



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



KARDİYOVASKÜLER HASTALIKLARIN TEŞHİSİNE YÖNELİK KALP SESLERİNİN SINIFLANDIRILMASI

ELİF ÇİÇEK

YÜKSEK LİSANS TEZİ

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Programı

DANIŞMAN

Dr. Öğr. Üyesi Hüseyin YÜCE

EŞ-DANIŞMAN

Prof. Dr. Alper KEPEZ

İSTANBUL, 2023



MARMARA UNIVERSITY
INSTITUTE FOR GRADUATE STUDIES
IN PURE AND APPLIED SCIENCES



**CLASSIFICATION OF HEART SOUNDS FOR
THE DIAGNOSIS OF CARDIOVASCULAR
DISEASES**

ELİF ÇİÇEK

(523519006)

MASTER THESIS

Department of Mechatronics Engineering

Thesis Supervisor

Dr. Öğr. Üyesi Hüseyin YÜCE

Thesis CO- Supervisor

Prof. Dr. Alper KEPEZ

ISTANBUL, 2023

TEŞEKKÜR

“Kardiyovasküler Hastalıkların Teşhisine Yönelik Kalp Seslerinin Sınıflandırılması” başlıklı tez çalışmamda yardımlarını ve desteklerini esirgemeyen Değerli Danışmanım Dr. Öğr. Üyesi Hüseyin YÜCE’ ye ve yine desteklerini esirgemeyen Eş Danışmanım Prof. Dr. Alper KEPEZ’ e en içten teşekkürlerimi sunarım.

Bana her zaman maddi ve manevi destek olan canım ailem; başta anne, babam olmak üzere kız kardeşlerime de tüm kalbimle sonsuz teşekkür ederim.

Lisans eğitimimde İlahiyat Bölümü ve Mekatronik Mühendisliğini birlikte okurken manevi desteklerini esirgemeyen Prof. Dr. Nihat AKKUŞ’ a ve Prof. Dr. Ali KÖSE’ ye de teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR.....	iii
ÖZET	vi
ABSTRACT	vii
SEMBOLLER.....	viii
KISALTMALAR.....	ix
ŞEKİL	xi
TABLO LİSTESİ.....	xiii
1. GİRİŞ.....	1
1.1. Amaç ve Kapsam	1
1.2. Literatür Taraması	2
1.3. Problemin Tanımı.....	6
1.4. Genel Bilgiler	6
1.4.1. Kalbin yapısı ve genel bilgiler.....	6
1.4.2. Kalp sesleri	10
1.4.2.1. Normal kalp sesleri.....	10
1.4.2.2. Anormal kalp sesleri.....	15
1.5. Kalp Sesi Sinyallerinin İşlenmesi	17
1.5.1. Kalp sesi sinyalinin toplanması	17
1.5.2. PCG ön işleme	18
1.5.3. Sinyal işleme	19
1.5.3.1. Zarf tabanlı yöntemler	19
1.5.3.2. Ayırmaya dayalı yöntemler	21
1.5.3.3. Zaman- Frekans işleme yöntemleri	22
2. MATERYAL VE METOT	23
2.1. Veri seti	24
2.2. Ön İşleme	28
2.2.1. PCG sinyal işleme ve kesirli fourier tabanlı özellik çıkartımı.....	28
2.2.2. Ön vurgu	28
2.2.3. Çerçeveleme	28

2.2.4.	Pencereleme.....	29
2.2.5.	Kesirli Fourier dönüşümü.....	29
2.2.6.	Mel filtre bankası ve MFCC çıkarımı	36
2.3.	Sınıflandırma.....	36
2.3.1.	Yapay zeka	36
2.3.2.	Makine öğrenmesi	37
2.3.3.	Derin Öğrenme	39
2.3.3.1.	CNN	40
2.3.3.2.	RNN	44
2.3.4.	Aşırı uydurma ve yetersiz uydurma.....	45
2.3.5.	Aktivasyon fonksiyonları	46
2.3.6.	Kullanılan derin öğrenme modelleri.....	46
3.	BULGULAR ve TARTIŞMA	50
3.1.	Bulgular ve sınırlar.....	50
3.1.1.	Hold-out doğrulama.....	51
3.1.2.	CNN k-fold çapraz doğrulama sonuçları.....	58
3.2.	Sınıflandırıcıların karşılaştırılması ve öneriler.....	59
3.3.	Tartışma.....	59
4.	SONUÇ	61
	KAYNAKÇA.....	62
	ÖZGEÇMİŞ	75

ÖZET

Kalp hastalıkları, dünya genelinde önemli bir sağlık sorunudur ve yılda milyonlarca insanın ölümüne neden olmaktadır. Önümüzdeki yıllarda bu sayının daha da artması beklenmektedir. Bu nedenle, erken teşhis ve doğru tanı, hayati öneme sahiptir. Kalp sesi, kalp sağlığı hakkında değerli bilgiler içeren önemli bir işarettir. Normal kalp sesleri, kalp kapakçıklarının açılıp kapanması ile oluşur ve kalp döngüsü boyunca "lub-dub" şeklinde duyulur.

Üfürümler, kardiyovasküler sistemin düzensiz kan akışından kaynaklanan titreşimlerdir ve hastalığın tanısında önemli bir rol oynarlar. Bu seslerin değerlendirilmesi için stetoskop ve diğer cihazlar kullanılırken, yapay zekâ tekniklerinin de katkısı önemli hale gelmektedir. Son araştırmalar, fonokardiyogram sinyallerinin özniteliklerinin çıkarılması ve derin öğrenme yöntemleri olan RNN ve CNN ile sınıflandırılmasının yüksek doğruluk sağlayabileceğini göstermektedir.

Bu çalışmada kalp seslerinin Kesirli Fourier Dönüşümünün zaman-frekans özeliği kullanılarak MFCC ile özellikleri çıkartılmıştır. Seslerin işlenmesinde MFCC literatürde sıkça kullanılan ve başarılı olan yöntemdir. Sonrasında bir boyutlu CNN ve RNN modelleriyle sınıflandırılmıştır.

Kalp seslerinin sınıflandırılması, özellikle kırsal bölgelerde ekokardiyografiye erişimin sınırlı olduğu durumlarda kullanışlı olabilir ve doktorların kalp hastalıklarını teşhis etme sürecini kolaylaştırabilir. Standartlaştırılmış ve kolay ulaşılabilir otomatik oskültasyon cihazları, klinikte büyük bir fayda sağlayabilir ve kalp hastalıklarının erken teşhisine katkıda bulunabilir. Bu şekilde, gelecekte kalp hastalıklarının tedavisi ve yönetimi için daha etkili bir yaklaşım geliştirilebilir.

ABSTRACT

Heart diseases are a significant global health problem, leading to millions of deaths each year. It is expected that this number will further increase in the coming years. Therefore, early diagnosis and accurate assessment are of vital importance. The heart sound, known as the cardiac auscultation, is a valuable indicator of heart health. Normal heart sounds are produced by the opening and closing of heart valves and are heard as "lub-dub" throughout the cardiac cycle.

Murmurs, which are vibrations caused by irregular blood flow in the cardiovascular system, play an essential role in diagnosing heart conditions. While stethoscopes and other traditional devices are used to evaluate these sounds, artificial intelligence techniques have also become increasingly significant. Recent studies have shown that extracting features from phonocardiogram signals and classifying them using deep learning methods such as RNN and CNN can achieve high accuracy.

In this study, the time-frequency representation of heart sounds was extracted using the Fractional Fourier Transform, and Mel Frequency Cepstral Coefficients (MFCC) were used to extract features. MFCC is a widely used and successful method in the literature for processing audio signals. Subsequently, one-dimensional CNN and RNN models were employed for the classification task.

The classification of heart sounds can be particularly useful in areas with limited access to echocardiography, facilitating the diagnosis of heart diseases for healthcare professionals. Standardized and easily accessible automatic auscultation devices can provide significant benefits in clinical settings, contributing to early diagnosis of heart diseases. In this way, a more effective approach to the treatment and management of heart diseases can be developed in the future.

SEMBOLLER

x	: Sinyal
E_s	: Ortalama Shannon Enerjisi
E_n	: Normalleştirilmiş Shannon Enerjisi
$z(n)$	: Sinyal Zarf
$w(t, \omega)$	: Temel Yoğunluk Fonksiyonu
α	: Ön Vurgu Filtre Katsayısı
$w[n]$	: Pencereleme Fonksiyonu
α	: FrFT Dönüş Açısı
y	: Tahmin
w	: Ağırlık
b	: Bias
$x[i]$	: Giriş Verileri
K	: Çekirdek
h_t	: Gizli durum
U	: Önceki Gizli Katman Çıktı Ağırlıkları
σ_h	: Aktivasyon Fonksiyonu

KISALTMALAR

AR	: Aort Yetersizliđi
AS	: Aort Darlıđı
AUC	: Area Under The Curve
AV	: Arteriyovenöz
CWP	: Chris William Dađılımı
CNN	: Convolutional Neural Network
CRNN	: CNN ve RNN
DNN	: Deep Neural Network
FFT	: Fast Fourier Transform
FN	: False negative
FP	: False positive
FRFT, FrFT	: Fractional Fourier Transform
HCM	: Hipertrofik kardiyomiyopati
K-NN	: K-Nearest Neighbors Algorithm
LSTM	: Long Short-Term Memory
MFCC	: Mel-Frequency Cepstral Coefficients
MFSC	: Mel- Frequency Spectral Coefficients
MR	: Mitral Yetersizlik
MS	: Mitral Darlık
PCG	: Phonocardiogram
PDA	: Patent Duktus Arteriyozus
PR	: Pulmoner Yetersizlik
RNN	: Recurrent Neural Network

STFT	: Short-time Fourier Transform
SVM	: Support Vector Machine
TN	: True negative
TP	: True positive
TR	: Triküspit Yetersizliği
WT	: Wavelet Transform



ŞEKİL

Şekil 1 Kalbin yapısı [34].....	6
Şekil 2 Kardiyovasküler sistemin devrelerini gösteren şematik bir diyagram [41]	8
Şekil 3 Dolaşım [35]	9
Şekil 4 Kalbin sirküsü (A) Sistol (B) Diyastol [42]	10
Şekil 5 PCG, Fonokardiyogram Wigger's diyagramı [52]	11
Şekil 6 S3, A2 aort kapak kapanması, P2 pulmonik kapak kapanması, S1 birinci kalp sesi, S3 üçüncü kalp sesi [38].....	13
Şekil 7 S4, A2 aort kapağı kapanması, P2 pulmonik kapak kapanması, S1 birinci kalp sesi, S4 dördüncü kalp sesi [38]	13
Şekil 8 Oskültasyon Alanlarının Gösterimi [37]	14
Şekil 9 Üfürüm Diyagramları [51]	15
Şekil 10 Kalp Kapak Hastalığı [37]	16
Şekil 11 Kardiyak mikrofonun yapısı [58].....	18
Şekil 12 Normal, MR	25
Şekil 13 AS, MVP.....	26
Şekil 14 MS.....	26
Şekil 15 Spektrum Normal, MR, AS.....	27
Şekil 16 Spektrum MVP, MS.....	27
Şekil 17 Sinyal ön işleme şeması	28
Şekil 18 Kırmızı işaretliler, kesirli Fourier+ Biyomedikal sinyal işleme [82].....	30
Şekil 19 FrFT etki alanı u ile temsil edilir. u_a ve u_{a+1} yönü ϕ açısı ile verilen eksenler [82]	31
Şekil 20 Yapay Sinir Ağları Katmanları Gösterimi [118].....	36
Şekil 21 Gözetimli Öğrenme [123]	38

Şekil 22 Pekiştirmeli Öğrenme ve çevresiyle etkileşimi [126]	39
Şekil 23 CNN, evrişimli sinir ağı öğrenim süreci [129].....	40
Şekil 24 Çekirdeğin hareketi [129]	41
Şekil 25 2B evrişimde tek bir özellik değerinin hesaplanması [130].....	42
Şekil 26 Havuzlama katmanı (pooling layer) [140]	42
Şekil 27 RNN [144].....	44
Şekil 28 Uyum çeşitleri gösterimi [146]	45
Şekil 29 Karmaşıklık Matrisi	50
Şekil 30 Kayıp değerlerinin çizdirilmesi (Train ve Val. Seti CNN)	53
Şekil 31 Doğruluk değerlerinin çizdirilmesi (Train ve Val. Seti CNN).....	53
Şekil 32 Kayıp değerlerinin çizdirilmesi (Train ve Val. Seti İki yönlü RNN- model1) 55	
Şekil 33 Doğruluk değerlerinin çizdirilmesi (Train ve Val. Seti İki yönlü RNN- model1)	55
Şekil 34 Kayıp değerlerinin çizdirilmesi (Train ve Val. Seti İki yönlü RNN- model2) 57	
Şekil 35 Doğruluk değerlerinin çizdirilmesi (Train ve Val. Seti İki yönlü RNN- model2)	57

TABLO LİSTESİ

Tablo 1 Oskültasyon Alanlarına Göre Kalp Seslerinin Yoğunluğu [37].....	14
Tablo 2 Levine Üfürüm Derecelendirmesi [51].....	16
Tablo 3 Chirp penceresinin özellikleri hem zaman hem de frekans alanlarında çalışır [83].	33
Tablo 4 Biyomedikal sinyal işlemede kullanılan FRFT özeti [82].....	34
Tablo 5 Test seti Sınıflandırma raporu (CNN)	52
Tablo 6 Test seti sınıflandırma raporu (İki yönlü RNN- model1).....	54
Tablo 7 Test seti sınıflandırma raporu (İki yönlü RNN- model1).....	56
Tablo 8 Test seti CNN sınıflandırma raporu	58
Tablo 9 Yaseen ve Kwon veri setiyle yapılan çalışmalar [74]	59

1. GİRİŞ

1.1. Amaç ve Kapsam

Bu tezin amacı; Kardiyovasküler hastalıklara yönelik teşhis için Phonocardiogram (PCG) sinyallerinin işlenmesi ve derin öğrenme ile sınıflandırılarak, sonuçların değerlendirilmesidir. Kalp hastalıklarının teşhisi, kalp seslerinin işlenerek, sınıflandırılmasıyla otomatik teşhis algoritmaları oluşturulabilir düşüncesinden yola çıkılmıştır. Kardiyovasküler hastalıklar dünyadaki ölüm sebeplerinin birinci sırasında yer almaktadır. Kalp hastalıklarının ise en çok görüldüğü yerler kırsal kesimler olmaktadır. Kırsal alanlarda yaşayanlar, rahatsızlıklarının önlenmesi için sınırlı imkana sahip olduğu için bu gibi yerlerde, birincil teşhis olanağı olan kalp seslerinin stetoskop ile dinlenmesi ve yorumlanması olan kardiyak oskültasyona güvenilmek zorundadır. Bununla birlikte oskültasyon işlemi pratisyen doktorun yeteneğine ve bilgisine bağlı olmaktadır. Doktorlar tarafından stetoskop ile duyulan doktorlar duyulan kalp sesleri, kalp kapakçıklarının açılıp kapanmasıyla oluşan ses ten kaynaklanmaktadır. Normal bir kalp sesi S1 sesinden (atriyoventriküler kapağın kapanmasıyla üretilen), S2 sesinden (yarım ay kapakçığının kapanmasıyla üretilen), sistol (S1 ve S2 arasında değişen) ve diyastolden (aralıklı) oluşur. Anormal kalp sesleri durumunda, üfürümler genellikle sistolik veya diyastolik aralıkta meydana gelir. Bu koşullarda hastalıklardan sadece birini oskültasyon ile tespit çok zahmetli bir iştir. Aynı zamanda klasik yöntemle kalp sesini doğru almak da zordur. Bu sebeple kalp sesinin dış seslerden filtrelenerek pürüzsüz ses ulaşmak ve kalp sesini kaydetmek son derece önemlidir. Wireless ve bluetooth stetoskop kullanılmaya başlanmıştır ancak wireless stetoskop ve bluetooth stetoskop oldukça maliyetlidir. Olası kalp hastalıklarının tanısı; normal ve anormal kalp seslerinin otomatik olarak alınarak kaydedilmesi için akıllı stetoskop ve güvenilir sınıflandırmasını gerçekleştiren bir sistemin geliştirilmesi arzu edilmektedir [1], [2].

Bu tez ile, normal ve anormal PCG sinyallerinin otomatik olarak sınıflandırmasına izin veren algoritma önerilmesi; elde edilecek araştırmaları ve yapılan çalışmaların sonuçlarını uluslararası dergilerde makaleler olarak yayınlamak, ulusal ve uluslararası konferansın, sempozyum ve seminerler sunmak, bu yolla literatüre katkıda bulunmak hedeflenmektedir.

Teoriler ve Modeller; Kalp sesleri durağan sesler olmayıp akustik sesler olarak tanımlanmıştır. Son zamanlar da akustik seslerin sınıflandırılması için araştırmalar literatürde incelenmiş, yarışmalardaki başarısı sebebiyle akustik ses bölütlenmesinde Mel-Frequency Cepstral Coefficients (MFCC) kullanılmasının daha doğru bir sonuca ulaştırılacağı varsayılmıştır. Derin öğrenme yöntemlerinin sınıflandırmadaki başarısı geleneksel makine öğrenme yöntemlerine göre büyüktür. Derin öğrenme yöntemleri katmanları sayesinde ve öznetelik çıkarımı sayesinde sistemin yükünü hafifletir ve öznetelik çıkarımındaki ek iş yükünü azaltır. Otomatik kalp sesi sınıflandırma teknolojisi, tarama sürecini desteklemek ve maliyetleri düşürmek için yüksek potansiyele sahiptir.

1.2. Literatür Taraması

Literatüre baktığımız zaman oldukça çalışmanın yapıldığı görülmüştür. Bu çalışmalar; Vepa J. ve ark. Short-time Fourier Transform (STFT) ve dalgacık dönüşümünü kullanarak özellik çıkartmış ve Support Vector Machine (SVM), K-Nearest Neighbors Algorithm (K-NN) ve Multi Layer Perceptron (MLP) kullandı [3]. SVM sınıflandırıcı ile %95'lik doğrulukla normal, sistolik diyastolik olarak ayırmıştır. Kalp seslerinin sınıflandırılmasında Potes C. ve ark. MFCC ile öznetelik çıkarımından sonra AdaBoost isimli bir model ve evrişimli sinir ağları ile eğitim yaptıktan sonra en son hangi sınıflandırıcı çıkışının kullanılacağını belirten karar verici bir algoritma kullanmıştır [4]. Rubin ve ark. 1-boyutlu PCG sinyalini MFCC kullanarak 2-D zaman-frekans ısı haritası gösterimlerine dönüştüren bir algoritma önerdi [5]. Normal ve anormal kalp sesi kayıtlarını otomatik olarak sınıflandırmak için evrişimli sinir ağı kullanıldı. PhysioNet / Computing in Cardiology Challenge 2016, kalp seslerini sınıflandırmak için geleneksel mimariler ve derin öğrenmeyle çeşitli algoritmaları geliştirmek, test etmek ve karşılaştırmak için bir veri seti sundu. Nivitha V. ve ark. Pascal veri tabanlarını kullanarak deneysel dalgacık dönüşümü tabanlı PCG sinyal ayrıştırması, Shannon entropi zarfı çıkarma, anlık faz bazlı sınır belirleme, kalp sesi ve üfürüm parametresi çıkarımı yöntemlerini uygulamıştır [6]. Bozkurt ve ark. çocuk kalp hastalıklarının tespiti için spektrogram, MFCC, Mel Spektrogram yöntemlerini bölümlemede kullanmıştır ve Convolutional Neural Network (CNN) ile anormal kalp seslerini sınıflandırmıştır [7]. Abduh Z. ve ark. Kesirli Fourier dönüşümü tabanına dayalı Mel- Frequency Spectral Coefficients (MFSC) kullanarak kalp seslerini sınıflandırdı [8]. Bölütleme yaparken sistolik ve diyastolik olarak ayırdı. Kardiyak

