

T.C
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

NORMAL VE PATOLOJİK KALP SES KAYITLARININ
ZAMAN-FREKANS TABANLI OTOMATİK SINIFLANDIRILMASI

Hasan ZAN

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DIYARBAKIR

Aralık-2018

T.C
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ
DİYARBAKIR

Hasan Zan tarafından yapılan “Normal ve Patolojik Kalp Ses Kayıtlarının Zaman-Frekans Tabanlı Otomatik Sınıflandırılması” konulu bu çalışma, jürimiz tarafından Elektrik–Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Mehmet Sıraç ÖZERDEM

Üye (Danışman) : Dr. Öğr. Üyesi Abdulnasır YILDIZ

Üye : Doç. Dr. Ömer Faruk ERTUĞRUL

Tez Savunma Sınavı Tarihi: 05/12/2018

Yukarıdaki bilgilerin doğruluğunu onaylarım.

..../..../2018

Prof. Dr. Sevtap SÜMER EKER

ENSTİTÜ MÜDÜR V.

TEŞEKKÜR

Bu tez çalışması süresince her anlamda yardımını, bilimsel katkılarını ve tecrübelerini hiçbir zaman esirgemeyen değerli hocam Dr. Öğr. Üyesi Abdulnasır Yıldız'a teşekkür ederim.

Bu tez çalışması, Dicle Üniversitesi Bilimsel Araştırma Projeleri (DÜBAP) Koordinatörlüğü tarafından 17.019 proje numarası ile desteklenmiştir.



İÇİNDEKİLER

	Sayfa
TEŞEKKÜR	I
İÇİNDEKİLER	II
ÖZET	V
ABSTRACT	VI
ÇİZELGE LİSTESİ	VII
ŞEKİL LİSTESİ	VIII
KISALTMALAR VE SİMGELER	IX
1. GİRİŞ.....	1
1.1. Genel Bilgi.....	1
1.2. Fonokardiogram	1
1.3. Örüntü Tanıma Yöntemleri	3
1.4. Tezin Amacı	4
1.5. Tezin Yapısı.....	5
2. KAYNAK ÖZETLERİ	7
3. MATERYAL VE METOT	13
3.1. Filtreleme ve Gürültüden Arındırma	13
3.2. Normalizasyon.....	13
3.3. Segmentasyon.....	14
3.3.1. Springer'in Segmentasyon Yöntemi.....	14
3.4. İstatistiksel Özellikler	17
3.5. Fourier Dönüşümü.....	19
3.5.1. Ayrık Fourier Dönüşümü	20
3.6. Dalgacık Dönüşümü	21
3.6.1. Sürekli Dalgacık Dönüşümü.....	22
3.6.2. Ayrık Dalgacık Dönüşümü	23
3.6.3. Hızlı Dalgacık Dönüşümü	23

3.7.	Mel Frekansı Kepstrum Katsayıları (MFCC).....	25
3.8.	Ardışık Geri Yönde Özellik Seçme Algoritması.....	28
3.9.	Sınıflandırıcı Metotları Topluluğu.....	28
3.9.1.	Karar Ağacı	29
3.9.2.	Boosting Algoritma Ailesi.....	32
3.9.3.	Bagging Algoritması	35
3.10.	Bayesian Optimizasyonu	36
3.11.	Kullanılan Veriler	36
3.11.1.	MIT Kalp Sesi Veri Seti	37
3.11.2.	Aalborg Üniversitesi Kalp Sesi Veri Seti	38
3.11.3.	Aristotle Üniversitesi Kalp Sesi Veri Seti	38
3.11.4.	Toosı Teknoloji Üniversitesi Kalp Sesi Veri Seti.....	39
3.11.5.	Haute Alsace Üniversitesi Kalp Sesi Veri Seti.....	39
3.11.6.	Dalian Teknoloji Üniversitesi Kalp Sesi Veri Seti	39
3.11.7.	Şiraz Üniversitesi Kalp Sesi Veri Seti.....	40
3.11.8.	Skejby Sygehus Hastanesi Kalp Sesi Veri Seti	40
3.11.9.	Yarışma Verilerinin Oluşturulması	40
3.11.10.	Çalışma Verilerinin Oluşturulması	40
3.12.	Algoritmanın Yapısı	42
3.12.1.	Önişlem	43
3.12.2.	Özellik Çıkarma-1	44
3.12.3.	Veri Seti Sınıflandırması	48
3.12.4.	Segmentasyon.....	48
3.12.5.	Özellik Çıkarma-2	48
3.12.6.	Özellik Seçme.....	53
3.12.7.	Nihai Sınıflandırma	53
4.	BULGULAR VE TARTIŞMA	59
4.1.	Teşhis Destek Doğruluğunu Ölçmede Kullanılan Parametreler.....	59

4.2.	Yarıřmada Kullanılan Parametreler.....	61
4.3.	Performans Sonuları	62
4.4.	Performans Sonularının Karřılařtırılması	66
5.	SONU VE NERİLER	67
6.	KAYNAKLAR.....	69
	ZGEMİř	75



ÖZET

NORMAL VE PATOLOJİK KALP SES KAYITLARININ ZAMAN-FREKANS TEMELLİ OTOMATİK SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Hasan ZAN

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

2018

Kardiyovasküler bozukluklar veya kalp hastalıkları dünyada artan ölümlerin ana sebeplerinden bir tanesidir. Kalp hastalıklarının erken, ucuz ve kolay bir şekilde teşhis edilmesi insanların yaşam süresini arttırmada yardımcı olabilmek potansiyeline sahiptir. Son 50 yıldır elektronik stetoskop ile kaydedilebilen, fonokardiyogram (PCG) olarak adlandırılan ve kalbin mekanik davranışı hakkında önemli bilgiler taşıyan kalp sesi işaretlerinden kişinin kalp hastası olup olmadığının tespitine yönelik çok sayıda teşhis destek algoritması geliştirilmiştir. Ancak geliştirilen bu algoritmaların başarımı genelde belirli bir lokasyondan alınan, gürültüsüz ve az sayıda kalp sesi kaydı içeren veri setleri üzerinden test edilmiştir. Bu da farklı lokasyonlardan alınan, gürültülü ve çok fazla sayıda kayıt içeren bir veri seti üzerinden başarımı test edilmiş yüksek performanslı algoritmaların geliştirilmesi gerektiğini gösterir. Bu tez çalışmasında PCG kayıtlarından kişiyi kalp hastası olup olmadığını tespit eden işaret işleme ve makine öğrenmesi temelli bir örüntü sınıflandırma algoritması geliştirilmeye çalışılmıştır. Geliştirilen algoritmanın başarımlı performansı 3240 kalp sesi kaydından oluşan bir veri bankası üzerinden test edilmiştir.

Bu çalışmada PCG kayıtlarından kalp hastalıklarının teşhis desteğine yönelik önerilen algoritma, ön işleme, özellik çıkarma-1, veri seti sınıflandırması, segmentasyon, özellik çıkarma-2, özellik seçme ve nihai sınıflandırma olmak üzere yedi temel aşamadan oluşmaktadır. Ön işleme aşamasında PCG kayıtlarındaki sivrili uçlar yok edilerek normalizasyon yapılmıştır. Sonraki aşamada kayıtların veri setine göre sınıflandırmaya yarayan sınıflandırıcının eğitilmesinde ve test edilmesinde kullanılan özellikler çıkarılmıştır. Kayıtlar alındıkları veri setine göre sınıflandırılırken karar ağaçları ve AdaBoostM2 algoritması ile oluşturulan sınıflandırıcı metotları topluluğu kullanılmıştır. Böylece, farklı veri setlerine ait veriler için farklı özellik ve sınıflandırıcı kullanılması sağlanmıştır. Algoritmanın segmentasyon aşamasında Springer'in segmentasyon algoritması kullanılarak kayıtlar temel kalp seslerine ayrılmıştır. Özellik çıkarma-2 aşamasında segmentasyonu yapılmış ve yapılmamış işaretlerin zaman, frekans ve zaman-frekans özellikleri çıkarılmıştır. Çıkarılan özellikler özellik seçme aşamasında azaltılmış ve algoritmanın son adımında yer alan sınıflandırıcıların eğitilmesinde ve test edilmesinde kullanılmıştır. Her bir kayıt için iki farklı sınıflandırıcı kullanıldığından kaydın normal veya anormal olduğuna yönelik son karar verilirken beş farklı kural kullanılarak en iyi sonucu veren kural bulunmuştur.

En iyi sonucu veren kural bulunduğundan sonra bu kural ile başarımlı performansı doğruluk, duyarlılık ve özgüllük açısından sırasıyla %95.21, %87.22 ve %97.28 olarak elde edilmiştir. Elde edilen bu değerlere göre önerilen algoritmanın performansı literatürdeki benzer çalışmalar ile kıyaslanmış ve önerilen algoritma başarılı bulunmuştur.

Anahtar Kelimeler: PCG, Kalp sesi, Fonokardiyogram, Fourier analizi, Dalgacık dönüşümü, MFCC, Sınıflandırıcı metotları topluluğu, Sınıflandırma

ABSTRACT

TIME-FREQUENCY BASED AUTOMATIC CLASSIFICATION OF NORMAL AND PATHOLOGIC HEART SAOUND RECORDINGS

MsC THESIS

Hasan ZAN

DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
INSTITUTE OF NATURAL AND APPLIED SCIENCES
UNIVERSITY OF DICLE

2018

Cardiovascular disorders or heart diseases that identify general status of heart are main reason of increasing death in the world. Easy, cheap and early diagnosis of heart diseases has potential to help to improve life expectancy of people. For 50 years, many experts have tried to develop diagnostic algorithms that can diagnose heart diseases by using heart sounds. Heart sounds recordings that are called as phonocardiogram (PCG) are recorded by an electronic stethoscope and have important information about mechanical activity of heart. However, algorithm developed so far are tested on data sets that contain few clean recordings obtained from only one body location. Therefore, it is necessary to develop a heart disease diagnostic algorithm with high performance and to test on a data set which contains both clean and noisy recordings obtained from different body locations. In this thesis, it is tried to develop a machine learning and signal processing based pattern recognition algorithm that can diagnose heart diseases of people. Developed algorithm is tested on a database that contains 3240 PCG recordings.

In this work, an algorithm is proposed for heart disease diagnosis. Proposed algorithm consists of seven main phases which are preprocessing, feature extraction-1, data set classification, segmentation, feature extraction-2, feature selection and final classification. In preprocessing phase, PCG recordings were denoised from spikes and normalized. In next phase, features that are used to train and test classifier segregating recordings with respect to data sets which they are collected from are extracted. Classifier ensembles which created with AdaBoostM2 and decision trees are used to categorize recordings according to their data sets. Thus, it is enabled to use different features and classifiers for data from different databases. In segmentation phase of algorithm, Springer's segmentation algorithm is used to divide PCGs into fundamental heart sounds. Various time, frequency and time-frequency features are extracted from segmented and non-segmented signals so two feature vectors are created per signal in feature extraction-2 phase. After number of features is reduced by feature selection algorithm, extracted features are handled for training and test of classifiers in the last phase of algorithm. Since there are two classifiers per signal, five different voting rules are used for final classification in order to find rule achieving best performance results.

After best rule is determined, best results (sensitivity: %87.22, specificity: %97.28 and accuracy: %95.21) are achieved when this rule is used for voting. Then, the proposed algorithm is compared with similar works with respect to performance results and proposed algorithm appears to be successful.

Keywords: PCG, Heart sound, Phonocardiogram, Fourier analysis, Wavelet transform, MFCC, Ensemble classifier, Classification

ÇİZELGE LİSTESİ

<u>Çizelge No</u>		<u>Sayfa</u>
Çizelge 1.1.	Kalp sesi bileşenleri ve özellikleri (Nabih-Ali ve ark. 2017)	2
Çizelge 2.1.	Kaynak özetleri	11
Çizelge 3.1.	ID3 algoritması	31
Çizelge 3.2.	AdaBoost algoritması	33
Çizelge 3.3.	Logit Boost algoritması	34
Çizelge 3.4.	Gentle AdaBoost algoritması	34
Çizelge 3.5.	Bagging algoritması	36
Çizelge 3.6.	Veri setleri ve özellikleri	37
Çizelge 3.7.	Yarışma verileri	41
Çizelge 3.8.	Çapraz doğrulama için çalışma eğitim veri seti ve test veri seti	41
Çizelge 3.9.	PCG kayıtlarının frekans ve zaman-frekans uzayına ait özellikleri	46
Çizelge 3.10.	Veri seti sınıflandırıcısına ait detaylar	48
Çizelge 3.11.	Veri setlerine göre seçilen özellik sayısı	53
Çizelge 3.12.	Çapraz doğrulamanın her adımında kullanılan veri ve özellik sayısı	55
Çizelge 3.13.	Nihai sınıflandırmada kullanılan sınıflandırıcılara ait detaylar	56
Çizelge 4.1.	Tanı testi sonuçlarının çizelge olarak gösterimi	59
Çizelge 4.2.	ROC eğrisinin altında kalan alan ile performans arasındaki ilişki	61
Çizelge 4.3.	Yarışmada kullanılan tanı testi sonuçlarının çizelge olarak gösterimi	61
Çizelge 4.4.	Veri seti sınıflandırmasına ilişkin karışıklık matrisi	62
Çizelge 4.5.	Nihai sınıflandırmada yer alan beş farklı kural	63
Çizelge 4.6.	Özellik seçme öncesi beş farklı kurala göre tanı testi sonuçları	64
Çizelge 4.7.	Özellik seçme sonrası beş farklı kurala göre tanı testi sonuçları	65
Çizelge 4.8.	Farklı çalışmaların performans sonuçları (değerler yüzde olarak verilmiştir)	66

ŞEKİL LİSTESİ

<u>Sekil No</u>		<u>Sayfa</u>
Şekil 1.1.	Tipik bir PCG kaydı (Varghees ve Ramachandran 2014)	2
Şekil 1.2.	Kalbin kasılması ve genişlemesi (Naigaonkar 2015)	3
Şekil 1.3.	Tipik bir PCG sınıflandırma algoritması	4
Şekil 3.1.	Eşzamanlı EKG ve PCG işaretleri (Springer ve ark. 2016)	15
Şekil 3.2.	Springer'in segmentasyon yönteminin blok diyagramı	16
Şekil 3.3.	Örnek dalgacık şekilleri	22
Şekil 3.4.	Üçüncü seviye hızlı dalgacık dönüşümü	24
Şekil 3.5.	MFCC algoritmasının blok diyagramı	25
Şekil 3.6.	Örnek bir mel filtre bankası	27
Şekil 3.7.	Özellik seçme algoritmasının blok diyagramı	27
Şekil 3.8.	Kök, düğüm, dal ve yaprak içeren bir karar ağacı	30
Şekil 3.9.	Boosting algoritmalarının genel yapısı	32
Şekil 3.10.	Bagging algoritmasının genel yapısı	35
Şekil 3.11.	Önerilen algoritmanın blok diyagramı	42
Şekil 3.12.	Önerilen algoritmanın önışlem aşamasının blok diyagramı	43
Şekil 3.13.	Sivri uçlu ve sivri ucu yok edilmiş iki PCG kaydı	44
Şekil 3.14.	İki farklı veri setine ait PCG kaydının 0-200 Hz aralığındaki güç spektrumu	45
Şekil 3.15.	İki farklı veri setine ait PCG kaydının 0.8-1 kHz aralığındaki güç spektrumu	46
Şekil 3.16.	Veri seti a'ya ait PCG kaydı ve bu kayda ait MFCC	47
Şekil 3.17.	Veri seti e'ye ait PCG kaydı ve bu kayda ait MFCC	47
Şekil 3.18.	Springer'in algoritmasıyla segmentasyonu yapılmış bir PCG işareti	49
Şekil 3.19.	Sınıflandırıcı-a'nın eğitilmesi ve optimize edilmesi	54
Şekil 3.20.	Sınıflandırıcı-e'nin eğitilmesi, optimize ve test edilmesi	55
Şekil 4.1.	Beş farklı kural için ROC eğrileri	65

KISALTMALAR VE SİMGELER

AADHSDB	: Aalborg Üniversitesi kalp sesi veri seti
ADD	: Ayrık dalgacık dönüşümü
AS	: Aortik stenosis
AUTHSDB	: Aristotle Üniversitesi kalp sesi veri seti
DLUTHSDB	: Dalian Teknoloji Üniversitesi kalp sesi veri seti
DN	: Doğru negatif
doğruluk _d	: Değiştirilmiş doğruluk
DP	: Doğru pozitif
duyarlılık _d	: Değiştirilmiş duyarlılık
EKG	: Elektrokardiyogram
GAL	: Gelişme ve öğrenme (grow and learn)
Hz	: Hertz
ISOM	: Kendiliğinden artarak organize olan harita
kNN	: K en yakın yakın komşuluk
KSFD	: Kısa süreli Fourier dönüşümü
LPC	: Linear predictive coefficient
MFCC	: Mel frequency cepstral coefficients
MFCC	: Mel frekansı cepstrum katsayıları
MIT	: Massachusetts Teknoloji Enstitüsü
MITHSDB	: Massachusetts Teknoloji Enstitüsü kalp sesi veri seti
MMG	: Maksimum mutlak genlik
MR	: Manyetik rezonans
MR	: Mitral yetersizlik
ms	: Milisaniye
özgüllük _d	: Değiştirilmiş özgüllük

PCG	: Fonokardiyogram
s	: Saniye
SDD	: Sürekli dalgacık dönüşümü
SOM	: Kendiliğinden organize olan harita (self-organizing map)
SSHSDB	: Skejby Sygehus Hastanesi kalp sesi veri seti
SUAHSDB	: Şiraz Üniversitesi kalp sesi veri seti
TUTHSDB	: Toosi Teknoloji Üniversitesi kalp sesi veri seti
WHO	: Dünya sağlık örgütü
YN	: Yanlış negatif
YP	: Yanlış pozitif
zcr	: Sıfırdan geçme oranı
Ω	: Ohm
$\Psi_{s,\tau}$	: Dalgacık dönüşümünün ana dalgacığı
R	: Reel sayılar kümesi
cA	: Ayrık dalgacık dönüşümü yaklaşım katsayıları
cD	: Ayrık dalgacık dönüşümü detay katsayıları
s	: Dalgacık dönüşümünde ölçek
μ	: Aritmetik ortalama
σ	: Standart sapma
τ	: Dalgacık dönüşümünde öteleme

1. GİRİŞ

1.1. Genel Bilgi

Kardiyovasküler bozukluklar veya kalp hastalıkları bir insanın kalp durumu hakkında bilgi veren genel bir terimdir. Kalp hastalıkları, dünyada artan ölümlerin ana kaynaklarından bir tanesidir. Her yıl Türkiye’de kalp hastalıkları yüzünden ölen insan sayısı diğer sebeplerden dolayı ölen insan sayısından daha fazladır. 2014 yılında ölen insan sayısının %25.61’lik kısmı kalp hastalıklarından dolayı öldüğü bildirilmiştir (WHO 2018).


Kalp hastalıklarını tespit etmek amacıyla elektrokardiyogram (EKG), bilgisayarlı tomografi, efor testi ve manyetik rezonans (MR) gibi gelişmiş yöntemlerin yanı sıra kalp sesinin stetoskop yardımıyla hekimler tarafından dinlenerek kalp sesindeki bozuklukların tespiti gibi basit yöntemler de kullanılmaktadır. Ayrıca son yıllarda kalp sesi kayıtlarını kullanarak işareti işleme teknikleri ve makine öğrenmesi yardımıyla kişilerin kalp hastalıklarına sahip olup olmadığını tespit eden örüntü tanıma yöntemleri geliştirilmeye çalışılmaktadır (Maglogiannis 2009).

1.2. Fonokardiogram

Elektronik stetoskop ile kaydedilip dijital işarete dönüştürülen kalp sesine fonokardiogram (PCG) denir (Zhongwei ve Samjin 2006). Bu işaretler kompleks, durağan olmayan işaretlerdir. Vücudun mekanik aktiviteleri sonucu meydana gelmekte olan bu işaretler kalp hastalıklarını tespit etmede önemli bilgiler içermektedir (Lekram ve Abhishek 2014).

PCG kayıtları dört kalp sesi bileşeninden (S1, S2, S3 ve S4) meydana gelmektedir. Temel kalp sesleri olarak da adlandırılan birinci ve ikinci kalp sesleri (S1 ve S2) herhangi bir hastalığa sahip olmayan her kalpten duyulmakta bu sesler kalpteki kapakçıkların kapanıp açılması sonucu oluşmaktadır. S1’in başlangıcı ile S2’nin başlangıcı arasında kalan bölge sistol (kalbin kasılması) olarak adlandırılmaktadır. S2’nin başlangıcı ve diğer döngüdeki S1’in başlangıcı arasında kalan bölge ise diyastol (kalbin gevşemesi) olarak adlandırılmaktadır. Hastalıklı bir kalbe ait PCG kayıtlarında üçüncü ve dördüncü (S3 ve S4) kalp sesleri de duyulabilir (Johnston 2007). Şekil 1.1. ve

Çizelge 1.1.'de tüm kalp seslerine sahip bir PCG kaydı ve bu kalp seslerinin özellikleri gösterilmektedir.



Şekil 1.1. Tipik bir PCG kaydı (Varghees ve Ramachandran 2014)


Çizelge 1.1. Kalp sesi bileşenleri ve özellikleri (Nabih-Ali ve ark. 2017)

Ses	S1	S2	S3	S4
Frekans	30 – 100 Hz	100 Hz'den fazla	20 – 25 Hz	30 Hz'den az
Zaman	50 – 100 ms	25 – 50 ms	120 – 150 ms	S1'den 90 ms önce
Oluşum	Mitral ve triküspit kapakçıkların kapanması	Aortik ve akciğer kapakçıkların kapanması	Erken diastolda karıncığın hızlı dolumu	Karıncığın kulakçığın kasılmasından dolayı dolumu

Şekil 1.2.'de verilen ve gevşeme ile kasılmadan oluşan kalp atımı sırasında duyulan olağan dışı seslere üfürüm denir. Üfürümler en yaygın görülen kalp anormalliklerinden biridir. Üfürümler ile kalp sesleri arasındaki temel fark üfürümlerin gürültülü ve daha uzun olmasıdır. Sistol aralığında meydana gelen üfürümler, sistolik üfürüm; diyastol aralığında meydana gelen üfürümler diyastolik üfürüm olarak sınıflandırılır (Nigam ve Priemer 2007).

