]	CinC2016	DVM	82,6	83,2	82,9
[38]	CinC2016	DVM	-	84,8	77,6
[39]	CinC2016	DVM	82,0	76,0	88,0
[40]	CinC2016	YSA	-	84,8	83,3
[41]	CinC2016	Ensemble YSA	-	86,9	84,9
[43]	CinC2016	Karar ağacı	79,0	77,0	80,0
[77]	CinC2016	DVM	94,0	-	-
[44]	CinC2016	KEYK	95,8	-	-
		YSA	94,2		
		RO	93,5		
		DVM	86,2		
[44]	CirCor2022	KEYK	76,3	-	-
		YSA	65,2		
		RO	68,8		
		DVM	58,8		
[45]	CirCor2022	Karar ağacı	79,9	92,7	77,6
[49]	CirCor2022	XGBoost	82,0	-	-
[78]	CirCor2022	DVM	69,6	-	-

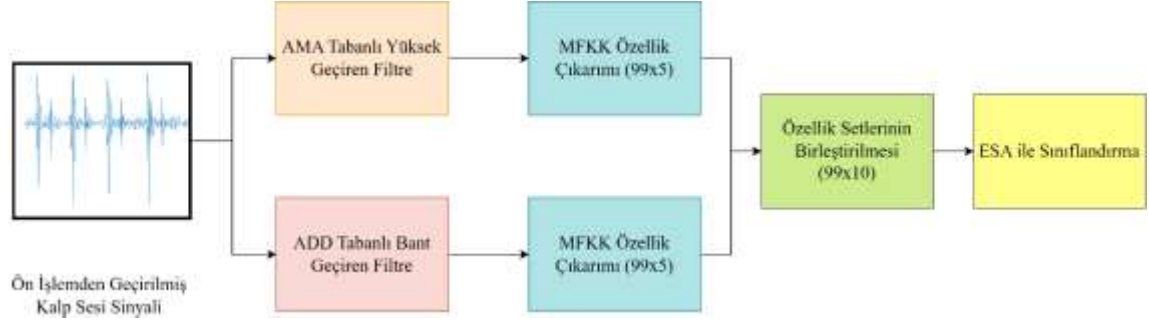
### 3.3 Uygulama 2: Derin Ağın Filtrelenmiş MFKK Değerleriyle Eğitimi

Kalp seslerinin farklı frekanslardaki bileşenlerinin özellikleri incelenerek kalp üfürümleriyle alakalı pek çok rahatsızlık fark edilebilir. Temel kalp sesleri 10-250Hz aralığında bileşenlerden oluşmaktadır. En yoğun enerjiye sahip oldukları aralık ise 100-200Hz bandındadır. Diğer taraftan kalp üfürümleri frekansları 600Hz'e kadar varan bileşenlere sahip olabilmektedir.

Bu uygulamanın hedefi, ön işlem aşamasından geçirilerek elde edilen 1 saniye uzunluğundaki PCG çerçevelerine ADD ve AMA tabanlı filtreler uygulayarak bunları tasarladığımız ESA mimarisine sınıflandırmaktır. ADD tabanlı filtre ile temel kalp seslerine ve AMA tabanlı filtre ile de üfürümlere ayrı ayrı odaklanılmıştır. Bu amaçla PCG çerçevelerinden yüksek frekanslı bileşenler AMA ile ve orta frekans aralığındaki (yaklaşık olarak 50-250Hz) bileşenler ADD ile filtrelenerek elde edilmiştir. Bu iki sinyalden MFKK özellikleri çıkarılıp tek bir özellik seti oluşturacak şekilde birleştirilerek ESA modelimizin eğitiminde kullanılmıştır.

Önerilen yöntem ön işlem, filtreleme, özellik çıkarımı ve ESA ile sınıflandırma adımlarından oluşmaktadır. Bu uygulamada PCG analizinde derin öğrenmenin başarısı ve performansı

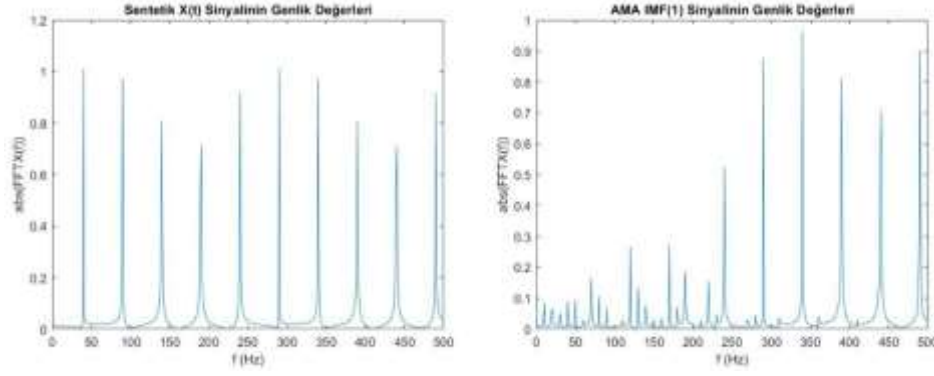
incelenmiştir. Çalışmamızda kullanılan PCG çerçeveleri, %80-%20 ve %90-%10 oranlarında eğitim/test kümelerine rastgele ayrılarak ESA modelinin eğitiminde kullanılmıştır. Önerilen yöntemin performansı doğruluk ölçütüyle değerlendirilmiştir. Şekil 4.2’de önerilen uygulamanın adımları gösterilmiştir.



**Şekil 3.2:** PCG çerçevelerinden çıkarılan özel frekans bantlarındaki sinyallerin MFKK değerlerinin ESA modeli sınıflandırılması

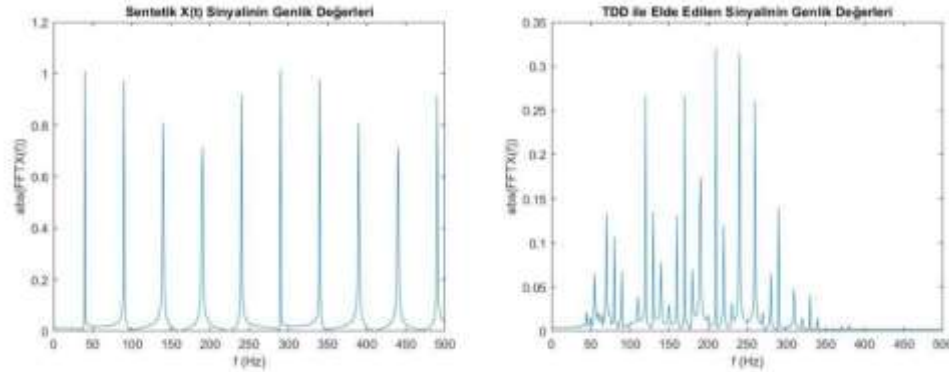
### 3.3.1 Filtreleme aşaması ve özellik setinin oluşturulması

AMA, zaman-frekans alanında yapılan çalışmalar için popüler bir seçim olmuştur. Diğer zaman-frekans algoritmalarından farklı olarak, AMA zaman alanında ve doğrudan sinyal üzerinde çalışır. Girdi olarak aldığı sinyali farklı düzeylerdeki frekans modlarına ayırır. AMA yöntemi, durağan olmayan ve doğrusal olmayan sinyallerin gizli yarı-periyodik özelliklerini çözmek için ayrıştırılmasını amaçlar. Yerel ve uyarlanabilir veri odaklı bir yöntemdir, bu da onu doğrusal olmayan ve durağan olmayan veri analizi için çok daha uygun bir teknik haline getirir [79]. Önerilen yöntemde kalp seslerinin yüksek frekanslı bileşenlerini elde etmek için AMA kullanmamızın amacı bu yöntemin daha önce birçok çalışmada başarılı sonuçlar vermiş olmasıdır. AMA gürültü gidermede [63], kalp seslerinin saptanması [80] ve bölümlenmesi [34] gibi birçok amaçla araştırmacılar tarafından tercih edilmiştir.



**Şekil 3.3:** Sentetik X(t) sinyalinin FD ile hesaplanan frekans genlik değerleri (solda). X(t) üstünde önerilen AMA tabanlı filtrenin uygulanmasından sonra elde edilen sinyalin FD ile hesaplanan frekans genlikleri (sağda).

Benzer şekilde ADD yöntemi de bilgisayarla örüntü tanıma, sinyal/görüntü filtreleme ve sıkıştırma yaygın uygulama alanları bulmuştur. PCG gibi biyomedikal sinyaller, durağan olmayan bir yapıda olmalarından dolayı zaman/frekans çözümlemesi gereken durumlarda dalgacık dönüşümü tercih edilmektedir. ADD ile sinyal yaklaşım ve detay katsayılarına ayrıştırıldıktan sonra bunlar eşikleme yöntemiyle filtrenip arkasından ters dalgacık dönüşümüyle yeniden oluşturulmaktadır. Bu amaçla değişik dalgacık aileleri, çeşitli dekompozisyon seviyeleri, farklı eşikleme değerleri ve eşikleme yöntemleri kullanılmıştır [81].



**Şekil 3.4:** Sentetik X(t) sinyalinin FD ile hesaplanan frekans genlik değerleri (solda). X(t) üstünde önerilen filtrenin uygulanmasından sonra TDD ile elde edilen sinyalin FD ile hesaplanan frekans genlikleri (sağda).

Kalp üfürümleri 200Hz üzerinde bileşenlerden oluşurken temel kalp seslerinin frekans seviyesi 250Hz'i aşmaz. Önerilen filtreleme metodunda verilerin bu karakteristik özelliklerinden yararlanılarak üfürümlerin beklendiği bandı ayrı ve temel kalp seslerinin beklendiği bandı ayrı olarak ele aldık. Bu amaçla AMA yöntemiyle sinyallerden yüksek

frekanslı bileşenleri filtreleyip ayırmak için birinci IMF fonksiyonunu saklarken daha düşük frekansa sahip diğer bileşenleri ayıkladık. İkinci aşamadaysa temel kalp seslerinin frekans sınırları olan 50-250Hz aralığındaki bileşenleri saptamak için ADD tabanlı bir filtreleme yaklaşımı kullanılmıştır. Kalp sesi sinyalleri üçüncü seviyeden daubechies-6 ana dalgacıyla ADD işlemine sokulduktan sonra birinci detay seviyesi ve yaklaşım katsayıları filtrelenmiştir. İkinci ve üçüncü seviye detay katsayılarından TDD ile filtrelenmiş sinyal yeniden oluşturulmuştur. TDD işleminin sonucunda elde edilen sinyaller yüksek ve alçak frekanslı bileşenlerden arındırılmış olup bunlardan orta frekans bandında yer alan temel kalp sesleri S1 ve S2'nin bileşenleri açıkça gözlemlenebilmektedir.

Birbirinden bağımsız olarak uygulanan iki filtreleme aşamasından sonra PCG çerçevelerinden MFKK özellikleri çıkarılmıştır. MFKK için pencere genişliği 20 ms ve adım boyutu 10 ms parametrelerinin kullanıldığı fonksiyonla 99x5'lik özellik setleri elde edilmiştir. Yüksek frekanslı ve orta frekanslı verilerden çıkarılan 99x5'lik iki farklı MFKK seti birleştirilerek 99x10 boyutlu tek bir özellik matrisine dönüştürülmüştür.

### 3.3.2 Derin ağ mimarisi

Derin öğrenme mimarisine dayanan modelleri eğitmek için çok sayıda ve mümkün olduğunca çeşitli örnek içeren veri setleri kullanmak gerekmektedir. Aksi takdirde ya model yeterince iyi eğitilemez ya da aşırı öğrenme olur. Veri setinin büyük olması modelin sınıflandırma başarısını artırırken hesaplama ve eğitim süresi, depolama ve hafıza gereksinimlerini de artırmaktadır. ESA modelimizi eğitmek için kullandığımız 1 saniyelik çerçevelerden oluşan veri setlerinin büyüklükleri CinC2016 veri seti için 109314 ve CirCor2022 veri seti için 106460 örnekten oluşmaktadır. Her iki veri seti de dengeli olup eşit sayıda normal ve anormal örnek içermektedir.