döngülere göre bölmek için Springer'in geliştirilmiş segmentasyon algoritması kullanılmıştır. K-NN, SVM gibi geleneksel sınıflandırıcıları kullanmıştır. Değerlendirmesi için 5 katlı çapraz doğrulama kullanmıştır. PhysioNet / Computing in Cardiology Challenge 2016 veri tabanını kullanan deneysel doğrulamanın sonuçları, sunulan yaklaşımın ve birkaç varyantının, kübik çekirdekli bir destek vektör makinesi sınıflandırıcısı kullanılarak elde edilen en iyi sonuçlarda 0,92'ye ulaşan bir değerlendirme puanıyla iyi performans gösterdiğini göstermektedir. Ferdoushi M. ve ark. kısa süreli fourier dönüşümünü MFCC tabanlı olarak kullandılar [9]. 124 normal ve anormal ses kaydı üzerinden destek vektör makineleri ile sınıflandırmalarını sağladılar. Test seti üfürüm seslerine ve diğer tüm sesleri içeren bir sete bölündüğünde genel olarak 0,88 doğruluk elde edilmiştir. Deng M. ve ark. MFCC özelliklerine ve evrişimli tekrarlayan sinir ağlarına dayanan yeni bir kalp sesi sınıflandırma yöntemi önerdi. Mel-frekans cepstrumlarını kalp sesi sinyalinin bölmeden hesapladılar. MFCC tabanlı özellikleri, özellik öğrenimi ve daha sonra sınıflandırma görevi için CNN ve RNN (CRNN) kullandılar [10]. Raza vd. Long Short-Term Memory(LSTM) modeline dayalı kalp sesi sınıflandırması için bir çerçeve sundu. Yazarlar, otomatik kalp atışı sınıflandırması için bir çözüm önermek için veri seti-B'yi kullandılar. Ön işleme adımında, mükemmel örnekler elde etmek ve azaltılmış alan özellikleri elde etmek için gürültüyü ve aşağı örneklemeyi iptal etmek için bant filtreleri kullandılar. Modellerini yalnızca modellerini klinik olmayan kullanım için yetersiz kılan EKG ile değerlendirdiler [11]. Sundaram D.S.B. ve ark. PCG sinyallerinin üzerinde 4. dereceden Butterworth alçak geçiren filtresi, yüksek frekanslı gürültüyü gidermek için 200 Hz' de kesme frekansı ile uyguladılar ve özel MATLAB yazılımı kullanılarak filtrelenmiş veri kümesi üzerinde MSF tahmini yapmışlardır. Bu yaklaşımda diğer birçok sınıflandırmadan farklı bir yol izlenmiştir, S1 veya S2'yi kullanmamış, bunun yerine normal veya patoloji gibi kalp durumuna bağlı olarak değişen toplam anlık frekans içeriğinin profilini çıkarmıştır [12]. Banerjee M. ve ark. 2D evrişimli ağ kullanarak artefakt, ekstra kalp sesi, ekstra sistol, üfürüm ve normal gibi beş belirlenmiş kalp sesi kategorisinin bir sınıflandırmasını EKG ve PCG kullanarak yaptı. MFCC özelliklerini kaydedilmiş ses dosyalarından çıkartıp önerilen modelde girdi olarak kullanarak sınıflandırma işlemini yaptılar [13]. Xiao B. ve ark. Kardiyovasküler hastalık tahmini için derin öğrenme teknolojilerine dayanan ve esas olarak üç bölümden oluşan yeni bir kalp sesi sınıflandırma yöntemi geliştirmiştir; ön işleme, dikkat mekanizmasına sahip derin bir CNN kullanılarak 1-B dalga biçimi kalp ses

yamaları sınıflandırması ve kalp ses kayıtlarının nihai tahmini için çoğunluk oylaması. CNN'lerin bilgi akışını geliştirmek için, klik bloklu bloklarla yığılmış bir stil mimarisi kullandılar ve her blokta önerilen CNN'de çift yönlü bir bağlantı yapısı tanıttılar [14]. Feng T. ve ark. Deep Neural Network (DNN) aracılığıyla ve kalp seslerini kullanarak Sol Ventriküller Hemodinamik Parametreleri tahmin etmeye çalışmışlardır. Kalp sesleri ve PCG sinyalleri ile kan basıncı arasında bağlantı olduğu 1960'larda Shah ve ark. İspatlamıştır. Bu çalışmada, dört sol ventrikül hemodinamik parametresini, sol ventrikül sistolik basıncını (LVSP), sol ventrikül diyastolik sistemini belirlemek için girdileri bir kardiyak döngünün HS ve PPG sinyallerinin segmentleri olan uçtan uca bir derin sinir ağı oluşturulmuştur [15]. Samiul Based S. ve ark. CNN ve RNN'in birleşimi olan CRNN ağı ile kalp hastalıklarını sınıflandırmayı teşhis etmeyi önermiştir. CRNN ağı CardioXNET çerçevesini kullanmışlardır. Yapılan bu çalışmada en büyük farklılık, manuel özellik çıkarma veya segmentasyon, büyütme veya kopyalama gibi ön işleme adımları içermeyen hafif bir CRNN ağı kullanarak PCG sinyallerinden kapak kalp hastalığının otomatik uçtan uca sınıflandırılmasıdır [16]. Babu K.A ve ark. eş zamanlı PCG ve PPG kayıtlarını kullanarak S1 ve S2 seslerini otomatik tanımlamışlardır. Bunu için Arduino arayüz tanıma ile topladıkları kayıtların yanı sıra ek olarak 2 çeşit veri tabanından faydalanmışlardır [17]. Anumukonda M. ve ark. algoritma, kalp sesi bileşenlerini dalgacık ayrıştırması ve Shannon enerjisini kullanarak sınıflandırarak önerdikleri algoritma ile 1756 sonuç alınarak test edilen anormal ve normal kalp seslerini içeren PhonoCardioGraphy deneysel sonuçlar, %99,17'lik iyi bir duyarlılık ve %1,5'lik algılama hatası oranı ortaya koydu. Kalp seslerini kaydetmek için Mikro Elektro Mekanik Sistemle (MEMS) mikrofonlarını kullanan sistemin kayıtlarını kullanarak sınıflandırma yaptılar [18]. Blanco A. ve ark. ECG ve PCG'den alınan sesleri yükselterek oskültasyon ile kalp rahatsızlıklarının teşhisine yönelik çalışma yapmışlardır [19]. Ren H. vd. nesnelerin interneti ile oskültasyon sonucunu akıllı telefona ileten bir bluetooth IOT cihazı ile gönderilen sesleri bluetooth yöntemi ile sınıflandırma yapılmıştır [20]. Mondal H. ve ark. Sınırlı kaynakların bulunduğu yerlerde PCG cihazı ve elektronik steteskopu edinmenin zorluğuna karşılık elde bulunan kısıtlı imkanlarla bluetooth cihazın nasıl yapıldığını göstermişlerdir [21]. Lee S. ve arkadaşları ECG ve PCG sinyallerini alabilen bir devre tasarımı yaparak akıllı steteskop yapmışlardır [22]. Lai S. ve arkadaşları kablosuz bir EKG sinyallerini toplayan bir sistem tasarlamışlardır [23]. Talab E. vd. dijital olarak steteskop ölçümü veya cep telefonu mikrofondan elde

ettiği kalp seslerini anormal veya normal sesler olarak tespit etmek için mobil uygulama geliştirmişlerdir [24]. Astudillo C. ve arkadaşları 3 boyutlu yazıcıdan elde ettikleri dongle içine elektret mikrofon yerleştirerek ucuz maliyetli stetoskop yapmışlardır [25]. Rajjilwal N. ve arkadaşları halka açık NHANES süper veri kümesinde dengesiz veri setlerine karşılık dirençli yığılmış-yoğun-CNN mimarisiyle sınıflandırmalarını yaparak %81.8 doğruluk payı elde etmişlerdir [26]. Wang P. ve arkadaşları giyilebilir EKG monitörü ile elde ettikleri kalp verilerine CNN ve LSTM uygulamışlardır ancak istenilen verim elde edilemediği için yarı denetimli yöntemi kullanarak %90.2 doğruluk payı ile sonuca ulaşmışlardır [27]. Shuvo S. ve arkadaşları GitHub PCG ve PhysioNet/CinC 2016 birleştirilmiş veri seti üzerinde beş kalp sesi sınıfını sınıflandırılmasını hedefleyerek CardioXnet'i temsili öğrenme ve sıralı kalıcı öğrenme yöntemleriyle kullanarak %88.09' lük bir doğruluk elde etmişlerdir [16]. Harjai S. ve arkadaşları Cleveland Clinic Foundation Heart Disease Datasetini kullanarak korelasyon tabanlı öznelik seçimi ile MLP kullanarak kalp hastalıklarını sınıflandırarak %89.2 kesinliğe ulaşmışlardır [28]. Ranipa K. ve arkadaşları tek etki alanındaki özellikler yerine farklı özellik çıkartma yöntemlerine dayalı olarak eğittikleri CNN mimarini kullanarak kalp seslerini sınıflandırmışlar ve %98,5 lik bir başarı elde etmişlerdir [29]. Li Z. ve arkadaşları MFCC ve Log Mel spektrumu özelliklerini girdi olarak alan iki ağırlıklı kayıp işlevini sınıf dengesizliğini azaltmak için önermiş , sınıflandırmada CNN mimarisini kullanarak %85 in üzerinde başarı elde etmişlerdir [30]. Mehrabbeik ve ark. mitral kalp kapakçığının sarkma hastalığının teşhisi için sinyali gürültüye tabi tutmuş daha sonrasında sinyali bölütlemişlerdir. Daha sonrasında Kesirli Fourier Dönüşümünü (FRFT) kullanarak özellik çıkartmış, çıkarılan özellikleri logaritmik medyan penceresi ile pencerelemişler , sınıflandırmayı ise KNN ve SVM ile yapmışlardır. Bu yöntemle %90' ın üzerinde doğruluk, duyarlılık, özgünlük elde etmişlerdir [31]. Anumukonda ve ark. MEMS mikrofonları kullanarak kalp seslerini kaydetmiş, dalgacık ayırıştırma yöntemi kullanarak özellik çıkartmışlardır ve Field Programmable Gate Array (FPGA) üzerinde geleneksel nöron modellerini uygulamışlardır. Bu yöntemle elde ettikleri başarı Area Under The Curve(AUC) değerlerine göre sırasıyla %99.3, %98.6, %98.7 ve %98.6' dır.


1.3. Problemin Tanımı

Dünya Sağlık Örgütü 2000-2016 yılları arasında ölüm sebeplerinin başında %31 oranla Kardiyovasküler hastalıkların geldiğini açıklamıştır [32]. Tahmini kardiyak hasta sayısı ve sağlık bakımı maliyetleri çok yüksek olsa da dikkate alınması gereken önemli bir nokta, çoğu Kardiyovasküler hastalığın önlenabilir ve tedavi edilebilir olmasıdır. Ancak, bu erken aşamada tanı ve uygun hastalık yönetimi gerektirir. Kardiyak fonksiyonla ilgili fizyolojik parametreleri zamanında ve uygun maliyetli bir şekilde yoğun bir şekilde izlemek ve analiz etmek için teknolojilerin geliştirilmesine acil ihtiyaç vardır [33]. Bu sebeple erken tanı amaçlı kalp sesi sinyallerini analiz ederek derin öğrenme ile sınıflandırılma araştırma konusudur.

1.4. Genel Bilgiler

1.4.1. Kalbin yapısı ve genel bilgiler

“Kalp, iki akciğer arasında göğüs boşluğunun ön bölümünde (bu bölüme ön mediastin)denir. Diyaframın üstünde ve göğüs kemiğinin arkasında yer alır. Kalbin yaklaşık 1/3 ü beden orta çizgisinin sağında, yaklaşık 2/3’ü de solundadır. Kalp, iki işlevi olan kaslı bir pompadır: Vücudun dokularından kan toplayıp akciğerlere pompalamak, akciğerlerden kan toplamak ve vücudun tüm dokularına pompalamak onun görevleridir” [35].



Şekil 1 Kalbin yapısı [34]


Kalp ve kan damarları kardiyovasküler sistem adı verilen kan taşıma ağını oluşturmaktadır [35]. Kalbin görevi, tüm vücudun ihtiyacı olan kanı iletmektir. Elektriksel kasılma ve yapısal işlevlerle bu görevlerini yerine getirir. Dört odadan oluşan kalbin yapısı şekil 1'deki gibidir. Kalbin ortasından daha yukarıda olan odacıklar, atrium(kulakçık) olarak adlandırılırken; aşağıda olan odacıklar ise ventrikül(karıncık) olarak adlandırılmıştır. Atriyum; kalbin depolama yeri, boş odacığı olarak ifade edilirken ventrikül ise kanı pompaladığı için kaslardan meydana gelir ve atriyumla kıyasla daha güçlü odacıklardır. Kalbin kan akışı, valflerle tek yönlü gerçekleşmektedir [36]. Sağ atriyum ve sağ ventrikül kirli kanı bulundururken, sol atriyum ve sol ventrikül akciğer tarafından temiz kanı bulundurur [37].

Kalpte iki grup valfler bulunmaktadır: Atriyoventriküler valfler ve semilunar (yarıma ay kapakçığı) valfler. Kalbin her iki tarafında bulunan Atriyoventriküler-AV valfler (sağ triküspit ve sol biküspit- mitral) atriyumdan ventrikülle tek yönlü kan akışı sağlar. Triküspit kapak, sağ taraftaki atriyum ve ventrikülü birbirinden ayırır. Mitral kapak, sol taraftaki atriyum ve ventrikülü ayırır. Sol ventrikül ile aort arasında aort kapakçığı bulunmaktadır. Sağ ventrikül ile pulmoner arter arasında ise pulmoner kapakçık bulunmaktadır. Bu iki kapakçık yarımaya benzediği için yarım ay kapakçıkları ismi verilmiştir(semilunar) [38].


Kalbin çalışması; odacıkların kasılması sistol ve odacıkların gevşemesi diyastol olmak üzere 2 fazdan oluşmaktadır [39]. Sistol sırasında; ventriküller büzülür, kanı sol ventrikülden aort içine ve aynı anda sağ ventrikülden pulmoner artere atar [37]. Diyastol sırasında atriyumlar büzülerek içerisindeki kanı genişleyen ventriküllere kanı aktarır [37]. Atriyumların kasılması ventrikülün gevşemesinin sonuna doğru olur. Ancak atriyumun gevşemesi ve ventrikülün kasılması neredeyse aynı anda olur [40]. Ventriküllerin kasılması(sistol), yarım ay kapakçıklarının(semilunar) açılmasını sağlayarak kanın pulmoner arter ve aorta akmasına neden olur. Ventriküller gevşediğinde(diyastol) valfler kapanır ve ventriküllere geri akışı durdurur [38].

Kalbin mekanik devresi şu şekildedir: En büyük toplardamar olan vena cavadan gelen kirli kan sağ atriyumla dolar. Sağ atriyumun basıncı sağ ventrikül basıncından fazla olunca, aralarında bulunan tek yönlü triküspit kapak açılarak kirli kanın sağ ventriküle geçmesine izin verir [41]. Ancak geçen kısım %75 kadardır. Kalan kanın boşaltılması için

atriyum kasılır, bu kasılmaya atriyal kasılma adı verilir [42], [43], [44], [45], [46]. Sağ ventrikül, gelen kirli kan birikip belli miktara ulaşınca akciğerlere pompalayabilmek için kasılmaya başlar, buna da izometrik kasılma adı verilir. Pulmoner kapağın da açılmasıyla akciğerlere kirli kanı pompalar. Akciğerlerin içerisindeki alveollere, nefes yoluyla gelen oksijen dolar. Oksijen az olan kısımdan çok olan kısma doğru geçiş yapar, böylelikle temizlenmiş kan, akciğer toplardamarının aracılığıyla sol atriyuma geçer, yeterli miktarda kan ile dolunca mitral kapak açılarak temiz kanın sol ventriküle geçmesine izin verir [44]. Sol ventrikül aort kapağının açılmasıyla önce en büyük atardamar olan aort damarına daha sonra da bütün hücrelere kanı pompalar. Bütün vücuda kanın pompalanması, sol ventrikülün yapısının diğerlerinden daha güçlü ve kaslı olmasını gerektirir [47], [44], [45], [46], [41] (şekil-3).




Şekil 2 Kardiyovasküler sistemin devrelerini gösteren şematik bir diyagram [41]



Şekil 3 Dolaşım [35]

Dolaşım A, Pulmoner ve sistemik dolaşıma hizmet eden iki kas pompasının (sağ ve sol kalp) anatomik düzeninin şematik gösterimidir. B, Vücudun dolaşımının şematik gösterimi, sağ ve sol kalp, seri halinde iki pompa olarak tasvir edilmiştir. Pulmoner ve sistemik dolaşımlar aslında bir sürekli döngünün seri bileşenleridir. C, sistemik dolaşım aslında vücudun çeşitli organlarına ve bölgelerine hizmet eden birçok paralel devreden oluşur [35].




Şekil 4 Kalbin sirküsü (A) Sistol (B) Diyastol [42]

1.4.2. Kalp sesleri

1.4.2.1. Normal kalp sesleri

Kalp sesleri, kalp kapakçıklarının hareketi ve kalpteki kan akışı ile ortaya çıkan biyolojik akustik sinyallerdir [48]. Bir kalp sesinin yoğunluğu, hareket halindeki kan sütunun hareketine göre değişmektedir [49]. Normal sesler valflerin kapanmasıyla oluşur. Valflerin açılmasıyla seslerin oluşması ise patolojik bir bulgudur [50]. Kalp sesleri S1, S2, S3 ve S4 olarak adlandırılan seslerden oluşmaktadır. S1-S2 en belirgin kalp sesleridir [38]. Ancak S3 ve S4 sesleri bazen duyulamaz, bu seslerin duyulmaması doğrudan patolojik bir bulgu değildir [42]. Kalbin kasılması esnasında kapakçıkların hareketiyle oluşan bu sesler, sağlıklı bir kalbin veya hastalıklı bir kalbin göstergesi olmaktadır. Bu seslere ilaveten kalp hastalıklarının belirtisi olan sistolik, diyastolik ve sürekli üfürümler kalpte meydana gelen seslerdendir [41], [51]. Kalp kasının gevşemesi(diyastol) sonunda atriyum(kalp kulakçığı) kasılır ve ventriküllerin fazladan kasılmasını sağlar, ventriküller (karıncık) basıncı, atriyum (kulakçık) basıncını aştığında, mitral triküspit kapakçıklar birbirine yakınlışır ve kapanır. Ventrikül basıncı artmaya devam ettiğinde aort ve pulmoner arter basıncını aştığında semilunar kapakçıklar açılır ve ejeksiyon (fırlatma) fazı başlar. İlk olarak elektriksel uyarıyla sinüste kasılmayla başlayan kalp hareketi de ventriküller kasılmayla devam eder ve mitral kapağın kapanmasıyla kasılması biter [41], [49].



Şekil 5 PCG, Fonokardiyogram Wigger's diyagramı [52]

Kalbin sağ tarafı ile sol tarafındaki basınç aynı değildir; sağ ventrikül, sağ atriyum ve pulmoner arterin basıncı sol taraftan daha düşüktür. Bu sebeple sol tarafın döngüsü daha önce gerçekleşmektedir [38]. Valflerin farklı zamanda kapanması ise bölünmüş bir kalp sesinin ortaya çıkmasını sağlar [38].

Kalp sesleri çoğunca kısadır. Kalp seslerini birbirinden ayıran özellikleri; yoğunluklarının değişmesi (sesin yüksekliğini), frekansları (perde) ve nitelikleridir (tını) [53], [54]. Normal kalp seslerinin frekansları genellikle düşüktür [42].

S1-Birincil kalp sesi


S1, ventriküller kasılmanın başlangıcında meydana gelir ve lub sesi ile tasvir edilir. S2 sesinden daha yoğundur [49], [42]. S1, mitral bileşen (M1) den kısa bir süre sonra triküspit bileşenin (T1) kapanmasıyla ortaya çıkmaktadır [38]. S1 sesinin ortaya çıkmasını sağlayan bileşenler;atriyal, mitral, triküspit ve aort [49]. S1 sesinin en önemli ve sesinin yoğunluğunu belirleyen bileşeni ise M1'dir [49]. Mitral kapak ile triküspit kapağın kapanmasıyla S1 sesi meydana gelir [44]. Mitral ve triküspit kapakların kapanması arasında kısa zaman farkına rağmen S1 tek ses olarak duyulmaktadır [37]. S1'in M1 bileşeni en iyi kalbin en alt uç kısmında duyulmaktadır [38]. S1'in en önemli özelliği yoğunluğudur [55].

S2-İkincil kalp sesi

S2 en iyi tabanda duyulur [55].Semilunar kapakçıklar olan aort ve pulmoner kapakların kapanmasının sonucunda sistolün sonu olan S2 meydana gelir ve dub sesi ile tasvir edilir [44], [55]. Aort ve pulmoner arterlerde diastolik basınç arttığında S2 sesi artar [49]. Bu nedenle S2 sesinin aort bileşeni (A2) ve pulmoner bileşeni (P2) olmak üzere 2 bileşeni vardır [38]. S1-S2 süresince kasılma(sistol), S2-S1 arasında ise gevşeme(diastol) olmaktadır. Sistolden genellikle daha uzun süren diastol evresi; kalp hızlandığında daha kısa sürebilmektedir [38]. S2 sesinin en iyi dinlendiği alan aortik ve pulmonik alanlardır [38].

S3- Üçüncü kalp sesi


Ventrikül basıncı atriyal basıncın altına düştüğünde mitral ve triküspit kapaklar A2'den kısa bir süre sonra atriyumlardan ventriküllere kan dolmasını sağlar [42]. Aort kapağının kapanmasından sonra düşük perdeli S3 titreşimi gelir. Ventrikülün bu dolumu 3 fazda incelenir; erken-hızlı doldurma fazı, yavaş doldurma fazı ve atriyal kasılma fazı [49]. S3 sesi erken-hızlı dolum evresinde duyulabilir [49]. 30 yaşına kadar S3 duyulabilirken, 30 yaşından sonra bu tını ventriküller dörtına olarak adlandırılır ve genellikle patolojik olarak değerlendirilebilir [38]. S3 sesi en iyi tepede duyulmaktadır [55].



Şekil 6 S3, A2 aort kapak kapanması, P2 pulmonik kapak kapanması, S1 birinci kalp sesi, S3 üçüncü kalp sesi [38]

S4- Dördüncü kalp sesi


S4 yumuşak ve düşük perdeli bir sestir, S1 in öncesinde duyulabilir [38]. Bebek, küçük çocuk, 50 yaş ve üstünde S4 kalp sesi duyulur. Diğer yaşlarda S4 duyulduğunda genellikle patolojik olduğu düşünülür [38]. S4 kalp sesi en iyi tepede duyulmaktadır [55]. S4, S3'ten daha yüksek perdeli ve daha gürültülüdür [37], [55].



