

**FONOKARDİYOĞRAFI SİNYALLERİ İLE DERİN
ÖĞRENME TABANLI KARAR DESTEK SİSTEMİ
TASARIMI**

**DEEP LEARNING BASED DECISION SUPPORT SYSTEM
DESIGN WITH PHONOCARDIOGRAPHY SIGNALS**

ELİF DEMİR ÖZTÜRK

PROF. DR. ATILA YILMAZ

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim - Öğretim ve Sınav Yönetmeliği'nin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı İçin Öngördüğü

YÜKSEK LİSANS TEZİ

olarak hazırlanmıştır.

Eylül 2024

ÖZET

FONOKARDİYOĞRAFİ SINYALLERİ İLE DERİN ÖĞRENME TABANLI KARAR DESTEK SİSTEMİ TASARIMI

Elif DEMİR ÖZTÜRK

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Atila YILMAZ

Eylül 2024, 118 sayfa

Bu çalışma, kardiyovasküler hastalıkların fonokardiyografi (FKG) sinyalleri kullanılarak derin öğrenme yöntemleriyle sınıflandırılması ve bu yaklaşımla doktorlar için karar destek sistemi geliştirmenin temelini oluşturmayı amaçlamıştır. Bu sayede, doktorların ön teshiş sürecine destek olunması planlanmıştır.

Çalışmada, daha önce yapılan proje çerçevesinde elektronik stetoskop ile toplanmış olan ve HU-PCG olarak adlandırdığımız veri seti ile kalp seslerinin sınıflandırılması amaçlanmıştır. Bunun yanında, kalp seslerinin sınıflandırılması konusunda yaygın olarak kullanılan PhysioNet/CinC 2016, PASCAL ve HVD veri setleri üzerinde de çalışılmış ve sonuçların karşılaştırması yapılmıştır. Kalp seslerinin sınıflandırılması için hem çok aşamalı geleneksel makine öğrenmesi yöntemleri hem de uçtan uca derin öğrenme tabanlı yöntemler değerlendirilmiştir. Makine öğrenmesi tabanlı yöntem için ön işleme, sonrasında MFCC ve DWT yöntemleri kullanılarak seslerinin tanımlanması, bölütleme, öznitelik çıkarımı ve dört farklı yöntemle (Doğrusal Sınıflandırıcı, k-NN, SVM, MLP-BP) sınıflandırma olmak üzere beş aşamalı sınıflandırma gerçekleştiren çalışma incelenmiştir. İncelenen çalışmada sınıflandırma; önce normal ve anormallerin bulunması, sonrasında hastalıkların

sınıflandırılması yapılacak şekilde iki kademeli karar mekanizması ile gerçekleştirilmiştir. FKG sinyallerinin derin öğrenme yöntemleri ile sınıflandırılabilmesi için basit ön işleme adımlarından geçirilen FKG sinyalinin girdi oluşturacağı bir boyutlu evrimsel sinir ağı (CNN) kullanılarak 1DCNN modeli, ön işleme sonrası mel spektrogramları oluşturulan FKG sinyali modelin girdisi olacak şekilde iki boyutlu CNN kullanılarak 2DCNN modeli geliştirilmiştir. Bu çalışmanın diğer bir amacı FKG sinyallerinin sınıflandırılmasını iki kademeli olarak gerçekleştirip, tek kademeli sınıflandırma ile karşılaştırmaktır. Bu doğrultuda, 1DCNN kullanılarak 2H-1DCNN ve 2S-1DCNN modelleri, 2DCNN kullanılarak 2S-2DCNN modeli geliştirilmiştir. 1DCNN ve 2DCNN modelleri ile normal ve anormal sınıflandırma, 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN, 2S-2DCNN modelleri ile normal ve hastalık bazında üç sınıflı sınıflandırma gerçekleştirilmiştir.

FKG sinyalini eşit uzunluktaki parçalara bölerek giriş verisi oluşturmak, her çevrimde (epoch) FKG sinyalinden eşit uzunlukta rastgele seçilen kısımlarla giriş verisi oluşturmak, FKG sinyalinin bölütlerinin (periyotlarına ayırarak) her biriniyle giriş verisi oluşturmak olmak üzere üç farklı veri artırma yöntemi ile modelin başarımının artırılması üzerinde çalışılmıştır. Ayrıca, öğrenim aktarımı (transfer learning) yöntemi ile daha büyük veri setleriyle eğitilmiş bir modelin, daha küçük veri setleri üzerinde yeniden eğitilmesiyle sınıflandırma performansı artırılmıştır. Bu yaklaşımların kullanılması, derin öğrenme tabanlı modellerin başarımını önemli ölçüde iyileştirmiş ve kalp seslerinin sınıflandırılması konusunda etkili bir çözüm sunmuştur.

Bu çalışmada, HU-PCG veri seti için normal anormal sınıflandırmada, öğrenim aktarımı ve sinyal içerisinden rastgele seçme yöntemleri kullanılarak 1DCNN ve 2DCNN modeller ile doğruluk metriğinde 1.0 sonucuyla en yüksek başarıım değeri elde edilmiştir. Üç sınıflı sınıflandırmada ise en yüksek başarıım değerleri öğrenim aktarımı ve sinyal içerisinden rastgele seçme yöntemleri kullanılarak 0.93 doğruluk ile 2S-1DCNN modeli, ikinci en yüksek doğruluk değerini 0.87 ile 2S-2DCNN modeli vermiştir.

Anahtar Kelimeler: Kalp sesleri, Fonokardiyogram, bölütleme, ayrık dalgacık dönüşümü, MFCC, sınıflandırma, sinir ağı, derin öğrenme, öğrenim aktarımı, veri artırma

ABSTRACT

DEEP LEARNING BASED DECISION SUPPORT SYSTEM DESIGN WITH PHONOCARDIOGRAPHY SIGNALS

Elif DEMİR ÖZTÜRK

Master of Science, Department Electrical and Electronics Engineering

Supervisor: Prof. Dr. Atila YILMAZ

September 2024, 118 pages

This study aims to classify cardiovascular diseases using phonocardiogram (PCG) signals through deep learning methods, thereby laying the foundation for developing a decision support system for doctors. In this way, it is planned to support physicians in the preliminary diagnosis process.

In this study, the classification of heart sounds was performed using the HU-PCG dataset, which was previously collected within our department. Additionally, comparative analyses were conducted using commonly used datasets in heart sound classification, including PhysioNet/CinC 2016, PASCAL, and HVD datasets. Both traditional machine learning methods, which involve multiple stages, and end-to-end deep learning-based methods were evaluated for heart sound classification. For the machine learning-based approach, a five-stage classification process was examined. In this approach, after the preprocessing step of the signals, a heart sound identification algorithm was employed using feature vectors created with MFCC and DWT techniques, finally segmentation is done. Features were extracted from the segmented signals, and classification was performed using Linear Classifier, k-NN, SVM, and MLP-BP methods. The classification was conducted in two

levels: first, the identification of normal and abnormal sounds, followed by the classification of diseases. For classifying PCG signals using deep learning methods, a 1D convolutional neural network (1DCNN) model was developed, where the PCG signal, which underwent simple preprocessing steps, served as the input. Additionally, a 2D convolutional neural network (2DCNN) model was developed, using mel spectrograms created from preprocessed PCG signals as the input. Another objective of this study is to perform a two level classification of PCG signals and compare it with single level classification. In this context, models such as 2H-1DCNN and 2S-1DCNN were developed using 1DCNN, and 2S-2DCNN models were developed using 2DCNN. With the 1DCNN and 2DCNN models, binary classification of normal versus abnormal was conducted, and three-class classification based on normal and disease states was performed using the 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN, and 2S-2DCNN models.

The study explored methods to improve the model's performance, such as using data augmentation by dividing the PCG signal into segments of equal length, random crop of the PCG signal of equal length in each epoch, and segmenting the PCG signal to create input data for each segment. Furthermore, transfer learning was employed to enhance classification performance by retraining a model, initially trained on larger datasets, on smaller datasets. The use of these approaches significantly improved the performance of deep learning-based models, providing an effective solution for classifying heart sounds.

In this study, for normal-abnormal classification on the HU-PCG dataset, the highest accuracy metric of 1.0 was achieved using 1DCNN and 2DCNN models with random crop from within the signal and transfer learning methods. For three-class models trained to distinguish between normal, aortic stenosis, and mitral regurgitation, the highest performance value of 0.93 accuracy was achieved using the 2S-1DCNN model with transfer learning and random crop methods, while the second-highest accuracy (that is 0.87) was achieved by the 2S-2DCNN model using the same methods.

Keywords: Heart sounds, phonocardiography, segmentation, discrete wavelet transform, MFCC, classification, neural networks, deep learning, transfer learning, data augmentation

TEŐEKKÜR

Öncelikle tez konusunun seçiminde ve çalışma sürecinde bilgi ve deneyimleriyle bana rehberlik eden, anlayış ve sabırla beni destekleyen danışmanım Sayın Prof.Dr.Atila Yılmaz'a teşekkürlerimi sunarım.

Bu tez konusunda yaptığı çalışmalar ve çalışmalarından bana aktardığı bilgi ve birikimden dolayı İbrahim Özkan'a teşekkür ederim.

Bu projenin gerçekleştirilmesi ve sağlıklı yürütülmesi için alınan destek sebebi ile Hacettepe Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimine ve ek veri toplanma çalışmasında Hacettepe Üniversitesi Kardiyoloji bölümündeki Sayın Prof.Dr. Hikmet Yorgun ve ekibine teşekkür ederim.

Son olarak hayatım boyunca benim yanımda olan, beni destekleyen ve bu günlere gelmemi sağlayan anneme, babama, abime ve tez çalışmam ve yüksek lisans akademik hayatım boyunca beni destekleyen, çalışma isteğim azaldığında beni motive eden, her zaman yanımda olan eşime çok teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
TABLolar	ix
ŞEKİLLER	xii
KISALTMALAR	xiv
1. GİRİŞ	1
2. Genel Bilgiler	5
2.1. Kalbin Yapısı ve Fonokardiyogram Sinyalleri	6
2.2. Sayısal Stetoskop	8
2.3. Fonokardiyogram Sinyallerinin Sınıflandırılması Konusunda Yapılmış Çalışmalar	10
2.4. Mel Spektrogram	12
2.5. Danışıklı Öğrenme ile Sınıflandırma	15
2.5.1. Doğrusal Sınıflandırıcısı (Mahalanobis Mesafe)	15
2.5.2. K En Yakın Komşu (k-NN)	16
2.5.3. Destek Vektör Makinaları (SVM)	16
2.5.4. Çok Katmanlı Perceptron (MLP)	18
2.5.5. Evrişimsel Sinir Ağları (CNN)	19
3. VERİ SETLERİ VE YÖNTEM	20
3.1. Veri Setleri	20
3.1.1. Birinci Veri Seti: HU-PCG	22
3.1.2. İkinci Veri Seti: HVD	23
3.1.3. Üçüncü veri Seti: PASCAL	23
3.1.4. Dördüncü veri seti: PhysioNet	24
3.2. Yöntem	25

3.2.1. Beş Aşamalı Makine Öğrenmesi Tabanlı Sınıflandırma	26
3.2.1.1. Ön İşleme	27
3.2.1.2. S1 ve S2 Tanımlama.....	27
3.2.1.3. Bölütleme	30
3.2.1.4. Özniteliklerin Çıkarılması.....	32
3.2.1.5. Sınıflandırma	32
3.2.2. Derin Öğrenme ile Sınıflandırma.....	33
3.2.2.1. Ön İşleme	35
3.2.2.2. Mel Spektrogram	38
3.2.2.3. 1D CNN Model (1DCNN)	40
3.2.2.4. İki Çıkışlı 1D CNN Model (2H-1DCNN).....	47
3.2.2.5. 2D CNN Model (2DCNN)	48
3.2.2.6. İki Aşamalı 1D CNN Model (2S-1DCNN) / 2D CNN Model (2S-2DCNN).....	51
4. UYGULAMA VE BAŞARIM SONUÇLARI	52
4.1. Başarım Metriği	53
4.2. Beş Aşamalı Makine Öğrenmesi Tabanlı Sınıflandırıcı Başarım Sonuçları	55
4.3. Derin Öğrenme Tabanlı Sınıflandırıcı Başarım Sonuçları	58
4.3.1. Normal-Anormal Sınıflandırma Başarım Sonuçları	59
4.3.1.1. 1DCNN Başarım Sonuçları	59
4.3.1.2. Mel Spektrogram Girişli 2DCNN Başarım Sonuçları	67
4.3.2. PhysioNet Veri Setinde 1DCNN ve 2DCNN Karşılaştırması.....	68
4.3.3. N, AD, MY Sınıflandırma Başarım Sonuçları	70
4.3.3.1. 1DCNN Başarım Sonuçları	71
4.3.3.2. 2H-1DCNN Başarım Sonuçları.....	74
4.3.3.3. 2S-1DCNN Başarım Sonuçları	76
4.3.3.4. Mel Spektrogram Girişli 2DCNN Başarım Sonuçları	77
4.3.3.5. 2S-2DCNN Başarım Sonuçları	78
4.3.3.6. 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN ve 2S-2DCNN ile N, AD, MY Sınıflandırmasının Karşılaştırılması.....	78

4.4. 1DCNN Sınıflandırıcı ve Beş Aşamalı Sınıflandırma Yaklaşımıyla MLP-BP	
Sınıflandırıcı Başarım Sonuçları Karşılaştırması	83
5. TARTIŞMA VE SONUÇ	85
EKLER A:	97
A.1. HPP ve HP Veri Setinde 1DCNN Model Başarım Sonuçları.....	97
A.2. PhysioNet-D Veri Setinde Alınmış Detay Sonuçlar	97

TABLULAR

	<u>Sayfa</u>
Tablo 3.1 Veri Setlerine Dair İstatik Bilgileri	21
Tablo 3.2 1DCNN Modeli Her Bir Katman Bilgileri	44
Tablo 3.3 2D CNN Model'i Her Bir Katman Bilgileri	50
Tablo 4.1 Her Bir Sınıflandırıcı İçin Zamana Bağlı Özniteliklerle Birinci Seviye Sınıflandırmada Bölüt Bazlı Başarım Sonuçları	56
Tablo 4.2 Her Bir Sınıflandırıcı İçin Zamana Bağlı Özniteliklerle İkinci Seviye Sınıflandırmada Bölüt Bazlı Başarım Sonuçları	56
Tablo 4.3 Her Bir Sınıflandırıcı İçin Zamana Bağlı ve MFCC Öznitelikleriyle Birinci Seviye Sınıflandırmada Bölüt Bazlı Başarım Sonuçları	57
Tablo 4.4 Her Bir Sınıflandırıcı İçin Zamana Bağlı ve MFCC Öznitelikleriyle İkinci Seviye Sınıflandırmada Bölüt Bazlı Başarım Sonuçları.....	57
Tablo 4.5 HU-PCG, HVD, PASCAL, PhysioNet Veri Setleri için Normal-Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları.....	60
Tablo 4.6 HU-PCG Veri Setinde Bütün, Parçalı, Bölütlenmiş, Rastgele Kırılmış Giriş Verileri ile Normal Anormal Sınıflandırmada Kişi Bazlı Başarım Sonuçları	62
Tablo 4.7 PhysioNet Veri Setinde Bütün, Rastgele Kırılmış Giriş Verileri ile Sınıflandırmada Kişi Bazlı Başarım Sonuçları	64
Tablo 4.8 HU-PCG Veri Seti için Ön Eğitilmiş/Eğitilmemiş Model ile Normal Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları.....	66
Tablo 4.9 PhysioNet Veri Seti için Ön Eğitilmiş/Eğitilmemiş 1DCNN Model ile Normal Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları	67
Tablo 4.10 HU-PCG Veri Seti için 2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre Normal Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları.....	67

Tablo 4.11	PhysioNet Veri Seti için 2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre Normal Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları.....	68
Tablo 4.12	PhysioNet Veri Seti için 1DCNN, 2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre Normal Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları	69
Tablo 4.13	HU-PCG Veri Setinde Bütün, Parçalı, Bölütlenmiş, Rastgele Kırılmış Giriş Verileri ile N, AD,MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları.....	72
Tablo 4.14	Bütün ve Bölütlenmiş Sinyallerde S1 ve S2 Seslerinin Çıkarılmamış ve Çıkarılmış Halleri ile N, AD, MY Sınıflandırmada Kişi Bazlı Başarım Sonuçları.....	73
Tablo 4.15	HU-PCG Veri Seti için Ön Eğitilmiş/Eğitilmemiş 1DCNN ile N, AD,MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları	74
Tablo 4.16	HU-PCG Veri Seti için 2H-1DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre N, AD,MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları.....	75
Tablo 4.17	HU-PCG Veri Seti için 2S-1DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre N, AD,MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları.....	76
Tablo 4.18	HU-PCG Veri Seti için Mel Spektrogram Girişli 2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre N, AD, MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları	77
Tablo 4.19	HU-PCG Veri Seti için 2S-2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre N, AD,MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları.....	79
Tablo 4.20	HU-PCG Veri Seti için 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN ve 2S-2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre N, AD,MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları	80

Tablo 4.21	HU-PCG Veri Seti için 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN ve 2S-2DCNN Modelleriyle N, AD,MY Sınıflandırmasında Eğitim ve Test Süreleri	82
Tablo 4.22	Normal Anormal Sınıflandırmada 1DCNN Sınıflandırıcı ve Beş Aşamalı Sınıflandırma Yaklaşımıyla MLP-BP Sınıflandırıcı ile Bölüt Bazlı Sınıflandırma Başarım Sonuçları	83
Tablo 4.23	Normal Anormal Sınıflandırmada 1DCNN Sınıflandırıcı ve Beş Aşamalı Sınıflandırma Yaklaşımıyla MLP-BP Sınıflandırıcı ile Kişi Bazlı Sınıflandırma Başarım Sonuçları	84
Tablo A.01	HPP, HP Veri Setleri için 1DCNN Model ile Normal Anormal Sınıflandırması Başarım Sonuçları	97
Tablo A.02	PhysioNet-D Veri Seti için 1DCNN, 2DCNN Modelleri ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre Normal Anormal Sınıflandırmasında Eğitim Başarım Sonuçları	98

ŞEKİLLER

	<u>Sayfa</u>
Şekil 2.1 Sağlıklı Bir Kalpten Tipik Kalp Sesi Sinyali (Üst Resim) - Patolojik Bir Kalpten Sistolik ve Diyastolik Üfürümler Üreten Kalp Sesi Sinyali (Alt Resim)	7
Şekil 2.2 Normal ve Anormal Fonokardiyogram Sinyalleri	8
Şekil 2.3 a) 3M Littmann CORE Sayısal Stetoskop, b) Eko Telefon Uygulaması Ses Kayıt Ekranı	9
Şekil 2.4 Eko İnternet Uygulaması Kayıtlı Veri Ekranı.....	10
Şekil 3.1 HU-PCG Veri Setindeki FKG Sinyal Örnekleri: a) Normal, b) MY Etiketli	22
Şekil 3.2 Yeni Toplanmış Verilerden FKG Sinyal Örnekleri: a) Normal, b) AD Etiketli	23
Şekil 3.3 HVD Veri Setindeki FKG Sinyal Örnekleri: a) Normal, b) AD Etiketli .	24
Şekil 3.4 PASCAL Veri Setindeki FKG Sinyal Örnekleri: a) Normal, b) Anormal	24
Şekil 3.5 PhysioNet Veri Setindeki FKG Sinyal Örnekleri: a) Normal b)Anormal	25
Şekil 3.6 İş Akışı	27
Şekil 3.7 HU-PCG Veri Setindeki Bir FKG Sinyali: a) Sinyalin İşlenmemiş Hali, b) Sinyalin Ön İşlenmiş Hali	28
Şekil 3.8 Beşinci Detay Katsayı Vektörü	28
Şekil 3.9 Katsayı Vektörü Üzerinde Kalp Döngüsü Süresi ve Sistol Süresi	29
Şekil 3.10 Katsayı Vektörü Üzerindeki Tepe Noktaları	29
Şekil 3.11 Çerçeve Sinyali	30
Şekil 3.12 FKG Sinyali ve Öznitelik Vektörü Üzerinde S1 ve S2 Bölgelerinin Gösterimi	31
Şekil 3.13 FKG Sinyali Üzerinde S1, S2 Sesleri ve Ses Bölgeleri	31
Şekil 3.14 Bölütlenmiş FKG Sinyali	32
Şekil 3.15 İki Kademeli Sınıflandırma Yaklaşımı	33

Şekil 3.16 HU-PCG Veri Setindeki FKG Örnek Sinyalleri: a) Normal Sinyalin Ön İşlenmemiş Hali, b) Normal Sinyalin Mel Spektrogramı, c) AD Sinyalin Ön İşlenmemiş Hali, d) AD Sinyalin Mel Spektrogramı	40
Şekil 3.17 Bir Boyutlu Evrişim (1D Convolution - 1D Conv)	41
Şekil 3.18 Bir Tane Bir Boyutlu CNN Katmanının Yapısı. d filtre boyutu, s kayma parametresi, K filtre sayısıdır.	41
Şekil 3.19 1DCNN Yapısı	42
Şekil 3.20 2H-1DCNN Yapısı	47
Şekil 3.21 İki Boyutlu Evrişim (2D Convolution - 2D Conv)	48
Şekil 3.22 Bir Tane İki boyutlu CNN Katmanının Yapısı	49
Şekil 3.23 2DCNN Yapısı	49
Şekil 3.24 Bir Tane İki boyutlu CNN Katmanının Yapısı	52

KISALTMALAR

1D	: Bir Boyutlu
2D	: İki Boyutlu
AD	: Aort Darlığı (Aort Stenosis)
aN	: Anormal
AY	: Aort Yetmezliği (Aort Regurgitation)
CNN	: Evrişimsel Sinir Ağları (Convolutional Neural Network)
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
DFT	: Ayrık Fourier Dönüşümü (Discrete Fourier Transform)
DWT	: Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)
EEG	: Elektroensefalogram (Electroencephalography)
EKG	: Elektrokardiyogram (Electrocardiography)
GPU	: Grafik İşlem Birimi (Graphics Processing Unit)
k-NN	: K-En Yakın Komşu (K-Nearest Neighbors)
MD	: Mitral Darlık (Mitral Stenosis)
MFCC	: Mel Frekans Kepstral Katsayıları (Mel Frequency Cepstral Coefficients)
MLP	: Çok Katmanlı Perceptron (Multi Layer Perceptron)
MVP	: Mitral Kapak Prolapsus (Mitral Valve Prolapse)
MY	: Mitral Yetmezlik (Mitral Regurgitation)
N	: Normal
FKG (PCG)	: Fonokardiyogram (Phonocardiogram)
PDA	: Patent Duktus Arteriosus (Patent Ductus Arteriosus)
STFT	: Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform)
SVM	: Destek Vektör Makinaları (Support Vector Machine)
TB	: Tam Bağlantı (Fully Connected)
TY	: Triküspid Yetmezlik (Tricuspid rRegurgitation)
VSD	: VentrikÜler Septal Defekt (Ventricular Septal Defect)

1. GİRİŞ

Bu yüzyılda bulaşıcı olmayan hastalıklar, ortalama insan ömrünü kısaltmaya devam etmekte ve giderek artmaktadır. Dünya Sağlık Örgütü'nün yayınladığı istatistiklere göre 2019 yılında dünya genelinde yaşanan ölümlerin %74'ü (yaklaşık olarak 41 milyon) bulaşıcı olmayan hastalıklardan kaynaklanmıştır [1]. Bu oran 2000 yılında %61 (yaklaşık olarak 31 milyon) iken 2019 yılında %74'e çıkması riskin arttığını göstermektedir. 2019 yılındaki bulaşıcı olmayan hastalıkların büyük bir bölümü kardiyovasküler rahatsızlıklardan kaynaklanmaktadır (17.9 milyon). Kardiyovasküler rahatsızlıkları 9.3 milyon ile kanser hastalıkları, 4.1 milyon ile solunum yolu hastalıkları, 2 milyon ile diyabet hastalıkları takip etmektedir. Bu istatistikler kardiyovasküler hastalıkların tespiti ve önlenmesinin gerekliliğini göstermektedir.

Kalp sesleri kardiyovasküler sisteme bağlı kalp hastalıklarına dair önemli bilgiler vermektedir. Bu sebeple en basit ve ucuz veri alma sistemi olan stetoskop ile alınan ses sinyallerinden doğru hastalık ön tanısı yapılabilmesi, hastalıkların daha erken tespit edilmesini sağlamaktadır. Ancak stetoskop ile dinlenen sesin hastalık bazında değerlendirilip ön tanı konulabilmesi, doktorun tecrübesine, hastalığın seviyesine ve sesteki üfürümlerin baskınlığına bağlı olmaktadır. Bu sebeple aslında hasta olan kişi için yanlış ön teşhis sonucu tedavi görememe durumu oluşabilmektedir. Bu projede; kalpten alınan ses sinyallerinin derin öğrenme yöntemleriyle hastalık bazında sınıflandırılması, burada geliştirilen sistemin ilerde de çalıştırılıp iyileştirilmesi ile doktorlara karar destek sistemi sunabilmek amaçlanmaktadır. Doktora sunulan karar destek sistemi ile hastalıkların daha doğru ön teşhisine olanak sağlanmış olacaktır.

Kalp ses sinyalindeki bir tam döngü iki ana sestten oluşmaktadır. Bunlar S1 ve S2 olarak adlandırılmaktadır. S1'den sonra ve S2'den önceki aralığa sistol, S2'den sonra ve S1'den önceki aralığa ise diyastol denilmektedir. Sistol ve diyastol bölgelerinde normal ses dışındaki seslere üfürüm denilmektedir. Üfürümler kardiyovasküler kalp rahatsızlıklarından kaynaklanmaktadır. Bir kalp ses sinyalinin grafiksel olarak temsiline fonokardiyogram

(FKG) sinyali denilmekte ve stetoskop ile elde edilebilmektedir. Stetoskop ile FKG sinyallerin dinlenmesi, kardiyovasküler rahatsızlıkları gözlemlemek için düşük maliyetli ve ön teşhis için yeterli bir izleme yöntemidir. Bu yöntem hasta için risk oluşturmadan kolaylıkla tekrarlanabilecek bir yöntemdir [2]. Bu sebeple kardiyovasküler rahatsızlıkların sınıflandırılması çalışmasında FKG sinyalleri kullanılmıştır.

FKG sinyalleri ile kalp seslerinin sınıflandırılması konusunda internette herkesin kullanımına açık ve bu konudaki çalışmalarda yaygın olarak kullanılan üç farklı veri seti bulunmaktadır. Bunlar PhysioNet/CinC 2016 yarışmasında paylaşılan, PASCAL Yarışmasında paylaşılan ve Yaseen ve ark. sunduğu çalışmada yer alan HVD isimli veri setleridir [3–5]. Bu veri setleri görsel olarak birbirlerine benzemekle birlikte farklı cihazlar ile toplandıkları için yapı olarak farklılıklar içermektedir. Ayrıca önceden Bölümümüz bünyesinde gerçekleştirilmiş çalışma ile toplanmış HU-PCG veri seti elimizde bulunmaktadır. Bu çalışmada asıl kullanılan veri seti bu veri seti olmakla birlikte yukarıda bahsedilmiş diğer veri setleri de karşılaştırmak ve başarıyı artırmak için kullanılmıştır. Kullanılan bütün veri setlerinde normal (N) veriler ve farklı üfürümlerden dolayı oluşmuş anormalliğe sahip anormal (aN) veriler bulunmaktadır. HU-PCG ve HVD veri setlerinde anormal veriler hastalık bazında etiketlenmiş olup Aort Darlığı (AD), Mitral Yetmezlik (MY), Mitral Darlık (MD), Patent Duktus Arteriozus (PDA), Triküspid Yetmezlik (TY), Aort Yetmezliği (AY), Ventriküler Septal Defekt (VSD), Mitral Kapak Prolapsusu (MVP) türlerinde anormallikler bulunmaktadır.

FKG sinyalleri sınıflandırılırken normal sınıfı ve K tane hastalık sınıfının yer aldığı $K + 1$ uzunluğunda olasılık vektörü üretmek tek kademede FKG sinyalinin normal mi hastalıklı mı, hastalıklıysa hangi hastalığı sahip sorularına cevap bulunabilmektedir. Fakat bu yaklaşımda sınıflandırmanın tek kademede gerçekleştirilmeye çalışılması sınıflandırma probleminin karmaşıklığını arttırmaktadır. Bunun yerine birden çok kademede sınıflandırmayı öneren bir yaklaşım bulunmaktadır. Bu yaklaşıma göre ilk kademede normal anormal sınıflandırması gerçekleştirilir. İkinci kademede anormal olarak bulunan veriler arasından sistol bölgesinde bulunan üfürümlerden kaynaklı anormallikler ve diyastol bölgesinde bulunan üfürümlerden kaynaklı anormalliklerin sınıflandırması gerçekleştirilir. Son olarak sistol bölgesindeki anormalliklerin kendi içinde, diyastol bölgesindeki anormalliklerin kendi

içinde sınıflandırılması gerçekleştirilir [6]. Burada bahsedilen kademeli yaklaşım önce normal anormal sınıflandırma, sonrasında hastalık bazında sınıflandırma olacak şekilde iki kademeli olarak da kullanılabilir.

FKG sinyallerinin sınıflandırılması konusunda bölütleme, öznitelik çıkarımı gibi çok aşamalı şekilde çalışan ve sınıflandırmayı makine öğrenmesi yöntemleri ile yapan çalışmalar bulunmakta, bunun yanında uçtan uca derin öğrenme tabanlı yöntemlerle çalışan farklı çalışmalar da bulunmaktadır. Çok aşamalı olup makine öğrenmesi tabanlı sınıflandırıcıları kullanan yöntemlerde FKG sinyali bölütlere ayrıldıktan sonrasında öznitelikler tek tek çıkarılır, sonrasında makine öğrenmesi yöntemleri kullanılarak sınıflandırma aşaması gerçekleştirilir. Uçtan uca olması amaçlanan derin öğrenme tabanlı yöntemlerde ise bölütleme aşaması tercih edilebilir bir aşamadır. Çoğunlukla öznitelikler çıkarılmadan Evrişimsel Sinir Ağları (CNN) tabanlı modeller ile öznitelik çıkarımı ve sınıflandırma işlemleri tek aşamada gerçekleştirilir. Derin öğrenme tabanlı yapılmış FKG sinyali sınıflandırma çalışmalarında genellikle iki farklı yaklaşım kullanılmıştır. Birinde FKG sinyali basit ön işleme adımları sonrasında bir boyutlu CNN modellere gönderilir, sınıflandırma bu şekilde gerçekleştirilir. Diğer yaklaşımda ise öncelikle ön işleme sonrasında FKG sinyalinin iki boyutlu mel spektrogram görseli oluşturulur. Oluşan mel spektrogramlar iki boyutlu CNN modele gönderilerek sınıflandırma aşaması gerçekleştirilir. Çalışmaların çoğunda mel spektrogramları çıkarılarak iki boyutlu CNN modellerde sınıflandırma yaklaşımı kullanılmıştır.

Bu çalışmada asıl amaçlanan HU-PCG veri setinin hastalık bazında derin öğrenme yöntemleri ile sınıflandırılması ve diğer makine öğrenmesi yöntemleri ile karşılaştırılmasıdır. Çalışmanın bir diğer amacı ise iki kademeli sınıflandırma yaklaşımının derin öğrenme tabanlı yöntemlerle sınıflandırma üzerindeki etkisini incelemektir. Bu kapsamda kalp seslerinin sınıflandırılması konusunda farklı yöntemler üzerinde çalışılmış ve bu yaklaşımlar karşılaştırılmıştır. İlk olarak, beş aşamalı önce ön işleme yapılmış sinyalin bölütlerine ayrılıp, sonrasında bu bölütler üzerinden öznitelikler çıkarılıp makine öğrenmesi yöntemleri ile sınıflandırma yaklaşımı incelenmiştir [7]. Diğer yaklaşımlarla karşılaştırabilmek için bu yaklaşımla geliştirilmiş çalışmanın sınıflandırma başarımları sonuçları alınmıştır. Sonrasında

bu çalışmanın asıl amacı olan derin öğrenme algoritmaları ile sınıflandırma yaklaşımları üzerinde çalışılmıştır. Öncelikle bir boyutlu giriş verisi ile geliştirilen bir boyutlu CNN modeller ile kalp seslerinin sınıflandırılması gerçekleştirilmiştir. Sonrasında FKG sinyallerinin mel spektrogramları oluşturulup bu çalışmada geliştirilmiş iki boyutlu CNN modele gönderilerek sınıflandırma gerçekleştirilmiştir.

Beş aşamalı FKG sinyallerinin sınıflandırılması çalışmasının ilk aşamasında sinyallerin ön işleme yapılmaktadır. Sonraki aşamada MFCC ve DWT teknikleri ile elde edilen bir öznelik vektörünü kullanarak oluşturulan bölütleme algoritması bulunmaktadır. Bölütlenmiş her bir sinyalin öznelikleri çıkarılarak öznelik vektörleri oluşturulmaktadır. Son olarak dört farklı makine öğrenmesi tabanlı sınıflandırma yöntemi kullanılarak sınıflandırma aşaması gerçekleştirilip, bu yöntemler karşılaştırılmaktadır. Sınıflandırma aşamasında iki kademeli sınıflandırma yaklaşımı kullanılmıştır. Öncelikle veriler normal anormal olarak sınıflandırılmış, sonrasında anormal veriler hastalık bazında sınıflandırılmıştır [7].