Uygulamamızda kullanılan derin ağ mimarisi ikili sınıflandırma yapmak üzere tasarlanmıştır. İlk katman olan girdi katmanı 99x10 boyutunda iki kanallı MFKK değerlerini kabul etmektedir. İkinci katman 5x5 boyutunda 5 filtreden oluşan evrişim katmanıdır. Ağırlık ve eşik değerlerini ayarlamak için bu katmandan sonra Düzeltilmiş Doğrusal Birim (DDB – Rectified Linear Units (RELU)) aktivasyonu uygulanmıştır. Modelin içindeki her evrişim katmanından sonra burada olduğu gibi bir DDB aktivasyonu kullanılmıştır. Üçüncü katman hesaplama miktarını azaltmak için kullanılan maksimum havuzlama katmanıdır. Adım boyutu 2x2 olup havuz büyüklüğü olarak da gene 2x2'dir. Evrişim-DDB-havuzlama katmanları üçlüsü model içerisinde farklı filtre büyüklüğü ve filtre sayısı parametreleri ile

üç kez kullanılmıştır. Bu katmanları sırasıyla 64 ve 32 gizli ünite içeren Çift Yönlü Uzun-Kısa Süreli Bellek (ÇYUKSB - Bidirectional Long-Short Term Memory (BiLSTM)) katmanları izlemektedir. Sınıflandırmadan önceki son aşamada da tam bağlı iki katman kullanılmıştır. Bu katmanlar sırasıyla 10 ve 2 nöron içermektedir. Model, hesaplama açısından verimli bir seçenek olan Adam optimizasyon algoritması ile eğitilmiştir. Mini parti boyutu olarak varsayılan değer olan 128 kullanılmıştır. Eğitim 20 turda gerçekleştirilmiştir. Öğrenme oranı olarak varsayılan değer olan 0,001 kullanılmıştır. Modelin eğitiminin çok uzun sürmemesi için bu değer daha fazla küçültülmemiştir. Böylelikle modelin minimum noktasına ulaşmak için parametrelerde daha az güncelleme yapması amaçlanmıştır. Derin ağ modelimizin katmanlarının detayları Çizelge 3.6'da verilmiştir.

**Çizelge 3.6:** Önerilen uygulamada kullanılan derin ağ mimarisi

Katman	Girdi/Çıktı Büyüküğü	Filtre Büyüküğü	Filtre Sayısı	Havuz Büyüküğü	Adım	Gizli Ünite
<b>Girdi</b>	(99, 10)	-	-	-	-	-
<b>Evrişim</b>	-	(5, 5)	5	-	-	-
<b>DDB</b>	-	-	-	-	-	-
<b>Maksimum Havuzlama</b>	-	-	-	(2, 2)	(2, 2)	-
<b>Evrişim</b>	-	(3, 3)	10	-	-	-
<b>DDB</b>	-	-	-	-	-	-
<b>Maksimum Havuzlama</b>	-	-	-	(2, 2)	(2, 2)	-
<b>Evrişim</b>	-	(2, 2)	20	-	-	-
<b>DDB</b>	-	-	-	-	-	-
<b>Maksimum Havuzlama</b>	-	-	-	(2, 2)	(2, 2)	-
<b>Düzleştirme</b>	-	-	-	-	-	-
<b>ÇYUKSB</b>	-	-	-	-	-	64
<b>ÇYUKSB</b>	-	-	-	-	-	32
<b>Tam Bağlı</b>	10	-	-	-	-	-
<b>Tam Bağlı</b>	2	-	-	-	-	-

### 3.3.3 Performans değerlendirmesi

Bu bölümde önerilen yöntemin başarısı ve sağlamlığı, literatürdeki ESA tabanlı diğer güncel yöntemlerle karşılaştırılmıştır. Bu yöntemlerde sunulan ESA modelleri doğrudan bir boyutlu PCG sinyali veya ondan çıkarılan MFKK benzeri iki boyutlu özellik matrisleriyle eğitilmişlerdir. Yöntemler arasında karşılaştırma ölçütü olarak *Doğruluk* metriği baz alınmıştır.

Önerilen yöntem, veri setlerinin %80'e %20 ve %90'a %10 eğitim/test kümesi olacak şekilde rastgele ayrılmasıyla her bir veri seti için birer kez çalıştırılmıştır. Bu ayrıştırmalarda büyük olan kısım eğitim için kullanılırken küçük kısım test için ayrılmıştır.

Çizelge 3.7'de kullanılan modelin eğitim aşamasında inşa edilirken gördüğü örnekler üzerindeki doğruluğu olan eğitim doğruluğu ve daha önce görmediği örnekler hakkındaki tahmin doğruluğu olan test doğruluğu verilmiştir.

**Çizelge 3.7:** Kullanılan modelin performansı ve doğruluk sonuçları

Eğitim-Test Oranı	CinC2016		CirCor2022	
	%80-%20	%90-%10	%80-%20	%90-%10
<b>Eğitim Doğruluğu</b>	90,4	91,5	82,3	84,2
<b>Test Doğruluğu</b>	89,0	89,1	77,2	78,5
<b>Çalışma Süresi (s)</b>	885	989	926	1012

Çizelge 3.8'de önerilen yöntemin CinC2016 ve CirCor2022 veri setini kullanan diğer çalışmalarla karşılaştırılması yapılmıştır.

**Çizelge 3.8:** CinC2016 ve CirCor2022 veri setlerini kullanarak yapılan farklı araştırmalarda sunulan benzer çalışmalar

Referans	Yıl	Veri seti	Yöntem	Doğruluk
[36]	2016	CinC2016	2B ESA	84,0
[82]	2019	CinC2016	Ensemble ESA	89,2
[58]	2020	CinC2016	1B ESA	85,7
[77]	2021	CinC2016	AlexNet ESA	97,9
[83]	2021	CinC2016	2B ESA	96,7
[84]	2023	CinC2016	1B ESA	96,3
[46]	2022	CirCor2022	ÇYUKSB	75,1
[47]	2022	CirCor2022	ESA	76,4
[85]	2022	CirCor2022	ESA	71,5
[49]	2022	CirCor2022	DBRes	76,2
[84]	2023	CirCor2022	1B ESA	87,1

### 3.4 Uygulama 3: ESA ile Spektrogram Sınıflandırma

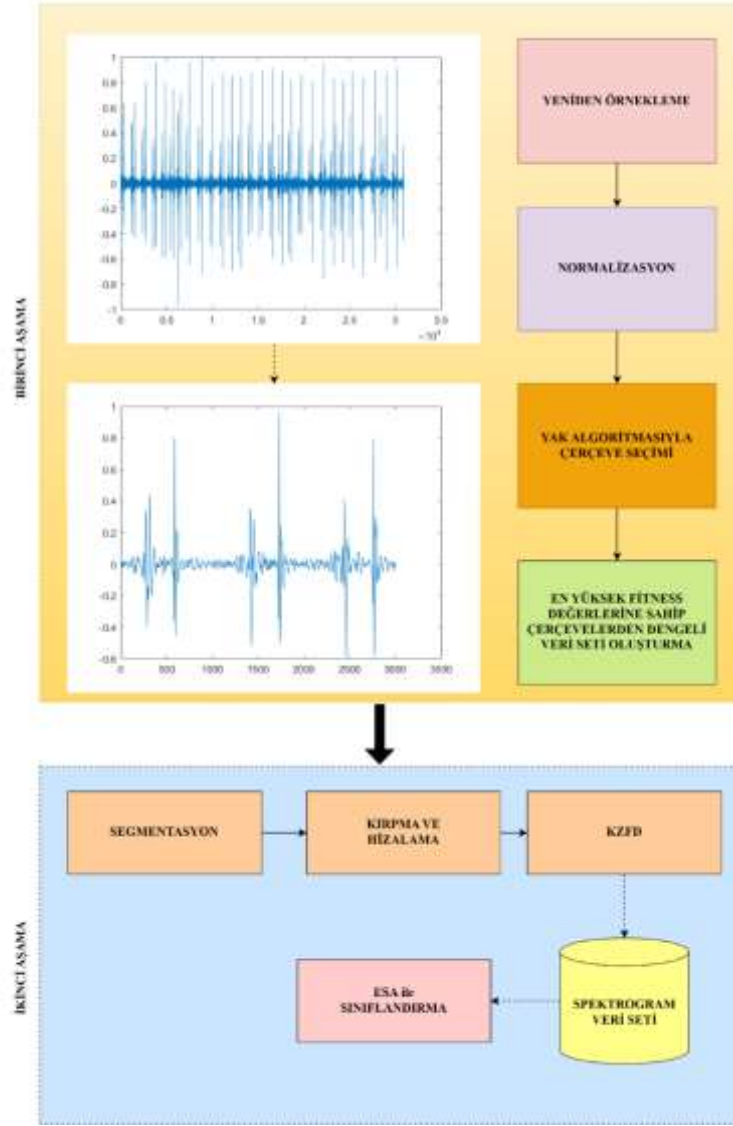
PCG veri tabanları birbirinden farklı uzunluklarda kayıtlar içermektedir. Ön işlem aşamasında başvurulan yöntemlerden birisi PCG kayıtlarını eşit uzunlukta olacak şekilde kırmaktır [13], [42], [43], [86]. Böylece standart bir uzunluğa getirilen sinyaller derin ağ

modelleriyle sınıflandırma sürecine geçebilmektedir. PCG kayıtlarında izlenen kalp sesleri periyodik bir yapıya sahiptir. Kalp sesleriyle birlikte üfürümler de benzer şekilde ayırt edilebilecek bir karakteristik sergiler. Değişik tip, çeşit ve şiddette görülebilen kalp üfürümleri, bir saniye kadar süren kardiyak döngü boyunca aynı konumlarda başlayıp biterler. Dolayısıyla kalp üfürümünün tespiti ve sınıflandırılması için birkaç dakika uzunluğunda olabilen tüm PCG kaydını incelemek seçilen kısa bir aralık kullanılarak da sınıflandırma yapılabilir. Bu yaklaşım hesaplama süresinde, bellek gereksiniminde ve hesaplama maliyetinde daha az kaynakla çalışmaya olanak sağlamaktadır.

PCG kaydının tamamını kullanmak yerine daha küçük boyutta verilerle çalışmanın bir avantajı da oskültasyon sırasında ani bir şekilde kayda giren çeşitli gürültülerden (bebek/çocuk ağlama sesleri, hastanın konuşması, çeşitli cihaz sesleri, hırıltı, öksürük, bağırsak hareketlerinden kaynaklanan sesler vb.) sakınmaktır. Her ne kadar ön işlem aşamasında kullanılan çeşitli filtrelerle gürültüler giderilmeye çalışılsa da kaydın tamamından öznelik çıkarırken bahsedilen gürültüler sınıflandırma başarısını düşürmektedir. Gürültü içeren PCG kayıtlarının sınıflandırıcıların genel başarısını olumsuz etkilememesi amacıyla ön sınıflayıcılar kullanılarak [41], [87] veri setindeki düşük kaliteli kayıtlar elenme yoluna başvurulmaktadır. Özellikle kontrolsüz ortamlardaki oskültasyon kayıtlarında ortamdan kaynaklanan çeşitli gürültülerle PCG kayıtları olumsuz etkilenir. Örneğin CinC2016 veri seti birçok gürültülü örnek içermektedir. Benzer şekilde CirCor2022 veri seti de mobil ortamlarda toplanmasından ötürü bölümlene kalitesini etkileyecek ölçüde ortam gürültüsü içermektedir [26].