Şekil 7 S4, A2 aort kapağı kapanması, P2 pulmonik kapak kapanması, S1 birinci kalp sesi, S4 dördüncü kalp sesi [38]

Oskültasyon Alanları

Kalp seslerini en iyi şekilde duyabilmek için seslere neden olan kapakçıkların bulunduğu yerden dinlemek gerekir [50]. Bu kısımlara oskültasyon alanları denilmektedir. Oskültasyon alanlarına göre kayıt yapılamadığında veri tabanından kaynaklı sınıflandırmada hatalar çıkabilmektedir [38], [50].



Şekil 8 Oskültasyon Alanlarının Gösterimi [37]


Tablo 1 Oskültasyon Alanlarına Göre Kalp Seslerinin Yoğunluğu [37]

	Aort	Pulmonik	İkinci Pulmonik	Mitral	Triküspit
Perde	$S_1 < S_2$	$S_1 < S_2$	$S_1 < S_2$	$S_1 > S_2$	$S_1 = S_2$
Ses	$S_1 < S_2$	$S_1 < S_2$	$S_2 < S_2$ a	$S_1 > S_2$ b	$S_1 > S_2$
Süre	$S_1 > S_2$	$S_1 > S_2$	$S_1 > S_2$	$S_1 > S_2$	$S_1 > S_2$
S2 Ay- rılması		Tüm oskültasyon alanlarında inhalasyonla artan S2 bölünmesi, P2 duyulamıyorsa mitral alanda duyulmayabilir.			
		Tüm oskültasyon alanlarında eskalasyon ile azalır.			
A ₂	En gürültülü	Yüksek ses	Azalmış ses		
P ₂	Azalmış ses	Daha gürültülü	En gürültülü		

- a, S1 ikinci pulmonik bölgede aort bölgesine göre nispeten daha yüksektir.
- b, S1 mitral bölgede triküspit bölgeye göre daha yüksek olabilir.

1.4.2.2. Anormal kalp sesleri

Kalbin içerisindeki kan akışı pürüzsüzdür, bu sebeple kan akışında titreşim olmamaktadır [38], [56]. Bu sebeple kalbin içindeki türbülanslı akış üfürüm denilen anormal titreşimlere ve seslere sebep olmaktadır [38]. Anormal kalp sesleri, ekstra kalp sesleri ve üfürümler olarak iki çeşittir [37], [55]. S1 ve S2 sesinin normal kalp sesinden, fazla olması veya azalması patolojik olarak değerlendirilmektedir. Kalbin kan akışı laminar iken, anormal kalpteki kan akışı ise türbülanslı olmaktadır. Türbülanslı akışın sonucu oluşan titreşimli akım üfürümlerin duyulmasına yol açar. Üfürümlerin geneli, 20-600 Hz frekans aralığındadır [33].



Şekil 9 Üfürüm Diyagramları [51]


Üfürümler sistolde diyastol esnasında duyulan uzun süreli seslerdir. Üfürümler; zamanına (sistolik üfürümler, diyastolik üfürümler, sürekli üfürümler), şekline (crescendo, decrescendo veya crescendo-decrescendo) ve kardiyak döngüdeki yerine (erken, orta, geç veya sürekli) göre sınıflandırılır [57], [33]. Sistolik ve diyastolik üfürümler ise erken, orta, geç ve holistik olarak sınıflandırılır. Sürekli üfürümler ise S2'nin ötesine geçen diyastole kadar uzanan sistolik üfürümlerdir [50]. Tüm sürekli üfürümler, diyastolik üfürümler ve geç üfürümler patolojiktir [51]. Anormal kalp seslerinin önemli bir kısmı kalp kapakçıklarındaki rahatsızlıktır [58]. Sistolik üfürümlere mitral yetersizlik (MR), aort darlığı(AS), triküspit yetersizliği(TR), hipertrofik kardiyomiopati (HCM), VSD; Diyastolik üfürümlere; aort yetersizliği (AR), pulmoner yetersizlik(PR), mitral darlığı(MS) ve triküspit darlığı (TS); Sürekli üfürümlere patent duktus arteriyozus (PDA), koroner arteriyovenöz (AV) fistül, rüptüre sinüs Valsalva anevrizması neden olabilir [37], [51], [55].

Üfürümün şiddeti Levine tarafından yapılan sistem ile tanımlanmaktadır [51]. Ancak her üfürüm patolojik olarak ele alınamaz [51]. Şekil-9 'da görüleceği üzere masum üfürümler bulunmaktadır; çocuklarda, ergenlerde ve sporcularda bir sebep olmaksızın da görülebilmektedir [37].

Tablo 2 Levine Üfürüm Derecelendirmesi [51]

Seviye	Bulgular
1/6	Sadece aralıklı ve yumuşak bir üfürüm ve çaba sağlayarak oluşturulan bir üfürüm
2/6	Yumuşak ama her vuruşta duyulabilen bir üfürüm.
3/6	Kolayca duyulabilen ve yüksek bir üfürüm
4/6	Her zaman patolojik, yüksek ve hissedilebilir bir üfürüm
5/6	Steteskopun ucunun yerleştirilmesiyle bile duyulabilen bir üfürüm
6/6	Steteskop ile temas haline olmasa bile duyulabilecek yüksek bir üfürüm.

Üfürümlerin en yaygın sebepleri kalp kapakçıklarının yapısal bozukluklarıdır [37].



Şekil 10 Kalp Kapak Hastalığı [37]

1.5. Kalp Sesi Sinyallerinin İşlenmesi

Sinyaller birçok değişkenden oluşan fonksiyonlardır. Sinyal işleme; sınıflandırmak için sinyalin üzerindeki faydalı bilgilerin çıkarılması anlamına gelir [58]. Kalp seslerinin analizi gruplandırılması özelliklerine göre farklılaşabilir. Bu tez de incelenen kısım gruplandırma segmentasyon yöntemlerinin temelde esas aldıkları fonksiyon çeşitleridir. Kalp sesi sinyallerinin işlenmesi üç başlık altında ele alınır; Sinyal verisi toplama, sinyal ön işleme ve sinyal analizi [48], [58].


1.5.1. Kalp sesi sinyalinin toplanması

Kalp sesleri, elektronik stetoskoplar veya fonokardiyografi cihazıyla kaydedilmektedir.

Kardiyak mikrofon çeşitleri:

- Metalize bir filmin indüklenen titreşimiyle bu film ile plaka arasındaki kapasitansı değiştirdiği ve sabit şarj koşulları altında kapasitör voltajında bir değişikliğe sebep olduğu kapasitör mikrofonlar.
- Kristal- piezoelektrik mikrofonlar; piezokristali titreştirerek voltajı sağlayan mikrofonlar,
- Elektret mikrofonlar, bir plakanın üzerinde kalıcı bir elektrostatik yük bulunduğu, hareketli plakanın ise kapasitansı değiştirip yükseltilecek bir voltajı indüklediği değişken kapasitör sensörler [58].

Kardiyak sesler için kullanılan stetoskop içindeki mikrofon yapısı dört bileşenden oluşmaktadır: harici kristal(piezoelektrik), zemin kafesi, salınımlı tambur, uyarma kaynağı.



Şekil 11 Kardiyak mikrofonun yapısı [58]

1.5.2. PCG ön işleme

PCG, ön işlemeden geçirilerek gürültüsü azaltılmalıdır. Erken aşamalarda düşük genliğe sahip üfürümler gürültüde hissedilemeyebilir [59]. PCG sinyalleri düşük frekanslı 20-1000 Hz arasındaki sinyallerdendir [58], [60]. PCG sinyallerinde gürültü önleme için literatürde farklı yöntemler kullanılmıştır; en küçük ortalama kareler yöntemi ile uyarlamalı filtre, ayrıştırma yöntemi temelinde dalgacık dönüşümü ve ampirik mod ayrıştırması, butterworth filtreleme, Normalleştirme, Morlet dalgacık kullanarak sürekli dalgacık dönüşümü, normalizasyon ile birlikte medyan ve alçak geçiren filtreleme(butterworth), ampirik mod ayrışımı ,karşılıklı wavelet paket kriteri [61].

PCG sinyallerinin sınıflandırılması ve bölütlenmesi için sinyali frekans bileşenlerine ayırmak ve frekansa gelen genliklerini belirleme, sinyalleri işlemek gerekmektedir [59]. Genel olarak segmentasyon kalp seslerini döngülere ayırmaktır. Segmentasyon ve sinyal işleme yöntemlerini dört çeşit altında toplamak mümkündür; zarf tabanlı yöntemler, ayrıştırma yöntemleri, zaman-frekans yöntemleri, makine öğrenimi tabanlı yöntemler [33], [59], [62].

1.5.3. Sinyal işleme

1.5.3.1. Zarf tabanlı yöntemler

Sinyalin zarfı, sinyalin uç noktalarını gösteren eğriden oluşur [62]. Zarf tabanlı bölütleme algoritmalarının çoğu, kalp seslerini diyastolik aralığın sistolik aralıktan daha uzun olduğunu varsayarak gerçekleştirir [33]. Ancak ek sesler üst üste binmiş olduğunda bu yöntem başarısız olur. Orta genlikli sesler zayıflatılırken, büyük ve düşük pikler tek zarf olarak görünebilir, bu da düşük genlikli sesleri sınıflandırmada başarısız olabilir. Bu metodoloji de PCG sinyaline S dönüşümünü uygulanarak kaplanan enerji hesaplanır, daha sonrasında Hilbert, Shannon türlerinden biri tercih edilerek uygulanır [59]. Bebeklerde ve anormal sinyallerin olduğu durumlarda tersi bir gözlem söz konusu olabilir [33]. Zarf tabanlı segmentasyon yöntemler; Shannon enerjisi, Homomorfik filtreleme, Hilbert dönüşümü.

i. Shannon enerjisi:

Shannon enerjisi orta genlikteki sinyallere nazaran düşük genlikli sinyalleri zayıflatır, yüksek genlikli sinyalleri de hapsedebilir [63], [64]. Ayarlanabilir pencereler ile sinyalin zarflarını hesaplamada kullanılır. Bu model, her örneğin yerel spektrumunun enerjisini hesaplayarak sinyal enerjisini kullanır [65].

$$\text{ShannonEnergy: } E = -x^2 \log x^2 \quad (1.1)$$

x , normalleştirme işleminin sinyali veya gürültü sinyalidir. Sinyalin genliğini belirli bir seviyeye getirmek için kazanç ile sinyalin çarpımıdır [65].

Ortalama Shannon enerjisi:

$$E_s = -\frac{1}{N} \sum_{i=1}^N x^2(i) \log x^2(i) \quad (1.2)$$

N sinyal uzunluğunu gösteren bir tamsayıdır. Sinyal zarfını hesaplamak için normalleştirilmiş Shannon enerjisine ihtiyaç vardır.

Normalleştirilmiş Shannon sinyali:

$$E_n(t) = \frac{E_s(t) - M(E_s(t))}{\max(|E_s(t)|)} \quad (1.3)$$

$E_n(t)$ normalleştirilmiş Shannon enerjisi, $E_s(t)$ ise ortalama Shannon enerjisidir. $M(E_s(t))$, $E_s(t)$ 'nin ortalama değeridir.

ii. Homomorfik filtreleme

Homomorfik filtreleme, sinyal zarflarını çıkartmak için kullanılır. Logaritmik dönüşüm kullanarak sinyalleri, doğrusal olmayan bileşenleri, doğrusal bileşenlere çevirir [61]. Kalp sesinin tanınması için PCG sinyalinin enerjisi hesaplanmasının ardından Homomorfik zarf çıkarılır. $x(n)$ PCG sinyalinin enerjisi olarak ifade edilir. $a(n)$ ise genlik bileşenini, $f(n)$ ise salınımlı bileşeni belirtir. Anormal kalp seslerini $f(n)$ temsil eder [61].

$$x(n) = a(n) * f(n) \quad (1.4)$$

Bu formüldeki çarpma gürültüsü logaritması alınarak toplama gürültüsüne dönüştürülebilir.

$$z(n) = \log(x(n)) \quad (1.5)$$

PCG sinyalinin zarfını elde etmek için ters dönüşüm uygulanır. Bu aşamada yüksek frekanslı bileşenler ve düşük frekanslar çıkarılır. Bu sebeple $f(n)$ aşağıdaki formülde bulunmamaktadır [61].

$$\exp[z_1(n)] \approx \exp[\log(a(n))] \approx a(n) \quad (1.6)$$

Çıkarılan zarf daha sonra istenirse filtre kullanılarak tekrar örneklenir, sonrasında ise diğer zarf yöntemlerinde olduğu gibi normalleştirilir [61].

iii. Hilbert dönüşümü

Hilbert dönüşümü, birçok sinyalin frekans analizi ve işlenmesi için kullanılan matematiksel bir işlemdir. Bir kalp sesi sinyalinde Hilbert dönüşümünü gerçekleştirmek için önce yüksek frekanslı gürültüyü gidermek için alçak geçiren filtreden geçirilir. Filtrelenen sinyal daha sonra, sinyalin frekans alanındaki karmaşık gösteriminin sanal kısmının mutlak değerini alarak sinyalin zarfını çıkaran Hilbert dönüşümünden geçirilir. Zarf daha sonra kalp sesi sinyalinin sistolik ve diyastolik fazlar gibi farklı evrelerini tanımlamak için kullanılabilir. Hilbert dönüşümüyle kalp sesi sinyalinin zarfı çıkarıldıktan sonra, sinyal farklı bileşenlerine ayrılmak için kullanılabilir.

$$\frac{H(u(t))}{t-s} = \lim_{\epsilon \rightarrow 0} \frac{1}{\pi} \int_{|s-t|>\epsilon} \frac{u(s)}{t-s} ds \quad (1.7)$$

$u(t)$ giriş işlevidir ve Hilbert dönüşümü (t) sağlanarak elde edilir [63]. Hilbert dönüşümü, Wavelet- Hilbert, Hilbert-Huang, Hilbert dönüşümü-Heron Formülü vb. birçok yöntemle beraber kullanılmaktadır.

1.5.3.2. Ayrışmaya dayalı yöntemler

Zaman alanı özelliklerine göre bölütleme değil, dinamik kütle tabanlı bir yöntem önerilmiştir [59]. Bu yöntem, kalp sesi atomlarının zaman-frekans alanlarında bir küme biçiminde toplandığını varsayar [66]. Ancak bu hipotez sadece normal kalp sesleri için geçerlidir, üfürümlerin dalga biçimleri kümelenme şeklinde değildir [66]. ICF (Anlık döngü frekans) kısa süreli döngü frekansını kullanarak belirlenir. Elde edilen ICF ise PCG sinyallerini bölütleme için kullanılmaktadır [59]. Segmentasyon için önerilen temel yoğunluk fonksiyonu şekildeki gibidir:

$$w(t, \omega) = \frac{1}{L \sum_{i=1}^L E_i} \sum_{i=1}^L \left\{ E_i \exp \left(- \left(\frac{t - t_i}{2\sigma_i} \right)^2 - \left(\frac{\omega - \omega_i}{2s} \sigma_i \right)^2 \right) \right\} \quad (1.8)$$

1.5.3.3.Zaman- Frekans işleme yöntemleri

Biyolojik sinyaller elektriksel, kimyasal ve akustik sinyaller olarak sınıflandırılmaktadır [67]. Kalp sesleri ortalama 10 Hz- 750 Hz arasında düşük frekans aralığında bulunurlar [60]. Frekans içeriği zamanla değiştiği için kalp sesi sinyalleri akustik sinyallerdir yani durağan olmayan sinyallerdir [68]. Kalp sesi sinyallerinin zaman ve frekans alanında gösterimi, sinyallerin yapısına ilişkin çeşitli özelliklerini göstermektedir [33]. Bu yöntemler; S dönüşümü, Fourier, kısa zamanlı Fourier, Wigner-Wille, Chris William dağılımı (CWP), Dalgacık dönüşümü, kısa zamanlı modifiye Hilbert dönüşümüdür.

i. Fourier yöntemleri

Fourier dönüşümü spektral analiz yöntemidir. Spektral analiz frekans alanındaki akım sinyallerinin temsilini ifade eder [69]. Klasik Fourier yöntemi zaman alanında gösterilen sinyali frekans alanına taşır ancak sonrasında frekans alanında gösterdiği özelliklerin zaman alanında gösterememektedir [70]. Özellikle kalp sesleri gibi durağan olmayan seslerde bu problem, sınıflandırmada frekansın özelliklerini göstermede yetersiz kalmasına sebep olmaktadır. Fourier dönüşümü öncelikle zaman alanını frekans fonksiyonuna dönüştürerek başlar.

ii. Dalgacık dönüşümü

Dalgacık dönüşümü; sinyal işleme, iletişim, görüntü sıkıştırma, tıbbi görüntüleme vb. alanlarda kullanılmaktadır [58]. Dalgacık dönüşümü küçük dalgacıkları analiz etmede etkili bir yöntemdir [63].

2. MATERYAL VE METOT

Kalp kapakçıklarının hareketleriyle oluşan kalp sesleri durağan değildir. Kalp sesleriyle hastalıkların tespiti için ilk adım veri tabanının oluşturulması veya mevcut veri tabanlarından uygun veri tabanını seçmek olacaktır.

Elde edilen kalp sesleri ön işlemeden geçirilerek normalizasyonu özellik çıkarımında gerçekleştirilmiştir. Sağlıklı insanda dört tür kalp sesi ve iki tür faz bulunmaktadır. Kardiyak oskültasyon sırasında, doktorlar özellikle anormal sesler ve kalp patolojisinin varlığını düşündüren ve ayrıca tanısal bilgi sağlayan çeşitli üfürüm türleri ile ilgilenirler. Kalp sesi analizinde daha yaygın olarak benimsenen segmentasyon tekniği, kardiyak döngü temelinde gerçekleştirilir, çünkü çoğu durumda, verilen hastalıkla ilgili kalp sinyalindeki aktiviteler, tek bir kardiyak döngü aralığında yer alır. Spesifik olarak segmentasyon algoritması kalp sesleri verilerini bölümlere ayırır; Sistol ve diyastol fazı. Ancak bu çalışmada segmentasyon yapılmamıştır.

Kalp seslerinin sınıflandırılması yapay zekâ problemlerinden tek etiketli ikili veya çoklu sınıflandırma alanına girmektedir. Bu alan her veri örneği için olasılık hesabı yaparak tek bir etiketleme yapan modeldir [71]. Ayırt edici özelliklerin belirlenmesi işlemi olan öz-nitelik özelliklerin çıkarılması, kalp seslerinin etkili sınıflandırılmasında önemli bir rol oynar. Özellikler dört alandan birindeki sinyallerden çıkartılabilir; zaman alanı, frekans alanı, istatistiksel alan ve zaman-frekans alanı. Kalp sesi analizinde daha yaygın olarak benimsenen segmentasyon tekniği, kardiyak döngü temelinde gerçekleştirilir, çünkü çoğu durumda, verilen hastalıkla ilgili HS sinyalindeki aktiviteler, tek bir kardiyak döngü aralığında yer alır. Ancak kalp sesleri durağan sinyaller değildir. Bu sebeple akustik sese benzer olan kalp sinyalleri FrFT tabanlı MFCC kullanılarak çıkarılmıştır. Bunun için kesirli fourier ve Mel frekans katsayıları kullanılmıştır. Fonokardiyogram sesleri konuşma seslerine benzer olduğu için spektral ve sepstral özellikler gibi sinyaller için MFCC kullanılmaktadır. Mel Frekans ölçeği 1kHz 'in alındaki frekanslar için yaklaşık olarak doğrusal, üzerindeki frekanslar için ise logaritmiktir. FrFT, Fourier dönüşümünün genelleştirme şeklidir ve bir sinyalin zaman-frekans düzleminde bir dönüşünü gösterir. Ayırık Fourier veya kosinüs dönüşümleri bir sinyalin frekans bileşenlerini elde edebilirken, esasen sinyali zaman içinde lokalize olmayan harmonik bileşenler açısından ayrıştırırlar. Bu nedenle, sinyaldeki yerel varyasyonları bir zaman-frekans analizi yöntemine

kıyasla tanımlayamazlar. FrFT, Fourier spektrumuyla Fourier dönüşümünün bir genelleşmesini sunar ve zaman alanı sinyali bu dönüşümün özel durumlarıdır. Bu nedenle, spektrogram gibi diğer yöntemlere göre daha esnek bir zaman-frekans gösterimine izin verir. FrFT, sabit olmayan sinyal işleme için uygundur ve temel sinyal analizi ve konuşma tanımada geniş uygulamalara sahiptir. Bu sebeple FrFT ile sinyal analizi yapılmıştır [72].

Sinyal analizi yapılan kalp seslerini, diğer yapay zekâ modellerine kıyasla yüksek doğruluk ve hassasiyet vadeden derin öğrenme mimarileriyle sınıflandırılmak istenmiştir. Bunun için akustik seslerin sınıflandırılmasında en çok başarı gösteren modellerden RNN ve CNN kullanılmıştır.

En son aşamada karmaşıklık matrisi yöntemi ile sınıflandırmanın performansı değerlendirilmiştir. Karmaşıklık matrisi; Makine öğrenimi sınıflandırma problemi için bir performans ölçümüdür. Öngörülen ve gerçek değerlerin 4 farklı kombinasyonunu içeren bir tablodur. True positive — Doğru Pozitif (TP): Hastaya hasta demek, False positive — Yanlış Pozitif (FP): Hasta olmayana hasta demek, True negative — Doğru Negatif(TN): Hasta olmayana hasta değil demek, False negative — Yanlış Negatif(FN): Hasta olana hasta değil demek. Bu şekilde karmaşıklık matrisiyle modelin performansı açıklanabilir. Doğruluk (Accuracy), doğru olarak sınıflandırılan örneklerin yüzdesidir. Duyarlılık (Recall), pozitif olarak tahmin etmemiz gereken işlemlerin ne kadarını pozitif olarak tahmin ettiğimizi gösteren bir metriktir. “Gerçek pozitiflerin ne kadarı doğru bir şekilde tanımlandı? “Kesinlik(precision), pozitif olarak tahmin ettiğimiz değerlerin gerçekten kaç adedinin pozitif olduğunu göstermektedir.