Derin öğrenme algoritmaları ile kalp seslerinin sınıflandırması konusunda bir boyutlu CNN kullanılarak uçtan uca sınıflandırmayı sağlayan, öznelik çıkarımına ihtiyaç duymayan ve basit bir yapıya sahip 1DCNN model geliştirilmiştir. Bu modelde bir boyutlu CNN kullanılmasının bir diğer sebebi ise kaynaklardaki bir çok çalışmadan farklılık oluşturmaktır. Çalışmaların çoğunda kullanılmış mel spektrogram girişli iki boyutlu CNN model ile sınıflandırma yaklaşımı ile buradaki tek boyutlu CNN model yaklaşımını karşılaştırabilmek için iki boyutlu CNN kullanılarak mel spektrogram girişli 2DCNN model geliştirilmiştir. İki kademeli sınıflandırma yaklaşımını derin öğrenme modellerinde deneyebilmek için 1DCNN kullanılarak İki Çıkışlı 1DCNN (2H-1DCNN) ve İki Aşamalı 1DCNN (2S-1DCNN), 2DCNN kullanılarak İki Aşamalı 2DCNN (2S-2DCNN) modelleri geliştirilmiştir. Öncelikle hastalık bazında sınıflandırma çalışmasının temelini oluşturmak için 1DCNN ve 2DCNN modelleri ile normal anormal sınıflandırması üzerinde çalışılmıştır. Sonrasında tasarlanan 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN, 2S-1DCNN modelleri kullanılarak N, AD, MY sınıflandırma üzerinde çalışılmıştır.

Veri setinde az sayıda veri bulunması derin öğrenme tabanlı modellerin başarımını düşürdüğü için başarımı artırmak amacıyla veri artırma yöntemleri üzerinde çalışılmıştır. FKG sinyalinin eşit uzunlukta parçalara bölünmesi ve her bir parçanın eğitilen modele gönderilmesi, her çevrimde (epoch) FKG sinyali içerisinde her biri aynı uzunlukta olacak şekilde rastgele seçilen kısımların eğitilen modele gönderilmesi, bölütlenmiş yani periyotlarına ayrılmış FKG sinyalinin her bir bölütünün eğitilen modele gönderilmesi yöntemleri veri artırma yöntemleri olarak kullanılmıştır. Başarım artırmak için veri artırma yöntemlerine ek olarak öğrenim aktarımı (transfer learning) yöntemi kullanılmıştır. Bu yöntem; daha çok veriye sahip bir veri setiyle eğitilmiş bir modelin daha küçük bir veri seti üzerinde yeni bir görev için yeniden eğitilmesiyle gerçekleştirilir.

Bu dokümanın akışı aşağıdaki gibidir:

- Birinci Bölümde çalışmanın amacı ve çalışmanın kapsamına dair bilgiler verilmektedir.
- İkinci Bölümde çalışmada bahsi geçen konulara dair genel bilgiler verilmektedir.
- Üçüncü Bölümde çalışmada kullanılan veri setleri, yöntem ve yaklaşımlara dair detay bilgiler verilmektedir.
- Dördüncü Bölümde bahsedilen veri setleri kullanılarak yöntemde anlatılan modellerle gerçekleştirilen eğitimlere dair detay bilgiler, eğitimler sonucunda elde edilmiş başarımlar ve karşılaştırmaları verilmektedir.
- Beşinci Bölümde çalışmada alınmış başarımların sonuçlarına dair değerlendirme ve varılan sonuçlara dair bilgiler bulunmaktadır.

2. Genel Bilgiler

Bu bölümde fonokardiyogram (FKG) sinyallerinin kuramsal alt yapısı, bu çalışmada bahsedilen konulara dair teknik detaylar ve FKG seslerinin sınıflandırılması konusunda

önceden yapılmış çalışmalar paylaşılmıştır. 2.1. başlığı altında kalbin genel yapısına ve bu çalışmada kullanılan FKG sinyallerine dair genel bilgiler verilmiştir. 2.2 başlığı altında kalp seslerinin toplanabilmesi için kullanılan sayısal stetoskopa dair bilgiler verilmiştir. 2.3 başlığı altında FKG sinyallerinin sınıflandırılması konusunda kaynaklarda bulunan çalışmalara dair bilgiler paylaşılmıştır. 2.4 başlığı altında Mel spektrogram konusuna dair, 2.5 başlığı altında ise bu çalışmada kullanılmış danışimli öğrenmeye dayalı sınıflandırıcılara dair kuramsal bilgiler verilmiştir.

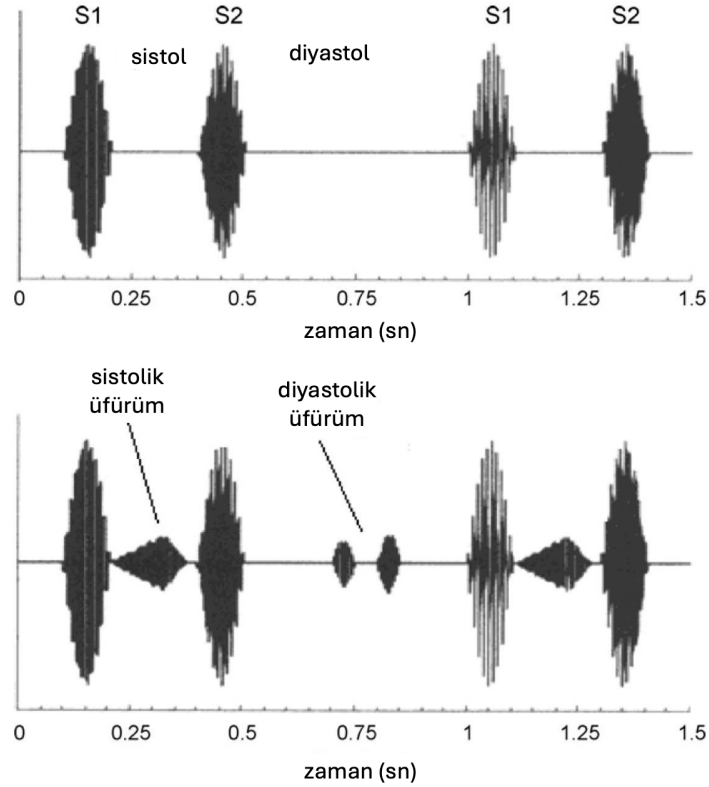
2.1. Kalbin Yapısı ve Fonokardiyogram Sinyalleri

Kalp, bir pompa gibi çalışarak vucuttaki tüm dokulara kanın iletilmesini sağlayan hayati öneme sahip organlardan biridir. Temel görevi, oksijence az (kirli) kanı akciğerlere gönderip, oksijence çok (temiz) kanı vücuda geri pompalamaktır [8].

Kalp aktivitelerinin iki türü vardır: elektrokardiyogram sinyali (EKG) ile temsil edilen elektriksel aktivite ve fonokardiyogram (FKG) sinyali olarak bilinen akustik sesler. FKG'ler, kalbin mekanik hareketiyle üretilen akustik dalgaların kayıtlarıdır [9]. Diğer bir deyişle, FKG sinyalleri kalp atımı sırasında çıkan seslerin grafik olarak kaydedilmesiyle oluşur. Kalp sesleri, kanın kalp kapaklarından akışı sırasında kapakların açılıp kapanması ve kalp kaslarının kasılma ve gevşeme safhalarında meydana gelen seslerdir [10]. Kalp sesinin ana bileşenleri sırası ile S1 sesi, S2 sesi, S1 sesi ile S2 sesi arasındaki geçen süre sistol, S2 ile S1 arasında geçen süre ise diyastol olarak adlandırılır [11].

Kalbe girip çıkan kan, 4 kapakçık tarafından kontrol edilir: mitral ve triküspit kapakçıkları kalbin odacıkları arasındaki kan alışverişini, pulmoner ve aort kapakçıkları ise kalp ile vücut arasındaki kan alışverişini sağlar [8]. Kalp döngüsü sırasında bu kapaklar açılıp kapanır ve bu süreçte sesler üretilir. S1, mitral ve triküspit kapakların ardışık kapanması sonucu oluşur. S2, aort ve pulmoner kapakların kapanması sonucu oluşur. Sistolik dönem, mitral ve triküspit kapakların kapanmasıyla başlar ve aort ve pulmoner kapakların kapanmasına kadar devam eder. Diyastolik dönem ise, aort ve pulmoner kapakların kapanmasından, mitral ve triküspit kapakların kapanmasına kadar olan zamanı içerir. Her iki sesin farklı

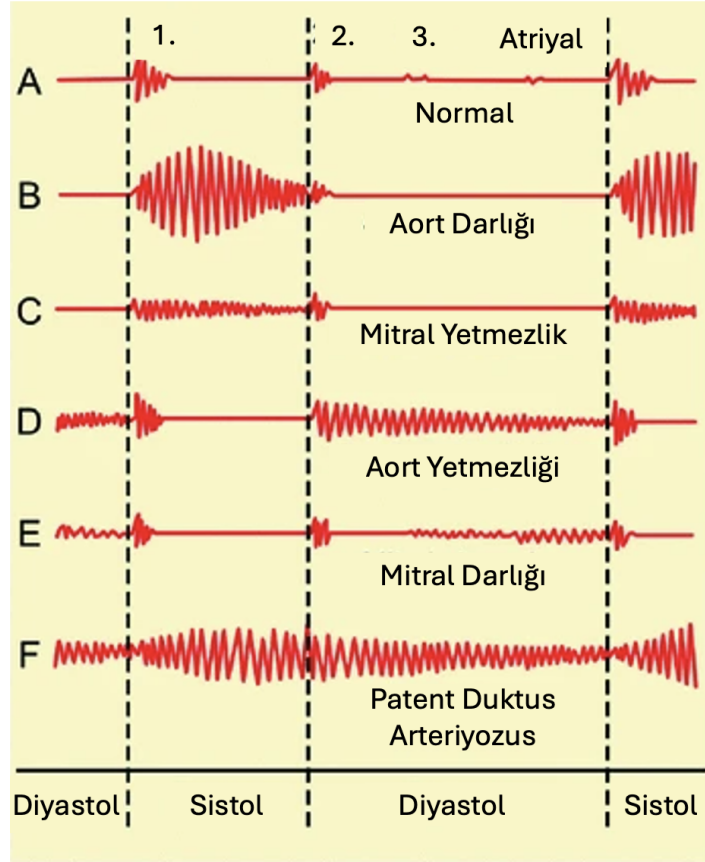
özellikleri vardır ve kalp kapak sorunları kalp sesinde anormal seslerin/üfürümlerin ortaya çıkmasına neden olur [12]. Bu üfürümler S1 ve S2 sinyalleri arasında bulunur. Kalp kapak sorunlarının bir çoğunda, belirli bir hastalıkla ilgili FKG sinyalindeki aktiviteler tek bir kalp döngüsü aralığında yer alır ve sürekli tekrar eder [13]. Şekil 2.1’de normal kalp sesine ait bir kardiyak döngü ile anormal kalp sesine ait bir kardiyak döngü gösterilmiştir.



Şekil 2.1 Sağlıklı Bir Kalpten Tipik Kalp Sesi Sinyali (Üst Resim) - Patolojik Bir Kalpten Sistolik ve Diyastolik Üfürümler Üreten Kalp Sesi Sinyali (Alt Resim) [14]

Kalp kapak sorunlarından dolayı kalp sesleri içerisinde oluşan üfürümler stetoskoplar ile doktorlar tarafından fark edilebilmektedir. Stetoskop ile kalp sesi dinlenip ön tanı yapılırken uygun odaklar kullanılmaktadır. Kalp kapakçıklarına bağlı olarak kalpte toplamda dört farklı odak bulunmaktadır. Bunlar; aort, pulmoner, triküspit ve mitral odaklardır. Stetoskop ile kalp sesi dinlenirken bu odaklar kullanılarak her bir hastalık için ona uygun odaktan alınan seslerde anormallik daha iyi duyulmaktadır.

Üfürümler genel olarak iki temel problemden biridir. Kapak darlığı, kapağın açılmasını engelleyerek kan akışında düzensizliğe sebep olur. Kapak yetmezliği, yetersiz kapanan kapaktan dolayı kanın bir kısmının geri kaçmasına sebep olur. Aort Darlığı (Aort Stenosis - AD)ve Mitral Yetmezlikde (Mitral Regurgitation - MY), sistolde üfürümler oluşur. Aort Yetmezliği (Aort Regurgitation - AY) ve Mitral Darlıkta (Mitral Stenosis - MD), diyastolde üfürümler oluşur. Patent Duktus Arteriyozus (PDA), sistol ve diyastol süreleri boyunca üfürüm oluşturur [15]. Şekil 2.2’de bahsedilen hastalıkların kalp seslerinin gösterimi bulunmaktadır.



Şekil 2.2 Normal ve Anormal Fonokardiyogram Sinyalleri [15]

2.2. Sayısal Stetoskop

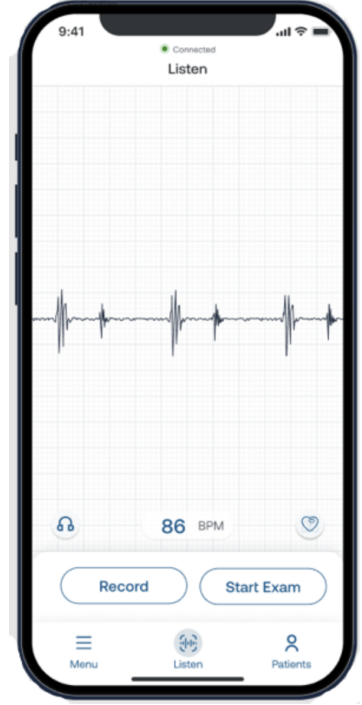
Sayısal stetoskop, kalp seslerinin dinlenmesini ve ses sinyalleri şeklinde kaydedilmesini sağlayan bir cihazdır. Kalp sesleri dinlenirken stetoskop açılmamış ise normal stetoskop

görevi görerek sadece kalp seslerinin dinlenmesini de sağlamakta, eğer cihaz açılmış ise kalp seslerinin akydedilmesini sağlamaktadır. Cihaz kalp seslerinin dinlenebilmesine ek olarak akciğer, bağırsaklar ve atardamaların da dinlenebilmesine olanak sağlamaktadır [16]. Şekil 2.3 (a)'da sayısal stetoskopun görseli bulunmaktadır.

Bluetooth bağlantısı ile telefon uygulamasına bağlanıp seçilen süre kadar kalp seslerinin kaydedilmesini ve kaydedilen verinin etiketlenmesi sağlamaktadır. Sesler kaydedilirken dinlemenin yapıldığı bölgeye dair odak bölgeleri seçilebilmekte, cinsiyet, oturarak yada ayakta dinleme gibi detayların her bir kayıt için kaydedilebilmesi sağlanmaktadır. Şekil 2.3 (b) görselinde uygulamanın ses kayıt ekran resmi bulunmaktadır. Ayrıca kayıtlara dair ek notlarda eklenebilmektedir. Sayısal stetoskopta aktif gürültü önleyici bulunmaktadır. Bu sayede ses kaydı sırasında ortamdaki gürültünün minimum seviyede kayda alınması sağlanmaktadır. Bu özellik kullanıcı seçimine bağlı olarak açılıp kapatılabilmektedir [16].



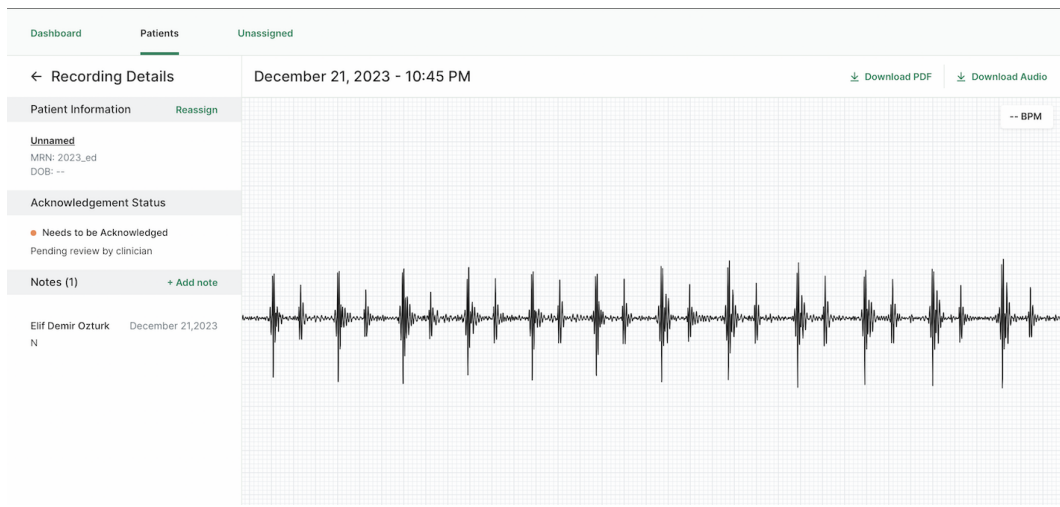
(a)



(b)

Şekil 2.3 a) 3M Littmann CORE Sayısal Stetoskop [16], b) Eko Telefon Uygulaması Ses Kayıt Ekranı [16]

Telefon uygulaması üzerinden kaydedilen veriler, internet üzerinden kullanıcı bilgileri ile girilen uygulama sayfasına otomatik olarak aktarılmaktadır. Bu sayfada verilerin gösterimi, dinlenebilmesi, sınıflandırılması, yönetimi ve indirilebilmesi sağlanmaktadır. Ses verileri 'wav' uzantılı ses dosyası olarak indirilebilmektedir. Ayrıca, uygulama üzerinden ses verilerinin zaman bağılı grafiksel gösterimini sunan pdf dosyaları da indirilebilmektedir. Şekil 2.4'de internet uygulaması üzerinde önceden kaydedilmiş bir verinin gösterildiği, indirme seçeneklerini içeren ekran görüntüsü bulunmaktadır.



Şekil 2.4 Eko İnternet Uygulaması Kayıtlı Veri Ekranı

Proje çerçevesinde alınan ve bölümümüzde bulunan 3M Littmann CORE Sayısal Stetoskop kullanılarak önceden yapılmış veri toplama çalışması ile HU-PCG veri setindeki verilerin toplanması işlemi gerçekleştirilmiştir. Bu tez çalışması kapsamında aynı sayısal stetoskop kullanılarak ek veri toplama çalışması gerçekleştirilmiştir.

2.3. Fonokardiyogram Sinyallerinin Sınıflandırılması Konusunda Yapılmış Çalışmalar

Kaynaklarda stetoskop ile kaydedilen FKG sinyalleri ile yapılan çalışmalarda ilk olarak belirlenen filtreler ile sesteki **gürültü temizlenmektedir** ve **normalizasyon** işlemi uygulanmaktadır. Sonraki aşamada çalışmaların bazıları **bölütleme** ile kalp seslerini bir

periyotluk parçalara böldükten sonrasında sınıflandırmayı gerçekleştirmektedir [13, 17–19]. Bazı çalışmalar kalp sesini önceden belirlenmiş sabit uzunlukta parçalara bölüp sınıflandırmayı bu parçalar üzerinden gerçekleştirmektedir [20–22]. Diğer çalışmalarda da kalp sesi bütün şeklinde işlenip sınılandırıcıya gönderilmektedir [5]. Sonraki aşama olan **öznitelik çıkarımı** aşaması bazı çalışmalarda atlanırken bazı çalışmalarda yoğun şekilde kullanılmaktadır [5, 21, 23–25]. Çıkan öznitelikler makine öğrenmesi tabanlı sınıflandırma yöntemlerine gönderilip normal anormal veya hangi anomali mevcut tespiti yapılmaktadır.

Bölütleme çalışmaları referans bazlı, zarf bazlı, özniteliğe dayalı, olasılıksal yöntemler olmak üzere dört kategoride toparlanarak en çok kullanılan yöntemler olmuştur [26]. Referans bazlı bölütleme algoritmalarında, elektrokardiyogram (EKG) gibi referans sinyaller kullanılır. Bu yöntemler genellikle donanımsal yük ve sinyallerin senkronize edilememesi nedenleriyle tercih edilmemektedir [19]. Zarf tabanlı yöntemlerde, FKG sinyalinden elde edilen zarf sinyalleri üzerinde temel kalp sesleri tanımlanır ve sinyalin tepe konumları bulunur ve bir döngüdeki bölgeler ayırt edilir [13]. Bölütleme yapmadan sinyali eşit parçalara ayırarak eğitime tercih edilen bir diğer yöntemdir [21]. Eşit uzunlukta parçalara ayırma sayesinde, ek bölütleme işlemlerine gerek kalmadan, tek sinyal birden fazla sinyale dönüştürülüp veri artışı sağlanmaktadır.

Öznitelik tabanlı yöntemler, kalp sesleriyle ilgili ayırt edici özelliklerin çıkarılıp, işlenmesine dayanır. Buradaki birçok çalışma zaman-frekans analizi teknikleri kullanılarak yapılmıştır. Kısa Zamanlı Fourier Dönüşümü (STFT), kalp seslerine yönelik öznitelikler çıkarmak için kullanılan yöntemlerden biridir [24]. STFT ile çıkarılan özniteliklerin zaman-frekans haritasına dönüştürülmesi ile hastalıklı örneklerle, sağlıklı örnekler arasındaki farklar belli olmaktadır [23]. Hem zaman hem de frekans açısından sabit çözünürlüğü nedeniyle STFT'nin yerine genellikle ölçeklenebilir çözünürlük sağlayabilen ve çeşitli dalgacıkların mevcudiyeti nedeniyle ilgili verilere daha uygun olan ayırık dalgacık dönüşümü (DWT) tercih edilebilir. Bu durum dalgacık dönüşümünü kalp sesi analizleri için avantajlı kılmaktadır [25]. Ses sinyalleri için bir diğer öznitelik çıkarma tekniği ise MFCC tekniğidir. Kaynak filtresi akustik modeline göre MFCC tekniği, kaynak ses sinyalinin ve onun geçtiği yolun özet, temsili modelini sağlar [27]. Kalp kapakçıklarının konumu

ve göğüste üfürümün yayılma yönü göz önüne alındığında, MFCC tekniğinin bu özelliği, bölütleme veya sınıflandırma algoritmaları için birçok çalışmada kullanılmaktadır [28]. Mitral kapak stenozu ve sistolik diyastol gibi rahatsızlıklar Dalga Biçim Diyagramı ile daha kolay bir şekilde tespit edilebilmektedir [29]. Bu öznitelik döngü sayısı, nabız gibi bilgileri barındırmaktadır.

Sınıflandırıcılar özniteliklerin sadece birisini kullanabilirken, birden fazla öznitelik türünü kaynaştırılarakta kullanılabilir. Kaynaştırmanın tespit başarımını olumlu yönde etkilediğini savunan bir çalışmada MFCC katsayıları ve DWT ile elde edilen özniteliklerin birleşiminin daha iyi sonuç verdiği belirtilmektedir [5]. MFCC katsayıları tek boyutlu öznitelik olarak kullanılmasına alternatif olarak bu katsayıların birleştirilmesi ile elde edilen zaman frekans temsili sunan spektrogram görüntüsü de kullanılabilir. Görüntü tek boyutlu öznitelikler ile doğrudan birleştirilemeyeceğinden 2 boyutlu evrişimsel sinir ağıyla elde edilen tek boyutlu öznitelik kaynaştırma için kullanılmaktadır [21]. Başka bir çalışmada PhysioNet verisetinde eğitilen model PASCAL verisetinde ince ayar (finetuning) yapılarak daha iyi sonuç elde etmeyi amaçlamaktadır [22]. Bu çalışmada ön işlem olarak yeniden örnekleme, gürültü silme ve sinyali sabit boyutlu parçalara bölme işlemleri yapılmaktadır. Sonrasında çıkan sinyal parçaları STFT tabanlı spektrogramlar üretmek için kullanmakta çıkan 2 boyutlu spektrogramlar öznitelik olarak evrişimsel sinir ağlarına yönlendirilip sınıflandırma yapılmaktadır. Aynı çalışmada, önceki çalışmalarla benzer şekilde sinyalleri ön işlemlerden geçirip ortaya çıkan sinyalden elde edilen spektrogram, evrişimsel sinir ağı üzerinden sınıflandırılmaktadır. Ek bir öznitelik çıkarımı uygulamadan ses sinyalini bütün olarak kullanan çalışmalarda bulunmaktadır. BU çalışmalardan birinde HVD veri setindeki 5 farklı sınıf için basit bir boyutlu CNN ağ yapısı ile sınıflandırma gerçekleştirilmiştir [30].

2.4. Mel Spektrogram

Ayrık Fourier Dönüşümü (DFT) zaman alanında ayrık (discrete) bulunan sinyalin frekans alanına dönüştürülmesini sağlar. Periyodik sinyaller için DFT sinyallerin analizi konusunda

yardımcı olsa da periyodik olmayan sinyaller için tek başına yetersiz kalmaktadır. Müzik, konuşma sesleri gibi periyodik olmayan sinyallerin analizinde spektrogram kullanılmaktadır. Spektrogram frekansa bağlı olarak zamandaki değişen genliğin gösterimidir. Zaman ve frekans değişimi iki boyutlu grafik üzerinde, genlik değişimi ise renklerle gösterilmektedir. Mel Spektrogram ise mel frekans ölçeği kullanılan bir spektrogram çeşitidir. İnsan kulağı düşük frekans aralıklarını daha iyi duyarken, yüksek frekans aralıklarını daha az duymaktadır. Bu sebeple, doğrusal frekans ölçeğine ile insan kulağının tepkisine daha uygun olan Mel ölçeği oluşturulmuştur [31].

Ses sinyallerinden Mel Spektrogram görseli oluşturulması aşağıdaki aşamalar ile sağlanmaktadır.

- 20-40 ms boyutlarında olacak şekilde okunan ses sinyali küçük ve eşit parçalara bölünür, bu parçalara çerçeve denilmektedir.
- Her bir çerçeve belirlenen pencere sinyali uygulanır. Çoğunlukla Hamming Pencere fonksiyonu kullanılır. Bu fonksiyonun kullanılmasının sebebi farklı çerçevelerdeki süreksizliği önleyip çerçeve başı ve sonundaki ani değişiklikleri ortadan kaldırmaktır [32]. Hamming pencere fonksiyonu Denklem (1) ile oluşturulmaktadır. Denklem içerisindeki 'N' sinyalin uzunluğunu, 'n' 0 ile N-1 aralığındaki sayıların indisini ifade etmektedir.

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

- Her bir pencereye DFT uygulanarak frekans alanına çevrilir.
- DFT sonuçlarının güç spektrumu elde edilir.
- Denklem (2) ile mel ölçekli Mel filtreler oluşturulur [25]. Denklemdeki 'f' Hz cinsinden frekans, 'mel' mel cinsinden frekanstır. Oluşturulan her filtre, üçgen şeklindedir ve belirli bir Mel frekans aralığını kapsar. Üçgen filtrelerin merkez frekansları Mel ölçeğine eşit aralıklı olarak yerleştirilir.

$$mel = 2595 \ln\left(1 + \frac{f}{700}\right) \quad (2)$$

- Elde edilen mel filtreler ile güç spektrumları çarpılır ve çarpımdan gelen sonuçlar toplanır, bu sayede mel spektrumlar elde edilir.
- Mel spektrumları Desibel ölçeğine çevrilir. Frekans gibi genlik artıkça insan kulağının algılama seviyesi aynı oranda artmaz. Desibel ölçeği insan kulağının algılamasına daha uygun logaritmik bir yapı sunar [32]. Denklem (3) bir enerji, güç değerini logaritmik ölçeğe çevrilmesini sağlar. S çevrilecek güç değeri, ref referans alınan güç değeri ve S_{dB} elde edilen logaritmik güç değerini ifade etmektedir.

$$S_{dB} = 10 \log_{10} \left(\frac{S}{ref} \right) \quad (3)$$

Mel Spektrogram oluşturulmasında kullanılan bazı parametreler vardır. Sinyallerdeki sınıflandırmada gerekli özelliklerin çıkarılması için parametrelerin seçimi önemlidir. Örnekleme hızı, pencere boyutu, adım boyutu, mel filtre sayısı, DFT Boyutu, minimum ve maksimum frekans değerleri mel spektrogramdaki oluştururken belirlenen parametrelerdir.

Örnekleme Hızı (Sampling Rate), kalp seslerindeki önemli frekans bileşenlerinin doğru bir şekilde yakalanmasını sağlar. Daha yüksek örnekleme hızları, daha ayrıntılı frekans çözünürlüğü sağlarken, daha fazla hesaplama maliyeti gerektirir.

Pencere Boyutu (Window Size) ve Adım Boyutu (Hop Length), zaman-frekans çözünürlüğünü belirler. Küçük pencere boyutu daha iyi zaman çözünürlüğü ve zamana bağlı geçişleri daha iyi yakalar. Büyük pencere boyutu daha iyi frekans bilgisi yakalarken zaman bağlı geçişleri daha kötü yakalar. Kısa adım boyutu yumuşak geçişli spektrogram ve daha iyi zaman çözünürlüğü sağlar, ancak yüksek hesaplama maliyeti gerektirir. Geniş adım boyutu ise sesdeki ince geçişleri kaçırabilir ve daha sert geçişli spektrogram oluşturur.

DFT Boyutu (DFT Size), frekans çözünürlüğünü belirler. Daha yüksek DFT boyutu, daha iyi frekans çözünürlüğü sağlarken daha fazla hesaplama maliyeti gerektirir. Düşük DFT boyutu ise frekans detaylarının kaybedilmesine sebep olabilir.

Mel Filtre Sayısı (Number of Mel Filters), frekans çözünürlüğünü belirler. Yüksek filtre sayısı frekans çözünürlüğünü artırır ve sesdeki detayları daha iyi yakalar, ancak hesaplama

maliyetini artırır. Daha az filtre sayısı frekans çözünürlüğünü düşürürken daha basit spektrogram sağlar ve veri boyutunu küçültür.

Seçilen minimum frekans değeri sinyaldeki düşük frekansları yakalarken, yüksek frekans değeri yüksek frekans detaylarını yakalar.

2.5. Danışımli Öğrenme ile Sınıflandırma

Makine öğrenmesi; bilgisayarı ilgili iş için spesifik olarak yönlendirmeden belli yöntemlerle o işi bilgisayarın insanlara benzer şekilde öğrenmesini sağlamaktadır. Makine öğrenmesinde farklı öğrenme teknikleri bulunmaktadır. Bunlar Danışımli Öğrenme (Supervised Learning), Danışımli Öğrenme (Unsupervised Learning), Pekiştirmeli Öğrenme (Reinforcement Learning)'dir. Danışımli Öğrenme ise etiketsiz veriler ile modelin öğrenmesidir. Pekiştirmeli Öğrenme, ödül ceza ile doğru gidişatı öğrenen modellerdir. Danışımli Öğrenme etiketli veriler ile sınıflandırılmayı öğrenen modelleri içermektedir.

Danışımli Öğrenme ile Sınıflandırma konusunda farklı yöntemler bulunmaktadır. Bu çalışmada kullanılan Doğrusal Sınıflandırıcı, K En Yakın Komşu (k-NN), Destek Vektör Makinaları (SVM), Yapay Sinir Ağları, Derin Öğrenme yöntemleri bu kısımda anlatılacaktır.

2.5.1. Doğrusal Sınıflandırıcısı (Mahalanobis Mesafe)

Mahalanobis mesafesi, Denklem (4) ile veri kümesinin korelasyonlarını dikkate alarak bir nokta ile bir dağılım arasındaki mesafeyi ölçer [33].

$$d_M(\mathbf{x}) = \sqrt{(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})} \quad (4)$$

\mathbf{x} : veri noktası

$\boldsymbol{\mu}$: ortalama vektörü

$\boldsymbol{\Sigma}$: kovaryans matrisi

Lineer Mahalanobis Mesafe sınıflandırıcısı, mahalanobis mesafesini en aza indirerek bir veri noktasını birkaç sınıftan birine atar. Bu sınıflandırıcı Denklem (5) ile yeni gelen veri için en yakın sınıfı bulup uygun sınıfı seçmeye çalışır.

$$\hat{y} = \arg \min_i (\mathbf{x} - \boldsymbol{\mu}_i)^T \boldsymbol{\Sigma}_i^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) \quad (5)$$

\mathbf{x} : veri noktası

$\boldsymbol{\mu}_i$: ilgili sınıfın ortalaması

$\boldsymbol{\Sigma}_i$: ilgili sınıfın kovaryans matrisi

Bu sınıflandırıcı, özellikler arasındaki korelasyonları etkili bir şekilde ele alır ve bu da onu birçok senaryoda Öklid mesafesine göre avantajlı hale getirir.