En yaygın görülen kalp hastalığı kalp kapakçığı hastalığıdır. Kapakçıklar her iki karıncığın sonunda yer alan kapaklardır ve normalde kanın karıncıkta tek yönlü akmasını sağlar. Kapakçıkların tam açılmaması sonucu kan akışının kısmen engellenmesi (AS) ve kapakçıkların tam kapanmaması sonucu kanın sızması (MR)

şeklinde iki temel kapakçık problemine rastlanmaktadır. Bu problemler çeşitli üfürümlere neden olur (Nabih-Ali ve ark. 2017).




Şekil 1.2. Kalbin kasılması ve genişlemesi (Naigaonkar 2015)

1.3. Örüntü Tanıma Yöntemleri

Örüntü tanıma yöntemleri bireyin sağlıklı veya hasta olduğunun teşhis edilmesine yardımcı olabilmektedir. PCG kayıtlarından elde edilebilen oldukça önemli bilgiler bu kayıtlara uygulanabilecek örüntü tanıma yöntemlerine uygun olan işaret işleme teknikleri ile faydalı hale getirilebilir. Her PCG kaydı ile ilgili oldukça fazla miktardaki bilginin manuel olarak derlenip hastalığın tahmin edilmesi zor olduğundan örüntü tanıma yöntemlerinin gerekliliği ortaya çıkmaktadır (Nabih-Ali ve ark. 2017). Şekil 1.3.'te PCG kayıtlarının otomatik sınıflandırılmasında kullanılan genel bir örüntü tanıma yönteminin yapısı görülmektedir.

Örüntü tanıma yönteminin ilk aşaması olan önışlem aşamasında genellikle işaretler önce filtreden geçirilerek gürültüden arındırılır ve ardından filtrelenmiş işaretler uygun bir normalizasyon yöntemi yardımıyla normalize edilerek kişiye özgü özelliklerden arındırılmaya çalışılır. Her zaman olmazsa da bazen işaret alt kalp seslerine ayrılır yani işarete segmentasyon uygulanır. Yöntemin üçüncü aşaması olan özellik çıkarım aşamasında ise işarete uygun özellik çıkarım yöntemleri uygulanarak

işaretin zaman, frekans ve zaman-frekans uzayına ait çeşitli istatistiksel özellikleri çıkarılır. Bu aşama sonucunda işaretin boyutu küçültülerek, işaret çok daha düşük boyutlu bir özellik vektörü ile temsil edilmiş olur. Yöntemin son aşaması olan sınıflandırma aşamasında ise işaretler, çıkarılmış olan özellik vektörleri üzerinden yapay sinir ağları, destek vektör makinesi, k en yakın komşuluk (kNN), karar ağaçları ve Adaboost gibi sınıflandırıcılar kullanılarak sınıflandırılır.



Şekil 1.3. Tipik bir PCG sınıflandırma algoritması

1.4. Tezin Amacı

Kardiyovasküler hastalıkların dünya genelindeki yaygınlığı ve bu hastalıklar nedeniyle her yıl milyonlarca kişinin öldüğü bilinen bir gerçektir (WHO 2018). Kardiyovasküler hastalığın tedavisi için erken tanı büyük önem taşımaktadır. Ancak,

uzman hekim başına düşen hasta sayısı yoğunluğundan dolayı hastaların uzman hekime ulaşma imkânı kısıtlıdır (Fattah 2017). Bu sebeple hastalığın erken tanısı ve tedavisi gecikmektedir. Dolayısıyla geliştirilecek bir teşhis destek sistemi ile belirtilen probleme bir çözüm bulunabilir.

Son zamanlarda, elektronik stetoskop ile kaydedilebilen, PCG olarak adlandırılan ve kalbin mekanik davranışı hakkında önemli bilgiler taşıyan kalp sesi işaretlerinden kişinin kalp hastası olup olmadığını tespitine yönelik çok sayıda teşhis destek algoritması geliştirilmiştir. Ancak geliştirilen bu algoritmaların başarımı genelde belirli bir lokasyondan alınan, gürültüsüz ve az sayıda kalp sesi kaydı içeren veri setleri üzerinden test edilmiştir. Literatürde farklı lokasyonlardan alınan, gürültülü ve çok sayıda kayıt içeren bir veri seti üzerinden başarımı test edilmiş çalışmalara pek rastlanmamaktadır.

Yukarda belirtilenler göz önüne alındığında, bu tez çalışmasında güdülen temel amaç; farklı lokasyonlu ve gürültülü kayıtların da içerisinde yer aldığı büyük bir PCG kaydı veri seti üzerinden kişiyi kalp hastası olup olmadığını tespit eden, işaret işleme ve makine öğrenmesi algoritmalarına dayalı doğruluğu yüksek bir örüntü tanıma yaklaşımı geliştirmektir.

Kalbin stetoskop yardımıyla dinlenerek hekimler tarafından analiz edilmesi insanın duyma duyusundaki sınırlamalar ile duymanın ve duyulmanın yorumlanmasının öznel olması gibi sebeplerden dolayı hala başarılı ve yeterli bir yöntem olarak görülmemektedir (Avendaño-Valencia ve ark. 2007). Bu nedenle tezin diğer bir amacı da doğruluğu yüksek bir teşhis destek algoritması geliştirerek kalp hastalıkları teşhisinde hekimlere yardımcı ikinci bir görüş sağlamaktır.

1.5. Tezin Yapısı

Bu tez; giriş, kaynak özetleri, materyal ve metot, bulgular ve tartışma, sonuç ve öneriler ile kaynaklar bölümlerinden oluşmaktadır. Giriş bölümünde, PCG kayıtları, kalp sesleri, üfürümler ve kalp hakkında genel bilgilerle beraber tezin amacına yer verilmiştir. PCG kayıtlarının sınıflandırılmasıyla ilgili olarak yapılan önceki çalışmalar kaynak özetleri bölümünde verilmiştir. Materyal ve metot bölümünde, çalışmada kullanılan PCG kayıtları ve bu kayıtların veri setleri hakkında bilgi verilmiş, önerilen algoritma detaylı şekilde açıklanmış ve son olarak algoritmanın Matlab programlama

dili ili gerçeklenmesine yer verilmiştir. Oluşturulan ve eğitilen algoritmanın test verileri ile test edilmesi ile elde edilen performans sonuçları bulgular ve tartışma bölümünde yer almaktadır. Sonuç ve öneriler bölümünde ise çalışmada ulaşılan sonuç ve öneriler yer almaktadır. Son bölüm olan kaynaklar bölümünde tez içinde atıf yapılan kaynaklara yer verilmiştir.



2. KAYNAK ÖZETLERİ

PCG kayıtlarını otomatik olarak sınıflandırma çalışmaları yaklaşık 50 yıldır pek çok araştırmacının ilgisini çekmiştir. Bazıları Çizelge 2.1.'de özet şeklinde verilmiş olan literatür çalışmaları incelendiğinde bu çalışmalarda farklı veri setleri kullanıldığı görülmektedir. Bu veri setleri, genellikle az sayıda, gürültüsüz PCG kayıtları içerdiğinden çalışmalarda kullanılan yöntemlerin başarıları yüksek olmuştur.

Literatürdeki çalışmalar önışlem ve segmentasyon açısından incelendiğinde çalışmaların önışlem aşamasında filtreleme ve dalgacık dönüşümü gibi yöntemler kullanılırken, segmentasyon için makine öğrenmesi, deneysel ayrıştırma, eşleştirme arayışı (matching pursuit) ve otokorelasyon gibi yöntemlerin kullanıldığı görülmektedir (Nabih-Ali, ve ark. 2017). Bu çalışmalardan bazıları aşağıda verilmiştir.

Liang ve ark. (1997) tarafından yapılan çalışmada kesim frekansı 882 Hz olan Chebyshev tip-1 filtresi kullanılarak kalp sesleri gürültüden arındırılmıştır. Ortalama Shanon enerji kullanılarak kalp sesleri S1, sistol, S2 ve diyastol olmak üzere dört bölgeye ayrılmıştır.

Gupta ve ark. (2006) kesim frekansı 750 Hz olan Chebyshev tip-1 filtresini kullanarak kalp seslerini gürültüden arındırmış ve homomorfik filtreleme ile K-means yığınlamayı kullanarak segmentasyon yapmıştır.

Wang ve ark. (2006) tarafından yapılan çalışmada dalgacık dönüşümü ile işaret gürültüden ayrılmıştır. Dalgacık dönüşümü temelli alt seviyeleri takip eden bir yöntem kullanılarak S1 ve S2 üfürümlerden ayrılmıştır.

Dokur ve Ölmez (2008) tarafından yapılan çalışmada üçüncü, dördüncü ve beşinci seviye dalgacık dönüşümü ile işaret gürültüden arındırılmıştır. Ardından tepe tespit edici (peak detector) kullanılarak S1 ve S2'nin zamanlamaları tespit edilmiştir.

Debbal ve ark. (2008) işareti alçak geçiren filtreden geçirerek gürültüden arındırmış, daha sonra kalp seslerini ve üfürümleri birbirinden ayırmak için normalleştirilmiş ortalama Shanon enerjiyi kullanmıştır.

Quiceno ve ark. (2008) Coifman 4 dalgacığı ile sekizinci seviye dalgacık dönüşümünü kullanarak PCG kayıtlarını gürültüden arındırmış ve EKG'den yararlanarak S1 ile S2'nin konumunu tespit etmiştir.

Hedayioglu ve ark. (2009) işareti gürültüden arındırmak için dalgacık dönümü kullanmış ve tepe tespit yöntemiyle segmentasyon yapmıştır.

Kouras ve ark. (2012) Db10 dalgacığı ile dalgacık dönüşümünü kullanarak işareti gürültüden arındırmış, daha sonra normalleştirilmiş Shanon entropi ve eşikleme kullanarak S1 ve S2'yi üfürümlerden ayırmıştır.

Moukadem ve ark. (2013) tarafından yapılan çalışmada PCG kayıtları kesim frekansı 30 Hz olan yüksek geçiren filtreden geçirilerek gürültüden arındırılmıştır. Ardından S-dönüşümü kullanılarak kalp sesleri S1, sistol, S2 ve diyastol olmak üzere dört bölgeye ayrılmıştır.

Guillermo ve ark. (2014) tarafından yapılan çalışmada işaret 4 kHz kesim frekansına sahip alçak geçiren filtre kullanılarak işaret gürültüden arındırılmıştır. Daha sonra sürekli dalgacık dönüşümü ve eşikleme kullanılarak S1 ve S2 tespit edilmiştir.

Boutana ve ark. (2014) tarafından yapılan çalışmada işaretlere önilem uygulanmadan deneysel yöntemlerle S1, S2 ve üfürümler bulunarak segmentasyon yapılmıştır.

Pedrosa ve ark. (2014) morlet ana dalgacığı ile sürekli dalgacık dönüşümünü kullanarak işareti gürültüden arındırmış ve işaretin periyodik bileşenlerini bulmak için otokorelasyon fonksiyonunu kullanmıştır.

Kang ve ark. (2015) tarafından yapılan çalışmada kesim frekansları 40-500 Hz olan bant geçiren filtre kullanılarak işaret gürültüden arındırılmıştır. Ortalama Shanon enerji kullanılarak kalp sesleri S1, sistol, S2 ve diyastol olmak üzere dört bölgeye ayrılmıştır.

Deng ve Ji-Qing (2016) tarafından yapılan çalışmada PCG kayıtların gürültüden arındırılması amacıyla bant geçiren, sıfır faz ve Butterworth filtreleri (25-900 Hz) kullanılmıştır. Bu çalışmada segmentasyon yapılmadan sınıflandırma yapılmıştır.

Schmidt ve ark. taraafından yapılan çalışmada ise saklı Markov modeli kullanılarak kalp sesi kayıtları S1, sistol, S2 ve diastol olmak üzere dört bölgeye ayrılmıştır.

Potes ve ark. (2016) tarafından yapılan çalışmada PCG kayıtları kesim frekansı 25-400 Hz olan bant geçiren filtreden geçirildikten sonra Bölüm 3.12.1.'de açıklanan

yöntemle kayıtlardaki sivri uçlar yok edilmiştir. Ardından kayıtlar Springer ve ark. (2016) tarafından geliştirilmiş olan ve literatürdeki en iyi segmentasyon yöntemi olarak nitelendirilen yöntemle S1, S2, sistol ve diyastol olmak üzere dört bölgeye ayrılmıştır.

Literatürdeki çalışmalar özellik çıkarma ve sınıflandırma açısından incelendiğinde özellik çıkarma aşamasında lineer frekans kepstrum katsayıları (LFCC), mel frekansı kepstrum katsayıları (MFCC), ayrık kosinüs dönüşümü (DCT), Fourier dönüşümü, ayrık Fourier dönüşümü (AFD), kısa süreli Fourier dönüşümü (KSFD), Choi-Williams dağılımı, dalgacık dönüşümü, ayrık dalgacık dönüşümü (ADD) gibi yöntemler kullanılırken, sınıflandırma aşamasında ise yapay sinir ağları (YSA), destek vektör makinesi (DVM), k en yakın komşuluk (kNN), sınıflandırıcı metotları topluluğu ve derin öğrenme algoritmalarının kullanıldığı görülmektedir (Nabih-Ali ve ark. 2017). Yapılan bazı çalışmalar aşağıda verilmiştir.

Reed ve ark. (2004) yaptıkları çalışmada beş adet normal ve anormal PCG kaydına Coifman dalgacığını kullanarak yedinci seviye dalgacık dönüşümü uygulamış, elde edilen özellik vektörünün boyutlarını azaltmak için en küçük ölçeğe sahip dört seviye atılmış, son olarak YSA kullanılarak PCG kayıtlarını sınıflandırmışlardır.

Gupta ve ark. (2006) tarafından yapılan çalışmada 41 adet PCG kaydı kullanılmıştır. Özellik çıkarma için Daubechies dalgacığı ile dalgacık dönüşümünü, sınıflandırma için gelişme ve öğrenme ağının (GAL) yanı sıra YSA kullanılmıştır.

Dokur ve Ölmez (2008) tarafından yapılan çalışmada 14 adet PCG kaydının özelliklerini çıkarmak için ayrık dalgacık dönüşümü, sınıflandırmak için Kohen'in kendiliğinden artarak organize olan haritası ve artan YSA kullanılmıştır.

Jaramillo-Garzon ve ark. (2008) tarafından yapılan çalışmada 16 normal PCG kaydı 6 adet üfürüm içeren PCG kaydı kullanılmıştır. Bu kayıtlar ayrıştırılmadan kısa süreli Fourier dönüşümü ve Choi-Williams dağılımı kullanılarak zaman-frekans uzayına dönüştürülmüş, aşağı örnekleme kullanılarak özellik matrisinin boyutları azaltılmış ve kNN kullanılarak sınıflandırma yapılmıştır.

Das ve ark. (2009) ile Ari ve Saha (2009) tarafından yapılan çalışmalarda PCG kayıtlarının özellikleri dalgacık dönüşümü kullanılarak çıkarılmış ve YSA kullanılarak sınıflandırma yapılmıştır. İlk çalışmada 95 adet normal ve 120 adet anormal PCG kaydı kullanılırken ikinci çalışmada 104 adet PCG kaydı kullanılmıştır.

Wen-Chung ve Chih-Chao (2011) tarafından yapılan çalışmada 44 adet PCG kaydının özelliklerini çıkarmak için kısa süreli Fourier dönüşümü ve ayrık kosinüs dönüşümü kullanılmıştır. Bu kayıtların sınıflandırılması için ise adaptif özellik seçme ile beraber DVM kullanılmıştır.

80 adet kalp sesi kaydı içeren ve Phanphaisarn ve ark. (2011) tarafından yapılan bu çalışmada özellik çıkarma için lineer tahmin edici, sınıflandırma için YSA kullanılmıştır.

Liu ve ark. (2012) tarafından 104 normal, 166 anormal kayıt ile Safara ve ark. (2013) tarafından 16 normal, 43 anormal kayıt ile yapılan çalışmalarda dalgacık dönüşümü tabanlı özellik çıkarım yöntemleri ile kayıtların özellikleri çıkarılmış ve DVM tabanlı sınıflandırıcılar ile kayıtlar sınıflandırılmıştır.

Amiri ve Armano (2013) tarafından 110 adet PCG kaydı ile yapılan çalışmada özellik çıkarma için kompleks Morlet dalgacık dönüşümü, sınıflandırma için karar ağaçları kullanılmıştır.

Roy ve Armano (2014) tarafından yapılan çalışmada özellik çıkarma için ayrık dalgacık dönüşümü kullanılmıştır. Çıkarılan özellikler kNN sınıflandırıcısı girişine verilerek PCG kayıtları sınıflandırılmıştır.

Bir diğer çalışmada insanın sesi algılama şeklinden türetilen MFCC katsayıları 23 adet PCG kaydının özelliklerini çıkarmak için kullanılmış ve daha sonra bu özelliklerle beraber DVM kullanılarak sınıflandırma yapılmıştır (Farzam ve Shirazi 2014).

Guillermo ve ark. (2014) tarafından 17 adet PCG kaydı ile yapılan çalışmada kompleks Morlet dalgacık dönüşümü özellik çıkarma için kullanılmıştır. Kalp sesi kayıtlarının belirlenen özellikleri ileri beslemeli bir YSA girişine verilerek sınıflandırma yapılmıştır.

Koçyiğit (2016) tarafından 14 PCG kaydı ile yapılan çalışmada dalgacık dönüşümü özellik çıkarma için kullanılmış. Çıkarılan özellik vektörünün boyutları bağımsız bileşen analizi yardımıyla azaltıldıktan sonra DVM, lineer diskriminant ve Bayes sınıflandırıcıları kullanılarak PCG kayıtları normal ve anormal olarak sınıflandırılmıştır.

Potes ve ark. (2016) tarafından bu tez çalışmasında da kullanılan kayıtlar ile yapılan çalışmada PCG kayıtları S1, S2, sistol ve diyastol şeklinde ayrıştırıldıktan sonra çeşitli zaman ve frekans özellikleri çıkarılarak sınıflandırıcı metotları topluluğu kullanılarak sınıflandırılmış. Ayrıca ayrıştırılan PCG kayıtları dört alt banda ayrıldıktan sonra derin öğrenme ağının girişine verilerek sınıflandırma yapılmış. Son olarak bu iki sınıflandırıcıdan elde edilen sonuçlar kullanılarak normal ve anormal şeklinde nihai bir karara varılmıştır.

Zabihi ve ark. (2016) tarafından bu tez çalışmasında da kullanılan kayıtlar ile yapılan çalışmada PCG kayıtları ayrıştırılmadan lineer tahmin edici ile, entropi tabanlı, MFCC katsayıları, dalgacık dönüşümü ve güç spektrumu tabanlı özellikler çıkarılmış. İşaretlerin gürültülü olup olmadığını belirlemek için ön bir sınıflandırma yapıldıktan sonra temiz ve gürültülü işaretler için çok sayıda YSA'nın birleşiminden oluşan farklı sınıflandırıcılar kullanılarak sınıflandırma yapılmıştır.

Çizelge 2.1. Kaynak özetleri

Çalışma	Veri Seti	Özellik Çıkarma	Sınıflandırma Yöntemi	Performans
Reed ve ark. (2004)	5 PCG kaydı	Coifman 4. derece dalgacığı	YSA	Doğruluk %100
Gupta ve ark. (2006)	41 PCG kaydı	Daubechies 2. derece dalgacığı	YSA ve GAL	YSA ile doğruluk Veri seti 1: %97.0 Veri seti 2: %98.5 Veri seti 2: %95.6 GAL ile doğruluk Veri seti 1: %97.0 Veri seti 2: %97.0 Veri seti 2: %95.6
Dokur ve Ölmez (2008)	14 PCG kaydı	ADD	ISOM ve Artan YSA	ISOM ile doğruluk: %95 YSA ile doğruluk: %70
Jarmillo-Garzon ve ark. (2008)	22 PCG kaydı	KSFD ve SDD	kNN	KSFD ile sınıflandırma doğruluk: %96.8 duyarlılık: %96.8 özelliklik: %96.8 SSD ile sınıflandırma doğruluk: %97.9 duyarlılık: %98.5 özelliklik: %95.6

Çizelge 2.1. Kaynak özetleri (devamı)

Çalışma	Veri Seti	Özellik Çıkarma	Sınıflandırma Yöntemi	Performans
Das ve ark. (2009)	215 PCG kaydı	ADD	YSA	doğruluk: %97.4 duyarlılık: %100 özgüllük: %96.0
Wen-Chung ve Chih-Chao (2011)	44 PCG kaydı	KSFD	DVM	doğruluk: %94.8
Phanphaisarn ve ark. (2011)	80 PCG kaydı	LPC	YSA	doğruluk: %100
Liu ve ark. (2012)	270 PCG kaydı	ADD	DVM	Normal PCG için doğruluk: %99.0 Atrial bozukluk için doğruluk: %100 Ventriküler bozukluk için doğruluk: %97.0
Amiri ve Armano (2013)	100 PCG kaydı	Kompleks Morlet dalgacık dönüşümü	Karar ağacı	doğruluk: %98.2 duyarlılık: %97.2 özgüllük: %100
Roy ve Armano (2014)	80 PCG kaydı	ADD	kNN	doğruluk: %100
(Farzam ve Shirazi 2014)	23 PCG kaydı	MFCC	DVM	doğruluk: %100
Guillermo ve ark. (2014)	17 PCG kaydı	Kompleks Morlet dalgacık dönüşümü	YSA	Doğruluk: %96.8
Koçyiğit (2016)	14 PCG kaydı	ADD	DVM, lineer diskriminant ve Bayes sınıflandırıcı	doğruluk: %98.5 duyarlılık: %99.9 özgüllük: %99.8
Potes ve ark. (2016)	3240 PCG kaydı	Zaman, frekans ve MFCC	Derin öğrenme ve AdaBoost	duyarlılık: %88.0 özgüllük: %82.0
Zabihi ve ark. (2016)	3240 PCG kaydı	LPC, ADD ve MFCC	Çok sayıda YSA	duyarlılık: %94.2 özgüllük: %88.8

ISOM: Kendiliğinden artarak organize olan harita, SDD: sürekli dalgacık dönüşümü, ADD: ayrık dalgacık dönüşümü, KSFD: kısa süreli Fourier dönüşümü, LPC: lineer tahmin edici katsayıları

3. MATERYAL VE METOT

Bu bölümde, kullanılan teşhis destek algoritması hakkında teorik bilgiler verildikten sonra algoritmada kullanılan veriler tanıtılıp algoritmanın yapısı hakkında bilgiler verilecektir.