2.1. Veri seti

Yapay zekâ sınıflandırma problemlerinde veriler, modelin başarısında çok etkili olmaktadır. Veri setleriyle ilgili modelin başarısını etkileyen sebepler şu şekilde sıralanabilir [73]:

- Veri setinin gürültüden arındırılmaması
- Veri setinin farklı dağıtıcılardan gelmemesi
- Veri setinin büyüklüğüne göre eğitim/geliştirme/ test seti oranının ayarlanamamış olması
- Veri setindeki sınıflarda eşit örneğe sahip olmaması.


Derin öğrenme modelleri eğitilmek için büyük veri setlerine ihtiyaç duyarlar. Bunun için şu ölçüt geçerli kabul edilmiştir: Data set 1.000.000' dan az ise train, dev, test olarak %60 ,%20 ,%20 veya %70,%15, %15 vb. şekilde bölünmelidir. 1.000.000'dan fazla veya bu rakama eşit ise %98, %1 , %1 vb. dağılımı yapılmalıdır [73].

Veri setinde gerekli ayarlamalar yapılamazsa veri seti, modelin başarısını olumsuz yönde etkileyecektir. Test setine yeni veriler eklendiğinde model onu tanımlayamayıp yetersiz uydurma (underfitting) gösterecektir.


Yaseen ve Kwon veri seti

GitHub'da yayımlanan erişime açık bir veri setidir [74]. Bu veri setinde aort darlığı (AS), mitral darlık (MS), mitral yetersizlik (MR), mitral kapak prolapsusu (MVP) ve normal sesi (Normal) olmak üzere 5 farklı sınıf bulunmaktadır. Örnekleme frekansı 8 kHz olan her sınıfta 200' er ses kaydı bulunmaktadır. Eşit sayıda örneğe sahip, çoklu sınıf barındırdığından bu veri seti seçilmiştir.


Spektrogram, sesin dosyasının frekanslarının zaman içerisindeki değişimini gösterir. Spektrum ise sesin frekans dağılımını göstermektedir. Her kategorideki örnek ses dosyalarının kesirli fourier dönüşümü kullanılarak frekans grafiği, spektrogram ve spektrumu görüntüleri elde edilmiştir.




Şekil 12 Normal, MR




Şekil 13 AS, MVP



Şekil 14 MS




Şekil 15 Spektrum Normal, MR, AS



Şekil 16 Spektrum MVP, MS

2.2. Ön İşleme



Şekil 17 Sinyal ön işleme şeması

2.2.1. PCG sinyal işleme ve kesirli fourier tabanlı özellik çıkartımı

2.2.2. Ön vurgu

Kalp sesi sinyallerine ön vurgu filtresi uygulanmaktadır. Ön vurgu filtresi; yüksek frekansları güçlendirir, düşük frekans bileşenlerini zayıflatarak spektrumu dengeler. Ön vurgu filtresiyle, şu problemlere çözüm olabileceği düşünülmüştür [72]:

- Düşük frekanslar yüksek frekanslara oranla daha büyük olabilir, bunun sonucu da kayan nokta hassasiyeti veya kararlılık sorunları oluşabilir.
- Sinyal-gürültü oranı (SNR); istenen sinyal ile istenmeyen gürültü arasındaki oran.

$$y(t) = x(t) - \alpha x(t - 1) \quad (2.1)$$

Filtre katsayısı için (α) 0,95 ve 0,97 değerlerinden 0,97 olarak seçilmiştir [75].

2.2.3. Çerçeveleme

Ön vurgudan sonra frekans içeriğinin zaman içerisinde analiz etmek için sinyal zaman dilimlerine bölünmüştür [75]. Tüm sinyale fourier uygulamak sinyalin frekans konturlarının kaybolmasına sebep olabilir [75]. Çerçeve boyutu için 125ms ve çerçeve uzunluğunun %50 sine yakın 50 ms'lik adımlar tercih edilmiştir [8].

2.2.4. Pencereleme

Çerçeveselenen sinyal, Hamming yöntemiyle pencerelenir. Bu yöntem MFCC özellik çıkarımında ve konuşma tanımla uygulamalarında yaygın olarak kullanılmaktadır. Pencereleme; seçilen aralıkta sonlu sıfır olmayan değerlere sahiptir ve bu aralığın dışında ise sıfır değerine sahiptir ve sinyali etkili bir şekilde sıfıra indirir [77]. Böylece spektral sızıntısının etkilerini azaltır ve sonlu sinyal segmenti üzerinde Fourier dönüşümüne izin verir. Pencereleme numpy kütüphanesi kullanılarak hesaplanır.

$$w[n] = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right) \quad (2.2)$$


2.2.5. Kesirli Fourier dönüşümü

Derin öğrenme işlemlerinde makine öğrenmesine nazaran ön işlem ve öznitelik çıkarımı gereksinimi azalmıştır. Ancak ön işleme ve öznitelik çıkarımının gereksiz olduğu söylenemez. Çünkü derin öğrenme modelleri ham verileri işlese de öğrenmesi için verilerin çok olması gerekir. Eldeki veri seti yeterli olmadığında ham veriyi işleme ve öznitelikleri çıkarmada yardımcı olmak modelin öğrenmesinde çok etkilidir [78]. Derin öğrenmede yeni bir metot olan uçtan uca eğitime yöntemi elenmiştir. Çünkü bu metot aradaki özniteliklerin çıkarımında yüksek başarıyı gösterememiştir. Bu sebeple verinin ön işlemi ve öznitelik çıkarımı önem arz etmektedir [79].

Durağan olmayan sinyallerin analizinde birçok yöntem denenmiştir. Yöntemlerin dezavantajı ve avantajları ise 1. Bölümde ele alınmıştır.

FRFT, 1929'da klasik Fourier dönüşümü özdeğerler açısından incelemek için Wiener ile başladı. Namias' ın yayınlarıyla 1980 de ise yeniden gündeme geldi, 1990'lara gelindiğinde kesirli Fourier ile ilgili pek çok makale vardı [80]. McBride ve diğerleri 1993 yılında yayınlanan "The fractional Fourier transform and applications" adlı makalelerinde FRFT için integral formunu kullanarak daha titiz bir matematiksel tanım sunmuşlardır. Bu makale, FRFT 'nin matematiksel temellerini ve bir dizi uygulama örneğini içermektedir. FRFT' nin integral formülü, Fourier Dönüşü ve diğer matematiksel kavramlarla yakından ilişkilidir ve geniş bir kullanım alanı vardır [81]. Mendlovic ve Özaktas, FRFT 'nin optik doğrulamasını gerçekleştiren öncü araştırmacılardandır. Bu çalışmada, bir

FRFT optik sistemini tasarlamışlar ve deneysel olarak sonuçlarını göstermişlerdir. Sonuçlar, FRFT' nin optik uygulamalarının mümkün olduğunu ve geleneksel Fourier dönüşümünden daha geniş bir dönüşüm yelpazesine sahip olduğunu göstermiştir. Bu çalışmada, FRFT' nin optik sistemlerde kullanımının fiziksel olarak anlaşılması ve uygulanması için bir çerçeve oluşturulmuştur [81]. Bu zamana kadar 2000'lerden günümüze kadar Kesirli Fourier alanında araştırmalar artmıştır [82].




Şekil 18 Kırmızı işaretliler, kesirli Fourier+ Biyomedikal sinyal işleme [82]

FRFT, Fourier dönüşümünün genelleştirilmiş bir versiyonudur. FRFT, bir sinyalin frekans bileşenlerinin incelenmesinde kullanılır ve sinyali belirli bir açıda dönüştürür. Bu sayede, sinyal işlemede çapraz terim paraziti üretmeyen bir dönüşüm yöntemi sağlar [80], [82], [83].

FRFT, birçok alanda kullanılan bir dönüşüm yöntemidir. Sinyal işlemede tarama filtrelerinin tasarımında, yapay sinir ağlarında öğrenme ve öğretme sürecinde, kuantum mekaniği alanında kuantum durumlarının incelenmesinde, kırınım teorisi alanında ışığın kırılma ve yansıma işlemlerinin incelenmesinde, optik iletim ve görüntü işleme alanlarında sinyallerin gönderimi ve işleminde kullanılabilir. FRFT, sinyal işlemede iyi uygulanabilirliğe sahip olmasının yanı sıra, sinyallerin frekans bileşenlerinin daha doğru bir şekilde incelenmesine de olanak sağlar. Bu sayede, sinyallerin özellikleri hakkında daha doğru ve detaylı bilgi edinilebilir [83].

Sinyal işleme yöntemlerinde Fast Fourier Transform (FFT) hesaplama açısından verim gösterse de zamansal değişikliklerin çözünürlüğünü kaybeder ve sabit olmayan sinyallerin analizinde sınırlıdır [84].



Şekil 19 FrFT etki alanı u ile temsil edilir. u_a ve u_{a+1} yönü ϕ açısı ile verilen eksenler [82]

STFT, farklı kayar pencerelerle zaman-frekans analizini yapsa da pencerelerin sabit boyutlu olması nedeniyle frekans ve zaman alanında sınırlı çözünürlük sağlar [84]. Yüksek frekanslarda, STFT' nin zamansal çözünürlüğü azalır ve zaman boyunca hızlı değişen sinyallerin analizinde bir dezavantaj haline gelir. Wavelet Transform(WT) ise, sinyallerin farklı ölçeklerdeki zaman ve frekans bileşenlerini inceleyen bir analiz yöntemidir. Bu nedenle farklı zaman aralıklarında yüksek ve düşük frekans bileşenlerini belirlemek mümkündür. Dezavantajı ise sinyalin en iyi şekilde temsili için kullanılan ana dalgacık seçimi ampirik yapılır ve analizin sonuçlarını, doğruluğunu etkiler [84]. FrFT çok bileşenli sinyallerle uğraşırken çapraz dönem paraziti üretmez. Dönüştürülmüş sinyalin birçok uygulamada bireysel bileşenlerine kolayca ayrılmasını sağlayarak, sinyali işlemenin iyi uygulanmasını sağlar [83], [85], [86]. FrFT hesaplama verimliliği açısından WT ve STFT' yi yapılan çalışmalarda geçmiştir [83].

FrFT, kesirli eksen olarak da bilinen u_a eksenı boyunca bir sinyal tanımlar ve birleşik bir zaman-frekans karakterizasyonu sağlar. u_a , Şekildeki düz çizgilerle gösterildiği gibi bir açı ϕ ile zaman-frekans düzlemi içinde döndürülmüş bir eksenidir. FrFT, kesirli Fourier dönüşümü olarak adlandırılır, çünkü dönüşümün derecesi kesirli bir sayıya eşit olabilir.

Bu kesirli sayı, dönüşüm sırasında zaman-frekans düzlemi boyunca dönüşün oranını belirler, bu sinyalin zaman ve frekans bileşenlerinin nasıl birleştirildiğini kontrol eder ve sinyalin zaman-frekans özelliklerini ayarlamaya olanak tanır [83].

FrFt' nin zaman-frekans gösterimi:

Fourier dönüşümü:

$$X(\omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} x(t)e^{-j\omega t} dt \quad (2.3)$$

Ters Fourier dönüşümü:

$$x(t) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} X(\omega)e^{j\omega t} d\omega \quad (2.4)$$

Fourier, sinyalin zaman ile frekans arasındaki bağlantısını kurar. x(t) sabit sinyaller için daha uygundur. Bir sinyal Fourier dönüşümüne tabi tutulduğunda dönüşümden sonra zaman bilgisi kaybolur, bu sebeple sinyal frekansın zamanla değişen eğilimini yansıtamaz [83]. Fourier dönüşümün dönüş açısı eklenmiş halidir; 2.3 formülünde görülmektedir [83], [87], [88]:

$$\begin{aligned} X_p(u) &= \int_{-\infty}^{\infty} K_p(t, u)x(t)dt \\ &= \begin{cases} \sqrt{\frac{1-j\cot\alpha}{2\pi}} \int_{-\infty}^{\infty} x(t)e^{j\left(\frac{u^2}{2\cot\alpha} - ut\csc\alpha + \frac{t^2}{2\cot\alpha}\right)} dt \alpha \neq n\pi \\ x(t)\alpha = 2n\pi \\ x(-t)\alpha = (2n \pm 1)\pi \end{cases} \quad (2.5) \end{aligned}$$

FrFT 'nin sırasını temsil eden p,

Sürekli FrFT 'nin bazı önemli özellikleri aşağıdaki gibidir:

Doğrusallık:

$$F^p[\sum_n c_n x_n(u)] = \sum_n c_n [F^p x_n(u)] \quad (2.6)$$

Merkeziyetçi:

$$(F^p)^{-1} = (F^p)^H \quad (2.7)$$

İndeks Toplama:

$$Fp^1 Fp^2 = Fp^{1+p^2} \quad (2.8)$$

Değişme:

$$\mathcal{F}^{a_2} \mathcal{F}^{a_1} = \mathcal{F}^{a_1} \mathcal{F}^{a_2} \quad (2.9)$$

Öz fonksiyonlar:

$$\mathcal{F}^a[\psi_n(u)] = \exp\left(-\frac{ian\pi}{2}\right) \psi_n(u) \quad (2.10)$$

Aynı zamanda FrFT çift simetrik sinyaller için çift simetrik ve tek simetrik sinyaller için tek simetrik özellik gösterir [87].

Tablo 3 Chirp penceresinin özellikleri hem zaman hem de frekans alanlarında çalışır [83].

Pencere Fonksiyonu	$g(t) = e^{\frac{jt^2}{2}}$	$g\left(\frac{t-t_0}{\sqrt{\tan\alpha}}\right) = e^{\frac{j}{2}\left(\frac{t-t_0}{\sqrt{\tan\alpha}}\right)^2}$
Zaman penceresi merkezi	x^*	$t_0 + \sqrt{\tan\alpha}x^*$
Zaman penceresinin yarım genişliği	Δgr	$\sqrt{\tan\alpha}\Delta gr$
Zaman penceresi aralığı	$[x^* - \Delta gr, x^* + \Delta gr]$	$\left[t_0 + \sqrt{\tan\alpha}x^* - \sqrt{\tan\alpha}\Delta gr, t_0 + \sqrt{\tan\alpha}x^* + \sqrt{\tan\alpha}\Delta gr \right]$
Frekans pencere merkezi	w^*	$\frac{w^*}{\sqrt{\tan\alpha}}$
Frekans penceresinin yarım genişliği	Δgr^*	$\frac{\Delta gr^*}{\sqrt{\tan\alpha}}$
Frekans penceresi aralığı	$[w^* - \Delta gr^*, w^* + \Delta gr^*]$	$\left[\frac{w^*}{\sqrt{\tan\alpha}} - \frac{\Delta gr^*}{\sqrt{\tan\alpha}}, \frac{w^*}{\sqrt{\tan\alpha}} + \frac{\Delta gr^*}{\sqrt{\tan\alpha}} \right]$

FrFT Tabanlı Anlık Frekans Tanımlama

Durağan olmayan sinyallerin anlık frekansı hesaplamak için, FrFT katsayılarının fazının türevini zamana göre alarak yapılabilir. FrFT kullanan IF formülü şu şekilde verilir [83]:

$$f(t_0) = \frac{1}{2\pi} w_m = \frac{1}{2\pi} [u(\alpha') \csc \alpha' - t_0 \cot \alpha'] \quad (2.11)$$

Tablo 4 Biyomedikal sinyal işlemede kullanılan FRFT özeti [82]

Ref.	Sinyal türü	DFrFT türü	Uygulanan (α)	Görev
[89]	Chirp model	Belirtilmemiş	0 ila 2 aralığında optimum	Sinyal algılama
[90]	EEG	Belirtilmemiş	0,4'lik adımlarla 0 ile 25 arası	Özellik ayıklama
[91]	Elastogramlar	Örnekleme tipi	Geometrik olarak hesaplanan optimal	Gürültü Giderme
[92]	Parmak izi sinyal modeli	Özvektör ayrışma tipi	0,1 adımlarında 1,0 ila 1	Kodlama
[93]	Parmak izi görüntüsü	Özvektör ayrışma tipi	0,1 adımlarında 1,0 ila 1	Kodlama
[94]	Parmak izi sinyal modeli	Belirtilmemiş	0,5 adımlarında 1,0 ila 1	Kodlama
[95]	Parmak izi görüntüsü	Belirtilmemiş	0,1 ila 1,9	Kodlama
[96]	EEG	Belirtilmemiş	0 ila 1 aralığında optimum	Özellik ayıklama
[97]	Embolik Doppler ultra ses	Özvektör ayrışma tipi	Ampirik denemelerle 0,09'a ayarlandı	Sinyal algılama
[98]	Beyin MR görüntüsü	Doğrusal kombinasyon tipi	0,6 adımlarında 1,0 ila 1	Özellik ayıklama
[99]	Beyin MR görüntüsü	Doğrusal kombinasyon tipi	0,6 adımlarında 1,0 ila 1	Özellik ayıklama
[100]	Beyin MR görüntüsü	Belirtilmemiş	0,6 adımlarında 1,0 ila 1	Özellik ayıklama
[101]	Beyin MR görüntüsü	Belirtilmemiş	0,2 adımlarında 1,0 ila 2	Özellik ayıklama
[102]	Biyoakustik (konuşma)	Belirtilmemiş	Ampirik olarak 0,75 olarak ayarlayın	Gürültü Giderme

Ref.	Sinyal türü	DFrFT türü	Uygulanan (α)	Görev
[103]	EEG	Örnekleme tipi	Eşik oluşturarak ampirik olarak	Özellik ayıklama
[104]	EEG	Belirtilmemiş	Enerji konsantrasyonu ile optimum	Özellik ayıklama
[105]	EKG	Belirtilmemiş	0 ila 1	Sinyal gösterimi
[106]	Beyin MR görüntüsü	Belirtilmemiş	0,6 adımlarında 1,0 ila 1	Özellik ayıklama
[107]	EEG	Özvektör ayrışma tipi	0,1 adımlarında 1,0 ila 1	Özellik ayıklama
[108]	Gen ekspresyon profili	Belirtilmemiş	0,1'lik adımlarla 0 ile 05 arası	Özellik ayıklama
[109]	EKG	Örnekleme tipi	Menzil belirtilmemiş olarak optimum	Geliştirilmiş Analiz
[110]	EEG	Belirtilmemiş	Belirtilmemiş	Özellik ayıklama
[111]	EKG	Örnekleme tipi	0,1 ila 1,1 aralığında optimum	Sinyal algılama
[112]	Atalet sinyali (insan hareketi)	Özvektör ayrışma tipi	0,75, 0,67, 0,65 ve 0,64	Özellik ayıklama
[113]	Biyoakustik (kalp sesleri)	Özvektör ayrışma tipi	0.9, 0.95, 1 ve 1.1	Özellik ayıklama
[114]	Biyoakustik (kalp sesleri)	Özvektör ayrışma tipi	0.9, 0.95, 1 ve 1.1	Özellik ayıklama

Biyomedikal sinyallerin işlenmesi ve sınıflandırılmasında alfa derecesi olarak 0,9 seçilmiştir. Bilinen keras, numpy, librosa vb. kütüphanelerde FrFt için bir kütüphane bulunmamıştır. Bunun yerine spkit sinyal işleme kütüphanesinden sp.frft ile hesaplama yapılmıştır. spkit.frft (signal, alpha) olarak iki değer almaktadır. For döngüsü kurularak pencerelenmiş sinyalin frft hesaplaması yapılır. Hesaplanan değerler çıktıları sanal ve gerçek sayılardan oluştuğu için np. array komutu ile dizin haline getirilen çıktının genliği np.abs komutuyla alınır. Genliği alınan işlenmiş sinyalin güç spektrumu hesaplanır. Güç spektrumu, sinyalin genliğinin karesine eşittir [115]. Kesirli fourier dönüşümü hem zaman hem frekans alanının özelliklerini taşıdığı için STFT yönteminde kullanılan nokta belirleme işlemi yapılmamıştır [116].

2.2.6. Mel filtre bankası ve MFCC çıkarımı

Güç spektrumu, frekans ölçeğinde bant aralıkları belirlenip mel filtre bankasından geçerek, mel frekans ölçeğine dönüştürülür [116]. Her bant aralığına üçgen filtre oluşturulur. Üçgen filtreler düzgün bir şekilde dağılır ve mel filtre bankasına eşlenir [8]. Filtre bant sayısı 20 belirlenmiştir [72].

Mel Ölçeği:


$$Mel(f) = 2595 \log \left(1 + \frac{f}{700} \right) \quad (2.12)$$

Elde edilen sonuçlara ayrık kosinüs dönüşümü (DCT) uygulandı, num_ceps değeri 24 olarak belirlenerek MFCC çıkarımı sağlandı.

2.3. Sınıflandırma

2.3.1. Yapay zeka

1950’li yıllarda bilgisayarın düşünme kavramı üzerinde araştırmalar sonucu yapay zeka kavramı ortaya çıkmıştır [71]. 1950 ile 1980 yılları arasında, yapay zekanın insan seviyesinde bilgiyi işleyeceğine inanılan ve sembolik yapay zekâ adı verilen bu akım hüküm sürmüştür. Bu görüş karmaşık sınıflandırma ve problemlerde istenilen çözümü getiremediği için yerine makine öğrenmesi terimi ortaya çıkmıştır [71]. Yapay zekâ aslında, makinelerin akıllı olmasını sağlayan algoritmaları ortaya koyar [117].