2.5.2. K En Yakın Komşu (k-NN)

k-En Yakın Komşu (k-NN) algoritması, sınıflandırma ve regresyon problemleri için kullanılan parametrik olmayan bir yöntemdir. Bu algoritma, bir sorgu noktası ile eğitim veri kümesindeki tüm noktalar arasındaki mesafeyi (genellikle Öklidyen mesafe) hesaplayarak çalışır ve en yakın k noktayı belirler. Sınıflandırma için, sorgu noktasını en yakın k komşusu arasında en yaygın olan sınıfa atar ve çoğunluk oyu yaklaşımını kullanır [34]. Algoritma, sorgu noktasının tüm eğitim noktalarına olan mesafesini hesaplama gereksinimi nedeniyle fazla hesaplama gerektirir ve bu nedenle büyük veri kümeleri için kullanılması ve uygun k değerinin bulunması zordur [35].

2.5.3. Destek Vektör Makinaları (SVM)

Destek Vektör Makineleri (SVM), sınıflandırma ve regresyon problemlerinde kullanılan danışmalı öğrenme algoritmalarından biridir [36]. SVM'in temel amacı, bir veri kümesindeki farklı sınıflar arasındaki marjı maksimize eden optimal hiper düzlemi bulmaktır.

İkili sınıflandırma problemlerinde, bu hiper düzlem, bir sınıfın veri noktalarını diğer sınıflardan en iyi şekilde ayıran bir düzleme denk gelmektedir. Denklem (6)'deki w ve b değerleri hiper düzlemi tanımlar [37].

$$w \cdot x + b = 0 \quad (6)$$

w : ağırlık vektörü

x : giriş özellik vektörü

b : yanlılık

SVM, hiperdüzlem ile her sınıftan en yakın veri noktaları (destek vektörleri) arasındaki mesafeyi maksimize etmeyi amaçlar. Denklem (7)'ü maximize edebilmek için $\frac{1}{2}\|w\|^2$ fonksiyonu fonksiyonunu minimize ederek elde edilir [38].

$$y_i(w \cdot x_i + b) \geq 1 \quad (7)$$

x_i : giriş verisi

y_i : çıkış verisi

Pratikte, birçok gerçek dünya problemi doğrusal olarak ayrılabilir değildir. Bunu çözmek için SVM'ler, verileri doğrusal ayrımın mümkün olduğu daha yüksek boyutlu bir uzaya taşırlar, bu duruma çekirdek hilesini denilir. Yaygın olarak kullanılan çekirdekler arasında polinomial çekirdek, radyal taban fonksiyonu (RBF) çekirdeği ve sigmoid çekirdeği bulunur. Çekirdek fonksiyonu $K(x_i, x_j)$, dönüştürülmüş özellik uzayındaki iç çarpımı hesaplar, böylece SVM'lerin dönüşümü açıkça gerçekleştirmeden doğrusal olmayan karar sınırlarını bulmasına olanak tanır. SVM optimizasyon probleminin dual formu bu çekirdek fonksiyonlarını kullanır ve kuadratik programlama teknikleriyle çözülür [39].

2.5.4. Çok Katmanlı Perceptron (MLP)

Perceptron, doğrusal ikili sınıflandırıcı yapısına sahip bir tür yapay sinir ağı modelidir [40]. En eski yapay nöron modellerinden biridir ve daha karmaşık sinir ağlarının temel yapı taşı olarak hizmet eder. Perceptronda her bir girdinin değeri, ona karşılık gelen ağırlıkla çarpılır ve tüm sonuçlar toplanır, toplama eğilim (bias) değeri eklenir. Denklem (8) burada yapılan işlemi göstermektedir.

$$w \cdot x + b = y \quad (8)$$

w_i : ağırlık vektörü

x_i : giriş vektörü

y_i : çıkış vektörü

Denklem (8)'deki çıkış değeri, bir aktivasyon fonksiyonu (genellikle basit bir adım fonksiyonu) kullanılarak perceptron çıktısı üretilir. Eğer çıkış değeri belirli bir eşik değerinin üzerindeyse, perceptron 1 çıktısı verir; aksi takdirde 0 çıktısı verir. Bu çıktı değeri perceptronun sınıflandırma çıktısıdır. Eğer perceptron hatalı bir sınıflandırma yaparsa, ağırlıklar ve eğilim değeri, hatayı azaltacak şekilde güncellenir. Bu süreç "öğrenme" süreci olarak adlandırılır.

Perceptron, yalnızca doğrusal olarak ayrılabilir problemlerde başarılıdır. Daha karmaşık ve doğrusal olmayan problemleri çözmek için ise çok katmanlı yapay sinir ağları ve daha gelişmiş aktivasyon fonksiyonları kullanılır. Çok Katmanlı Perceptron (Multi-Layer Perceptron, MLP), giriş katmanı, bir veya daha fazla gizli katman ve çıkış katmanından oluşan, çok katmanlı bir düğüm yapısına sahip bir tür çok katmanlı yapay sinir ağıdır. Belirli bir katmandaki her düğüm veya nöron, sonraki katmandaki her düğüme bağlıdır ve her bağlantı, eğitim sırasında ayarlanan bir ağırlık ile ilişkilidir. MLP'ler, zincir kuralı ile her ağırlığa göre bir kayıp fonksiyonunun gradyanını hesaplayarak hatayı en aza indirmek için ağırlıkları iteratif olarak güncelleyen, geri yayılım (backpropagation) adı verilen danişımli

bir öğrenme tekniğini kullanır. Gizli katmanlarda kullanılan aktivasyon fonksiyonları tipik olarak sigmoid, hiperbolik tanjant (tanh) veya doğrultulmuş lineer birim (ReLU) gibi doğrusal olmayan fonksiyonlardır, bu da MLP'lerin verilerdeki karmaşık desenleri ve etkileşimleri yakalamasını sağlar. MLP'ler, birçok derin öğrenme mimarisinde temel olup, görüntü ve konuşma tanıma ile doğal dil işleme gibi çeşitli alanlarda geniş çapta uygulanmıştır [41, 42].

2.5.5. Evrişimsel Sinir Ağları (CNN)

Evrişimsel sinir ağları (CNN), ardışık evrişim katmanlarından oluşan bir yapay sinir ağıdır. Evrişim filtrelerinin ağırlıkları öğrenilebilir değerler içermektedir. Bu ağırlıkların geri yayılım yoluyla (backpropagation) öğrenilmesi, ilk olarak LeCun ve ekibi tarafından LeNet ağıının önerildiği çalışmada gerçekleştirilmiştir [43]. El yazısıyla yazılmış karakterlerin tanınmasını amaçlayan LeNet çalışması MNIST verisetini kullanarak eğitim gerçekleştirmiştir [44]. Büyük miktarda parametrenin verilerden öğrenilmesi, büyük veri kümeleri ve paralel hesaplama kaynakları gerektirir. İlk başlarda, derin öğrenme algoritmaları Merkezi İşlem Birimleri (CPU) kullanılmıştır, bu da uzun eğitim sürelerine yol açmıştır. Grafik İşlem Birimi (GPU) ise daha kısa eğitim sürelerini mümkün kılar. Evrişimsel sinir ağlarının bir diğer avantajı, paylaşımlı parametreler kullanarak parametre sayısının azaltılmasıdır.

Evrişimsel sinir ağlarının başka bir kullanımı ise tek boyutlu sinyallerin işlenmesidir. Tek boyutlu sinyallerin işlenmesi, zaman serileri analizi, konuşma tanıma, biyomedikal sinyaller (örneğin EKG ve EEG) gibi çeşitli uygulama alanlarında büyük önem taşır. Tek boyutlu sinyaller için kullanılan CNN mimarileri, iki boyutlu görüntü verilerini işlemek için kullanılan mimarilere benzer şekilde çalışır, ancak filtreler ve katmanlar tek boyutlu veri üzerinde uygulanır. Bu yöntemler, sinyal özelliklerinin otomatik olarak çıkarılmasını ve sınıflandırılmasını sağlar. Örneğin, bir konuşma tanıma sistemi, ses dalgası verilerinden anlamlı özellikleri çıkarabilir ve bu özellikleri kullanarak konuşma

tanıma işlemini gerçekleştirebilir. Benzer şekilde, biyomedikal sinyal işleme alanında, derin öğrenme algoritmaları hastalıkların erken teşhisi ve izlenmesi için kullanılabilir.

Tek boyutlu evrişimsel sinir ağlarında, birden fazla katmandan oluşup her katmanında tek boyutlu (1D) evrişim işlemi uygulanmaktadır. Tek boyutlu (1D) evrişim, bir filtrenin giriş sinyali üzerinde kayarak, eleman bazında çarpımlar gerçekleştirmesi ve sonuçları toplayarak çıktı oluşturması işlemlerini içermektedir. Filtre boyutu, adım sayısı ve doldurma gibi ana parametreler, filtrenin giriş verileriyle etkileşimini belirler. 1D evrişimsel katmanlar, yerel örüntülerin tespit edilmesi, tam bağlantı katmanlarına (fully connected) kıyasla parametre sayısını azaltma gibi avantajlar sunar; bu, daha hızlı eğitim süreçleri ve aşırı öğrenme (overfit) sorununun engellenmesini sağlar.

3. VERİ SETLERİ VE YÖNTEM

Bu başlık altında, çalışmada kullanılan FKG sinyallerini içeren veri setleri ve hastalık tespiti için önerilen yöntemler hakkında ayrıntılı bilgiler anlatılmaktadır. İlk olarak kullanılan HU-PCG, HVD, PASCAL ve Physionet veri setleri anlatılıp, ikinci kısımda önerilen yöntemler işlenmiştir.

3.1. Veri Setleri

Bu çalışmada önerdiğimiz makine öğrenmesi tabanlı yöntemler danışımlı öğrenme (supervised training) tekniğini kullanmaktadır. Danışımlı öğrenme için FKG sinyali ve her bir sinyale denk gelen gerçek etiketlerin (ground truth) bulunması gerekmektedir. Girdi ve gerçek etiketlerin bulunduğu bölümümüz tarafından toplanmış FKG sinyalleri ve etiketlerini içeren HU-PCG veri setine ek olarak 1000 adet FKG sinyali içeren HVD veri seti, 461 adet FKG sinyali içeren PASCAL veri seti ve 3240 adet FKG sinyali içeren PhysioNet veri seti yöntemler geliştirilirken ve test edilirken kullanılmıştır. Kullandığımız her veri seti FKG sinyalleri için normal anormal bilgisini içermektedir. Kardiyovasküler hastalığın hangi türü olduğu bilgisi ise sadece HU-PCG ve HVD veri setlerinde bulunmaktadır. Bölülümüzce

Veri Seti	Toplam	Normal	Anormal	AD	MY	MD	PDA	AY	TY	MVP
HU-PCG	170*	107	63	23	20	10	5	3	2	-
HU-PCG-T	13	2	11	2	5	-	-	-	4	-
HVD	1000	200	800	2000	200	200	-	200	-	200
PASCAL	461	320	141	-	-	-	-	-	-	-
PhysioNet	3240	2575	665	-	-	-	-	-	-	-
PhysioNet-D	351	150	151	-	-	-	-	-	-	-
HPP***	3821**	2982	839	-	-	-	-	-	-	-
HP****	581**	407	174	-	-	-	-	-	-	-

Tablo 3.1 Veri Setlerine Dair İstatik Bilgileri

* Çalışmada HU-PCG veri seti için 107 adet normal, 23 adet AD, 20 adet MY toplamda 150 adet FKG sinyali kullanılmıştır.

** Bu veri seti oluşturulurken HU-PCG veri setinden 150 adet sinyal eklenmiştir.

*** Bu veri seti HU-PCG, PASCAL ve PhysioNet veri setlerinin birleştirilmesi ile oluşturulmuştur.


**** Bu veri seti HU-PCG ve PASCAL veri setlerinin birleştirilmesi ile oluşturulmuştur.

toplanan HU-PCG veri setinin hastalığın türü ile ilgili içerdiği sınıf sayısı 6, HVD verisetinin içerdiği sınıf sayısı ise 5'tir. Verisetlerinin ayrıntılı istatistikleri Tablo 3.1'de bulunmaktadır. Bahsi geçen veri setleri alt başlıklarda detaylı bir şekilde açıklanmıştır.

Yaptığımız çalışmaların temel amacı, bölümümüz tarafından kaynaklara kazandırılan HU-PCG verisetinde sonuçlar elde etmektir. Bunun sebebi ise, HU-PCG veriseti toplanırken kullanılan cihaz ve ortam şartlarının ileride yapılması planlanan nihai ürünün kullanacağı cihaz ve ortam şartları ile büyük benzerlik göstermesidir. Diğer 3 verisetinin kullanılma amaçlarından ilki önerdiğimiz yöntemlerin genelleme yeteklerinin olup olmadığını görebilmektir. İkinci amaç, ön eğitim tekniğini kullanarak HU-PCG verisetindeki başarıyı arttırmaktır. Üçüncü ve son amaç önerdiğimiz yöntemi kaynaklardaki diğer yöntemlerle karşılaştırmaktır.


3.1.1. Birinci Veri Seti: HU-PCG

3MTM Littmann® 3200 Elektronik Stetoskop ile toplanan FKG sinyallerinden oluşan veri setidir. Veri seti 106 normal, 62 adet anormal sinyalden oluşmaktadır. Anormal sinyallerin sınıfları ve veri sayıları şu şekildedir: 20 adet Mitral Darlığı (MD), 31 adet Mitral Yetmezliği (MY), 39 adet Aort Darlığı (AD), 4 adet Patent Duktus Arteriozus (PDA), 2 adet Triküspid Yetmezliği (TY), 3 adet Aort Yetmezliği (AY) ve 1 adet Ventriküler Septal Defekt (VSD). Diğer verilerden az miktarda bulunması sebebiyle bu projede sadece 107 adet normal, 23 adet AD, 20 adet MY toplamda 150 adet FKG sinyali kullanılmıştır. Verilerin örnekleme sıklığı 4000 Hz'dir. Şekil 3.1a ve Şekil 3.1b normal ve anormal (AD) olan iki farklı sinyalin grafikleri gösterilmektedir.



Şekil 3.1 HU-PCG Veri Setindeki FKG Sinyal Örnekleri: a) Normal, b) MY Etiketli

Bu çalışma kapsamında ek veri toplama çalışması yapılmıştır. Veri toplama çalışmasında 16 farklı kişiden toplamda 22 adet veri toplanmıştır. Ancak toplanan veriler değerlendirildiğinde bu verilerden 10 farklı kişiye ait olan toplam 13 adet veri test amaçlı seçilmiştir. On kişiden üçünde iki farklı hastalık bulunmaktadır. Veriler toplanırken iki farklı hastalık bulunan hastalardan hastalığa uygun odaklardan alınacak şekilde iki farklı ses kaydı alınmıştır. Veriler otuz saniye boyunca alınmış sonrasında kaydedilmiştir. Verilerin örnekleme sıklığı 4000 Hz'dir. Yeni toplanmış veriler arasından sırası ile normal, Aort Darlığı (AD) etiketlerine sahip FKG sinyalleri Şekil 3.2a ve Şekil 3.2b gösterilmiştir.



Şekil 3.2 Yeni Toplanmış Verilerden FKG Sinyal Örnekleri: a) Normal, b) AD Etiketli


Çalışmada yeni toplanan test verileri test edilirken HU-PCG veri setinin eğitim, doğrulama ve test olarak üçe bölünmesi sonucu oluşan test setine eklenerek kullanılmıştır. Bu çoğaltılmış test seti kullanıldığında dokümanda bahsedilirken "HU-PCG-T" olarak bahsedilmiştir.

3.1.2. İkinci Veri Seti: HVD

Toplam 1000 adet FKG sinyali içeren veri seti olup, Yaseen ve ark. tarafından yayınlanan çalışmada HVD veri seti paylaşılmıştır [5]. Bu veri setinde normal, AD, MY, MD ve MVP (Mitral Kapak Prolapsusu-Mitral Valve Prolapse) olmak üzere beş farklı sınıfta veri seti bulunmakta ve her bir sınıftan 200 tane FKG sinyali bulunmaktadır. Verilerin örnekleme sıklığı 8000 Hz'dir. Şekil 3.3a ve Şekil 3.3b normal ve anormal (AD) iki farklı sinyalin zamana bağlı çizimlerinin görseli bulunmaktadır.


3.1.3. Üçüncü veri Seti: PASCAL

PASCAL Yarışmasında kalp seslerinin blütlenmesi konusunda A veri seti, sınıflandırılması konusunda B veri seti paylaşılmıştır [4]. Bu çalışmada B veri seti kullanılmıştır. PASCAL B veri seti 320 normal, 141 anormal (kalp üfürümleri ve ekstra sistol sesleri içerir) olmak üzere toplamda 461 FKG sinyalinden oluşmaktadır. Ayrıca veri setindeki veriler gürültülü ve



Şekil 3.3 HVD Veri Setindeki FKG Sinyal Örnekleri: a) Normal, b) AD Etiketli


gürültüsüz şekilde de sınıflandırılmıştır. Verilerin örnekleme sıklığı 4000 Hz'dir. Şekil 3.4a ve Şekil 3.4b'de bu veri setine ait normal, anormal iki farklı FKG sinyalinin grafiği bulunmaktadır.



Şekil 3.4 PASCAL Veri Setindeki FKG Sinyal Örnekleri: a) Normal, b) Anormal

3.1.4. Dördüncü veri seti: PhysioNet

PhysioNet yarışmasında paylaşılan veriseti, 2575 normal ve 665 anormal olmak üzere toplam 3240 tane FKG sinyalinden oluşmaktadır [3]. Bu veri setinde de anormal verileri ayrıca sınıflandırılmamıştır. Verilerin örnekleme sıklığı 2000 Hz'dir. Şekil 3.5a ve Şekil 3.5b'de normal ve anormal bu veri setine ait FKG sinyalleri gösterilmektedir.



Şekil 3.5 PhysioNet Veri Setindeki FKG Sinyal Örnekleri: a) Normal b)Anormal

Yarışmada yarışmacıların aldığı sonuçları karşılaştırabilmek için ayrıca doğrulama veri seti paylaşılmıştır. Bu veri setinde 150 adet normal, 151 adet anormal olmak üzere toplamda 301 adet veri bulunmaktadır. Verilerin yapısı yukarıda bahsedilenler ile aynıdır. Çalışmada bu veri setinden "PhysioNet-D" olarak bahsedilmiştir.

3.2. Yöntem

FKG sınıflandırma yöntemleri, uçtan uca öğrenilen yöntemler (end-to-end learning) ve aşamalı yöntemler olarak iki ana grupta toplanmıştır. Uçtan uca öğrenilen yöntemlerde sınıflandırıcıya girmeden önce sinyal üzerinde yapılan işlemlerin azaltılması amaçlanmaktadır. Bu sayede çok aşamalı yöntemlerdeki, periyot bazlı bölütleme ve uygun özniteliklerin çıkarılması aşamaları atlanabilmektedir. Bu aşamalar yerine model içerisinde öğrenilen parametrelerin artırılması ile gerek periyot bazlı bölütleme gerekse uygun özniteliklerin örtük (implicit) bir şekilde öğrenilmesi beklenmektedir. Periyot bazlı bölütleme ve öznitelik çıkarımı aşamalarında tercih edilen öznitelik vektörleri (zamana bağlı öznitelikler ve MFCC öznitelikleri) ve bu vektörlerin işlenmesinde belirlenen hiperparametreler sinyal kaydının alındığı cihaz ve ortama bağlı olarak değişiklik gösterebilmektedir. Yeni bir cihaza geçildiğinde parametrelerin yeniden ayarlanması gerekebilmektedir. Uçtan uca öğrenme ile bu aşamadaki hiperparametrelere gerek kalmamaktadır.

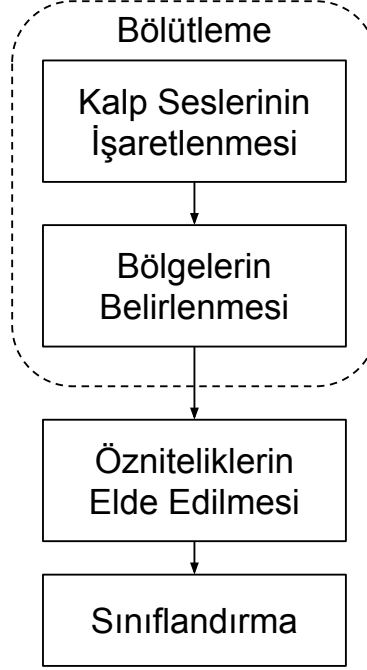
Uçtan uca öğrenilen yöntemlerin öğrendiği parametre sayısının artmasından dolayı eğitilen modellerin genelleme yeteneği edinmesi yerine aşırı öğrenme ile ezberlemesi olasılığı artmaktadır. Bunu engellemek için eğitim için kullanılan veri setinin miktar olarak fazla ve çeşitli olması gerekmektedir. Veri setinin küçük olduğu durumlarda öğrenilen parametre sayısının azalmasından dolayı çok aşamalı yöntemler avantajlı konuma gelmektedir. Uçtan uca öğrenilen yöntemlerin öznitelik çıkarımı ve bölütleme işlemlerini model içinde örtük (implicit) bir şekilde öğrenmesine karşın aşamalı sınıflandırmalardaki bölütleme ve öznitelik çıkarımının açık (explicit) bir şekilde yapılması bu yöntemleri daha deterministik bir hale getirmektedir.

Bu çalışmada kalp seslerinin sınıflandırılmasında uçtan uca öğrenilen ve aşamalı sınıflandırma gerçekleştiren farklı yöntemler incelenmiştir. Aşamalı sınıflandırma gerçekleştiren yöntemlerden birinde ön işleme, S1 ve S2 bölgeleri tanımlama, bölütleme, özniteliklerin çıkarılması ve en sonunda da makine öğrenmesi tabanlı sınıflandırma aşamalarında oluşmaktadır [7]. Bu yöntem ile geliştirilmiş çalışma ile aşamalı sınıflandırma incelenmiş, tekrar çalıştırılıp sonuçlar alınmıştır. Uçtan uca öğrenilen yöntemleri inceleyebilmek için ise iki farklı bir boyutlu ve iki boyutlu CNN içeren modeller tasarlanmış, bu modeller sayesinde derin öğrenme yöntemleri ile sınıflandırma üzerinde çalışılmıştır. 3.2.1 başlığı altında beş aşamalı önceden yapılmış çalışmaya dair bilgiler verilmiştir. 3.2.2 başlığı altında bu tez çalışmasında gerçekleştirilen derin öğrenme ile sınıflandırma için tasarlanmış modeller ve kullanılan yöntemler anlatılmıştır.

3.2.1. Beş Aşamalı Makine Öğrenmesi Tabanlı Sınıflandırma

Öznitelik çıkararak sınıflandırma yaklaşımı beş evreli olup en sonunda sınıflandırma yapılmaktadır. Ön işleme, S1 ve S2 bölgelerini tanımlama, bölütleme, özniteliklerin çıkarılması ve son olarak da sınıflandırma aşamalarından oluşmaktadır. Şekil 3.6'da bu yaklaşıma dair iş akışını gösterilmektedir. Bu çalışmada sınıflandırıcı eğitimleri HU-PCG veri seti ile gerçekleştirilmiştir [7]. Bu yaklaşımla önceden yapılmış çalışma incelenmiş

ve çalışmadaki kodların çalıştırılması ile bu dokümandaki bu beş aşamalı yaklaşımla ilgili sonuçlar elde edilmiştir.




Şekil 3.6 İş Akışı [7]

3.2.1.1. Ön İşleme

FKG kalp sesi sinyaline 5-700 frekans aralığında bandpass filtre uygulanıp, sonrasında ses mutlak maximumuna göre normalize edilmiştir [45]. Şekil 3.7a'de HU-PCG veri setinden seçilmiş bir örneğin zamana bağlı grafiksel gösterimini sunmaktadır. Şekil 3.7b'de ise Şekil 3.7a'daki sinyalin ön işlenmiş görseli bulunmaktadır.


3.2.1.2. S1 ve S2 Tanımlama

Ön işleme aşamasından geçirilmiş FKG sinyali kullanılarak Mel ölçekli enerji spektrumuna Sayısal Dalgacık Dönüşümü (DWT) uygulanmasıyla elde edilen öznitelik vektörü, sinyalin eğri enerji spektrumunun Mel-filtre bankasından geçirilmesiyle oluşturulmuştur. Filtre katsayıları üzerinde DWT uygulaması için Daubechies - 8 (db8) tipi bir dalgacık tercih edilmiştir. Filtrenin beşinci detay katsayıları, kalp seslerindeki S1 ve S2



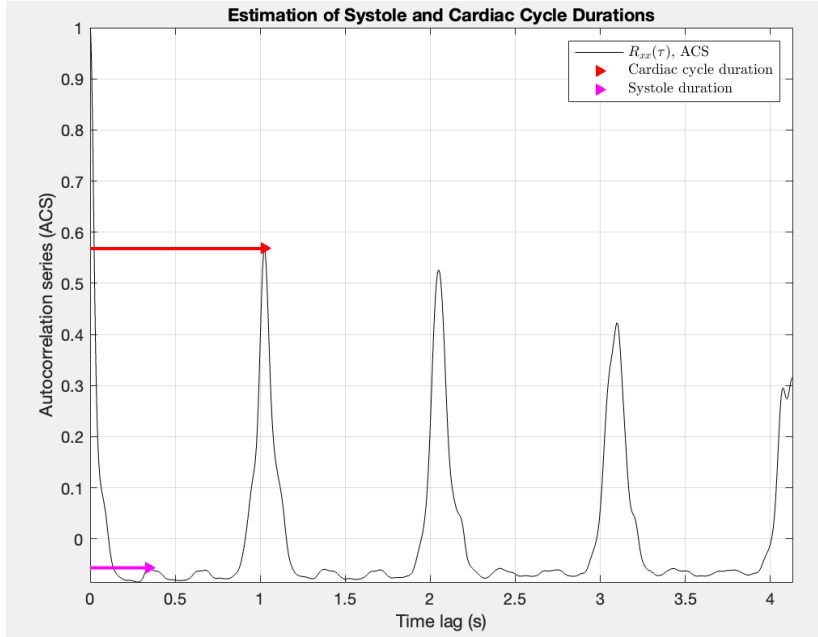
Şekil 3.7 HU-PCG Veri Setindeki Bir FKG Sinyali: a) Sinyalin İşlenmemiş Hali, b) Sinyalin Ön İşlenmiş Hali

bölgeleri tanımlama adımı için öznitelik vektörü olarak seçilmiştir [46], [47]. Beşinci detay katsayı vektörü Şekil 3.8’de verilmiştir.




Şekil 3.8 Beşinci Detay Katsayı Vektörü

Öznitelik vektörünün oto-korelasyon serisi ve ön bilgiler ortalama kalp döngüsü ve sistol sürelerinin tahmin edilmesinde kullanılmıştır [7]. Şekil 3.9’de katsayı vektörünün bir kısmı üzerinde tahmin edilmiş kalp döngüsü süresi ve sistol süresi gösterimi yapılmıştır.



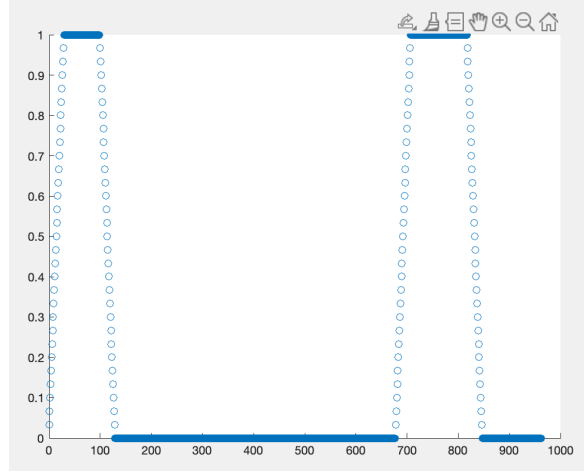
Şekil 3.9 Katsayı Vektörü Üzerinde Kalp Döngüsü Süresi ve Sistol Süresi

Öznelik vektörü üzerinde, dinamik olarak değişen eşik değerleri kullanılarak sesteki tepe noktaları tespit edilmiştir. Belli bir eşik değerinin altında olan veya bir diğerine çok yakın olan tepe noktaları kontrol edilmiş, elenmiştir [7]. Şekil 3.10'de beşinci katsayı vektörü üzerindeki tahmin edilmiş tepe noktaları gösterilmiştir.



Şekil 3.10 Katsayı Vektörü Üzerindeki Tepe Noktaları

Tepe noktalarının konumu ve kalp döngüsü, sistol süreleri bilgileri kullanılarak, öznitelik vektörü üzerinde çerçeve sinyali oluşturularak S1 ve S2 bölgeleri tanımlanmıştır [7]. Şekil 3.11’de S1 ve S2 bölgelerinin bulunabilmesi için kullanılan çerçeve sinyali gösterilmiştir.

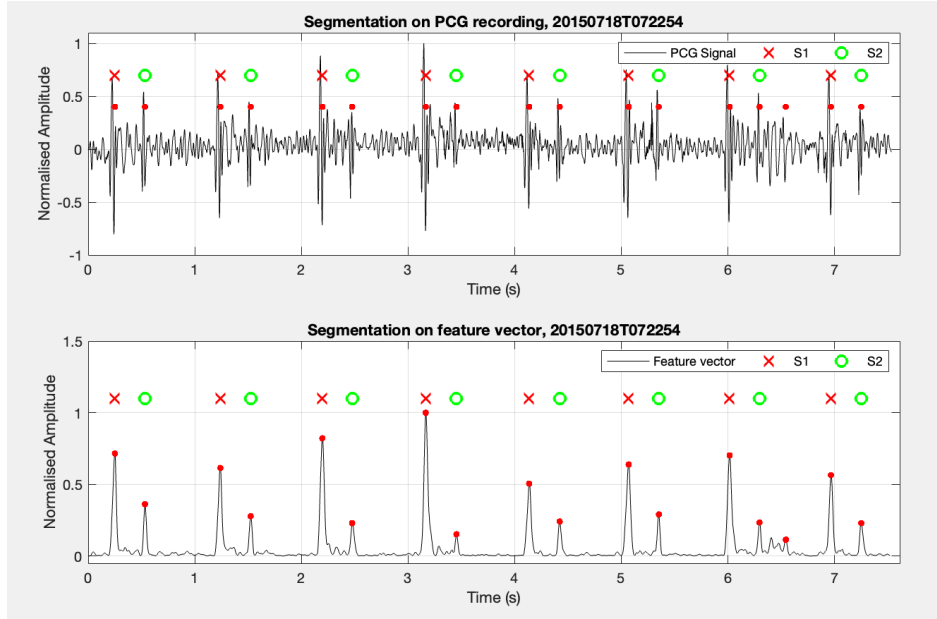


Şekil 3.11 Çerçeve Sinyali

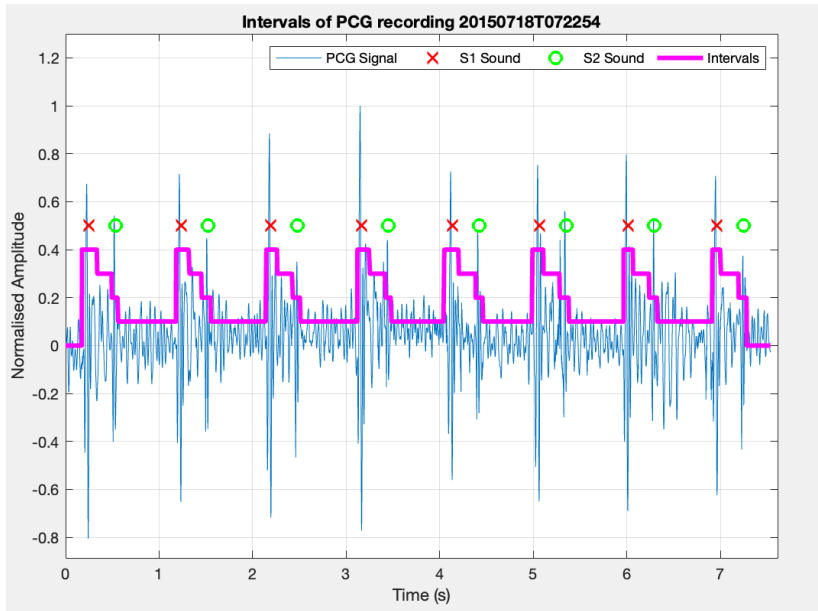
Son olarak, yanlış etiketlenmiş kalp seslerini düzeltmek için bir hata düzeltme adımı kullanılır [7]. Şekil 3.12’de tahmin edilmiş S1 ve S2 bölgelerinin yerleri, adaptif eşikleri ve tepe konumları (öznitelik vektöründeki kırmızı noktalar) FKG sinyali ve öznitelik vektöründe gösterilmiştir.

3.2.1.3. Bölütleme

S1, sistol, S2, diyastol süreleri FKG sinyali, S1, S2 yerleri, kalp atış hızı süresi bilgileri kullanılarak hesaplanmıştır. FKG sinyalinde temel kalp seslerini belirledikten sonra, ses kardiyak döngüsü bileşenlerine ayrılmıştır. S1 seslerini sınırlamak için bir eşik değeri olarak FKG sinyalinin zarfının ortalama değerine seçilmiş, S2 seslerini sınırlamak için sinyalin birinci türevinden oluşan zarfın ortalamasına seçilmiştir. Eşik ve ilgili zarfların kesişimi, her bir kardiyak döngüde S1 ve S2 sınırlarını belirlenmiş ve bu sayede ses sinyalindeki her bir periyot için başlangıç ve bitiş zamanları belirlenmiştir [7]. Şekil 3.13’de FKG sinyali üzerindeki S1, S2 sesleri ve S1, sistol, S2, diyastol bölgelerini gösterilmiştir.