3.1. Filtreleme ve Gürültüden Arındırma

Gürültü diğer işaretlerde olduğu gibi PCG işaretlerinde de büyük bir problemdir. Kullanılan sensör, sensörün temas ettiği yüzey, işaretlerin alındığı vücut bölgesi, solunum ve arka plandaki gürültülerin hepsi elde edilen PCG işaretlerinin kalitesine etki etmektedir. Bu da pratikte PCG kayıtlarının, sürtünme, mideden gelen guruldama, akciğerlerden gelen solunum ve kaydın alındığı çevreden gelen gürültü seslerini içermesine neden olur.

PCG kayıtlarını gürültüden temizlemek için genellikle filtreleme kullanılmaktadır (Nabih-Ali ve ark. 2017). Gürültünün tipine göre seçilecek bir alçak geçiren filtre ile sadece belli bir frekans değerinden küçük bileşenlerin geçişine izin verilerek frekansı yüksek olan gürültüler elemine edilmektedir. Eğer gürültüler asıl işaretlerden daha düşük frekans bileşenlerine sahip ise yüksek geçiren bir filtre ile sadece belli frekans değerinden yüksek bileşenlerin geçişine izin verilerek gürültüler yok edilmektedir. Eğer işaret hem yüksek hem de düşük frekanslı gürültüye sahip ise bant geçiren bir filtre yardımıyla işaret gürültülerden arındırılabilir.

PCG işaretlerinin gürültüden arındırılması için Bölüm 3.6.'da açıklanan dalgacık dönüşümü de kullanılabilir.

3.2. Normalizasyon

PCG işaretleri elde edilirken çok farklı sensör tipi ve vücudun farklı bölgeleri kullanıldığından işaretlerin genlikleri farklılıklar göstermekte ve bu genlik değerleri birbirinden farklı aralıklarda yer almaktadır. Bu özelliklere sahip işaretleri birbiriyle karşılaştırmak ve işaretleri tekrar ölçeklendirerek bütün işaretlerin aynı genlik aralığına sahip olması için normalizasyon yapılması gerekir. Bu çalışmada işareti $[-1, 1]$ aralığına ölçeklendiren ve Denklem 3.1'de verilmiş olan min-maks normalizasyonu kullanılmıştır.

$$x_n = 2 \times \frac{x_i - x_{min}}{x_{max} - x_{min}} - 1 \quad (3.1)$$

Burada, x_i orijinal işareti, x_n normalleştirilmiş işareti, x_{min} işaretin en küçük değeri, x_{max} işaretin en büyük değerini ifade eder.

3.3. Segmentasyon

Bir PCG işaretinin temel kalp seslerinin konumunun tespit edilerek kasılma ve gevşeme bölgelerine ayrıştırılmasına segmentasyon denir. Liu (2016) yazdığı makalede segmentasyonun kalp seslerinin analizinde ilk adım olduğunu belirtmiştir. Bir PCG işaretinin segmentasyonunun yapılabilmesi için temel kalp seslerinin yerinin belirlenmesi gerekir (Springer ve ark.2016). Şekil 3.1.'de PCG ve EKG işaretleri verilmiştir. S1, kalbin kasılmaya başladığı anda meydana gelen kulakçıkta kapakçıklarının kapanması ile başlar ve EKG'de R tepesinin hemen sonrasına denk gelir. S2, kalbin gevşemeye başladığı anda meydana gelen yarım ay kapakçıklarının kapanması ile başlar ve yaklaşık olarak EKG'deki T dalgasının bittiği yerde biter (Liu 2016). Moukadem ve ark. (2013) tarafından yazılan makaleye göre S1 ve S2'nin yerini belirlemek için uzman hekimler tarafından kullanılan yöntem ise şu şekildedir:


- S1'in başlangıcı mitral kapakçıklarının kapanması sonucu oluşan yüksek frekanslı titreşimlerin başladığı noktadır.
- S2'nin başlangıcı aortik kapakçıklarının kapanması sonucu yüksek frekanslı titreşimlerin başladığı noktadır.
- S1 ve S2'nin bitişi ise bu titreşimlerin bittiği yerlerdir.

PCG işaretlerinin segmentasyonu için pek çok yöntem kullanılmaktadır. Literatürde en iyi ve en başarılı yöntem olarak nitelendirilen yöntem Springer'in geliştirdiği saklı Markov modeli temelli yöntemdir.

3.3.1. Springer'in Segmentasyon Yöntemi

Blok diyagramı Şekil 3.2.'de verilmiş olan Springer'in segmentasyon yöntemi yedi temel aşamadan oluşur. PCG işaretlerinin doğru bir şekilde etiketlenmesi EKG işaretlerinin doğru bir şekilde etiketlenmesine bağlı olduğundan ilk adımda düşük işaret kalitesine sahip EKG işaretleri veri setinden çıkarılmıştır. Bunun için EKG işaretlerindeki R tepesini tespit etmeye yarayan dört farklı yöntem ile EKG

işaretlerindeki R tepeleri tespit edilmiştir. Birbirine yakın sonuçlar veren üç yöntem değerlendirme için seçilmiştir. Daha sonra işaretler 4 s'lik bölütlere ayrılmıştır. 100 ms'lik tolerans dâhilinde her üç yöntemin de aynı sonucu verdiği pencerelerin R tepesi etiketlenmesi yapılmış diğer pencereler ileriki aşamalarda kullanılmamıştır. T dalgasının

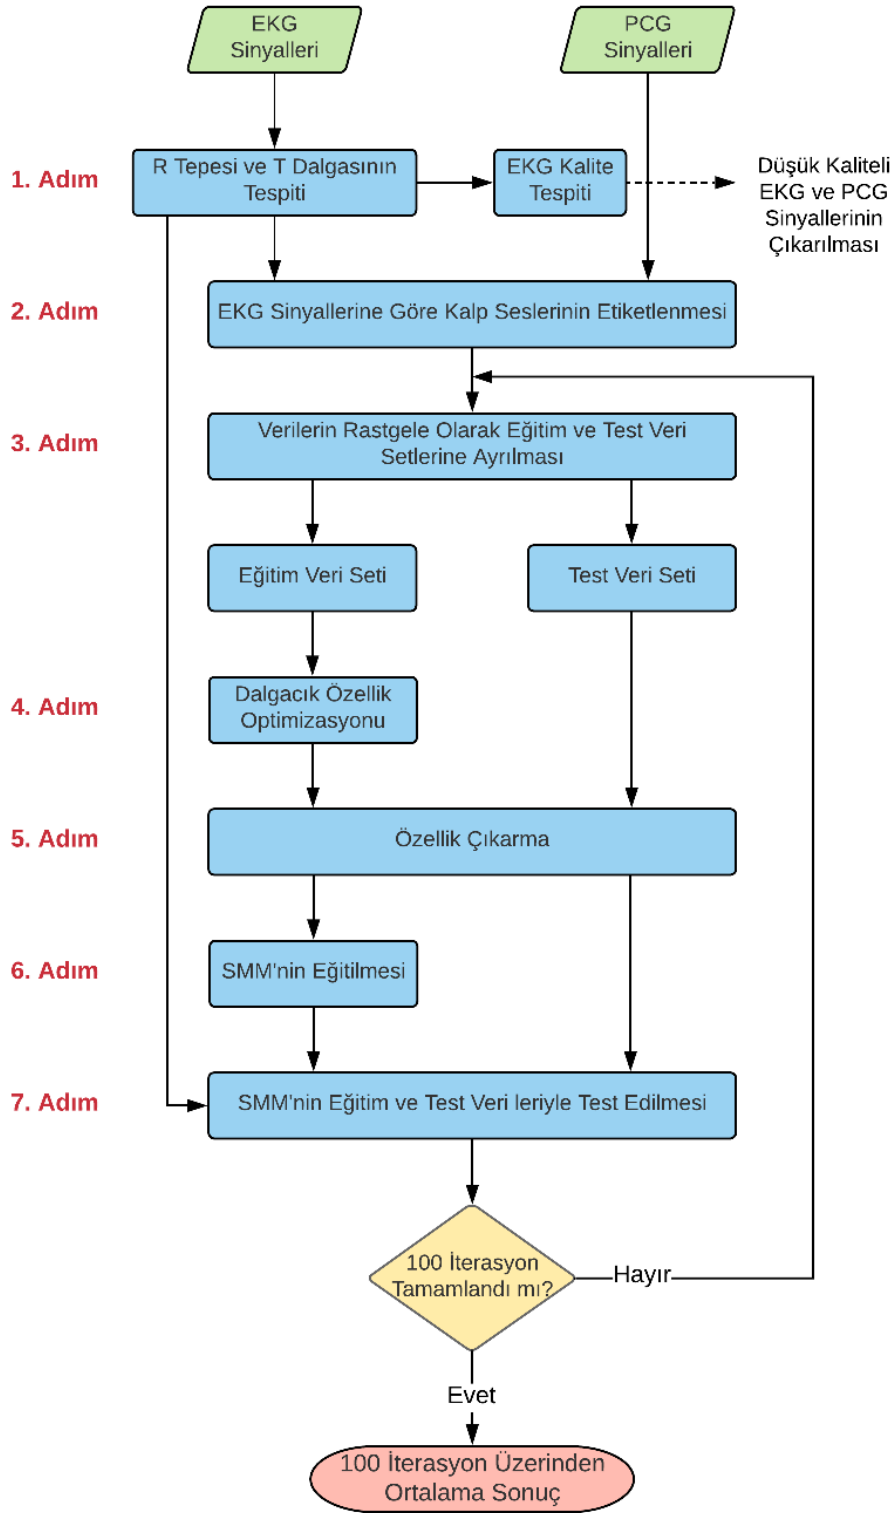


Şekil 3.1. Eşzamanlı EKG ve PCG işaretleri (Springer ve ark. 2016)

sonunu tespit etmek için önceki adımda değerlendirme dışı kalmamış bölütler ile yine aynı dört yöntem kullanılmış ve bu dört yöntemin ortanca sonucuna en uzak sonucu veren yöntem değerlendirme dışı bırakılmıştır. Eğer herhangi bir yöntemin sonucu eksik olursa bölüt değerlendirme dışı bırakılmıştır. Kalan üç yöntemin verdiği ortanca sonuç T dalgasının sonu olarak kabul edilmiştir.

İlk adımda EKG işaretlerindeki R tepesi ve T dalgasının sonu tespit edildikten sonra ikinci adımda Springer'in (2016) çalışmasında anlatıldığı gibi EKG işaretleri referans alınarak PCG işaretlerindeki S₁, S₂, sistol ve diastol bölgeleri tespit edilmiştir.

Üçüncü adımda, bir önceki adımda S₁, S₂, diastol ve sistol bölgeleri tespit edilen PCG işaretleri normal ile anormal işaretlerinin oranı aynı olacak şekilde eğitim ve test veri setine ayrılmıştır.



Şekil 3.2. Springer'in segmentasyon yönteminin blok diyagramı

PCG işaretlerinin dalgacık dönüşümü özellikleri çıkarılırken hangi dalgacığın daha iyi sonuç vereceği tam olarak bilinmediğinden bu adımda dalgacık dönüşümü için deneme yanılma yoluyla optimizasyon yapılmıştır.

Beşinci adımda, yeniden örneklemeden sonra çeşitli yöntemlerle PCG işaretlerinin zarf eğrisi (bir işaretin ekstremum noktalarını ana hatlarıyla belirten eğri) elde edilmiştir.

Altıncı adımda çıkarılan özellikler ve referans noktalar kullanılarak saklı Markov modeli eğitilmiştir. Son adımda test veri seti kullanılarak algoritma test edilmiştir. Tüm işlemler 100 defa tekrarlanıp ortalama sonuç elde edilmiştir. Konuyla ilgili detaylı bilgi Springer ve ark. (2016) tarafından yapılan çalışmada mevcuttur.

3.4. İstatistiksel Özellikler

a) Aritmetik Ortalama

Bir işaretin aritmetik ortalaması Denklem 3.2'deki gibi hesaplanır (Illowsky ve Dean 2013).

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.2)$$

Burada, x_i orijinal işareti, n örnek sayısını ve μ işaretin aritmetik ortalamasını ifade eder.

b) Minimum

Minimum, bir işaretin en küçük değeridir (Illowsky ve Dean 2013).

c) Maksimum

Maksimum, bir işaretin en büyük değeridir (Illowsky ve Dean 2013).

d) Standart Sapma

Bir işaretin standart sapması Denklem 3.3'teki gibi hesaplanır (Illowsky ve Dean 2013).

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2} \quad (3.3)$$

Burada, x_i orijinal işareti, n örnek sayısını, μ işaretin aritmetik ortalamasını ve σ işaretin standart sapmasını ifade eder.

e) Varyans

Varyans standart sapmanın karesi şeklinde tanımlanır (Illowsky ve Dean 2013).

f) Toplam Harmonik Bozulma

Toplam harmonik bozulma, bir işaretteki harmoniklerin etkin değerinin (veya gücünün) temel frekans bileşenin etkin değerine (veya gücüne) oranı şeklinde tanımlanır.

g) Sıfırdan Geçme Oranı

Bir işaretteki işaret değişimi oranı şeklinde tanımlanan sıfırdan geçme oranı Denklem 3.4'teki gibi hesaplanır (Illowsky ve Dean 2013).

$$zcr = \frac{1}{n} \sum_{i=1}^n |sgn(x_i) - sgn(x_{i-1})| \quad (3.4)$$

Burada, x_i orijinal işareti, n örnek sayısını ve zcr işaretin standart sapmasını ifade eder.

h) Basıklık

Bir dağılımın yüksekliğinin normal dağılımın yüksekliğinden ne kadar saptığının bir ölçüsü olarak tanımlanan basıklık Denklem 3.5'teki gibi hesaplanır (Illowsky ve Dean 2013).

$$\text{basıklık} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^4}{\left(\sqrt{\sum_{i=1}^n (x_i - \mu)^2} \right)^2} \quad (3.5)$$

Burada, x_i orijinal işareti, n örnek sayısını ve μ işaretin aritmetik ortalamasını ifade eder.

i) Etkin Değer

Bir işaretin etkin değeri Denklem 3.6'daki gibi hesaplanır.

$$x_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (3.6)$$

Burada, x_i orijinal işareti, n örnek sayısını ve x_{RMS} işaretin etkin değerini ifade eder.

j) Ortanca Değer

Bir işareti oluşturan noktalar küçükten büyüğe sıralandığında ortadaki noktaya o işaretin ortanca değeri denir.

k) Çarpıklık

Çarpıklık, bir işaretin dağılımının normal dağılıma göre ne kadar asimetrik olduğunun ölçüsüdür ve Denklem 3.7’teki gibi hesaplanır.

$$\text{çarpılık} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^3}{\left(\sqrt{\sum_{i=1}^n (x_i - \mu)^2} \right)^3} \quad (3.7)$$

Burada, x_i orijinal işareti, n örnek sayısını ve μ işaretin aritmetik ortalamasını ifade eder.

3.5. Fourier Dönüşümü

Güneş ışığının bir prizma yardımıyla gökkuşağı renklerine ayrılması iyi bilinen bir olaydır. Newton, 1672’de yazdığı makalede prizma tarafından oluşturulan devamlı renk bantlarını tanımlamak için spektrum terimini kullanmıştır. Her bir renk görünür spektrumun belli bir frekansına denk gelir. Yani, ışığın renklere ayrılması bir çeşit frekans analizidir.

Bir işaretin frekans analizi o işaretin frekans (sinüzoidal) bileşenlerine ayrıştırılmasını içerir. Yalnız, bu durumda ışık yerine zamanın bir fonksiyonu olan işaretler ve prizma yerine ise Fourier dönüşümü kullanılır. Fourier dönümü, 19. yüzyılın başlarında Fransız matematikçi Jean Baptiste Joseph Fourier tarafından ortaya atıldıktan yıllar sonra günümüzde işaret işleme alanında en çok kullanılan tekniklerden biri haline gelmiştir.

Bir $x_T(t)$ fonksiyonu Denklem 3.8 ’deki gibi ifade edilebilir ve bu ifadeye Fourier serisi açılımı denir.

$$x_T(t) = a_0 + \sum_{n=1}^{\infty} (a_n \cos(n\omega_0 t) + b_n \sin(n\omega_0 t)) = \sum_{n=-\infty}^{+\infty} c_n e^{jn\omega_0 t} \quad (3.8)$$

Burada, $x_T(t)$ t değişkenine bağlı T periyotlu ve $\omega_0 = 2\pi/T$ temel frekanslı periyodik bir fonksiyonu, a_n, b_n ve $n = 1, 2, 3 \dots$ sabit katsayıları ifade eder. Denklem 3.8'deki katsayılar Denklem 3.9-3.12'teki gibi hesaplanır.

$$a_0 = \frac{1}{T} \int_0^T x_T(t) dt \quad (3.9)$$

$$a_n = \frac{2}{T} \int_0^T x_T(t) \cos(n\omega_0 t) dt \quad (3.10)$$

$$b_n = \frac{2}{T} \int_0^T x_T(t) \sin(n\omega_0 t) dt \quad (3.11)$$

$$c_n = \frac{1}{T} \int_0^T x_T(t) e^{-jn\omega_0 t} dt \quad (3.12)$$

Bir fonksiyonun Fourier dönüşümü, periyot sonsuza giderken ($T \rightarrow \infty$) Fourier serisinin özel bir durumudur. Denklem 3.12 yeniden düzenlenirse Denklem 3.13 elde edilir.

$$Tc_n = \int_0^T x_T(t) e^{-jn\omega_0 t} dt \quad (3.13)$$

$T \rightarrow \infty$ iken temel frekans, $\omega_0 = 2\pi/T$ oldukça küçük bir değer alır ve $n\omega_0$, $[-\infty, +\infty]$ arasında herhangi bir değer alabilen sürekli bir büyüklük haline gelir. $\omega = n\omega_0$ ve $X(\omega) = Tc_n$ değerleri Denklem 3.13'te yerine yazılırsa Denklem 3.14 elde edilir.

$$X(\omega) = \int_{-\infty}^{+\infty} x(t) e^{-j\omega t} dt \quad (3.14)$$

Denklem 3.14 Fourier dönüşümü olarak adlandırılır. Eğer Denklem 3.14 yeniden düzenlenirse birim Hertz olacak şekilde dönüşüm yapan Denklem 3.15 elde edilir.

$$X(f) = \int_{-\infty}^{+\infty} x(t) e^{-j2\pi f t} dt \quad (3.15)$$

3.5.1. Ayırık Fourier Dönüşümü

Ayrık zamanlı bir işaretin frekans analizi genellikle ve en kolay şekilde bir bilgisayar veya özel olarak tasarlanmış bir donanım ile yapılabilir. Ayrık zamanlı bir işaretin frekans analizini yapmak için zaman uzayında tanımlı işaret frekans uzayı

eşdeğerine dönüştürülür. Bu dönüşüm için Fourier dönüşümü kullanılır, yalnız bu dönüşüm frekansın sürekli bir fonksiyonu olduğu için hesaplama açısından pek uygun bir yöntem değildir. Bu yüzden ayrık işaretlerin frekans dönüşümünü yapmak için ayrık Fourier dönüşümü geliştirilmiştir. Eğer Fourier dönüşümü Denklem 3.16'daki gibi N örnek ile periyodik olarak örneklenir ise $X(\omega)$, 2π periyoduna sahip periyodik bir fonksiyon olduğundan sadece temel frekans aralığında yer alan örnekler gereklidir.

$$\omega = \frac{2\pi k}{N}, \quad k = 0, 1, \dots, N-1 \quad (3.16)$$

Fourier dönüşümünün N adet ayrık frekans için hesaplanması sonucu Denklem 3.17'deki eşitlik olan ayrık Fourier dönüşümü elde edilir (Proakis ve Manolakis 1996).

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi kn/N}, \quad k = 0, 1, \dots, N-1 \quad (3.17)$$


3.6. Dalgacık Dönüşümü

Fourier dönüşümü işaret işleme alanında en çok kullanılan dönüşüm olmasına rağmen durağan olmayan, yani frekans içeriği zamana göre değişen işaretlerin frekans analizinde yetersiz kalmaktadır. Çünkü bir işaretin Fourier dönüşümü ile frekans analizi yapıldığında o işaretin zaman bilgisi yok olur ve hangi frekansın hangi zamanda (veya zaman aralığında) meydana geldiği bilinemez. Bu nedenle hangi frekansın hangi zaman aralığında meydana geldiğini tespit etmek amacıyla kısa süreli Fourier dönüşümü geliştirilmiştir.

Kısa süreli Fourier dönüşümünde işaret sabit genişlikte dikdörtgen pencerelere ayrılarak her pencerenin Fourier dönüşümü ayrı ayrı yapılarak işaretin frekans analizi yapılır. Fakat geniş bir pencere seçildiğinde dönüşümün frekans çözünürlüğü yüksek, zaman çözünürlüğü ise düşük olur. Öte yandan, dar bir pencere seçildiğinde ise frekans çözünürlüğü düşük, zaman çözünürlüğü yüksek olur. Kısa süreli Fourier dönüşümünün bu dezavantajından dolayı dalgacık dönüşümü geliştirilmiştir.