Şekil 20 Yapay Sinir Ağları Katmanları Gösterimi [118]

İleri beslemeli sinir ağı veya tamamen bağlı sinir ağı insan beyninin nöronal sistemini örnek olarak oluşturulmuş en eski sinir ağlarındandır [119].


$$\hat{y} = \text{sigmoid} \left(\sum_{i=1}^3 w_{ij} x_i + b_j \right) \quad (2.13)$$

$\mathbf{W} \in \mathbb{R}^{c \times d}$, $\mathbf{b} \in \mathbb{R}^c$ ve c , kategori sayısını temsil eder. $\mathbf{W}$ parametresi ağırlık, $\mathbf{b}$ parametresi bias vektörüdür [119]. x_i giriş sütunu vektörünün i . elamanını gösterir [119].

2.3.2. Makine öğrenmesi


Charles Babbage 1830- 1840 yılları arasında “Analitik Makine” adı verilen makineleri matematiksel analizleri yerine getirmek için tasarladı. Yapay zekayı literatüre kazandıran insanlardan Alan Turing, yapay zekayı şekillendiren Turing testini 1950 yılında “Hesaplama Makinesi ve Zekâ” isimli makalesinde anlatmıştır [120]. Daha sonraki süreçlerde bilgisayarlar eldeki bilgilerden çıkarımlar elde ederek kendisi öğrenme sürecini gerçekleştirebilir mi? Gibi sorularından ardından makine öğrenmesi kavramı ortaya çıkmıştır [71], [121]. Sembolik yapay zekâda kullanıcı kuralları ve girdileri yükler, problemin çözümü ortaya koyulan kuralların veriler üzerinde denenmesi sonucunda ortaya çıkar. Makine öğrenmesi ise verileri ve tahmini çıktıları kullanarak kurallarını kendisi öğrenerek yeni problemlere çözüm bulmayı sağlar [117], [122]. Boyut indirgeme, kümeleme, sınıflandırma, tahmin makine öğreniminden çözmesi beklenen durumlardır. Sembolik yapay zekadan makine öğrenmesinin farkı, eğitilebilir ve esnek olmasıdır. Makine öğrenmesi ve alt dalı derin öğrenme teorik kısımdan çok uygulamaya bağlıdır [71]. Makine öğrenmesi problemleri çeşitleri:

- Gözetimli öğrenme; verilerin olduğu ve etiketlenmiş olduğu eğitim verileri sunarak gelecek girdileri de öğrenmiş olduğu bu kurallara göre sınıflandırması, etiketlemesi veya tahmin etmesi istenir. Gözetimli öğrenme, Gözetimli öğrenme algoritmalarına aynı zamanda sınıflandırma ve regresyon algoritmaları da denilmiştir [117]. Regresyon algoritmaları devamlı değerlerin sonuçlarını tahmin eder ve tahmin için bir grafik çizer. Sınıflandırma problemleri ise özelliklere göre ayrık değerlerin çıktığını tahmine ederek verileri sınıflandırır [122]. Gözetimli öğrenmenin en bilinen yöntemleri; SVM ve lineer ayırmadır [122].



Şekil 21 Gözetimli Öğrenme [123]

- Gözetimsiz öğrenme; eğitim verilerinde etiketlenmemiş verilerin sunulup, modelin kendi başına kuralları ve istenen özellikleri bulması beklenen yöntemdir. Denetimsiz öğrenme, gözetimsiz öğrenmenin veriler üzerindeki uygulanma halidir; denetimsiz öğrenmeye örnek olarak kümeleme ve boyutsallık örnek gösterilebilir [124], [71]. Gözetimsiz öğrenme yöntemlerinden en çok bilinen çeşitleri; K- kümeleme ve Ana bileşen analizidir [122].
- Bir ortamla etkileşim; buna çevrim dışı öğrenme adı da verilir. Bu öğrenme modelinde, büyük veri setlerinin eğitilmesi zor olduğu durumlarda veya eğitim veri setinin maliyeti büyük olduğunda sabit veri setinin üzerinde eğitim yapılmasıdır. Ancak veri seti güncelleştirilemeden, tahminlerde bulunması istenir [125].
- Yarı denetimli öğrenme; öğrenme sürecinden etiketli veriler ile etiketsiz verilerle karşılaştırılarak öğrenme süreci gerçekleştirilir. Yangın olan yöntemleri; kendi kendine eğitim, grafik tabanlı yarı gözetimli öğrenme ve yarı gözetimli SVM olarak belirtilir [122].
- Pekiştirmeli öğrenme; temeli psikolojideki Thorndike' nin pekiştirmeli öğrenme teorisinden ortaya çıkmıştır. Bu yönetime göre çevreyle etkileşimde olan özne, yaptığı eylemlerin sonucunu gözlemleyerek ödülleriyle göre öğrenmeyi gerçekleştirir, buna göre hangi eylemleri yapması gerektiğine karar verir [122]. Go oyununda en üst seviye oyuncuları yapay zeka bu yöntemle yenebilmiştir [71].



Şekil 22 Pekiştirmeli Öğrenme ve çevresiyle etkileşimi [126]

Makine öğrenimi modellerinin hedefi, modellerinin genelleme yaparak hiç görmediği veriler üzerinde de istenilen sonuçlara ulaşabilmesidir. Bunu engelleyen aşırı uydurmadır.

Bir model oluşturulması ve değerlendirilmesi üç aşamada gerçekleştirilir. Eğitim, doğrulama ve test veri setidir.

2.3.3. Derin Öğrenme

Derin öğrenme, makine öğrenmesinin alt dilimidir. Makine öğrenmesi ham verileri işleyemez, bu sebeple ham verilerden başlayarak birden çok katmanda işlem yaparak öğrenen derin öğrenme ortaya çıkmıştır [71], [127]. Makine öğrenmesi bir, iki katmandan oluşurken derin öğrenme binlerce katmandan meydana gelir [71].


İşlemden geçirilmemiş ses sinyallerinden ve görüntülerinden öğrenme, çeşitli uzunluklardaki sözler ile çevrimini yapma gibi makine öğrenmesinin yetersiz kaldığı durumlarda derin öğrenme üstün gelmiştir [128].

Karmaşık veriler karşısında derin öğrenme yöntemi yanlış yönlendirebilir. Bunun için veri ön işleme, veri temizleme, veri gerçeği kontrolünden sonra derin öğrenme yöntemi uygulanmalıdır. Aynı zamanda problemin çeşidine göre derin öğrenme metotları seçilmelidir [127].

Az maliyetli ancak yüksek kalitede sensörlerin ortaya çıkışı ve GPU gelişimiyle birlikte çok gelişmiş teknolojiye yapay zekâ algoritmaları kullanılabilir hale geldi [118].

2.3.3.1.CNN

CNN, Evrişimli sinir ağları, görüntü tanıma ve sınıflandırma gibi bilgisayarlı görme görevlerinde yaygın olarak kullanılan, ileri beslemeli bir ağıdır [129], [130]. Evrişimli sinir ağları, ileri beslemeli ağların evrişimli ve derin yapılı halidir [119]. İleri beslemeli ağlar her bilgiyi ayrı işleyerek hafızalarında tutmazlar, bu sebeple birbirinden bağımsız verileri tek büyük vektöre dönüştürerek işlemek gerekir [131]. İleri beslemeli ağlarda her katman bir sonrakinin giriş verisi niteliğindedir. Derin öğrenme algoritmasında gerekli olan ön işlem diğer sınıflandırıcılara nazaran oldukça düşüktür [129]. Giriş bilgilerine bir dizi filtre uygulayarak girişin farklı yönlerini vurgulayan özellik haritasını ortaya çıkarır. Özellik haritaları etkinleştirme işlevlerinden geçirilir; böylece CNN'nin öğrenme yeteneği ve sınıflandırma performansı artarak karmaşık ilişkileri modellemesi beklenir [129].



Şekil 23 CNN, evrişimli sinir ağı öğrenim süreci [129]

A- CNN'in katmanları

CNN'ler evrişimli ağlar, bilgisayarlı görü modelleri olarak da bilinirler. CNN'ler evrişimli katmanlar, havuzlama katmanları ve tam bağlı(fully connected) katmanlar gibi farklı katman türlerini bir arada kullanarak oluşturulur [132], [133]. Evrişimli katmanlar, görüntülerin özelliklerini çıkarmak için bir dizi filtre kullanarak girdi özellikleri vurgulayarak özellik haritaları oluştururlar [133], [134]. Havuzlama katmanları, evrişimli katmanların çıktılarını küçültmek ve özetlemek için kullanılır [135], [136]. Bu ağın yükünü azaltarak aşırı öğrenmeyi engeller. Havuzlama katmanları, maksimum havuzlama veya ortalama havuzlama gibi farklı tekniklerle uygulanır. Tam bağlı katmanları ise, ağın özelliklerini ağın özelliklerini çıkarmak için evrişimli ve havuzlama katmanlarından aldıkları bilgiyi birleştirir. Aldığı bu özellikleri çıktı sınıflarına bağlanan sinir ağına iletir.


Katmanlardan öğrenilen özellikler sınıflandırma gibi çıktılar için kullanılır [136].

Evrişimsel katmanlar

Evrişimli katmanlar (convolutional layer), özellikle görüntü işleme uygulamalarında kullanılan bir tür sinir ağı katmanıdır.


$$Y[m, n] = \sum_{i=1}^K \sum_{j=1}^K K[i, j] X[m - 1 + i, n - 1 + j] \quad (2.14)$$

Bu katmanlar, giriş olarak bir görüntü ve küçük bir ağırlık matrisi olan çekirdeği alırlar ve bu çekirdeği görüntü üzerinde kaydırarak özellik haritaları üretirler [127], [128], [129], [137].



Şekil 24 Çekirdeğin hareketi [129]

K, çekirdek ve küçük bir ağırlık matrisidir. K, K' nin genişliği veya yüksekliğidir [93], [94]. Her bir görüntüsü X' in bir bölgesine karşılık gelir. X' in çekirdek K ile iç çarpılması ve sonuçlarının toplanmasıyla hesaplanır (şekil 24). Bu hesaplama, giriş görüntüsünün her bir ögesi için ayrı ayrı yapılır ve çıkış değerleri, çekirdek K'nin her bir bölgesi için bir çıkış değeri üretir. Çıktılar, özellikler olarak, çıktılarının görüntüleri de özellik haritası olarak adlandırılır [129], [130], [138].



Şekil 25 2B evrişimde tek bir özellik değerinin hesaplanması [130]


Tek boyutlu evrişimli katmanın yapısı aşağıdaki gibidir.

$$Y[n] = \sum_{i=1}^K K[i]X[n - 1 + i] \quad (2.15)$$

Tek evrişimli katman paralel evrişimleri sayesinde giriş bilgilerinden özellikleri çıkartırken, diğer katmanlar önceki katmanlardan elde edilen özellikler sayesinde karmaşık özellikleri çıkartabilir [139]. Evrişimli katman makine öğreniminde gerekli olan özellik mühendisliğinin yerini almaktadır.

Havuz katmanı

Evrişim katmanlarının peşi sıra gelen katmanlara havuz katmanı (pooling layer) denir. Evrişimli katmanların çıkardığı özellik haritasının uzlamsal boyutunu azaltarak bir kısım bilgilerin kaybolmasına sebep olur [48], [139]. Bilgilerin kaybolmasıyla veriyi sığdırmayı ve işlem yükünü azaltmayı sağlar [48].



Şekil 26 Havuzlama katmanı (pooling layer) [140]

Şekil 26’ da birleştirilmiş özellik haritasındaki $y_i^{(l+2)}$ birimi, m büyüklüğündeki havuzlama alanına odaklanmış havuzlama işlemi gösterilmektedir. üç farklı havuz katmanı modeli vardır:

Ortalama havuz katmanı havuz alanındaki değerlerin ortalamasını alarak elde ettiği sonucu yeni özellik haritasındaki konuma yazar.

$$f\left([o_{(i-1)m+1}^{(l+1)}, \dots, o_{im}^{(l+1)}]\right) = \frac{1}{m} \left(\sum_{j=(i-1)m+1}^{im} o_j^{(l+1)} \right) \quad (2.16)$$

Maksimum havuzlama havuz alanındaki en yüksek değerleri alarak yazar. Maksimum havuzlama yöntemi en yaygın olan yöntemlerdendir.

$$f\left([o_{(i-1)m+1}^{(l+1)}, \dots, o_{im}^{(l+1)}]\right) = \max_{(j=(i-1)m+1):(j=im)} o_j^{(l+1)} \quad (2.17)$$

Toplam havuzlama, havuz alanındaki değerlerin toplamını alarak yapar.

$$f\left([o_{(i-1)m+1}^{(l+1)}, \dots, o_{im}^{(l+1)}]\right) = \sum_{j=(i-1)m+1}^{im} o_j^{(l+1)} \quad (2.18)$$

Havuzlama(pooling) katmanı, boyutu azaltırken kenarların özelliklerinin kaybolmasına sebep olabilir. Birçok havuz katmanından oluşan yapıda boyut gittikçe küçülür böylece istenilen özellikleri sinir ağı öğrenememiş olur. Bunu giderebilmek için doldurma işlemi (padding) yapılmaktadır [141]. Bu şekilde derin ağlar oluşturulabilir [142].


Tam bağlı katman

Tam bağlı katman (fully connected layer) , ardışık katmanlar arasında nöronları birbirine bağlayarak iletişimi sağlar [143].

Bu katmanlar dışında doğrusal olmayan noktaları yakalamayı sağlayan ReLU katmanı ve CNN öğrenme süresini azaltmak için kullanılan normalleştirme katmanları da CNN mimarilerine göre bulunabilmektedir [143]. CNN, diğer iki katmanı birçok kez tekrar eder. En son daha soyut olan özellikleri oluşturarak sınıflandırma için tam bağlı katmanlar kullanılır [140].

2.3.3.2.RNN

RNN, yönlendirilmiş döngülerle grafik oluşturur ve öğrendiği bilgilere yeni bilgileri ekleyerek artırılmış olarak bilgileri işler [71], [127], [144].



Şekil 27 RNN [144]

$$\tilde{h}_t = Vx_t + Uh_{t-1} + b_h \quad (2.19)$$

$$h_t = \sigma_h(\tilde{h}_t) \quad (2.20)$$

$$\tilde{y}_t = Wh_t + b_y \quad (2.21)$$


$$y_t = \sigma_y(\tilde{y}_t). \quad (2.22)$$

W , V ve U matrisleri ağırlık matrisleridir. b_h ve b_y bias vektörleridir. σ_h ve σ_y gizli katmandaki ve çıktı katmanındaki etkinleştirme işlevleridir. RNN, h 'nin güncellenmesini tekrarlar [145]. Çıktı y_t tüm geçmiş girdilerden ve mevcut girdilerden etkilenecek tahmin sonucunu gösterir [145].

RNN'ler zaman ve sıraya bağımlı verileri işler [131]. Girdi dizisinin düzeni sonuçları etkiler. Ancak çift yönlü RNN'ler(bidirectional RNN), diziye ileri yönde (baştan sona) ve diğeri de geriye doğru(sondan başa) çift yönlü olarak işler [131]. Yinelemeli ağlarda dropout kullanırken iki farklı dropout çeşidi kullanılır; recurrent_dropout ve dropout [131].

2.3.4. Aşırı uydurma ve yetersiz uydurma

Makine öğreniminde/derin öğrenmede en önemli noktalardan biri de eniyileme ve genelleştirme arasındaki rekabettir. Eniyileme algoritmaları, modelin eğitim setinde en iyi öğrenmesini hedeflerken, genelleştirme ise önceden görmediği verilerde de iyi performansı hedefler [78].



Şekil 28 Uyum çeşitleri gösterimi [146]

Çekirdeklerin ebatları ve adedi ayarlanabilir ancak çok fazla çekirdeğin olması overfitting problemine sebep olabilir [137].

Overfitting (aşırı uydurma), yapay zeka modelinin sadece eğitim verisi üzerinde çalışıp, test verisinde düzgünce çalışamaması demektir [146], [147]. Aşırı uydurma olmaması için uygun parametreleri seçmek ve veri setlerine uygun modelleri eğitmek gerekir. Yapay zekâ modeli, eğitim setinden yeterli öğrenim gerçekleştiremezse uyumsuz (underfitting), istenilen gibi eğitim verisi üzerinde eğitilip, test verisindekileri yakalarsa iyi uyum (good fit), eğitim verisi örneklerini ezberleyip sadece o veri setinde başarılı olursa aşırı uyum-uydurma (overfitting) olacaktır (şekil-28).

Derin öğrenme sınıflandırmasında sadece oranlar önemli değildir. Bir modelin başarısı, yaptığı hatanın niteliğine göre de değişebilmektedir. Problemin gerçek hayattaki önemi hatanın da ağırlığını arttır. Bu hata sadece istatistik olarak hesaplanamaz. Bu durumda modelin gerçekten başarısını ölçmek için kayıp fonksiyonuna ağırlık eklemek gerekir.

Sınıflandırma hatası:

$$\frac{1}{m_{dev}} \sum_{i=1}^{m_{dev}} \mathcal{L}\{\hat{y}^{(i)} \neq y^{(i)}\} \quad (2.23)$$

Ağırlıklı sınıflandırma hatası:

$$\frac{1}{wi} \sum_{i=1}^{m_{dev}} wi \mathcal{L}\{\hat{y}_-^{(i)} \neq y^{(i)}\} \quad (2.24)$$

İnsanın hatası ile eğitim seti hatası arasındaki fark bias değerini verirken, eğitim seti ile doğrulama seti arasındaki fark ise varyans değerini vermektedir[148].

2.3.5. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları, çalışmada doğrusal olmayanları da tanımayı hedefler [149].

Sigmoid, tanh, ReLU bu fonksiyonlardandır.

Sınıflandırma problemleri için ReLU aktivasyon fonksiyonu kullanılmıştır. ReLU, negatif değerleri sıfırlar, pozitif değerleri ise değiştirmez.

$$a = \max(0, z) \quad (2.25)$$

Çıkış dense katmanında ise değerleri olasılık dağılımına dönüştürdüğü için softmax aktivasyon fonksiyonu kullanılır.

$$p(y = k|x) = \frac{\exp(o_k(x, w))}{\sum_{t=1}^c \exp(o_t(x, w))} \quad (2.26)$$

2.3.6. Kullanılan derin öğrenme modelleri

A- CNN:

Oluşturulan modellerde parametrelerin artması aşırı uydurmaya sebep olduğu görülmüştür. Bu yüzden parametreleri azaltacak daha basit bir model tanımlanmıştır. Hiper parametrelerin ayarlanması için birçok kez deneme yapılmıştır. Beş sınıf katmanı olduğu için beş dense katmanı eklendi. Veri boyutlarını azaltması için MaxPooling eklendi. Veri seti eşit ancak küçük boyutta olduğu için overfitting olmaması için l2 düzenleme fonksiyonu dense katmanlarına eklendi. Her havuzlama katmanından sonra dropout sinir ağının %20 sini rastgele bırakacak şekilde ayarlandı. Epoch değeri; 30,120, 50 gibi değerler arasından deneme yanılma ile 50 olarak belirlendi. Batch değeri ise deneme yanılma sonucu 3 olarak belirlendi. Kayıp fonksiyonu için çoklu sınıflandırmada kullanılan categorical_crossentropy kullanılmıştır.

Model: "sequential_3"

Layer (type)	Output Shape	Param #
conv1d_8 (Conv1D)	(None, 3760, 64)	256
max_pooling1d_8 (MaxPooling1D)	(None, 1880, 64)	0
dropout_8 (Dropout)	(None, 1880, 64)	0
conv1d_9 (Conv1D)	(None, 1878, 128)	24704
max_pooling1d_9 (MaxPooling1D)	(None, 939, 128)	0
dropout_9 (Dropout)	(None, 939, 128)	0
dense_17 (Dense)	(None, 939, 256)	33024
dense_18 (Dense)	(None, 939, 128)	32896
dense_19 (Dense)	(None, 939, 64)	8256
dense_20 (Dense)	(None, 939, 32)	2080
flatten_3 (Flatten)	(None, 30048)	0
dense_21 (Dense)	(None, 5)	150245
Total params: 251,461		
Trainable params: 251,461		
Non-trainable params: 0		

B- Bidirecitonal-RNN

RNN modelleri için Kaggle’ da bulunan açık kodlardan yararlanılmıştır [150]

Model 1 : "sequential_25"

LSTM hücre değeri 16, dropout ve recurrent dropout değeri 0,2 olarak belirlenmiştir. Dense katmanından sonra yine 0.3 dropout eklenmiştir. Epoch değeri yine deneme yanılma ile 30 olarak belirlenmiştir. Batch değeri deneme yanılma ile bulunmuştur. Aktivasyon için ReLU fonksiyonu tanımlanmıştır. Dense katmanı 5 sınıf olduğu için 5 Dense eklenmiştir, çıkış katmanı için çıktısı 5 olacak şekilde ve çoklu sınıflandırmada kullanılan softmax fonksiyonu kullanılmıştır. Kayıp fonksiyonu için categorical_crossentropy

kullanılmıştır.