Önerilen yöntemle sinyalin entropi ve enerji değerlerinden yararlanarak yapay arı kolonisi algoritmasıyla sistolik, diyastolik veya sürekli üfürümlerin kardiyak döngüde en açık şekilde görülebileceği kısa çerçevelerin kırılması gerçekleştirilmiştir. Bölümlenme yapılar başlangıç hizaları S1 olacak şekilde ayarlanan alt çerçevelerden KZFD ile çıkarılan spektrogramlar önerilen bir derin ağ mimarisiyle sınıflandırılmıştır.





Şekil 3.5: Önerilen uygulamanın adımları

### 3.4.1 YAK tabanlı çerçeve seçimi

Önerilen yöntemin ön işlem aşamasında PCG kayıtları 1000Hz'e göre yeniden örneklenmiş ve normalize edilmiştir. Bu yöntemle PCG kayıtları içerisinde ani olarak meydana gelen ve sürekli olmayan gürültülerden etkilenmeyen en temiz çerçevelerin seçilmesi amaçlanmıştır. Çerçeve boyutu olarak üç saniye seçilmiştir. Çerçevelerin fitness değerlerini hesaplamak için entropi ve enerji değerlerinden yararlanılmıştır. Eşitlik 3.1'de ifade edilen şekilde bir PCG çerçevesinin fitness değeri onun entropisinin enerjisine bölümüyle hesaplanmıştır.

$$Fitness_j = \frac{Entropi_j}{Enerji_j} \quad (3.1)$$

PCG kayıtlarının içerisindeki yüksek entropi ve düşük enerji değerlerine sahip olan çerçeveler önerilen yöntemle bulunmaya çalışılmıştır. YAK algoritmasında kullanılan parametrelerin değerleri Çizelge 3.9’da verilmiştir. Yiyecek kaynakları olarak PCG kaydının üstündeki üç saniyelik parçalar kullanılmıştır. Bu yiyecek kaynakları üstünde çalışacak olan ilk popülasyon rastgele konumlarla başlatılmıştır.

Her iterasyonda popülasyonda yer alan arılar kendi tiplerine göre optimal sonuca ulaşmak için hareket etmişlerdir. Bu amaçla işçi arılar kendi kaynakları üstünde Çizelge 3.9’da verilen alt ve üst limit arasındaki rastgele değerler kadar ilerleme yaparak yeni gıda kaynaklarına ulaşmaya çalışmıştır. Kaşif arılarsa rastgele konumlardaki yiyecek kaynaklarını incelemiştir. Son olarak gözcü arılar Eşitlik 2.88’de verilen rulet tekerleği yöntemiyle popülasyonun ulaşabildiği en optimal sonuçlar arasında seçim yapmıştır. Popülasyondaki arılar eğer yeni iterasyon sırasında ulaştıkları yiyecek kaynağı eski yiyecek kaynaklarından daha değerliyse bunu güncellemiş ve çalışmaya yeni buldukları yiyecek kaynağıyla devam etmiştir. İterasyonlar maksimum döngü sayısına ulaşınca kadar devam etmiştir. Maksimum döngü sayısına ulaşıncaya kadar tüm popülasyonun ulaştıkları yiyecek kaynakları arasından en yüksek fitness değerlerine sahip olan çerçeveler seçilerek bunlarla normal/anormal PCG çerçeve sayısı dengeli bir veri seti oluşturulmuştur.

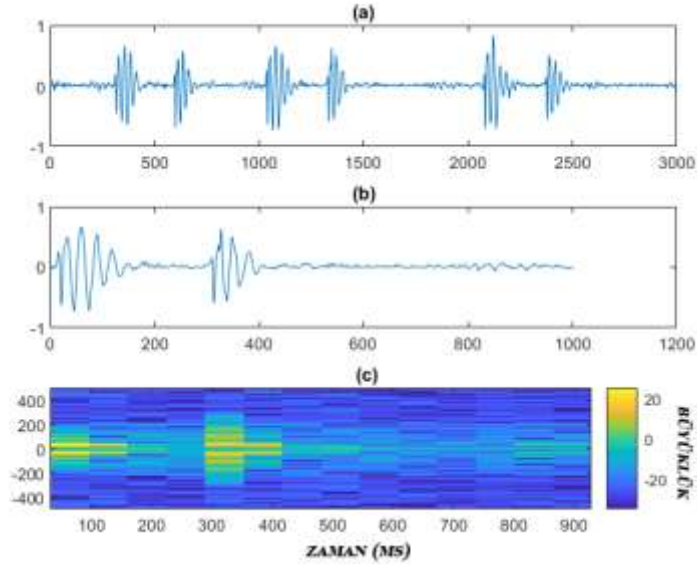
**Çizelge 3.9:** YAK algoritması parametreleri

Parametre	Değer
İşçi arı sayısı	30
Gözcü arı sayısı	4
Kaşif arı sayısı	16
Alt limit	-100
Üst limit	100
Maksimum döngü sayısı	50

### 3.4.2 KZFD ile spektrogram oluşturulması

Bu aşamada YAK tabanlı çerçeve seçimi aşamasında elde edilen kalp sesi sinyallerinin KZFD ile elde edilen iki boyutlu spektrogramları hazırlanmıştır. Ancak PCG çerçevelerinin başlangıç noktaları farklı bölümlere karşılık gelmektedir. Elde edilen spektrogram verilerinin başlangıç ve bitiş kısımlarında tutarlılığı sağlamak için çerçeveler [7]’de sunulan açık kaynak kodlu bölümleme yöntemiyle S1, sistol, S2 ve diyastol konumlarına ayrılmıştır. Elde edilen bölümlerin zamansal konum bilgilerinden yararlanarak YAK çerçevelerinden hepsi S1 bölümü ile başlayan bir saniye uzunluğunda alt çerçeveler çıkarılmıştır. Arkasından

KZFD ile bunlardan spektrogram çıkarılmıştır. KZFD işleminde pencere büyüklüğü 128 ve çakışma boyutu 64 olarak seçilmiştir. Pencereleme *Hamming* fonksiyonu uygulanarak yumuşatılmış ve 128x14 boyutunda spektrogramlar elde edilmiştir.



**Şekil 3.6:** 3 saniyelik PCG çerçevesi (a), bölümlenme sonrası kırılan 1 saniyelik çerçeve (b) ve KZFD spektrogram (c)

### 3.4.3 Derin ağ mimarisi

PCG çerçeve seçimi ve sinyal kırpma işlemlerinin arkasından CinC2016 veri setinden 5235 ve CirCor2022 veri setinden 4774 adet boyutları 128x14 olan spektrogram elde edilmiştir. Zamansal olarak yorumlandığında anlamlı sonuçlar veren bu verinin sınıflandırılmasında kullanılan ESA modelinde konvolüsyon ve ÇYUKB katmanları birlikte kullanılmıştır. Girdi katmanı sıralı girdi (sequence input) türünde olan girdiyi kabul etmektedir. Girdiyi kabul eden ilk katmanının arkasından evrişim, DDB ve maksimum havuzlama katmanlarından oluşan bloklar yer almaktadır. Bu şekilde beş evrişim katmanında işlenerek oluşturulan özellik haritaları düzleştirilmektedir. Daha derin bir ağ tercih edilerek hesaplama yükünü arttırmaktansa kullanılan evrişim katmanlarının filtre sayıları daha yüksek tutulmuştur. Konvolüsyon ve havuzlama katman bloklarının en son çıktısı olan özellik haritası düzleştirme katmanında tek boyutlu bir vektöre dönüştürülmektedir. Bu vektör 32 üniteden oluşan bir ÇYUKSB katmanı ile işlendikten sonra sırasıyla 100, 10 ve 2 nörona sahip üç tam bağlı katmana verilmektedir. Uygulamada kullanılan ESA mimarisi ikili sınıflandırma problemini çözmek üzere tasarlanmıştır. Dolayısıyla son sıradaki tam bağlı katman iki nörona sahiptir. Modelin eğitim setini aşırı öğrenmesinin önüne geçebilmek için ilk tam

bağlı katmandan sonra 0,5 oranında rastgelelikle seyreltme yapan seyreltme katmanına yer verilmiştir. Derin ağ mimarisinde yer alan katmanların detayları Çizelge 3.10’da verilmiştir.

Öğrenme parametrelerinin optimizasyonu için Adam optimizasyon algoritması kullanılmıştır. Mini parti boyutu olarak 40 seçilmiş ve modelin aynı anda 40 veriyi işlemesi sağlanmıştır. Gradyan düşüş faktörü ( $\beta_1$ ) olarak 0,9 ve karesi alınan gradyan düşüş faktörü ( $\beta_2$ ) olarak 0,99 değerleriyle çalışılmıştır. 20 tur sayısı ile ESA eğitimleri gerçekleştirilmiştir ve öğrenme oranı olarak 0,0003 kullanılmıştır. Küçük bir öğrenme oranı, daha yavaş model eğitimi anlamına gelir. Modelin minimum noktasına ulaşmak için parametrelerde birçok güncelleme yapmasını gerektirir. Öte yandan, büyük bir öğrenme oranı, büyük adımlarla parametrelerde ciddi güncellemeler meydana getirir ve bu nedenle yakınsama yerine sapmaya neden olabilir. Bu uygulamada önerilen ESA modeli, 3.3.2’de önerilenden daha küçük öğrenme oranı kullanılarak çalıştırılmıştır. Bu değerlerin kullanılmasıyla optimize edici, yerel minimuma ulaşmak için parametreleri daha başarılı güncellemiştir.

**Çizelge 3.10:** Önerilen uygulamada kullanılan ESA mimarisi

Katman	Girdi/Çıktı Büyüküğü	Filtre Büyüküğü	Filtre Sayısı	Havuz Büyüküğü	Adım	Gizli Ünite
Girdi	(128, 14)	-	-	-	-	-
Evrişim	-	(5, 3)	10	-	-	-
Maksimum Havuzlama	-	-	-	(2, 1)	(2, 1)	-
Evrişim	-	(2, 2)	20	-	-	-
DDB	-	-	-	-	-	-
Maksimum Havuzlama	-	-	-	(4, 1)	(2, 1)	-
Evrişim	-	(2, 2)	40	-	-	-
DDB	-	-	-	-	-	-
Maksimum Havuzlama	-	-	-	(4, 1)	(2, 1)	-
Evrişim	-	(2, 2)	20	-	-	-
DDB	-	-	-	-	-	-
Maksimum Havuzlama	-	-	-	(4, 1)	(2, 1)	-
Evrişim	-	(2, 2)	10	-	-	-
Maksimum Havuzlama	-	-	-	(2, 1)	(2, 1)	-
Düzleştirme	-	-	-	-	-	-
ÇYUKSB	-	-	-	-	-	32
Tam Bağlı	100	-	-	-	-	-
Seyreltme	0,5	-	-	-	-	-
Tam Bağlı	10	-	-	-	-	-
Tam Bağlı	2	-	-	-	-	-

### 3.4.4 Performans değerlendirmesi

Bu bölümde önerilen yöntemin başarısı ve sağlamlığı, *Doğruluk* metriği ve çalışma süresi baz alınarak sunulmuştur. Önerilen yöntem, veri setlerinin %80’e %20 ve %90’a %10 eğitim/test kümesi olacak şekilde rastgele ayrılmasıyla her bir veri seti için ayrı ayrı çalıştırılmıştır. CinC2016 ve CirCor2022 veri setleri üzerinde çalışan ESA modelinin eğitim

aşamasında inşa edilirken gördüğü örnekler üzerindeki doğruluğu olan eğitim doğruluğu ve daha önce görmediği örnekler hakkındaki tahmin doğruluğu olan test doğruluğu sunulmuştur. Elde edilen en iyi sonuçlar Çizelge 3.11’de verilmiştir.