Dalgacık dönüşümünde yüksek frekans ve zaman çözünürlüğü elde etmek için düşük frekanslı bölgelerde geniş, yüksek frekanslı bölgelerde ise dar bir pencere (dalgacık) seçilerek işaretin zaman-frekans analizi yapılır. Böylece işaretin düşük frekanslı bölgeleri için yüksek frekans çözünürlüğü, yüksek frekanslı bölgeleri için ise

yüksek zaman çözünürlüğü elde edilir. Fourier dönüşümünde işaretler, farklı frekanstaki sinüzoidal işaretlerin toplamı şeklinde ifade edilirken, dalgacık dönüşümünde işaretler, Şekil 3.3.'te verilmiş herhangi bir ana dalgacığın zamanda ötelenmiş ve farklı ölçekteki hallerinin toplamı şeklinde ifade edilir (Burrus ve ark. 1998).



Şekil 3.3. Örnek dalgacık şekilleri

3.6.1. Sürekli Dalgacık Dönüşümü

Sürekli dalgacık dönüşümü Denklem 3.18'deki gibi tanımlanır.

$$c(s, \tau) = \int_{\mathbb{R}} f(t) \Psi_{s, \tau}(t)^* dt, \quad s \in \mathbb{R}^+ - \{0\}, \tau \in \mathbb{R} \quad (3.18)$$

Burada, $\Psi_{s, \tau}(t)^*$ ana dalgacığın kompleks eşleniğini, $c(s, \tau)$ dalgacık katsayılarını, $f(t)$ dalgacık dönüşümü hesaplanacak olan işaret, s ölçeği ve τ öteleme ifade eder. Tüm dalgacıklar tek bir ana dalgacıktan ölçek (s) ve öteleme (τ) değiştirilerek Denklem 3.19 yardımıyla elde edilir. Ölçek arttırıldığında ana dalgacık genişler, azaltıldığında ise büzülür. Öteleme değiştirildiğinde ise dalgacık zamanda ileriye ve geriye doğru ötelenir.

$$\Psi_{s, \tau}(t) = \frac{1}{\sqrt{s}} \Psi\left(\frac{t - \tau}{s}\right) \quad (3.19)$$

Sürekli dalgacık dönüşümü aşağıdaki adımlar takip edilerek hesaplanır:

1. Bir dalgacık seçilir ve orijinal işaretin başlangıç kısmı ile karşılaştırılır.
2. Denklem 3.18 kullanılarak dalgacık katsayısı hesaplanır, yani dalgacığın işaretin o kısmı ile ne kadar ilişkili olduğu hesaplanır.

3. Tüm işareti kapsayıcaya kadar öteleme yapılarak birinci ve ikinci adım tekrar edilir.
4. Ölçek değeri değiştirilerek birinci, ikinci ve üçüncü adım tekrar edilir.
5. Tüm ölçek değerleri için birinci adımdan dördüncü adıma kadar olan kısım tekrar edilir.

Dalgacık katsayılarından orijinal işareti elde etmek için Denklem 3.20'deki ters dalgacık dönüşümü kullanılır.

$$f(t) = \int_{R^+} \int_R c(s, \tau) \Psi_{s, \tau}(t) ds d\tau \quad (3.20)$$

3.6.2. Ayırık Dalgacık Dönüşümü

Ölçek ve öteleme parametrelerinin sürekli bir şekilde değişimi işaretin fazlaca gereksiz bilgi içerecek şekilde temsil edilmesine neden olur ve işlem yükünü oldukça artırır. Ölçek ve öteleme parametrelerinin ayırık bir şekilde değiştirilmesi hem işlem yükünü azaltır hem de dönüşümdeki gereksiz bilgilerin atılmasını sağlar. Ölçek ve öteleme parametrelerinin ayırık seçilmesiyle ayırık dalgacık dönüşümü elde edilir. j ve k pozitif tam sayılar olmak üzere ölçek için j adet, öteleme için k adet adım seçilirse $s = 2^{-j}$ ve $\tau = k2^{-j}$ elde edilir. Bu değerler Denklem 3.19'da yerine yazılırsa Denklem 3.21'teki eşitlik elde edilir.

$$\Psi_{j,k}(t) = 2^{j/2} \Psi(2^j t - k) \quad (3.21)$$

Böylece sırasıyla Denklem 3.22 ve 3.23'te verilen ayırık ve ters ayırık dalgacık dönüşümleri elde edilir. Ayırık dalgacık dönüşümü de Bölüm 3.6.1.'de verilen adımlar ile hesaplanır.

$$c(j, k) = \sum_t f(t) \Psi_{j,k}(t)^* \quad (3.22)$$

$$f(t) = \sum_k \sum_j c(j, k) \Psi_{j,k}(t) \quad (3.23)$$

3.6.3. Hızlı Dalgacık Dönüşümü


Mallat (1989) yaptığı çalışmada ayırık dalgacık dönüşümünün hesaplanmasında yeni bir yöntem geliştirmiştir. Bu yöntemde, işaretin farklı ölçeklerdeki

analizi için farklı kesim frekanslarına sahip filtreler kullanılır. Yüksek frekansların analizi için işaret yüksek geçiren filtre serilerinden, düşük frekansların analizi içinse işaret alçak geçiren filtrelerden geçirilir.

N tane örneğe sahip $x[n]$ işaretinin dalgacık katsayıları, hesaplanırken işaret alçak geçiren bir filtreden geçirilir ve örnek sayısı yarıya düşecek şekilde yeniden örneklenerek birinci seviye yaklaşım katsayısı (cA_1) elde edilir. Daha sonra işaret yüksek geçiren filtreden geçirilir ve örnek sayısı yarıya düşecek şekilde yeniden örneklenerek birinci seviye detay katsayısı (cD_1) elde edilir. Bu işlemler matematiksel olarak Denklem 3.24 ve 3.25'deki gibi ifade edilebilir. Daha yüksek seviyelerde katsayılar elde etmek için bu işlemler tekrar edilir. $g[n]$ yüksek geçiren ve $h[n]$ alçak geçiren filtre olmak üzere Şekil 3.4.'de üçüncü seviye hızlı dalgacık dönüşümünün işlem adımları görülmektedir.

$$y_{yüksek} = cD = \sum_n x[n] \cdot g[2k - n] \quad (3.24)$$

$$y_{alçak} = cA = \sum_n x[n] \cdot h[2k - n] \quad (3.25)$$



Şekil 3.4. Üçüncü seviye hızlı dalgacık dönüşümü

İşaret, dalgacık katsayılarından yukarıdaki adımlar tersten takip edilerek tekrar oluşturulabilir. Bu süreç ters hızlı dalgacık dönüşümü olarak adlandırılır ve matematiksel olarak Denklem 3.26'daki gibi ifade edilebilir.


$$x[n] = \sum_{k=-\infty}^{+\infty} (y_{yüksek}[k] \cdot g[-n + 2k] + y_{alçak}[k] \cdot h[-n + 2k]) \quad (3.26)$$

İşaret yeniden oluşturulurken dalgacık katsayılarına çeşitli eşiklemeler uygulanarak dalgacık dönüşümü, işareti gürültüden arındırmak amacıyla da kullanılabilir (Sardy ve ark. 2001).

3.7. Mel Frekanslı Kepstrum Katsayıları (MFCC)

Konuşma tanıma uygulamalarında en çok kullanılan özellik çıkarma yöntemlerinden bir tanesi mel frekanslı kepstrum katsayılarıdır (O'Shaughnessy 2008). Bu yöntem ilk defa Bridle ve Brown tarafından 1974 yılında bahsedilmiştir ve 1976'da insanın kelimeleri yanlış anlama deneylerini temel alarak Mermelstein tarafından geliştirilmiştir (Mermelstein 1976).

Sözel mesajlar hakkındaki bilginin tamamını içeren özellik vektörü çıkarmak için MFCC, insanın konuşma ve duyma sistemlerinin bir kısmını taklit eder. Bu yöntem sesin yüksekliğinin insan tarafından logaritmik olarak algılanmasını ve insanın sesin frekansını gerçek frekanstan farklı algılamasını taklit eder ve konuşmacıya bağlı karakteristikleri, konuşmanın temel frekansını ve bu frekansın harmoniklerini çıkararak elemine etmeye çalışır. MFCC'nin blok diyagramı Şekil 3.5.'te verilmiştir.



Şekil 3.5. MFCC algoritmasının blok diyagramı

a) Pencereleme

Bu adımda 20 ile 40 ms arasında bir pencere seçilerek bu pencere her adımda genellikle pencere genişliğinin yarısı kadar kaydırılır. Her bir pencere için diğer adımlarda açıklanan işlemler işarete uygulanır.

b) Fourier Dönüşümü

İşaretin frekans analizini yapmak için Bölüm 3.5.1.'de açıklanan ayrık Fourier dönüşümü kullanılarak işaretin frekans bileşenleri bulunur. İşaretin frekans spektrumu Denklem 3.27'deki gibi hesaplanır.

$$c_{\tau,k}^{(1)} = \left| \frac{1}{N} \sum_{i=0}^{N-1} f_i e^{-j2\pi i k / N} \right|, \quad k = 0, 1, \dots, \left(\frac{N}{2} - 1\right) \quad (3.27)$$

Burada, f orijinal işareti, N penceredeki örnek sayısını ve τ pencere adımını ifade eder.

c) Mel Ölçek Filtrelemesi

Bu adımda Mel frekansı spektrumu hesaplanır. Bunun için işaretin spektrumu N_d adet bant geçiren filtreden geçirilerek her bandın enerjisi hesaplanır. Bu filtreleme insanın kulağını taklit eder çünkü insanın duyma sistemi ileriki süreçler için bir frekans bandının gücünü işaret olarak kullanır. Mel frekansı spektrumu Denklem 3.28'deki gibi hesaplanır.

$$c_{\tau,i}^{(2)} = \sum_{k=0}^{N/2-1} d_{i,k} c_{\tau,k}^{(1)}, \quad i = 0, 1, \dots, N_d \quad (3.28)$$


Burada, d filtre genliğini, N_d filtre sayısını, k frekansı ve i indeksi ifade eder. f orijinal işaret olmak üzere Denklem 3.29'da tanımlanan mel ölçeğine göre yerleştirilen bant geçiren filtrelerin sayısı, şekli ve frekansı farklılık gösterebilir. Örnek bir mel filtre bankası Şekil 3.6.'da verilmiştir.

$$M(f) = 1125 \ln \left(1 + \frac{f}{700} \right) \quad (3.29)$$

d) Logaritma

İnsanın sesin yüksekliğini algılama şeklini taklit etmek için bu adımda işaretin logaritması Denklem 3.30 kullanılarak alınır.

$$c_{\tau,i}^{(3)} = \log c_{\tau,i}^{(2)}, \quad i = 0, 1, \dots, N_d \quad (3.30)$$



Şekil 3.6. Örnek bir mel filtre bankası

e) Ayırık Kosinüs Dönüşümü

Beşinci adım olarak konuşmacıya bağlı karakteristiklerin yok edilmesi amacıyla kepsral katsayılar hesaplanır. Logaritmik spektrumun ayırık kosinüs dönüşümü yapılarak konuşmacıya bağlı temel frekansın harmonikleri daha yüksek dereceden katsayılara dönüştürülür. Sadece düşük seviyedeki katsayılar kullanılırsa konuşmacıya bağlı bileşenler baskılanmış olur. Ayırık kosinüs dönüşümü Denklem 3.31'teki gibi hesaplanır.

$$c_{\tau,i}^{(4)} = \sum_{i=1}^{N_d} c_{\tau,i}^{(3)} \cos\left(\frac{k(2i-1)\pi}{2N_d}\right), \quad i = 0, 1, \dots, N_{mc} < N_d \quad (3.31)$$

Burada, N_{mc} , seçilen kepsral katsayı sayısını ifade etmektedir.

f) Fark


Şimdiye kadar olan bütün adımlar sadece bir zaman penceresine ait bilgiler içermektedir. Konuşmanın dinamik doğasının temsil edilebilmesi için katsayıların farkları da Denklem 3.32-33 kullanılarak özellik vektörüne eklenmektedir (Kido 2014).

$$\Delta c_{\tau,i}^{(4)} = c_{\tau+1,i}^{(4)} - c_{\tau-1,i}^{(4)}, \quad \Delta \Delta c_{\tau,i}^{(4)} = \Delta c_{\tau+1,i}^{(4)} - \Delta c_{\tau-1,i}^{(4)} \quad (3.32)$$

$$c_{\tau,i}^{(4)} = \begin{bmatrix} c_{\tau,i}^{(4)} & \Delta c_{\tau,i}^{(4)} & \Delta \Delta c_{\tau,i}^{(4)} \end{bmatrix} \quad (3.33)$$

3.8. Ardışık Geri Yönde Özellik Seçme Algoritması

Özellik seçmenin amacı, çıkarılan özellik kümesinden daha az sınıflandırma hatası elde edilebilecek bir alt küme seçilmesidir. Blok diyagramı Şekil 3.7.'de verilen ardışık geri yönde özellik seçme algoritması orijinal altküme ile başlar ve orijinal altküme, değerlendirme kriterine göre değerlendirilir. Sonra, alt kümeden bir özellik çıkarılır ve aday alt küme oluşturulur. Aday alt küme, değerlendirme kriterine göre değerlendirilir. Değerlendirme sonucunda özellik çıkarılmadan önceki performanstan daha iyi bir performans elde edilir ise özellik atılır, edilmez ise özellik geri eklenir. Daha sonra alt kümeden başka bir özellik çıkarılarak aynı işlemler tekrarlanır. Durma kriterine ulaşıncaya veya bütün özellikler denene kadar aynı işlemler tekrarlanır (Jain ve Zongker, 1997).



Şekil 3.7. Özellik seçme algoritmasının blok diyagramı

3.9. Sınıflandırıcı Metotları Topluluğu


Pek çok araştırmacı çok sayıda sınıflandırıcının tahminlerini birleştirerek tek bir sınıflandırıcı oluşturma tekniğini incelemiştir. Elde edilen sınıflandırıcı, yani topluluk, genellikle bu topluluğu oluşturan her bir sınıflandırıcıdan daha yüksek bir doğruluğa sahip olur. Bu yöntemin temel prensibi bir grup zayıf sınıflandırıcıyı çeşitli algoritmalar kullanarak bir araya getirip güçlü bir sınıflandırıcı oluşturmaktır. Sınıflandırıcı topluluğu oluşturulurken en çok kullanılan algoritmalar Boosting ailesi algoritmaları ve bagging algoritmasıdır. Bu algoritmalar ile beraber en çok kullanılan zayıf sınıflandırıcı ise karar ağacıdır (Zhukov ve ark. 2017).

3.9.1. Karar Ağacı

Danışmanlı öğrenme (eğitim veri setinde hangi girişin hangi çıkışa karşılık geldiği bilinen) yöntemlerinden olan karar ağacı, en çok kullanılan ve en pratik tümevarım çıkarım yöntemlerinden bir tanesidir. Anlaşılması kolay bir yöntem olmasından dolayı medikal durumları teşhisten kredi geri dönüş riskini değerlendirmeye kadar pek çok alanda kullanılmaktadır (Mitchell 1997). Bu yöntem aşağıdaki durumlar için uygun bir yöntemdir:

- Özellik-değer çifti ile temsil edilen örnekler: Karar ağacı için en uygun örnek sıcaklık gibi bir özelliğin sıcak, serin ve soğuk gibi az sayıda değer ile temsil edildiği örneklerdir.
- Hedef fonksiyonun ayrık değerli olması: Karar ağacı en iyi sonucu iki sınıfa sahip örneklerde verir.
- Eğitim veri setinin hata içermesi: Karar ağacı yöntemi hem eğitim örneklerinin sınıflandırılmasındaki hatalara hem de bu örnekleri tanımlayan özelliklerdeki hatalara dayanıklıdır.
- Eğitim veri setinde eksik özellik olması: Bazı örneklerin özellikleri eksik olsa dahi karar ağacı kullanılabilir (örneğin bazı günler için havanın neminin bilinmemesi).

Karar ağacı, örnekleri ağaç şeklinde, kökten örneğin sınıfını veren yapraklara doğru sıralayarak sınıflandırma yapar. Ağaçtaki her düğüm örneğin bazı özellikleri için bir test noktasıdır ve bu düğümden aşağı yönde uzanan her bir dal ise düğümün olası değerlerine denk gelir. Bir örnek, ağacın ilk düğümü olan kökten sınıflandırılmaya başlanır. Özellik bu düğümde test edilerek sahip olduğu değere göre alt dallara ayrılır ve nihai bir sınıf elde edilene kadar bu işlemler devam eder (Mitchell 1997). Şekil 3.8.'de Pazar gününün tenis oynamaya elverişli olup olmadığı değerlendirilmektedir. Bu ağaca göre eğer hava durumu (birinci özellik, düğüm) bulutlu ise “elverişli” olarak sınıflandırılır, eğer hava güneşli ise nem durumuna göre karar verilir. Eğer nem normal ise “elverişli”, nem yüksek ise “elverişsiz” olarak sınıflandırılır. Eğer hava yağmurlu ise rüzgâr durumuna göre karar verilir. Rüzgâr zayıf ise “elverişli”, rüzgâr kuvvetli ise “elverişsiz” olarak sınıflandırılır.



Şekil 3.8. Kök, düğüm, dal ve yaprak içeren bir karar ağacı

Karar ağaçlarının eğitilmesi için geliştirilen algoritmaların çoğu yukarıdan aşağıya doğru olası karar ağaçları uzayında arama yapan ve ID3 olarak adlandırılan temel algoritmanın varyasyonlarıdır.

Temel algoritma (ID3) “Ağacın kökünde hangi özellik test edilmeli?” sorusuyla başlayarak karar ağacını yukarıdan aşağıya doğru yapılandırır. Algoritma bu soruyu cevaplamak için her bir özelliğin eğitim veri setini tek başına ne kadar iyi sınıflandırdığını değerlendirmek için istatistiksel bir test kullanır. Hangi özelliğin en iyisi olduğuna karar verdikten sonra bu özelliği ağacın kökünde kullanıp eğitim verilerini bu özelliği kullanarak test eder ve olası sonuçlara göre yeni dallar oluşturur. Daha sonra yeni oluşturulan düğümler için de en iyi özellikleri seçerek sınıflandırma yapana kadar işlemleri tekrar eder. Bu algoritma asla geriye giderek önceki kararları yeniden değerlendirmez. Çizelge 3.1.’de ikili sınıflandırma yapan örnek bir algoritma verilmiştir.

Algoritma, her düğümde kullanılacak en iyi özelliği seçerken özelliğin, eğitim veri setini hedef sınıflandırmaya göre ne kadar iyi ayırdığının bir ölçüsü olan bilgi kazancını kullanır. Bilgi kazancının tanımlanabilmesi için enformasyon teorisinde geniş kullanım alanı olan entropinin tanımlanması gerekmektedir (Mitchell 1997).

Çizelge 3.1. ID3 algoritması

Girişler:	Örnekler, Hedef vektörü, Özellik vektörü
Çıkışlar:	Karar ağacı
A1.	Ağacın kökünü oluştur
A2.	Tüm örnekler pozitif ise tek düğümlü bir ağaç oluştur ve örnekleri (+) ile
A3.	etiketle
A4.	Tüm örnekler negatif ise tek düğümlü ağaç oluştur ve örnekleri (-) ile etiketle
A5.	Eğer özellik vektörü boş ise tek düğümlü bir ağaç oluştur ve örnekleri hedef vektöründe sayıca daha fazla olan sınıf ile etiketle
A6.	Öbür türlü başla
A7.	Bilgi kazancının en yüksek olduğu özelliği bul (A)
A8.	Kök düğüm için A 'yı ata
A9.	Özellik vektörü, A 'daki her bir v_i özelliği için:
A10.	Örneklerin A 'ya göre test edilmesine denk yeni dal ekle $A = v_i$
A11.	Örnekler_{v_i} , A için v_i 'ye sahip örneklerin altkümesi olmak üzere
A12.	Eğer Örnekler_{v_i} boş ise
A13.	Bu dalın altına yaprak ekle ve örnekleri hedef vektöründe sayıca daha fazla olan sınıf ile etiketle
A14.	Eğer Örnekler_{v_i} boş değilse
A15.	Yeni alt ağaç ekle
A16.	ID3(Örnekler_{v_i} , hedef vektörü, özellik vektörü- $\{A\}$)
A17.	Son

Entropi: rastgele seçilmiş örneklerin ne kadar saf (seçilen örneklerin sadece bir sınıfa ait olması durumu) olduğunun bir göstergesidir. Bir kümenin entropisi Denklem 3.34'deki gibi tanımlanır.

$$Entropi(S) = -p_{\oplus} \log_2 p_{\oplus} - p_{\ominus} \log_2 p_{\ominus} \quad (3.34)$$

Burada, S pozitif ve negatif hedef sınıfları içeren örnekler kümesini, $p_{\oplus}$ pozitif örneklerin oranını ve $p_{\ominus}$ negatif örneklerin oranını ifade eder. Eğer hedef sınıfların sayısı ikiden fazla ise entropi Denklem 3.35'teki gibi tanımlanır.

$$Entropi(S) = \sum_{i=1}^c -p_i \log_2 p_i \quad (3.35)$$


Burada, c hedef sınıfların sayısını ifade eder. Entropi, $[0,1]$ aralığında değer alır ve bu değer küçüldükçe yapılan sınıflandırmanın başarısı artar. Seçilen bir A özelliğine göre entropide beklenen azalmaya bilgi kazancı denir. Bilgi kazancı Denklem 3.36'deki gibi tanımlanır.

$$Kazanç(S, A) = Entropi(S) - \sum_{v \in \text{değer}(A)} \frac{|S_v|}{|S|} Entropi(S_v) \quad (3.36)$$

Burada, S pozitif ve negatif hedef sınıflarını içeren örnekler kümesini, $\text{değer}(A)$ A özelliği için tüm olası değerler kümesini, S_v A 'nın değerlerinin v olduğu S 'nin altkümesini ifade eder.

3.9.2. Boosting Algoritma Ailesi

Boosting, sınıflandırma metodolojisindeki en önemli gelişmelerden bir tanesidir. Boosting ile yeniden ağırlıklandırılmış eğitim verilerine sınıflandırma algoritmalarından bir tanesi sıra ile uygulanır ve elde edilen sonuçlar ağırlıkları ile beraber oylanarak tek bir sınıflandırma sonucu elde edilir. Şekil 3.9.'da Boosting algoritmalarının genel yapısı verilmiştir.



