



**KALP RAHATSIZLIKLARININ YAPAY ZEKÂ ALGORİTMALARI VE
AKILLI TELEFONLAR/TABLETLER KULLANILARAK TESPİT
EDİLMESİ**

Mesut GÜVEN

**DOKTORA TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2021

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Mesut GÜVEN

08/06/2021

KALP RAHATSIZLIKLARININ YAPAY ZEKÂ ALGORİTMALARI VE AKILLI TELEFONLAR/TABLETLER KULLANILARAK TESPİT EDİLMESİ

(Doktora Tezi)

Mesut GÜVEN

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2021

ÖZET

Bu tez çalışması kapsamında, mobil cihazlar ve dijital stetoskop kullanılarak kalp seslerinin hastalık bakımından analiz edilebilmesi için yapay zekâ destekli mobil uygulama geliştirilmiştir. Söz konusu uygulama, dijital stetoskop ile elde edilen kalp sesini yapay zekâ modülünde analiz ederek her beş saniyede hastalık teşhis sonucu üretmektedir. Üretilen tahmin, mobil cihazın ekranında sunulmakta olup, ayrıca anlık olarak kalp sesinin grafiği de ekranda görülmektedir. Tüm hesaplama işlemleri mobil cihazın donanımı üzerinde ve anlık olarak gerçekleştirilmektedir. Dolayısıyla, kalp sesinin internet kullanılarak bulut ortamına aktarılması ve hesaplama işlemlerinin bulut donanım üzerinde gerçekleştirilmesine ihtiyaç yoktur. Geliştirilen mobil uygulama Ankara Şehir Hastanesi Kardiyoloji Cerrahisi Bölümü'nde 162 hasta üzerinde denenmiş olup, mobil uygulamanın %92 doğruluk oranı ile hastalık tahmini yapabildiği tespit edilmiştir. Bu tahmin doğruluk oranı oldukça iyi bir sonuçtur, çünkü sadece iyi eğitilmiş kardiyologlar tarafından bu kadar yüksek bir hastalık tahmin oranı yakalanabilmektedir. Sonuç olarak, kalp hastalıklarının teşhis edilmesinde kullanılan en yaygın ve en eski yöntemlerden olan stetoskop ile kalp seslerinin dinlenmesi yönteminin, yapay zekâ algoritmalarının mobil cihazlarda uygulanması ile köklü bir değişime uğrayacağı ve uzman doktordan bağımsız olarak ön tanı yapılabilmesini sağlayacağı değerlendirilmektedir.

Bilim Kodu : 90542

Anahtar Kelimeler : Kalp hastalıkları, yapay zekâ, makine öğrenmesi, dijital stetoskop

Sayfa Adedi : 84

Danışman : Prof. Dr. Fırat HARDALAÇ

DETECTION OF HEART DISEASES USING ARTIFICIAL INTELLIGENCE
ALGORITHMS AND SMART PHONES / TABLETS

(Ph. D. Thesis)

Mesut GÜVEN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2021

ABSTRACT

Within the scope of this thesis, an artificial intelligence supported mobile application has been developed to analyze heart sounds in terms of disease using mobile devices and digital stethoscope. The application in question uses the heart sound obtained with a digital stethoscope. It produces disease diagnosis results every five seconds by analyzing heart sounds in the artificial intelligence module. The forecast is presented on the screen of the mobile device, and the graphic of the heart sound is also displayed on the screen. All calculations are performed instantly on the hardware of the mobile device. Therefore, it is not necessary to transfer the heart sound to the cloud using the internet and to perform the calculations on the cloud hardware. The developed mobile application has been tested on 162 patients in the Department of Cardiology Surgery of Ankara City Hospital, and it has been determined that the mobile application can predict the disease with an accuracy rate of 92%. This prediction accuracy is a very good result, as such a high disease prediction rate can only be achieved by well-trained cardiologists. As a result, it is considered that the auscultation, which is one of the most common and oldest methods used in the diagnosis of heart diseases, will undergo a radical change with the application of artificial intelligence algorithms on mobile devices and will enable pre-diagnosis to be made independently of the specialist doctor.

Science Code : 90542

Key Words : Heart Diseases, artificial intelligence, machine learning, digital stethoscope

Page Number : 84

Supervisor : Prof. Dr. Fırat HARDALAÇ

TEŞEKKÜR

Tez çalışması boyunca;

Maddi manevi desteklerini esirgemeyen ailem, sevgili eşim Tuba GÜVEN ve geliştirilen mobil uygulamayı deneyen ilk kişi olan sevgili kızım Defne GÜVEN,

Değerli görüş ve önerileri ile tezin mükemmel bir şekilde oluşmasına katkı sağlayan danışman hocam Prof. Dr. Fırat HARDALAÇ ile tez izleme komitesindeki hocalarım Prof. Dr. Murat Hüsnü SAZLI ile Prof. Dr. Sabri KOÇER,

Ankara Şehir Hastanesi'nde gerçekleştirilen testlerde her türlü desteği veren Prof. Dr. Kanat ÖZİŞİK ve Dr. Funda TUNA,