**Çizelge 3.11:** ESA modelimizin performansı ve doğruluk sonuçları

Eğitim-Test Oranı	CinC2016		CirCor2022	
	%80-%20	%90-%10	%80-%20	%90-%10
Eğitim Doğruluğu	97,2	98,9	87,0	88,7
Test Doğruluğu	93,0	94,5	80,5	82,0
Çalışma Süresi (s)	195	195	179	154

Önerilen yöntemi kıyaslamak için araştırmacılar tarafından öncelikle KZFD veya DD kullanarak elde edilen zaman-frekans verisini farklı metotlarla sınıflandıran çalışmalar incelenmiştir. Bu çalışmalarla önerilen yöntem arasında karşılaştırma ölçütü olarak *Doğruluk* metriği kullanılmıştır. Karşılaştırma tablosu Çizelge 3.12’de verilmiştir.


**Çizelge 3.12:** CinC2016 ve CirCor2022 veri setlerini kullanarak yapılan farklı araştırmalar ve bunlarda elde edilen sonuçlar

Referans	Yıl	Veri seti	Yöntem	Skor
[37]	2016	CinC2016	ESA	81,3
[86]	2020	CinC2016	ESA	86,0
[88]	2020	CinC2016	ESA	88,0
[89]	2021	CinC2016	ESA	95,4
[90]	2022	CinC2016	ResNet-50	79,3
			VGG-16	79,7
			ESA	85,2
[91]	2023	CinC2016	YAMNet	92,2
[92]	2022	CirCor2022	ESA	59,9
[13]	2022	CirCor2022	ESA	81,0

### 3.5 Uygulama 4: Derin Öğrenmeyle Aritmi Analizi

Aritmi, hastanın kalp atışında gözlemlenen ritim düzensizliğidir. Bir çeşit aritmi olan atriyal fibrilasyon, EKG kayıtlarına bakılarak tespit edilmektedir. Kardiyak döngü boyunca kalbin her atımında meydana gelen düzenli kasılıp gevşemeler EKG kompleksinde tanımlı aralıklara denk gelmektedir. EKG kompleksi içerisinde yer alan P dalgası, QRS bileşimi ve T dalgası AF hakkında bilgi vermektedir. Birbirini takip eden R tepeleri arasındaki

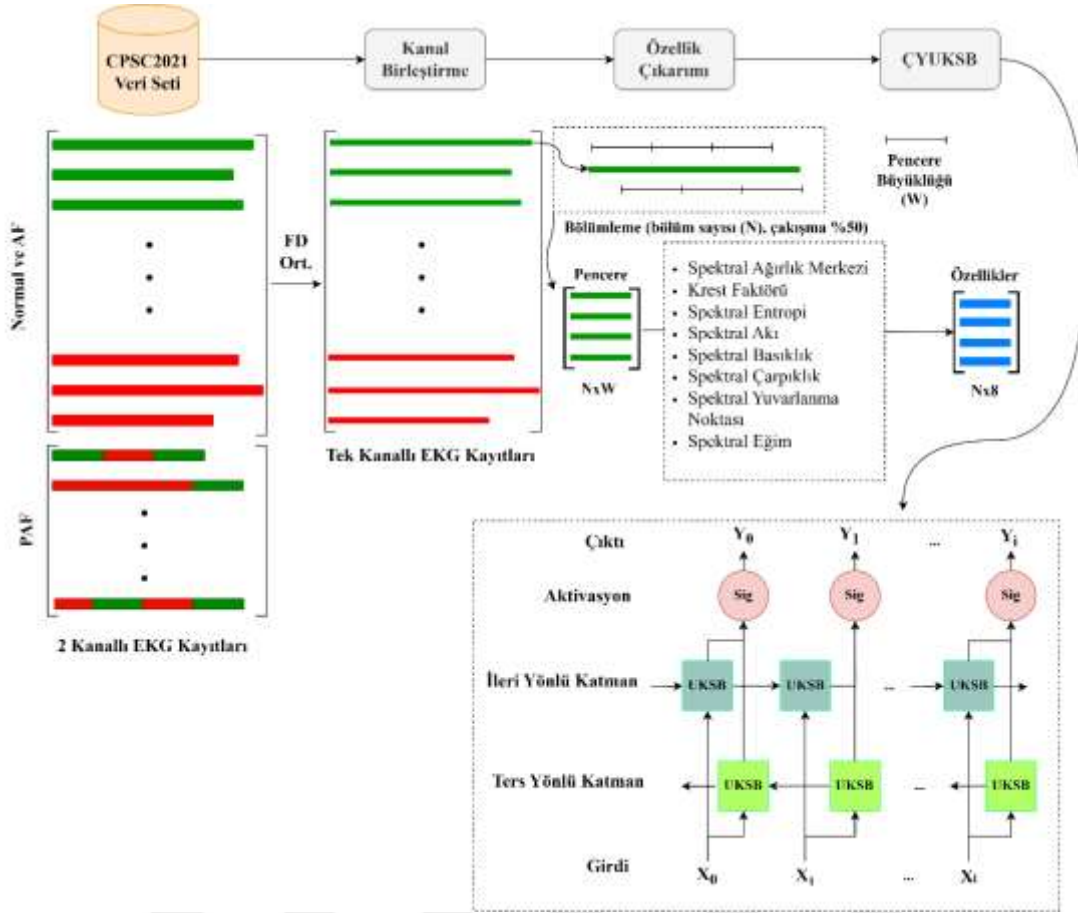
düzensizlik ve P dalgasının beklendiği konumda gözlemlenen titreşimsel bozukluklar önemli AF göstergeleridir.



**Şekil 3.7:** Tek bir kardiyak döngü boyunca gözlemlenen EKG sinyali

Normal seyreden EKG sinyali içerisinde 30 saniyeden uzun süreli fibrilasyonlar PAF göstergesidir. PAF olarak tanımlanan EKG sinyallerinde hem normal hem de aritmi gözlemlenmektedir. EKG kayıtları üzerinden PAF teşhisi yapmak için 7 güne kadar süren takipler yapılmaktadır. Bu uygulamanın geliştirilmesinin amacı durağan olmayan ve seri olarak ele alınması anlamlı sonuçlar veren EKG sinyalini sınıflandırmada ÇYUKSB tabanlı derin öğrenme modellerinin etkisini incelemektir.

Önerilen uygulama; ön işlem, 2 derivasyonlu EKG kayıtlarının tek kanala dönüştürülmesi, özellik çıkarımı ve sınıflandırma aşamalarından oluşmaktadır. CPSC2021 veri tabanına ait veri setleri olan Set 1 ve Set 2 bu çalışmada kullanılmıştır. Ayrıca bu setin birleşiminden üçüncü bir set daha oluşturularak (Set 1-2) kullanılmıştır. Yöntemin başarısı *Doğruluk* ölçüt parametresi kullanılarak değerlendirilmiştir.



Şekil 3.8: Önerilen yöntemin eğitim aşaması

### 3.5.1 Ön işlem aşaması

CPSC2021 veri seti normal, AF ve PAF sınıflarından kayıtlara sahiptir. PAF kayıtları içerisinde normal ve fibrilasyon içeren kesitlere sahiptir. Önerilen derin öğrenme ağı, eğitim aşamasında normal ve AF kayıtlarının eşit uzunluktaki bölümleri kullanılarak eğitilmiştir. PAF kayıtları modele üçüncü bir sınıf olarak tanıtılmamıştır. AF ve normal sınıflarından örneklerle eğitilen ÇYUKSB modeli, test aşamasında her üç sınıfın da mevcut olduğu tüm veri setleriyle test edilmiştir.

Veri setindeki her bir EKG kaydı, I ve II derivasyonlarına sahiptir. Veri setinde her EKG kaydı için iki sinyal saklanmaktadır. Ön işlem aşamasında bu sinyaller, frekansları 360Hz olacak şekilde yeniden örneklenmiştir. Arkasından her bir kaydın iki derivasyonu FD ile zaman alanından frekans alanına taşınmıştır. Burada genlik değerlerinin ortalaması alınarak TFD ile zaman alanına taşınmış ve tek bir sinyal elde edilmiştir. Elde edilen sinyal, derin öğrenme modelinde işlenebilmesi için sabit uzunlukta pencereye bölümlenmiştir. Bu

amaçla pencere büyüklüğü olarak 0,3, 0,4 ve 0,5 saniye uzunluğunda bölümlenmelerle deneyler yapılmıştır.

Bu aşamada ayrıca sinyal normalizasyonu ve taban çizgisi artefaktının sistemin performansı üstündeki etkisi incelenmiştir. Bu amaçla sinyalden P dalgaları çıkarılmış ve bunlar farklı yöntemlerle artefaktan arındırılmaya çalışılmıştır. İlk olarak P dalgalarının üstünde 0,5-50Hz aralığında bant geçiren filtre uygulanmıştır. Bu yöntemle kas hareketleri ve harici etkilerden kaynaklı yüksek frekansa sahip artefaktlar temizlenmeye çalışılmıştır. İkinci filtreleme yönteminde AMA ile dekompoze edilen sinyal, seçilen ilk sıralardaki IMF'ler kullanılarak yeniden oluşturulmuştur. Üçüncü artefakt temizleme yöntemindeyse sinyal üzerinde daubechies-6 ana dalgacığı ile 6 seviyeli ADD uygulanarak katsayılar elde edilmiştir. Yaklaşım (approximation) katsayıları filtrelenerek kalan katsayılardan TDD ile sinyal geri dönüştürülmüştür. İkinci ve üçüncü yaklaşımlarla hareket ve nefes alışverişi kaynaklı düşük frekanslı artefaktların temizlenmesi hedeflenmiştir. Elde edilen işlenmiş P dalgaları en büyük mutlak değere bölünme ve z-skor normalizasyonlarından sonra ÇYUKSB katmanı içeren bir derin ağ ile sınıflandırılmıştır. Derin ağ modelinin ulaştığı eğitim doğrulukları Çizelge 3.13'te verilmiştir. Buradan çıkan sonuçlar doğrultusunda önerilen yöntemde kullanılan sinyallere artefakt temizliği yapılmamıştır. Normalizasyon içinse maksimum mutlak değerle bölme işlemi uygulanmıştır.