Şekil 3.9. Boosting algoritmalarının genel yapısı

a) AdaBoost Algoritması

AdaBoost veya AdaBoostM1 algoritmasında, ilk başta eğitim veri setindeki tüm örneklerin ağırlıkları aynı olarak belirlenir ve zayıf sınıflandırıcı eğitilerek veriler sınıflandırılır. Sınıflandırma sonucuna göre yanlış sınıflandırılan örneklerin ağırlıkları artırılır, doğru sınıflandırılan örneklerin ağırlıkları ise azaltılır. Daha sonra ağırlıkları

değiştirilmiş örnekler kullanılarak bir sonraki sınıflandırıcı eğitilir. Belirlenen sınıflandırıcı sayısına ulaşana kadar bu işlemler tekrar edilir. En sonunda ağırlıklar ve sınıflandırma sonuçları kullanılarak nihai bir sınıflandırma sonucuna varılır (Mathworks 2018). Çizelge 3.2.'de AdaBoost algoritması verilmiştir.

Çizelge 3.2. AdaBoost algoritması

Girişler:	Veri seti $Z = (z_1, z_2, \dots, z_N), z_i = (x_i, y_i), x_i \in X$ ve $y_i \in \{-1, +1\}$ M, maksimum sınıflandırıcı sayısı
Çıktılar:	Sınıflandırıcı $H: X \rightarrow \{-1, 1\}$
A1.	Başlangıç ağırlıklarını belirle $w_i^{(1)} = 1/N, i \in \{1, 2, \dots, N\}$ ve $m = 1$
A2.	While $m \leq M$ do
A3.	$H_m: X \rightarrow \{-1, 1\}$ sınıflandırıcısını elde etmek için zayıf sınıflandırıcıyı Z üzerinde eğit
A4.	H_m 'nin ağırlıklı hatası olan $err_m = \sum_{i=1}^N w_i^{(m)} h(-y_i H_m(x_i))$ 'yi hesapla
A5.	$\alpha_m = \frac{1}{2} \log \left(\frac{1-err_m}{err_m} \right)$ 'yi hesapla
A6.	Her bir örnek için ağırlıkları değiştir $v_i^{(m)} = w_i^{(m)} \exp(-\alpha_m y_i H(x_i))$
A7.	Ağırlıkları normalize et: $S_m = \sum_{j=1}^N v_j$ ve $i = 1, 2, \dots, N$, için $w_i^{(m+1)} =$
A8.	$v_i^{(m)} / S_m$ 'yi hesapla
A9.	m 'yi arttır: $m \leftarrow m + 1$
A10.	End while
A11.	Nihai sınıflandırıcı, $H(x) = \text{sgn}(\sum_{j=1}^M \alpha_j(x) H_j(x))$ 'yi elde et

a) Logit Boost Algoritması

Logit Boost algoritması eksponansiyel kaybı azaltmak yerine negatif şartlı logaritmik benzerliği en aza indirmeye çalışır. Çizelge 3.3.'de Logit Boost algoritması verilmiştir.

b) Gentle AdaBoost

Gentle AdaBoost, AdaBoost algoritmasının geliştirilmiş bir versiyonu olmakla beraber bu algoritma daha stabil ve daha güvenilirdir (Mathworks 2018). Çizelge 3.4.'de Gentle AdaBoost algoritması verilmiştir.

Çizelge 3.3. Logit Boost algoritması

Girişler:	Veri seti $Z = (z_1, z_2, \dots, z_N), z_i = (x_i, y_i), x_i \in X$ ve $y_i^* \in \{0, +1\}$ M, maksimum sınıflandırıcı sayısı
Çıkışlar:	Sınıflandırıcı $H: X \rightarrow \{-1, 1\}$
A1.	Başlangıç ağırlıklarını belirle $w_i = 1/N, i \in \{1, 2, \dots, N\}$
A2.	For $m = 1$ 'den M 'ye && while $H_m \neq 0$ do
A3.	$z_i = \frac{y_i^* - p(x_i)}{p(x_i)(1 - p(x_i))}$ 'yi ve ağırlıkları, $w_i = p(x_i)(1 - p(x_i))$ 'yi hesapla.
A4.	$H_m(x)$ 'i z_i 'nin ağırlıklı en küçük karelerini ve w_i ağırlıklarını kullanarak eğit.
A5.	$H(x) = H(x) + \frac{1}{2} H_m(x)$ 'i ve $p(x) = \frac{\exp(H(x))}{\exp(H(x)) + \exp(-H(x))}$ 'i güncelle.
A6.	End for
A7.	Nihai sınıflandırıcı, $H(x) = \text{sgn}(\sum_{j=1}^M \alpha_j(x) H_j(x))$ 'yı elde et.

Çizelge 3.4. Gentle AdaBoost algoritması

Girişler:	Veri seti $Z = (z_1, z_2, \dots, z_N), z_i = (x_i, y_i), x_i \in X$ ve $y_i \in \{-1, +1\}$ M, maksimum sınıflandırıcı sayısı
Çıkışlar:	Sınıflandırıcı $H: X \rightarrow \{-1, 1\}$
A1.	Başlangıç ağırlıklarını belirle $w_i = 1/N, i \in \{1, 2, \dots, N\}$
A2.	For $m = 1$ 'den M 'ye do
A3.	$H_m(x)$ 'i y_i 'nin ağırlıklı en küçük karelerini ve w_i ağırlıklarını kullanarak eğit.
A4.	$H(x) \leftarrow H(x) + H_m(x)$ 'i güncelle.
A5.	$w_i \leftarrow w_i \exp(-y_i H_m(x_i))$ 'yi güncelle ve normalize et: $\sum_i w_i = 1$
A6.	End for
A7.	Nihai sınıflandırıcı, $H(x) = \text{sgn}(\sum_{j=1}^M \alpha_j(x) H_j(x))$ 'yı elde et

c) AdaBoostM2

AdaBoostM2, AdaBoost algoritmasının ikiden fazla sınıf için kullanılması için değiştirilmiş halidir. AdaBoost algoritmasından farklı olarak hata Denklem 3.37'deki gibi hesaplanır (Mathworks 2018).

$$err_m = \frac{1}{2} \sum_{i=1}^N \sum_{k \neq y_i} w_{i,k}^{(m)} (1 - h_m(x_i, y_i) + h_m(x_i, k)) \quad (3.37)$$


Burada, k sınıf sayısını ve err_m hatayı ifade eder.

d) RUSBoost Algoritması

RUSBoost algoritması her sınıfta farklı sayıda örnek sayısı içeren, yani dengesiz verilere sahip uygulamalar için geliştirilmiştir. Bu algoritma AdaBoostM2'nin değiştirilmiş bir versiyonudur. RUSBoost algoritması, tüm sınıflardaki en az örnek sayısını tespit eder ve tüm sınıflar için sadece belirlenen sayıda örneği dikkate alarak işlemler yapar (Mathworks 2018).

3.9.3. Bagging Algoritması

Bootstrap, genel amaçlı ve örnek temelli bir istatistiksel yöntemdir. Bu yöntemde, temel bir veri setinden rastgele, her seferinde eşit sayıda ve tekrar yerine koymak suretiyle veri alınarak ayırık eğitim verileri oluşturulur.



Şekil 3.10. Bagging algoritmasının genel yapısı

Bagging, bootstrap örnekleme kullanılarak sınıflandırıcıların doğruluğunu arttırmak için kullanılan bir tekniktir. $Z = \{z_1, z_2, \dots, z_N\}$, N boyutlu eğitim veri seti, $z_i = (x_i, y_i)$, veri集中的 her bir örnek, y_i ise i 'nci örneğin sınıfı olsun. Bootstrap

kullanılarak $Z_b \subseteq Z, b = 0, 1, \dots, B$ olmak üzere B adet alt veri seti oluşturularak B adet sınıflandırıcı eğitilir. Eğitilen bu sınıflandırıcılar test verisini sınıflandırmada kullanılır. Çoğunluk oyunu alan sınıf nihai sınıf olarak belirlenir. Şekil 3.10.'da Bagging algoritmasının genel yapısı ve Çizelge 3.5.'te Bagging algoritması verilmiştir.

Çizelge 3.5. Bagging algoritması

Girişler:	Veri seti $Z = (z_1, z_2, \dots, z_N), z_i = (x_i, y_i), x_i \in X$ ve $y_i \in \{-1, +1\}$ B, bootstrap örnek sayısı
Çıktılar:	Sınıflandırıcı $H: X \rightarrow \{-1, 1\}$
A1.	For $m = 1$ 'den B 'ye do
A2.	Z_b, b 'ninci bootstrap örneğini elde etmek için Z 'den rastgele N tane örnek seç (geri yerine koyarak)
A3.	Z_b 'yi kullanarak H_b sınıflandırıcısını eğit
A4.	End for
A5.	Nihai sınıflandırıcı, $H(x) = \text{sgn}(\sum_{b=1}^B H_b(x))$ 'yı çoğunluk oyu ile elde et

3.10. Bayesian Optimizasyonu

Makine öğrenmesi algoritmaları genellikle model parametrelerinin hassas bir şekilde ayarlanmasını gerektirir. Bu ayarlama, yazılı kuralları olmayan, uzman bilgisi gerektiren ve genellikle deneme yanılma ile yapılmakla beraber çözülmeye çalışılan problemin tipine göre büyük farklılıklar göstermektedir. Bayesian optimizasyonu öğrenme algoritmalarının performansını optimize etmek amacıyla model parametrelerini otomatik bir şekilde ayarlamaya yarayan bir optimizasyon algoritmasıdır. Bu optimizasyon hakkında detaylı bilgi (Chandradevan 2017) yaptığı çalışmada bulunmaktadır.

3.11. Kullanılan Veriler

Yapılan önceki çalışmaların çoğundaki en büyük eksiklik kullanılan verilerin kısıtlı sayıda ve gürültüsüz olmasıydı. Bu amaçla pek çok kurum tarafından desteklenen physionet.org, geniş bir veri bankası oluşturmak ve dünyadaki araştırmacıları normal ve anormal PCG kayıtlarının sınıflandırılması konusunda çalışma yapmaları için teşvik etmek amacıyla 2016 yılında bir yarışma düzenledi. Yarışma kapsamında oluşturulan

veri bankasının eğitim seti “physionet.org/challenge/2016” adresinden indirilebilmektedir.

Bu yeni veri bankası, üç kıtadan, yedi ülkeden ve yedi araştırmacı takım tarafından toplanan toplam sekiz farklı veri setinin bir araya getirilmesinden oluşmaktadır. Verilerin toplanması 10 yıldan fazla sürdüğü için kullanılan donanım, verilerin kalitesi, hasta tipleri, kayıt için kullanılan vücut bölgesi temel farklılıklar göstermektedir. Aşağıda bir araya getirilen sekiz farklı veri bankasına ilişkin bilgiler verilmiştir (Liu 2016). Veri bankasına ait detaylar Çizelge 3.6.’da verilmiştir.

Çizelge 3.6. Veri setleri ve özellikleri

Veri Seti	Denek Tipi	Denek Sayısı	Yaş	Kayıt Sayısı	Kayıt Uzunluğu	Örnekleme Frekansı
MITHSDB	Normal	38	Bilinmiyor	117	33±5	44100 Hz
	Anormal	83	Bilinmiyor	292	33±5	44100 Hz
AADHSDB	Normal	121	Bilinmiyor	544	8	4000 Hz
	Anormal	30	Bilinmiyor	151	8	4000 Hz
AUTHHSDB	Normal	11	29±8	11	47±25	4000 Hz
	Anormal	34	77±9	34	56±34	4000 Hz
TUTHSDB	Normal	28	Bilinmiyor	174	15	4000 Hz
	Anormal	16	Bilinmiyor		15	4000 Hz
UHAHSDB	Normal	19	18-40	19	14±5	8000 Hz
	Anormal	36	44-90	60	16±9	8000 Hz
DLUTHSDB	Normal	174	25±3	338	209±78	800-22050 Hz
	Anormal	335	60±12	335	17±12	8000 Hz
SUAHSDB	Normal	79	56±16	81	33±5	8000 Hz
	Anormal	33	56±16	33	33±5	8000 Hz
SSHHSDB	Normal	12	Bilinmiyor	12	36±12	8000 Hz
	Anormal	23	Bilinmiyor	23	36±12	8000 Hz
Toplam	—	1072	—	2224	—	—

3.11.1. MIT Kalp Sesi Veri Seti

Massachusetts Teknoloji Enstitüsü kalp sesi veri seti (MITHSDB) Prof. John Guttag, Dr. Zeeshan Syed ve arkadaşları tarafından oluşturulmuştur. Kalp sesleri, EKG ile eşzamanlı bir şekilde 20-20000 Hz frekans tepkisine sahip Welch Allyn Meditron elektronik stetoskop (Skaneateles Falls, New York, USA) kullanılarak kaydedilmiştir. Kaydedilen toplam 409 PCG kaydı 44100 Hz örnekleme frekansı ile örneklenmiştir. 121 tane denekten alınan kayıtlar kaydedilirken vücudun farklı bölgeleri kullanılmış ve her bir denekten birden fazla kayıt alınmıştır. Denekler beş gruba ayrılarak kayıt işlemi gerçekleştirilmiştir.

- Normal kontrol grubu: 38 denek ve 117 kayıt
- Mitral kapakçık kayması: 37 denek ve 118 kayıt
- Zararsız üfürümler: 34 denek ve 118 kayıt
- Aortik hastalık: 5 denek ve 17 kayıt
- Çeşitli kalp hastalıkları: 7 denek ve 23 kayıt

Her bir deneğin kalp sağlığı durumu Massachusetts General Hastanesinde yapılan EKG incelemesi sonucu doğrulanmıştır. Kayıt işlemi ev ziyaretlerinde veya hastane ortamında kontrolsüz bir çevrede gerçekleştirilmiştir. Dolayısıyla pek çok kayıt, konuşma, köpek havlaması, çocuk gürültüleri, stetoskop hareketleri ve nefes alma gibi gürültü kaynakları tarafından bozulmaya uğramıştır. Kayıtların uzunluğu 9 ile 37 saniye (ortalama: 33 s) arasında değişmektedir (Liu 2016).

3.11.2. Aalborg Üniversitesi Kalp Sesi Veri Seti

Aalborg Üniversitesi kalp sesi veri seti (AADHSDB) Schmidt ve ark. (2015) tarafından oluşturulmuştur. Kalp sesleri vücudun tek bir bölgesinden 20-1000 Hz frekans tepkisine sahip Littmann E4000 elektronik stetoskop (3M, Maplewood, Minnesota) kullanılarak kaydedilmiştir. Kaydedilen toplam 695 PCG kaydı 4 kHz örnekleme frekansı ile örneklenmiştir. Veri alınan toplam 151 deneğin kalp sağlığı Aalborg Hastanesi kardiyoloji birimi tarafından belirlenmiştir. Deneklerin 30 tanesinin kalp kapakçığı problemine sahip olduğu, diğer deneklerin sağlıklı oldukları tespit edilmiştir. Sekiz saniyelik veriler kaydedilirken deneklerin normal nefes almaları istenmiştir (C. Liu 2016).

3.11.3. Aristotle Üniversitesi Kalp Sesi Veri Seti

Aristotle Üniversitesi kalp sesi veri seti (AUTHHSDB) (Papadaniil ve Hadjileontiadis 2014) tarafından oluşturulmuştur. Kalp sesleri, hastane ortamında işaretleri güçlendiren ve filtrelemeyen özel yapım bir stetoskop ile 4 kHz örnekleme frekansı ile kayıt edilmiştir. Ekokardiyogram ile doktorlar tarafından hastalık durumları tespit edilen 18 ile 90 yaş arasındaki 45 deneğin PCG kaydı veri setinde yer almaktadır. Tüm deneklerin aynı vücut bölgesinden, denek başına bir kayıt alınmıştır ve bu kayıtların uzunluğu 10 ile 122 s (ortalama: 50 s) arasında (Liu 2016).

3.11.4. Toosi Teknoloji Üniversitesi Kalp Sesi Veri Seti

Toosi Teknoloji Üniversitesi kalp sesi veri seti (TUTHSDB) (Naseri ve Homaeinezhad 2013) tarafından oluşturulmuştur. Bu veri seti 28'i sağlıklı ve 16'sı çeşitli kalp kapakçığı problemlerine sahip deneklerin kalp sesini içermektedir. Toplam 174 PCG kaydına sahip bu veri setinde, kayıtlar, Littmann 3200 elektronik stetoskop (3M, Maplewood, Minnesota) ile 4 kHz örnekleme frekansı ile vücudun dört farklı bölgesinden kaydedilmiştir ve her bir kaydın uzunluğu 15 saniyedir (Liu 2016).

3.11.5. Haute Alsace Üniversitesi Kalp Sesi Veri Seti

Haute Alsace Üniversitesi kalp sesi veri seti (UHAHSDB) (Moukadem ve ark. 2013) tarafından oluşturulmuştur. Kalp sesleri, Infral şirketi tarafından üretilen prototip stetoskop kullanılarak 8 kHz örnekleme frekansı ile örneklenerek kaydedilmiştir. Bu veri seti 39'u normal, 40'ı patolojik olmak üzere toplam 79 tane PCG kaydı içermektedir. Hem erkek hem de dişi olan deneklerin yaşları 18 ile 90 arasında değişmektedir. PCG kayıtlarının uzunluğu 6 ile 49 saniye arasında değişmektedir (Liu 2016).

3.11.6. Dalian Teknoloji Üniversitesi Kalp Sesi Veri Seti

Dalian Teknoloji Üniversitesi kalp sesi veri seti (DLUTHSDB) (Tang ve ark. 2012) tarafından oluşturulmuştur. Yaşları 10 ile 88 arasında değişen 227'si dişi, 108'i erkek olan ve çeşitli kalp hastlıklarına sahip deneklerin kalp sesi hastane ortamında elektronik stetoskop kullanılarak 8 kHz örnekleme frekansı ile kaydedilmiştir. Her bir denekten bir kayıt alınarak toplam 335 anormal PCG kaydı elde edilmiştir. Bu kayıtların uzunluğu 3 ile 98 saniye arasında değişmektedir. Bu deneklerin kalp sağlığı uzman kardiyologlar tarafından tespit edilmiştir. Yaşları 4 ile 35 arasında değişen 2'si dişi, 172'si erkek olan sağlıklı deneklerin kalp sesi üniversitenin Biyomedikal Mühendislik Laboratuvarında mikrofon sensörü (MLT201, ADInstrument, Australia) veya piezoelektrik sensor (Xinhangxingye Technology Co. Ltd, China) ile çeşitli örnekleme frekansları ile örneklenerek kaydedilmiştir. Bu kayıtların uzunluğu 27.5 ile 312.5 saniye arasında değişmektedir. Her bir denekten birden fazla kayıt alınarak toplam 338 anormal PCG kaydı elde edilmiştir. Kayıtların 218'i denekler dinlenirken, 120'si bir aktiviteden hemen sonra kaydedilmiştir (Liu 2016).

3.11.7. Şiraz Üniversitesi Kalp Sesi Veri Seti

Şiraz Üniversitesi kalp sesi veri seti (SUAHSDB) (Samieinasab ve Sameni 2015) tarafından oluşturulmuştur. PCG kayıtları 79'u sağlıklı, 33'ü çeşitli kalp hastalığına sahip denegin (toplam 69 dişi, 43 erkek, 16 ile 88 yaş aralığında) kalp sesi JABES dijital elektronik stetoskop (GS Technology Co. Ltd, Güney Kore) ile 8 kHz örnekleme frekansı ile kaydedilmiştir. Kayıt yapılırken dinlenmiş olan deneklerin normal nefes almaları istenmiştir. Hasta deneklerden birer, sağlıklı deneklerden üçer kayıt alınarak toplam 114 (81 normal, 33 anormal) PCG kaydı elde edilmiştir. Kayıtların uzunluğu 30 ile 60 saniye arasında değişmektedir (Liu 2016).

3.11.8. Skejby Sygehus Hastanesi Kalp Sesi Veri Seti

Skejby Sygehus Hastanesi kalp sesi veri seti (SSHHSDB) 12'si normal, 23'ü kalp kapakçığı problemine sahip toplam 35 denekten elde edilmiştir. Kayıtlar 8 kHz örnekleme frekansına ve 15 ile 69s uzunluğuna sahiptir (Liu 2016).

3.11.9. Yarışma Verilerinin Oluşturulması

Yarışma verileri hazırlanırken yukarıda belirtilen veri setlerindeki kayıtların örnekleme frekansları farklı olduğundan tüm kayıtlar örnekleme frekansı 2 kHz'e olacak şekilde yeniden örneklendirilerek bir araya getirilmiştir. DLUTHSDB veri setine ait normal 338 PCG kaydı çok uzun olduğundan daha kısa parçalara ayrılarak toplam 4517 PCG kaydı elde edilmiştir. Veri setleri a'dan i'ye kadar yeniden isimlendirilmiş ve eğitim ile test veri setleri şeklinde ikiye ayrılmıştır. Her iki veri setinde de PCG kayıtları normal ve anormal şeklinde sınıflandırılmıştır. Her iki setteki normal ve anormal PCG kayıtlarının sayısı birbirinden farklıdır. Detaylar Çizelge 3.7.'da verilmiştir.

3.11.10. Çalışma Verilerinin Oluşturulması

Yarışma verilerinden sadece eğitim verileri yarışmanın internet sitesinden indirilebildiğinden bu çalışmada sadece yarışma eğitim veri seti kullanılmıştır. Yarışma eğitim veri seti (bu noktadan sonra çalışma veri seti olarak nitelendirilecektir) yeniden düzenlenerek beşli çapraz doğrulama kullanımı için uygun hale getirilmiştir. Yani verilerden beş kopya oluşturulmuş ve her bir kopya beş parçaya bölünmüştür. Dört parça eğitim, bir parça ise test için kullanılmıştır. Her kopya için bu işlem

tekrarlandıktan sonra çıkan sonuçların ortalaması alınarak başarı oranı hesaplanmıştır. Böylece tüm verilerin hem eğitim hem de test için kullanılması sağlanmıştır. Detaylar Çizelge 3.8.'de verilmiştir.