Stetoskop cihaz desteği nedeniyle dostum Barış ÜNVER (TURK AI),

ve ismini belirtmediğim fakat desteklerini sürekli hissettiğim tüm arkadaşlarıma teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	xii
RESİMLERİN LİSTESİ	xiv
SİMGELER VE KISALTMALAR.....	xv
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETİ.....	5
3. MATERYAL VE MOBİL UYGULAMANIN TANITILMASI	11
3.1. Materyal	11
3.1.1. PhysioNet CINC veri seti	11
3.1.2. Ankara Şehir Hastanesi veri seti	15
3.2. Mobil Uygulama.....	16
3.2.1. Girdi bloğu	19
3.2.2. Özniteliklerin çıkartılması bloğu	20
3.2.3. Sınıflandırma bloğu	28
3.2.4. Çıktı bloğu.....	29
4. SINIFLANDIRMA ALGORİTMALARI VE SINIFLANDIRMA BAŞARIMI TEST SONUÇLARI	31
4.1. Lojistik Regresyon Analizi Algoritması	32
4.2. Diskriminant Analizi Algoritmaları	34

	Sayfa
4.3. Naive Bayes Algoritmaları	37
4.4. Karar Ağacı Algoritmaları	40
4.5. Topluluk Öğrenmesi Algoritmaları	44
4.6. Destek Vektör Makinaları Algoritmaları	51
4.7. K-En Yakın Komşuluk Algoritmaları	60
5. MOBİL UYGULAMA İLE GERÇEKLEŞTİRİLEN DOĞRULAMA TEST SONUÇLARI	69
6. SONUÇ VE ÖNERİLER	75
KAYNAKLAR	79
ÖZGEÇMİŞ	83

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. MIT kalp sesi veri tabanı detaylı özellikleri	12
Çizelge 3.2. AAD kalp sesi veri tabanı detaylı özellikleri	12
Çizelge 3.3. AUTH kalp sesi veri tabanı detaylı özellikleri	13
Çizelge 3.4. TUT kalp sesi veri tabanı detaylı özellikleri.....	13
Çizelge 3.5. UHA kalp sesi veri tabanı detaylı özellikleri.....	14
Çizelge 3.6. DLUT kalp sesi veri tabanı detaylı özellikleri	14
Çizelge 3.7. SUA kalp sesi veri tabanı detaylı özellikleri.....	15
Çizelge 3.8. SUF kalp sesi veri tabanı detaylı özellikleri	15
Çizelge 3.9. SSH kalp sesi veri tabanı detaylı özellikleri	15
Çizelge 3.10. Ankara Şehir Hastanesi kalp sesi veri tabanı detaylı özellikleri.....	16
Çizelge 3.11. Öznitelikler	25
Çizelge 4.1. Test için kullanılan öznitelik setleri	31
Çizelge 4.2. Test için kullanılan hata matrisi	32
Çizelge 4.3. Lojistik regresyon algoritmasına ait sınıflandırma metrikleri	33
Çizelge 4.4. Diskriminant analiz algoritmalarına ait başarımlar metrikleri	35
Çizelge 4.5. Naive Bayes algoritmalarına ait başarımlar metrikleri	37
Çizelge 4.6. Karar ağacı algoritmalarına ait başarımlar metrikleri	41
Çizelge 4.7. Topluluk öğrenmesi algoritmalarına ait başarımlar metrikleri	46
Çizelge 4.8. Destek vektör makinası algoritmalarına ait başarımlar metrikleri	59
Çizelge 4.9. KNN algoritmalarının Parametreleri	60
Çizelge 4.10. KNN algoritmalarına ait başarımlar metrikleri	61
Çizelge 5.1. Literatürde belirtilen stetoskop ile kalp hastalığı tespit başarımları	69
Çizelge 5.2. Ticari ürünlere ilişkin kalp hastalığı tespit başarımları.....	70

Çizelge	Sayfa
Çizelge 5.3. Sınıflandırma algoritmasının başarımının karşılaştırılması	72
Çizelge 6.1. Mobil uygulama ve mevcut ticari yazılımların karşılaştırılması	75

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Mobil uygulamanın temel bileşenleri ve çalışma tasarımı	17
Şekil 3.2. Mobil uygulamaya ait MATLAB Simulink modeli	18
Şekil 3.3. Öznitelik çıkartma süreci	21
Şekil 3.4. Temel kalp sesleri, periyotlar ve gürültü örüntüleri	22
Şekil 3.5. Aday zirveler ve eleme sonrası kalan S1-S2 temsilci zirve noktaları	23
Şekil 3.6. Cep telefonuna ait mobil uygulama ekranı	30
Şekil 3.7. Tablet cihazına ait mobil uygulama ekranı.....	30
Şekil 4.1. Komşuluk analizi sonrasında özniteliklerin taşıdıkları bilgi seviyeleri.....	31
Şekil 4.2. Lojistik regresyon analizine ilişkin hata matrisi (33 öznitelik)	33
Şekil 4.3. Lojistik regresyon analizine ilişkin hata matrisi (15 öznitelik).	34
Şekil 4.4. Lineer diskriminant analizine ilişkin hata matrisi (33 öznitelik).....	35
Şekil 4.5. Lineer diskriminant analizine ilişkin hata matrisi (15 öznitelik).....	36
Şekil 4.6. Quadratic diskriminant analizine ilişkin hata matrisi (15 öznitelik)	36
Şekil 4.7. Gaussian Naive Bayes hata matrisi (33 öznitelik).....	38
Şekil 4.8. Gaussian Naive Bayes hata matrisi (15 öznitelik).....	38
Şekil 4.9. Kernel Naive Bayes hata matrisi (33 öznitelik).....	39
Şekil 4.10. Kernel Naive Bayes hata matrisi (15 öznitelik).....	39
Şekil 4.11. Fine Tree algoritmasına ait hata matrisi (33 öznitelik).....	41
Şekil 4.12. Fine Tree algoritmasına ait hata matrisi (15 öznitelik).....	42
Şekil 4.13. Medium Tree algoritmasına ait hata matrisi (33 öznitelik).	42
Şekil 4.14. Medium Tree algoritmasına ait hata matrisi (15 öznitelik)	43
Şekil 4.15. Coarse Tree algoritmasına ait hata matrisi (33 öznitelik).....	43