Model: "sequential_25"

Layer (type)	Output Shape	Param #
bidirectional_15 (Bidirectional)	(None, 3762, 32)	2304
dense_84 (Dense)	(None, 3762, 16)	528
dropout_12 (Dropout)	(None, 3762, 16)	0
dense_85 (Dense)	(None, 3762, 8)	136
dense_86 (Dense)	(None, 3762, 8)	72
dense_87 (Dense)	(None, 3762, 8)	72
flatten_10 (Flatten)	(None, 30096)	0
dense_88 (Dense)	(None, 5)	150485
Total params: 153,597		
Trainable params: 153,597		
Non-trainable params: 0		

Model 2: "sequential_1":

LSTM hücreleri 128 olarak belirlenmiştir. Epoch 30 belirlenmiştir. LSTM için dropout 0.05 ve recurrent dropout 0,2 seçilmiştir. Dense katmanından sonra yine 0.3 dropout eklenmiştir.

Model: "sequential_1" [150]

Layer (type)	Output Shape	Param #
bidirectional_1 (Bidirectional)	(None, 3762, 256)	133120
dense_5 (Dense)	(None, 3762, 128)	32896
dropout_1 (Dropout)	(None, 3762, 128)	0
dense_6 (Dense)	(None, 3762, 128)	16512
dense_7 (Dense)	(None, 3762, 64)	8256
dense_8 (Dense)	(None, 3762, 64)	4160

flatten_1 (Flatten)	(None, 240768)	0
dense_9 (Dense)	(None, 5)	1203845

=====
Total params: 1,398,789
Trainable params: 1,398,789
Non-trainable params: 0



3. BULGULAR ve TARTIŞMA

3.1. Bulgular ve sınırlar

Veri setinde yanlış etiketleme olmadığı varsayılmıştır. Yaseen ve Kwon, seti kullanılmıştır. Yanlış etiketlenmiş bir veri setindeki hata eğer sistematik ise derin öğrenme modeli üzerinde olumsuz olarak büyük oranda etkileyecektir [151]. Ancak yanlış etiketleme tesadüfi ise derin öğrenme modeli bu tür hatalara karşı oldukça dirençli olduğundan büyük bir problem çıkmayacaktır [152]. Modeller çalışmadan önce veriler karıştırılıp shuffle yapıldığı için başarı oranlarının farklı çıkması ve bazen bir modelin diğer modele göre daha başarılı olması normaldir. Sonuçların değerlendirilmesinde bu durum göz önünde bulundurulmalıdır.

Modelimizin başarısını tam anlamıyla ölçmek için aynı zamanda insan hatasını gözlemlemek gerekir. İnsan hatasının yüzdesi modelimizin gerçekte ne kadar başarılı olduğunu da gösterecektir ancak doktorların kalp hastalıklarının teşhisindeki hata payı ile ilgili yaptığımız araştırmalarda çalışma bulunmamıştır. Çünkü kalp hastalıklarının teşhisinde sadece oskültasyona bakılmamaktadır, EKG gibi sonuçlardan da faydalanılmaktadır. Bu da tam anlamıyla önerilen teşhis metodumuzun ne kadar başarılı olduğunu ölçemeyeceğimiz anlamına gelmektedir [153].

Sınıflandırma raporu:

KARMAŞIKLIK MATRİSİ		Gerçek (Actual) Sonuçlar	
		Pozitif (1)	Negatif (0)
Tahminlenen (Predicted) Sonuçlar	Pozitif (1)	TP [1, 1] True Pozitif	FP [1, 0] False Pozitif
	Negatif (0)	FN [0, 1] False Negatif	TN [0, 0] True Negatif

Şekil 29 Karmaşıklık Matrisi

- Kesinlik (Precision), Gerçek pozitif tahminlerin model tarafından yapılan toplam pozitif tahmin sayısına oranıdır. Tahmin edilen sinyallerin kaçının gerçekte doğru olduğunu ölçer.

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.1)$$

- Duyarlılık (recall), duyarlılık veya gerçek pozitif oran olarak da bilinir. Gerçek-pozitif tahminlerin verilerdeki gerçek pozitif örneklerin toplam sayısına oranıdır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.2)$$

- F1-Skor, hassasiyet ve duyarlılığın birlikte değerlendirilmesini sağlar, ikisinin harmonik ortalamasını alır.

$$F1 = \frac{2 * (hassasiyet) * (duyarlılık)}{hassasiyet + duyarlılık} \quad (3.3)$$

- Support: test veri setinde belirtilen sınıflardan ne kadar olduğunu gösterir.
- Doğruluk(accuracy):

$$\frac{TP + TN}{P + N} \quad (3.4)$$

3.1.1. Hold-out doğrulama

Veri seti, MFCC ile işlenip yüklendikten sonra sklearn kütüphanesinden train split komutu ile veriler karıştırılıp train ve test set olarak %80 %20 ayrılmıştır. Daha sonra da oluşturulan train seti tekrar train ve val seti olarak %80, %20 ayrılmıştır.

Veri setinde hesaplama karışıklığına sebep olacağı düşünüldüğü için segmentasyon yapılmamıştır, MFCC öznitelik çıkarımı dışında farklı bir filtre ve normalleştirme uygulanmamıştır. MFCC öznitelik çıkarımı için num_ceps=24, cep_lifter=23 olarak belirlenmiştir. Öznitelik çıkarımı sonucu verilerin boyutları 3 boyutludur, dizin olarak çıkmıştır. (1000, 3762, 1) şeklindeki datada 1000; ses dosyası adedi, 3762; öznitelik, 1 ses dosyasının tek boyutlu olduğunu gösterir. Bu yüzden 1 boyutlu CNN kullanılmıştır; input (3762,1) olarak belirlenmiştir. Etiketler tensorflow kütüphanesinden one hot encoding yöntemi ile sayısal özelliklere dönüştürülmüştür. Kernel boyutu CNN için 3 olarak belirlenmiştir. 5 sınıf olduğu için 5 dense katmanı kullanılmıştır, son dense katmanında 5 sınıfa ayrılması istendiği için num_class 5 olarak belirlenmiştir. Dense katmanı sayısı ile sınıf sayısının eşit olması gerekir [151]. Optimizasyon için Adam kullanılmıştır.

Bir ağı modellerken 2 önemli husus göz önünde bulundurulmalıdır, kayıp fonksiyonu ve eniyileme algoritması [78]. Kayıp fonksiyonu için çoklu sınıflandırmada kullanılan kategorik çapraz entropi(categorical_crossentropy) kullanılmıştır. Çoklu sınıflandırma olduğu için çıktı katmanında etiketler için olasılık hesabı yapan softmax aktivasyon kullanılmıştır. Funcitonal Api ile de aynı model kullanılsa da istenilen başarı elde edilemediği için Sequential model fonksiyonu kullanılmıştır.

CNN sonuçları


Elde edilen sonuçlara göre, kayıp değerleri artmamış genellikle azalmıştır, aynı zamanda doğruluk değerleri de genellikle artmıştır. Bu sonuçlar overfitting veya underfitting olmadığını göstermektedir. Modelin başarılı olduğu f1 skoru ve tahmin değerleriyle ortaya konulmuştur: loss: 0.0144 - accuracy: 1.0000 - val_loss: 0.1085 - val_accuracy: 0.9625

Modelin test kümesinde F1 skoru tablodaki gibidir. Doğruluk ve kayıp değerleri ise; Test Loss: 0.21741896867752075, Test Accuracy: 0.9350000023841858.


Çıkan değerler modelin oldukça başarılı olduğunu göstermektedir.

Tablo 5 Test seti Sınıflandırma raporu (CNN)

	precision	recall	f1-score	support
AS	0.93	0.93	0.93	44
MR	0.94	0.92	0.93	48
MS	0.88	0.95	0.91	37
MVP	0.95	0.92	0.93	38
Normal	1.00	0.97	0.98	33
accuracy			0.94	200
macro avg	0.94	0.94	0.94	200
weighted avg	0.94	0.94	0.94	200



Şekil 30 Kayıp değerlerinin çizdirilmesi (Train ve Val. Seti CNN)



Şekil 31 Doğruluk değerlerinin çizdirilmesi (Train ve Val. Seti CNN)


RNN sonuçları model 1:

Model, hem eğitim seti, doğrulama seti ve test setlerinin hepsinde uyumlu doğruluk değeri elde etmiştir. Ancak CNN'e göre hesaplama maaliyeti daha büyüktür. Bu yüzden modelde parametreler azaltılmış 153,597 parametre kullanılmıştır. Sınıflandırma raporunda da metriklerin hepsinde %90'nın üzerinde başarı gözlenmiştir.


Modelin test kümesinde F1 skoru tablodaki gibidir. Doğruluk ve kayıp değerleri ise; loss: 0.1860- acc: 0.9500, Test Loss: 0.18596450984477997 Test Accuracy: 0.949999988079071.

Tablo 6 Test seti sınıflandırma raporu (İki yönlü RNN- model1)

	precision	recall	f1-score	support
AS	0.93	0.95	0.94	44
MR	0.96	0.98	0.97	48
MS	0.95	0.95	0.95	37
MVP	0.92	0.95	0.94	38
Normal	1.00	0.91	0.95	33
accuracy			0.95	200
macro avg	0.95	0.95	0.95	200
weighted avg	0.95	0.95	0.95	200



Şekil 32 Kayıp değerlerinin çizdirilmesi (Train ve Val. Seti İki yönlü RNN- model1)



Şekil 33 Doğruluk değerlerinin çizdirilmesi (Train ve Val. Seti İki yönlü RNN- model1)


RNN sonuçları model 2:

Model 2'nin RNN ve dense katmanlarının sayısı modelin karmaşık olmasına sebep olmuş ve hesaplama maaliyeti yükselmiştir. Eğitim ve doğrulama setinin hesaplanmasında model aşırı uydurmaya gidince 13. Adımda erken durdurulmuştur. Val_acc ise 8. Adımdan sonra aynı çıkmaya başlamıştır. Sınıflandırma raporunda da metriklerin hepsinde %90'ın üzerinde başarı gözlenmiştir.


Modelin test kümesinde F1 skoru tablodaki gibidir. Doğruluk ve kayıp değerleri ise; loss: loss: 0.0514 - acc: 0.9700, Test Loss: 0.05137641727924347, Test Accuracy: 0.9700000286102295

Tablo 7 Test seti sınıflandırma raporu (İki yönlü RNN- model1)

	precision	recall	f1-score	support
AS	0.98	0.95	0.97	44
MR	0.98	1.00	0.99	48
MS	0.95	0.97	0.96	37
MVP	0.95	0.92	0.93	38
Normal	1.00	1.00	1.00	33
accuracy			0.97	200
macro avg	0.97	0.97	0.97	200
weighted avg	0.97	0.97	0.97	200



Şekil 34 Kayıp değerlerinin çizdirilmesi (Train ve Val. Seti İki yönlü RNN- model2)



Şekil 35 Doğruluk değerlerinin çizdirilmesi (Train ve Val. Seti İki yönlü RNN- model2)

3.1.2. CNN k-fold çapraz doğrulama sonuçları

Verinin kümelerle ayrıştırılmadan önce karıştırılması gerekir. Böylece veri seti her çalıştırmada farklı şekilde kümelendir. Bu da metrik sonuçlarının her çalıştırmada farklı çıkabilmesine sebep olur. Bu sebeple öncelikle data test seti (%20) ve çaprazlama seti (%80) olarak ikiye ayrılır. Daha sonra çaprazlama seti için ayrılan set üzerinde k fold çapraz doğrulama yapılır sonrasında test veri seti dışındaki verilerin hepsi model.fit denilerek eğitilir. Sonrasında ayrılan test seti üzerinde model tahmini ve hesaplaması yapılır. RNN modelleri için çapraz doğrulama hesaplama karışıklığından dolayı yapılamamıştır. RNN Çapraz doğrulama sonuçları daha farklı çıkabilir.

Validation seti doğrulama skoru: [0.9125000238418579, 0.9312499761581421, 0.90625, 0.9624999761581421, 0.9312499761581421]

Ortalama Validation doğrulama skoru: Avg. accuracy score:0.9287499904632568

Test seti doğruluk ve karmaşıklık matrisi değerleri: loss: 0.1082 - accuracy: 0.9800

Test Loss: 0.10823376476764679, Test Accuracy: 0.9800000190734863

Tablo 8 Test seti CNN sınıflandırma raporu

	precision	recall	f1-score	support
AS	1.00	0.95	0.98	44
MR	1.00	1.00	1.00	48
MS	1.00	0.95	0.97	37
MVP	0.90	1.00	0.95	38
Normal	1.00	1.00	1.00	33
accuracy			0.98	200
macro avg	0.98	0.98	0.98	200
weighted avg	0.98	0.98	0.98	200

5 katlı çapraz doğrulama sonucu overfitting olmadığını ve başarılı olduğunu göstermektedir.

3.2. Sınıflandırıcıların karşılaştırılması ve öneriler

CNN ve RNN modellerinden oluşan 3 modele baktığımızda hepsinin başarılı olduğunu söyleyebiliriz. Hold-out metoduna göre en başarılı model RNN model 2 olmaktadır ancak kısa sürede aşırı uydurmaya gitmiştir. En büyük doğruluk ve F1 skoruna sahiptir. Sonra ise RNN model 1 gelmektedir. Elde edilen sonuçlarda RNN modellerinin daha başarılı olduğu gözlenmiştir. Ancak sınıflandırıcılar çalıştırılırken shuffle edilip çalıştırılmıştır. Veri setinin karıştırılması, sınıflandırıcıların farklı çalıştırmalarda farklı sonuçlar elde etmesini sağlar. Bu yüzden kıyaslanmada hangisinin daha başarılı olduğu konusunda kesinlik yoktur.

RNN modellerinin hesaplamasının maliyetli ve CNN'e göre daha kolay başarı gösteren model olduğu sonucuna varılmıştır. Başarılı CNN modelini bulmak ise RNN'e göre daha fazla vakit almıştır. Bu çalışmada bölütleme(segmentasyon) yapılmamıştır. İleriki çalışmalarda segmentasyonun sınıflandırıcılara etkisi gözlemlenebilir. Daha büyük bir veri setinde önerdiğimiz metodun başarısı ölçülebilir. Hesaplama karmaşıklığından dolayı sadece CNN için 5 katlı çapraz doğrulama kullanılmıştır. RNN modelleri için 5 katlı çapraz doğrulama yapılırsa sonuçlar değişkenlik gösterebilir.

3.3. Tartışma

Tablo 9 Yaseen ve Kwon veri setiyle yapılan çalışmalar [74]

Yazarlar	Veri Seti	Özellik çıkarma yöntemleri	Sınıflandırıcı	Acc. (%)
Yaseen ve Kwon (2018)	Kendi veri kümesi	MFCC'ler ve DWT özellikleri	SVM	97.9
Ghosh ve ark. (2019)	Yaseen ve Kwon (2018) veri seti	büyüklik ve faz özellikleri	RF	95.13
Zeng ve ark. (2021b)	Yaseen ve Kwon (2018) veri seti	Ayarlanabilir Q faktörü dalgacık dönüşümü	Derin Dalga-cık	98.48
Arslan Ö. ve Karhan M.	Yaseen ve Kwon (2018) veri seti	EMD'ye dayalı MFCC'ler	SVM	96.2

Arslan Ö. ve Karhan M.	Yaseen ve Kwon (2018) veri seti	EMD'ye dayalı MFCC'ler	DNN	98.9
Bu çalışma	Yaseen ve Kwon (2018) veri seti	FrFT tabanlı MFCC	CNN	93.5 98
Bu çalışma	Yaseen ve Kwon (2018) veri seti	FrFT tabanlı MFCC	RNN Model1	95
Bu çalışma	Yaseen ve Kwon (2018) veri seti	FrFT tabanlı MFCC	RNN2 Model2	97

Tablo-9’da görüldüğü üzere bu çalışmada önerilen yöntem, başarılı olmuştur. Aynı zamanda belirtilen doğruluk oranları, FrFT’yi kullanan Zaid A. Ve ark., PhysioNet/Computing in Cardiology Challenge 2016 veri seti üzerinde elde ettiği (0,9550 doğruluk) oranına benzerdir [8]. Bu da önerilen metodun başarılı olduğunu göstermektedir. Veri setinin dağılımı, bias değerleri, hiper parametre ayarları, Batch ve Epoch değerleri değiştikçe sınıflandırıcıların başarı oranlarında değişiklikler olacaktır. Sonuçlar değerlendirilirken bu durumlar göz önünde bulundurulmalıdır. Çapraz doğrulama yapıldığında RNN sonuçları daha doğru değerler verecektir.

4. SONUÇ

FrFT tabanlı MFCC özelliklerinin, geleneksel MFCC' ye göre daha yüksek çözünürlüklü frekans spektrumları elde etme potansiyeli, ses işleme ve konuşma tanıma gibi alanlarda önemli avantajlar sunabilir. Bu çalışmada, geleneksel ve modern sinyal işleme tekniklerinin birleştirilerek, ses verilerini daha etkili bir şekilde temsil etmek ve derin öğrenme modellerinin performansını artırmak için FrFT tabanlı MFCC özellikleri önerilmiştir.

Elde edilen bulgular, FrFT tabanlı MFCC özelliklerinin, bazı durumlarda geleneksel MFCC 'ye göre daha iyi performans gösterdiğini ortaya koymaktadır. Bu durum, ses verilerinin frekans alanında daha ayrıntılı bir şekilde temsil edilmesinin, modelin sesleri daha iyi ayırt etme ve tanıma yeteneğini artırdığını göstermektedir.

Sonuç olarak, bu çalışma, ses işleme ve konuşma tanıma gibi alanlarda ses verilerinin daha etkili bir şekilde temsil edilmesi ve derin öğrenme modellerinin performansının artırılması açısından önemli bir potansiyel taşıdığını göstermektedir. FrFT tabanlı MFCC özelliklerinin ve derin öğrenme modellerinin kullanımı ses işleme alanında daha iyi performans elde etmeye yönelik önemli bir seçenek olduğunu göstermektedir.

KAYNAKÇA

- [1] Yaseen, S. Gui-Young, ve S. Kwon, “Classification of Heart Sound Signal Using Multiple Features”, *Applied Sciences*, c. 8, sy 12, Ara. 2018, doi: 10.3390/app8122344.
- [2] G. Çelebi, “Sayısal Stetoskop ile Elde Edilen Kalp Ses (Fonokardiyogram) Sinyallerinin Bölütlenmesi ve Sınıflandırılması”, Fen Bilimleri Enstitüsü, 2017.
- [3] J. Vepa, “Classification of heart murmurs using cepstral features and support vector machines”, içinde *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Minneapolis, MN: IEEE, Eyl. 2009, ss. 2539-2542. doi: 10.1109/IEMBS.2009.5334810.
- [4] C. Potes, S. Parvaneh, A. Rahman, ve B. Conroy, “Ensemble of feature-based and deep learning-based classifiers for detection of abnormal heart sounds”, içinde *2016 Computing in Cardiology Conference (CinC)*, Eyl. 2016, ss. 621-624.
- [5] Jonathan Rubin, Rui Abreu, Saigopal Nelaturi, Ion Matei, ve Kumar Sricharan, “Classifying heart sound recordings using deep convolutional neural networks and mel-frequency cepstral coefficients | IEEE Conference Publication | IEEE Xplore”, Mar. 2017, Erişim: 29 Temmuz 2023. [Çevrimiçi]. Erişim adresi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/document/7868867>
- [6] V. Nivitha Varghees ve K. I. Ramachandran, “Effective Heart Sound Segmentation and Murmur Classification Using Empirical Wavelet Transform and Instantaneous Phase for Electronic Stethoscope”, *IEEE Sensors J.*, c. 17, sy 12, ss. 3861-3872, Haz. 2017, doi: 10.1109/JSEN.2017.2694970.
- [7] B. Bozkurt, I. Germanakis, ve Y. Stylianou, “A study of time-frequency features for CNN-based automatic heart sound classification for pathology detection”, *Computers in Biology and Medicine*, c. 100, ss. 132-143, Eyl. 2018, doi: 10.1016/j.compbiomed.2018.06.026.
- [8] Z. Abduh, E. A. Nehary, M. A. Wahed, ve Y. M. Kadah, “Classification of Heart Sounds Using Fractional Fourier Transform Based Mel-Frequency Spectral Coefficients and Stacked Autoencoder Deep Neural Network”, *Journal of Medical Imaging and Health Informatics*, c. 9, sy 1, ss. 1-8, Oca. 2019, doi: 10.1166/jmihi.2019.2568.
- [9] M. Ferdoushi, M. Paul, ve S. A. Fattah, “A Spectral Centroid Based Analysis of Heart sounds for Disease Detection Using Machine Learning”, içinde *2019 IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE)*, Bangalore, India: IEEE, Kas. 2019, ss. 1-6. doi: 10.1109/WIECON-ECE48653.2019.9019975.
- [10] M. Deng, T. Meng, J. Cao, S. Wang, J. Zhang, ve H. Fan, “Heart sound classification based on improved MFCC features and convolutional recurrent neural networks”, *Neural Networks*, c. 130, ss. 22-32, Eki. 2020, doi: 10.1016/j.neunet.2020.06.015.
- [11] A. Raza, A. Mehmood, S. Ullah, M. Ahmad, G. S. Choi, ve B.-W. On, “Heartbeat Sound Signal Classification Using Deep Learning”, *Sensors*, c. 19, sy 21, Art. sy 21,

Oca. 2019, doi: 10.3390/s19214819.