**Çizelge 3.13:** Ön işlemde geçen EKG kompleksinin P dalgasından artefakt temizlenmesinin performans üstünde etkisi

Artefakt Temizleme Yöntemi	Normalizasyon	Set 1	Set 2	Set 1-2
<b>Yok</b>	Maks. abs. değer	<b>97,2</b>	85,1	<b>95,2</b>
	z-skor	96,8	81,9	95,0
<b>Bant Geçiren Filtre</b>	Maks. abs. değer	91,2	88,4	88,8
	z-skor	92,0	88,9	90,2
<b>AMA (IMF 1 ve 2)</b>	Maks. abs. değer	86,0	84,1	80,5
	z-skor	86,5	84,8	81,4
<b>AMA (IMF 1, 2 ve 3)</b>	Maks. abs. değer	88,8	87,3	85,6
	z-skor	89,3	87,0	87,0
<b>ADD</b>	Maks. abs. değer	91,9	89,9	89,6
	z-skor	93,0	<b>90,3</b>	90,5

### 3.5.2 Özellik çıkarımı ve sınıflandırma

Ön işlem aşamasında tek kanala dönüştürülerek bölümlenen EKG kayıtlarından uzunluklarına bağlı olarak değişken sayıda pencereler çıkarılmıştır.  $N$  adet pencereye sahip



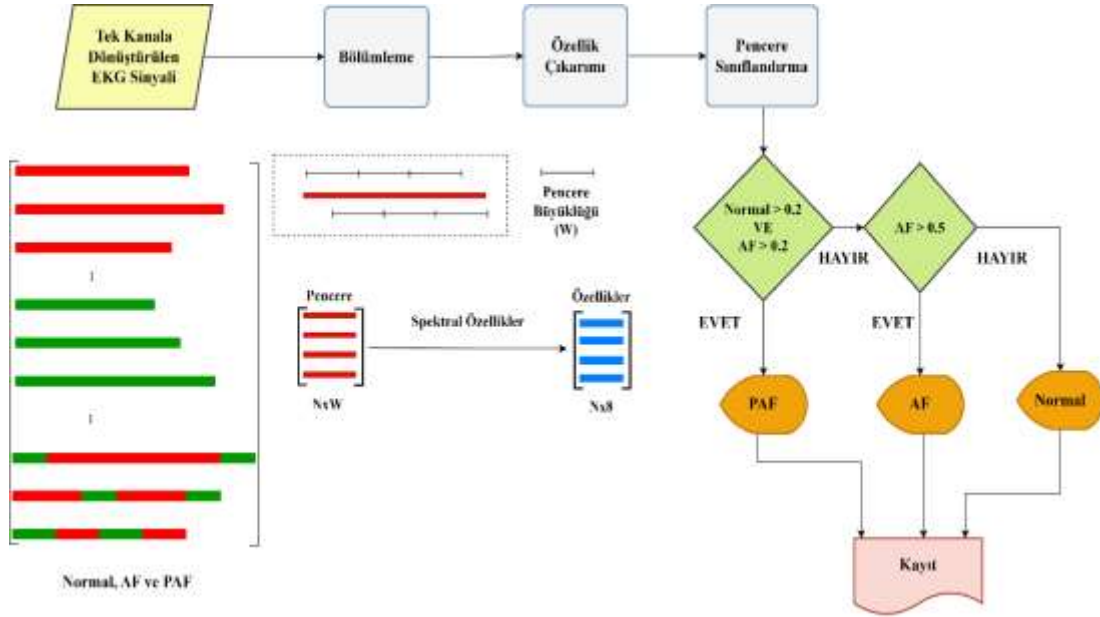
olan bir sinyalden çıkarılan 8 spektral özelliikle (spektral ağırlık merkezi, spektral krest, spektral entropi, spektral akı, spektral çarpıklık, spektral basıklık, spektral yuvarlanma noktası ve spektral eğim) toplamda  $N \times 8$  boyutunda özellik matrisleri oluşturulmuştur.

Önerilen yöntemde kullanılan derin ağ iki sınıflı (normal ve AF) ayırma yapacak şekilde tasarlanmıştır. Kullanılan derin ağ modeli ÇYUKSB katmanına dayanmaktadır. ÇYUKSB ile veri hem ileri yönde hem de geri yönde işlenir. Böylece girdi dizisinin her iki yönündeki değerleri arasındaki sıralı bağımlılıkları yakalamada başarılı sonuçlar alınmaktadır. Önerilen yöntemde kullanılan derin öğrenme modelinin katmanları Çizelge 3.14’te verilmiştir.

**Çizelge 3.14:** EKG sınıflandırmak için önerilen ÇYUKSB tabanlı derin ağ mimarisi

<b>Katman</b>	<b>Boyut</b>	<b>Gizli Ünite Sayısı</b>
<b>Girdi</b>	60, 80 veya 100	-
<b>ÇYUKSB</b>	-	120, 160, 200, 240 veya 280
<b>Tam Bağlı</b>	2	-
<b>Yumuşatma</b>	-	-
<b>Sınıflandırma</b>	-	-

Normal ve AF kayıtlarından elde edilen pencerelerle eğitilen model, test aşamasında PAF kayıtlarının pencerelerini de sınıflandırmada kullanılmıştır. Sabit uzunlukta bölümlere ayrılan kayıtları önerilen model normal veya fibrilasyon içerikli olarak etiketlenmiştir. Arkasından EKG kaydına ait olan tüm bölümlerin etiketlerinin oranına bakılarak test aşamasının son kararı verilmiştir. Bu aşamada eğer hem normal hem de AF oranı 0,2’den yüksekse kayıt PAF olarak belirlenmiştir. Eğer AF oranı 0,5’den yüksekse EKG kaydı AF olarak ve aksi takdirde de normal olarak sınıflandırılmıştır. Test aşamasında izlenen karar alma algoritması Şekil 3.9’da gösterilmiştir.



**Şekil 3.9:** EKG kayıtlarının sınıflandırılmasında kullanılan karar alma algoritması

Çalışmada sunulan yöntemin performansını karşılaştırmak için Chen ve diğ. [72] tarafından önerilen bir derin ağ modeli kullanılmıştır. Evrişim ve UKSB katmanlarından oluşan basamaklara sahip olan bu modelin girdisini EKG sinyalinin R-R tepeleri arası uzaklıkları ve 10 saniyelik sabit uzunluktaki pencereleri oluşturmaktadır. R-R tepeleri arası mesafeler  $22 \times 1$  ve 10 saniye uzunluğundaki pencereler  $3600 \times 1$  boyutunda seri formatında girdiler oluşturmaktadır. Bu girdiler evrişim katmanlarından işlenerek ortak boyutlara indirgindikten sonra birleştirilmektedir.

Girdilerin birleştirilmesinden sonra veri içerisindeki uzun süreli bağımlılıklar 32 ve 64 gizli üniteye sahip iki UKSB katmanı ile yakalanmıştır. UKSB birimleri arasındaki bağlantılar, bilgilerin ardışık zaman adımları arasında döngüsel olarak işlenerek derin ağın zaman kavramını anlamasına ve girdideki zamansal dinamikleri dahili bir geri bildirim mekanizmasıyla yorumlamasına olanak tanır. UKSB katmanlarının aksine veriyi çift yönlü işleyip bağımlılıkları tespit eden ÇYUKSB katmanları daha başarılı sonuçlar vermesine karşılık UKSB'den daha fazla hafıza ve hesaplama zamanına ihtiyaç duyar.

Önerilen uygulamayı karşılaştırmak için bu çalışmada kullanılan ve Chen ve diğ. [72] tarafından geliştirilen ESA ve UKSB tabanlı derin ağın katmanları Çizelge 3.15'te verilmiştir. Bu derin ağ, önerilen modelin aksine üç sınıfla eğitilerek normal, AF ve PAF sınıflandırması için test aşamasında doğrudan karar vermektedir.

**Çizelge 3.15:** [72]'de sunulan ve tez çalışmasında önerilen yöntemi karşılaştırmak için kodlanan derin ağ mimarisi

Katman	Girdi/Çıktı Büyüküğü	Filtre Büyüküğü	Filtre Sayısı	Havuz Büyüküğü	Adım	Gizli Ünite
<b>Girdi-1</b>	(3600, 1)	-	-	-	-	-
<b>Evrişim</b>	-	(251, 1)	5	-	-	-
<b>Maksimum Havuzlama</b>	-	-	-	(2, 1)	(2, 2)	-
<b>Evrişim</b>	-	(150, 1)	5	-	-	-
<b>Maksimum Havuzlama</b>	-	-	-	(2, 1)	(2, 2)	-
<b>Evrişim</b>	-	(100, 1)	10	-	-	-
<b>Maksimum Havuzlama</b>	-	-	-	(2, 1)	(2, 2)	-
<b>Evrişim</b>	-	(81, 1)	20	-	-	-
<b>Maksimum Havuzlama</b>	-	-	-	(2, 1)	(2, 2)	-
<b>Evrişim</b>	-	(61, 1)	20	-	-	-
<b>Maksimum Havuzlama</b>	-	-	-	(2, 1)	(2, 2)	-
<b>Evrişim</b>	-	(14, 1)	10	-	-	-
<b>Maksimum Havuzlama</b>	-	-	-	(2, 1)	(2, 2)	-
<b>Girdi-2</b>	(22, 1)	-	-	-	-	-
<b>Evrişim</b>	-	(3, 1)	10	-	-	-
<b>Maksimum Havuzlama</b>	-	-	-	(2, 1)	(2, 2)	-
<b>Birleştirme</b>	(11, 10)	-	-	-	-	-
<b>UKSB</b>	-	-	-	-	-	32
<b>UKSB</b>	-	-	-	-	-	64
<b>Tam Bağlı</b>	3	-	-	-	-	-

### 3.5.3 Performans değerlendirmesi

Bu bölümde önerilen yöntemin başarısı ve sağlamlığı *Doğruluk* metriği kullanılarak ölçülmüş ve diğer yöntemle karşılaştırılmıştır. CPSC2021 veri setlerinin kullanıldığı çalışmada öncelikle uygun pencere boyutu ve gizli ünite sayısı parametrelerini bulmak için eğitimler yapılmıştır. ÇYUKSB katmanlı derin ağın eğitimi burada bulunan parametrelere göre yapılmıştır. Eğitilen derin ağ, test aşamasında üç sınıflı ayırımı yapmada kullanılmıştır.

**Çizelge 3.16:** Önerilen yöntemin farklı parametrelerle elde edilen eğitim doğrulukları

Pencere boyutu (saniye)	ÇYUKSB Gizli Ünite Sayısı	Set 1	Set 2	Set 1-2
0,3	120	99,6	87,9	<b>99,6</b>
0,3	160	<b>99,7</b>	87,2	99,5
0,3	200	<b>99,7</b>	83,6	<b>99,6</b>
0,3	240	99,0	84,9	<b>99,6</b>
0,3	280	99,6	83,5	<b>99,6</b>
0,4	120	98,6	88,0	99,4
0,4	160	99,5	86,8	99,2
0,4	200	99,6	88,5	<b>99,6</b>
0,4	240	99,6	87,5	99,1
0,4	280	<b>99,7</b>	84,6	99,3
0,5	120	99,0	86,5	98,2
0,5	160	99,0	88,5	99,2
0,5	200	99,0	<b>88,6</b>	99,2
0,5	240	99,1	87,4	99,3
0,5	280	99,4	85,4	99,1

Çizelge 3.16’da görüldüğü gibi ÇYUKSB katmanlı derin öğrenme ağı eğitim aşamasında CPSC2021 veri setlerinden ilkinde %99’un üzerinde doğruluğa ulaşabilmektedir. İkinci veri setinde eğitim doğruluğu düşmekle beraber %88’in üzerindedir. Her iki veri setinin toplamı olan Set 1-2 kullanılarak yapılan deneylerde başarı yükselerek %99’u aşmaktadır. Eğitim aşamasında ulaşılan bu sonuçlar iki sınıflı Normal, AF ayırımına aittir. Önerilen yöntem, iki sınıfla eğitilen derin ağı test aşamasında üçlü sınıflandırmada kullanılmaktadır. Bu amaçla, Çizelge 3.16’daki sonuçlara bakarak 200 gizli ünitelerden oluşan ÇYUKSB katmanlı derin ağı oluşturulup eğitilmiş ve Şekil 3.9’da gösterilen karar alma algoritmasıyla EKG verileri üç sınıfa ayrılmıştır. Önerilen yöntemin test doğruluğu Çizelge 3.17’de verilmiştir.