Şekil	Sayfa
Şekil 4.16. Coarse Tree algoritmasına ait hata matrisi (15 öznitelik).....	44
Şekil 4.17. Boosted Trees algoritmasına ait hata matrisi (33 öznitelik)	46
Şekil 4.18. Boosted Trees algoritmasına ait hata matrisi (15 öznitelik)	47
Şekil 4.19. Bagged Trees algoritmasına ait hata matrisi (33 öznitelik)	47
Şekil 4.20. Bagged Trees algoritmasına ait hata matrisi (15 öznitelik)	48
Şekil 4.21. Subspace Discriminant algoritmasına ait hata matrisi (33 öznitelik)	48
Şekil 4.22. Subspace Discriminant algoritmasına ait hata matrisi (15 öznitelik)	49
Şekil 4.23. Subspace KNN algoritmasına ait hata matrisi (33 öznitelik)	49
Şekil 4.24. Subspace KNN algoritmasına ait hata matrisi (15 öznitelik)	50
Şekil 4.25. RUSBoosted Trees algoritmasına ait hata matrisi (33 öznitelik)	50
Şekil 4.26. RUSBoosted Trees algoritmasına ait hata matrisi (15 öznitelik)	51
Şekil 4.27. Lineer ayrıştırılabilen örneklerdeki destek vektör makinasının çizilmesi....	52
Şekil 4.28. Lineer ayrıştırılamayan örneklerdeki destek vektör makinasının çizilmesi .	52
Şekil 4.29. Lineer SVM algoritmasına ait hata matrisi (33 öznitelik)	53
Şekil 4.30. Lineer SVM algoritmasına ait hata matrisi (15 öznitelik)	53
Şekil 4.31. Quadratic SVM algoritmasına ait hata matrisi (33 öznitelik)	54
Şekil 4.32. Quadratic SVM algoritmasına ait hata matrisi (15 öznitelik)	54
Şekil 4.33. Cubic SVM algoritmasına ait hata matrisi (33 öznitelik)	55
Şekil 4.34. Cubic SVM algoritmasına ait hata matrisi (15 öznitelik)	55
Şekil 4.35. Fine Gaussian SVM algoritmasına ait hata matrisi (33 öznitelik)	56
Şekil 4.36. Fine Gaussian SVM algoritmasına ait hata matrisi (15 öznitelik)	56
Şekil 4.37. Medium Gaussian SVM algoritmasına ait hata matrisi (33 öznitelik)	57
Şekil 4.38. Medium Gaussian SVM algoritmasına ait hata matrisi (15 öznitelik)	57
Şekil 4.39. Coarse Gaussian SVM algoritmasına ait hata matrisi (33 öznitelik)	58

Şekil	Sayfa
Şekil 4.40. Coarse Gaussian SVM algoritmasına ait hata matrisi (15 öznitelik).....	58
Şekil 4.41. Fine KNN algoritmasına ait hata matrisi (33 öznitelik)	62
Şekil 4.42. Fine KNN algoritmasına ait hata matrisi (15 öznitelik)	62
Şekil 4.43. Medium KNN algoritmasına ait hata matrisi (33 öznitelik).....	63
Şekil 4.44. Medium KNN algoritmasına ait hata matrisi (15 öznitelik).....	63
Şekil 4.45. Coarse KNN algoritmasına ait hata matrisi (33 öznitelik)	64
Şekil 4.46. Coarse KNN algoritmasına ait hata matrisi (15 öznitelik)	64
Şekil 4.47. Cosine KNN algoritmasına ait hata matrisi (33 öznitelik)	65
Şekil 4.48. Cosine KNN algoritmasına ait hata matrisi (15 öznitelik)	65
Şekil 4.49. Cubic KNN algoritmasına ait hata matrisi (33 öznitelik).....	66
Şekil 4.50. Cubic KNN algoritmasına ait hata matrisi (15 öznitelik).....	66
Şekil 4.51. Weighted KNN algoritmasına ait hata matrisi (33 öznitelik).....	67
Şekil 4.52. Weighted KNN algoritmasına ait hata matrisi (15 öznitelik).....	67

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 5.1. Kalp sesi grafiđi ile tablet cihaza ait mobil uygulama ekranı.....	70
Resim 5.2. Hastalık tahmin görseli ile tablet cihaza ait mobil uygulama ekranı.....	71
Resim 5.3. Doğrulama testlerinde kullanılan dijital stetoskop cihaz.....	71