Şekil 3.12 FKG Sinyali ve Öznitelik Vektörü Üzerinde S1 ve S2 Bölgelerinin Gösterimi



Şekil 3.13 FKG Sinyali Üzerinde S1, S2 Sesleri ve Ses Bölgeleri

Şekil 3.14'de her bir bölgenin (S1, sistol, S2, diyastol) ayrı renklerle gösterildiği bölütlenmiş FKG sinyali bulunmaktadır.



Şekil 3.14 Bölütlenmiş FKG Sinyali

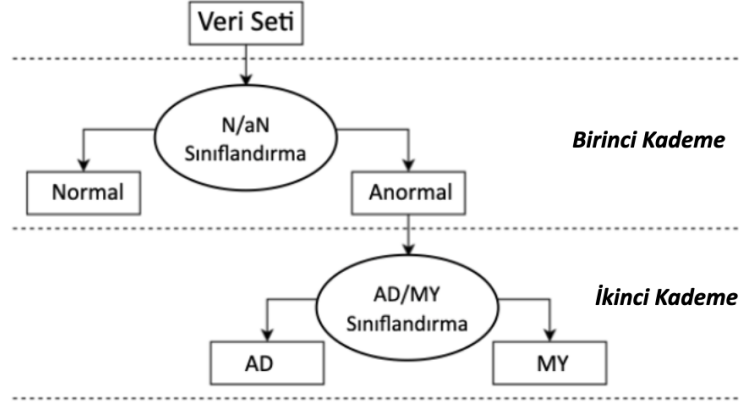
3.2.1.4. Özniteliklerin Çıkarılması

Zamana bağlı beş farklı öznitelik ile MFCC öznitelikleri kullanılmıştır. Zamana bağlı öznitelikler rms, varyans, enerji, basıklık, ilgili sinyalin maksimum ve minimum genliği arasındaki fark olarak tanımlanan dinamik aralık parametreleri kullanılarak çıkarılmıştır. Zamana bağlı öznitelikler sistol ve diyastol kısımları 3 bölünerek, S1 ve S2 kısımları olmak üzere toplam 8 parçaya ayrılmış bir periyotluk sinyalin her birinden tek tek çıkarılmıştır. Bu sayede bir periyotluk sinyal için 40 eleman uzunluğunda bir öznitelik vektörü oluşturulmuştur [7].

MFCC öznitelikleri bir tam kardiyak döngü için çıkarılmıştır. 12 MFC katsayısının ilk beş özniteliği kullanılarak toplamda 65'lik bir vektör oluşmuştur. Zamana bağlı ve MFCC öznitelik vektörlerinin birleştirilmesi ile her bir kardiyak döngü için 105 eleman uzunluğunda bir öznitelik vektörü oluşturulmuştur [7].

3.2.1.5. Sınıflandırma

İki kademeli bir sınıflandırma yaklaşımı kullanılmıştır. Şekil 3.15'de iki kademeli sınıflandırma yaklaşımı gösterilmiştir. Bu yaklaşımda önce normal ve anormal sınıflandırılması yapıp, sonrasında anormal veriler arasında AD-MY sınıflandırılması yapılmıştır [7].



Şekil 3.15 İki Kademeli Sınıflandırma Yaklaşımı

Dört farklı yöntem ile sınıflandırma çalışması yapıp sonuçlar karşılaştırılmıştır. Bu yöntemler kNN, SVM, MLP-BP ve Doğrusal (Linear Mahalanobis distance) Sınıflandırıcısıdır. k-NN sınıflandırıcısında üçüncü üssün Minkowski uzaklık metriği ile komşu sayısı beş olacak şekilde eğitim yapılmıştır. SVM sınıflandırıcısı üçüncü dereceden Polynomial Kernel fonksiyonuyla eğitilmiştir. MLP-BP ağı, sırasıyla on dokuz ve on bir nöronlu iki gizli katmana ve 2 çıkışlı sonuç katmanına sahip bir yapıdadır [7].

Her bir kardiyak döngü için oluşturulmuş 1×10^5 uzunluğundaki öznitelik vektörleri ayrı birer giriş verisi olarak düşünülüp, bu öznitelik vektör verileri eğitim, doğrulama ve test olarak üç veri setine bölünmüştür. Eğitim verileri kullanılarak yukarıda açıklanmış sınıflandırıcılar ile eğitimler gerçekleştirilmiştir. Eğitim aşamasında aynı anda bütün eğitim verisi (batch size) işlenerek toplamda 10 çevrimde (epoch) eğitim gerçekleştirilmiştir. Sonrasında test veri seti üzerinde testler gerçekleştirilmiştir.

3.2.2. Derin Öğrenme ile Sınıflandırma

Bu çalışmanın odak noktası derin öğrenme algoritmaları kullanılarak FKG sinyallerinin normal anormal ve hastalık türüne göre sınıflandırılması, sonrasında diğer makine öğrenmesi yöntemleri ile karşılaştırılmasıdır. Derin öğrenme ile sınıflandırma yapılırken ön işlemenin azaltılması ve öznitelik çıkarımının olmaması veya azaltılması amaçlanmaktadır. Bu

kapsamda önerdiğimiz yöntemler iki sınıfta ele alınmaktadır. İlki, FKG sinyaline gürültü temizleme ve normalizasyon adımları uygulandıktan sonra 1 boyutlu evrişimlerden oluşan 1D CNN modelinden (1DCNN) geçmesiyle sınıflandırmanın yapılmasıdır. İkincisi, gürültü temizleme, normalizasyon adımlarından sonra FKG sinyalinin mel-spektogramının oluşturulması ve sonrasında 2 boyutlu evrişimler içeren 2D CNN modeline (2DCNN) gönderilmesidir. 1D CNN modelinin ve 2D CNN modelinin çıktıları aynıdır.

İki yöntem karşılaştırıldığında, 1DCNN öznelik çıkarmadan çalışması ile 2DCNN modeline göre daha avantajlı konumda bulunmaktadır. Öznelik çıkarma aşamasında belirlenmesi gereken hiperparametrelerin olmaması ve model içinde öğrenilen parametre sayısının 2DCNN modeline göre daha az olması sonucunda her bir FKG sinyalini sınıflandırmak için yapılan işlem sayısının az olması 1DCNN modelinin diğer olumlu yanıdır. Bu sayede daha küçük bir işlemcide gerçek zamanlı olarak çalıştırılıp sonuç elde etmesi mümkün hale gelmektedir.

Bu çalışmanın bir diğer amacı ise yukarıda bahsedilmiş diğer makine öğrenmesi yöntemleri ile sınıflandırma yaklaşımında kullanılan iki kademeli sınıflandırma yaklaşımının derin öğrenme modelleri ile başarıma katkısının incelenmesidir. 3.2.1.5. başlığı altında açıklanmış ilk önce normal anormal sınıflandırma, sonrasında AD ve MY sınıflandırma olacak şekilde iki kademeli sınıflandırma yaklaşımı bu çalışmada derin öğrenme yöntemleri üzerinde denenmiştir. İki kademeli sınıflandırma yaklaşımının 1DCNN ile denenebilmesi için 1DCNN'in özelleştirilmesi ile kısmen iki kademeli sınıflandırma yapan İki Çıkışlı 1D CNN Model (2H-1DCNN) ve sınıflandırmayı iki kademe gerçekleştiren İki Aşamalı 1D CNN Model (2S-1DCNN) tasarlanmıştır. 2DCNN'in iki kademeli sınıflandırmadaki başarımları görebilmek için ise İki Aşamalı 2D CNN Model (2S-2DCNN) tasarlanmıştır. İki kademeli sınıflandırma için oluşturulan bu modeller normal anormal sınıflandırmada kullanılmamıştır.

Toplanmış FKG sinyalleri gürültü içerebilir, modelin girişine uygun yapıda olmayabilir, doğrudan modele girdi olması başarımları negatif yönde etkileyebilir. Bu sebeple sinyaller modele gönderilemeden öncesinde sinyallere ön işleme işlemleri uygulanır. Bu çalışmada FKG sinyallerine uygun olan normalizasyon, filtreleme ve veri artırma ön işleme adımları

kullanılmıştır. Normalizasyon verinin bütün indislerinin aynı aralıklara getirilmesidir. Veriyi gürültüden ayırabilmek için filtreleme işlemi uygulanır. Veri artırma yöntemleri ise veri setinde az veri bulunması ve derin öğrenme modelleri daha çok veri ile daha iyi sonuçlar vermesi durumlarına çözüm olarak kullanılan yöntemlerdir.

Bu çalışmadaki derin öğrenme tabanlı sınıflandırmalar Python dilinde yazılmış kodlar ile gerçekleştirilmiştir. Mel spektrogramlar oluşturulurken Librosa kütüphanesi kullanılmıştır [48]. CPU tarafında yapılan dizin işlemlerinde Numpy kütüphanesi kullanılmıştır [49]. Modeller geliştirilirken Pytorch'daki CNN yapı kullanılarak geliştirilmiştir [50]. Bu çalışma kapsamında eğitim ve testler Apple M2 işlemcili, 16 GB RAM'e sahip bir bilgisayarda gerçekleştirilmiştir.

3.2.2.1. başlığı altında sınıflandırmanın ilk aşaması olan ön işleme ile ilgili, 3.2.2.2. başlığı altında mel spektrogramların nasıl çıkarıldığı, nelere dikkat edildiği ile ilgili, 3.2.2.3. başlığı altında 1D CNN Model ile ilgili, 3.2.2.4. başlığı altında İki Çıkışlı 1D CNN Model ile ilgili, 3.2.2.5. başlığı altında 2D CNN Model ile ilgili, 3.2.2.6. başlığı altında ise İki Aşamalı 1D CNN/2D CNN Model ile ilgili detaylı bilgiler verilmiştir.

3.2.2.1. Ön İşleme

FKG sinyallerinin sınıflandırmasında öncelikle ön işleme adımı uygulanır. Ön işleme, ham verilerin analiz edilebilir bir formata dönüştürülmesi sürecidir. Ham veri genellikle eksik, hatalı veya uygunsuz formatta olabilir ve bu verilerin doğrudan analiz edilmesi veya bir modele girdi olarak kullanılması genellikle doğru sonuçlar vermez. Bu nedenle, verilerin temizlenmesi, dönüştürülmesi ve uygun bir forma getirilmesi gerekir. FKG sinyalleri toplanırken kalp sesine ek olarak çevresel seslerden gelen gürültülerde kaydedilmektedir. Sinyallerden gürültüleri temizlemek için filtreleme işlemi yapılmaktadır. Bir FKG sinyali içerisinde yer alan her bir indisteki sayı farklı özellikleri ifade etmekle birlikte bu özellikler (features) farklı ölçeklerde olabilir. Örneğin, bir özellik yüzlerce veya binlerce aralığında değerler alırken, başka bir özellik sadece 0 ile 1 arasında olabilir. Veri dönüştürme işlemlerinden biri olan normalizasyon, bu farklı ölçeklerdeki değerleri ortak bir ölçeğe getirerek, özellikler arasındaki karşılaştırmaları ve hesaplamaları daha anlamlı hale getirir.

Bu çalışmada kalp ses sinyallerine önce normalizasyon uygulanmakta, sonrasında 5-150 frekans aralığında bandpass filtresinden geçirilmektedir. Tasarlanan modele giren verilerin aynı boyutta olması gerektiği için bütün veriler aynı boyutta olacak şekilde yeniden boyutlandırılmaktadır.

Bu aşamada iki farklı normalizasyon yöntemi kullanılıp, sonuçları karşılaştırılmıştır. Bu yöntemlerden biri sesi mutlak maximuma göre normalleştirme (maksimum normalizasyon), diğeri ise Z-score normalleştirmedir (zscore normalizasyon). Denklem (9), mutlak maximuma göre normalleştirme denklemidir. Bu normalizasyon ile verinin genliği -1 ile 1 arasında dağılıma sahip olur.

$$maxNorm = \frac{x}{maxx} \quad (9)$$

x : bir FKG sinyali

$max x$: x in maximum değeri

Denklem (10), zscore normalizasyon denklemidir. Z-score normalleştirmede sinyalden ortalaması çıkarılıp standart sapmasına bölünür. Bu sayede sinyaldeki verilerin dağılımının ortalaması sıfır standart sapması ise 1 olur.

$$Zscore = \frac{x - \mu}{\sigma} \quad (10)$$

μ : FKG sinyalinin ortalaması

σ : FKG sinyalinin standart sapması

Ön işleme adımları sonrasında farklı veri artırma yöntemleri kullanılmaktadır. Veri artırma (data augmentation), derin öğrenme ve diğerk makine öğrenmesi yöntemlerinde , mevcut veri kümesini genişletmek ve modellerin genelleme yeteneklerini artırmak amacıyla uygulanan

tekniklerin genel adıdır. Modellerin başarımlarını artırmak için kullanılır. Bu kapsamda bu çalışmada kullanılan veri artırma yöntemleri; bölütlenme, rastgele kırpma, sabit boyutlu parçalara ayırmadır. Bu yöntemlerin bu çalışmada nasıl kullanıldığı aşağıda anlatılmıştır.

Bölütleme: Bölütlenmiş verinin bu modelin başarımına faydasının olup olmayacağını gözlemlemek için bölütlenmiş veri girdi olarak kullanılmıştır. Bölütlenmiş veriler yukarıda açıklanmış çalışmadaki önceden geliştirilmiş bölütleme algoritması ile hazırlanmıştır [7]. Bu sebeple bu bölümde bölütlemeye dair bilgilere yer verilmemiştir. Bölütlenmiş veri kullanıldığında ön işleme aşamasındaki normalleştirme ve filtreden geçirme adımları bölütleme aşaması öncesinde gerçekleştirildiği için, burada normalleştirme ve filtre uygulama adımları tekrar uygulanmaz.

Bölütlenmiş veri kullanıldığında ağırlık giriş verisi bir periyotluk veriler olurken, bölütlenmemiş veri kullanıldığında giriş verisi bütün bir sinyal olmaktadır. Bölütlenmemiş ses sinyali kullanıldığında sinyallerin örnekleme (sample) boyutu 20000 olarak seçilmiştir. Bölütlenmiş veri kullanıldığında ise sinyallerin örnekleme (sample) boyutu 4000 olarak seçilmiştir. Bu seçimler deneyler yapılarak gerçekleştirilmiştir.

Rastgele kırpma (random crop): Rastgele kırpma yöntemi yukarıdaki çalışmalara ek olarak kullanılmıştır. Rastgele kırpma, veri artırma (data augmentation) için kullanılan bir tekniktir. Her çevrimde (epoch) verinin belirli bir kısmının rastgele seçilerek, bu kısmın kırılması ile oluşturulur. Bu kırılmış veri daha sonra modelin giriş verisi olarak kullanılır. Bu teknik ile amaç, modele her çevrimde (epoch) verinin farklı bir kısmını göndererek modelin aşırı öğrenmesini engellemektir. Bu sayede eğitim verisinde çeşitlilik sağlayarak ve modelin henüz görmediği verilere karşı daha iyi genelleme yapmasını sağlamaktır. Bu yöntem genellikle görüntü sınıflandırma, nesne algılama gibi yöntemlerde kullanılmaktadır. Kalp seslerinin sınıflandırması problemi tam olarak bu gruba girmese de ardışık sinyaller içermesi, bu sebeple her kırılan kısmın kalp sesi için anlamlı veri olması ve bu tekniğin basit bir veri artırımı tekniği olması sebeplerinden dolayı bu teknik bu çalışmada kullanılmıştır.

Çalışmada bu teknik şu şekilde kullanılmıştır; eğitim aşamasında FKG verisi içerisinde 20000 örnekleme boyutunda rastgele kırılan verilerle sınıflandırıcıya göndererek eğitim

gerçekleştirilir. Her seferinde 20000'lik kesit alınabilecek şekilde başlangıç noktası rastgele olarak seçilip, bu başlangıç noktasından itibaren 20000 uzunluğundaki kısım alınıp eğitime gönderilir. Eğer o verinin boyutu 20000'den kısa ise verinin boyutu 20000 uzunluğuna getirilir. Bu sayede modele giden bütün verilerin boyutlarının aynı olması sağlanmakla beraber her seferinde yaklaşık aynı sayıda periyotta sinyal modele gönderilmiş olur. Bu işlem yapıldıktan sonrasında filtreleme ve normalleştirme adımları uygulanır.

Bu şekilde eğitilen modeller için test aşamasında iki farklı yaklaşım kullanılmıştır. Bunlardan birinde; test aşamasında test setindeki verilerin ilk 20000 boyutundaki kısımları alınmış, sadece bu kısım üzerinden sınıflandırma başarımı ölçülmüştür. Diğer yaklaşımda ise test verisi çoğaltma (test augmentation) yöntemi ile başarımleri ölçülmüştür. Bu yöntemde; her biri 20000 örnekleme boyutunda olacak şekilde veri parçalara ayrılmış, modele gönderilip her biri için ayrı ayrı alınan sınıflandırma sonuçlarının ortalaması çıkış değerini oluşturur. Bu teknik ile alınan sonuçların gösterildiği tablolarda bu teknik "Bütün/Parçalı/Bölütlenmiş/R.Kırpma" başlığı altında "R.Kırpma" olarak ifade edilmiştir.

Sabit Boyutlu Parçalara Ayırma: Veriyi eşit uzunluktaki parçalara bölüp kullanma üzerinde çalışılmıştır. Veri sayısını artırmak ve bilgiyi daha kısa parçalar halinde verip modelin daha iyi öğrenmesini sağlamak için FKG sinyali sabit boyutlarda olacak şekilde eşit parçalara bölünür. Her bir parça 20000 vektörlük boyutlarda olacak şekilde hazırlanır. Parçalar alınırken başlangıç noktasına 20000 eklenerek bitiş noktası bulunur, bitiş noktası bir sonraki parçanın başlangıcı olarak alınıp 20000 eklenerek bu parçanın bitiş noktası bulunur. Sinyal bu şekilde 20000 uzunluğunda parçalara bölünür. Bu yöntem sayesinde modele her zaman aynı uzunlukta veri iletebilmek için yeniden boyutlandırma işlemi yapmaya gerek kalmaz. Ve modele orjinal sinyal yapısı bozulmadan yani sinyal sıkıştırılmadan veya genişletilmeden kullanılmış olur. Ayrıca bu yöntem bölütleme işlemine göre daha basit bir yöntemdir. Bu yöntem ile alınan sonuçların gösterildiği tablolarda bu durum "Bütün/Parçalı/Bölütlenmiş/R.Kırpma" başlığı altında "Parçalı" olarak ifade edilmiştir.

3.2.2.2. Mel Spektrogram

Mel spektrogram oluşturulmuş sinyal ile derin öğrenme modelleri kullanılarak

sınıflandırma kaynaklarda kalp seslerinin sınıflandırılmasına dair çalışmaların bir çoğunda kullanılmıştır. Bir boyutlu veri ile sınıflandırma ve diğer çalışmalardaki mel spektrogram verileri ile sınıflandırma yaklaşımlarını karşılaştırabilmek için FKG sinyallerini mel spektrogramları oluşturulup bu veriler için tasarlanan 2DCNN ile eğitimleri gerçekleştirilmiştir. Aşağıda bu çalışmada mel spektrogramların nasıl çıkarıldığı, nelere dikkat edildiği detaylı bir şekilde anlatılmıştır.

Filtreden geçirilme ve normalizasyon adımları sonrasında FKG sinyallerinin mel spektrogramları oluşturulmuştur. Mel spektrogram oluştururken FKG sinyali içerisinde rastgele kırılan 20000 uzunluğundaki veriler kullanılmıştır. Bu sayede örnekleme hızı aynı kalmıştır. HU-PCG veri setinde örnekleme hızı 4000 Hz, PhysioNet veri setinde örnekleme hızı 2000 Hz'dir.

Kalp sesleri için genellikle 25 ms ile 50 ms arasında pencere boyutları kullanılır. Adım boyutu ise pencere boyutunun yarısı veya üçte biri olarak seçilebilir. Bu, zaman-frekans çözünürlüğü arasında bir denge sağlar. Bu çalışmada pencere boyutu 25 ms, adım boyutu 12,5 ms olarak seçilmiştir.

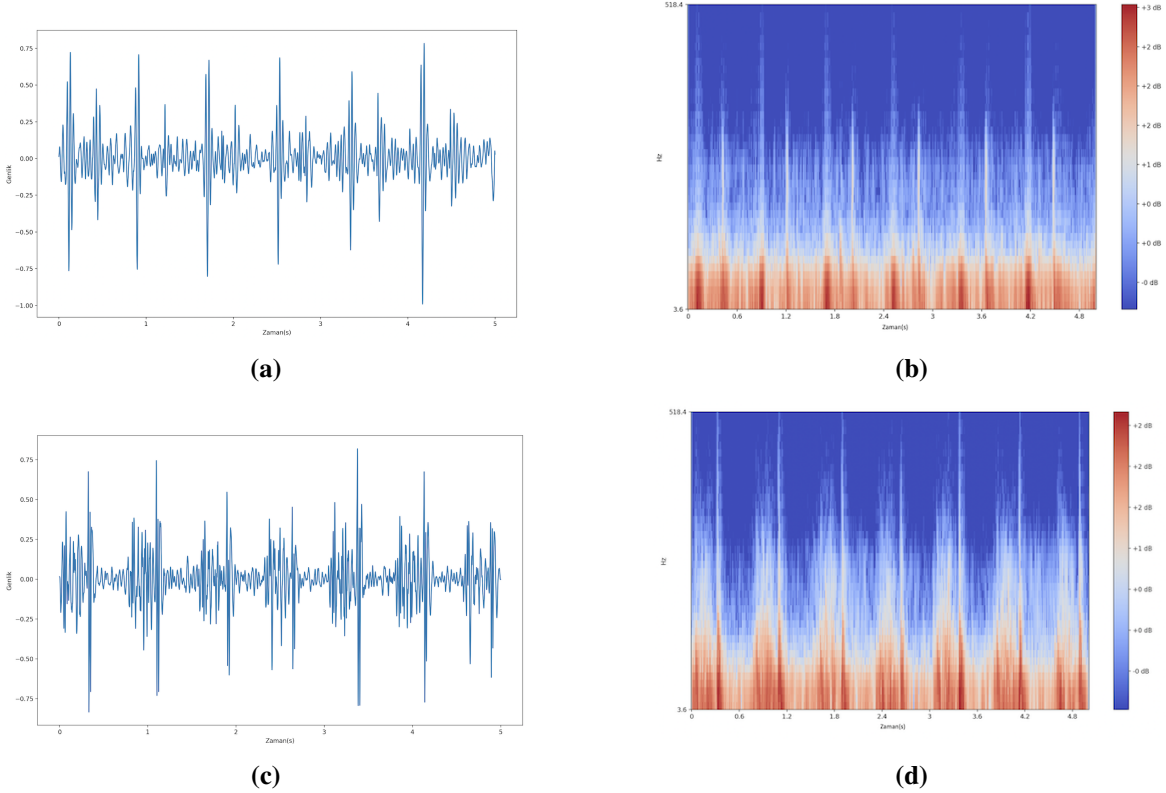
Kalp sesleri için yaygın olarak kullanılan DFT boyutları 256, 512 veya 1024'dir. Bu değerler genellikle yeterli frekans çözünürlüğü sağlarken, aynı zamanda zaman çözünürlüğünü de makul bir seviyede tutar. Bu çalışmada üç değer denenmiş, en yüksek başarımları veren 512 DFT boyutu seçilmiştir.

Kalp seslerinin sınıflandırılmasında genellikle 20 ila 40 adet mel filtresi kullanılır. Bu, yeterli frekans çözünürlüğü sağlarken hesaplama maliyetini de yönetilebilir kılar. Çalışmada filtre sayısı 40 olarak seçilmiştir.

Kalp sesleri 20 ile 200 Hz aralığındadır [51]. Mel spektrogramı daha geniş alabilmek için minimum ve maksimum frekans aralıkları 15 ile 512 olarak seçilmiştir.

Belirtilen parametreler kullanılarak bir FKG sinyalinden rastgele 20000 uzunluğundaki parçanın kullanılması ile 40x401 uzunluğunda iki boyutlu bir mel spektrogram veri oluşur. Şekil 3.16'daki (a) görselinde normal bir FKG sinyalinin ön işlenmiş 20000 vektör

uzunluğundaki parçası, (b) görselinde aynı sinyalin mel spektrogramı gösterilmiştir. (c) görselinde AD etiketli bir sinyalin ön işlenmiş halinin 20000 vektör uzunluğundaki parçası, (d) görselinde aynı sinyalin mel spektrogramı gösterilmiştir. Normal ve anomal sinyallerin mel spektrogramları incelendiğinde anormalliğin görsel üzerinde fark edilebilir haldedir.




Şekil 3.16 HU-PCG Veri Setindeki FKG Örnek Sinyalleri: a) Normal Sinyalin Ön İşlenmemiş Hali, b) Normal Sinyalin Mel Spektrogramı, c) AD Sinyalin Ön İşlenmemiş Hali, d) AD Sinyalin Mel Spektrogramı

3.2.2.3. 1D CNN Model (1DCNN)

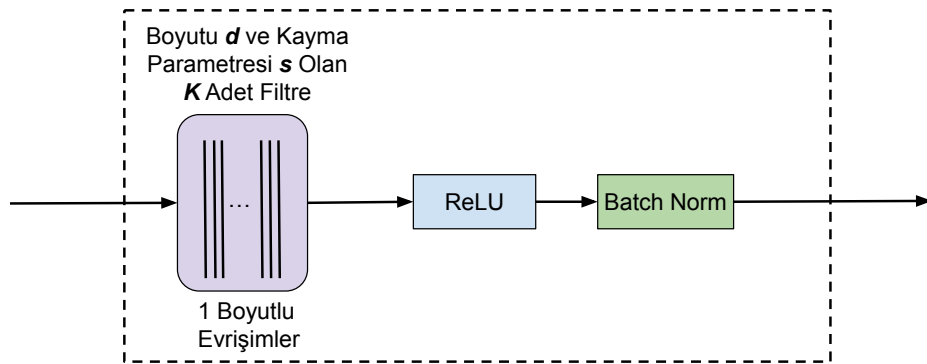
1DCNN basit bir yapıya sahip, modelin giriş verisine basit ön işleme adımları uygulandıktan sonrasında veri yapısı değiştirilmeden bir boyutlu veri ile modele giriş yapacak şekilde tasarlanmış bir modeldir. 1DCNN temelde bir boyutlu evrişim filtrelerinin kullanılması ve ek katmanlar ile tasarlanmıştır. Evrişim filtresi, giriş verisi boyunca bir boyut üzerinde sırayla kaydırılarak her adımda, filtre ağırlıkları, giriş verisiyle çarpılır ve sonuç toplanarak bir çıkış (feature map) oluşturulur. Bu işlem, bir boyutlu bir çıktı üretir. Şekil

3.21’de kayma parametresi 1 ve boyutu 3 olan bir filtre ile bir boyutlu evrişim işleminin nasıl yapıldığı gösterilmektedir.



Şekil 3.17 Bir Boyutlu Evrişim (1D Convolution - 1D Conv)

Bir boyutlu evrişimlerin birleştirilmesi ile 1D CNN katmanları oluşturulmuştur. Her bir 1D CNN katmanı Tablo 3.2’de bahsedilen filtre sayısı kadar bir boyutlu evrişim katmanı (convolution), “ReLU” aktivasyon işlevi ve Batch normalleştirme adımlarından oluşmaktadır. Şekil 3.18’de 1D CNN katmanının iç yapısı gösterilmektedir.



Şekil 3.18 Bir Tane Bir Boyutlu CNN Katmanının Yapısı. d filtre boyutu, s kayma parametresi, K filtre sayısıdır.

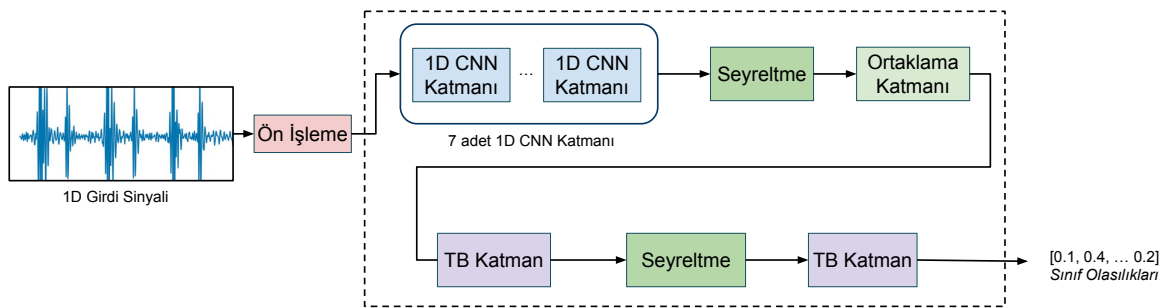
Modelin, veriden daha fazla bilgi öğrenebilmesi için her bir katmanda birden çok filtre kullanılmıştır. Evrişim işleminden sonra ReLU aktivasyon fonksiyonu bulunmaktadır.

ReLU aktivasyon fonksiyonunun kullanılmasının sebebi işlemleri doğrusal olmayan bir yapıya çevirebilmek ve kompleks problemleri çözebilmek içindir. ReLU, derin öğrenme ve sinir ağlarında sıkça kullanılan bir aktivasyon fonksiyonudur. Pozitif girdiler için aynı değeri verirken negatif değerler için sıfır değeri verir [52]. Denklem 11’de ReLU aktivasyon fonksiyonunun denklemi gösterilmiştir.

$$\text{ReLU}(x) = \max(0, x) \quad (11)$$

ReLU fonksiyonun bir kaç avantajı vardır. Bunlardan ilki basit bir fonksiyon olması, hesaplaması kolay olmasıdır. Bir diğeri modelin öğrenme aşamasında geri yayılım zamanında türev hesaplanırken negatif sonuca sahip girdilerin ReLU Fonksiyonu sonrası sonucu sıfır olacak, sonrasında türevi de sıfır olacaktır. Bu sayede bazı nöronların öğrenmesine gerek kalmayıp, modelin hızlı çalışmasını sağlamaktadır. Türevi sıfır olan fonksiyonlar sonucu geri yayılım yapılamamakta model öğrenememektedir. Bu fonksiyon pozitif girdilerde girdinin kendi değerini vereceği için türevi bir olacak, bu sayede türevi hesaplandığı için geri yayılım yapılabilecektir. Bu avantajlarında dolayı derin öğrenme modellerinde genellikle kullanılmaktadır.

7 tane 1D CNN katmanı, 1 tane ortalama kullanılarak ortaklama katmanı (Average Pooling Layer), 2 tane ise tam bağlantılı katmanının (Fully Connected Layer) birleştirilmesi ile 1DCNN tasarlanmıştır. Şekil 3.19’da kalp seslerinin sınıflandırılması için oluşturulmuş 1DCNN’in yapısı gösterilmektedir.



Şekil 3.19 1DCNN Yapısı

Modelin ađ yapısında öncelikle bir boyutlu evriřim katmanları kullanılmıřtır. Sonrasında CNN vektör yapısını tam bađlantılı katman yapısına çevirilmesi için bir boyutu ortadan kaldırmayı sađlayan ortalama kullanılarak yapılan ortaklama katmanı (global average pooling) kullanılmıřtır [53].

Ortaklama (pooling) iřlemi, evriřim katmanlarından sonra uygulanarak uzamsal boyutları küçültmek ve modelin genel başarımını artırmak amacıyla kullanılır. Farklı ortaklama yöntemleri vardır. Bunlar maksimumunu kullanarak ortaklama, ortalamasını kullanarak ortaklamadır. Ortalama ile ortaklama iřleminde, belirli bir pencere boyutu üzerinden kaydırılarak giriř verisi üzerindeki her bir bölgedeki elemanların ortalamasını alır. Maksimumu ile ortaklamada ise aynı iřlem penceredeki deđerlerden maksimumu seçilerek yapılır. Ortaklama iřlemi ile verinin özetlenmesi ve daha düşük boyutlu bir temsile indirgenmesi sađlanır. Böylece model, daha az parametre ile daha verimli bir řekilde öđrenebilir. Bu çalıřmada ortalama ile ortaklama iřlemi kullanılmıřtır.

Ortaklama katmanlarından sonrasında Tam Bađlantı katmanları gelmektedir. Tam Bađlantı (TB) katmanları birbirine bađlantılı nöronlardan oluřan katman ve "ReLU" aktivasyon iřlevi adımlarından oluřmaktadır. Tam bađlantı katmanları, 1D CNN katmanlarında öđrenilen özniteliklerle sınıflandırma ařaması için kullanılmıřtır. Çıkıř verisinin oluřtuđu son tam bađlantı katmanında "ReLU" aktivasyon fonksiyonu kullanılmamıřtır.

1D CNN katmanlarının en sonuncusundan sonra ve iki tam bađlantı katmanları arasında sırasıyla 0.15 ve 0.30 oranlarında seyreltme iřlemi uygulanmaktadır.