Çizelge 3.7. Yarışma verileri


Set	Alt Set	Veri Kaynağı	Denek Sayısı	Kayıt Sayısı	Anormal (%)	Normal (%)	Kesin Olmayan
Eğitim	eğitim-a	MITHSDB	121	409	67.5	28.4	4.2
	eğitim-b	AADHSDB	106	490	14.9	60.2	24.9
	eğitim-c	AUTHHSDB	31	31	64.5	22.6	12.9
	eğitim-d	UHAHSDB	38	55	47.3	47.3	5.5
	eğitim-e	DLUTHSDB	356	2141	7.1	86.7	6.2
	eğitim-f	SUAHSDB	112	114	27.2	68.4	4.4
	Toplam		764	3240	18.1	73	8.8
Test	test-b	AADHSDB	45	205	15.6	48.8	35.6
	test-c	AUTHHSDB	14	14	64.3	28.6	7.1
	test-d	UHAHSDB	17	24	45.8	45.8	8.3
	test-e	DLUTHSDB	153	883	6.7	86.4	6.9
	test-g	TUTHSDB	44	116	18.1	81.9	0
	test-i	SSHHSDB	35	35	60	34.3	5.7
	Toplam		308	1277	12	77.1	10.9

Çizelge 3.8. Çapraz doğrulama için çalışma eğitim veri seti ve test veri seti

Veri Seti	Alt Veri Seti	Normal	Anormal	Toplam
Eğitim	a	94	234	328
	b	309	84	393
	c	6	19	25
	d	22	22	44
	e	1566	146	1712
	f	64	27	91
	Toplam	2061	532	2593
Test	a	23	58	81
	b	77	20	97
	c	1	5	6
	d	5	6	11
	e	392	37	429
	f	16	7	23
	Toplam	514	133	647

3.12. Algoritmanın Yapısı


Önerilen algoritma Matlab R2017b programında yazılmış olup önışlem, özellik çıkarma-1, veri seti sınıflandırması, segmentasyon, özellik çıkarma-2, özellik seçme ve nihai sınıflandırma olmak üzere yedi temel aşamadan oluşmaktadır. Önerilen algoritmanın blok diyagramı Şekil 3.11’de verilmiştir.



Şekil 3.11. Önerilen algoritmanın blok diyagramı

3.12.1. Önişlem

Çoğu örüntü sınıflandırma algoritmalarının önişlem aşamasında gürültüden arındırma, filtreden geçirme, yeniden örneklendirme ve normalizasyon gibi işlemler yapılır. Bu algoritmanın önişlem aşamasında sırasıyla, PCG kayıtlarındaki gürültüden kaynaklı sivri uçları yok etmek amacıyla gürültüden arındırma ve normalizasyon işlemleri yapılmıştır. Şekil 3.12’de önerilen algoritmanın önişlem aşamasının blok diyagramı verilmiştir.




Şekil 3.12. Önerilen algoritmanın önişlem aşamasının blok diyagramı

a) Gürültüden Arındırma

Bu adımda amaç PCG kaydı alınırken çeşitli nedenlerle işaretde oluşan sivri uçların yok edilmesidir. Bunun için (Schmidt ve ark. 2010) tarafından geliştirilen ve kısa açıklaması aşağıda adımlar halinde verilen metot kullanılmıştır. Şekil 3.13.’te sivri uçları yok edilmiş bir PCG kaydı verilmiştir.

- 1) İşaret 500 ms’lik bölütlere ayrılır.
- 2) Her bölütteki maksimum mutlak genlik (MMG) bulunur.
- 3) Eğer en az bir tane MMG, tüm MMG’lerin ortanca değerinin üç katını geçerse a’den e’ye kadar olan işlemler uygulanır, yoksa dördüncü adıma geçilir.
 - a) En yüksek MMG değerine sahip bölüt seçilir.
 - b) Seçilen bölütte sivri ucun tepe noktası MMG’nin konumu olarak tanımlanır.
 - c) Sivri ucun başlangıç noktası, MMG’den önce işaretin en son sıfırdan geçtiği nokta olarak tanımlanır.
 - d) Sivri ucun son bulunduğu nokta, MMG’den sonra işaretin ilk defa sıfırdan geçtiği nokta olarak tanımlanır.
 - e) Tanımlanan sivri uç sıfırlar ile değiştirilir.
- 4) İşlem tamamlanır.



Şekil 3.13. Sivri uçlu ve sivri ucu yok edilmiş iki PCG kaydı

b) Normalizasyon

Algoritmanın bu adımında Bölüm 3.2.’de açıklanan min-maks normalizasyonu kullanılmıştır.

3.12.2. Özellik Çıkarma-1

Bu adımında hangi PCG kaydının hangi veri setine ait olduğunu belirleyecek olan sınıflandırıcı-1’de kullanılmak üzere her PCG kaydının zaman, frekans ve zaman-frekans uzayına ait çeşitli özellikleri çıkarılmıştır.

a) Zaman Uzayına Ait Özellikler

İşaretin zaman uzayına ait istatistiksel altı özelliği aşağıda verilmiştir.


- Ortalama
- Minimum
- Maksimum
- Standart sapma
- Basıklık
- Çarpıklık

b) Frekans Uzayına Ait Özellikler

PCG kayıtlarının frekans uzayına ait özellikleri elde edilirken işareten ziyade işarettaki gürültülerin bulunduğu frekans aralıkları göz önünde bulundurularak işaretin 0-200 Hz ile 800-1000 Hz frekans aralıklarındaki güç spektrumu ayrık Fourier dönüşümü kullanılarak elde edilmiştir. Şekil 3.14-15'te farklı veri setlerinden alınan iki PCG kaydının 0-200 Hz ve 800-1000 Hz frekans aralığındaki güç spektrumları verilmiştir

c) Zaman-frekans Uzayına Ait Özellikler


İşaretlerin hem frekans hem de zaman uzayına ait özelliklerinden faydalanmak amacıyla ayrıca işaretlerin mel frekansı kepstrum katsayıları elde edilmiştir. Şekil 3.16-17.'de iki veri setine ait iki kaydın mel frekansı kepstrum katsayıları verilmiştir. Frekans ve zaman-frekans uzayına ait özellikler Çizelge 3.9.'da verilmiştir.



Şekil 3.14. İki farklı veri setine ait PCG kaydının 0-200 Hz aralığındaki güç spektrumu

Böylece, PCG kayıtlarının veri setlerine göre sınıflandırılmasında kullanılmak üzere yedisi zaman, 16'sı frekans ve 112'si zaman-frekans uzayına ait olmak üzere


toplamda 135 adet özellik elde edilmiştir. Bu özellikler sınıflandırıcının hem eğitilmesinde hem de test edilmesinde kullanılmıştır.




Şekil 3.15. İki farklı veri setine ait PCG kaydının 0.8-1 kHz aralığındaki güç spektrumu

Çizelge 3.9. PCG kayıtlarının frekans ve zaman-frekans uzayına ait özellikleri

0-200 Hz Frekans Bandı	800-1000 Hz Frekans Bandı	MFCC (14 seviye)
Minimum	Minimum	Maksimum
Maksimum	Maksimum	Ortalama
Ortalama	Ortalama	Standart Sapma
Ortanca	Ortanca	Varyans
Çarpıklık	Çarpıklık	Çarpıklık
Basıklık	Basıklık	Basıklık
Etkin Değer	Etkin Değer	Etkin Değer
Etkin Değer/Maksimum	Etkin Değer/Maksimum	Entropi
Toplam: 9 adet	Toplam: 8 adet	Toplam: $8 \times 14 = 112$ adet



Şekil 3.16. Veri seti a'ya ait PCG kaydı ve bu kayda ait MFCC



Şekil 3.17. Veri seti e'ye ait PCG kaydı ve bu kayda ait MFCC

3.12.3. Veri Seti Sınıflandırması

Bu aşamanın amacı altı adet veri setinden alınan kalp sesi kayıtlarının altı sınıfa ayrılmasıdır. Böylece, sonraki adımlarda her veri setine ait kayıtlar için farklı özellikler seçilmesi mümkün olacaktır. Ayrıca, her veri seti için ayrı ayrı eğitilen sınıflandırıcıların aynı veri setine ait kayıtların sınıflandırılması için kullanılması sağlanmış olacaktır.

Bu adımda kullanılan sınıflandırıcı metotları topluluğu oluşturulurken AdaBoostM2 algoritması ile beraber karar ağacı kullanıldı. Bu sınıflandırıcı beşli çapraz doğrulamanın her adımında her biri 135 adet özelliğe sahip 2592 adet kayıt ile eğitilirken 648 adet kayıt ile test edilmiştir. Sınıflandırıcının parametreleri ayarlanırken Bayesian optimizasyonu kullanılmıştır. Çapraz doğrulamanın ilk aşamasında eğitilmiş ve optimize edilmiş sınıflandırıcıya ait detaylar Çizelge 3.10.'de verilmiştir.

Çizelge 3.10. Veri seti sınıflandırıcısına ait detaylar

Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	AdaBoostM2
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	439
Öğrenme Oranı	0,9985


3.12.4. Segmentasyon

Bölüm 3.3'te de tanımlandığı üzere bir PCG işaretinin temel kalp seslerinin konumunun tespit edilmesine segmentasyon denir. Algoritmanın bu adımında Springer'in segmentasyon algoritması kullanılarak PCG işaretlerinin S1, sistol, S2 ve diastol bölgelerinin başlangıç ve bitiş noktaları tespit edilmiştir. Böylelikle, algoritmanın özellik çıkarma-2 adımında bu bölgelerdeki anormalliklerin tespit edilmesine yardımcı olabilecek özelliklerin çıkarılması mümkün olmaktadır.

3.12.5. Özellik Çıkarma-2

Şekil 3.11'den de görüleceği gibi algoritmanın bu aşaması Özellik Çıkarma-2A ve Özellik Çıkarma-2B olmak üzere iki kısımdan oluşmaktadır. Birinci kısımda segmentasyonu yapılmış PCG kayıtlarının kalp döngüsü, zaman, frekans ve zaman-

frekans özellikleri, ikinci kısımda ise segmentasyonu yapılmamış PCG kayıtlarının zaman, frekans ve zaman-frekans özellikleri çıkarılmıştır.



Şekil 3.18. Springer'in algoritmasıyla segmentasyonu yapılmış bir PCG işareti

a) Özellik Çıkarma-2A

Bu kısımda, segmentasyon aşamasında dört bölgeye ayrılan ve bir örneği Şekil 3.18.'de verilen PCG kayıtlarının özellikleri çıkarılmıştır. Çıkarılan özellikler aşağıda verilmiştir (20 kalp döngüsü + 56 zaman + 336 zaman – frekans = 412 özellik).

Kalp döngüsü özellikleri: PCG kayıtlarının hastalıkla yakından ilişkili olan temel kalp sesi bölgelerinin uzunlukları ve genlikleri ile ilgili özellikler (20 özellik):

- Her kalp döngüsündeki S1 sürelerinin ortalaması,
- Her kalp döngüsündeki S1 sürelerinin standart sapması,
- Her kalp döngüsündeki sistol sürelerinin ortalaması,
- Her kalp döngüsündeki sistol sürelerinin standart sapması,
- Her kalp döngüsündeki S2 sürelerinin ortalaması,
- Her kalp döngüsündeki S2 sürelerinin standart sapması,

- Her kalp döngüsündeki diastol sürelerinin ortalaması,
- Her kalp döngüsündeki diastol sürelerinin standart sapması,
- Her kalp döngüsünün sürelerinin ortalaması,
- Her kalp döngüsünün sürelerinin standart sapması,
- Her sistol sürelerinin içinde bulunduğu kalp döngüsünün sürelerine oranlarının ortalaması,
- Her sistol sürelerinin içinde bulunduğu kalp döngüsünün sürelerine oranlarının standart sapması
- Her diastol sürelerinin içinde bulunduğu kalp döngüsünün sürelerine oranlarının ortalaması,
- Her diastol sürelerinin içinde bulunduğu kalp döngüsünün sürelerine oranlarının standart sapması
- Her kalp döngüsündeki sistol sürelerinin diastol sürelerine oranlarının ortalaması,
- Her kalp döngüsündeki sistol sürelerinin diastol sürelerine oranlarının standart sapması
- Her kalp döngüsündeki sistolün ortalama mutlak genliğinin diastolün ortalama mutlak genliğine oranlarının ortalaması
- Her kalp döngüsündeki sistolün ortalama mutlak genliğinin diastolün ortalama mutlak genliğine oranlarının standart sapması
- Her kalp döngüsündeki diastolün ortalama mutlak genliğinin S2'nin ortalama mutlak genliğine oranlarının ortalaması
- Her kalp döngüsündeki diastolün ortalama mutlak genliğinin S2'nin ortalama mutlak genliğine oranlarının standart sapması

Zaman uzayına ait özellikler: PCG kayıtlarının her kalp döngüsündeki dört bölgenin aşağıda verilmiş istatistiksel özelliklerinin ortalaması ve standart sapması (4 bölge $\times$ 7 özellik $\times$ 2 özellik = 56 özellik):

- Etkin değer
- Basıklık
- Ortalama
- Standart sapma

- Varyans
- Entropi
- Maksimum değer

Zaman-frekans uzayına ait özellikler: PCG kayıtlarının her kalp döngüsündeki dört bölgenin 13 seviyeli (+1 filtre enerjisi) mel frekansı katsayılarının aşağıdaki özelliklerinin ortalaması ($4 \text{ bölge} \times 14 \text{ katsayı} \times 6 \text{ özellik} = 336 \text{ özellik}$):

- Etkin değer
- Basıklık
- Çarpıklık
- Ortalama
- Standart sapma
- Varyans

b) Özellik Çıkarma-2B

Bu kısımda segmentasyonu yapılmamış PCG kayıtlarının zaman, frekans ve zaman-frekans özellikleri çıkarılmıştır. Çıkarılan özellikler aşağıda verilmiştir ($10 \text{ zaman} + 10 \text{ frekans} + 148 \text{ zaman - frekans} = 168 \text{ özellik}$).

Zaman uzayına ait özellikler: PCG kayıtlarının zaman uzayına ait aşağıda verilen istatistiksel özellikleri (10 özellik)

- Etkin değer
- Sıfırdan geçme oranı
- Basıklık
- Çarpıklık
- Ortalama
- Standart sapma
- Varyans
- Entropi
- Maksimum değer
- Ortanca

Frekans uzayına ait özellikler: PCG kayıtlarının ayrık Fourier dönüşümü ile elde edilen güç spektrumunun aşağıdaki istatistiksel özellikleri (10 özellik):

- Etkin değer
- Toplam harmonik bozulma
- Basıklık
- Çarpıklık
- Ortalama
- Standart sapma
- Varyans
- Entropi
- Maksimum değer
- Ortanca

Dalgacık özellikleri: PCG kayıtlarının üçüncü ve dördüncü seviye “db4” dalgacığı ile elde edilen dalgacık dönüşümünün birinci, ikinci ve üçüncü seviye detay ile üçüncü seviye yaklaşım katsayılarının aşağıdaki istatistiksel özellikleri (4 bant $\times$ 9 özellik = 36 özellik):

- Etkin değer
- Sıfırdan geçme oranı
- Basıklık
- Çarpıklık
- Ortalama
- Standart sapma
- Varyans
- Entropi
- Ortanca

MFCC özellikleri: PCG kayıtlarının 13 seviyeli (+1 filtre enerjisi) mel frekansı keppstrum katsayılarının aşağıdaki istatistiksel özellikleri (14 katsayı $\times$ 8 özellik = 112 özellik):

- Etkin değer
- Basıklık

- Çarpıklık
- Ortalama
- Standart sapma
- Varyans
- Entropi
- Maksimum değer

3.12.6. Özellik Seçme


Algoritmanın bu aşamasında, her PCG kaydı için elde edilen özellik vektörünün boyutları Bölüm 3.8.'de verilen ardışık geri yönde özellik seçme algoritması kullanılarak azaltılmıştır. Özellik seçme algoritması kullanıldıktan sonra elde edilen yeni özellik sayıları Çizelge 3.11.'de verilmiştir.

Çizelge 3.11. Veri setlerine göre seçilen özellik sayısı

Veri Seti	Özellik-2A	Özellik-2B
a	410	164
b	411	166
c	410	166
d	411	168
e	410	166
f	411	168

3.12.7. Nihai Sınıflandırma

Her veri seti için ikişer adet sınıflandırıcı olmak üzere toplamda 12 adet sınıflandırıcı metotları topluluğu (her veri iki adet özellik vektörüne sahip olduğundan her veri seti için ikişer adet sınıflandırıcı) içeren bu aşamanın amacı PCG kayıtlarını normal veya anormal şeklinde sınıflandırmaktır. Bu 12 adet sınıflandırıcı çiftler halinde sadece bir veri setine ait veriler kullanılarak eğitilmiş ve Bayesian optimizasyonu kullanılarak optimize edilmiştir. Sınıflandırıcı-a'nın optimizasyonu ile optimize edilmesine ilişkin grafik Şekil 3.19.'da verilmiştir.

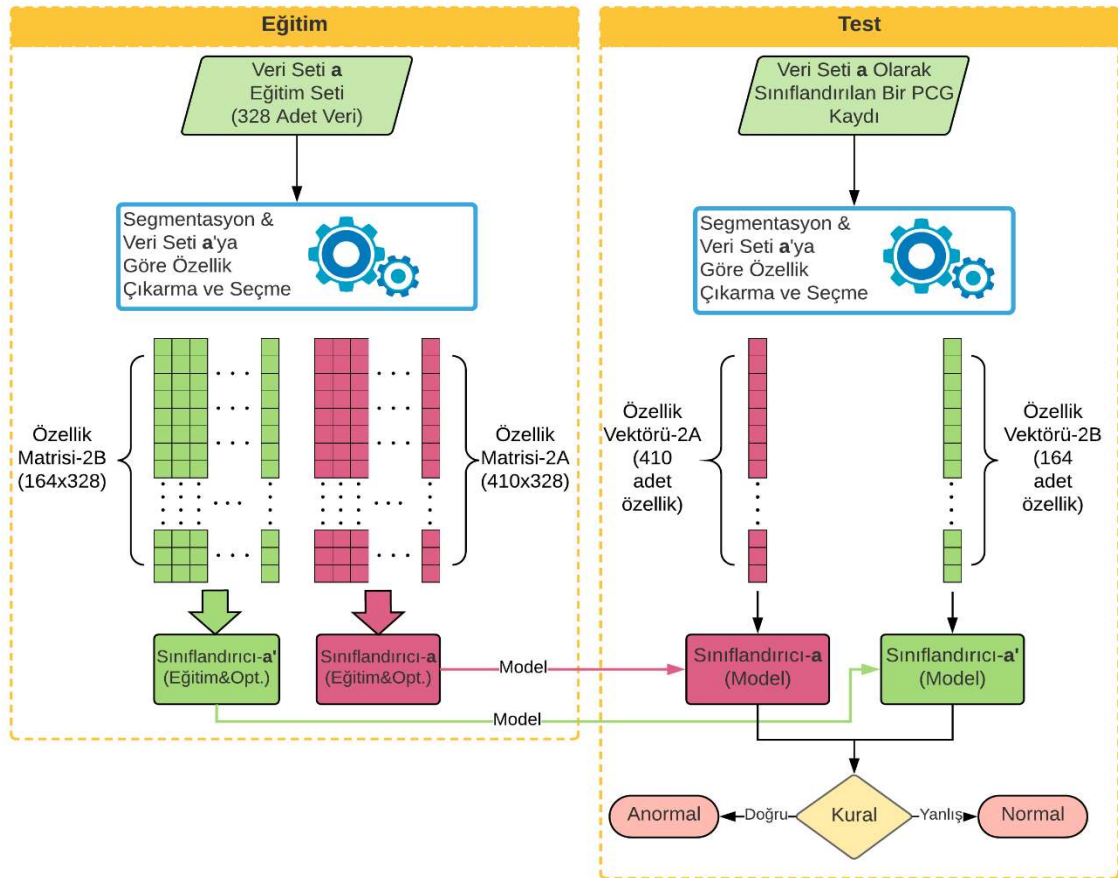


Şekil 3.19. Sınıflandırıcı-e'nin eğitilmesi ve optimize edilmesi

Verilerin farklı donanımlarla, farklı ortamlarda ve vücudun farklı bölgeleri (lokasyonları) kullanılarak kaydedilmiş olması göz önüne alındığında benzer veriler (yani aynı veri setine ait veriler) için ayrı sınıflandırıcıların kullanılması ve daha sonra iki adet sınıflandırıcının sonuçlarına göre “oylama” yapılması ile sınıflandırma performansının artırılması amaçlanmıştır. Örnek olarak blok diyagramı Şekil 3.20.'de verilen veri seti a'dan alınan kayıtların sınıflandırılmasını göz önüne alalım. Çapraz doğrulamanın her adımında 328 adet veri kullanılarak (her veri için iki adet özellik vektörü) iki adet sınıflandırıcı eğitilmiş ve optimize edilmiştir. Algoritma test edilirken sıra veri seti a'ya ait olan 81 adet veriden herhangi birine geldiğinde algoritmanın “Veri Seti Sınıflandırması” aşamasında bu verinin veri seti a'dan geldiği tespit edilir. Böylece veri seti a için seçilmiş özellikler çıkarılır. Daha sonra bu özellikler kullanılarak eğitilmiş olan Sınıflandırıcı-a ve Sınıflandırıcı-a' ile bu verinin “normal” veya “anormal” olduğu tespit edilir. Eğer her iki sınıflandırıcı da bu verinin “anormal” olduğu sonucuna varırsa bu verinin “anormal” olduğuna, diğer sonuçlarda ise verinin “normal” olduğuna karar verilir. Beşli çapraz doğrulamanın her adımında kullanılan veri ve veri başına düşen özellik sayıları Çizelge 3.12.'de verilmiştir.