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Hz

$\mathbb{R}^n$

μ

σ

Açıklamalar

Hertz

Reel Sayılar Kümesi

Ortalama Değer

Standart Sapma

Kısaltmalar

AAD

AH

AS

Adaboost

CPD

DA

FIFO

KAH

KNN

LR

MIT

MKH

MY

NB

PCG

PPG

RAM

RUSBoosting

SVM

Açıklamalar

Aalborg University

Aort Hastalıkları

Aortic Stenozu

Adaptive Boost

Çeşitli Patolojik Durumlar

Discriminant Analysis

First In First OUT

Korener Arter Hastalığı

K-Nearest Neighbour

Logistic Regression

Massachusetts Institute of Technology

Mitral Kapak Hastalıkları

Mitral Yetersizliği

Naive Bayes

Phonocardiogram

Photoplethysmogram

Random Access Memory

Random Under Sampling Boosting

Support Vector Machines

1. GİRİŞ

Problem durumu / Konunun tanımı

Kalp hastalıkları kaynaklı ölümler küresel çapta tüm ölümlerin başlıca nedenidir. Geçen yıl ortaya çıkan Yeni Korona Virüs (COVID19) nedeniyle küresel çapta bir salgın yaşanmakta olup, bu nedenle meydana gelen ölümler yukarıda belirtilen istatistik değerinde kullanılmamıştır. Kalp hastalıklarının teşhis edilmesi için kullanılan tetkik yöntemlerinden birisi stetoskop cihazı ile kalp sesinin dinlenmesidir. Uzman hekimler tarafından kullanılan stetoskoplar zaman içerisinde ses kaydı yapabilen ve istenmeyen sesleri temizleyen kabiliyetli cihazlara dönüşmüştür. Bu cihazlar sayesinde kalp seslerine ait kayıtlar sayısal olarak alınmakta ve uzman hekimler tarafından incelenmek üzere e-posta, mesajlaşma sistemleri vb. uygulamalar kullanılarak paylaşılabilmektedir. Dijital kalp seslerinin yapay zekâ ve makine öğrenmesi yöntemleri analiz edilmesi konusunda uzun yıllardır çalışmalar yürütülmektedir. Söz konusu çalışmalardan elde edilen sonuçlar, yapay zekâ ve makine öğrenmesi kullanılarak uzman bir kardiyolog kadar iyi derecede hastalık analizi yapılabildiğini göstermektedir.

Geleneksek tıp modelinde hastalık teşhisi klinik ortamlarda doktorlar tarafından yapılmakta olup, gelişmiş ülkelerde bile sağlık hizmetleri pahalıdır. Bu konuya ilişkin olarak; sağlık hizmetlerinin yüksek maliyeti nedeniyle periyodik olarak tekrarlanması gereken sağlık muayeneleri çoğu zaman yapılamamaktadır. Oysa tıbbın geleceği bağlantı kuran ve çok hassas alıcılara sahip mobil cihazların kullanıldığı mobil sağlık uygulamaları doğru bir yönde gelişmektedir. Geleneksel tıp modelinin aksine bu yeni model hastalığın önlenmesine odaklı, verilerin analitik olarak işlenmesini sağlayan ve kişiye özel bir model olmaktadır. Akıllı cihazların kabiliyetlerinin artması ve akıllı cihazlar ile internetin geniş kitleler tarafından kullanılması ile sağlık hizmetleri sanal ve gerçek dünyanın birleştiği bir hizmet modeliyle sunulabilir. Yeni tıp modelinde tanı cihazlarına yapay zekâ ve makine öğrenmesi ile röntgenleri ve doku örneklerini nasıl okuyacakları öğretiliyor. Örneğin, Google'daki araştırmacılar retina görüntüsü ile hastanın yüksek tansiyonu olduğuna ya da kalp krizi veya felç riskinin yüksek olduğuna işaret eden örüntülerin tespit edilmesi için çalışmalar sürdürmektedir.

Araştırmanın amacı

Stetoskop aracılığıyla kaydedilen kalp seslerinin mobil cihazda gömülü olan yazılım sayesinde analizinin yapılarak kalp sağlığı konusunda anlık olarak ön tanı bilgisinin sunulmasıdır. Tez çalışmasının hedefi ise; tasarlanacak mobil sağlık uygulamasını kullanıcının kolaylıkla kullanması, bunun için mobil yazılımın kullanıcı dostu, basit ve sade olmasıdır. Bu yazılıma ilişkin kullanılan yapay zekâ algoritmalarının kalp rahatsızlıklarını en az %90 doğruluk ile tespit etmesi gerekmektedir.

Bu amaç ve hedef ile tez çalışmasının özgün değeri

Dijital stetoskoplar donanımsal olarak çok gelişmiş durumdadır ve birçok stetoskop kendi mobil uygulaması yardımıyla kalp seslerini kaydedilmektedir. Kalp seslerini kaydedebilen birçok ürün olmasına rağmen, bu kayıtların hastalık bakımından analiz edilmesini sağlayan ve kullanıcılara kalp hastalığı konusunda sınıflandırma sonucu sunan bir mobil uygulama hizmetinin kısıtlı olduğu görülmektedir. Dolayısıyla, kalp hastalıklarının tespit edilmesi için yapay zekâ yöntemlerinin mobil uygulama ile entegre edilerek kullanıcıya sunulması tez çalışmasının temel özgünlüğüdür. Ayrıca, uygulamanın mobil cihaz donanımı üzerinde çalışabilmesi ve gerçek zamanlı sonuç üretecek şekilde tasarlanması çalışmanın ikinci özgünlüğüdür. Ankara Şehir Hastanesi'nde gerçekleştirilen doğrulama testlerinde elde edilen ses kayıtları ile literatüre yeni bir veri seti kazandırılmış olup, bu yeni veri seti çalışmanın bir diğer özgünlüğüdür.