Seyreltme (dropout), sinir ađları ve derin öđrenme modellerinde ařırı öđrenmeyi (overfitting) önlemek için kullanılan yöntemlerden biridir. Bu yöntemde bazı nöronlar devre dıřı bırakılarak modelin eđitimi gerçekeřtirilir [54]. Bu iřlem, modelin belirli nöronlara ařırı derecede bađımlı olmasını engelleyerek daha genel bir model elde edilmesini sađlar. Eđitim ařamasında, her ileri dođru geçiřte belirlenen olasılık oranında nöronlar rastgele atlanır. Atlanan nöronlar, o geçiř sırasında hesaplamalara katılmaz ve bu řekilde modelin farklı nöron kombinasyonları ile eđitilmesi sađlanır. Test ařamasında bu iřlem uygulanmaz. Sadece bütün nöronların çıkıřları belirlenen oranda ölçeklendirilir.

Sıra	Katman Türü	AF*	Norm**	Filtre Boyutu	Kayma Değeri	Filtre Sayısı	Çıkış Boyutu
0	Giriş Sinyali	-	-	-	-	-	$B^{***} \times N^{****}$
1	1D Conv	ReLU	Batch Norm	3	1	64	$B \times 64 \times (N-2)$
2	1D Conv	ReLU	Batch Norm	2	1	64	$B \times 64 \times (N-3)$
3	1D Conv	ReLU	Batch Norm	3	2	64	$B \times 64 \times (N/2-2)$
4	1D Conv	ReLU	Batch Norm	3	1	64	$B \times 64 \times (N/2-4)$
5	1D Conv	ReLU	Batch Norm	3	2	64	$B \times 64 \times (N/4-3)$
6	1D Conv	ReLU	Batch Norm	3	1	64	$B \times 64 \times (N/4-4)$
7	1D Conv	ReLU	Batch Norm	3	2	32	$B \times 32 \times (N/8-3)$
8	Seyreltme (0.15)	-	-	-	-	-	$B \times 32 \times (N/8-3)$
9	Ortaklama Katmanı	-	-	-	-	-	$B \times 32$
10	TB Katmanı	ReLU	-	-	-	-	$B \times 128$
11	Seyreltme (0.30)	-	-	-	-	-	$B \times 128$
12	TB Katmanı	-	-	-	-	-	$B \times C^{****}$

Tablo 3.2 1DCNN Modeli Her Bir Katman Bilgileri

* AF; Aktivasyon fonksiyonuna denk gelmektedir.

**Norm; Normalizasyon türünü ifade etmektedir.

***B; aynı anda eğitime giden veri sayısıdır (batch size).

*** N; ağa giriş verisinin boyutudur.

**** C; sınıflandırılacak sınıf sayısıdır.

Tablo 3.2’de 1DCNN’in her bir katmanı hakkında detaylı istatistik bilgileri verilmiştir.

Giriş verisinin boyutuna göre model içerisindeki parametrelerde değişikliğe gerek yoktur. Bu sayede farklı uzunluklarda veri göndermek mümkün kılınmıştır. Burada önemli olan aynı anda modele gönderilen (batch size) verilerin boyutu aynı olmak zorundadır.

Yapılan deneyler sonucunda tablodaki filtre boyutlarının en iyi sonucu vermesi sebebiyle bu parametreler seçilmiştir. Her CNN aşamasında birden fazla kayma değeri uygulanması aradaki bazı değerli bilgilerin alınmasına engel olduğu için bu durumda daha düşük başarımların değeri alınmıştır. Bu sebeple kayma değerleri tablodaki gibi seçilmiştir.

Bir boyutlu evrişimlerin çıkış boyutları kullanılan filtre sayısı ile filtre boyutu, kayma sayısı ve giriş verisini doldurma (padding) sayısına bağlı olarak oluşmaktadır. Bu modelin hiç bir katmanında giriş verisini doldurma (padding) işlemi yapılmamıştır. 1 bir boyutlu evrişimsel katman için Tablo 3.2'de Çıkış Boyutu kısmında verilen bilgilerde ikinci boyuta denk gelen kısım filtre sayısına bağlı olarak oluşmakta, üçüncü boyuta denk gelen kısım ise filtre boyutu ve kayma sayısına bağlı olarak oluşmaktadır.

Modelin verdiği çıkışın boyutu sınıflandırılmak istenen sınıf sayısına göre değiştirilebilmektedir. Bu değişiklik için sadece son aşamadaki tam bağlantı katmanının çıkış sayısını sınıflandırılacak sınıf sayısına uygun olarak güncellemek yeterli olmaktadır. Normal anormal sınıflandırılması yapılmak istendiğinde son aşamadaki tam bağlantı katmanının çıkış boyutu 2 ayarlanarak sınıflandırıcının da boyutu 2 olarak ayarlanmış olmaktadır. Aynı şekilde normal, MY, AD sınıflandırılması yapılmak istendiğinde son aşamadaki tam bağlantı katmanının çıkış boyutu 3 olarak ayarlanmaktadır.

Modelin eğitim aşamasında Adam optimizasyon fonksiyonu kullanılmıştır [55]. Adam optimizasyon fonksiyonu adaptif öğrenme oranı (learnin rate) ve momentum ile daha hızlı ve verimli bir yapı sağladığı için bu çalışmada tercih edilmiştir.

Öğrenme oranını kosinüs eğrisi izleyerek kademeli olarak azaltan öğrenme oranı planlayıcısı kullanılmıştır. Bu planlayıcı eğitim sırasında öğrenme oranını dinamik olarak ayarlamak için kullanılır ve modelin yakınsaması (convergence) açısından daha iyi sonuçlar verir. Bu planlayıcı ile öğrenme oranı 10^{-3} ile 10^{-5} arasında giderek azalacak şekilde ayarlanmıştır.

Çapraz Entropi Kaybı (Cross Entropy Loss), sınıflandırma problemlerinde yaygın olarak kullanılan bir kayıp fonksiyonudur. Bu fonksiyon, doğru etiket ile tahmin edilen olasılıklar arasındaki farkı ölçme yeteneğine sahip olup, modellerin doğru sınıflar için yüksek

olasılıklar üretmesini teşvik eder. Logaritmanın özellikliğini kullanarak, yanlış tahminleri daha ağır bir şekilde cezalandırır ve böylece modeli daha doğru ve güvenilir tahminler yapmaya yönlendirir. Bu sebeplerle eğitim aşamasında Çapraz Entropi Kaybı kayıp fonksiyonu kullanılmıştır. Python'da bulunan Çapraz Entropi Kaybı kayıp fonksiyonu softmax fonksiyonunu kendi içerisinde içerdiği için 1DCNN yapısının son aşamasında tam bağlantı katmanına softmax fonksiyonu eklenmemiştir.

$$\text{Çapraz Entropi Kaybı} = -\frac{1}{N} \sum_{i=1}^N [t_i \log(p_i)] \quad (12)$$

t_i : doğru etiket

p_i : tahmin edilen etiket

N : toplam veri sayısı

Modelin çıktısı her bir sınıfa ait değerlerdir. Model eğitim boyunca o sınıfın etiketinin sahip olduğu sayısal değere yakınsamaya çalışır. Doğrulama ve test aşamasında ise yüksek değere sahip olan çıktı tahmin edilen sınıf olarak seçilmekte, test sonucu bu duruma göre yapılmaktadır.

Bu model ile eğitimler gerçekleştirilirken eğitim aşamasında aynı anda 16 adet veri (batch size) işlenerek toplamda 500 çevrimde (epoch) gerçekleştirilmiştir.


Veri setinin az olması derin öğrenmede modellerin yeterli öğrenememesine veya aşırı öğrenmesine sebep olmaktadır. Az veri setine sahip problemlerde öğrenme aktarımı (transfer learning) yöntemi yaygın olarak kullanılmaktadır. Bu çalışmada da bu yaklaşım önceden daha çok veriye sahip veri seti ile eğitilmiş modelin ağırlıklarının kullanılarak asıl amaçlanan veri seti ile yine aynı model için yeniden eğitilmesi şeklinde kullanılmıştır. İkinci eğitim önceden elde edilmiş model ağırlıklarından öğrenmeye başlayacak şekilde yapılmıştır. Bu yaklaşım ile yapılmış eğitimlerin başarımlarının paylaşıldığı tablolarda "Ön Eğitilmiş/Eğitilmemiş" başlığı altında bu yaklaşım kullanılarak deneyler için "Ön Eğitilmiş" olarak, bu yaklaşım kullanılmayan deneyler için ise "Ön Eğitilmemiş" olarak bahsedilmiştir.

Burada anlatılmış 1DCNN’i basit bir ağ yapısına sahip olup öznelik çıkarılmadan sınıflandırılmanın yapılmasını sağlamaktadır. Basit ve hızlı bir model olmakla birlikte, farklı giriş boyutları ve sınıflandırılacak sınıf sayısı için kolay değiştirilebilir yapıya sahiptir.

3.2.2.4. İki Çıkışlı 1D CNN Model (2H-1DCNN)

Bu model 3.2.2.3.’de anlatılan 1DCNN ile aynı yapıya sahip olup, ikiden fazla sınıflandırma için özelleştirilmiş bir modeldir. İki farklı çıktı verecek şekilde tasarlanmıştır. Çıktılardan ilki normal anormal sınıflandırma çıktısı, ikincisi ise anormal veriler için hastalık sınıflandırmasıdır.

Şekil 3.20’de 2H-1DCNN’in yapısı gösterilmiştir. 1DCNN’deki 7 adet CNN katmanı burada da aynı şekilde ve aynı parametrelerle bulunmaktadır. CNN katmanlarından sonrasında normal anormal sınıf çıktısı ve hastalık sınıf çıktısı verebilmek için iki farklı hat oluşturulmuştur. Bu iki hatta da 1DCNN ile aynı parametrelere sahip olan aynı katmanlar olacak şekilde sırasıyla Seyreltme, Ortaklama, Tam Bağlantı, Seyreltme ve Tam bağlantı katmanları bulunmaktadır. Parametrelerdeki tek fark normal anormal sınıflandırma çıktısı veren hattın çıktısı tek boyutlu, hastalık sınıflandırma çıktısı veren hattın çıktısı ise normal sınıf dahil olmayacak şekilde sınıflandırılmak istenen toplam hastalık sınıf sayısı boyutundadır.




Şekil 3.20 2H-1DCNN Yapısı

1DCNN’de olduğu gibi bu modelin eğitim aşamasında da Adam optimizasyon fonksiyonu aynı parametreler ile kullanılmıştır [55]. 1DCNN’de kullanılan öğrenme oranını kosinüs eğrisi izleyerek kademeli olarak azaltan öğrenme oranı planlayıcısı burada da aynı şekilde kullanılmıştır.

Normal anormal sınıflandırmanın olduğu birinci hattın çıktısı Sigmoid aktivasyon fonksiyonundan geçirildikten sonrasında İkili Çapraz Entropi Kaybı (Binary Cross Entropy Loss) fonksiyonu ile bu hattın kaybı hesaplanmıştır. Buradaki eşik değeri 0.4 olarak seçilmiştir. Eğer o verinin gerçek etiketi anormal ise ikinci hattın kaybı Çapraz Entropi Kaybı (Cross Entropy Loss) fonksiyonu ile hesaplanmış, eğer etiket normal ise ikinci hattın kayıp değeri sıfır olarak alınmıştır. Her iki hattın kayıp değerleri toplamı ile eğitim aşamasındaki geri yayılım (backpropagation) ve sonrasında ağırlıkların güncellenmesi sağlanmıştır. Test aşamasında ise model önce ilk hattın sonucuna bakmakta, eğer normale çıktıyı normal vermekte, eğer anormalse ikinci hattın çıktısı sonucu vermektedir.

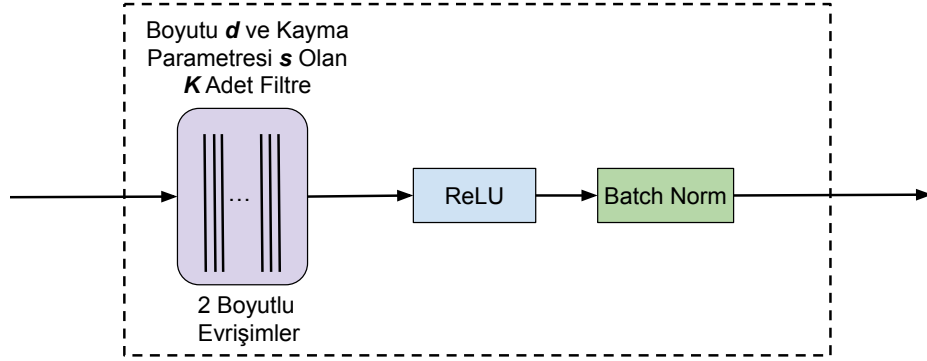
3.2.2.5. 2D CNN Model (2DCNN)

2DCNN, bir boyutlu FKG sinyali 2 boyutlu yapıya çevrildikten sonrasında giriş verisi olarak kullanılan modeldir. Bu modelin temelinde iki boyutlu evrişimler bulunmaktadır. İki boyutlu evrişim bir görüntü üzerinde iki boyutlu bir filtrenin kaydırılması ile oluşturulur. Filtre, görüntünün sol üst köşesinden başlayarak sağa doğru kaydırılır. Filtre ve görüntünün çakışan bölümleri çarpılır ve sonuçlar toplanarak yeni bir değer elde edilir. Bu işlem görüntünün tüm bölgeleri için tekrarlanır. Filtrenin tüm görüntü üzerindeki kaydırma işlemi tamamlandığında, her bir pozisyonda elde edilen sonuçlarla yeni bir iki boyutlu matris yapıda veri oluşturulur. Bu matris, görüntünün filtrelenmiş versiyonunu veya bir özellik haritasını (feature map) temsil eder. Şekil 3.21’de kayma parametresi 1, doldurma (padding) parametresi 1 ve boyutu 3x3 olan bir filtre ile iki boyutlu evrişim işleminin nasıl yapıldığı gösterilmektedir.




Şekil 3.21 İki Boyutlu Evrişim (2D Convolution - 2D Conv) [56]

İki boyutlu evrişimlerin birleştirilmesi ile 2D CNN katmanları oluşturulur. Her bir 2D CNN katmanı Tablo 3.3’de bahsedilen filtre sayısı kadar iki boyutlu evrişim katmanı (convolution), “ReLU” aktivasyon işlevi ve Batch normalleştirme adımlarından oluşmaktadır. Şekil 3.18’de 2D CNN katmanının iç yapısı gösterilmektedir.



Şekil 3.22 Bir Tane İki boyutlu CNN Katmanının Yapısı

4 tane 2D CNN katmanı, 1 tane ortalama kullanılarak ortaklama katmanı, 1 tane ise tam bağlantılı katmanının birleştirilmesi ile 2DCNN oluşmaktadır. 2D CNN katmanlar sonrasında gelen Tam Bağlantı katmanları 1DCNNdekiler ile aynı yapıya sahiptir. 2D CNN katmanları sonunda ve iki tam bağlantılı katmanlar arasında sırasıyla 0.15 ve 0.30 oranlarında seyreltme (dropout) işlemi uygulanmaktadır. Şekil 3.23’de 2DCNN’in yapısı gösterilmektedir.



Şekil 3.23 2DCNN Yapısı

Tablo 3.2’de 2DCNN katmanlarının sayısal bilgileri verilmiştir.

2DCNN’in ağ yapısı 1DCNN’e benzemektedir. Aradaki fark giriş verisinin boyutu ve baştaki CNN katmanlarıdır. 1DCNN’in giriş verisinin boyutu bir boyutlu ve modelin ağ yapısında da

Sıra	Katman Türü	AF*	Norm**	Filtre Boyutu	Kayma Değeri	Doldurma Değeri	Filtre Sayısı	Çıkış Boyutu
0	Giriş Sinyali	-	-	-	-	-	-	$B^{***} \times N_1 \times N_2^{****}$
1	2D Conv	ReLU	Batch Norm	3x3	1x1	0	32	$B \times 32 \times (N_1 - 2) \times (N_2 - 2)$
2	2D Conv	ReLU	Batch Norm	3x3	1x1	0	64	$B \times 64 \times (N_1 - 4) \times (N_2 - 4)$
3	2D Conv	ReLU	Batch Norm	3x3	2x2	1x1	64	$B \times 64 \times (N_1 / 2 - 2) \times (N_2 / 2 - 2)$
4	2D Conv	ReLU	Batch Norm	3x3	1x1	0	32	$B \times 32 \times (N_1 / 2 - 4) \times (N_2 / 2 - 4)$
8	Seyreltme (0.15)	-	-	-	-	-	-	$B \times 32 \times (N_1 / 2 - 4) \times (N_2 / 2 - 4)$
9	Ortaklama Katmanı	-	-	-	-	-	-	$B \times 32$
10	TB Katmanı	ReLU	-	-	-	-	-	$B \times 64$
11	Seyreltme (0.30)	-	-	-	-	-	-	$B \times 64$
12	TB Katmanı	-	-	-	-	-	-	$B \times C^{*****}$

Tablo 3.3 2D CNN Model'i Her Bir Katman Bilgileri

* AF; Aktivasyon fonksiyonuna denk gelmektedir.

** Norm; Normalizasyon türünü ifade etmektedir.

*** B; aynı anda eğitime giden veri sayısıdır (batch size).

*** $N_1 \times N_2$; ağa giriş verisinin boyutudur.

***** C; sınıflandırılacak sınıf sayısıdır.

bir boyutlu evrişim kullanılırken, 2DCNN'in giriş verisi iki boyutlu ve modelin ağ yapısında iki boyutlu evrişim kullanılmıştır.

Yapılan deneyler sonucunda tablodaki değerlerle daha iyi sonuç alındığı için bu değerler seçilmiştir. Evrişim işlemi sonrası çıkış boyutu bir boyutlu yada iki boyutlu olmasından bağımsız aynı değerlere bağlı olarak değişmektedir. Tek fark iki boyutlu evrişimde iki boyutlu girişine uygun iki boyutlu çıkış vermektir.

Tablo 3.3'de çıkış boyutu sütunundaki bilgiler için ikinci boyut kullanılan filtre sayısı ile

oluşmakta, üçüncü boyuta denk gelen kısım girişi sinyalinin ilk boyutu için filtre boyutu ve kayma sayısına bağlı olarak oluşmakta, dördüncü boyut ise girişi sinyalinin ikinci boyutu için filtre boyutu ve kayma sayısına bağlı olarak oluşmaktadır.

Aynı anda modele gönderilen giriş verilerinin hepsinin boyutu aynı olduğu müddetçe, farklı eğitimlerde değişen giriş verisi boyutuna göre modelin yapısının değiştirilmesine gerek bulunmamaktadır. Model bu değişikliğe uygun olarak tasarlanmıştır.

1DCNN ile aynı şekilde bu 2DCNN’de de çıkış boyutu sınıflandırılmak istenen sınıf sayısına göre değiştirilebilmektedir.

Modelin eğitim aşamasında Adam optimizasyon fonksiyonu kullanılmıştır [55]. 1DCNN’de kullanılan öğrenme oranını kosinüs eğrisi izleyerek kademeli olarak azaltan öğrenme oranı planlayıcısı burada da aynı şekilde kullanılmıştır. Kayıp fonksiyonu olarak da Çapraz Entropi Kaybı (Cross Entropy Loss) kullanılmıştır.

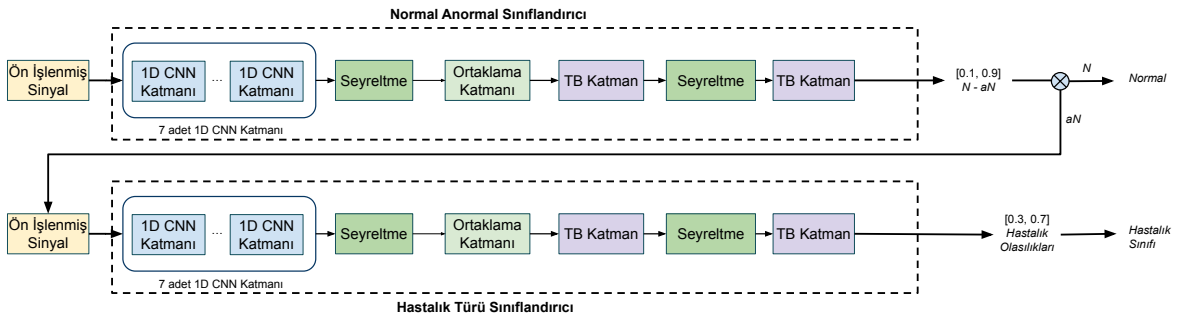
Bu model ile eğitimler gerçekleştirilirken eğitim aşamasında aynı anda 16 adet veri (batch size) işlenerek toplamda 500 çevrimde (epoch) gerçekleştirilmiştir.

2DCNN ağ yapısı olarak karmaşık bir yapıya sahip olmasada giriş verisinin yapısının iki boyutluya çevrilmesi gerektiği için daha fazla işlem gerektiren bir yapıya sahiptir.

3.2.2.6. İki Aşamalı 1D CNN Model (2S-1DCNN) / 2D CNN Model (2S-2DCNN)

Bu çalışmada geliştirilmiş 1DCNN ve 2DCNN ile iki kademeli sınıflandırmayı test edebilmek amacıyla bu yapı tasarlanmıştır. 1DCNN için 3.2.2.3. başlığı altında, 2DCNN için ise 3.2.2.4. başlığı altında açıklanmış modeller tamamen aynı olacak şekilde burada kullanılmıştır. Bu yapıda normal-anormal ve AD-MY sınıflandırma için modeller ayrı ayrı eğitilir. Test aşamasında iki model ile bütün test verileri için çıktı alınır. Önce normal-anormal sınıflandırıcının her bir FKG sinyali için 2x1 boyutlu verdiği çıktıda hangi indisin daha yüksek değer verdiğine bakılır. Eğer çıktının ilk indisi daha büyük ise iki kademeli sınıflandırıcı çıktısı normal olarak verilir. İkinci AD-MY sınıflandırıcının sonucuna bakılmadan bu FKG sinyali için tahmin edilmiş sınıflandırma normal olarak verilir. Eğer

normal anormal sınıflandırıcıda çıktının ikinci indisi daha büyük değere sahipse sınıflandırıcı çıktısı anormal olarak verilir. Bu sonuç sonrasında, bu veri için AD-MY sınıflandırıcının verdiği sonuca bakılır. Eğer bu sınıflandırıcının verdiği çıktının ilk indisi daha büyükse bu sinyal için tahmin edilmiş sonuç AD, eğer ikinci indisi daha büyük ise tahmin edilmiş sonuç MY olarak verilir. Şekil 3.24’de 1DCNN kullanılarak iki kademeli sınıflandırmanın test aşamasında nasıl gerçekleştirildiği gösterilmiştir. 2DCNN ile iki kademeli sınıflandırma da aynı yapıya sahip olup normal normal sınıflandırıcı ve hastalık türü sınıflandırıcı içlerindeki görsel Şekil 3.23 ile aynıdır.



Şekil 3.24 Bir Tane İki boyutlu CNN Katmanının Yapısı

4. UYGULAMA VE BAŞARIM SONUÇLARI

Önceden yapılmış çalışmanın incelenmesi ve geliştirilmiş sistemin tekrar çalıştırılması ile elde edilen sonuçlar ve bu tez çalışması ile geliştirilen modeller ile elde edilen sonuçlar bu başlık altında açıklanmıştır. 4.1. başlığı altında alınan sonuçları karşılaştırabilmek için kullanılan başarımleri açıklanmıştır. 4.2. başlığı altında önceden yapılmış çalışmanın tekrar çalıştırılması ile elde edilen başarımleri paylaşılmıştır. 4.3. başlığı altında ise derin öğrenme yöntemleri kullanılarak gerçekleştirilen sınıflandırma başarımleri paylaşılmıştır. Tablolarda karşılaştırmalı sonuçlar paylaşılırken elde edilmiş en yüksek başarımleri tabloya kalın harflerle yazılmıştır.

4.2 başlığı altında anlatılan çalışmadaki sınıflandırma çıktıları bölüt bazlı gerçekleştirilmiş, 4.3 başlığı altında anlatılan derin öğrenme yöntemleri ile sınıflandırma çıktıları ise kişi

bazlı gerçekleştirilmiştir. Bu sebeple bu iki başlık altındaki sonuçların karşılaştırılması adil olmamaktadır. Bölüt bazlı sınıflandırma yapılarak bölütlenmiş verinin derin öğrenme yöntemi ile sınıflandırılması sonuçlarının 4.2'deki en yüksek alınmış başarımları ile karşılaştırılması 4.4 başlığı altında verilmiştir

4.1. Başarımları Metriği

Önerilen sistemlerin sınıflandırma başarımlarını ölçmek için Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall/Sensitivity), Özgüllük (Specificity) ve F1 Score metrikleri kullanılmıştır. Bu metriklerin hesaplanmasında True Positive, True Negative, False Positive, False Negative değerleri kullanılmaktadır. Bu değerlerin açıklaması aşağıdaki gibidir:

- True Positive (TP): Pozitif olarak tahmin edilmiş, etiketi gerçekte pozitif olan verilerin sayısıdır.
- True Negative (TN): Negatif olarak tahmin edilmiş, etiketi gerçekte negatif olan verilerin sayısıdır.
- False Positive (FP): Pozitif olarak tahmin edilmiş, etiketi gerçekte negatif olan verilerin sayısıdır.
- False Negative (FN): Negatif olarak tahmin edilmiş, etiketi gerçekte pozitif olan verilerin sayısıdır.

Doğruluk, modelde sınıfına bakılmaksızın doğru tahmin edilmiş verilerin sayısının bütün verilerin sayısına oranıdır. Denklem (13) ile doğruluk metriğinin nasıl hesaplandığı verilmiştir. Özellikle dengeli dağılıma sahip olmayan veri setlerinde sadece bu parametrenin kullanılması çoğunlukta olan verinin daha iyi tahmin edilmesinden dolayı az olan sınıfın doğru tahmin edilip edilemediğini ölçmemektedir.

$$Doğruluk(Accuracy) = \frac{TP + TN}{TP + TN + FP + FN} \quad (13)$$

Kesinlik bütün yaptığımız pozitif tahminlerden ne kadarının gerçekte pozitif olduğu bilgisini verir. Kesinlik metriği, Denklem (14) ile verilmiştir.

$$Kesinlik(Precision) = \frac{TP}{TP + FP} \quad (14)$$

Duyarlılık pozitif sınıftaki bütün verilerden ne kadarının doğru tahmin edildiği bilgisini verir. Duyarlılık metriği, Denklem (15) ile verilmiştir.

$$Duyarlılık(Recall/Sensitivity) = \frac{TP}{TP + FN} \quad (15)$$

Özgüllük negatif sınıftaki bütün verilerden ne kadarının doğru tahmin edildiği bilgisini verir. Özgüllük metriği, Denklem (16) ile verilmiştir.

$$Özgüllük(Specificity) = \frac{TN}{TN + FP} \quad (16)$$

F1 score, kesinlik ve duyarlılık parametrelerinin harmonik ortalamasıdır. Denklem (17)'de F1 score gösterilmiştir. Dengesiz dağılıma sahip veri setlerinde kesinlik veya duyarlılık tek başına yeterli olmayabilir; biri yüksekken diğeri düşük olabilir. F1 score, bu iki metriğin dengeli bir ölçüsünü sunar. Bu sebeple dengesiz veri dağılıma sahip problemlerin başarımlarını karşılaştırırken doğruluk metriği ile beraber kesinlik ve duyarlılık metriklerine bakmak yerine F1 score metriği kullanılabilir.

$$F1Score = \frac{2 * Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (17)$$

4.3. başlığı altındaki sonuçlarda farklı denemeler ve her sınıf için sonuçlar paylaşıldığı için veri çokluğu oluşturmamak adına doğruluk ve her bir sınıf için F1 score metrikleri paylaşılmıştır.

4.2. Beş Aşamalı Makine Öğrenmesi Tabanlı Sınıflandırıcı Başarım Sonuçları

Bu bölümde beş aşamalı sınıflandırma yaklaşımına dair önceden geliştirilmiş çalışmanın test edilmesi sonucu alınan sınıflandırma başarım sonuçları paylaşılmıştır [7]. Öncelikle, ön işleme, S1, S2 seslerinin tanımlanması ve bölütleme adımları ile bölütlenmiş FKG sinyalleri oluşturulmuştur. Sonrasında oluşturulan her bir bölüt için özniteliklerin çıkarılıp birleştirilmesi ile bir öznitelik vektörü oluşturulmuştur. Her bir bölütün öznitelik vektörleri yan yana eklenerek sınıflandırma aşamasının yapılacağı veri seti oluşturulmuştur. Her bir FKG sinyalinin bölütlerinin öznitelik vektörleri ayrı verilmiş gibi düşünülerek veriler eğitim, test ve doğrulama setleri olarak üçe ayrılmış, bölütlenmiş veri üzerinden sınıflandırma gerçekleştirilmiştir. Bu başlık altındaki testler bölüt bazlı gerçekleştirilmiştir. Model eğitilirken kişinin PCG sinyal kaydının bir kısmı eğitimde kullanılırken, aynı sinyalin kalan kısmı ise testte kullanılmış, model kısmen eğitilirken gördüğü veri üzerinde test edilmiştir.

Sadece zamana bağlı özniteliklerle ve hem zamana bağlı öznitelikleri hem de MFCC öznitelikleri bir arada olacak şekilde dört farklı sınıflandırma yöntemiyle ayrı ayrı iki seviyeli sınıflandırma yapılabilecek şekilde eğitimler alınmıştır. Bu doğrultuda, ilk seviye sınıflandırma normal anormal sınıflandırması olmuştur. İkinci seviye sınıflandırma ise AD (AS) ve MY (MI) sınıflandırması olmuştur. Doğrusal Sınıflandırıcı, MLP, k-NN ve SVM yöntemleri için birinci seviye ve ikinci seviye sınıflandırma sonuçları iki ayrı tabloda verilmiştir.

Sadece zamana bağlı özniteliklerle Doğrusal Sınıflandırıcı, MLP, k-NN ve SVM yöntemleri için birinci seviye sınıflandırma sonuçları Tablo 4.1’de verilmiştir.

Başarım Kriteri(%)	Doğrusal - Sınıflandırıcı		k-NN		SVM		MLP-BP	
	N	aN	N	aN	N	aN	N	aN
Duyarlılık	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
Kesinlik	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
Özgüllük	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
Doğruluk	1.0		1.0		1.0		1.0	

Tablo 4.1 Her Bir Sınıflandırıcı İçin Zamana Bağlı Özniteliklerle Birinci Seviye Sınıflandırmada Bölüt Bazlı Başarım Sonuçları

Sadece zamana bağlı özniteliklerle Doğrusal Sınıflandırıcı, MLP, k-NN ve SVM yöntemleri için ikinci seviye sınıflandırma sonuçları Tablo 4.2’de verilmiştir.

Başarım Kriteri(%)	Doğrusal - Sınıflandırıcı		k-NN		SVM		MLP-BP	
	AD	MY	AD	MY	AD	MY	AD	MY
Duyarlılık	0.67	0.62	0.81	0.62	0.88	0.82	0.90	0.89
Kesinlik	0.65	0.65	0.69	0.76	0.84	0.87	0.89	0.90
Özgüllük	0.62	0.67	0.62	0.81	0.82	0.88	0.89	0.90
Doğruluk	0.65		0.72		0.85		0.89	

Tablo 4.2 Her Bir Sınıflandırıcı İçin Zamana Bağlı Özniteliklerle İkinci Seviye Sınıflandırmada Bölüt Bazlı Başarım Sonuçları

Zamana bağlı ve MFCC öznitelikleri ile Doğrusal Sınıflandırıcı, MLP, k-NN ve SVM yöntemleri için birinci seviye sınıflandırma sonuçları Tablo 4.3’de verilmiştir.

Başarım Kriteri (%)	Doğrusal - Sınıflandırıcı		k-NN		SVM		MLP-BP	
	N	aN	N	aN	N	aN	N	aN
Duyarlılık	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
Kesinlik	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
Özgüllük	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
Doğruluk	1.0		1.0		1.0		1.0	

Tablo 4.3 Her Bir Sınıflandırıcı İçin Zamana Bağlı ve MFCC Öznitelikleriyle Birinci Seviye Sınıflandırmada Bölüt Bazlı Başarım Sonuçları

Zamana bağlı ve MFCC öznitelikleri ile Doğrusal Sınıflandırıcı, MLP, k-NN ve SVM yöntemleri için ikinci seviye sınıflandırma sonuçları Tablo 4.4’de verilmiştir.

Başarım Kriteri (%)	Doğrusal - Sınıflandırıcı		k-NN		SVM		MLP-BP	
	AD	MY	AD	MY	AD	MY	AD	MY
Duyarlılık	0.87	0.86	0.85	0.76	0.94	0.93	0.92	0.83
Kesinlik	0.87	0.86	0.79	0.83	0.93	0.93	0.85	0.90
Özgüllük	0.86	0.87	0.76	0.85	0.93	0.94	0.83	0.91
Doğruluk	0.86		0.81		0.93		0.87	

Tablo 4.4 Her Bir Sınıflandırıcı İçin Zamana Bağlı ve MFCC Öznitelikleriyle İkinci Seviye Sınıflandırmada Bölüt Bazlı Başarım Sonuçları

Bütün sınıflandırıcılar için MFCC öznitelikleri ve zaman bağlı öznitelikleri kullanılarak eğitilmiş sınıflandırıcıların test sonuçları sadece zamana bağlı özniteliklerle yapılan test sonuçlarına göre daha başarılı olmuştur. Buradan MFCC özniteliklerinde bazı hastalıklar bazında sınıflandırma için kayda değer bilgiler verdiği değerlendirilebilir.