Çizelge 3.12. Çapraz doğrulamanın her adımında kullanılan veri ve özellik sayısı

Sınıflandırıcı	Eğitim Veri Sayısı	Test Veri Sayısı	Özellik Sayısı
Sınıflandırıcı-a	328	81	410
Sınıflandırıcı-a'	328	81	164
Sınıflandırıcı-b	393	97	411
Sınıflandırıcı-b'	393	97	166
Sınıflandırıcı-c	25	6	410
Sınıflandırıcı-c'	25	6	166
Sınıflandırıcı-d	44	11	411
Sınıflandırıcı-d'	44	11	168
Sınıflandırıcı-e	1712	429	410
Sınıflandırıcı-e'	1712	429	166
Sınıflandırıcı-f	91	23	411
Sınıflandırıcı-f'	91	23	168

**Şekil 3.20.** Sınıflandırıcı-a'nın eğitilmesi, optimize ve test edilmesi

Veri setlerindeki büyük farklılıklar neticesinde sınıflandırıcıların eğitim ve optimizasyonu sonucunda elde edilen sınıflandırıcıların çeşitli parametreleri farklılıklar göstermiştir. Sınıflandırıcılara ait Bayesian optimizasyonu kullanılarak elde edilen parametreler Çizelge 3.13.'te verilmiştir.

Çizelge 3.13. Nihai sınıflandırmada kullanılan sınıflandırıcılara ait detaylar

Sınıflandırıcı Adı	Sınıflandırıcı-a
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	Bagging
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	498
Öğrenme Oranı	1
Sınıflandırıcı Adı	Sınıflandırıcı-a'
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	AdaBoostM1
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	446
Öğrenme Oranı	0,988
Sınıflandırıcı Adı	Sınıflandırıcı-b
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	LogitBoost
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	499
Öğrenme Oranı	0,087
Sınıflandırıcı Adı	Sınıflandırıcı-b'
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	AdaBoostM1
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	463
Öğrenme Oranı	0,4332

Çizelge 3.13. Nihai sınıflandırmada kullanılan sınıflandırıcılara ait detaylar (devamı)

Sınıflandırıcı Adı	Sınıflandırıcı-c
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	GentleBoost
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	10
Öğrenme Oranı	0,5314
Sınıflandırıcı Adı	Sınıflandırıcı-c'
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	LogitBoost
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	16
Öğrenme Oranı	0,001
Sınıflandırıcı Adı	Sınıflandırıcı-d
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	GentleBoost
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	500
Öğrenme Oranı	0,2114
Sınıflandırıcı Adı	Sınıflandırıcı-d'
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	Bagging
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	217
Öğrenme Oranı	1
Sınıflandırıcı Adı	Sınıflandırıcı-e
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	AdaBoostM1
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	492
Öğrenme Oranı	0,9942

Çizelge 3.13. Nihai sınıflandırmada kullanılan sınıflandırıcılara ait detaylar (devamı)

Sınıflandırıcı Adı	Sınıflandırıcı-e'
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	GentleBoost
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	168
Öğrenme Oranı	0,0022
Sınıflandırıcı Adı	Sınıflandırıcı-f
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	GentleBoost
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	417
Öğrenme Oranı	0,0025
Sınıflandırıcı Adı	Sınıflandırıcı-f'
Sınıflandırıcı Türü	Sınıflandırıcı Metotları Topluluğu
Algoritma	Bagging
Zayıf Sınıflandırıcı Türü	Karar Ağacı
Zayıf Sınıflandırıcı Sayısı	423
Öğrenme Oranı	1

4. BULGULAR VE TARTIŞMA

Bu bölümde önerilen algoritmanın performansını ölçmede kullanılan parametreler açıklandıktan sonra elde edilen sonuçlar aynı verileri kullanan diğer çalışmaların sonuçları ile beraber karşılaştırmalı olarak verilecektir.

4.1. Teşhis Destek Doğruluğunu Ölçmede Kullanılan Parametreler

Biyomedikal çalışmalarda tanı testi çalışılan deneklerde hastalık olup olmadığını tahmin etmekte kullanılır. Örneğin, bu çalışmada tanı testi yani önerilen algoritmanın test edilmesi deneklerde herhangi bir kalp hastalığı bulunup bulunmadığını tahmin etmede kullanılmıştır. Tanı testi, test sonuçlarının deneğin gerçek durumu ile karşılaştırılarak doğrulanır. Test doğrulaması belirli bir kullanım için testin uygunluğunu değerlendirmek ve böylece testin hastalıklı ve sağlıklı bireyleri tanımada ne kadar iyi olduğunu değerlendirmek için kullanılan bir değerlendirme yöntemidir. Test doğrulaması testin performansını ölçmede kullanılan parametrelerin hesaplanmasını içerir (Wong ve Lim 2011).

Çizelge 4.1. Tanı testi sonuçlarının çizelge olarak gösterimi

Tanı testi Sonuçları	Gerçek Durum	
	Anormal (Hastalıklı, Pozitif)	Normal (Sağlıklı, Negatif)
Anormal (Hastalıklı, Pozitif)	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
Normal (Sağlıklı, Negatif)	Yanlış Negatif (YN)	Doğru Negatif (DN)

Çizelge 4.1.'den görülebileceği gibi gerçek durumu hastalıklı (pozitif) olan bir deneğin tanı testi sonucunda yine hastalıklı (pozitif) çıkması doğru pozitif (DP), tanı testi sonucunda sağlıklı (negatif) çıkması yanlış negatif (YN) olarak değerlendirilir. Gerçek durumu sağlıklı (negatif) olan bir deneğin tanı testi sonucunda yine sağlıklı (negatif) çıkması doğru negatif (DN), tanı testi sonucunda hastalıklı (pozitif) çıkması yanlış negatif (YP) olarak değerlendirilir.

Bir tanı testinin duyarlılığı o deneyin hastalıklı bireyleri doğru tanıma becerisini gösterir ve Denklem 4.1'deki gibi tanımlanır.

$$\text{duyarlılık} = \frac{DP}{DP + YN} \times 100 \quad (4.1)$$

Bir tanı testinin özgüllüğü o deneyin sağlıklı bireyleri doğru tanıma becerisini gösterir ve Denklem 4.2'deki gibi tanımlanır.

$$\text{özgüllük} = \frac{DN}{YP + DN} \times 100 \quad (4.2)$$

Bir tanı testinin doğruluğu o deneyin tüm bireyleri doğru tanıma becerisini gösterir ve Denklem 4.3'deki gibi tanımlanır.

$$\text{doğruluk} = \frac{DP + DN}{DP + YP + DN + YN} \times 100 \quad (4.3)$$

Pozitif yorum gücü (PPV), tanı testi sonucunda hasta olarak teşhis edilmiş deneklerin gerçekten de hasta olma olasılığı olarak tanımlanır ve Denklem 4.4'teki gibi hesaplanır. Negatif yorum gücü (NPV) ise, tanı testi sonucunda negatif (sağlıklı) olarak teşhis edilmiş deneklerin gerçekten de negatif (sağlıklı) olma olasılığı olarak tanımlanır ve Denklem 4.5'teki gibi hesaplanır. Duyarlılık ve özgüllüğün aksine bu iki değer denek grubunda hastalığın sık görülmesine (prevelans) bağlıdır. Bu nedenle bu iki değer farklı hastalık prevelansına sahip grupların karşılaştırılmasında kullanılmamalıdır (Wong ve Lim 2011).

$$\text{PPV} = \frac{DP}{DP + YP} \times 100 \quad (4.4)$$

$$\text{NPV} = \frac{DN}{DN + YN} \times 100 \quad (4.5)$$

ROC analizi, klinik çalışmalarda tanı testinin sağlıklı (negatif) ve hastalıklı (pozitif) iki durumu ne kadar doğru bir şekilde ayırdığını ölçmede kullanılır. Analiz genellikle ROC eğrisi kullanılarak yapılır. ROC eğrisi, doğru pozitif oranının yanlış pozitif oranına göre değişiminin çizilmesiyle elde edilir. Eğrinin altında kalan alanın fazlalığı tanı testinin başarısını gösterir. Tanı testinin %100 duyarlılık ve %100 özgüllük göstermesi durumunda eğrinin altındaki alan en büyük değerini alır. Ayrıca ROC eğrisi, eğrilerin altında kalan alanın büyüklüğü göz önüne alınmak suretiyle birden fazla tanı testini karşılaştırmak için de kullanılır (Hajian-Tilaki 2013). Çizelge 4.2.'de Eğrinin altında kalan alan ile tanı testinin performansı arasındaki ilişki verilmiştir (Hajian-Tilaki 2013).

Çizelge 4.2. ROC eğrisinin altında kalan alan ile performans arasındaki ilişki

Alan	Tanı Testinin Performansı
0.9-1.0	Mükemmel
0.8-0.9	Çok iyi
0.7-0.8	İyi
0.6-0.7	Yeterli
0.5-0.6	Kötü
≤ 0.5	Kullanışsız

4.2. Yarışmada Kullanılan Parametreler

Yarışmada kullanılan verilerin bir kısmının temiz bir kısmının ise gürültülü olmasından dolayı yarışmada performans ölçümünde Bölüm 4.1.'deki parametrelerin değiştirilmiş hali kullanılmıştır. Karşılaştırma yapabilmek açısından bu çalışmada da aynı parametreler hesaplanmıştır.

Çizelge 4.3. Yarışmada kullanılan tanı testi sonuçlarının çizelge olarak gösterimi

Gerçek Durum	Tanı testi Sonuçları	
	Normal	Anormal
Normal ve Temiz	Nn_1	Na_1
Normal ve Gürültülü	Nn_2	Na_2
Anormal ve Temiz	An_1	Aa_1
Anormal ve Gürültülü	An_2	Aa_2

Parametrelerin hesaplanmasında kullanılan ağırlıklar Denklem 4.6-9'de verilmiştir.

$$\omega_{a_1} = \frac{\text{Temiz ve anormal kayıt sayısı}}{\text{Toplam anormal kayıt sayısı}} \quad (4.6)$$

$$\omega_{a_2} = \frac{\text{Gürültülü ve anormal kayıt sayısı}}{\text{Toplam anormal kayıt sayısı}} \quad (4.7)$$

$$\omega_{n_1} = \frac{\text{Temiz ve normal kayıt sayısı}}{\text{Toplam normal kayıt sayısı}} \quad (4.8)$$

$$\omega_{n_2} = \frac{\text{Gürültülü ve normal kayıt sayısı}}{\text{Toplam normal kayıt sayısı}} \quad (4.9)$$

Değiştirilmiş duyarlılık, özgüllük ve doğruluk ise Denklem 4.10-12'deki gibi hesaplanır.

$$\text{duyarlılık}_d = \frac{\omega a_1 \times Aa_1}{Aa_1 + An_1} + \frac{\omega a_2 \times Aa_2}{Aa_2 + An_2} \quad (4.10)$$

$$\text{özgüllük}_d = \frac{\omega n_1 \times Nn_1}{Na_1 + Nn_1} + \frac{\omega n_2 \times Nn_2}{Na_2 + Nn_2} \quad (4.11)$$

$$\text{doğruluk}_d = \frac{\text{duyarlılık}_d + \text{özgüllük}_d}{2} \quad (4.12)$$

4.3. Performans Sonuçları

Bölüm 3.11.10.'da açıklandığı üzere algoritmanın eğitilmesinde beşli çapraz doğrulama kullanılmıştır. Yani verilerden toplam beş kopya oluşturulmuş, bu kopyalar beş parçaya ayrılmış, oluşturulan parçaların dördü eğitim, biri test (tanı testi) için kullanılmıştır. Sonuçlar beş adet tanı testinin ortalaması olarak verilmiştir.

Algoritmanın veri seti sınıflandırması aşaması performans sonuçlarını etkilediğinden dolayı bu bölümde veri seti sınıflandırmasına ilişkin performans sonuçları da verilmiştir. Bu sınıflandırmaya ilişkin karışıklık matrisi Çizelge 4.4.'te verilmiştir.

Çizelge 4.4. Veri seti sınıflandırmasına ilişkin karışıklık matrisi

Tahmin Edilen Sınıf	Gerçek Sınıf							Toplam
		a	b	c	d	e	f	
	a	404	0	10	0	2	0	
	b	0	485	0	0	0	0	
	c	1	0	6	0	0	0	
	d	0	5	0	50	3	0	
	e	4	0	16	5	2136	0	
	f	0	0	0	0	0	114	
	Toplam	%98,8	%99,0	%18,8	%90,9	%99,8	%100,0	

Karışıklık matrisinden de görülebileceği gibi toplamda %98.6'lık bir doğruluk elde edilmiştir. Veri seti a'ya ait 409 kayıttan 404'ü doğru sınıflandırılırken 5'i yanlış sınıflandırılmıştır. Veri seti b'ye ait 490 kayıttan 485'i doğru sınıflandırılmış; fakat 5'i yanlış sınıflandırılmıştır. En düşük sınıflandırma performansına sahip veri seti olan veri

seti c'ye ait 32 kayıttan 6'sı doğru, 26 tanesi yanlış sınıflandırılmıştır. Veri seti d'ye ait 55 kayıttan 50'si doğru sınıflandırılmasına rağmen bu veri setine ait 5 kayıt yanlış sınıflandırılmıştır. En fazla kayıt içeren veri seti olan veri seti e'ye ait 2141 kayıttan 2136'sı doğru ve sadece 5 tanesi yanlış sınıflandırılmıştır. Veri seti f'ye ait tüm kayıtlar ise doğru sınıflandırılmıştır. Dolayısıyla veri seti f'ye ait kayıtlar sınıflandırılırken en yüksek başarı elde edilmiştir.

Tanı testi, algoritmanın son aşaması olan nihai sınıflandırmada yer alan ve deneme yanılma yoluyla bulunan beş farklı kural ile gerçekleştirilmiştir. Kurallara ait detaylar Çizelge 4.5.'te verilmiştir. Çizelgede yer alan (x), (a), (b), (c), (d), (e) veya (f)'yi; (x') ise (a'), (b'), (c'), (d'), (e') veya (f')'nü temsil etmektedir.

Çizelge 4.5. Nihai sınıflandırmada yer alan beş farklı kural

Kural	Algoritmanın Sonucu	
	Anormal	Normal
Kural 1	Eğer Sınıflandırıcı-x anormal ise	Diğer türlü
Kural 2	Eğer Sınıflandırıcı-x' anormal ise	Diğer türlü
Kural 3	Eğer Sınıflandırıcı-x VEYA Sınıflandırıcı-x' anormal ise	Diğer türlü
Kural 4	Eğer Sınıflandırıcı-x VE Sınıflandırıcı-x' anormal ise	Diğer türlü
Kural 5	Veri seti a için: Kural 4	Diğer türlü
	Veri seti b, c ve d için: Kural 3	
	Veri seti e için: Kural 1	
	Veri seti f için: Kural 2	

Özellik seçme öncesinde beş kural için gerçekleştirilen tanı testi sonuçları Çizelge 4.6.'da verilmiştir. Sonuçlardan da görülebileceği gibi hem doğruluk hem de değiştirilmiş doğruluk anlamında en iyi sonuç kural 5'in kullanılmasıyla elde edilmiştir. Algoritmanın eğitilmesinde kullanılan verilerdeki pozitif ve negatif kayıtlar arasındaki sayıca dengesizlikten dolayı tüm durumlarda duyarlılık özgüllükten daha küçük çıkmıştır. En yüksek özgüllük kural 4'ün kullanılmasıyla, en yüksek duyarlılık kural 5'in kullanılmasıyla, en yüksek PPV kural 4'ün ve en yüksek NPV kural 5'in kullanılmasıyla elde edilmiştir. Sadece segmentasyonu yapılmış veriler kullanıldığında (kural 1) sadece segmentasyonu yapılmamış verilerin kullanıldığı duruma (kural 2) göre daha düşük performans sonuçları elde edilmiştir. Kural 5 kullanıldığında, algoritma kural 2 ile çok benzer sonuçlar vermişse de değiştirilmiş doğruluk kural 5 kullanıldığında daha yüksek olmuştur.

Çizelge 4.6. Özellik seçme öncesi beş farklı kurala göre tanı testi sonuçları

	Kural 1	Kural 2	Kural 3	Kural 4	Kural 5
Duyarlılık	82.71	84.21	87.22	79.70	87.22
Özgüllük	96.69	96.69	95.72	97.67	95.91
Doğruluk	93.82	94.13	93.97	93.97	94.13
PPV	86.61	86.82	84.06	89.83	84.67
NPV	95.58	95.95	96.66	94.89	96.67
Duyarlılık_a	82.71	84.21	87.22	79.70	87.22
Özgüllük_a	96.69	96.69	95.72	97.67	95.91
Doğruluk_a	89.70	90.45	91.47	88.68	91.56


Özellik seçme sonrasında beş kural için gerçekleştirilen tanı testi sonuçları Çizelge 4.7’de verilmiştir. Sonuçlardan da görülebileceği gibi hem doğruluk hem de değiştirilmiş doğruluk anlamında en iyi sonuç kural 5’in kullanılmasıyla elde edilmiştir. Algoritmanın eğitilmesinde kullanılan verilerdeki pozitif ve negatif kayıtlar arasındaki sayıca dengesizlikten dolayı tüm durumlarda duyarlılık özgüllükten daha küçük çıkmıştır. En yüksek özgüllük kural 4’ün kullanılmasıyla elde edilmişse de bu durumda duyarlılık ve doğrulukta büyük bir düşüş meydana gelmiştir. Kural 1 ve kural 2’nin kullanıldığı durumlarda negatif kayıtların doğru sınıflandırılma başarısı aynı olsa da pozitif kayıtların doğru sınıflandırılmasında kural 1 daha iyi sonuç vermiştir. Sonuçlara pozitif yorum gücü açısından bakıldığında en yüksek pozitif yorum gücü kural 4 kullanıldığında elde edilmekle beraber kural 5 ve kural 4’ün birbirine çok yakın olduğu görülmektedir. En yüksek negatif yorum gücü ise hemen hemen tüm ölçütlerde en yüksek sonuçların elde edildiği kural 5’in kullanıldığı durumda elde edildiği görülmektedir.

Algoritmanın performansı, özellik seçme öncesi ve sonrası şeklinde değerlendirildiğinde kural 5’te performansta küçük bir artışın olduğu görülmektedir. En yüksek doğruluk %94.13’ten %95.21’e ve en yüksek değiştirilmiş doğruluk %91.56’dan %92.25’e çıkmıştır. En yüksek duyarlılık değişmese de özgüllükte %0.4’lük bir artış görülmektedir. Özellik seçme sonrası kuralların değiştirilmiş doğruluk performanslarına bakıldığında kural 5’te yükselme görülürken diğer kurallarda düşüş meydana gelmiştir. Doğruluk açısından bakıldığında ise kural 5 ve kural 3’te yükselme görülürken diğer kurallarda düşüş meydana gelmiştir.

Çizelge 4.7. Özellik seçme sonrası beş farklı kurala göre tanı testi sonuçları

	Kural 1	Kural 2	Kural 3	Kural 4	Kural 5
Duyarlılık	80.45	72.93	86.47	75.94	87.22
Özgüllük	97.08	97.08	96.30	98.05	97.28
Doğruluk	93.67	92.12	94.28	93.51	95.21
PPV	87.70	88.62	85.82	90.99	89.23
NPV	95.05	95.42	96.49	94.03	96.71
Duyarlılık_a	80.45	72.93	86.47	75.94	87.22
Özgüllük_a	97.08	97.08	96.30	98.05	97.28
Doğruluk_a	88.77	85.01	91.38	87.00	92.25

Şekil 4.1.'de özellik seçme sonrası beş farklı kurala ait ROC eğrileri ve sınır değer eğrisi verilmiştir. ROC eğrisi sınır değere yaklaştıkça yani eğrinin altındaki alan azaldıkça sınıflandırma performansı azalır. ROC eğrisi grafiğin üst köşelerine yaklaştıkça yani eğrinin altında kalan arttıkça sınıflandırma performansı artar. Eğrilerin altında kalan alan sırasıyla 0.8962, 0.8501, 0.9138 0.8700 ve 0.9225 olarak hesaplanmıştır. Buna göre en iyi sınıflandırma performansını yeşil eğri ile gösterilen kural 5 göstermiştir ve Çizelge 4.2.'ye göre “mükemmel” olarak nitelendirilmektedir.

**Şekil 4.1.** Beş farklı kural için ROC eğrileri

4.4. Performans Sonuçlarının Karşılaştırılması

Bu bölümde, önerilen algoritmanın tanı testi sonucunda elde edilen performans sonuçları hekimlerin ve aynı veri setini kullanan diğer çalışmaların sonuçları ile karşılaştırılmıştır. Çizelge 4.8.'de verilen çalışmalardan ilk ikisi birinci basamak hekimler ile uzman kardiyologların kalp hastalıklarını stetoskop ile teşhis etme başarısını göstermektedir. Özellikle ilk basamak hekimlerinin teşhis performansının oldukça düşük olduğu görülmektedir. Geri kalan çalışmaların tamamı aynı veri seti kullanılarak geliştirilmiştir. Bazı çalışmalarda beşli çapraz doğrulama bazılarında ise onlu çapraz doğrulama kullanılmıştır. Üçten yediye kadar olan çalışmalar 2016'da yapılan yarışmada ilk beşe giren çalışmalardır. Doğru bir karşılaştırma yapabilmek için bu çalışmaların yarışma sonuçları değil de çalışmaların eğitim veri seti ile gösterdikleri performansları verilmiş olup önerilen algoritma değiştirilmiş doğruluk açısından bu çalışmaların tamamından daha iyi sonuç vermiştir. Sekizden on ikiye kadar olan çalışmalar ise yarışmadan sonra yapılan çalışmalardır. Yine bu çalışmaların eğitim veri seti üstünden gösterdikleri performanslar verilmiştir. Önerilen algoritma değiştirilmiş doğruluk bakımından en iyi ikinci performansı göstermiştir ve daha iyi performans gösteren 11. çalışmadan sadece %0.97 daha az bir skor elde etmiştir.