Araştırmanın önemi

Kalp hastalıklarına yatkın olan bireylere uygulanması gereken muayene ve testlerin halihazırda sadece klinik ortamda yapılması nedeniyle hastaların sağlık hizmetine ulaşmasında aksaklıklar meydana gelmektedir. Ayrıca, sağlıklı olmasına rağmen çeşitli nedenlerden dolayı kalp sağlık durumunu öğrenmek isteyen bireyler de kliniklere başvurmaktadır, bu durum da sağlık hizmetlerinin etkinliği azalmaktadır. Klinik ortamda yapılan testlerin maliyeti nedeniyle hastalar rutin tarama ve testleri de yaptırmamaktadır. Geliştirilecek mobil kalp sağlık uygulaması sayesinde klinik ziyarete gerek kalmadan kalp sağlığı konusunda ön tarama yapılabilecektir. Dolayısıyla, daha çok kişi sağlık hizmeti alabilecektir. Geliştirilecek mobil kalp sağlık uygulaması ile kalp hastalığı konusunda

sağlıklı bireyler ön tarama yapabilir, bu sayede klinikler gereksiz yere meşgul edilmeyecek ve sağlık hizmetlerinin etkinliği artırılabacaktır. Bu durum, klinik ve uzman doktor maliyetlerini ortadan kaldıracığından sağlık hizmetlerinin maliyetini de düşürülebilir.

Sınırlılıklar

Yapay zekâ algoritmalarını eğitmek için PhysioNet CINC 2016 açık kaynak veri seti kullanılmıştır. Söz konusu veri seti değişik tarihlerde bağımsız olarak gerçekleştirilmiş çalışmalardan elde edilmiş kalp seslerini içermektedir. Cinsiyet, yaş, örnekleme frekansı ve kayıt kalitesi gibi kriterler her veri tabanı için farklıdır ve sadece normal, anormal olarak iki farklı gruba ayrılarak etiketlenmiştir. Sadece iki sınıf bulunması nedeniyle, geliştirilen yapay zekâ algoritması da iki sınıflı bir tahmin sonucu üretecek şekilde tasarlanabilmiştir. Dolayısıyla, algoritmanın hasta olarak tespit ettiği durumlarda detaylı hastalık tespiti üretilmesi mümkün değildir. Bu kısıt stetoskop ile kalp sesi dinleyerek teşhis etme yöntemine özgü bir kısıttır. Stetoskop ile kalp seslerini dinledikten sonra bir anormallik tespit edilirse hem doğrulama yapmak hem de hastalığı detaylandırmak için ileri tetkikler uygulanmaktadır.

Sonuç olarak, bu tez çalışması kapsamında, kalp hastalıklarının akıllı cihazlar ve yapay zekâ algoritmaları kullanılarak tespit edilmesi hedeflenmiştir. Bu amacı gerçekleştirmek için mobil cihazlarda anlık olarak analiz yapabilme kabiliyetine sahip özgün bir yapay zekâ algoritması geliştirilmiştir. Söz konusu algoritma, yine tez çalışması kapsamında geliştirilen mobil uygulamanın bir parçası olarak kullanılmış olup, uygulama sadece bir dijital stetoskop cihazı ile her beş saniyede bir kalp sesini dinlemekte ve hastalık tahmini verisini mobil cihazın ekranında göstermektedir. Bu verinin yanı sıra, uzman hekimlerin kalp sesine ait grafiği inceleyebilmeleri için anlık grafik bilgisini de ekranda gösterilmektedir. Tez çalışması kapsamında geliştirilen uygulama ve buna benzer uzaktan ön tanı ve teşhis gibi uygulamaların küresel ölçekte sağlık hizmetlerini olumlu olarak etkileyeceği ve giderek yaygınlaşacağı değerlendirilmektedir [1-3].

2. LİTERATÜR ÖZETİ

Tez çalışması kapsamında detaylı olarak literatür incelendiğinde;

Yasemin M. Akay, Metin Akay, Walter Welkowitz ve John Kostis'in 1994 yılında gerçekleştirdiği çalışmada [4] Rutger Üniversitesi veri tabanında bulunan 112 hastaya ait kalp sesinden dalgacık dönüşümü katsayıları ile fiziksel muayene sırasında elde edilen yaş, cinsiyet, vücut ağırlığı, sigara içip içmediği ve systolic, diastolic basınçları da içeren bir öznitelik vektörü oluşturmuş olup, bu öznitelikler yapay sinir ağları kullanılarak sınıflandırılmıştır.

1997 yılında H. Liang ve arkadaşları tarafından gerçekleştirilen çalışmada Shannon enerji kullanılarak bölümleme yapılmıştır [5]. Bu yöntemde sinyal dönüşümü yapıldıktan sonra eşik seviyenin üzerindeki zirve noktaları tespit edilir ve aralarından fazla olanlar elenerek gerçek S1 ve S2 notaları tespit edilmeye çalışılır. Aynı yıl dalgacık dönüşümü ile benzer bölümleme çalışmaları yapılmış olup, başarı oranları %95 üzerindedir.

1998 yılında Liang H. ve arkadaşları tarafından yapılan çalışma kapsamında, dalgacık dönüşümü ve karar ağacı benzeri bir yapı ile öznitelikler çıkartılmış olup, yapay sinir ağları ile 85 adet kalp sesi üzerinde %85 başarı oranı ile sınıflandırılmıştır [6].