- [12] D. S. B. Sundaram, S. Shivaram, R. Balasubramani, A. Muthyala, ve S. P. Arunachalam, “Robust Discrimination of Phonocardiogram Signal with Normal Heart Sounds and Murmur Using a Multiscale Frequency Analysis”, içinde *2019 IEEE Healthcare Innovations and Point of Care Technologies, (HI-POCT)*, Kas. 2019, ss. 107-110. doi: 10.1109/HI-POCT45284.2019.8962884.
- [13] “Multi-class Heart Sounds Classification Using 2D-Convolutional Neural Network | IEEE Conference Publication | IEEE Xplore”. <https://ieeexplore.ieee.org/document/9277204> (erişim 23 Eylül 2022).
- [14] B. Xiao, Y. Xu, X. Bi, J. Zhang, ve X. Ma, “Heart sounds classification using a novel 1-D convolutional neural network with extremely low parameter consumption”, *Neurocomputing*, c. 392, ss. 153-159, Haz. 2020, doi: 10.1016/j.neucom.2018.09.101.
- [15] T. Feng, H. Tang, M. Wang, C. Zhang, H. Wang, ve F. Cong, “Continuous Estimation of Left Ventricular Hemodynamic Parameters Based on Heart Sound and PPG Signals Using Deep Neural Network”, içinde *2020 International Conference on Sensing, Measurement & Data Analytics in the era of Artificial Intelligence (ICSMD)*, Eki. 2020, ss. 313-318. doi: 10.1109/ICSMD50554.2020.9261681.
- [16] S. B. Shuvo, S. N. Ali, S. I. Swapnil, M. S. Al-Rakhami, ve A. Gumaei, “CardioXNet: A Novel Lightweight Deep Learning Framework for Cardiovascular Disease Classification Using Heart Sound Recordings”, *IEEE Access*, c. 9, ss. 36955-36967, 2021, doi: 10.1109/ACCESS.2021.3063129.
- [17] K. A. Babu, B. Ramkumar, ve M. S. Manikandan, “Automatic Identification of S1 and S2 Heart Sounds Using Simultaneous PCG and PPG Recordings”, *IEEE Sensors Journal*, c. 18, sy 22, ss. 9430-9440, Kas. 2018, doi: 10.1109/JSEN.2018.2869416.
- [18] M. Anumukonda, P. R. Lakkamraju, ve S. R. Chowdhury, “Classification of Abnormal and Normal Heart Sounds Using the MEMS based High Performance Phono-CardioGraphy System”, içinde *2020 International Conference on Artificial Intelligence and Signal Processing (AISP)*, Oca. 2020, ss. 1-7. doi: 10.1109/AISP48273.2020.9073020.
- [19] A. Lorena, A. Blanco, M. Weger, S. Grautoff, R. Höldrich, ve T. Hermann, *CardioScope: ECG sonification and auditory augmentation of heart sounds to support cardiac diagnostic and monitoring*. 2019.
- [20] H. Ren, H. Jin, C. Chen, H. Ghayvat, ve W. Chen, “A Novel Cardiac Auscultation Monitoring System Based on Wireless Sensing for Healthcare”, *IEEE Journal of Translational Engineering in Health and Medicine*, c. 6, ss. 1-12, Oca. 2018, doi: 10.1109/JTEHM.2018.2847329.
- [21] H. Mondal, S. Mondal, ve K. Saha, “Development of a Low-Cost Wireless Phonocardiograph With a Bluetooth Headset under Resource-Limited Conditions”, *Medical Sciences*, c. 6, sy 4, Art. sy 4, Ara. 2018, doi: 10.3390/medsci6040117.
- [22] S.-Y. Lee, P.-W. Huang, J.-R. Chiou, C. Tsou, Y.-Y. Liao, ve J.-Y. Chen, “Electrocardiogram and Phonocardiogram Monitoring System for Cardiac Auscultation”, *IEEE Transactions on Biomedical Circuits and Systems*, c. 13, sy 6, ss. 1471-1482,

Ara. 2019, doi: 10.1109/TBCAS.2019.2947694.

- [23] S.-C. Lai, P.-C. Tail, M.-K. Lee, S.-F. Lei, ve C.-H. Luo, “Prototype System Design of ECG Signal Acquisition with Lossless Data Compression Algorithm Applied for Smart Devices”, içinde *2018 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW)*, Taichung: IEEE, May. 2018, ss. 1-2. doi: 10.1109/ICCE-China.2018.8448842.
- [24] E. Talab, O. Mohamed, L. Begum, F. Aloul, ve A. Sagahyroon, “Detecting Heart Anomalies Using Mobile Phones and Machine Learning”, içinde *2019 IEEE 19th International Conference on Bioinformatics and Bioengineering (BIBE)*, Athens, Greece: IEEE, Eki. 2019, ss. 428-432. doi: 10.1109/BIBE.2019.00083.
- [25] C. Aguilera-Astudillo, M. Chavez-Campos, A. Gonzalez-Suarez, ve J. L. Garcia-Cordero, “A low-cost 3-D printed stethoscope connected to a smartphone”, içinde *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Orlando, FL, USA: IEEE, Ağu. 2016, ss. 4365-4368. doi: 10.1109/EMBC.2016.7591694.
- [26] N. S. Rajjliwal ve G. Chetty, “Deep Learning Based Decision Support Framework for Cardiovascular Disease Prediction”, içinde *2021 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)*, Brisbane, Australia: IEEE, Ara. 2021, ss. 1-12. doi: 10.1109/CSDE53843.2021.9718459.
- [27] P. Wang vd., “A Wearable ECG Monitor for Deep Learning Based Real-Time Cardiovascular Disease Detection”, Oca. 2022, doi: 10.48550/arXiv.2201.10083.
- [28] S. Harjai ve S. K. Khatri, “An Intelligent Clinical Decision Support System Based on Artificial Neural Network for Early Diagnosis of Cardiovascular Diseases in Rural Areas”, içinde *2019 Amity International Conference on Artificial Intelligence (AICAI)*, Dubai, United Arab Emirates: IEEE, Şub. 2019, ss. 729-736. doi: 10.1109/AICAI.2019.8701237.
- [29] K. Ranipa, W.-P. Zhu, ve M. N. S. Swamy, “Multimodal CNN Fusion Architecture with Multi-Features for Heart Sound Classification”, içinde *2021 IEEE International Symposium on Circuits and Systems (ISCAS)*, Daegu, Korea: IEEE, May. 2021, ss. 1-5. doi: 10.1109/ISCAS51556.2021.9401551.
- [30] Z. Li, Y. Chang, ve B. W. Schuller, “CNN-Based Heart Sound Classification with an Imbalance-Compensating Weighted Loss Function”, içinde *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Glasgow, Scotland, United Kingdom: IEEE, Tem. 2022, ss. 4934-4937. doi: 10.1109/EMBC48229.2022.9871904.
- [31] M. M, R. S, F. A, ve R. K. E, “Phonocardiography-based mitral valve prolapse detection with using fractional fourier transform”, *Biomedical physics & engineering express*, c. 7, sy 1, Kas. 2020, doi: 10.1088/2057-1976/abcaab.
- [32] “Classification of heart sounds using fractional fourier transform based mel-frequency spectral coefficients and traditional classifiers”, *Biomedical Signal Processing and Control*, c. 57, s. 101788, Mar. 2020, doi: 10.1016/j.bspc.2019.101788.
- [33] A. K. Dwivedi, S. A. Imtiaz, ve E. Rodriguez-Villegas, “Algorithms for Automatic Analysis and Classification of Heart Sounds—A Systematic Review”, *IEEE Access*,

- c. 7, ss. 8316-8345, 2019, doi: 10.1109/ACCESS.2018.2889437.
- [34] U. F. O. Themes, “Cardiac Anatomy, Physiology, and Imaging Modalities”, *Radio-logy Key*, 29 Ağustos 2016. <https://radiologykey.com/cardiac-anatomy-physiology-and-imaging-modalities/> (erişim 26 Temmuz 2023).
- [35] K. L. Moore ve A. F. Dalley, *Clinically Oriented Anatomy*. Wolters kluwer india Pvt Ltd, 2018.
- [36] Andrew R. Marks, “Cardiac and Circulatory Function”, içinde *Goldman-Cecil Me-dicine*, Elsevier, 2020, ss. 241-245. e3. Erişim: 05 Kasım 2022. [Çevrimiçi]. Erişim adresi: <https://1da29564ffc94212c5733ac3ef259e6b1ca3e3c0.vetison-line.com/#!/content/book/3-s2.0-B9780323532662000473?scrollTo=%23hl0000236>
- [37] Jane W. Ball DrPH, RN, CPNP, Joyce E. Dains DrPH, JD, APRN, FNP- BC, FNAP, FAANP, FAAN, John A. Flynn MD, MBA, MEd, Barry S. Solomon MD, MPH and Rosalyn W. Stewart MD, MS, MBA, “Seidel’s Guide to Physical Examination: An Interprofessional Approach”, 10. bsElsevier, 2023, ss. 326-363. Erişim: 31 Ekim 2022. [Çevrimiçi]. Erişim adresi: <https://1da29564ffc94212c5733ac3ef259e6b1ca3e3c0.vetisonline.com/#!/con-tent/book/3-s2.0-B9780323761833000152?scrollTo=%23hl0002053>
- [38] George Bojanov, “Blood Pressure, Heart Tones, and Diagnoses”, içinde *Handbook of Cardiac Anatomy, Physiology and Devices*, 2009, ss. 243-255. Erişim: 31 Ekim 2022. [Çevrimiçi]. Erişim adresi: https://745e9234ede24d509e2ae15e4d48ef6be2b3b85c.vetisonline.com/chap-ter/10.1007/978-3-319-19464-6_18
- [39] Alicia Armour, “Understanding Hemodynamics”, içinde *Textbook of Diagnostic So-nography*, Elsevier, 2023, ss. 908-915. Erişim: 14 Kasım 2022. [Çevrimiçi]. Erişim adresi: <https://1da29564ffc94212c5733ac3ef259e6b1ca3e3c0.vetison-line.com/#!/content/book/3-s2.0-B9780323826464000317?scrollTo=%23hl0000272>
- [40] S. B. system, “The Cardiac Cycle | Wigger’s diagram | Geeky Medics”, 07 Mayıs 2022. <https://geekymedics.com/the-cardiac-cycle/> (erişim 11 Kasım 2022).
- [41] Linda S. Costanzo PhD, “Cardiovascular physiology”, içinde *Costanzo Physiology*, Elsevier, 2022, ss. 119-194. Erişim: 14 Kasım 2022. [Çevrimiçi]. Erişim adresi: <https://1da29564ffc94212c5733ac3ef259e6b1ca3e3c0.vetisonline.com/#!/con-tent/book/3-s2.0-B9780323793339000134?scrollTo=%23hl0004298>
- [42] J. W. B. R. D. CPNP, J. E. D. D. J. A. F. B. F. F. FAAN, J. A. F. M. M. MEd, B. S. S. M. MPH, ve R. W. S. M. M. MBA, *Seidel’s Guide to Physical Examination: An Interprofessional Approach*, 9th edition. St. Louis, Missouri: Mosby, 2018.
- [43] Andrew R. Marks, “Cardiac and Circulatory Function”, içinde *Goldman-Cecil Me-dicine*, Elsevier, 2020, ss. 241-245. e3. Erişim: 05 Kasım 2022. [Çevrimiçi]. Erişim adresi: <https://1da29564ffc94212c5733ac3ef259e6b1ca3e3c0.vetison-line.com/#!/content/book/3-s2.0-B9780323532662000473?scrollTo=%23hl0000236>
- [44] A. J. Weinhaus, “Anatomy of the Human Heart”, içinde *Handbook of Cardiac*

- Anatomy, Physiology, and Devices*, P. A. Iaizzo, Ed., Cham: Springer International Publishing, 2015, ss. 61-88. doi: 10.1007/978-3-319-19464-6_5.
- [45] “Prof. Dr. Ahmet Akgül - Kalbimizin Yapısı”. <https://www.ahmetakgul.com.tr/index.php/uzmanliklar/kalp-hastaliklari/317-kalbimizin-yapisi> (erişim 23 Eylül 2022).
- [46] “Thorax - 3D Interactive Anatomy Tutorials”, *AnatomyZone*. <https://anatomy-zone.com/thorax/> (erişim 23 Eylül 2022).
- [47] John T. Hansen PhD, “Introduction to the Human Body”, içinde *Netter’s Clinical Anatomy*, Elsevier, 2019, ss. 1-49. Erişim: 23 Eylül 2022. [Çevrimiçi]. Erişim adresi: <https://1da29564ffc94212c5733ac3ef259e6b1ca3e3c0.vetisonline.com/#!/content/book/3-s2.0-B9780323531887000020?scrollTo=%23hl0001307>
- [48] S. A. Singh, T. G. Meitei, ve S. Majumder, “6 - Short PCG classification based on deep learning”, içinde *Deep Learning Techniques for Biomedical and Health Informatics*, B. Agarwal, V. E. Balas, L. C. Jain, R. C. Poonia, ve Manisha, Ed., Academic Press, 2020, ss. 141-164. doi: 10.1016/B978-0-12-819061-6.00006-9.
- [49] N. Ranganathan, V. Sivaciyan, ve F. B. Saksena, “Heart Sounds”, içinde *The Art and Science of Cardiac Physical Examination: With Heart Sounds and Pulse Wave Forms on CD*, N. Ranganathan, V. Sivaciyan, ve F. B. Saksena, Ed., içinde Contemporary Cardiology. Totowa, NJ: Humana Press, 2007, ss. 141-210. doi: 10.1007/978-1-59745-023-2_6.
- [50] Mark H. Swartz, “The Heart”, içinde *Textbook of Physical Diagnosis: History and Examination*, Elsevier, 2021, ss. 14, 293-326. Erişim: 09 Kasım 2022. [Çevrimiçi]. Erişim adresi: <https://1da29564ffc94212c5733ac3ef259e6b1ca3e3c0.vetisonline.com/#!/content/book/3-s2.0-B9780323672924000140?scrollTo=hl0001109>
- [51] G. N. Salvatore Mangione, “Heart Murmurs and Sounds”, içinde *Cardiology Secrets*, Elsevier Health Sciences, 2018, ss. 11-21.
- [52] C. Ahlström, “Nonlinear phonocardiographic Signal Processing”, 2008, Erişim: 01 Aralık 2022. [Çevrimiçi]. Erişim adresi: <http://urn.kb.se/resolve?urn=urn:nbn:se:liu:diva-11302>
- [53] X.-Y. Zhang, E. MacPherson, ve Y.-T. Zhang, “Relations between the timing of the second heart sound and aortic blood pressure”, *IEEE Trans Biomed Eng*, c. 55, sy 4, ss. 1291-1297, Nis. 2008, doi: 10.1109/TBME.2007.912422.
- [54] X. Yang ve W. Zeng, “A relative value method for measuring and evaluating neonatal cardiac reserve”, *Indian J Pediatr*, c. 77, sy 6, ss. 661-664, Haz. 2010, doi: 10.1007/s12098-010-0058-5.
- [55] Salvatore Mangione MD, Peter D. Sullivan MD, ve Michael S. Wagner MD, “The Cardiovascular Exam - ClinicalKey”, içinde *Physical Diagnosis Secrets*, 3. bsElsevier, 2021, ss. 211-29. Erişim: 14 Kasım 2022. [Çevrimiçi]. Erişim adresi: <https://1da29564ffc94212c5733ac3ef259e6b1ca3e3c0.vetisonline.com/#!/content/book/3-s2.0-B9780323263368000102?scrollTo=%23hl0002060>
- [56] D. S. M. Amin ve B.-R. Fethi, “Features for Heartbeat Sound Signal Normal and

- Pathological”, *Recent Patents on Computer Science*, c. 1, sy 1, ss. 1-8, Oca. 2008.
- [57] S. Ari, P. Kumar, ve G. Saha, “A robust heart sound segmentation algorithm for commonly occurring heart valve diseases”, *J Med Eng Technol*, c. 32, sy 6, ss. 456-465, Ara. 2008, doi: 10.1080/03091900601015162.
- [58] *Phonocardiography Signal Processing*. Erişim: 05 Aralık 2022. [Çevrimiçi]. Erişim adresi: <https://link.springer.com/book/10.1007/978-3-031-01637-0>
- [59] S. H. Shaikh Salleh vd., “Key Techniques and Challenges for Processing of Heart Sound Signals”, içinde *Applied Intelligence and Informatics*, Springer, Cham, 2021, ss. 136-149. Erişim: 29 Kasım 2022. [Çevrimiçi]. Erişim adresi: https://link.springer.com/chapter/10.1007/978-3-030-82269-9_11
- [60] A. Moukadem, A. Dieterlen, C. Brandt, A. Moukadem, A. Dieterlen, ve C. Brandt, *Phonocardiogram Signal Processing Module for Auto-Diagnosis and Telemedicine Applications*. IntechOpen, 2012. doi: 10.5772/48447.
- [61] “Analysis of PCG signals using quality assessment and homomorphic filters for localization and classification of heart sounds”, *Computer Methods and Programs in Biomedicine*, c. 164, ss. 143-157, Eki. 2018, doi: 10.1016/j.cmpb.2018.07.006.
- [62] N. Giordano ve M. Knaflitz, “Multi-source signal processing in phonocardiography: comparison among signal selection and signal enhancement techniques”, içinde *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Berlin, Germany: IEEE, Tem. 2019, ss. 6689-6692. doi: 10.1109/EMBC.2019.8856725.
- [63] “A critical review of heart sound signal segmentation algorithms”, *Smart Health*, c. 24, s. 100283, Haz. 2022, doi: 10.1016/j.smhl.2022.100283.
- [64] L. N. Sharma, “Multiscale analysis of heart sound for segmentation using multiscale Hilbert envelope”, içinde *2015 13th International Conference on ICT and Knowledge Engineering (ICT & Knowledge Engineering 2015)*, Kas. 2015, ss. 33-37. doi: 10.1109/ICTKE.2015.7368467.
- [65] A. W. Setiawan ve W. Sujatmiko, “Comparison of Fetal Heart Rate Detection Using Envelope Extraction and Shannon Energy”, içinde *2019 International Seminar on Application for Technology of Information and Communication (iSemantic)*, Semarang, Indonesia: IEEE, Eyl. 2019, ss. 446-449. doi: 10.1109/ISEMAN-TIC.2019.8884227.
- [66] “Segmentation of heart sounds based on dynamic clustering”, *Biomedical Signal Processing and Control*, c. 7, sy 5, ss. 509-516, Eyl. 2012, doi: 10.1016/j.bspc.2011.09.002.
- [67] M. K. Ahirwal, A. Kumar, ve G. K. Singh, “Biomedical Signals”, içinde *Computational Intelligence and Biomedical Signal Processing*, Springer International Publishing, 2021, ss. 1-20. Erişim: 29 Kasım 2022. [Çevrimiçi]. Erişim adresi: https://link.springer.com/chapter/10.1007/978-3-030-67098-6_1
- [68] B. S. Emmanuel, “A review of signal processing techniques for heart sound analysis in clinical diagnosis”, *Journal of Medical Engineering & Technology*, c. 36, sy 6, ss. 303-307, Ağu. 2012, doi: 10.3109/03091902.2012.684831.