**Çizelge 3.17:** Önerilen yöntemin test performansı ve diğer yöntemlerle karşılaştırması

Metot	Set 1	Set 2	Set 1-2
[72]	83,2	73,5	79,3
<b>Önerilen yöntem</b>	89,9	81,6	86,1

Çizelge 3.17’de 200 adet gizli ünitelerden oluşan bir ÇYUKSB tabanlı derin ağı kullanan önerilen yöntem, ESA+UKSB hibridi olan 20 katmanlı bir derin ağı ile karşılaştırılmıştır. ESA modelleri uzamsal olarak verilerle başa çıkmada güçlüyken UKSB ise ardışık ilişki içerisinde olan serilerle çalışıldığında etkilidir. Bu iki mimarinin katmanlarının ortak bir modelde basamaklar halinde kullanılmasıyla her iki modelin güçlü yanlarını birleştiren bir hibrit model elde edilmiştir. Diğer taraftan, ÇYUKSB zamansal verileri yorumlamada

UKSB kullanan ađlardan daha bařarılıdır. Ancak bu model kullanılırken daha uzun hesaplama zamanı ve yüksek bilgisayar hafızasına ihtiyaç duyulmaktadır. Katman sayısı az olmasına rađmen önerilen yöntemle CPSC2021 veri setleri üzerinde daha yüksek dođrulukta sonuçlar alınmıştır.



#### 4. SONUÇ VE ÖNERİLER

Bu tezde, PCG kayıtlarında temel kalp seslerinin yanında görülebilen kalp üfürümlerinin bilgisayar destekli sistemlerle tanınmasına çalışılmıştır. Kalp seslerinin bölümlenmesi ve normal/anormal olarak sınıflandırılmasında yönelik literatürdeki mevcut yöntemler incelenmiştir. Bu çalışmalarda önerilen çözümler, karşılaşılan problemler ve eksiklikler analiz edilmiştir. Makine öğrenmesi yöntemleriyle kardiyovasküler rahatsızlıkların analizinde kullanılan derin ağ tabanlı yöntemlerin performansını karşılaştırabilmek amacıyla klasik sınıflayıcılar birinci uygulamada test edilmiştir. İkinci uygulamada temel kalp seslerinin ve üfürümlerin frekans bantlarına göre filtrelenip bunlardan çıkarılan MFKK değerleriyle sınıflandırma yapan bir çalışma yapılmıştır. Son çalışmada PCG kayıtlarından entropi ve enerji değerlerini optimize ederek çerçeve çıkararak ve çerçevelerin spektrogramlarını sınıflandırmada kullanan bir uygulama önerilmiştir.

Tezde sunulan PCG analizi yapan yöntemlerde CinC2016 ve CirCor2022 veri setleri kullanılmıştır. Literatürdeki en kapsamlı ve en geniş olan bu iki veri setinin örnekleme frekansı, kayıt süresi ve sınıf sayısında farklılıklar bulunmaktadır. Ön işlem aşamasında PCG kayıtları ortak bir değere yeniden örneklendirilmiş, normalize edilmiş, bir saniye uzunluğunda çerçevelere ayrılmış, uyum problemleri giderilmiş ve dengeli birer veri setine dönüştürülmüştür. CinC2016 veri setinden elde edilen 109314 ve CirCor2022 veri setinden elde edilen 106460 PCG çerçevesi tezde sunulan birinci ve ikinci uygulamalarda kullanılmıştır. Tezde kullanılan diğer bir kaynak CPSC2021 EKG veri setidir. İki derivasyonlu EKG kayıtları içeren CPSC2021 veri seti ön işlem aşamasında FD ile tek kanala dönüştürülmüş ve pencerelere bölümlenmiştir.

Yapılan ilk uygulamada KEYK, DVM ve C4.5 karar ağacı sınıflandırıcılarının performansları ölçülmüştür. Sınıflayıcılar, 10 katlı çapraz doğrulama yapacak şekilde kullanılmıştır. Bu sınıflayıcıları standart bir ölçüm kriteri olarak kullanıp literatüre tanımlamak için halka açık olarak sunulan WEKA uygulama program arabirimi altında sunulan implementasyonlar kullanılmıştır. KEYK ile CinC2016 veri seti için 89,9 doğruluk oranına ve CirCor2022 veri seti için 72,9 doğruluk oranına ulaşılmıştır. DVM ile CinC2016 veri setinde 85,0 doğruluk oranı ve CirCor2022 veri setinde 67,7 doğruluk oranı elde

edilmiştir. En yüksek doğruluk oranları C4.5 karar ağacıyla CinC2016 veri setinde 92,3 olarak ve CirCor2022 veri setinde 81,8 olarak kaydedilmiştir. Farklı çalışmalarda derin olmayan bu ve benzeri sınıflayıcıları kullanarak literatürde sunulan çalışmalarda da yaklaşık olarak bu aralıklarda sonuçlar göze çarpmaktadır.

Yapılan ikinci çalışmada ön işlem aşamasıyla üretilen 1 saniye uzunluğundaki PCG çerçeveleri ADD ve AMA tabanlı filtrelerle orta ve yüksek frekans bantlarına ayrılmıştır. Orta frekans bandında temel kalp seslerinin saptanması ve yüksek frekans bandında üfürümlerin yakalanması amaçlanmıştır. Her iki filtrelenmiş sinyalden MFKK özellikleri çıkarılmıştır. Aynı MFKK pencerelerine karşılık gelen değerler birleştirilerek elde edilen 99x10 boyutlu özellik matrisi önce %80 eğitim ve %20 test örneği olacak şekilde sonra da %90 eğitim ve %10 test örneği olacak şekilde ikiye bölünmüştür. Bu veriler ESA mimarisine girdi olarak verilmiştir. Eğitim ve test setlerindeki örnekler rastgele seçilmiş ve ESA modeli bunlarla tekrar tekrar çalıştırılmıştır. Farklı verilerle çalışan modelin genel performansı tatmin edici düzeydedir. Verinin onda birini test olarak kullanan deneylerde CinC2016 veri setinde 89,1 doğruluk değeri ve CirCor2022 veri setinde 78,5 doğruluk değeri kaydedilmiştir. Modelin çalışma süreleri ise CinC2016 veri setinde yapılan deneyde yaklaşık olarak 989 saniye ve CirCor2022 veri setinin kullanıldığı deneyde 1012 saniyedir.

Yapılan üçüncü çalışmada ilk iki uygulamadan farklı olarak ön işlem aşamasıyla oluşturulan PCG çerçeve veri setleri kullanılmamıştır. Üçüncü uygulamada, YAK tabanlı entropi/enerji optimizasyonu ile PCG kayıtlarından önce 3 saniyelik çerçeveler çıkarılmıştır. Bu çerçevelerden hem CiinC2016 hem de CirCor2022 için dengeli birer veri seti oluşturulmuştur. Bu yaklaşımla PCG kayıtlarına ani olarak giren hırıltı, konuşma ve ortam sesi benzeri gürültülerin etkisinden kaçınılması amaçlanmıştır. Bu çerçeveler ikinci aşamada bölümlenme işlemiyle S1, sistol, S2 ve diyastol kısımlarına ayrıştırılmıştır. Üç saniyelik bölümlenmiş çerçevelerden hepsi aynı anda S1 ile başlayan birer saniyelik daha küçük çerçeveler kırılarak çıkarılmıştır. Elde edilen bir saniye uzunluğundaki çerçevelerden KZFD ile çıkarılan spektrogram çıkarılmıştır. PCG çerçeve seçimi ve sinyal kırma işlemlerinin arkasından CinC2016 veri setinden 5235 ve CirCor2022 veri setinden 4774 adet boyutları 128x14 olan spektrogram elde edilmiştir. Spektrogram verisi önce %80 eğitim ve %20 test örneği olacak şekilde sonra da %90 eğitim ve %10 test örneği olacak şekilde ikiye bölünmüştür. Bu veriler ESA mimarisine girdi olarak verilmiştir. Eğitim ve test setlerindeki örnekler rastgele seçilmiş ve ESA modeli bunlarla tekrar tekrar çalıştırılmıştır. Yapılan deneyler sonunda elde edilen en iyi doğruluk sonuçları CinC2016 veri setinde 94,5 ve

CirCor2022 veri setinde 82,0 olmuştur. Literatürde benzer yaklaşımlar kullanan güncel çalışmalarla karşılaştırıldığında sonuçlar tatmin edicidir. Modelin çalışma süreleri ise CinC2016 veri setinde yapılan deneyde yaklaşık olarak 195 saniye ve CirCor2022 veri setinin kullanıldığı deneyde 154 saniyedir. Bu uygulamada önerilen yaklaşım doğruluk metriğine kullanılarak yapılan karşılaştırmada ilk iki modelden daha başarılı olmasının yanında model tarafından harcanan süre açısından da ilk iki uygulamada sunulan yöntemlerden daha iyidir.

Yapılan son çalışmada CPSC2021 veri setindeki EKG kayıtları normal, AF ve PAF olarak sınıflandırılmıştır. Eğitim parametrelerini belirlemek için değişik pencere boyutlarıyla deneyler yapılmıştır. Pencereye ayrılan EKG sinyallerinden spektral özellikler çıkarılmıştır ve bu özellik matrisleriyle derin ÇYUKSB katmanına sahip bir derin ağ eğitilmiştir. Kullanılan derin ağ, normal ve AF kayıtlarını tanımak üzere eğitilmiştir. Test aşamasında PAF kayıtlarına ait bölümler normal veya AF olarak etiketlenmiştir. Herhangi bir kayıt sınıflandırılırken o kayda ait tüm bölümlerin etiketlerinin oranlarına bakılarak karar alınmıştır. Önerilen yöntem, evrimsel katmanlara ve UKSB'e sahip bir derin ağ ile karşılaştırılmıştır. ÇYUKSB kullanan önerilen yöntemle ESA+UKSB hibridi olan yöntemden  $\%7 \pm 1$  daha yüksek doğrulukta sonuçlar alındığı görülmüştür.

İki PCG veri setini karşılaştırdığımızda CirCor2022 veri setinin CinC2016 veri setinden daha zorlayıcı olduğu görülmüştür. Söz konusu veri setinin kullanıldığı PhysioNet 2022 yarışmasına katılan tüm katılımcıların aldığı doğruluk, hassasiyet ve kesinlik değerleri bunu göstermektedir. Klinisyenler tarafından tespit edilmiş olan üfürüm etiketlerinin klinik sonucu tahmin etmedeki zayıf hassasiyeti, veri setindeki üfürümlerin çoğunun işitilebilir bir seviyede olmadığına işaret etmektedir. Gelecekte yeni veri setleriyle tezde önerilen yöntemler geliştirilebilir. Bu kapsamda gerekli etik izinler alındıktan sonra ve gerekli teknik altyapı sağlandıktan sonra hastanelerden PCG kayıtları toplanarak özel bir veri seti oluşturulabilir.

ESA modelleriyle yapılan deneylerde ÇYUKSB katman kullanıldığında modelin performansında önemli bir artış olmaktadır. Ancak katman sayısı fazla artırıldığı durumlarda performansta düşüş gözlemlenmiştir. Her ne kadar daha fazla derinlikte ve çok katmandan oluşan modeller sinyallerdeki daha karmaşık kalıpları öğrenebileceği düşünülse de bu durum aşırı öğrenmeye yol açarak rastgele örneklerden oluşan test veri setini sınıflandırmada performans düşüklüğüne yol açmaktadır. Dördüncü uygulamada UKSB ve evrimsel katmanlara sahip olan bir derin ağ ile ÇYUKSB tabanlı bir derin ağ karşılaştırılmıştır.



CPSC2021 veri setinin EKG kayıtlarının kullanıldığı çalışmada ÇYUKSB kullanan yöntemle daha yüksek doğrulukta sonuçlar alınmıştır.

Benzer şekilde KEYK, DVM ve C4.5 karar ağacı sınıflandırıcılarında kullanılan özelliklerin de sınıflandırma performansı üstünde doğrudan etkileri görülmüştür. Veriyi yüksek kabiliyetle temsil eden az sayıda öznelikle yapılan sınıflandırmalar, çok kalabalık öznelik setleri kullanılan deneylerden daha başarılı sonuçlar vermiştir.