Bu çalışmalara destek olmak amacıyla, 2000 yılında PhysioNet kalp seslerini açık kaynak olarak sunmuştur. Daha sonra; 2002 yılında Oskiper ve arkadaşları, kayan pencere ile tek saklı katmandan oluşan yapay sinir ağı kullanmışlardır [7]. 2003 yılında L.G. Gamero ve R. Watrous tarafından, systolic ve diastolic periyotlar arasındaki zamansal farklılık kullanılarak bir saklı Markov modeli ağı yardımıyla temel kalp sesi bölümlemesi gerçekleştirilmiştir. Sonuçlar, kalp sesine ait elektrokardiyogram sinyalinin zirveleri ile karşılaştırılmış olup, birinci kalp sesi bölümlemesi için %95 ve ikinci kalp sesi bölümlemesi için %97 tahmin doğruluğu yakalanmıştır [8].

2005 yılında D. Gill, N. Gavrieli ve N. Intrator yaptıkları çalışmada homomorfik filtre kullanılmadan önce shannon enerji ortalamalarını hesaplayarak bölümleme başarısını artırmışlardır. Toplam 44 adet ses sinyali üzerinde denemeler yapılmış olup, bölümleme

konusunda %96,5 hassasiyet oranı elde edilmiştir [9]. Aynı yıl Bhatikar ve arkadaşları özellikle bebeklerde gözlenen masum üfleme durumunun patolojik üflemeden ayrıştırılması konusunda çalışmıştır [10]. Denver’da bulunan çocuk hastanesinde toplam 241 adet kalp sesi kaydedilmiş olup, bunların 88 adedi masum üfleme ve 153 adedi de patolojik üfleme grubuna aittir. İlk olarak ses sinyallerine hızlı Fourier dönüşümü uygulanmış ve 0-300 Hz. aralığında bir dağılıma sahip olduğu tespit edilmiştir. Daha sonra 252 üyeli giriş katmanına, 15 üyeli ara katmanına ve 1 üyeli çıkış katmanına sahip olan yapay sinir ağı eğitilerek kullanılmıştır. Test için ayrılan kitle üzerinde yapılan denemelerde 29 masum üflemeden 24’ünü ve 24 patolojik üflemeden 21’ini doğru sınıfta tahmin etmiştir. Yine 2005 yılında Nigam ve arkadaşları üfleme örüntüsü olan kalp seslerinin temel bileşenlerini ayırarak incelemişlerdir. Çalışma kapsamında dinamik sistem teorisinde önerilen dönüşümler kalp sesi sinyallerine uygulanmış olup, temel kalp sesleri ile üfleme bileşenlerini ayrıştırılmıştır [11].

2006 yılında Ahlstrom Christer ve arkadaşları tarafından gerçekleştirilen çalışmada kalp üfürümlerinin tespit edilmesi için aortik stenosis, mitral yetmezlik veya fizyolojik üfleme olan 36 hastanın kalp sesi alınmış olup, Shannon enerjisi, dalgacık dönüşüm kullanılarak 207 adet öznitelik çıkartılmıştır [12]. Bunlardan 157 adedinin üfürüm tespiti konusunda daha önce kullanılmayan özniteliklerden oluşmaktadır. Eski ve yeni öznitelikler birleştirilerek oluşturulan 14 elemanlı bir vektör kullanılarak sınıflandırma yapılmış olup, %86 oranında doğru sınıflandırma elde edilmiştir. Aynı yıl Zhongwei Jiang ve Samjin Choi tarafından yapılan çalışmada farklı eşik seviyeleri ve kümeleme algoritması kullanılarak temel kalp sesleri ayrıştırılmıştır [13]. Aynı yıl D. Kumar ve arkadaşlarının yaptığı çalışma ile Shannon enerji dönüşümü kullanılarak ses sinyalleri elektrokardiyogram eşlenikleri olmadan temel kalp seslerine ayrıştırılmıştır [14].

2007 yılında Gupta ve arkadaşları tarafından yapılan çalışmada temel kalp seslerinin ayrıştırılması için ses sinyalleri önce homomorfik filtreden geçirilmiş olup, daha sonra k-means kümeleme algoritması kullanılmıştır. Bölümlene safhasından sonra öznitelikler çıkartılmış ve bu öznitelikler yapay sinir ağının girdisi olarak kullanılmıştır. Sağlıklı, systolic ve diastolic üfleme olmak üzere üç farklı kategorideki kalp sesleri sınıflandırılmış olup, başarımları sırasıyla normal örnekler için %99, systolic üfleme için %85 ve diastolic üfleme için %86’dır [15].

2008 yılında Chauhan ve arkadaşları Shannon Ortalama enerjiler ile sinyalin zarfın bulduktan sonra belirlenen eşik değeri yardımıyla bölümlendirme yapmış daha sonra çıkartılan öznelikler ve saklı Markov modeli ile 1381 adet kalp sesi üzerinde sınıflandırma yapılmıştır [16]. Elde edilen başarı sırasıyla; systolic üfleme için %96 ve diastolic üfleme ayrımı için %90'dır. Aynı yıl Choi ve arkadaşları zarf bulmak için en uygun yöntem konusunda bir inceleme yapmış olup, Shannon enerji, Hilbert dönüşümü ve kardiyak sesi karakteristiği dalga formu yöntemlerini karşılaştırılmıştır [17].

2009 yılında Maglogiannis I. ve arkadaşları tarafından yapılan çalışmada dalgacık dönüşümü kullanılarak temel kalp sesleri ve periyotları bulunmuştur. Daha sonra bu periyotların uzunlukları, ortalama değerleri ve varyant değerleri vb. bilgiler kullanılarak 100 adet öznelik çıkartılmış olup, sınıflandırma için destek vektör makinaları kullanılmıştır. Çalışmada yapılan sınıflandırma sonucunda %93,42 doğruluk oranı elde edilmiştir [18]. Aynı yıl Chen T. ve arkadaşları mobil telefon üzerinden, elektrokardiyogram sinyallerini bölümlenen ve kalp atım sayısını bulan bir çalışma yapmıştır [19].