Normal-anormal sınıflandırma da 4 farklı sınıflandırma yöntemi birbirlerine yakın sonuçlar vermiştir. Doğrusal Sınıflandırıcının sonuçları diğerlerine yakın olsa da en düşük sonucu bu yöntem vermiştir. İkinci aşama olan MY ve AD sınıflandırmasında en düşük sonucu yine Doğrusal Sınıflandırıcı, en yüksek sonucu ise MLP-BP yöntemi vermiştir. Doğrusal Sınıflandırıcının en düşük sonuçları vermesi FKG kalp seslerinin karmaşık bir yapıya sahip olması bu sebeple doğrusal bir sistemin bu verileri sınıflandırma konusunda yetersiz olduğu düşünülmüştür.

4.3. Derin Öğrenme Tabanlı Sınıflandırıcı Başarım Sonuçları

Derin öğrenme yöntemleri kullanılarak kalp seslerinin sınıflandırılmasında iki farklı sınıflandırma gerçekleştirilmiştir. Bunlardan ilki normal ve anormal olarak iki sınıflı sınıflandırma, diğeri ise normal, AD, MY olacak şekilde üç sınıflı sınıflandırmadır. Bu başlık altında önce iki sınıflı sınıflandırma başarım sonuçları, sonrasında üç sınıflı sınıflandırma başarım sonuçları paylaşılmıştır.

Bu tez çalışmasında kalp seslerinin sınıflandırılması konusunda beş farklı model tasarlanmıştır. Bunlar 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN ve 2S-2DCNN'dir. 2H-1DCNN ve 2S-1DCNN modelleri 1DCNN kullanılarak, 2S-2DCNN ise 2DCNN kullanılarak ikiden fazla sınıflandırma için özelleştirilmiş modellerdir. Bu modellerden sadece 1DCNN ve 2DCNN normal ve anormal sınıflandırma için kullanılmış, üç sınıflı sınıflandırmada beş modelde kullanılmıştır. Aşağıdaki başlıklar altında sonuçlar verilirken bu model başlıkları altında alınan sonuçlar paylaşılmıştır. Sonuç tablolarında verilmiş 'MN' kısaltması maksimum normalizasyonu, 'ZN' kısaltması zscore normalizasyonu ifade etmektedir.

Bu başlık altındaki test kişi bazlı gerçekleştirilmiş, modeller eğitimde hiç görmedikleri veriler üzerinden test edilmiştir. Her bir veri seti yüzde seksen eğitim, yüzde on doğrulama, yüzde on test olacak şekilde ayrılmıştır. Doğru karşılaştırma yapabilmek için veri setini bölme işlemi hep aynı yerden başlayacak ve her bir deney için eğitim, doğrulama ve test verileri aynı olacak şekilde ayarlanmıştır. Bölütlenmiş ve Parçalı veriler

ile eğitim ve test gerçekleştirilirken bu setler dikkate alınmış, bir FKG sinyalinin bütün bölütlerinin/parçalarının aynı set içinde olması sağlanmıştır.

4.3.1. Normal-Anormal Sınıflandırma Başarım Sonuçları

Az miktardaki veri setleri ile derin öğrenme algoritmaları yeterli öğrenmeyi sağlayamamakta ya da aşırı öğrenme sorunu yaşamaktadır. Bu sebeple bu projede kullanılan veri seti HU-PCG ile 3.1. başlığı altında açıklanan HVD, PASCAL, PhysioNet veri setleri ile aynı model eğitilerek sonuçlar sinyaller bazında incelenmiş, bu sayede diğer veri setleri bu veri seti ile eğitilmiş model başarımını artırmaya nasıl katkı sağlayabilir sorusu üzerinde çalışılmıştır. PASCAL ve PhysioNet veri setlerindeki veriler sadece normal ve anormal olarak etiketlenmiştir. Adil bir karşılaştırma yapabilmek için burada dört farklı veri seti için normal anormal sınıflandırıcı eğitilmiştir.

Bu başlık altında önce 1DCNN ile normal anormal sınıflandırma sonuçları, sonrasında da 2DCNN ile normal anormal sınıflandırma sonuçları verilmiştir. Son olarak PhysioNet veri seti için 1DCNN ve 2DCNN modellerinin başarımlarının karşılaştırılması verilmiştir.

4.3.1.1. 1DCNN Başarım Sonuçları

FKG sinyaline basit seviye ön işleme uygulanarak ön işlenmiş bir boyutlu veri giriş verisi oluşturacak şekilde 1DCNN’de veri setleri için eğitimler gerçekleştirilmiştir. Farklı yaklaşımlarda modelin nasıl çalıştığı ve başarımı test edilmiştir. İlk başta bu model ile HU-PCG, HVD, PASCAL, PhysioNet veri setleri için alınan başarım sonuçları paylaşılmıştır. Sonrasında sırasıyla; veri artırma yöntemlerinin başarım sonuçları, ön eğitilmiş modellerin başarım sonuçları paylaşılmıştır.

HU-PCG, HVD, PASCAL, PhysioNet Veri Setlerinde Başarım Sonuçları

Dört veri seti için veriler sadece ön işleme aşamasından geçirilip modele giriş olacak şekilde normal-anormal sınıflandırma için eğitimler gerçekleştirilmiş ve test sonuçları alınmıştır. Sonuçlar Tablo 4.5’de sunulmuştur. İki farklı normalizasyon yöntemi kullanılarak alınmış sonuçlar Tablo 4.5’de MN ve ZN başlıkları altındaki sütunlarda verilmiştir.

Deney Sırası	Veri Seti	Doğruluk		Normal-F1 score		Anormal-F1 score	
		MN	ZN	MN	ZN	MN	ZN
1	HU-PCG	0.80	0.87	0.87	0.91	0.57	0.75
2	HVD	1.00*	1.00*	1.00	1.00	1.00	1.00
3	PASCAL	0.81	0.79	0.89	0.88	0.40	0.29
4	PhysioNet	0.86	0.87	0.91	0.92	0.70	0.71

Tablo 4.5 HU-PCG, HVD, PASCAL, PhysioNet Veri Setleri için Normal-Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* Bu deneyde % 100 doğruluk alındığı için çevrim (epoch) sayısı 143 olarak seçilmiştir.

Tablo 4.5'deki sonuçlar incelendiğinde; tasarlanan modelin tek bir veri seti için özelleştirilmiş olmadığı, farklı veri setleri içinde çalışabilir olduğu görülmüştür. HU-PCG veri seti dışında diğer veri setlerinde de yüksek sonuçlar elde edilmiş olunması diğer veri setlerinin HU-PCG veri setinin başarımını artırmak için kullanılabileceği sonucuna varılmıştır. Bu veri setleri kullanılarak başarımı artırmak için iki farklı yöntem kullanılabilir. Bu yöntemlerden birinde veri setleri birleştirilerek oluşturulan yeni veri setiyle ya da HU-PCG veri setine göre miktarca daha çok veri içeren veri setlerinde eğitimler gerçekleştirilerek öğrenme aktarımı gerçekleştirilebilir. Diğer yöntem ise diğerlerine karşın daha yüksek oranda veri sayısına sahip PhysioNet veri setinde alınan başarım sonuçlarına göre geliştirilmiş model iyileştirilip HU-PCG veri seti için eğitim gerçekleştirilebilir. Derin öğrenme modelleri daha çok veri iyi daha güvenilir sonuçlar verdiği için bu şekilde bir yöntem düşünülmüştür. Bu iki yöntemde bu çalışmada kullanılmış aşağıda ilgili başlıklar altında başarım sonuçları verilmiştir.

HU-PCG ve PhysioNet veri setlerinde zscore normalizasyon yöntemi daha iyi sonuç verirken, PASCAL veri setinde mutlak maksimum normalizasyon yöntemi daha iyi sonuç vermiştir. Bu farklılık her iki normalizasyon yönteminde kullanılabileceği ve diğer yapılan deneylerde de iki yöntemin ayrı ayrı değerlendirilmesi gerektiğini göstermektedir.

HVD veri seti ile gerçekleştirilmiş eğitim sonundaki test sonucu diğer veri setlerine göre en yüksek sonucu vermiştir. Bu veri setinin zamana bağlı görsellerine ve burada alınan test sonuçlarına bakıldığında bu veri setinin gürültüden temizlenmiş bir veri seti olduğu düşünülmüştür. Bu sebeple aşağıda yapılmış diğer denemelerde bu veri seti kullanılmamıştır. Buna ek olarak, HU-PCG, PhysioNet ve Pascal veri setleri ile alınan eğitim sonuçlarının birbirlerine yakın olmasından dolayı verilerin benzer yapıda olduğu düşünülmüştür.

Veri Artırma Yöntemlerinin Başarım Sonuçları

3.2.2.1. başlığı altında anlatılmış veri artırma yöntemleri kullanılarak eğitilen 1DCNN'den alınan başarım değerleri karşılaştırılmıştır. Bu kapsamda rastgele kırpma, sabit boyutlu parçalara ayırma, bölütleme yöntemleri kullanılmıştır. Rastgele kırpma yönteminde her çevrimde bir FKG sinyali içerisinde rastgele 20000 uzunluğunda kırılan veri ile eğitim gerçekleştirilmiştir. Buradaki test bütün bir FKG sinyalin tek aşamada testi, test verisi çoğaltma yöntemi ve her bir FKG sinyalinin ilk 20000 uzunluğundaki kısmı ile elde edilen veri üzerinden başarım sonuçları alınmış, en yüksek başarım sonucu her bir FKG sinyalinin ilk 20000 uzunluğundaki kısmının testi ile alınmıştır. Bu sebeple test aşaması her bir FKG sinyali için sinyalin ilk 20000 uzunluğundaki kısmı ile gerçekleştirilmiştir. Parçalı veri yönteminde ise FKG sinyali her biri 20000 uzunluğunda olacak şekilde eşit uzunlukta parçalara ayrılıp her bir parça ayrı bir eğitim verisi olacak şekilde eğitim gerçekleştirilmiştir. Çalışmada amaç FKG ses sinyalinin bir bütün olarak sınıflandırılması olduğu ve diğer yöntemlerle karşılaştırmanın adil olabilmesi için testler parçalı veriler ayrı sinyallermiş gibi düşünülmeyen bütün bir ses sinyali üzerinden çıktı alınarak hesaplanmıştır. Bu sebeple test verisi çoğaltma yöntemi ve FKG verisinin ilk 20000 uzunluğundaki kısmı ile test edilmiştir. Test verisi çoğaltma yöntemi ile yapılan test sonucu daha yüksek olduğu için bu dokümanda bu sonuç gösterilmiştir. Bölütlenmiş veri kullanılırken her bir bölütlenmiş veri ayrı giriş verisi olacak şekilde eğitim ve test aşamaları gerçekleştirilmiştir. Yukarıda açıklanmış veri artırma yöntemleri ile bu yöntemin karşılaştırılabilmesi için bu başlık altında kişi bazlı bölütlenmiş veri ile sınıflandırma başarım sonuçları paylaşılmıştır. Bölütlenmiş verinin derin öğrenme yöntemleri ile sınıflandırılması başarım sonuçlarını 3.2.1. başlığı altında açıklanmış yöntemle karşılaştırabilmek için kişi bazlı değil, bölütlenmiş veri bazlı gerçekleştirilmiş

başarım sonuçları 4.4 başlığı altında verilmiştir. Hiçbir veri artırma yöntemi kullanılmadan yapılan eğitim başarım sonuçları ile yukarıda bahsedilmiş veri artırma yöntemleri ile yapılan eğitim başarım sonuçları Tablo 4.6’da gösterilmiştir. Bu tablodaki bütün başarım sonuçları HU-PCG veri seti ile gerçekleştirilmiş eğitimler için alınmıştır. Tabloda maksimum ve zscore normalizasyon yöntemleri için alınan sonuçlar sırasıyla MN, ZN sütunları altında verilmiştir. Bölütlenmiş veri 3.2.1. başlığı altında açıklanan şekilde oluşturulduğu ve bu yöntemde maksimum normalizasyon yöntemi kullanıldığı için buradaki tabloda sadece maksimum normalizasyon yöntemi sütunu doldurulmuştur.

Deney Sırası	Veri Artırma Yöntemi	Doğruluk		Normal-F1 score		Anormal-F1 score	
		MN	ZN	MN	ZN	MN	ZN
1	Yok	0.80	0.87	0.87	0.91	0.57	0.75
2	Parçalı	0.93	0.87	0.95	0.91	0.91	0.75
3	Bölütlenmiş	0.77	-	0.85	-	0.49	-
4	R.Kırpma*	0.93	0.93	0.95	0.95	0.89	0.89

Tablo 4.6 HU-PCG Veri Setinde Bütün, Parçalı, Bölütlenmiş, Rastgele Kırpılmış Giriş Verileri ile Normal Anormal Sınıflandırmada Kişi Bazlı Başarım Sonuçları

* R.Kırpma; rastgele kırpma yöntemini ifade edilmektedir.

Tablo 4.6’deki sonuçlar incelendiğinde maksimum normalizasyon kullanıldığında Rastgele Kırpma ve Parçalı eğitim sonuçlarının aynı olduğu ve diğer iki yöntemle göre daha yüksek olduğu görülmüştür. Zscore normalizasyon kullanıldığında ise en yüksek başarım değerini Rastgele Kırpma yönteminin verdiği görülmüştür. Buradan yola çıkarak modele giriş yapan veri içerisinde her seferinde yaklaşık aynı periyot sayısında sinyal göndermek modelin öğrenmesine fayda sağlamıştır. Bir FKG sinyalini parçalara bölünüp bir çevrimde bütün bir FKG sinyalinin ayrı ayrı parçalar halinde görülüp eğitilmesi kadar her çevrimde FKG sinyalinin farklı bir kısmını görülüp eğitilmesi başarıma katkı sağlamıştır.

Bölütlenmiş olarak modele gönderilen veri daha az bilgi içermektedir. Az veri bulunan veri setleri ile derin öğrenme modellerinin öğrenebilmesi için modele gönderilen verinin daha çok detay içermesi gerekmektedir. Bu sebeple bölütlenmiş veri ile yapılan eğitimin test sonucu en düşük gelmiştir.

Yukarıdaki denemelerde her iki normalizasyon yönteminde en yüksek sonucu veren rastgele kırpma yöntemi daha yüksek veriye sahip PhysioNet veri seti ile de denenmiş, alınan sonuçlar gözlemlenmiştir. Rastgele kırpma yöntemiyle yapılan eğitim sonucu elde edilen başarımın tespiti için iki farklı test yöntemi ile testler yapılmış, sonuçlar karşılaştırılmıştır. Tablo 4.7’de sonuçlar paylaşılmıştır. Bu yöntemin başarıma faydası olup olmadığını gözlemleyebilmek için Tablo 4.5’deki 4. deney sonucu da bu tabloya 1. deney sonucu olarak eklenmiştir. Tablo 4.7 Deney 1’deki eğitim FKG sinyalinin tamamı ile gerçekleştirildiği için tablodaki başarım sonucu da bütün FKG verisinin bir seferde modele gönderilip test edilmesi ile gerçekleştirilmiştir. Deney 2 ve 3’de Rastgele Kırpma yöntemi kullanılmıştır. Deney 2’nin başarım sonucu hesaplanırken test verisindeki FKG sinyalinin başlangıcından itibaren ilk 20000 uzunluğundaki kısım ile oluşan veri ile test gerçekleştirilmiştir. Deney 3’ün başarım sonucu test verisi çoğaltma (test augmentation) yöntemi kullanılarak hesaplanmıştır. Rastgele kırpma yöntemi test edilirken bütün veri üzerinden test daha düşük olduğu için tabloda gösterilmemiştir. Daha düşük olmasının sebebi modelin görmeye alışkın olduğu periyot uzunluğundaki veri olmaması bu sebeple modelin düzgün cevap verememesi olduğu düşünülmüştür.

Deney Sırası	Veri Artırma Yöntemi	Test Etme Yöntemi	Doğruluk		Normal-F1 score		Anormal-F1 score	
			MN	ZN	MN	ZN	MN	ZN
1	Yok	Bütün*	0.86	0.87	0.91	0.92	0.70	0.71
2	R.Kırpma**	İlk V.***	0.92	0.91	0.95	0.94	0.84	0.82
3	R.Kırpma**	Test Ç.***	0.91	0.90	0.94	0.93	0.81	0.78

Tablo 4.7 PhysioNet Veri Setinde Bütün, Rastgele Kırılmış Giriş Verileri ile Sınıflandırmada Kişi Bazlı Başarım Sonuçları

* Bütün; testin bütün veri üzerinden yapıldığını ifade etmektedir.

** R.Kırpma; rastgele kırpma yöntemini ifade edilmektedir.

*** İlk V.; FKG sinyali içerisinde ilk 20000 uzunluğundaki kısım ile test yapıldığını ifade etmektedir.

**** Test Ç.; test verisi çoğaltma yöntemi ile test yapıldığını ifade etmektedir.

Tablo 4.7'deki sonuçlar incelendiğinde Rastgele Kırpma yönteminin bu veri setinde de başarımı artırdığı görülmüştür. Rastgele Kırpma yöntemi ile her çevrimde (epoch) modele bir FKG sinyalinin farklı parçası verilmekte, bu sayede modelin aşırı öğrenmesini engellemeye katkı sağladığı sonuç olarak da başarımı artırdığı düşünülmüştür. Ayrıca bu yöntem sayesinde modele her seferinde yaklaşık aynı periyot sayılarında veriler gönderilerek modelin hep aynı yapıda veri alması sağlanmış, bu sayede daha rahat öğrenebildiği sonucuna varılmıştır. FKG sinyalinin ilk 20000 örneklem uzunluğundaki kısmı üzerinden test etme ile test çoğaltma yöntemi ile test etme birbirlerin yakın sonuçlar vermiştir. Test verisi çoğaltma yöntemi bütün veriyi görüp ayrı ayrı değerlendirip ortalama bir değer verdiği için ek olarak kullanılabilir bir ölçme parametresi olabileceği düşünülmüştür.

Ön Eğitilmiş ve Eğitilmemiş Deneylelerin Başarım Sonuçları

HU-PCG veri setindeki verilerin sayısının az olması ve derin öğrenme modellerinin çok veri ile daha iyi çalışması sebepleriyle öğrenme aktarımı yöntemi denenmiştir. Öncelikle HPP, HP, PASCAL, PhysioNet veri setleri ile eğitimler gerçekleştirilmiş, sonrasında bu

eğitimlerde elde edilmiş model ağırlıklarıyla eğitime başlanacak şekilde HU-PCG veri seti ile tekrar eğitimler yapılmış, alınan sonuçlar incelenmiştir. Bu şekilde yapılan eğitimler "Ön Eğitilmiş" olarak adlandırılmıştır.

Gürültüden ayrıştırıldığı düşünülen HVD veri seti hariç, HU-PCG, PASCAL, PhysioNet veri setlerinin birleştirilmesi oluşturulan veri setine HPP veri seti denilmiştir. Örnekleme hızları aynı olmasının başarıma katkısı olabileceği düşüncesi ile HU-PCG ve PASCAL veri setleri birleştirilmiş, oluşan veri setine HP veri seti denilmiştir. Bu iki veri seti ile gerçekleştirilmiş eğitim, PASCAL veri seti ile gerçekleştirilmiş eğitim ve PhysioNet veri seti ile gerçekleştirilmiş eğitim model ağırlıkları ile HU-PCG veri seti için Ön Eğitilmiş eğitimler gerçekleştirilmiştir. Burada tek başına PASCAL veri seti ile Ön Eğitim işleminin uygulanmasının sebebi PASCAL veri setinin HU-PCG veri setine göre daha çok veri içermesi ve HU-PCG veri seti ile aynı örnekleme hızına sahip olmasıdır. PhysioNet veri seti ile Ön Eğitim işleminin uygulanmasının sebebi ise en çok veriye sahip PhysioNet veri seti ile yapılmış eğitimdeki modellerin daha genellebilir şekilde öğrendiği düşünülmektedir. Bir önceki yapılan testlerde en yüksek sonuçların rastgele kırpma yöntemi ile alınmasından dolayı buradaki eğitimler rastgele kırpma yöntemi ve zscore normalizasyon yöntemleri kullanılarak gerçekleştirilmiştir.

HPP ve HP veri setleri ile yapılmış eğitimlerin başarımları doküman sonundaki EKLER başlığı altında verilmiştir. Tablo 4.8'de HU-PCG veri seti için Ön Eğitilmemiş model ile alınan başarımları sonucu ve yukarıda bahsedilen Ön Eğitilmiş eğitimler sonucu alınan başarımları verilmiştir. Tablo 4.8'deki sonuçlar incelendiğinde HPP ve HP veri setiyle önden eğitilmiş model ağırlıkları kullanılarak sonrasında da HU-PCG veri setinde eğitilmiş modellerin başarımları değerlerinin, PASCAL ve PhysioNet veri seti ile önceden eğitilmiş model ağırlıkları kullanılarak sonrasında HU-PCG veri setinde eğitilmiş modellere göre daha düşük olduğu görülmüştür. Bu duruma veri setlerinin yapılarının ve örnekleme hızlarının farklı olmalarından kaynaklandığı düşünülmüş, bütün veya bir kısım veri setlerinin birleştirilip alınan eğitimdeki ağırlıkların kullanılması ve tekrar eğitimin başarıma katkısının olmadığı düşünülmüştür. Bunun aksine başka veri setleri ile birleştirilmeden sadece bir veri seti

Deney Sırası	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk	Normal- F1 score	Anormal- F1 score
1	Ön Eğitilmemiş	0.93	0.95	0.89
2	Ön Eğitilmiş*	0.87	0.91	0.75
3	Ön Eğitilmiş**	0.87	0.90	0.80
4	Ön Eğitilmiş***	0.93	0.95	0.89
5	Ön Eğitilmiş****	1.0	1.0	1.0

Tablo 4.8 HU-PCG Veri Seti için Ön Eğitilmiş/Eğitilmemiş Model ile Normal Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* HPP veri seti ile elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

** HP veri seti ile elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

*** PASCAL veri seti ile elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

**** PhysioNet veri seti ile elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

ile eğitilen modelin ağırlıkları ile eğitime başlanıp HU-PCG veri seti için tekrar eğitmenin başarımı artırdığı görülmüştür.

Tablo 4.8’de en yüksek başarım 5. deney ile elde edilmiştir. Buradaki başarım artmasının sebebi en çok veriye sahip PhysioNet veri seti ile yapılan eğitim sonucu öğrenilen ağırlıkların daha genellenebilir bir model oluşturması ve bu durumun buradaki ağırlıklarla yapılan Ön Eğitilmiş eğitime katkı sağladığı düşünülmüştür.

Ön Eğitilmiş yaklaşımının PhysioNet veri setindeki etkisini gözlemleyebilmek için bu veri içinde Ön Eğitilmiş yaklaşımı ile eğitimler gerçekleştirilmiş, sonuçlar Tablo 4.9’de paylaşılmıştır. HP veri seti içerisinde PhysioNet veri seti olmaması sebebiyle HP veri seti için önceden eğitilmiş modelle PhysioNet veri seti ile yeniden eğitim yapılmamıştır. Tablo 4.9’deki sonuçlar incelendiğinde PhysioNet veri seti için birleştirilmiş HPP veri seti ile Ön Eğitilmiş yaklaşımı kullanılarak eğitmenin başarımı düşürdüğü, PhysioNet ile eğitilmiş modelin ağırlıkları ile başlayacak şekilde PhysioNet veri seti için tekrar eğitmenin doğruluk parametresini artırmasada anormal sınıf için F1 Score değerini artırdığı görülmüştür. HPP veri seti içindeki her bir veri setinin yapısının farklı olmasından bu sebeple modelin yeteri kadar öğrenememesinden dolayı HPP veri setiyle yapılmış Ön Eğitilmiş yaklaşımını başarıma faydası olmamıştır. Deney 3’deki anormal başarımının artmasının sebebi ise çok veriye sahip

Deney Sırası	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk	Normal- F1 score	Anormal- F1 score
1	Ön Eğitilmemiş	0.91	0.94	0.82
2	Ön Eğitilmiş*	0.88	0.92	0.75
3	Ön Eğitilmiş**	0.91	0.94	0.83

Tablo 4.9 PhysioNet Veri Seti için Ön Eğitilmiş/Eğitilmemiş 1DCNN Model ile Normal Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* HPP veri seti ile elde edilen model ağırlıklarını kullanılarak yapılmış eğitim sonucudur.

** Bu tabloda Deney 1 ile elde edilen model ağırlıklarını kullanılarak yapılmış eğitim sonucudur.

bir veri seti olması ve bir önceki eğitimde az öğrenmiş olması ikinci eğitimde daha çok öğrenebilmesini sağlamıştır.

4.3.1.2. Mel Spektrogram Girişli 2DCNN Başarım Sonuçları

Ön işleme başlığı altında anlatılan şekilde oluşturulmuş iki boyutlu mel spektrogram verileri ile 2DCNN’de HU-PCG ve PhysioNet veri setlerinde eğitimler gerçekleştirilmiştir. Ayrıca Ön Eğitilmiş yöntemiyle de eğitimler gerçekleştirilmiştir. Yapılan bu eğitimler sonucu alınan başarım sonuçları HU-PCG veri seti için Tablo 4.10’da, PhysioNet veri seti için ise Tablo 4.11’de paylaşılmıştır. Maksimum ve zscore normalizasyon yöntemlerine göre alınmış eğitim sonuçları ayrı sütunlarda gösterilmiştir.

Deney Sırası	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk		Normal- F1 score		Anormal- F1 score	
		MN	ZN	MN	ZN	MN	ZN
1	Ön Eğitilmemiş	1.0	0.93	1.0	0.95	1.0	0.91
2	Ön Eğitilmiş*	0.80	0.87	0.80	0.91	0.80	0.75

Tablo 4.10 HU-PCG Veri Seti için 2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre Normal Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* PhysioNet veri seti için 2DCNN ile normal anormal sınıflandırmada elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

Tablo 4.10'daki sonuçlar değerlendirildiğinde maksimum ve zscore normalizasyon yöntemlerinin aynı sonuçlar verdiği görülmüştür. Ön Eğitilmiş ağırlıklarla tekrar eğitimin burada faydası olmadığı, başarımı düşürdüğü görülmüştür. FKG sinyalinin mel spektrogramı oluşturulurken örnekleme hızına ve verilerin yapısına uygun şekilde iki boyutlu görseller oluşmakta, eğitim bu görseller üzerinden yapılmaktadır. Farklı veri setlerinde farklı yapıda mel spektrogram oluşmaktadır. Bu durumun Ön Eğitilmiş yöntemindeki düşük başarımın sebebi olduğu düşünülmüştür.

Deney Sırası	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk		Normal-F1 score		Anormal-F1 score	
		MN	ZN	MN	ZN	MN	ZN
1	Ön Eğitilmemiş	0.92	0.92	0.95	0.95	0.83	0.84
2	Ön Eğitilmiş*	0.92	0.91	0.95	0.94	0.83	0.82

Tablo 4.11 PhysioNet Veri Seti için 2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre Normal Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* PhysioNet veri seti için 2DCNN ile normal anormal sınıflandırmada elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

Tablo 4.11'deki sonuçlar incelendiğinde; PhysioNet veri setinde de her iki normalizasyon yöntemleri yaklaşık aynı sonuçlar vermiştir. Bu sebeple her iki yöntemde tercih edilebilir. Yine aynı şekilde Ön Eğitilmiş yaklaşımının bu veri seti ile 2DCNN modelde kullanılmasının bir faydası olmadığı görülmüştür.

4.3.2. PhysioNet Veri Setinde 1DCNN ve 2DCNN Karşılaştırması

1DCNN ve 2DCNN modelleri kullanılarak PhysioNet veri setinde normal anormal eğitimleri yukarıdaki başlıklar altında açıklandığı şekilde gerçekleştirilmiştir. Bu başlık altında ise PhysioNet veri setindeki her iki modelin başarımlarının karşılaştırılması Tablo 4.12 verilmiştir. Rasgele kırpmaya veri artırma yöntemiyle daha yüksek başarımlar

sağlanması sebebiyle buradaki karşılaştırmada bu yöntem kullanılarak gerçekleştirilmiştir. Karşılaştırmaya Ön Eğitilmiş yaklaşımı ile elde edilmiş sonuçların karşılaştırılması da eklenmiştir.

1DCNN ve 2DCNN modellerinde her bir FKG sinyalinin testi için geçen süre bakımından karşılaştırılması Tablo 4.12'deki ayrı bir sütunda verilmiştir. Her iki paylaşılmış süre maksimum normalizasyon yöntemleri ile alınmış sürelerdir. Zscore normalizasyon ve/veya Ön Eğitilmiş yaklaşımı kullanıldığında arada belirgin bir fark olmadığı için bu deneylerin test aşamalarındaki süreler paylaşılmamıştır. 2DCNN ile bir FKG sinyali için yapılan test süresi 1DCNN ile yapılanın yaklaşık iki katı kadardır. Ayrıca PhysioNet veri seti için 1DCNN'in eğitimi 3 saat 37 dakika sürerken, 2DCNN ile eğitim 5 saat 56 dakika sürmektedir. Burada da yaklaşık iki katı kadar bir fark bulunmaktadır. İki model arasındaki bu süre farkları 2DCNN'de önce mel spektrogramların oluşturulduktan sonra 1DCNN'e göre daha büyük bir modelle eğitilmesinden kaynaklanmaktadır. 1DCNN'nin daha kısa sürede çalışması bir artı oluşturmaktadır.

Model	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk		Normal- F1 score		Anormal- F1 score		Test Süresi*
		MN	ZN	MN	ZN	MN	ZN	
1DCNN	Ön Eğitilmemiş	0.92	0.91	0.95	0.94	0.84	0.82	9.35ms
1DCNN	Ön Eğitilmiş**	0.92	0.91	0.95	0.94	0.84	0.83	-
2DCNN	Ön Eğitilmemiş	0.92	0.92	0.95	0.95	0.83	0.84	18.96ms
2DCNN	Ön Eğitilmiş***	0.92	0.91	0.95	0.94	0.83	0.82	-

Tablo 4.12 PhysioNet Veri Seti için 1DCNN, 2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre Normal Anormal Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* PhysioNet veri setindeki her bir FKG sinyali için test aşamasında geçen süreyi ifade etmektedir.

** PhysioNet veri seti ile elde edilen 1DCNN ile normal anormal sınıflandırma model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

*** PhysioNet veri seti ile elde edilen 2DCNN ile normal anormal sınıflandırma model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

Tablo 4.12'de sonuçlar değerlendirildiğinde 1DCNN ve 2DCNN modellerine göre alınan sonuçlarının birbirlerine çok yakın neredeyse aynı olduğu görülmüştür. Buradan yola çıkarak FKG sinyallerinin sınıflandırılması probleminde sinyalin mel spektrogramlarını çıkararak

daha büyük bir yapıya sahip iki boyutlu CNN modelinde geliştirilmesi yerine daha basit yapıdaki basit ön işleme adımlarına sahip bir boyutlu CNN bir modelin yeterli olduğu görülmüştür. Ayrıca 1DCNN'in daha kısa sürede eğitilip test edilebilmesi durumu da bu modelin tercih edilebilir olmasını artırmaktadır.

Bu çalışmada PyhsioNet veri seti ile yapılmış deneylere göre alınmış en yüksek başarımların değerleri Tablo 4.12'de elde edilmiştir. Buradaki yöntemlerin PhysioNet yarışmasında sonuçların karşılaştırılabilmesi için paylaşılan PhysioNet-D veri setindeki sonuçlarını görebilmek adına tablodaki her bir adım PhysioNet veri seti sadece eğitim ve doğrulama olacak şekilde ikiye bölünüp bu sayede daha çok veriyle eğitimler yapılmıştır. Elde edilen öğrenilmiş ağırlıklara sahip modellerle PysioNet-D veri seti test edilmiştir. En yüksek başarımların değeri maksimum normalizasyon kullanılarak Ön Eğitilmiş 1DCNN model ve zscore normalizasyon kullanılarak Ön Eğitilmiş 2DCNN model ile 0.99 doğruluk, normal ve anormal sınıfları için 0.99 F1 score değerleriyle elde edilmiştir. Burada elde edilmiş detaylı başarımların sonuçları doküman sonunda EKLER başlığı altında verilmiştir.

4.3.3. N, AD, MY Sınıflandırma Başarımların Sonuçları

Bu çalışmadaki asıl amaçlanan HU-PCG veri setindeki kalp seslerini hastalık bazında sınıflandırabilmektir. Normal anormal sınıflandırmadaki sonuçların hastalık bazında sınıflandırma yapabilmek için modelin geliştirilmesine referans olması ve iki kademeli sınıflandırma yöntemlerinde kullanılabilmesi amaçlanmıştır. Normal anormal sınıflandırmada alınmış başarımların sonuçları değerlendirilip bunlara uygun şekilde N, AD, MY sınıflandırılması üzerinde çalışılmıştır. Bu çalışmada geliştirilmiş 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN, 2S-2DCNN ile N, AD, MY sınıflandırması gerçekleştirilmiş, elde edilmiş başarımların sonuçları bu başlık altında paylaşılmıştır. HU-PCG veri seti için normal anormal sınıflandırmada kullanılan eğitim, doğrulama ve test setleri burada da aynen kullanılmış, bu başlık altında gösterilen bütün deneyler bu setler kullanılarak gerçekleştirilmiştir. Bölütlenmiş verinin sınıflandırılmasında yine aynı bölünmüş eğitim, test, doğrulama setleri kullanılmıştır.