ESA modelinin verimli kullanılabilmesi için bir başka gereklilik de yeterli sayıda örneğe sahip veri setlerine sahip olmaktır. Küçük örneklem boyutu ESA modelini aşırı öğrenmeye maruz bırakabilir. ESA mimarisiyle fark edilebilir bir doğruluk elde edebilmek için binlerce örnekten oluşan veri setleri kullanılmalıdır.

Gelecekteki çalışmalarda, kalp seslerinin içerdikleri üfürümün sistolik, diyastolik veya sürekli olması bakımından türlerine göre sınıflandırılmasına yönelik uygulamalar geliştirilebilir. Ayrıca temel kalp seslerinin bölümlenmesi için farklı çalışmalar yapılabilir.

## KAYNAKLAR

- [1] **Khan, M. U., Samer, S., Alshehri, M. D., Baloch, N. K., Khan, H., Hussain, F., ... & Zikria, Y. B. (2022).** Artificial neural network-based cardiovascular disease prediction using spectral features. *Computers and Electrical Engineering*, 101, 108094.
- [2] **Kanejima, Y., Kitamura, M., & Izawa, K. P. (2019).** Self-monitoring to increase physical activity in patients with cardiovascular disease: a systematic review and meta-analysis. *Aging clinical and experimental research*, 31, 163-173.
- [3] **Friedman, J., Saric, M. (2018).** Echocardiography in a Patient with a New Murmur. In: Herzog, E., Argulian, E. (eds) *Echocardiography in the CCU*. Springer, Cham. [https://doi.org/10.1007/978-3-319-90278-4\\_6](https://doi.org/10.1007/978-3-319-90278-4_6)
- [4] **Silverman, M. E., & Wooley, C. F. (2008).** Samuel A. Levine and the history of grading systolic murmurs. *The American journal of cardiology*, 102(8), 1107-1110.
- [5] **Felner J. M. (1990).** The First Heart Sound. *Clinical Methods*, NCBI Bookshelf, Chapter 22. Available from: <https://www.ncbi.nlm.nih.gov/books/NBK333/>
- [6] **Varghees, V. N., & Ramachandran, K. I. (2014).** A novel heart sound activity detection framework for automated heart sound analysis. *Biomedical Signal Processing and Control*, 13, 174-188.
- [7] **Springer, D. B., Tarassenko, L., & Clifford, G. D. (2015).** Logistic regression-HSMM-based heart sound segmentation. *IEEE transactions on biomedical engineering*, 63(4), 822-832.
- [8] **Ismail, S., Siddiqi, I., & Akram, U. (2018).** Localization and classification of heart beats in phonocardiography signals—a comprehensive review. *EURASIP Journal on Advances in Signal Processing*, 2018(1), 1-27.
- [9] **Schmidt, S. E., Holst-Hansen, C., Graff, C., Toft, E., & Struijk, J. J. (2010).** Segmentation of heart sound recordings by a duration-dependent hidden Markov model. *Physiological measurement*, 31(4), 513.

- [10] **Liu, C., Springer, D., Li, Q., Moody, B., Juan, R. A., Chorro, F. J., & Castells, F. (2016).** José Millet Roig, Ikaro Silva, Alistair EW Johnson, et al. An open access database for the evaluation of heart sound algorithms. *Physiological Measurement*, 37(12), 2181.
- [11] **Ren, Z., Chang, Y., Nguyen, T. T., Tan, Y., Qian, K., & Schuller, B. W. (2023).** A Comprehensive Survey on Heart Sound Analysis in the Deep Learning Era. arXiv preprint arXiv:2301.09362.
- [12] **Sun, H., Chen, W., & Gong, J. (2013).** An improved empirical mode decomposition-wavelet algorithm for phonocardiogram signal denoising and its application in the first and second heart sound extraction. In 2013 6th international conference on biomedical engineering and informatics (pp. 187-191). IEEE.
- [13] **Xu, Y., Bao, X., Lam, H. K., & Kamavuako, E. (2022).** Hierarchical Multi-Scale Convolutional Network for Murmurs Detection on PCG Signals. In *Computing in Cardiology (CinC) 2022*.
- [14] **Wang, Y., Li, W., Zhou, J., Li, X., & Pu, Y. (2014).** Identification of the normal and abnormal heart sounds using wavelet-time entropy features based on OMS-WPD. *Future Generation Computer Systems*, 37, 488-495.
- [15] **Oliveira, J., Renna, F., Mantadelis, T., & Coimbra, M. (2018).** Adaptive sojourn time HSMM for heart sound segmentation. *IEEE journal of biomedical and health informatics*, 23(2), 642-649.
- [16] **Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P., & Mark, R. (2000).** J. Mietus, G. Moody, C.-K. Peng, H. Stanley, Physiobank, physiotoolkit, 33 and physionet: Components of a new research resource for complex 34 physiologic signals. *Circulation*, 101.
- [17] **J. H. Oliveira, F. Renna, P. Costa, D. Nogueira, C. Oliveira, C. Ferreira, A. Jorge, S. Mattos, T. Hatem, T. Tavares, A. Elola, A. Rad, R. Sameni, G. D. Clifford, & M. T. Coimbra (2021).** The CirCor DigiScope Dataset: From Murmur Detection to Murmur Classification. *IEEE Journal of Biomedical and Health Informatics*, <https://doi.org/10.1109/JBHI.2021.3137048>.

- [18] **Oliveira, J., Renna, F., Costa, P., Nogueira, M., Oliveira, A. C., Elola, A., Ferreira, C., Jorge, A., Bahrami Rad, A., Reyna, M., Sameni, R., Clifford, G., & Coimbra, M. (2022).** The CirCor DigiScope Phonocardiogram Dataset (version 1.0.1). PhysioNet. <https://doi.org/10.13026/7bkn-d780>.
- [19] **Reyna, M. A., Kiarashi, Y., Elola, A., Oliveira, J., Renna, F., Gu, A., ... & Clifford, G. D. (2022).** Heart murmur detection from phonocardiogram recordings: The george b. moody physionet challenge 2022. medRxiv, 2022-08.
- [20] **Dwivedi, A. K., Imtiaz, S. A., & Rodriguez-Villegas, E. (2018).** Algorithms for automatic analysis and classification of heart sounds—a systematic review. *IEEE Access*, 7, 8316-8345.
- [21] **Bentley, P.J., Nordehn, G., Coimbra, M., Mannor, S. (2011).** The PASCAL classifying heart sounds challenge 2011 (CHSC2011) Results. [www.peterjbentley.com/heartchallenge/](http://www.peterjbentley.com/heartchallenge/)
- [22] **Thompson, W. R., Reinisch, A. J., Unterberger, M. J., & Schriebl, A. J. (2019).** Artificial intelligence-assisted auscultation of heart murmurs: validation by virtual clinical trial. *Pediatric cardiology*, 40, 623-629.
- [23] **Son, G. Y., & Kwon, S. (2018).** Classification of heart sound signal using multiple features. *Applied Sciences*, 8(12), 2344.
- [24] **Chen, J., Guo, Z., Xu, X., Zhang, L. B., Teng, Y., Chen, Y., ... & Wang, W. (2023).** A Robust Deep Learning Framework Based on Spectrograms for Heart Sound Classification. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*.
- [25] **Das, S., Pal, S., & Mitra, M. (2019).** Supervised model for Cochleagram feature based fundamental heart sound identification. *Biomedical Signal Processing and Control*, 52, 32-40.
- [26] **Elola, A., Aramendi, E., Oliveira, J., Renna, F., Coimbra, M. T., Reyna, M. A., ... & Rad, A. B. (2022).** Beyond Heart Murmur Detection: Automatic Murmur Grading from Phonocardiogram. arXiv preprint arXiv:2209.13385.
- [27] **Delgado-Trejos, E., Quiceno-Manrique, A. F., Godino-Llorente, J. I., Blanco-Velasco, M., & Castellanos-Dominguez, G. (2009).** Digital auscultation analysis for heart murmur detection. *Annals of biomedical engineering*, 37, 337-353.

- [28] **Radia, F., & Zine-Eddine, H. S. (2019).** A new heart sounds segmentation approach based on the correlation between ECG and PCG signals. *International Journal of Biomedical Engineering and Technology*, 29(2), 174-185.
- [29] **Behbahani, S. (2019).** A hybrid algorithm for heart sounds segmentation based on phonocardiogram. *Journal of Medical Engineering & Technology*, 43(6), 363-377.
- [30] **El-Segaier, M., Lilja, O., Lukkarinen, S., Sörnmo, L., Sepponen, R., & Pesonen, E. (2005).** Computer-based detection and analysis of heart sound and murmur. *Annals of biomedical engineering*, 33, 937-942.
- [31] **Safara, F., Doraisamy, S., Azman, A., Jantan, A., & Ramaiah, A. R. A. (2013).** Multi-level basis selection of wavelet packet decomposition tree for heart sound classification. *Computers in biology and medicine*, 43(10), 1407-1414.
- [32] **Kiranyaz, S., Zabihi, M., Rad, A. B., Ince, T., Hamila, R., & Gabbouj, M. (2020).** Real-time phonocardiogram anomaly detection by adaptive 1D convolutional neural networks. *Neurocomputing*, 411, 291-301.
- [33] **Ari, S., & Saha, G. (2007).** On a robust algorithm for heart sound segmentation. *Journal of Mechanics in Medicine and Biology*, 7(02), 129-150.
- [34] **Papadaniil, C. D., & Hadjileontiadis, L. J. (2013).** Efficient heart sound segmentation and extraction using ensemble empirical mode decomposition and kurtosis features. *IEEE journal of biomedical and health informatics*, 18(4), 1138-1152.
- [35] **Potes, C., Parvaneh, S., Rahman, A., & Conroy, B. (2016).** Ensemble of feature-based and deep learning-based classifiers for detection of abnormal heart sounds. In *2016 computing in cardiology conference (CinC)* (pp. 621-624). IEEE.
- [36] **Rubin, J., Abreu, R., Ganguli, A., Nelaturi, S., Matei, I., & Sricharan, K. (2016).** Classifying heart sound recordings using deep convolutional neural networks and mel-frequency cepstral coefficients. In *2016 Computing in cardiology conference (CinC)* (pp. 813-816). IEEE.
- [37] **Nilanon, T., Yao, J., Hao, J., Purushotham, S., & Liu, Y. (2016).** Normal/abnormal heart sound recordings classification using convolutional neural network. In *2016 computing in cardiology conference (CinC)* (pp. 585-588). IEEE.

- [38] **Tschannen, M., Kramer, T., Marti, G., Heinzmann, M., & Wiatowski, T. (2016).** Heart sound classification using deep structured features. In 2016 Computing in Cardiology Conference (CinC) (pp. 565-568). IEEE.
- [39] **Munia, T. T., Tavakolian, K., Verma, A. K., Zakeri, V., Khosrow-Khavar, F., Fazel-Rezai, R., & Akhbardeh, A. (2016).** Heart sound classification from wavelet decomposed signal using morphological and statistical features. In 2016 Computing in Cardiology Conference (CinC) (pp. 597-600). IEEE.
- [40] **Kay, E., & Agarwal, A. (2016).** Dropconnected neural network trained with diverse features for classifying heart sounds. In 2016 Computing in Cardiology Conference (CinC) (pp. 617-620). IEEE.
- [41] **Zabihi, M., Rad, A. B., Kiranyaz, S., Gabbouj, M., & Katsaggelos, A. K. (2016).** Heart sound anomaly and quality detection using ensemble of neural networks without segmentation. In 2016 computing in cardiology conference (CinC) (pp. 613-616). IEEE.
- [42] **Langley, P., & Murray, A. (2016).** Abnormal heart sounds detected from short duration unsegmented phonocardiograms by wavelet entropy. In 2016 Computing in Cardiology Conference (CinC) (pp. 545-548). IEEE.
- [43] **Langley, P., & Murray, A. (2017).** Heart sound classification from unsegmented phonocardiograms. *Physiological measurement*, 38(8), 1658.
- [44] **Fuadah, Y. N., Pramudito, M. A., & Lim, K. M. (2022).** An Optimal Approach for Heart Sound Classification Using Grid Search in Hyperparameter Optimization of Machine Learning. *Bioengineering*, 10(1), 45.
- [45] **McDonald, A., Gales, M., & Agarwal, A. (2022).** Detection of Heart Murmurs in Phonocardiograms with Parallel Hidden Semi-Markov Models.
- [46] **Monteiro, S., Fred, A., & Plácido da Silva, H. (2022).** Detection of Heart Sound Murmurs and Clinical Outcome with Bidirectional Long Short-Term Memory Networks. In *Proceedings of the 49th Computing in Cardiology Conference*, Tampere, Finland (pp. 4-7).
- [47] **Ballas, A., Papapanagiotou, V., Delopoulos, A., & Diou, C. (2022).** Listen to your heart: A self-supervised approach for detecting murmur in heart-beat sounds for the Physionet 2022 challenge. *arXiv e-prints*, arXiv-2208.