2010 yılında Schmidt ve arkadaşları, Süreye-Bağlı Saklı Markov Modeli kullanarak kalp sesi bölümlenmesi yapmıştır. Geleneksel yöntemlere ilave olarak veri ön işleme ve öznelik çıkartma safhasından sonra systolic ve diastolic periyot sürelerinin tahmin edilmesi safhası eklenmiştir [20]. Aynı yıl Ari ve arkadaşları tarafından gerçekleştirilen çalışmada dalgacık dönüşümü ile oluşturulan öznelikler ve destek vektör makinası kullanılarak sınıflandırma yapılmıştır [21]. Önerilen yöntemde Lagrange çarpımı, en küçük kare algoritması ile değiştirilmiş ve ağırlık vektöründe yapılan bu değişim ile sınıflandırma hatası azaltılmıştır. Sonuçların diğer yöntemlere göre daha başarılı olduğu tespit edilmiştir. Aynı yıl, Avendano-Valencia LD., ve arkadaşları tarafından yapılan çalışmada, 26 normal ve 19 üfürüm içeren toplam 45 örnek En-yakın komşuluk sınıflandırıcı kullanılmış olup, %99 sınıflandırma başarısı elde edilmiştir [22].

2011 yılında PhysioNet/Computing in Cardiology Challenge 2011 tarafından yapılan yarışma kapsamında katılımcıların 2000 adet elektrokardiyogram sinyalinin bir mobil uygulama kullanarak sınıflandırılması istenmiştir. Katılımcılar tarafından gerçekleştirilen çalışmalarda elde edilen sonuçlar bildirgesi ile sunulmuştur. Aynı yıl Arash Gharenbaghi ve arkadaşları çocuklara ait elektrokardiyogram ve ses sinyallerinin her ikisine birden

bölümleme çalışmaları yapmıştır. Sağlıklı ve patolojik olarak hasta olarak tanımlanan 120 kişiye ait sinyaller üzerinde analiz yapılmıştır. Çalışma kapsamında izlenen yöntem sırasıyla; sinyallerin dalgacık dönüşümü alınmış, ikinci seviye katsayılar ile yeniden sinyal elde edilerek belirlenen eşik seviye üzerindeki zirve noktaları tespit edilmiştir [23]. Aynı yıl Li T. ve arkadaşları kalp seslerinin periyodik bir sinyal olduğunu ve bu periyodikliği ortaya koyma çalışmıştır [24]. Aynı yıl Moukadem ve arkadaşları tarafından yapılan çalışmada öznelik çıkartılması için hızlı Fourier dönüşümü kullanılmıştır [25].

2013 yılında Castro Ana ve arkadaşları kalp seslerini oluşturan temel bileşenleri Shannon enerji kullanarak bölümlere ayırmıştır. PhysioNet verileri ile yapılan kıyaslama neticesinde birinci kalp seslerinin konumları %91 oranında, ikinci kalp seslerinin konumları ise %93 oranında doğru olarak bulunmuştur [26]. Aynı yıl Moukadem ve arkadaşları tarafından yapılan çalışma kapsamında Fourier dönüşümü ve Shannon enerji dönüşümü karşılaştırılmıştır [27]. Aynı yıl Naseri ve arkadaşları kayan pencere yöntemi ile temel kalp seslerini tespit etmeyi başarmıştır [28].

2014 yılında Papadaniil ve arkadaşları uyguladıkları hesaplamalarla kalp sesi sinyalini ikili sinyal formuna dönüştürmüştür. Bu dönüşüm ile temel kalp sesleri ayrıştırılmıştır [29]. Aynı yıl Pedrosa ve arkadaşlarının yaptığı çalışmada sırasıyla; Shannon enerji, sürekli ve ayrık dalgacık dönüşümü, Mel frekans katsayıları kullanılarak 250 adet öznelik çıkartılmış olup, bunlardan 167 adedi optimal öznelik seti olarak seçilerek temel kalp sesi bileşenleri tespit edilmiştir [30].

2015 yılında Patidar ve arkadaşlarının yaptıkları çalışma kapsamında dalgacık dönüşümü ve sınıflandırma için destek vektör makinaları kullanılmıştır. Kullanılan ayarlanabilir seviye dalgacık dönüşümü ayrık zamanlı bir dönüşüm olup, sinyalin daha yumuşak bir halde sunulmasını gerçekleştirilmiştir [31].