N, AD, MY sınıflandırma için 4.3.2.1. başlığı altında 1DCNN ile sınıflandırma başarımları, 4.3.2.2. başlığı altında 2H-1DCNN ile sınıflandırma başarımları, 4.3.2.3. başlığı altında 2S-1DCNN ile sınıflandırma başarımları, 4.3.2.4. başlığı altında 2DCNN ile sınıflandırma başarımları, 4.3.2.5. başlığı altında 2S-2DCNN ile sınıflandırma başarımları, 4.3.2.5. başlığı altında modelleri başarımlarının karşılaştırılması paylaşılmıştır.

4.3.3.1. 1DCNN Başarım Sonuçları

HU-PCG veri seti kullanılarak 1DCNN ile N, AD, MY sınıflandırılması yapılmıştır. Normal anormal sınıflandırmasındaki veri artırma yöntemleri kullanılarak ve Ön Eğitilmiş model yöntemi kullanılarak üç sınıflı sınıflandırma başarımları ölçülmüştür. Öncelikle veri artırma yöntemlerinin başarımları verilmiştir. Ayrıca S1 ve S2 seslerinde hastalıklardaki anormalliklerin olmamasından dolayı bu seslerin kalp seslerinden çıkarılmasına katkısı olup olmayacağı denenmiş ve burada alınmış başarımları paylaşılmıştır. Son olarak Ön Eğitilmiş yöntemi ile yapılmış eğitimleri başarımları verilmiştir.

Veri Artırma Yöntemlerinin Başarım Sonuçları

FKG sinyalinin bütün hali, bölütlenmiş hali, sinyalin 20000 uzunluktaki parçalara bölünmüş hali ve sinyal içerisinden rastgele kırılan 20000 uzunluğundaki hali olmak üzere dört farklı giriş verisi ile eğitimler gerçekleştirilmiştir. Buradaki başarımları kişi bazlı sınıflandırma ile yapılmış testler ile elde edilmiştir. Bölütlenmiş verinin bölüt bazlı sınıflandırılması ile elde edilmiş başarımları sonucunda alınan test başarımları Tablo 4.13'de paylaşılmıştır. Tabloda Deney 2'deki test sonuçları test verisi çoğaltma yöntemi ile alınmıştır.

Deney Sırası	Veri Artırma Yöntemi	Doğruluk		Normal-F1 score		AD-F1 score		MY-F1 score	
		MN	ZN	MN	ZN	MN	ZN	MN	ZN
1	Yok	0.73	0.67	0.87	0.83	0	0	0.40	0
2	Parçalı	0.87	0.73	0.95	0.91	0.80	0.40	0.67	0
3	Bölütlenmiş	0.72	-	0.85	-	0.51	-	0	-
4	R.Kırpma*	0.80	0.73	0.91	0.83	0.50	0.67	0.50	0

Tablo 4.13 HU-PCG Veri Setinde Bütün, Parçalı, Bölütlenmiş, Rastgele Kırılmış Giriş Verileri ile N, AD,MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* R.Kırpma; rastgele kırpma yöntemini ifade edilmektedir.

Tabloda maksimum ve zscore normalizasyon yöntemleri için alınan sonuçlar sırasıyla MN, ZN sütunları altında verilmiştir. Bölütlenmiş veri 3.2.1. başlığı altında açıklanan şekilde oluşturulduğu ve bu yöntemde maksimum normalizasyon yöntemi kullanıldığı için buradaki tabloda sadece maksimum normalizasyon yöntemi sütunu doldurulmuştur.

Tablo 4.13'deki sonuçlar değerlendirildiğinde en yüksek test sonucunun maksimum normalizasyon kullanılarak Deney 2'de Parçalı veri yöntemi ile alındığı, ikinci en yüksek başarımları maksimum normalizasyon ile Rastgele Kırpma yöntemiyle sağlanmıştır. Zscore normalizasyon kullanılarak yapılan eğitimlerde en yüksek başarımları Parçalı ve Rastgele Kırpma yöntemleri ile alınmıştır. Normal anormal sınıflandırmada olduğu gibi burada da bu iki veri artırma yönteminin başarıma katkı sağladığı görülmüştür. FKG sinyalinin eşit uzunlukta parçalara ayrılması bu sayede daha çok veri varmış gibi modelin eğitilmesi model başarımlarını artırmıştır. Rastgele kırpma yönteminde ise model bir FKG sinyalinin her çevrimde farklı kısımlarını gördüğü için model daha iyi öğrenebilmiştir. Bölütlenmiş veri ile eğitim yapılırken modele daha az bilgi verilmesinden dolayı bu yöntem modelin öğrenmesi için yeterli olmamaktadır. Ayrıca bölütlemeye daha basit bir yöntem olan Parçalı yöntemi ile verinin sayısını hem artırılmış hemde başarımlarını artırmıştır. Ancak bölütlemeye başarımlarını artışı sağlanamamıştır.

Tablo 4.13’de her iki normalizasyon yöntemi ile alınan sonuçlar incelendiğinde yerine göre iki yöntemde daha iyi sonuç verdiği durumlar olmuştur. Maksimum normalizasyon yöntemi genel olarak daha yüksek sonuçlar vermiştir.

Tablo 4.14’de FKG sinyalinin bütün hali ve bölütlenmiş halleri için S1 ve S2 sesleri çıkartılmamış halleri ve çıkartılarak oluşan yeni sinyaller ile alınan eğitim sonucundaki kişi bazlı sınıflandırma ile başarımlarını gösterilmektedir. Buradaki sonuçlar maksimum normalizasyon yöntemi kullanılarak gerçekleştirilmiş eğitim başarımlarıdır.

Deney Sırası	Veri Artırma Yöntemi	S1 ve S2 Çıkarılmış/ Çıkarılmamış	Doğruluk	Normal-F1 score	AD-F1 score	MY-F1 score
1	Yok	Çıkarılmamış	0.73	0.87	0	0.40
2	Yok	Çıkarılmış	0.67	0.80	0	0
3	Bölütlenmiş	Çıkarılmamış	0.72	0.85	0.51	0
4	Bölütlenmiş	Çıkarılmış	0.65	0.81	0.22	0.18

Tablo 4.14 Bütün ve Bölütlenmiş Sinyallerde S1 ve S2 Seslerinin Çıkarılmamış ve Çıkarılmış Halleri ile N, AD, MY Sınıflandırmada Kişi Bazlı Başarımları

Tablodaki sonuçlar incelendiğinde S1 ve S2 seslerinin çıkarılmasının başarıma etkisinin olmadığı, en yüksek başarımların S1, S2 sesleri çıkarılmamış FKG sinyalinin bütünü üzerinden yapılan eğitimle alındığı görülmüştür. Bu durumun sebepleri az veri ile eğitim yapılması ve S1 ve S2 sesleri çıkarıldıktan sonrasında bir periyotluk sinyal içinden modelin öğrenebileceği yapının bozulmasıdır.

Ön Eğitilmiş ve Eğitilmemiş Deneylerin Başarımları

Normal anormal sınıflandırmada Ön Eğitim yöntemi ile eğitilmiş modelde başarımların arttığı görülmüştür. Bu sebeple N, AD, MY sınıflandırmasında da bu yöntem denenmiştir. Tablo 4.14’de her iki normalizasyon yönteminde yüksek başarımların Rastgele Kırpma yöntemi ile elde edildiği için buradaki eğitim ve testler de buradaki yaklaşım ile

gerçekleştirilmiştir. Alınan başarımlar sonuçları Tablo 4.15’de verilmiştir. Maksimum ve zscore normalleştirme yöntemlerine ait sonuçları ayrı sütunlarda verilmiştir.

Deney Sırası	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk		Normal- F1 score		AD- F1 score		MY- F1 score	
		MN	ZN	MN	ZN	MN	ZN	MN	ZN
1	Ön Eğitilmemiş	0.80	0.73	0.91	0.83	0.50	0.67	0.50	0
2	Ön Eğitilmiş*	0.73	0.73	0.90	0.86	0.40	0.40	0.40	0.50
3	Ön Eğitilmiş**	0.80	0.73	1.0	0.91	0.57	0.40	0	0

Tablo 4.15 HU-PCG Veri Seti için Ön Eğitilmiş/Eğitilmemiş 1DCNN ile N, AD,MY Sınıflandırmasında Kişi Bazlı Başarımlar Sonuçları

* HU-PCG veri seti ile elde edilen normal anormal sınıflandırma model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

** PhysioNet veri seti ile elde edilen normal anormal sınıflandırma model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

Tablo 4.15’de verilen sonuçlara göre Ön Eğitilmiş yöntem ile eğitimin doğruluk değeri bazında başarımlar artırmada etkisinin olmadığı görülmüştür. Ancak Deney 2’deki sonuçlar incelendiğinde normal anormal sınıf için yapılmış eğitim ağırlıkları ile aynı veri seti için üç sınıflı sınıflandırmada tekrardan eğitimin anormal sınıfındaki hastalıkları daha iyi oranda bulabildiği görülmüştür. Deney 3’de ise daha çok veri setine sahip PhysioNet veri seti ile normal anormal sınıflandırma için eğitilmiş model ağırlıkları kullanmanın normal sınıfı bulmadaki başarımlarını artırdığı görülmüştür. PhysioNet veri setinin normal anormal sınıflandırmadaki yüksek başarımlarını ve daha genellebilir bir model sunması buradaki normal sınıf başarımlarını artırmıştır.

4.3.3.2. 2H-1DCNN Başarımlar Sonuçları

HU-PCG veri seti ile 2H-1DCNN kullanılarak N, AD, MY sınıflandırması gerçekleştirilmiştir. Tablo 4.14’de her iki normalizasyon yönteminde yüksek başarımlar

değerleri Rastgele Kırpma yöntemiyle alındığı için burada gerçekleştirilen eğitimlerde de aynı yöntem kullanılmıştır. Tablo 4.16’da bu model ile elde edilmiş başarımlar sonuçları verilmiştir. Yine aynı tabloda Ön Eğitilmiş yöntemi ile alınmış başarımlar sonuçları da paylaşılmıştır. Maksimum ve zscore normalleştirme yöntemlerine ait sonuçlar ayrı sütunlarda verilmiştir.

Deney Sırası	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk		Normal- F1 score		AD- F1 score		MY- F1 score	
		MN	ZN	MN	ZN	MN	ZN	MN	ZN
1	Ön Eğitilmemiş	0.80	0.73	0.91	0.91	0.50	0.40	0.50	0
2	Ön Eğitilmiş*	0.67	0.73	0.86	0.95	0.40	0.50	0	0
3	Ön Eğitilmiş**	0.67	0.73	0.84	0.95	0.40	0.33	0.33	0
4	Ön Eğitilmiş***	0.80	0.67	1.0	0.90	0.40	0.27	0.40	0

Tablo 4.16 HU-PCG Veri Seti için 2H-1DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre N, AD,MY Sınıflandırmasında Kişi Bazlı Başarımlar Sonuçları

* HU-PCG veri seti için 1DCNN ile normal anormal sınıflandırmada elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

** HU-PCG veri seti için 1DCNN ile N, AD, MY sınıflandırmada elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

*** PhysioNet veri seti ile elde edilen normal anormal sınıflandırma model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

Tablo 4.16’deki sonuçlara göre en yüksek başarımlar değerleri Deney 1 ve 4’deki maksimum normalizasyon yöntemleri kullanılarak alınmıştır. Bunun yanında her iki hastalığı bulmada en yüksek başarımları sağlayan Deney 1 olmuştur. Genel olarak Ön Eğitilmiş yöntemi burada başarımlara katkı sağlamamakla birlikte Tablo 4.15’deki gibi PhysioNet veri setinde eğitilmiş 1DCNN ile normal anormal sınıflandırmadaki model ağırlıkları ile 2H-2DCNN’in tekrar eğitilmesi normal sınıflandırmadaki başarımların artmasını sağlamıştır.

4.3.3.3. 2S-1DCNN Başarım Sonuçları

2S-1DCNN çift aşamalı sınıflandırma yaklaşımının 1DCNN ile denenmiş halidir. Burada akış şu şekildedir; 1DCNN ile eğitilmiş normal-anormal ve AD-MY sınıflandırıcılar kullanılarak test veri seti için her sınıflandırıcının çıktıları alınır. Eğer normal anormal sınıflandırıcının sonucu normal ise, çıktı normal, eğer anormal ise bu çıktı için AD-MY sınıflandırıcı sonucuna bakılır, bu sınıflandırıcının sonucu çıktıyı verir.

Yapılmış deneylerin çoğunda yüksek başarımlar rastgele kırılma yöntemi ile eğitilmiş modellerden alındığı için buradaki her iki sınıflandırıcı bu yöntem ile eğitilip sonuçlar alınmıştır. Ayrıca Ön Eğitilmiş modellerin buraya katkı sağlayıp sağlamadığını görebilmek için Ön Eğitilmiş yaklaşımı ile eğitilmiş iki kademeli sınıflandırma başarımları ve Ön Eğitilmemiş başarımları Tablo 4.17’de verilmiştir. Maksimum normalizasyon ve zscore normalizasyon sonuçları ayrı sütunlarda verilmiştir.

Deney Sırası	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk		Normal-F1 score		AD-F1 score		MY-F1 score	
		MN	ZN	MN	ZN	MN	ZN	MN	ZN
1	Ön Eğitilmemiş	0.80	0.73	0.95	0.95	0.40	0.40	0.50	0
2	Ön Eğitilmiş*	0.80	0.80	0.95	1.0	0.40	0.40	0.50	0.40
3	Ön Eğitilmiş**	0.80	0.93	0.95	1.0	0.67	0.80	0	0.80
4	Ön Eğitilmiş***	0.80	0.87	0.95	1.0	0.67	0.67	0	0.50

Tablo 4.17 HU-PCG Veri Seti için 2S-1DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre N, AD,MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* Normal anormal sınıflandırıcı için Tablo 4.8 Deney 5’de bahsedilen ağırlıklara sahip model ve AD-MY sınıflandırıcı için Tablo 4.15 Deney 1’de öğrenilmiş ağırlıklarla Ön Eğitilmiş yaklaşımı kullanılarak eğitilen model kullanılarak yapılmış test başarımlarıdır.

** Normal anormal sınıflandırıcı için Tablo 4.8 Deney 5’de bahsedilen ağırlıklara sahip model ve AD-MY sınıflandırıcı için Tablo 4.8 Deney 1’de öğrenilmiş ağırlıklarla Ön Eğitilmiş yaklaşımı kullanılarak eğitilen model kullanılarak yapılmış test başarımlarıdır.

*** Normal anormal sınıflandırıcı için Tablo 4.8 Deney 5’de bahsedilen ağırlıklara sahip model ile AD-MY sınıflandırıcı için PhysioNet veri seti kullanılarak 1DCNN ile normal anormal sınıflandırıcıda öğrenilmiş ağırlıklarla Ön Eğitilmiş yaklaşımı kullanılarak eğitilen model kullanılarak yapılmış test başarımlarıdır.

1DCNN modelde iki kademeli sınıflandırma yaklaşımı belli bir değerin üzerinde yüksek başarımlar vermiştir. Maksimum normalizasyon yönteminde Ön Eğitilmiş

yaklaşımları ile eğitim doğruluk değerinde bir artış göstermezken, zscore normalizasyon yöntemiyle alınan eğitimlerde başarımın arttığı görülmüştür. Başarımı en çok artıran deneme HU-PCG veri setinde normal anormal sınıflandırma ile eğitilmiş model ağırlıklarından başlayacak şekilde AD-MY sınıflandırması için modelin eğitilmesi yaklaşımıdır. Buradaki Ön Eğitilmiş yaklaşımı ikinci aşamadaki AD-MY sınıflandırıcının başarımını artırırken, ilk aşamadaki normal anormal sınıflandırıcısında başarımının hali hazırda yüksek olması bu yaklaşımdaki iki kademeli sınıflandırmada başarımı daha çok artırmıştır.

4.3.3.4. Mel Spektrogram Girişli 2DCNN Başarım Sonuçları

Melspektrogram için Ön İşleme başlığı altında belirtilen parametreler kullanılarak oluşturulan mel spektrogram görselleri giriş verisi olacak şekilde 2DCNN ile yapılan eğitim sonucu alınan başarım sonuçları Tablo 4.18'de verilmiştir. Maksimum ve zscore normalizasyon yöntemlerine göre alınmış eğitim sonuçları ayrı sütunlarda gösterilmiştir. Ayrıca Ön Eğitilmiş yöntemiyle de eğitimler gerçekleştirilmiş, başarım sonuçları yine aynı tabloda paylaşılmıştır.

Deney Sırası	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk		Normal- F1 score		AD- F1 score		MY- F1 score	
		MN	ZN	MN	ZN	MN	ZN	MN	ZN
1	Ön Eğitilmemiş	0.73	0.73	0.89	0.90	0.50	0.40	0.50	0.40
2	Ön Eğitilmiş*	0.73	0.80	0.91	0.95	0.40	0.40	0	0.50
3	Ön Eğitilmiş**	0.73	0.73	0.91	0.91	0.40	0.40	0	0

Tablo 4.18 HU-PCG Veri Seti için Mel Spektrogram Girişli 2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre N, AD, MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* HU-PCG veri seti için 2DCNN ile normal anormal sınıflandırmada elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

** PhysioNet veri seti için 2DCNN ile normal anormal sınıflandırmada elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

Tablo 4.18'deki sonuçlar incelendiğinde FKG sinyallerinin mel spektrogramları kullanılarak normal, AD ve MY sınıflandırmasında çok yüksek olmasa da bir başarı sağlamıştır. İki farklı normalizasyon yöntemleri yakın sonuçlar verirken, tablodaki en yüksek başarı değerini zscore normalizasyon yöntemi kullanılarak HU-PCG normal anormal sınıflandırmada elde edilen model ağırlıkları ile Ön Eğitilmiş yaklaşımı kullanılarak eğitilmiş N, AD, MY sınıflandırmada elde edilmiştir. Normal anormal sınıflandırmaya göre, üç sınıflı sınıflandırma da Ön eğitilmiş yönteminin başarıma katkısı olduğu görülmüştür. HU-PCG veri setiyle elde edilen normal anormal sınıflandırmadaki model ağırlıklarının yine aynı veri setiyle üç sınıflı sınıflandırmada kullanılmasının modelin başarımını artırdığı düşünülmüştür. Bu artış her iki sınıflandırmada da aynı veri seti olduğu için mel spektrogramlar aynı yapıya sahip olduğu için sağlanmıştır.

4.3.3.5. 2S-2DCNN Başarım Sonuçları

2S-2DCNN ile iki kademeli sınıflandırma yaklaşımı denenmiş ve alınan sonuçlar Tablo 4.19'de verilmiştir. Tabloda ayrıca Ön Eğitilmiş yöntemi ile yapılmış sonuçlarda verilmiştir. Maksimum ve zscore normalizasyon yöntemleri tabloda ayrı sütunlarda paylaşılmıştır.

Tablo 4.19'deki sonuçlar incelendiğinde Deney 1'de maksimum normalizasyon yöntemi daha yüksek başarı değerleri verirken Ön Eğitilmiş yaklaşımı ile yapılan deneylerde zscore normalizasyon yöntemi daha yüksek başarı değerleri vermiştir. Ön Eğitilmiş yaklaşımı; maksimum normalizasyon ile yapılan eğitimlerin başarımını düşürürken, zscore normalizasyonla yapılan eğitimlerin başarımını artırmış veya değiştirmemiştir. En yüksek başarı değeri zscore normalizasyon kullanılarak Ön Eğitilmiş normal anormal sınıflandırılması ve üç sınıflı sınıflandırıcı ile Ön Eğitilmiş AD-MY sınıflandırılması ile elde edilmiştir. Üç sınıflı sınıflandırıcıda mel spektrogramları kullanılarak hastalık bazında sınıflandırılan modelde hastalıklar daha iyi bulunduğu için buradaki Ön Eğitilmiş yaklaşımıyla bu modelde de başarımı artırdığı düşünülmüştür.

4.3.3.6. 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN ve 2S-2DCNN ile N, AD, MY Sınıflandırmasının Karşılaştırılması

Deney Sırası	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk		Normal-F1 score		AD-F1 score		MY-F1 score	
		MN	ZN	MN	ZN	MN	ZN	MN	ZN
1	Ön Eğitilmemiş	0.80	0.73	0.73	0.95	0.57	0.50	0	0
2	Ön Eğitilmiş*	0.67	0.87	0.86	0.91	0.33	0.67	0	0.80
3	Ön Eğitilmiş**	0.67	0.73	0.86	0.91	0.33	0.40	0	0
4	Ön Eğitilmiş***	0.67	0.80	0.86	0.91	0.33	0	0	0.67

Tablo 4.19 HU-PCG Veri Seti için 2S-2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre N, AD,MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* Normal anormal sınıflandırıcı için Tablo 4.10 Deney 2’de bahsedilen ağırlıklara sahip model ve AD-MY sınıflandırıcı için N, AD, MY olacak şekilde üç sınıflı sınıflandırıcı ile öğrenilmiş ağırlıklarla Ön Eğitilmiş yaklaşımı kullanılarak eğitilen model kullanılarak yapılmış test başarım sonuçlarıdır.

** Normal anormal sınıflandırıcı için Tablo 4.10 Deney 2’de bahsedilen ağırlıklara sahip model ve AD-MY sınıflandırıcı için HU-PCG veri seti için normal anormal sınıflandırıcı ile öğrenilmiş ağırlıklarla Ön Eğitilmiş yaklaşımı kullanılarak eğitilen model kullanılarak yapılmış test başarım sonuçlarıdır.

*** Normal anormal sınıflandırıcı için Tablo 4.10 Deney 2’de bahsedilen ağırlıklara sahip model ve AD-MY sınıflandırıcı için PhysioNet veri seti için normal anormal sınıflandırıcı ile öğrenilmiş ağırlıklarla Ön Eğitilmiş yaklaşımı kullanılarak eğitilen model kullanılarak yapılmış test başarım sonuçlarıdır.

Bu çalışmada iki farklı model geliştirilmiştir. İki kademeli sınıflandırma yaklaşımını kullanabilmek adına bu iki ayrı modelin farklı varyasyonlarının oluşturulması ile bu iki modele ek olarak üç ayrı model oluşmuştur. Geliştirilmiş modeller sırayla 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN, 2S-2DCNN’dir. Bütün modeller N, AD, MY sınıflandırmada kullanıldığı için geliştirilmiş bütün modellerin karşılaştırılması da N, AD, MY sınıflandırma başlığı altında verilmiştir.

Her bir modelde en yüksek başarım değerleri çoğunlukla rastgele kırpma veri artırma yöntemiyle alındığı için buradaki karşılaştırmada da bu yöntemle alınmış sonuçlar paylaşılmıştır.

Tablo 4.20’deki sonuçlar incelendiğinde en yüksek başarım zscore normalizasyon yöntemi kullanılarak 2S-1DCNN ile sağlanmıştır. Burada normal FKG sinyallerinin tamamı doğru bulunurken, AD ve MY etiketli FKG sinyalleri de yüksek başarımlarla tahmin edilmiştir.

Model	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk		Normal- F1 score		AD- F1 score		MY- F1 score	
		MN	ZN	MN	ZN	MN	ZN	MN	ZN
1DCNN	Ön Eğitilmemiş	0.80	0.73	0.91	0.83	0.50	0.67	0.50	0
1DCNN	Ön Eğitilmiş*	0.80	0.73	1.0	0.91	0.57	0.40	0	0
2H-1DCNN	Ön Eğitilmemiş	0.80	0.73	0.91	0.91	0.50	0.40	0.50	0
2H-1DCNN	Ön Eğitilmiş**	0.80	0.67	1.0	0.90	0.40	0.27	0.40	0
2S-1DCNN	Ön Eğitilmemiş	0.80	0.73	0.95	0.95	0.40	0.40	0.50	0
2S-1DCNN	Ön Eğitilmiş***	0.80	0.93	0.95	1.0	0.67	0.80	0	0.80
2DCNN	Ön Eğitilmemiş	0.73	0.73	0.89	0.90	0.50	0.40	0.50	0.40
2DCNN	Ön Eğitilmiş****	0.73	0.80	0.91	0.95	0.40	0.40	0	0.50
2S-2DCNN	Ön Eğitilmemiş	0.80	0.73	1.0	0.95	0.57	0.50	0	0
2S-2DCNN	Ön Eğitilmiş*****	0.67	0.87	0.86	0.91	0.33	0.67	0	0.80

Tablo 4.20 HU-PCG Veri Seti için 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN ve 2S-2DCNN ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre N, AD,MY Sınıflandırmasında Kişi Bazlı Başarım Sonuçları

* PhysioNet veri seti ile elde edilen 1DCNN normal anormal sınıflandırma model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

** PhysioNet veri seti ile elde edilen 1DCNN normal anormal sınıflandırma model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

*** Tablo 4.17 Deney 3'deki sonuçlar buraya eklenmiştir.

**** HU-PCG veri seti için 2DCNN ile normal anormal sınıflandırmada elde edilen model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

*****Tablo 4.19 Deney 2'deki sonuçlar buraya eklenmiştir.

Tablodaki 1DCNN ile 2DCNN sonuçları değerlendirildiğinde 2DCNN'deki önce mel spektrogram çıkarımı ve sonrasında daha daha karmaşık bir modelin eğitilmesi ek işlemlerinin 1DCNN'e göre başarıma ek bir katkısı olmadığı iki modelinde benzer sonuçlar verdiği görülmüştür. Buradaki sonuç Tablo 4.12'de alınan sonuçlar sonrası yapılan çıkarımla uyumludur. Bunun yanında, MY hastalığını sınıflandırma 1DCNN göre 2DCNN daha başarılı olmuştur. 1DCNN'in varyasyonu olan 2H-1DCNN'deki doğruluk sonuçları 1DCNN'e göre farklılık göstermemekle beraber maksimum normalizasyon kullanılarak elde edilen sonuçlar daha yüksek olup MY etiketli verileri daha iyi bulunmuştur. 1DCNN ve 2DCNN modelleri kullanılarak oluşturulan iki kademeli sınıflandırma yapan modeller ise

tek aşamalı sınıflandırma yapan modellere göre daha yüksek başarımlarını sunmuştur. En yüksek doğruluk değerini 1DCNN içeren 2S-1DCNN verirken, bir sonraki en yüksek değeri 2DCNN içeren 2S-2DCNN vermiştir.

Tablodaki 1DCNN, 2H-1DCNN ve 2S-1DCNN başarımlarına göre maksimum normalizasyon yöntemi ile hepsi benzer sonuçlar verirken, zscore normalizasyonda en yüksek değeri 2S-1DCNN yöntemi vermiştir. Yine benzer şekilde 2DCNN ve 2S-2DCNN sonuçları karşılaştırıldığında 2S-2DCNN zscore normalizasyon yönteminde daha yüksek sonuçlar vermiştir. Normal anormal sınıflandırmada daha az sınıf olması buna bağlı olarak daha basit bir problem olmasının sonucu olarak normal anormal sınıflandırma daha yüksek başarımlarını vermektedir. Bunun sonucu olarak 2S-1DCNN ve 2S-2DCNN'deki anormal ve normal sınıflandırılması daha başarılı bir şekilde yapılmaktadır. Buna ek olarak anormallerin sınıflandırılmasında sadece anormallere bakıldığı için, bu durumda buradaki başarımların artmasına katkı sağlamıştır.

Tablo 4.20'de en yüksek sonuç alınmış her iki model bu çalışma ile toplanmış verilerin yukarıda test sonucu alınmış test veri setine eklenmiş hali ile tekrar test gerçekleştirilmiştir. Alınan test sonuçlarına göre Ön Eğitilmiş 2S-1DCNN modeli ile alınmış doğruluk değeri 0.70, sırası ile N, AD, MY için F1 score değerleri ise 0.91, 0.53, 0.44 olmuştur. 2S-2DCNN modeli ile alınmış doğruluk değeri 0.61, sırası ile N, AD, MY için F1 score değerleri ise 0.80, 0.40, 0.36 olmuştur. Bu birleştirilmiş veri seti ile daha düşük sonuç alınmış olmasının sebebi, ek toplanan HU-PCG-T veri setinin HU-PCG veri seti ile aynı şartlar altında toplanmış olmamasıdır.

Yukarıda başarımlarını sonuçları bazında karşılaştırılmış 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN ve 2S-2DCNN modellerinin eğitim ve test aşamalarındaki süreleri karşılaştırılabilmek için Tablo 4.21'de verilmiştir. Bütün süreler maksimum normalizasyon yöntemiyle alınmıştır. Normalleştirme yönteminin değişmesi veya Ön Eğitilmiş yaklaşımının süreleri çok fazla etkilemediği için farklı yöntemler için farklı süreler yerine her bir model için tek süre değerleri verilmiştir.

Model	1DCNN	2H-1DCNN	2S-1DCNN	2DCNN	2H-2DCNN
Eğitim Süresi*	10dk	19dk	21dk***	31dk	40dk****
Test Süresi**	14,51ms	20,8ms	19,88ms	70.82ms	99,94ms

Tablo 4.21 HU-PCG Veri Seti için 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN ve 2S-2DCNN Modelleriyle N, AD,MY Sınıflandırmasında Eğitim ve Test Süreleri

* HU-PCG veri seti ile gerçekleştirilen eğitimin toplam süreyi göstermektedir.

** HU-PCG veri setindeki her bir FKG sinyalinin testi için geçen süreyi göstermektedir.

*** N-An sınıflandırma için geçen süre 19 dakika, AD-MY sınıflandırma için geçen süre 3 dakikadır.

Buraya toplam süre yazılmıştır.

**** N-An sınıflandırma için geçen süre 27 dakika, AD-MY sınıflandırma için geçen süre 13 dakikadır. Buraya toplam süre yazılmıştır.

Tablodaki süreler değerlendirildiğinde en hızlı eğitim ve test aşamalarını gerçekleştiren 1DCNN olmuştur. En yavaş çalışan ise 2S-2DCNN olmuştur. 2DCNN’de Mel spektrogram çıkarılması ve 1DCNN’e göre daha büyük bir modelin eğitilmesi durumları 1DCNN’e göre daha uzun süre gerektirmekte, test aşaması da buradaki fazla işlemlerden dolayı daha uzun vakit almaktadır. Bunun yanında iki kademeli sınıflandırma gerçekleştiren 2H-1DCNN, 2S-1DCNN modelleri tek aşamalı 1DCNN’e göre, 2S-2DCNN ise 2DCNN’e göre daha uzun sürelerde çalışmaktadır. İki kademeli sınıflandırmayı gerçekleştiren modellerde modellerin iki kere kullanılıyor olmasından dolayı bu sonuç beklenen bir sonuçtur.

Alınan başarımların ve modellerin çalışma sürelerinin karşılaştırılması sonucunda varılan sonuç test aşamasında en hızlı olmasada en hızlı modelden yaklaşık 5 milisaniye daha uzun süren ve en yüksek başarımlarını veren zscore normalizasyon kullanılarak ve Ön Eğitilmiş yaklaşımı ile 2S-1DCNN’de elde edilmiştir.

4.4. 1DCNN Sınıflandırıcı ve Beş Aşamalı Sınıflandırma Yaklaşımıyla MLP-BP Sınıflandırıcı Başarım Sonuçları Karşılaştırması

3.2.1. başlığı altında açıklanmış beş aşamalı sınıflandırma çalışması başarımının uçtan uca sınıflandıran derin öğrenme yöntemleri ile karşılaştırılabilmesi için 4.2. başlığı altında açıklandığı şekilde bölüt bazlı ve 4.3. başlığı altında açıklandığı şekilde kişi bazlı sınıflandırma her iki model için gerçekleştirilmiştir.

Bes aşamalı sınıflandırma yaklaşımında HU-PCG veri setindeki bütün veriler için bölütleme gerçekleştirilmiş, her bir bölütten zamana bağlı ve MFCC öznitelikleri bir arada çıkarılıp kaydedilmiştir. Elde edilen öznitelikler kullanılarak MLP-BP yöntemi ile normal anormal sınıflandırma gerçekleştirilmiştir. Aynı bölütlenmiş veriler kullanılarak 1DCNN model ile normal anormal sınıflandırma gerçekleştirilmiştir. Her iki yaklaşımın bölüt bazlı testlerinin başarım sonuçlarının karşılaştırması Tablo 4.22’de verilmiştir.

Başarım Kriteri(%)	1DCNN		MLP-BP	
	N	aN	N	aN
Duyarlılık	1.0	0.98	1.0	1.0
Kesinlik	0.99	0.99	1.0	1.0
Özgüllük	0.98	1.0	1.0	1.0
Doğruluk	0.99		1.0	

Tablo 4.22 Normal Anormal Sınıflandırmada 1DCNN Sınıflandırıcı ve Beş Aşamalı Sınıflandırma Yaklaşımıyla MLP-BP Sınıflandırıcı ile Bölüt Bazlı Sınıflandırma Başarım Sonuçları

Tablo 4.22’deki sonuçlara göre bölüt bazlı normal anormal sınıflandırmada beş aşamalı makine öğrenmesi tabanlı sınıflandırıcıda MLP-BP ile edilmiş başarı 1DCNN ile elde edilen daha yüksek olmasına birlikte 1DCNN ile elde edilen başarım değerleri de bu değerlere çok yakın bir sonuç vermiştir.