- [48] **Papapanagiotou, V., Diou, C., & Delopoulos, A. (2017).** Chewing detection from an in-ear microphone using convolutional neural networks. In 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 1258-1261). IEEE.
- [49] **Walker, B., Krones, F., Kiskin, I., Parsons, G., Lyons, T., Mahdi, A., & Deanery, N. I. H. R. (2022).** Dual Bayesian ResNet: A Deep Learning Approach to Heart Murmur Detection. *Computing in Cardiology*.
- [50] **Wang, X., Ma, C., Zhang, X., Gao, H., Clifford, G., & Liu, C. (2021).** Paroxysmal atrial fibrillation events detection from dynamic ECG recordings: The 4th China physiological signal challenge 2021. In *Proc. PhysioNet* (pp. 1-83).
- [51] **Dokur, Z., & Ölmez, T. (2009).** Feature determination for heart sounds based on divergence analysis. *Digital Signal Processing*, 19(3), 521-531.
- [52] **Tang, H., Li, T., Qiu, T., & Park, Y. (2012).** Segmentation of heart sounds based on dynamic clustering. *Biomedical Signal Processing and Control*, 7(5), 509-516.
- [53] **Singh, S. A., Majumder, S., & Mishra, M. (2019).** Classification of short unsegmented heart sound based on deep learning. In 2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) (pp. 1-6). IEEE.
- [54] **Li, S., Li, F., Tang, S., & Luo, F. (2021).** Heart sounds classification based on feature fusion using lightweight neural networks. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-9.
- [55] **Ibrahim, N., Jamal, N., Sha'abani, M. N. A. H., & Mahadi, L. F. (2021).** A Comparative Study of Heart Sound Signal Classification Based on Temporal, Spectral and Geometric Features. In 2020 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES) (pp. 24-29). IEEE.
- [56] **Zeng, W., Yuan, J., Yuan, C., Wang, Q., Liu, F., & Wang, Y. (2021).** A new approach for the detection of abnormal heart sound signals using TQWT, VMD and neural networks. *Artificial Intelligence Review*, 54(3), 1613-1647.

- [57] **Wu, J. M. T., Tsai, M. H., Huang, Y. Z., Islam, S. H., Hassan, M. M., Alelaiwi, A., & Fortino, G. (2019).** Applying an ensemble convolutional neural network with Savitzky–Golay filter to construct a phonocardiogram prediction model. *Applied Soft Computing*, 78, 29-40.
- [58] **Krishnan, P. T., Balasubramanian, P., & Umapathy, S. (2020).** Automated heart sound classification system from unsegmented phonocardiogram (PCG) using deep neural network. *Physical and Engineering Sciences in Medicine*, 43, 505-515.
- [59] **Al-Naami, B., Fraihat, H., Gharaibeh, N. Y., & Al-Hinnawi, A. R. M. (2020).** A Framework classification of heart sound signals in physionet challenge 2016 using high order statistics and adaptive neuro-fuzzy inference system. *IEEE Access*, 8, 224852-224859.
- [60] **Xiao, B., Xu, Y., Bi, X., Zhang, J., & Ma, X. (2020).** Heart sounds classification using a novel 1-D convolutional neural network with extremely low parameter consumption. *Neurocomputing*, 392, 153-159.
- [61] **Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... & Liu, H. H. (1998).** The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, 454(1971), 903-995.
- [62] **Zeiler, A., Faltermeier, R., Keck, I. R., Tomé, A. M., Puntonet, C. G., & Lang, E. W. (2010).** Empirical mode decomposition-an introduction. In *The 2010 international joint conference on neural networks (IJCNN)* (pp. 1-8). IEEE.
- [63] **Aziz, S., Khan, M. U., Alhaisoni, M., Akram, T., & Altaf, M. (2020).** Phonocardiogram signal processing for automatic diagnosis of congenital heart disorders through fusion of temporal and cepstral features. *Sensors*, 20(13), 3790.
- [64] **Chowdhury, T. H., Poudel, K. N., & Hu, Y. (2020).** Time-frequency analysis, denoising, compression, segmentation, and classification of PCG signals. *IEEE Access*, 8, 160882-160890.
- [65] **Redlarski, G., Gradolewski, D., & Palkowski, A. (2014).** A system for heart sounds classification. *PloS one*, 9(11), e112673.



- [66] **Bilal, M., Israr, H., Shahid, M., & Khan, A. (2016).** Sentiment classification of Roman-Urdu opinions using Naïve Bayesian, Decision Tree and KNN classification techniques. *Journal of King Saud University-Computer and Information Sciences*, 28(3), 330-344.
- [67] **Cortes, C., & Vapnik, V. (1995).** Support-vector networks. *Machine learning*, 20, 273-297.
- [68] **LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998).** Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [69] **Hochreiter, S., & Schmidhuber, J. (1997).** Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- [70] **Zhang, J., Zhu, Y., Zhang, X., Ye, M., & Yang, J. (2018).** Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas. *Journal of hydrology*, 561, 918-929.
- [71] **Gündüz, A. F., & Talu, M. F. (2023).** Atrial fibrillation classification and detection from ECG recordings. *Biomedical Signal Processing and Control*, 82, 104531.
- [72] **Chen, C., Hua, Z., Zhang, R., Liu, G., & Wen, W. (2020).** Automated arrhythmia classification based on a combination network of CNN and LSTM. *Biomedical Signal Processing and Control*, 57, 101819.
- [73] **Karaboga, D. (2005).** An idea based on honey bee swarm for numerical optimization (Vol. 200, pp. 1-10). Technical report-tr06, Erciyes university, engineering faculty, computer engineering department.
- [74] **Zhang, Y., & Wu, L. (2011).** Optimal multi-level thresholding based on maximum Tsallis entropy via an artificial bee colony approach. *Entropy*, 13(4), 841-859.
- [75] **Eibe Frank, Mark A. Hall, and Ian H. Witten (2016).** The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques", Morgan Kaufmann, Fourth Edition, 2016.
- [76] **Platt, J. (1998).** Sequential minimal optimization: A fast algorithm for training support vector machines.

- [77] **Dhar, P., Dutta, S., & Mukherjee, V. (2021).** Cross-wavelet assisted convolution neural network (AlexNet) approach for phonocardiogram signals classification. *Biomedical Signal Processing and Control*, 63, 102142.
- [78] **Müller, K., & Goda, M. A. (2022).** Heart Murmur Detection in Phonocardiographic Signals Using Breathing Noise Suppression. In *2022 Computing in Cardiology (CinC) (Vol. 498, pp. 1-4)*. IEEE.
- [79] **Stallone, A., Cicone, A., & Materassi, M. (2020).** New insights and best practices for the successful use of Empirical Mode Decomposition, Iterative Filtering and derived algorithms. *Scientific reports*, 10(1), 15161.
- [80] **Mishra, M., Banerjee, S., Thomas, D. C., Dutta, S., & Mukherjee, A. (2018).** Detection of third heart sound using variational mode decomposition. *IEEE Transactions on Instrumentation and Measurement*, 67(7), 1713-1721.
- [81] **Ali, M. N., El-Dahshan, E. S. A., & Yahia, A. H. (2017).** Denoising of heart sound signals using discrete wavelet transform. *Circuits, Systems, and Signal Processing*, 36, 4482-4497.
- [82] **Noman, F., Ting, C. M., Salleh, S. H., & Ombao, H. (2019).** Short-segment heart sound classification using an ensemble of deep convolutional neural networks. In *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) (pp. 1318-1322)*. IEEE.
- [83] **Nehary, E. A., Abduh, Z., & Rajan, S. (2021).** A Deep Convolutional Neural Network Classification of Heart Sounds using Fractional Fourier Transform. In *2021 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) (pp. 1-5)*. IEEE.
- [84] **Patwa, A., Rahman, M. M. U., & Al-Naffouri, T. Y. (2023).** Heart Murmur and Abnormal PCG Detection via Wavelet Scattering Transform & a 1D-CNN. arXiv preprint arXiv:2303.11423.
- [85] **Rohr, M., Müller, B., Dill, S., Güney, G., & Antink, C. H. (2022).** Two-Stage Multitask-Lerner for PCG Murmur Location Detection.
- [86] **Li, T., Yin, Y., Ma, K., Zhang, S., & Liu, M. (2021).** Lightweight end-to-end neural network model for automatic heart sound classification. *Information*, 12(2), 54.

- [87] **Tang, H., Wang, M., Hu, Y., Guo, B., & Li, T. (2021).** Automated signal quality assessment for heart sound signal by novel features and evaluation in open public datasets. *BioMed Research International*, 2021.
- [88] **Singh, S. A., Meitei, T. G., & Majumder, S. (2020).** Short PCG classification based on deep learning. In *Deep Learning Techniques for Biomedical and Health Informatics* (pp. 141-164). Academic Press.
- [89] **Khan, K. N., Khan, F. A., Abid, A., Olmez, T., Dokur, Z., Khandakar, A., ... & Khan, M. S. (2021).** Deep learning based classification of unsegmented phonocardiogram spectrograms leveraging transfer learning. *Physiological measurement*, 42(9), 095003.
- [90] **Karhade, J., Dash, S., Ghosh, S. K., Dash, D. K., & Tripathy, R. K. (2022).** Time–frequency-domain deep learning framework for the automated detection of heart valve disorders using PCG signals. *IEEE Transactions on Instrumentation and Measurement*, 71, 1-11.
- [91] **Maity, A., Pathak, A., & Saha, G. (2023).** Transfer learning based heart valve disease classification from Phonocardiogram signal. *Biomedical Signal Processing and Control*, 85, 104805.
- [92] **Petrolis, R., Paukstaitiene, R., Rudokaite, G., Macas, A., Grigaliunas, A., & Krisciukaitis, A. (2022).** Convolutional Neural Network Approach for Heart Murmur Sound Detection in Auscultation Signals Using Wavelet Transform Based Features. In *2022 Computing in Cardiology (CinC)* (Vol. 498, pp. 1-4). IEEE.

## ÖZGEÇMİŞ

**Ad-Soyad** : Ali Fatih Gündüz

### ÖĞRENİM DURUMU:

- **Lisans** : 2012, Orta Doğu Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği
- **Yüksek Lisans** : 2016, Orta Doğu Teknik Üniversitesi Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği

### MESLEKİ DENEYİM:

- 2012-2013 Tübitak, Araştırmacı
- 2013-2015 ODTÜ, Asistan
- 2016-... Malatya Turgut Özal Üniversitesi Akçadağ Meslek Yüksekokulu Bilgisayar Programcılığı programında öğretim görevlisi olarak çalışmaktadır.