- [69] C. da Costa, M. Kashiwagi, ve M. H. Mathias, “Rotor failure detection of induction motors by wavelet transform and Fourier transform in non-stationary condition”, *Case Studies in Mechanical Systems and Signal Processing*, c. 1, ss. 15-26, Tem. 2015, doi: 10.1016/j.csmssp.2015.05.001.
- [70] “Fractional Fourier transform: Time-frequency representation and structural instantaneous frequency identification”, *Mechanical Systems and Signal Processing*, c. 178, s. 109305, Eki. 2022, doi: 10.1016/j.ymssp.2022.109305.
- [71] François Chollet, *Python ile Derin Öğrenme « Buzdağı Yayınevi*.
- [72] Z. Abduh, E. A. Nehary, M. Abdel Wahed, ve Y. M. Kadah, “Classification of heart sounds using fractional fourier transform based mel-frequency spectral coefficients and traditional classifiers”, *Biomedical Signal Processing and Control*, c. 57, s. 101788, Mar. 2020, doi: 10.1016/j.bspc.2019.101788.
- [73] “Improving Deep Neural Networks: Hyperparameter Tuning, Regularization and Optimization - Practical Aspects of Deep Learning - Week 1”, *Coursera*. <https://www.coursera.org/learn/deep-neural-network/home/welcome> (erişim 23 Haziran 2023).
- [74] Ö. Arslan ve M. Karhan, “Effect of Hilbert-Huang transform on classification of PCG signals using machine learning”, *Journal of King Saud University - Computer and Information Sciences*, Oca. 2022, doi: 10.1016/j.jksuci.2021.12.019.
- [75] H. Fayek, “Speech Processing for Machine Learning: Filter banks, Mel-Frequency Cepstral Coefficients (MFCCs) and What’s In-Between”, *Haytham Fayek*, 21 Nisan 2016. <https://haythamfayek.com/2016/04/21/speech-processing-for-machine-learning.html> (erişim 24 Temmuz 2023).
- [76] “Environmentally robust ASR front-end for deep neural network acoustic models”, *Computer Speech & Language*, c. 31, sy 1, ss. 65-86, May. 2015, doi: 10.1016/j.csl.2014.11.008.
- [77] Prajoy Podder, Tanvir Zaman Khan, ve Mamdudul Haque Khan, “Comparative Performance Analysis of Hamming, Hanning and Blackman Window”, *International Journal of Computer Applications (0975 – 8887) Volume 96– No.18*, Haz. 2014.
- [78] François Chollet, *Python ile Derin Öğrenme*, 1. Eryaman/Ankara: Buzdağı Yayınevi, 2019.
- [79] *Whether to use End-to-end Deep Learning*. Erişim: 22 Haziran 2023. [Çevrimiçi Video]. Erişim adresi: <https://www.coursera.org/learn/machine-learning-projects/home/welcome>
- [80] “Fractional Fourier transform as a signal processing tool: An overview of recent developments”, *Signal Processing*, c. 91, sy 6, ss. 1351-1369, Haz. 2011, doi: 10.1016/j.sigpro.2010.10.008.
- [81] C. Zhu, Y. Sun, ve C. Pan, “Speech Enhancement with Fractional Fourier Transform”, içinde *2022 21st International Symposium on Communications and Information Technologies (ISCIT)*, Xi’an, China: IEEE, Eyl. 2022, ss. 296-302. doi: 10.1109/ISCIT55906.2022.9931218.
- [82] “The fractional Fourier transform as a biomedical signal and image processing tool:

- A review”, *Biocybernetics and Biomedical Engineering*, c. 40, sy 3, ss. 1081-1093, Tem. 2020, doi: 10.1016/j.bbe.2020.05.004.
- [83] Lian Lu ve Wei-Xin ren, “Fractional Fourier transform: Time-frequency representation and structural instantaneous frequency identification”, *Mechanical Systems and Signal Processing*, c. 178, s. 109305, Eki. 2022, doi: 10.1016/j.ymssp.2022.109305.
- [84] “Analysis of photoplethysmogram signal to estimate heart rate during physical activity using fractional fourier transform – A sampling frequency independent and reference signal-less method”, *Computer Methods and Programs in Biomedicine*, c. 229, s. 107294, Şub. 2023, doi: 10.1016/j.cmpb.2022.107294.
- [85] “ISAR imaging of target with complex motion associated with the fractional Fourier transform”, *Digital Signal Processing*, c. 83, ss. 332-345, Ara. 2018, doi: 10.1016/j.dsp.2018.09.012.
- [86] “Sampling expansion for irregularly sampled signals in fractional Fourier transform domain”, *Digital Signal Processing*, c. 34, ss. 74-81, Kas. 2014, doi: 10.1016/j.dsp.2014.08.004.
- [87] P. K. Anh, L. P. Castro, P. T. Thao, ve N. M. Tuan, “New sampling theorem and multiplicative filtering in the FRFT domain”, *SIViP*, c. 13, sy 5, ss. 951-958, Tem. 2019, doi: 10.1007/s11760-019-01432-5.
- [88] H. M. Ozaktas ve M. A. Kutay, “The fractional fourier transform”, içinde *2001 European Control Conference (ECC)*, Porto: IEEE, Eyl. 2001, ss. 1477-1483. doi: 10.23919/ECC.2001.7076127.
- [89] “Biomedical signal detection based on fractional fourier transform | IEEE Conference Publication | IEEE Xplore”. <https://ieeexplore.ieee.org/abstract/document/4570600/> (erişim 24 Temmuz 2023).
- [90] C. Guerrero-Mosquera, M. Verleysen, ve A. N. Vazquez, “EEG feature selection using mutual information and support vector machine: A comparative analysis”, içinde *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*, Ağu. 2010, ss. 4946-4949. doi: 10.1109/IEMBS.2010.5627239.
- [91] S. R. Subramaniam, T. K. Hon, A. Georgakis, ve G. Papadakis, “Fractional fourier-based filter for denoising elastograms”, içinde *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*, Ağu. 2010, ss. 4028-4031. doi: 10.1109/IEMBS.2010.5628095.
- [92] R. Iwai ve H. Yoshimura, “A New Method for Improving Robustness of Registered Fingerprint Data Using the Fractional Fourier Transform”, *International Journal of Communications, Network and System Sciences*, c. 3, sy 9, Art. sy 9, Eyl. 2010, doi: 10.4236/ijcns.2010.39096.
- [93] R. Iwai ve H. Yoshimura, “New method for increasing matching accuracy and reducing process time of fingerprint data by the fractional Fourier transform”, içinde *2010 IEEE International Conference on Image Processing*, Eyl. 2010, ss. 3061-3064. doi: 10.1109/ICIP.2010.5654171.
- [94] R. Iwai ve H. Yoshimura, “Matching Accuracy Analysis of Fingerprint Templates

Generated by Data Processing Method Using the Fractional Fourier Transform”, *International Journal of Communications, Network and System Sciences*, c. 4, sy 1, Art. sy 1, Oca. 2011, doi: 10.4236/ijcns.2011.41003.

- [95] R. Iwai ve H. Yoshimura, “Accuracy Analysis in Fingerprint Authentication Using the Fractional Fourier Transform without Misalignment Correction of Scanned Images”, *International Journal of Communications, Network and System Sciences*, c. 5, sy 3, Art. sy 3, Mar. 2012, doi: 10.4236/ijcns.2012.53022.
- [96] I. Rizwan-i-Haque, M. F. Khan, M. Saleem, ve N. I. Rao, “Network weight adjustment in a fractional fourier transform based multi-channel brain computer interface for person authentication”, içinde *2012 11th International Conference on Information Science, Signal Processing and their Applications (ISSPA)*, Tem. 2012, ss. 900-905. doi: 10.1109/ISSPA.2012.6310682.
- [97] M. Gençer, G. Bilgin, ve N. Aydin, “Emboic Doppler ultrasound signal detection via fractional Fourier transform”, içinde *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Tem. 2013, ss. 3050-3053. doi: 10.1109/EMBC.2013.6610184.
- [98] S. Wang vd., “Pathological Brain Detection by a Novel Image Feature—Fractional Fourier Entropy”, *Entropy*, c. 17, sy 12, Art. sy 12, Ara. 2015, doi: 10.3390/e17127877.
- [99] Y.-D. Zhang, S. Chen, S.-H. Wang, J.-F. Yang, ve P. Phillips, “Magnetic resonance brain image classification based on weighted-type fractional Fourier transform and nonparallel support vector machine”, *International Journal of Imaging Systems and Technology*, c. 25, sy 4, ss. 317-327, 2015, doi: 10.1002/ima.22144.
- [100] Y. Zhang, Y. Sun, P. Phillips, G. Liu, X. Zhou, ve S. Wang, “A Multilayer Perceptron Based Smart Pathological Brain Detection System by Fractional Fourier Entropy”, *J Med Syst*, c. 40, sy 7, s. 173, Haz. 2016, doi: 10.1007/s10916-016-0525-2.
- [101] S. Wang vd., “Detection of Left-Sided and Right-Sided Hearing Loss via Fractional Fourier Transform”, *Entropy*, c. 18, sy 5, Art. sy 5, May. 2016, doi: 10.3390/e18050194.
- [102] P. Kumar ve S. Kansal, “Noise removal in speech signal using fractional fourier transform”, içinde *2017 International Conference on Information, Communication, Instrumentation and Control (ICICIC)*, Ağu. 2017, ss. 1-4. doi: 10.1109/ICO-MICON.2017.8279117.
- [103] “Chaos feature study in fractional Fourier domain for preictal prediction of epileptic seizure”, *Neurocomputing*, c. 249, ss. 290-298, Ağu. 2017, doi: 10.1016/j.neucom.2017.04.019.
- [104] “A robust high-resolution time–frequency representation based on the local optimization of the short-time fractional Fourier transform”, *Digital Signal Processing*, c. 70, ss. 125-144, Kas. 2017, doi: 10.1016/j.dsp.2017.07.022.
- [105] Yu. M. Belousov, N. N. Elkin, V. I. Man’ko, E. G. Popov, ve S. V. Revenko, “Tomographic Representation of Electrocardiogram Signals”, *J Russ Laser Res*, c. 39, sy 3, ss. 302-313, May. 2018, doi: 10.1007/s10946-018-9722-4.

- [106] Y. Zhang, Q. Hu, Z. Guo, J. Xu, ve K. Xiong, “Multi-Class Brain Images Classification Based on Reality-Preserving Fractional Fourier Transform and Adaboost”, içinde *2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)*, Haz. 2018, ss. 444-447. doi: 10.1109/ICIVC.2018.8492732.
- [107] “Electroencephalogram Based Biometrics | Proceedings of the 2018 2nd International Conference on Biometric Engineering and Applications”. <https://dl.acm.org/doi/abs/10.1145/3230820.3230821> (erişim 24 Temmuz 2023).
- [108] Z. Guo, Y. Xin, ve Y. Zhao, “Cancer classification using entropy analysis in fractional Fourier domain of gene expression profile”, *Biotechnology & Biotechnological Equipment*, c. 32, sy 4, ss. 1042-1046, Tem. 2018, doi: 10.1080/13102818.2017.1413596.
- [109] V. Gupta ve M. Mittal, “A Comparison of ECG Signal Pre-processing Using FrFT, FrWT and IPCA for Improved Analysis”, *IRBM*, c. 40, sy 3, ss. 145-156, Haz. 2019, doi: 10.1016/j.irbm.2019.04.003.
- [110] Q. Yang, Y. Wu, ve R. Cao, “Brain-Computer Interface System of Steady-State Visual Evoked Potentials Based on Fractional Domain Features”, içinde *2019 IEEE 8th Data Driven Control and Learning Systems Conference (DDCLS)*, May. 2019, ss. 1128-1131. doi: 10.1109/DDCLS.2019.8908868.
- [111] “QRS complex detection using fractional Stockwell transform and fractional Stockwell Shannon energy”, *Biomedical Signal Processing and Control*, c. 54, s. 101628, Eyl. 2019, doi: 10.1016/j.bspc.2019.101628.
- [112] T. Wang, N. Liu, Z. Su, ve C. Li, “A New Time-Frequency Feature Extraction Method for Action Detection on Artificial Knee by Fractional Fourier Transform”, *Micromachines*, c. 10, sy 5, Art. sy 5, May. 2019, doi: 10.3390/mi10050333.
- [113] Z. Abduh, E. A. Nehary, M. Abdel Wahed, ve Y. M. Kadah, “Classification of heart sounds using fractional fourier transform based mel-frequency spectral coefficients and traditional classifiers”, *Biomedical Signal Processing and Control*, c. 57, s. 101788, Mar. 2020, doi: 10.1016/j.bspc.2019.101788.
- [114] E. A. Nehary, Z. Abduh, ve S. Rajan, “A Deep Convolutional Neural Network Classification of Heart Sounds using Fractional Fourier Transform”, içinde *2021 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, Glasgow, United Kingdom: IEEE, May. 2021, ss. 1-5. doi: 10.1109/I2MTC50364.2021.9459909.
- [115] B. Rajesh ve D. G. Bhalke, “Automatic genre classification of Indian Tamil and western music using fractional MFCC”, *Int J Speech Technol*, c. 19, sy 3, ss. 551-563, Eyl. 2016, doi: 10.1007/s10772-016-9347-3.
- [116] “Electronics | Free Full-Text | Research on Speech Emotion Recognition Based on the Fractional Fourier Transform”. <https://www.mdpi.com/2079-9292/11/20/3393> (erişim 25 Temmuz 2023).
- [117] M. Alloghani, D. Al-Jumeily, J. Mustafina, A. Hussain, ve A. J. Aljaaf, “A Systematic Review on Supervised and Unsupervised Machine Learning Algorithms for Data Science”, *Supervised and Unsupervised Learning for Data Science*, ss. 3-21, 2020, doi: 10.1007/978-3-030-22475-2_1.

- [118] “Dive into Deep Learning — Dive into Deep Learning 1.0.0-beta0 documentation”. <https://d2l.ai/> (erişim 27 Mart 2023).
- [119] X. Zhou, H. Liu, C. Shi, ve J. Liu, “Chapter 2 - The basics of deep learning”, içinde *Deep Learning on Edge Computing Devices*, X. Zhou, H. Liu, C. Shi, ve J. Liu, Ed., Elsevier, 2022, ss. 19-36. doi: 10.1016/B978-0-32-385783-3.00009-0.
- [120] R. J. Lipton, “Might Turing Have Won a Turing Award?”, *Computer*, c. 45, sy 6, ss. 96-97, Haz. 2012, doi: 10.1109/MC.2012.211.
- [121] M. Cannataro, P. H. Guzzi, G. Agapito, C. Zucco, ve M. Milano, “Chapter 3 - Artificial intelligence”, içinde *Artificial Intelligence in Bioinformatics*, M. Cannataro, P. H. Guzzi, G. Agapito, C. Zucco, ve M. Milano, Ed., Elsevier, 2022, ss. 29-33. doi: 10.1016/B978-0-12-822952-1.00012-7.
- [122] “Study on artificial intelligence: The state of the art and future prospects”, *Journal of Industrial Information Integration*, c. 23, s. 100224, Eyl. 2021, doi: 10.1016/j.jii.2021.100224.
- [123] “1. Giriş — Derin Öğrenmeye Dalış 0.17.5 documentation”. https://tr.d2l.ai/chapter_introduction/index.html#gozetimli-ogrenme (erişim 25 Ocak 2023).
- [124] “1. Giriş — Derin Öğrenmeye Dalış 0.17.5 documentation”. https://tr.d2l.ai/chapter_introduction/index.html#gozetimsiz-ve-kendi-kendine-gozetimli-ogrenme (erişim 26 Ocak 2023).
- [125] “1. Giriş — Derin Öğrenmeye Dalış 0.17.5 documentation”. https://tr.d2l.ai/chapter_introduction/index.html#bir-ortamla-etkilesim (erişim 26 Ocak 2023).
- [126] “1. Giriş — Derin Öğrenmeye Dalış 0.17.5 documentation”. https://tr.d2l.ai/chapter_introduction/index.html#pekistirmeli-ogrenme (erişim 26 Ocak 2023).
- [127] “Deep learning applications for disease diagnosis”, *Deep Learning for Medical Applications with Unique Data*, ss. 31-51, Oca. 2022, doi: 10.1016/B978-0-12-824145-5.00005-8.
- [128] “1. Giriş — Derin Öğrenmeye Dalış 0.17.5 documentation”. https://tr.d2l.ai/chapter_introduction/index.html#ozellikler (erişim 26 Ocak 2023).
- [129] S. Shajun Nisha, M. Mohamed Sathik, ve M. Nagoor Meeral, “3 - Application, algorithm, tools directly related to deep learning”, içinde *Handbook of Deep Learning in Biomedical Engineering*, V. E. Balas, B. K. Mishra, ve R. Kumar, Ed., Academic Press, 2021, ss. 61-84. doi: 10.1016/B978-0-12-823014-5.00007-7.
- [130] J. Raitoharju, “Chapter 3 - Convolutional neural networks”, içinde *Deep Learning for Robot Perception and Cognition*, A. Iosifidis ve A. Tefas, Ed., Academic Press, 2022, ss. 35-69. doi: <https://doi.org/10.1016/B978-0-32-385787-1.00008-7>.
- [131] François Chollet, “Yinemeli Sinir Ağını Anlamak”, içinde *Python ile Derin Öğrenme*, I. bsEryaman/Ankara: Buzdağı Yayınevi, 2019, s. 208.
- [132] “Applications of convolutional neural networks for spectral analysis”, içinde *Intelligent Nanotechnology*, Elsevier, 2023, ss. 145-186. doi: 10.1016/B978-0-323-85796-3.00006-8.
- [133] N. Ketkar ve J. Moolayil, “Convolutional Neural Networks”, içinde *Deep*

- Learning with Python*, Apress, Berkeley, CA, 2021, ss. 197-242. doi: 10.1007/978-1-4842-5364-9_6.
- [134] Z. J. Wang vd., “CNN Explainer: Learning Convolutional Neural Networks with Interactive Visualization”, *IEEE Trans. Visual. Comput. Graphics*, c. 27, sy 2, ss. 1396-1406, Şub. 2021, doi: 10.1109/TVCG.2020.3030418.
- [135] H. Habibi Aghdam ve E. Jahani Heravi, “Convolutional Neural Networks”, içinde *Guide to Convolutional Neural Networks*, Springer, Cham, 2017, ss. 85-130. doi: 10.1007/978-3-319-57550-6_3.
- [136] D. Rengasamy, M. Jafari, B. Rothwell, X. Chen, ve G. P. Figueredo, “Deep Learning with Dynamically Weighted Loss Function for Sensor-Based Prognostics and Health Management”, *Sensors*, c. 20, sy 3, Art. sy 3, Oca. 2020, doi: 10.3390/s20030723.
- [137] S.-C. Huang ve T.-H. Le, “Chapter 4 - Multi-category classification problem”, içinde *Principles and Labs for Deep Learning*, S.-C. Huang ve T.-H. Le, Ed., Academic Press, 2021, ss. 81-116. doi: 10.1016/B978-0-323-90198-7.00005-7.
- [138] M. Cannataro, P. H. Guzzi, G. Agapito, C. Zucco, ve M. Milano, “Chapter 5 - Deep learning”, içinde *Artificial Intelligence in Bioinformatics*, M. Cannataro, P. H. Guzzi, G. Agapito, C. Zucco, ve M. Milano, Ed., Elsevier, 2022, ss. 53-60. doi: 10.1016/B978-0-12-822952-1.00014-0.
- [139] J. Raitoharju, “Chapter 3 - Convolutional neural networks”, içinde *Deep Learning for Robot Perception and Cognition*, A. Iosifidis ve A. Tefas, Ed., Academic Press, 2022, ss. 35-69. doi: 10.1016/B978-0-32-385787-1.00008-7.
- [140] C. Xiao ve J. Sun, “Convolutional Neural Networks (CNN)”, içinde *Introduction to Deep Learning for Healthcare*, Springer, Cham, 2021, ss. 83-109. doi: 10.1007/978-3-030-82184-5_6.
- [141] H. Naseri ve V. Mehrdad, “Novel CNN with investigation on accuracy by modifying stride, padding, kernel size and filter numbers”, *Multimed Tools Appl*, c. 82, sy 15, ss. 23673-23691, Haz. 2023, doi: 10.1007/s11042-023-14603-x.
- [142] “Pooling Layers | Coursera”. <https://www.coursera.org/learn/convolutional-neural-networks/lecture/hELHk/pooling-layers> (erişim 25 Haziran 2023).
- [143] F. Demir, D. A. Abdullah, ve A. Sengur, “A New Deep CNN Model for Environmental Sound Classification”, *IEEE Access*, c. 8, ss. 66529-66537, 2020, doi: 10.1109/ACCESS.2020.2984903.
- [144] F. M. Salem, “Recurrent Neural Networks (RNN)”, içinde *Recurrent Neural Networks*, Springer, Cham, 2022, ss. 43-67. doi: 10.1007/978-3-030-89929-5_3.
- [145] H. Nakayama, “Recurrent Neural Network”, içinde *Computer Vision*, Springer, Cham, 2021, ss. 1051-1058. doi: 10.1007/978-3-030-63416-2_855.
- [146] S. Mutasa, S. Sun, ve R. Ha, “Understanding artificial intelligence based radiology studies: What is overfitting?”, *Clinical Imaging*, c. 65, ss. 96-99, Eyl. 2020, doi: 10.1016/j.clinimag.2020.04.025.
- [147] X. Ying, “An Overview of Overfitting and its Solutions”, *J. Phys.: Conf. Ser.*, c.

1168, sy 2, s. 022022, Şub. 2019, doi: 10.1088/1742-6596/1168/2/022022.

- [148] *Understanding Human-level Performance*. Erişim: 21 Haziran 2023. [Çevrimiçi Video]. Erişim adresi: <https://www.coursera.org/learn/machine-learning-projects/home/welcome>
- [149] *MIT Introduction to Deep Learning | 6.S191*, (10 Mart 2023). Erişim: 26 Temmuz 2023. [Çevrimiçi Video]. Erişim adresi: <https://www.youtube.com/watch?v=QDX-1M5Nj7s>
- [150] “Heartbeat Sound LSTM Classification | Kaggle”. <https://www.kaggle.com/code/abdallahaboelkhair/heartbeat-sound-lstm-classification> (erişim 26 Temmuz 2023).
- [151] “Convolutional Model, Step by Step”, *Coursera*. https://www.coursera.org/learn/convolutional-neural-networks/programming/4xt9A/convolutional-model-step-by-step/lab?path=%2Fnotebooks%2Frelease%2FW1A1%2FConvolution_model_Step_by_Step_v1.ipynb (erişim 25 Haziran 2023).
- [152] *Cleaning Up Incorrectly Labeled Data*. Erişim: 21 Haziran 2023. [Çevrimiçi Video]. Erişim adresi: <https://www.coursera.org/learn/machine-learning-projects/lecture/Ggkxn/andrej-karpathy-interview>
- [153] *Bias and Variance with Mismatched Data Distributions*. Erişim: 22 Haziran 2023. [Çevrimiçi Video]. Erişim adresi: <https://www.coursera.org/learn/machine-learning-projects/home/welcome>

ÖZGEÇMİŞ

Adı Soyadı : Elif ÇİÇEK

Yabancı Dil : İngilizce, Arapça

Eğitim Durumu

Derece	Yıl	Bölüm	Okul
Lise	2006-2010		Düzce Anadolu İmam-Hatip Lisesi
Lisans	2010-2015	İlahiyat Fakültesi	Marmara Üniversitesi
Lisans	2012-2016	Mekatronik Mühendisliği	Marmara Üniversitesi
Y. Lisans	2023	Mekatronik Mühendisliği	Marmara Üniversitesi

İş Deneyimi

İş Yeri	Yıl	Pozisyon
Sarsılmaz Silah Sanayi	2014	Stajyer
Nursan CNC Fabrikası	2015	Stajyer
Endmaksan Mühendislik	2015	Stajyer
Diyanet İşleri Başkanlığı	2018-2019	K.K.Ö
MEB	2019- Halen	Öğretmen