Çizelge 4.8. Farklı çalışmaların performans sonuçları (değerler yüzde olarak verilmiştir)

#	Çalışma	Doğrulama Yöntemi	Dğ	Dy _d	Öz _d	Dğ _d
1	İlk basamak hekimler (Etchells ve Bell 1997)	—	40.0	—	—	—
2	Uzman kardiyologlar (Etchells ve Bell 1997)	—	80.0	—	—	—
3	Potes ve ark. (2016)	5'li çapraz doğrulama	—	88.0	82.0	85.0
4	Zabihi ve ark. (2016)	10'lu çapraz doğrulama	—	94.2	88.8	91.5
5	Kay ve Agarwal (2017)	10'lu çapraz doğrulama	—	84.8	83.3	84.1
6	Bobillo (2016)	10'lu çapraz doğrulama	—	94.6	89.3	91.9
7	Homsı ve ark. (2016)	10'lu çapraz doğrulama	—	94.4	86.9	88.4
8	Whitaker ve ark. (2017)	5'li çapraz doğrulama	—	88.8	88.2	88.4
9	Beritelli ve ark (2018)	5'li çapraz doğrulama	94.0	93.0	91.0	92.0
10	Langley ve Murray (2017)	5'li çapraz doğrulama	80.0	94.0	65.0	79.5
11	Homsı ve Warrick (2017)	5'li çapraz doğrulama	—	95.9	90.5	93.2
12	Önerilen algoritma	5'li çapraz doğrulama	95.2	87.2	97.2	92.3

Dğ: doğruluk, Dy_d: değiştirilmiş duyarlılık, Öz_d: değiştirilmiş özgüllük, Dğ_d: değiştirilmiş doğruluk

5. SONUÇ VE ÖNERİLER

Bu çalışmada farklı veri setlerinden alınan kalp sesi kayıtlarını otomatik olarak sınıflandıran bir Matlab algoritması geliştirilmiştir. Önışlem, özellik çıkarma-1, veri seti sınıflandırması, segmentasyon, özellik çıkarma-2, özellik seçme ve nihai sınıflandırma olmak üzere önerilen algoritma yedi temel aşamadan oluşmaktadır. Önışlem aşamasında PCG kayıtlarındaki sivri uçlar yok edilerek normalizasyon yapılmıştır. Sonraki aşamada, kayıtların veri setine göre sınıflandırmaya yarayan sınıflandırıcının eğitilmesinde ve test edilmesinde kullanılan özellikler çıkarılmıştır. Kayıtlar alındıkları veri setine göre sınıflandırılırken sınıflandırıcı metotları topluluğu kullanılmıştır. Böylece, farklı veri setlerine ait veriler için farklı özellik ve sınıflandırıcı kullanılması sağlanmıştır. Algoritmanın segmentasyon aşamasında Springer'in segmentasyon algoritması kullanılarak kayıtlar temel kalp seslerine ayrılmıştır. Özellik çıkarma-2 aşamasında segmentasyonu yapılmış ve yapılmamış işaretlerin zaman, frekans ve zaman-frekans özellikleri çıkarılmıştır. Çıkarılan özellikler, özellik seçme aşamasında azaltılarak algoritmanın son adımında yer alan sınıflandırıcıların eğitilmesinde ve tanı testinde kullanılmıştır. Her bir kayıt için iki farklı sınıflandırıcı kullanıldığından kaydın normal veya anormal olduğuna yönelik son karar verilirken beş farklı kural kullanılarak en iyi sonucu veren kural bulunmuştur. Elde edilen sonuçlar önerilen algoritmanın ilk basamak ve uzman hekimlerden daha başarılı sonuçlar verdiğini göstermiştir.

Önerilen algoritmanın en iyi performans gösterdiği durumda duyarlılık, özgüllük, doğruluk, pozitif ve negatif yorum gücü sırasıyla %87.22, %97.28, %95.21, %89.23 ve %96.71 şeklinde elde edilmiştir. Önerilen algoritmanın bu performans değerleri literatürde yapılmış diğer çalışmaların performans değerleri ile kıyaslandığında önerilen algoritmanın başarılı olduğu görülmüştür. Bu da önerilen algoritmanı PCG kayıtlarını normal ve anormal olarak sınıflandırmada oldukça başarılı olduğunun bir göstergesidir. Dolayısıyla önerilen algoritmanın başarımlar değerleri ilk derece ve uzman hekimlerin başarımlar sonuçları ve aynı veri bankasını kullanan literatürdeki diğer benzer çalışmaların başarımlar performansı ile kıyaslandığında algoritmanın kalp hastalıklarının teşhis etmede hekimlere yardımcı olabileceği düşünülmektedir.

Gelecekte, önerilen algoritmanın gerek özellik çıkarım aşamasında ve gerekse sınıflandırma aşamasında daha güçlü yöntemler kullanılarak algoritmanın iyileştirilmesi yoluna gidilip performansı artırılabilir. Böylelikle performansı artırılan sınıflandırma algoritması kullanılarak oluşturulacak Microsoft Windows tabanlı kullanımı kolay ve ucuz bir yazılım hekimlere teşhis destek amacıyla sunulabilir.

Kalp hastalıklarının erken teşhisi ve tedavisi hastaların ani ölümünü engelleyebilir. PCG kayıtlarını analiz eden uygun, ucuz ve kolay kullanılabilen teşhis destek sistemleri insan hayatını kurtarma potansiyeli açısından önemlidir. Özellikle uzman hekime ulaşmanın zor olduğu ülkelerde kullanılmak amacıyla önerilen algoritmanın bir akıllı telefon uygulaması geliştirilebilir. Böylece, insanların ev ortamında, ucuz ve kolay bir şekilde herhangi bir kalp rahatsızlığına sahip olup olmadıklarını dair erkenden fikir sahibi olmaları mümkün olabilir.

6. KAYNAKLAR

- Amiri, A. M., Armano, G. 2013. An intelligent diagnostic system for congenital heart defects. *International Journal of Advanced Computer Science and Applications*, 4(7): 93–97.
- Ari, S., Saha, G. 2009. In search of an optimization technique for Artificial Neural Network to classify abnormal heart sounds. *Applied Soft Computing*, 9(1): 330–340.
- Avendaño-Valencia, L., Ferrero, J., Castellanos-Domínguez, G. 2007. Improved parametric estimation of time-frequency representation for cardiac murmur discrimination. 2008 Computers in Cardiology, 14–17 Eylül 2008, Bologna. S, 157–160.
- Beritelli, F., Capizzi, G., Sciuto, G. L., Napoli, C., Scaglione, F. 2018. Automatic heart activity diagnosis based on Gram polynomials and probabilistic neural networks. *Biomedical Engineering Letters*, 8(1): 77–85.
- Bobillo, I. J. D. 2016. A tensor approach to heart sound classification. 2016 Computing in Cardiology Conference (CinC), 11–14 Eylül 2016, Vancouver. S, 629–632.
- Boutana, D., Benidir, M., Barkat, B. 2014. Segmentation and time-frequency analysis of pathological Heart Sound Signals using the EMD method. 2014 22nd European Signal Processing Conference (EUSIPCO), 1–5 Eylül 2014, Lisbon. S, 1437–1441.
- Burrus, C. S., Gopinath, R. A., Guo, H. 1998. Introduction to Wavelets and Wavelet Transforms. Prentice Hall, Yayın No: 0-13-489600-9 , Sayfa: 66–100. New Jersey.
- Chandradevan, R. 2017. Towards Data Science. Erişim: [https://towardsdatascience.com/shallow-understanding-on-bayesian-optimization]. Erişim Tarihi: 19.05.2018.
- Das, R., Turkoglu, I., Sengur, A. 2009. Diagnosis of valvular heart disease through neural networks ensembles. *Computer Methods and Programs in Biomedicine*, 93(2): 185–191.
- Debbal, S., Hamza, C., Bereksi-Reguig, F. 2008. Segmentation of heart sounds and heart murmurs. *Journal of Mechanics in Medicine and Biology*, 8(4): 549–559.
- Deng, S., Ji-Qing, H. 2016. Towards heart sound classification without segmentation via autocorrelation feature and diffusion maps. *Future Generation Computer Systems*, 60(C): 13–21.
- Dokur, Z., Ölmez T. 2008. Heart sound classification using wavelet transform and incremental self-organizing map. *Digital Signal Processing*, 18(6): 951–959.
- Etchells, E., Bell C. 1997. Does this patient have an abnormal systolic murmur. *The Journal of the American Medical Association (JAMA)*, 277(7): 564–571.
- Farzam, B., Shirazi, J. 2014. The diagnosis of heart diseases based on PCG signals using MFCC coefficients and SVM classifier. *International Journal of Innovative Science, Engineering & Technology*, 1(10): 654–659.

Fattah, S. A. 2017. Stetho-phone: Low-cost digital stethoscope for remote personalized healthcare. 2017 IEEE Global Humanitarian Technology Conference (GHTC), 19–22 Ekim 2017, San Jose. S, 1–7.

Guillermo, J., Sanchez, E., Ricalde, L., Cruz, B. J., Castillo, A. 2014. Intelligent classification of real heart diseases based on radial wavelet neural network. 2014 Cairo International Biomedical Engineering Conference (CIBEC), 11–13 Aralık 2014, Kahire. S, 162–165.

Gupta, C. N., Palaniappan, R., Swaminathan S. 2016. Classification of homomorphic segmented phonocardiogram signals using grow and learn network. 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference, 17–18 Ocak 2006, Shanghai. S, 4251–4254.

Hajian-Tilaki, K. 2013. Receiver Operating Characteristic (ROC) Curve Analysis for Medical Diagnostic Test Evaluation. *Caspian Journal of Internal Medicine*, 4(2): 627–635.

Hedayioglu, L., Coimbra, M., Mattos, S. 2009. Heart sound segmentation for digital stethoscope integration. Yüksek lisans tezi, University of Porto Faculty of Medicine and Faculty of Sciences, Porto, 41–56.

Homsı, M. N., Medina, N., Hernandez, M., Quintero, N., Perpiñan, G., Quintana, A., Warrick, P. 2016. Automatic heart sound recording classification using a nested set of ensemble algorithms. 2016 Computing in Cardiology Conference (CinC), 11–14 Eylül 2016, Vancouver. S, 817–820.

Homsı, M. N., Warrick, P. 2017. Ensemble methods with outliers for phonocardiogram classification. *Physiological Measurement*, 38(8): 1631–1644.

Illowsky, B., Dean, S. 2013. Introductory Statistics. Openstax, Yayın No: 1-947172-05-0, Sayfa: 75–82. Houston.

Jaramillo-Garzon, J., Quiceno-Manrique, A., Godino-Llorente, I. 2008. Feature extraction for murmur detection based on support vector regression of time-frequency representations. 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 20–25 Ağustos 2008, Vancouver. S, 1623–1626.

Johnston, M. 2007. The third heart sound for diagnosis of acute heart failure. *Current Heart Failure Reports*, 4(3): 164–169.

Kang, S., Doroshov, R., McConnaughey, J., Ahsan, K., Raj, S. 2015. Heart sound segmentation toward automated heart murmur classification in pediatric patents. 2015 8th International Conference on Signal Processing, Image Processing and Pattern Recognition (SIP), 25 Kasım 2015, Jeju. S, 9–12.

Kay, E., Agarwal, A. 2017. DropConnected neural networks trained on time–frequency and inter–beat features for classifying heart sounds. *Physiological Measurement*, 38(8): 1645–1657.

Kido, K. 2014. Digital Fourier Analysis: Advanced Techniques. Springer, Yayın No: 978-1-4939-1127-1, Sayfa: 85–103. New York.

Koçyiğit, Y. 2016. Heart sound signal classification using fast independent component analysis. *Turkish Journal of Electrical Engineering & Computer Sciences*, 24 (4): 2949–2960.

Kouras, N., Boutana, D., Benidir, M. 2012. Wavelet based segmentation and time-frequency characterisation of some abnormal heart sound signals. 2012 24th International Conference on Microelectronics (ICM), 16 Aralık 2012, Algiers. S, 1–4.

Langley, P., Murray, A. 2017. Heart sound classification from unsegmented phonocardiograms. *Physiological Measurement*, 38(8): 1658–1670.

Lekram, B., Abhishek, M. 2014. Heart sound segmentation techniques: a survey. *IOSR Journal of Electrical and Electronics Engineering (IOSR-JEEE)*, 4(Electronics Eng): 46-49.

Liang, H., Lukkarinen, S., Hartimo, I. 1997. Heart sound segmentation algorithm based on heart sound envelopogram. Computers in Cardiology 1997, 7–10 Eylül 1997, Lund. S, 105–108.

Liu, C. 2016. An open access database for the evaluation of heart sound algorithms. *Physiological Measurement*, 37(12): 2181–2213.

Liu, J., Wang, H., Liu, W., Zhang, J. 2012. Autonomous detection and classification of congenital heart disease using an auscultation vest. *Journal of Computational Information Systems*, 8(2): 485–492.

Maglogiannis, I. 2009. Support Vectors Machine-based identification of heart valve diseases using heart sounds. *Computer Methods and Programs in Biomedicine*, 95(1): 47–61.

Mallat, S. G. 1989. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1(7): 674–693.

Mathworks. 2018. Ensemble Algorithms. Erişim: [https://www.mathworks.com/help/stats/ensemble-algorithms.html]. Erişim Tarihi: 05.05.2018.

Mermelstein, P. 1976. Distance measures for speech recognition—psychological and instrumental. Joint Workshop on Pattern Recognition and Artificial Intelligence, 1–3 Haziran 1976, Massachusetts. S, 374–388.

Mitchell, T. M. 1997. Machine Learning. McGraw–Hill, Yayın No: 0070428077, Sayfa: 52–66. New York.

Moukadem, A., Dieterlena, A., Hueberb, N., Brandtc, C. 2013. A robust heart sounds segmentation module based on S–transform. *Biomedical Signal Processing and Control*, 8(3): 273–281.

Nabih–Ali, M., El-Sayed, A., Yahiba, A. 2017. A review of intelligent systems for heart sound. *Journal of Medical Engineering & Technology*, 41(7): 553–563.

Naigaonkar, M. 2018. Erişim: [http://www.differencebetween.net/science/health/difference-between-systolic-and-diastolic/]. Erişim Tarihi: 28.05.2018.

Naseri, H., Homaeinezhad, M. R. 2013. Detection and boundary identification of phonocardiogram sounds using an expert frequency-energy based metric. *Annals of Biomedical Engineering*, 41(2): 279–292.

- Nigam, V., Priemer, R. 2007. A simplicity-based fuzzy clustering approach for detection and extraction of murmurs from the phonocardiogram. *Physiological Measurement*, 41(7): 29–33.
- O'Shaughnessy, D. 2008. Automatic speech recognition: history, methods and challenges. *Pattern Recognition*, 41(10): 2965–2979.
- Papadaniil, C. D., Hadjileontiadis, L. J. 2014. Efficient heart sound segmentation and extraction using ensemble empirical mode decomposition and kurtosis features. *IEEE Journal of Biomedical and Health Informatics*, 18(4): 1138–1152.
- Pedrosa, J., Castro, A., Vinhoza, T. T. 2014. Automatic heart sound segmentation and murmur detection in pediatric phonocardiograms. 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 26–30 Ağustos 2014, Chicago. S, 2294–2297.
- Phanphaisarn, W., Roeksabutr, A., Wardkein, P., Koseeyaporn, J., Yupapin, P. P. 2011. Heart detection and diagnosis based on ECG and EPCG relationships. *Medical Devices: Evidence and Research*, 4(1): 133–144.
- Potes, C., Parvaneh, S., Rahman, A., Conroy, B. 2016. Ensemble of feature-based and deep learning-based classifiers for detection of abnormal heart sounds. 2016 Computing in Cardiology Conference (CinC), 11–14 Eylül 2016, Vancouver. S, 621–624.
- Proakis, J., Manolakis, D. 1996. Digital Signal Processing. Prentice-Hall, Yayın No: 0-13-394338-9, Sayfa: 230–243. New Jersey.
- Quiceno, A., Delgado, E., Vallverd, M., Matijasevic, A. M, Castellanos-Domnguez, G. 2008. Effective phonocardiogram segmentation using nonlinear dynamic analysis and high-frequency decomposition. 2008 Computers in Cardiology, 14–17 Eylül 2008, Bologna. S, 161–164.
- Reed, T. R., Reed, N. E., Fritzson, P. 2004. Heart sound analysis for symptom detection and computer-aided diagnosis. *Simulation Modelling Practice and Theory*, 12(2): 129–146.
- Roy, A. K., Misal, A. 2014. Comparative evaluation for classification of PCG signals using KNN technique for wavelet transform. *International Journal of Engineering Technology and Management*, 2(1): 1–4.
- Safara, F., Doraisamy, S., Azman, A., Jantan, A., Ramaiah A 2013. Multi-level basis selection of wavelet packet decomposition tree for heart sound classification. *Computers in Biology and Medicine*, : 43(10)1407-1414.
- Samieinasab, M., Sameni, R. 2015. Fetal phonocardiogram extraction using single channel blind source separation. 2015 23rd Iranian Conference on Electrical Engineering, 10–14 Mayıs 2015, Tahrn. S, 78–83.
- Sardy, S., Tseng, P., Bruce, A. 2001. Robust wavelet denoising. *IEEE Transactions on Signal Processing*, 49(6): 1146–1152.
- Schmidt, S. E., Holst-Hansen, C., Graff, C., Toft, E., Struijk, J. J. 2010. Segmentation of heart sound recordings by a duration-dependent. *Physiological Measurement*, 31(4): 513–542.

- Schmidt, S. E., Holst-Hansen, C., Graff, C., Toft, E., Struijk, J. J. 2010. Noise and the detection of coronary artery disease with an electronic stethoscope. 2010 5th Cairo International Biomedical Engineering Conference, 16–18 Aralık 2010, Kahire. S, 2611–2619.
- Springer, D. B., Tarassenko, L., Clifford, G. D. 2016. Logistic regression–HSMM–based heart sound segmentation. *IEEE Transactions on Biomedical Engineering*, 63(4): 822–832.
- Tang, H., Li, T., Qiu, T., Park, Y. 2012. Segmentation of heart sounds based on dynamic clustering. *Biomedical Signal Processing and Control*, 7(5): 509–516.
- Varghees, N. V., Ramachandran, K. 2014. A novel heart sound activity detection framework for automated heart sound analysis. *Biomedical Signal Processing and Control*, 13: 174–188.
- Wang, P., Kim, Y., Ling, L. H., Soh, C. B. 2006. 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference, 17–18 Ocak 2006, Shanghai. S, 5519–5522.
- Wen-Chung, K., Chih-Chao, W. 2011. Automatic phonocardiograph signal analysis for detecting heart valve disorders. *Expert Systems with Applications*, 38(6): 6458–6468.
- Whitaker, B. M., Suresha, P. B., Liu, C., Clifford, G. D., Anderson, D. V. 2017. Combining sparse coding and time–domain features for heart sound classification. *Physiological Measurement*, 38(8): 1701–1713.
- WHO. 2018. Erişim: [<http://www.who.int/countries/tur/en/>]. Erişim Tarihi: 03.24.2018.
- Wong, H. B., Lim, G. H. 2011. Measures of diagnostic accuracy: sensitivity, specificity, PPV and NPV. *International Federation of Clinical Chemistry and Laboratory Medicine*, 19(4): 316–318.
- Zabihi, M., Rad, A. B., Kiranyaz, S., Gabbouj, M., Katsaggelos, A. K. 2016. Heart sound anomaly and quality detection using ensemble of neural networks without segmentation. 2016 Computing in Cardiology Conference (CinC), 11–14 Eylül 2016, Vancouver. S, 613–616.
- Zhongwei, J., Samjin, C. 2006. A cardiac sound characteristics waveform. *Expert Systems with Applications*, 31(2): 286–298.
- Zhukov, A., Tomin, N., Kurbatsky, V., Sidorov, D., Panasetsky, D., Foley, A. 2017. Ensemble methods of classification for power systems security assessment. *Applied Computing and Informatics*, 15(2): 100–106.



ÖZGEÇMİŞ

Adı Soyadı : Hasan ZAN
Doğum Yeri : Kızıltepe
Doğum Tarihi : 16.02.1989
Medeni Hali : Evli
Yabancı Dil : İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise : Kızıltepe Atatürk Lisesi (2004-2007)
Lisans : İstanbul Teknik Üniversitesi, Elektrik Mühendisliği (2007-2012)

Çalıştığı Kurum/Kurumlar ve Yıl

Okosis Otomasyon ve Kontrol Sistemleri Ltd. Şti. (2012-2015), İstanbul
Şırnak Üniversitesi, Öğretim Görevlisi (2016-2018), Şırnak
Mardin Artuklu Üniversitesi, Öğretim Görevlisi (2018-Halen), Mardin





DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ İNTİHAL FORMU

ÖĞRENCİ BİLGİLERİ

ADI VE SOYADI	Hasan ZAN
ÖĞRENCİ NO	16805002
EĞİTİM – ÖĞRETİM YILI	2018-2019
YARIYIL	☒ Güz ☐ Bahar
ANABİLİM DALI	
PROGRAM	Yüksek Lisans
TEZ KONUSU	Normal ve Patolojik Kalp Ses Kayıtlarının Zaman-Frekans Tabanlı Otomatik Sınıflandırılması

İNTİHAL RAPORU BİLGİLERİ

RAPOR TÜRÜ	Tez Savunma Sınavı Sonrası
SAYFA SAYISI	87
BENZERLİK ORANI	%12
RAPORLAMA TARİHİ	09/12/2018

Yukarıda başlığı/konusu gösterilen tez çalışmamın kapak sayfası, giriş, ana bölümler, sonuç ve tartışma kısımlarından oluşan toplam 87 sayfalık kısmına ilişkin, 09/12/2018 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı %12'dir.

Uygulanan filtrelemeler:

- ☐ Kabul/Onay sayfaları hariç,
- ☐ Kaynakça hariç
- ☐ Alıntılar hariç/dâhil
- ☐ Diğer

Dicle Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Programlarda Tez Çalışması İntihal Raporu Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

Hasan ZAN
14/12/2018

Dr. Öğr. Üyesi Abdulnasir YILDIZ
Tez Danışmanı
14/12/2018

Prof. Dr. İbrahim KAYA
Anabilim Dalı Başkanı
14/12/2018