Beş aşamalı sınıflandırma çalışması başarımının uçtan uca sınıflandıran derin öğrenme yöntemleri ile kişi bazlı karşılaştırılabilmesi için 4.3. başlığı altında verilmiş sonuçlarda kullanılan test seti burada her iki yaklaşımının test başarımlarının hesaplanmasında kullanılmış alınan sonuçlar karşılaştırılmıştır. Beş aşamalı çalışmada; önceden bölünmüş eğitim ve doğrulama seti birleştirilip ön işleme, bölütleme sonrası zamana bağlı ve MFCC öznitelikleri bir arada kullanılarak MLP-BP ile normal-anormal sınıflandırması için eğitim gerçekleştirilmiştir. MLP-BP ara katmanlarındaki nöron sayısı sırasıyla 124 ve 64 olarak ayarlanmış, tam bağlantı katmanları arasında seyreltme ve katman normalizasyon uygulanmıştır. Maksimum normalizasyon ve rastgele kırpma yöntemleri kullanılarak 1DCNN model ile normal anormal sınıflandırma için eğitim gerçekleştirilmiştir. Ortak test setinde her iki sınıflandırıcı test edilmiştir. Bu sayede her iki sınıflandırıcı hiç görmedikleri veriler üzerinden test edilmiştir. Tablo 4.23’de normal anormal sınıflandırma başarımları sonuçları verilmiştir.

Başarım Kriteri(%)	1DCNN		MLP-BP	
	N	aN	N	aN
Duyarlılık	1.0	0.80	0.70	1.0
Kesinlik	0.91	1.00	1.00	0.62
Özgüllük	0.80	1.0	1.0	0.70
Doğruluk	0.93		0.80	

Tablo 4.23 Normal Anormal Sınıflandırmada 1DCNN Sınıflandırıcı ve Beş Aşamalı Sınıflandırma Yaklaşımıyla MLP-BP Sınıflandırıcı ile Kişi Bazlı Sınıflandırma Başarım Sonuçları

Tablo 4.23’deki sonuçlara göre kişi bazlı normal anormal sınıflandırmada 1DCNN modelin daha yüksek başarımları verdiği, hiç görmediği verilerde daha iyi sonuç verebildiği görülmüştür. Beş aşamalı bölütleme sonrasında öznitelik çıkararak MLP-BP ile sınıflandırmada, sınıflandırıcının sadece modele gönderilen öznitelikler üzerinden öğrenme sağlayabildiği ancak rastgele kırpma yöntemi ile derin öğrenme tabanlı 1DCNN modele

gönderilen sinyal üzerinden önemli noktaları modelin kendisi bulması sebepleriyle 1DCNN modelin daha yüksek başarımlar değerleri sağladığı görülmüştür.

Bölüt bazlı sınıflandırmada beş aşamalı MLP-BP sınıflandırıcı yüksek sonuç verirken, kişi bazlı sınıflandırmada düşük sonuç vermesi modelin ezberlediğini göstermektedir. Bunun yanında bölüt bazlı sınıflandırmadakinin göre düşük olsa da kişi bazlı sınıflandırmada yüzde doksanın üzerinde doğruluk değeri veren 1DCNN modelin genelleştirme kapasitesinin bulunduğu, daha karmaşık problemleri daha iyi çözümlenebildiği görülmüştür. Buradaki sonuçtan yola çıkılarak FKG sinyallerinin sınıflandırılmasında bölütlenmiş sinyalden öznitelikler çıkarılıp Doğrusal Sınıflandırıcı, SVM, MLP, k-NN makine öğrenmesi yöntemlerinin yanında öznitelik çıkarmadan derin öğrenme yöntemleri ile sınıflandırılmasında başarılı sonuçlar verebildiği sonucuna varılmıştır.

5. TARTIŞMA VE SONUÇ

Bu çalışmada derin öğrenme yöntemleri kullanılarak FKG sinyallerinin sınıflandırılması konusunda biri bir boyutlu evrişimsel sinir ağları (CNN) içeren (1DCNN), diğeri mel spektrogram girişli iki boyutlu evrişimsel sinir ağları içeren (2DCNN) iki farklı model geliştirilmiştir. Önce normal anormal sonrasında AD-MY sınıflandırma gerçekleştirilecek şekilde iki kademeli sınıflandırma için 1DCNN'in özelleştirilmesi ile 2H-1DCNN ve 2S-1DCNN modelleri, 2DCNN'in özelleştirilmesi ile 2H-2DCNN modeli geliştirilmiş, kişi bazlı sınıflandırmalar alınmıştır. Derin öğrenme yöntemleri kullanılmadan bölütleme, öznitelik çıkarımı gibi ek aşamalarla ve Doğrusal Sınıflandırıcı, k-NN, SVM, MLP-BP yöntemleri kullanılarak bölüt bazlı sınıflandırma gerçekleştiren çalışma incelenmiş, bu çalışmadaki sonuçlar alınmış ve derin öğrenme tabanlı modellerin sınıflandırma başarımlar sonuçları ile karşılaştırılmıştır.

Ön işleme, S1-S2 seslerini tanımlama, bölütleme, özniteliklerin çıkarılması ve sınıflandırma olmak üzere beş aşamalı sınıflandırma çalışması incelenmiş ve başarımlar sonuçları alınmıştır [7]. Bu çalışmada filtreleme ve normalizasyon adımları, sonrasında MFCC ve DWT

öznitelikleri ile S1, S2 sesleri tanımlanmış, bu bilgiler ve ön bilgiler kullanılarak kalp sesleri bölütlerine ayrılmıştır. Her bir bölüt için sadece zaman bağlı öznitelikleri, zamana bağlı öznitelikler ve MFCC öznitelikleri bir arada olacak şekilde iki ayrı durum için öznitelik vektörleri oluşturulmuştur. Son olarak öznitelik vektörleriyle Doğrusal Sınıflandırıcı, k-NN, SVM, MLP-BP yöntemleri kullanılarak normal-anormal, AD-MY sınıflandırmaları gerçekleştirilmiştir. Bu şekilde iki ayrı sınıflandırma yapılarak iki kademeli önce normal anormal sınıflandırması, sonrasında AD-MY sınıflandırması gerçekleştirilmiştir.

Bir boyutlu evrişim sinir ağları ile basit bir yapıya sahip, daha az ön işlemeye ihtiyaç duyan, özniteliklerin elle çıkarılmasına ihtiyaç duymayan, daha hızlı çalışabilen 1DCNN model oluşturulmuştur. 1DCNN kullanılarak iki kademeli sınıflandırma gerçekleştirebilmek için oluşturulan 2H-1DCNN model iki ayrı çıkış vermekte, ilk çıkış normal anormal sınıf çıktısı, ikinci çıkış ise anormal sınıf çıktısı vermektedir. Model, eğer ilk çıkış normale ikinci çıkışın kaybını dikkate almadan, eğer ilk çıkış anormal ise her iki çıkışın kaybını dikkate alarak eğitilmiştir. Bu modelin test aşamasında ise önce ilk çıkışa bakılmış, eğer ilk çıkış normale modelin sınıflandırma çıktısı normal olarak verilmiş, eğer ilk çıkış anormalse ikinci çıkışın çıktısına bakılmıştır. Eğer ikinci çıkışın çıktısı AD ise modelin çıktısı AD, eğer ikinci çıkışın çıktısı MY ise modelin çıktısı MY olarak verilmiştir. 1DCNN kullanılarak iki kademeli sınıflandırma gerçekleştiren diğer bir model ise 2S-1DCNN'dir. Bu modelde normal ve anormal sınıflandırma ve AD-MY sınıflandırma için 1DCNN model eğitilmiştir. Test aşamasında her iki eğitilmiş modelin çıktıları alınmış, eğer bir FKG sinyali için normal anormal sınıflandırıcının sonucu normal ise o sinyal için 2S-1DCNN model çıktısı normal olarak, eğer normal anormal sınıflandırıcının sonucu anormal ise AD-MY sınıflandırıcının çıktısı 2S-1DCNN modelinin çıktısını vermiştir. Buradaki modellere ek olarak Ön işleme adımı sonrasında mel spektrogramları çıkarılan FKG sinyalleri modelin girdisi olacak şekilde 1DCNN'e göre daha büyük bir yapıya sahip iki boyutlu evrişimsel sinir ağları ile 2DCNN model oluşturulmuştur. 2S-1DCNN ile aynı mantığa sahip 2D-CNN kullanılarak iki kademeli sınıflandırma gerçekleştiren 2S-2DCNN model oluşturulmuştur. Bütün modeller için maksimum ve zscore normalizasyon yöntemleri ayrı ayrı denenmiştir.

Bu çalışmada asıl amaçlanan HU-PCG veri seti ile derin öğrenme tabanlı model

geliştirmek iken derin öğrenme modellerinin daha çok veri ile daha başarılı çalışmasından dolayı internette herkesin kullanımına açık HVD, PASCAL, PhysioNet veri setleri de kullanılmıştır. 1DCNN model ile HU-PCG, HVD, PASCAL, PhysioNet veri setleri, 2DCNN model ile HU-PCG, PhysioNet veri setleri kullanılarak normal anormal sınıflandırılması gerçekleştirilmiştir. Her bir veri seti için belli bir seviye üzerinde sonuçlar alınması her iki modelin tek bir veri seti için özelleşmemiş diğer veri setleri içinde kullanılabilen bir yapıya sahip olduğunu göstermiştir. Bunlara ek olarak HU-PCG veri setinde 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN, 2S-2DCNN modelleri ile N, AD, MY olacak şekilde üç sınıflı sınıflandırma gerçekleştirilmiştir.

Bir FKG sinyalinin bütünü ile modele gönderilmesine ek olarak, FKG sinyali eşit uzunlukta parçalara bölüp her bir parça ayrı veriymiş gibi düşünülerek modele gönderilmesi, bölütlenmiş veri kullanılarak ve her biri ayrı bir veriymiş gibi düşünülerek modele gönderilmesi, her seferinde aynı uzunlukta olacak şekilde FKG sinyali içerisinde rastgele bir kısmının seçilerek modele gönderilmesi yöntemleri ayrı ayrı kullanılarak 1DCNN modelinin eğitilmesi sağlanmıştır. Bu veri artırma yöntemlerinin hepsi normal ve anormal sınıflandırma ve N, AD, MY sınıflandırmaların her ikisinde de denenmiştir. Test aşamasında kişi bazlı sınıflandırma ile sonuçlar alınmıştır. Her iki sınıflandırma için FKG sinyali içerisinde rastgele seçilen bir kısım ile eğitim ve sinyalin eşit boyutta parçalara bölünen veri ile eğitim benzer sonuçlar, hiç bir veri artırma yöntemi kullanılmayan eğitime ve bölütlenmiş veri ile eğitime göre daha yüksek sonuçlar verdiği görülmüştür.

Az veri ile eğitimdeki başarıyı artırmak için kullanılan bir diğer yol ise öğrenme aktarımı yöntemi olan önceden eğitilmiş model ağırlıkları ile yine aynı model kullanılarak ve bu öğrenilmiş model ağırlıklarından başlanacak şekilde modelin tekrar eğitilmesidir. Bazı modellerde bu yöntem başarıyı artırmaz iken kullanılan bir çok modelde başarıyı artırdığı görülmüştür.

Geliştirilen 1DCNN ve 2DCNN modellerinin başarımları karşılaştırıldığında birbirlerine yakın sonuçlar verdiği, çalışma süreleri bazında karşılaştırıldığında ise 1DCNN modelin daha hızlı olduğu görülmüştür. 1DCNN, 2H-1DCNN, 2S-1DCNN, 2DCNN

ve 2S-2DCNN modellerinin başarımları sonuçları karşılaştırıldığında en yüksek başarımları değerini; öğrenme aktarımı ve zscore normalizasyon kullanılarak eğitilen 2S-1DCNN, ikinci en yüksek başarımları; öğrenme aktarımı ve zscore normalizasyon kullanılarak eğitilen 2S-2DCNN modelleri vermiştir. İki kademeli modellerin en yüksek başarımları değerlerini veremesinden dolayı, hastalık bazlı sınıflandırma gerçekleştirirken iki kademeli sınıflandırmanın derin öğrenme modellerinde başarımları artırdığı görülmüştür. Çalışma süreleri olarak karşılaştırma gerçekleştirildiğinde en kısa sürede çalışan 1DCNN, ikinci en kısa sürede çalışan ise 2S-1DCNN'dir. En uzun sürede çalışan ise 2S-2DCNN'dir. Hem başarımları değerlerinin yüksek olması hemde çalışması süresinin 2H-1DCNN, 2DCNN, 2S-2DCNN yöntemlerine göre kısa olup, en hızlı çalışan modelden yaklaşık 5 mili saniye uzun olması sebeplerinden dolayı FKG sinyalleri sınıflandırmasında en tercih edilebilir modelin 2S-1DCNN olduğu sonucuna varılmıştır.

FKG sinyallerinin bölüt bazlı sınıflandırılmasında beş aşamalı MLP-BP yöntemi ile sınıflandırma ve 1DCNN model ile sınıflandırmada beş aşamalı MLP-BP yöntemi daha yüksek başarımları değeri verirken, kişi bazlı sınıflandırma, modellerin eğitim aşamasında hiç görmedikleri veriler üzerinden test edilmesinde 1DCNN model daha yüksek başarımları değeri vermiştir. Görmediği verilerde derin öğrenme tabanlı 1DCNN modelin daha yüksek başarımları göstermesi bu modelin daha genelleyebilir bir model olduğu, karmaşık problemleri daha iyi yorumlayabildiğini göstermiştir. Makine öğrenmesi tabanlı yöntemde yapının çok aşamalı olması, öznelik çıkarımı ve sınıflandırma aşamalarının bağımsız olması kullanım zorluğu oluşturmakta ve çalışma anında ek süre gerektirmektedir. Veri seti özelinde oluşturulan özneliklerin parametrelerinin, sınıflandırmanın farklı veri setleri için kullanılacağı zaman yeniden ayarlanması gerekmektedir. Ancak bu götürülere rağmen öznelik çıkarımının deterministik olması alınacak sonuçların tahmin edilebilir olmasını ve sınıflandırıcı aşamalı olup parçalara ayrılmış olduğu için oluşabilecek hataların daha kolay bir şekilde bulunup düzeltilmesini sağlamaktadır. Bunun yanında derin öğrenme yöntemleri daha kapalı bir şekilde çalıştığı ve stokastik bir yapıda oldukları için, bu yöntemler tahmin edilmesi ve hataların kontrol edilmesi daha zor bir yapıya sahiptir. Buna ek çok sayıda veri ile daha yüksek başarımları vermesi ve veri toplamanın zor bir işlem olması derin öğrenme

yöntemlerinin diğere bir götürüsüdür. Bu götürüler yanında derin öğrenme modellerinin en büyük getirisi tek aşamada uçtan uca sınıflandırma gerçekleştirebilmesi, buna bağlı olarak da test aşamasının çok hızlı gerçekleşebilmesidir. Bir diğere getirisi ise hangi özneliklerin sınıflandırma için önemli olduğunu bulmaya gerek kalmadan derin öğrenme modelinin öznelikleri kendi için öğrenmesi, belli başlı özneliklerin çıkarılıp modele gönderilmemesi, sadece belli şeyleri öğrenmesi için modelin kısıtlanmamış olmasıdır.

Bu çalışma sayesinde, derin öğrenme yöntemleriyle FKG sinyallerinin sınıflandırılması konusunda bir altyapı oluşturulmuştur. İleride, hastalık bazlı sınıflandırmada başarımların değerlerinin artırılması, daha farklı hastalık sınıflarındaki veriler kullanılarak üç kademeli sınıflandırma konusunda çalışılması, burada geliştirilen modellerin iyileştirilmesiyle doktora geri dönüş verecek karar destek sisteminin oluşturulması planlanmaktadır.

REFERANSLAR

- [1] World Health Organization. World health statistics 2023: monitoring health for the sdgs, sustainable development goals. https://cdn.who.int/media/docs/default-source/gho-documents/world-health-statistic-reports/2023/world-health-statistics-2023_20230519_.pdf.
- [2] Sidi Mouhamed Debbal and A Meziane Tani. Heart sounds analysis and murmurs. *International Journal of Medical Engineering and Informatics*, 8(1):49–62, 2016.
- [3] Gari D Clifford, Chengyu Liu, Benjamin Moody, David Springer, Ikaro Silva, Qiao Li, and Roger G Mark. Classification of normal/abnormal heart sound recordings: The physionet/computing in cardiology challenge 2016. In *2016 Computing in cardiology conference (CinC)*, pages 609–612. IEEE, 2016.

- [4] Peter Bentley, Glenn Nordehn, Miguel Coimbra, and Shie Mannor. The PASCAL Classifying Heart Sounds Challenge 2011 (CHSC2011) Results. <http://www.peterjbentley.com/heartchallenge/index.html>.
- [5] Yaseen, Gui-Young Son, and Soonil Kwon. Classification of heart sound signal using multiple features. *Applied Sciences*, 8(12):2344, **2018**.
- [6] Ibrahim Ozkan and Atila Yilmaz. Fonokardiyografi tabanlı tıbbi karar destek sistemi tasarımı. *Doktora Tez İzleme Komitesi Raporu - 4, Hacettepe Üniversitesi*, **2021**.
- [7] Ibrahim Ozkan and Atila Yilmaz. Performance of using mel-frequency cepstrum based features in nonlinear classifiers for phonocardiography recordings. In *2023 31st European Signal Processing Conference (EUSIPCO)*, pages 1190–1194. IEEE, **2023**.
- [8] Hakan Gerçekoğlu. Kalbin yapısı. <https://drhakangercekoglu.com/hastaliklar/kalbin-yapisi>, Note: Accessed: Nisan 2024.
- [9] F Meziani, Sidi Mouhamed Debbal, and A Atbi. Analysis of phonocardiogram signals using wavelet transform. *Journal of Medical Engineering & Technology*, 36(6):283–302, **2012**.
- [10] Uğur Fidan, Naim Karasekreter, and Gülin Ütebay. Real time wireless monitoring of ecg and pcg signals at computer. In *2010 15th National Biomedical Engineering Meeting*, pages 1–4. IEEE, **2010**.
- [11] H Liang, Sakari Lukkarinen, and Iiro Hartimo. Heart sound segmentation algorithm based on heart sound envelopogram. In *Computers in Cardiology 1997*, pages 105–108. IEEE, **1997**.
- [12] Onsy Abdel-Alim, Nadder Hamdy, and MA El-Hanjouri. Heart diseases diagnosis using heart sounds. In *Proceedings of the Nineteenth National Radio Science Conference*, pages 634–640. IEEE, **2002**.

- [13] Cota Navin Gupta, Ramaswamy Palaniappan, Sreeraman Rajan, Sundaram Swaminathan, and SM Krishnan. Segmentation and classification of heart sounds. In *Canadian Conference on Electrical and Computer Engineering, 2005.*, pages 1674–1677. IEEE, **2005**.
- [14] Ilias Maglogiannis, Euripidis Loukis, Elias Zafropoulos, and Antonis Stasis. Support vectors machine-based identification of heart valve diseases using heart sounds. *Computer methods and programs in biomedicine*, 95(1):47–61, **2009**.
- [15] Joyanta Kumar Roy, Tanmay Sinha Roy, and Subhas Chandra Mukhopadhyay. Heart sound: Detection and analytical approach towards diseases. *Modern Sensing Technologies*, pages 103–145, **2019**.
- [16] ekohealth. 3m™ littmann® core digital stethoscope overview and care. https://support.ekohealth.com/hc/en-us/articles/8693611782427-3M-Littmann-CORE-Digital-Stethoscope-Overview-and-UID-06fd65b4-af58-d043-d0d7-c7df1e59ddc1_UID-2ea79305-f877-a71a-5670-6f453a8405fd, Note: Accessed: Augustos 2024.
- [17] Chul Kwak and O-W Kwon. Cardiac disorder classification by heart sound signals using murmur likelihood and hidden markov model state likelihood. *IET signal processing*, 6(4):326–334, **2012**.
- [18] David B Springer, Lionel Tarassenko, and Gari D Clifford. Logistic regression-hsmm-based heart sound segmentation. *IEEE transactions on biomedical engineering*, 63(4):822–832, **2015**.
- [19] Amit Krishna Dwivedi, Syed Anas Imtiaz, and Esther Rodriguez-Villegas. Algorithms for automatic analysis and classification of heart sounds—a systematic review. *IEEE Access*, 7:8316–8345, **2018**.
- [20] Tanachat Nilanon, Jiayu Yao, Junheng Hao, Sanjay Purushotham, and Yan Liu. Normal/abnormal heart sound recordings classification using convolutional

- neural network. In *2016 computing in cardiology conference (CinC)*, pages 585–588. IEEE, **2016**.
- [21] Han Li, Xinpei Wang, Changchun Liu, Qiang Zeng, Yansong Zheng, Xi Chu, Lianke Yao, Jikuo Wang, Yu Jiao, and Chandan Karmakar. A fusion framework based on multi-domain features and deep learning features of phonocardiogram for coronary artery disease detection. *Computers in biology and medicine*, 120:103733, **2020**.
- [22] Kaleem Nawaz Khan, Faiq Ahmad Khan, Anam Abid, Tamer Olmez, Zumray Dokur, Amith Khandakar, Muhammad EH Chowdhury, and Muhammad Salman Khan. Deep learning based classification of unsegmented phonocardiogram spectrograms leveraging transfer learning. *Physiological measurement*, 42(9):095003, **2021**.
- [23] Junxin Chen, Zhihuan Guo, Xu Xu, Li-bo Zhang, Yue Teng, Yongyong Chen, Marcin Woźniak, and Wei Wang. A robust deep learning framework based on spectrograms for heart sound classification. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, **2023**.
- [24] Miguel A Alonso-Arévalo, Alejandro Cruz-Gutiérrez, Roilhi F Ibarra-Hernández, Eloísa García-Canseco, and Roberto Conte-Galván. Robust heart sound segmentation based on spectral change detection and genetic algorithms. *Biomedical Signal Processing and Control*, 63:102208, **2021**.
- [25] Tanzil Hoque Chowdhury, Khem Narayan Poudel, and Yating Hu. Time-frequency analysis, denoising, compression, segmentation, and classification of pcg signals. *Ieee Access*, 8:160882–160890, **2020**.
- [26] MG Manisha Milani, Pg Emeroylariffion Abas, and Liyanage C De Silva. A critical review of heart sound signal segmentation algorithms. *Smart Health*, 24:100283, **2022**.

- [27] Suma Paulose, Dominic Mathew, and Abraham Thomas. Performance evaluation of different modeling methods and classifiers with mfcc and ihc features for speaker recognition. *Procedia computer science*, 115:55–62, **2017**.
- [28] N Shreyas, Venkatraman Manikandan, Srinivasan Malini, and Shanmuganathan Chandrakala. Trends of sound event recognition in audio surveillance: A recent review and study. *The Cognitive Approach in Cloud Computing and Internet of Things Technologies for Surveillance Tracking Systems*, pages 95–106, **2020**.
- [29] Menghui Xiang, Junbin Zang, Juliang Wang, Haoxin Wang, Chenzheng Zhou, Ruiyu Bi, Zhidong Zhang, and Chenyang Xue. Research of heart sound classification using two-dimensional features. *Biomedical Signal Processing and Control*, 79:104190, **2023**.
- [30] Neeraj Baghel, Malay Kishore Dutta, and Radim Burget. Automatic diagnosis of multiple cardiac diseases from pcg signals using convolutional neural network. *Computer Methods and Programs in Biomedicine*, 197:105750, **2020**.
- [31] Stanley Smith Stevens, John Volkman, and Edwin Broomell Newman. A scale for the measurement of the psychological magnitude pitch. *The journal of the acoustical society of america*, 8(3):185–190, **1937**.
- [32] Daniel Jurafsky and James H Martin. *Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition*.
- [33] Hamid Ghorbani. Mahalanobis distance and its application for detecting multivariate outliers. *Facta Universitatis, Series: Mathematics and Informatics*, pages 583–595, **2019**.
- [34] Yingquan Wu, Krassimir Ianakiev, and Venu Govindaraju. Improved k-nearest neighbor classification. *Pattern recognition*, 35(10):2311–2318, **2002**.
- [35] Shichao Zhang. Challenges in knn classification. *IEEE Transactions on Knowledge and Data Engineering*, 34(10):4663–4675, **2021**.

- [36] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Machine learning*, 20:273–297, **1995**.
- [37] Samit Ari, Koushik Hembram, and Goutam Saha. Detection of cardiac abnormality from pcg signal using lms based least square svm classifier. *Expert Systems with Applications*, 37(12):8019–8026, **2010**.
- [38] Hong Tang, Ziyin Dai, Yuanlin Jiang, Ting Li, Chengyu Liu, et al. Pcg classification using multidomain features and svm classifier. *BioMed research international*, 2018, **2018**.
- [39] Alex J Smola and Bernhard Schölkopf. A tutorial on support vector regression. *Statistics and computing*, 14:199–222, **2004**.
- [40] Frank Rosenblatt. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6):386, **1958**.
- [41] David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams. Learning representations by back-propagating errors. *nature*, 323(6088):533–536, **1986**.
- [42] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *nature*, 521(7553):436–444, **2015**.
- [43] Yann LeCun, Bernhard Boser, John S Denker, Donnie Henderson, Richard E Howard, Wayne Hubbard, and Lawrence D Jackel. Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1(4):541–551, **1989**.
- [44] Yann LeCun, Corinna Cortes, and CJ Burges. Mnist handwritten digit database. *ATT Labs [Online]*. Available: <http://yann.lecun.com/exdb/mnist>, 2, **2010**.
- [45] Gülşen Çelebi. Sayısal stetoskop ile elde edilen kalp ses (fonokardiyogram) sinyallerinin bölütlenmesi ve sınıflandırılması. **2017**.
- [46] İbrahim Özkan, Atila Yılmaz, and Gülşen Çelebi. Hybrid segmentation algorithm using mel-frequency cepstrum and wavelet transform for phonocardiography

- records. In *2019 27th Signal Processing and Communications Applications Conference (SIU)*, pages 1–4. IEEE, **2019**.
- [47] Ibrahim Ozkan, Atila Yilmaz, and Gulsen Celebi. Improved segmentation with dynamic threshold adjustment for phonocardiography recordings. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 6681–6684. IEEE, **2019**.
- [48] Brian McFee, Colin Raffel, Dawen Liang, Daniel PW Ellis, Matt McVicar, Eric Battenberg, and Oriol Nieto. librosa: Audio and music signal analysis in python. In *SciPy*, pages 18–24. **2015**.
- [49] Charles R Harris, K Jarrod Millman, Stéfan J Van Der Walt, Ralf Gommers, Pauli Virtanen, David Cournapeau, Eric Wieser, Julian Taylor, Sebastian Berg, Nathaniel J Smith, et al. Array programming with numpy. *Nature*, 585(7825):357–362, **2020**.
- [50] Adam Paszke, Sam Gross, Francisco Massa, Adam Lerer, James Bradbury, Gregory Chanan, Trevor Killeen, Zeming Lin, Natalia Gimelshein, Luca Antiga, et al. Pytorch: An imperative style, high-performance deep learning library. *Advances in neural information processing systems*, 32, **2019**.
- [51] Prihatin Oktivasari, Freddy Haryanto, Riandini Riandini, S Suprijadi, et al. A real-time heart rate signal detection using an electronic stethoscope with labview. *Journal of Biomedical Physics & Engineering*, 10(3):375, **2020**.
- [52] Kunihiro Fukushima. Visual feature extraction by a multilayered network of analog threshold elements. *IEEE Transactions on Systems Science and Cybernetics*, 5(4):322–333, **1969**.
- [53] Min Lin, Qiang Chen, and Shuicheng Yan. Network in network. *arXiv preprint arXiv:1312.4400*, **2013**.

- [54] Geoffrey E Hinton, Nitish Srivastava, Alex Krizhevsky, Ilya Sutskever, and Ruslan R Salakhutdinov. Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*, **2012**.
- [55] Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, **2014**.
- [56] Vincent Dumoulin and Francesco Visin. A guide to convolution arithmetic for deep learning. *arXiv preprint arXiv:1603.07285*, **2016**.

EKLER A:

A.1 HPP ve HP Veri Setinde 1DCNN Model Başarım

Sonuçları

Ön eğitilmiş yaklaşımının kullanılabilmesi için veri setlerinin birleştirilmesi ile oluşturulmuş zscore normalizasyon yöntemi ve rastgele kırpma veri artırma yöntemleri ile HPP, HP veri setlerinde 1DCNN ile alınmış başarımlar Tablo A.01’de verilmiştir.

Deney Sırası	Veri Seti	Doğruluk	Normal-F1 score	Anormal-F1 score
1	HPP	0.87	0.92	0.68
2	HP	0.75	0.84	0.44

Tablo A.01 HPP, HP Veri Setleri için 1DCNN Model ile Normal Anormal Sınıflandırması Başarım Sonuçları

4. Uygulama ve Başarım Sonuçları başlığı altındaki Tablo 4.5’deki sonuçlar ile Tablo A.01’deki sonuçlar karşılaştırıldığında veri setleri birleştirilerek yapılan eğitimin başarımlarını artırmadığı görülmüştür. Her bir veri setinin farklı şartlarda toplanarak oluşturulmuş olması buna bağlı olarak farklı yapılara sahip olması buradaki başarımların düşüklüğünün sebebidir.

A.2 PhysioNet-D Veri Setinde Alınmış Detay Sonuçlar

PhysioNet veri setiyle yapılmış kaynaklardaki diğer çalışmalarla karşılaştırma yapabilmek için PhysioNet veri setinde en iyi çalışan modellerle PhysioNet-D veri setinde test gerçekleştirilmiştir. Bu çalışmada PhysioNet veri seti için en yüksek başarımların sağlandığı model ve yöntemler 4. Uygulama ve Başarım Sonuçları başlığı altındaki Tablo 4.12'deki alınan sonuçlarda verilmiş deneylerdir. Bu yöntem ve modeller seçilip PhysioNet veri seti sadece eğitim ve doğrulama olacak şekilde ikiye bölünmüş eğitimler alınmıştır. PhysioNet-D veri seti test veri seti olarak kullanılacağı için ayrıca test veri seti oluşturulmasına ihtiyaç bulunmamaktadır. Bu sebeple PhysioNet veri seti eğitim ve doğrulama olarak ikiye bölünmüş; bu sayede eğitim yapılan veri sayısının artırılması amaçlanmıştır. Yapılan eğitimler sonucunda PhysioNet-D veri setinde alınmış başarımların sonuçları Tablo A.02'de paylaşılmıştır.

Model	Ön Eğitilmiş/ Eğitilmemiş	Doğruluk		Normal- F1 score		Anormal- F1 score	
		MN*	ZN**	MN*	ZN**	MN*	ZN**
1DCNN	Ön Eğitilmemiş	0.95	0.96	0.95	0.96	0.95	0.96
1DCNN	Ön Eğitilmiş***	0.99	0.97	0.99	0.97	0.99	0.97
2DCNN	Ön Eğitilmemiş	0.94	0.94	0.94	0.94	0.94	0.94
2DCNN	Ön Eğitilmiş****	0.96	0.99	0.96	0.99	0.96	0.99

Tablo A.02 PhysioNet-D Veri Seti için 1DCNN, 2DCNN Modelleri ile Ön Eğitilmiş/Eğitilmemiş Yöntemlerine göre Normal Anormal Sınıflandırmasında Eğitim Başarım Sonuçları

* MN; maksimum normalizasyonu ifade etmektedir.

** ZM; zscore normalizasyonu ifade etmektedir.

*** PhysioNet-D veri seti ile elde edilen 1DCNN ile normal anormal sınıflandırma model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

**** PhysioNet-D veri seti ile elde edilen 2DCNN ile normal anormal sınıflandırma model ağırlıkları kullanılarak yapılmış eğitim sonucudur.

Tablo A.02'deki sonuçlara göre en yüksek başarımlar maksimum normalizasyon kullanılarak Ön Eğitilmiş 1DCNN model ve zscore normalizasyon kullanılarak Ön Eğitilmiş 2DCNN model ile elde edilmiştir. Buna ek olarak Tablo A.02'deki sonuçlar ve 4. Uygulama ve Başarımlar başlığı altında Tablo 4.12'deki sonuçlar değerlendirildiğinde daha çok veri ile eğitilmiş olan Tablo A.02'deki deneylerin daha yüksek başarımlar verdiğini görülmüştür. Bu sonuç derin öğrenme tabanlı modellerin daha iyi öğrenmesi için veri sayısının önemini göstermektedir. 4. Uygulama ve Başarımlar başlığı altında Tablo 4.12'deki Ön Eğitilmiş modellerin ön eğitilmemişlere göre başarımlarını değiştirmezken burada başarımların artmış olmasının daha çok veri ile eğitim yapılmasından dolayı olduğu düşünülmüştür.