2016 yılında PhysioNet tarafından kalp seslerinin analizi çalışmalarında kullanılmış tüm veri setleri birleştirilerek veri seti özellikleri ve kullanılan analiz yöntemleri detaylı olarak açıklanmıştır [32]. Söz konusu çalışmada kalp seslerinin temel özellikleri ve bölümleri açıklanmaktadır. Temel kalp sesi bileşenleri olan S1 ve S2 kalp seslerinin yapısı, frekans aralığı ifade edilmektedir. Kalp seslerinin gürültü etkisinden temizlenmesi için kullanılan yöntemler ele alınmıştır. Ayrıca kalp sesi bölümleme ve sınıflandırma çalışmalarında

kullanılan farklı veri setleri birleştirilerek 2435 adet kalp sesinden oluşan bir veri seti oluşturulmuş ve kullanıma sunulmuştur. Çalışma kapsamında sunulan veri seti halen referans veri seti olarak kullanılmakta olup, birçok çalışma ve uygulama bu veriler kullanılarak tasarlanmaktadır. Aynı yıl Chengyu Liu ve arkadaşları 2016 PhysioNet kapsamında oluşturulan veri seti üzerinde sınıflandırma yarışması yapılmış olup, katılımcıların yöntemleri ve başarı sonuçları ortaya konulmuş olup, yapay sinir ağları, destek vektör makinaları, en-yakın komşuluk sınıflandırıcı gibi çeşitli sınıflandırma yöntemleri ve dalgacık dönüşümü, Mel frekans dönüşümü gibi bölümleme yöntemi kullanılmıştır [33]. Literatürdeki tüm yöntemlerin denenmiş olması nedeniyle çok kapsamlı bir kaynaktır. Ayrıca, literatürdeki en kapsamlı açık kaynak veri setinin de sunulmuş olması bu çalışmanın önemini artırmış olmaktadır.

2018 yılında Siddique Latif ve arkadaşları benzer şekilde derin öğrenme ile sınıflandırma çalışması yapmışlardır [34]. Aynı yıl Juan P. ve arkadaşları PhysioNet veri setini kullanarak evrişim sinir ağı eğitmiş olup, kalan verileri test için kullanarak %97 başarıya ulaşmışlardır [35].

2019 yılında Yu Tsaoa ve arkadaşları tarafından yapılan çalışmada, dijital stetoskop tarafından gürültü etkisinin çok az olduğu bir ortam ve kaliteli cihazlar ile orijinal kalp sesleri kaydedilmiştir. İkinci adımda ise orijinal sesler üzerine değişik sinyal-gürültü oranlarında gürültü etkisi eklenerek yapay gürültülü veriler elde edilmiştir. Orijinal sesler kullanılarak bir derin öğrenme algoritması eğitilmiş olup, bu algoritma ile gürültü bindirilen sesler analiz edilmiş ve temel kalp seslerine ayrıştırılmıştır [36].

3. VERİ VE MOBİL UYGULAMANIN TANITILMASI

Bu bölümde, tez çalışması kapsamında kullanılan veri seti, geliştirilen yapay zekâ algoritması ve bu algoritmayı kullanarak anlık olarak hastalık tahmini yapan mobil uygulama modeli açıklanacaktır.

3.1. Veri

Yapay zekâ algoritmasının eğitilmesi için PhysioNet CINC 2016 veri seti, mobil uygulamanın klinik performansını ölçmek için ise Ankara Şehir Hastanesi veri seti kullanılmıştır.

3.1.1. PhysioNet CINC veri seti

PhysioNet CINC 2016, kalp sesi analizi ve hastalık tespiti çalışmalarında kullanılan tüm kayıtların birleştirildiği en geniş veri setidir. Birbirinden bağımsız ve değişik zamanlarda gerçekleştirilmiş dokuz çalışmaya ait veri tabanlarını içermektedir. Bu nedenle kullanılan kayıt cihazı, kayıt kalitesi, kayıt yeri pozisyonu, katılımcıların yaşları, cinsiyetleri vb. özellikler bakımından farklılıklar bulunmaktadır. Kalp sesi kayıtlarının tamamı uzman hekimler tarafından iki sınıfa ayrılmış olup, sırasıyla; sağlıklı bireyler “normal” ve hasta bireyler de “anormal” olarak ifade edilerek etiketlenmiştir. Bağımsız gruplar tarafından yapılan çalışmalarda farklı uzman hekimler tarafından etiketlendiği için kişisel hatalar barındırmaktadır. Kayıtlar on saniye ile birkaç dakika arasında değişen uzunluklarda kaydedilmiştir. PhysioNet CINC 2016 veri setini oluşturan dokuz veri tabanı hakkında detaylı bilgiler aşağıda sunulmaktadır.

- **MIT veri tabanı:** Prof. John Guttag, Dr. Zeeshan Syed ve meslektaşları tarafından Massachusetts Teknik Üniversitesi'nde oluşturulmuş olup, toplam 409 kalp sesi içermektedir [37, 38]. Kayıt esnasında Welch Allyn Meditron elektronik stetoskop kullanılmış olup, kayıt cihazı göğüs üzerinde dokuz farklı noktaya odaklanmıştır. Her katılımcıdan birden fazla kayıt alınmış olup, toplam beş farklı grup oluşturulmuştur. Bu gruplar sırasıyla; normal, mitral kapak hastalıkları, üfleme, aort hastalıkları ve çeşitli patolojik durumlardır. Kayıtlar ev ziyaretleri esnasında veya klinik ortamlarda hastane

ziyaretlerinde toplanmıştır. Kayıtlarda organlardan kaynaklanan gürültüler, stetoskop cihazın hareket ettirilmesinden kaynaklanan gürültüler ile konuşma, araç sesi gibi ortam gürültüleri vardır. Bu veri setindeki toplam katılımcı sayısı ve kayıt sayıları Çizelge 3.1.'de gösterilmektedir.

Çizelge 3.1. MIT kalp sesi veri tabanı detaylı özellikleri

Veri tabanı	Bulgu	Katılımcı sayısı	Kayıt sayısı	Örnekleme frekansı
MIT	Normal	38	117	44 100 Hz, Welch Allyn electronic stethoscope
	MKH	37	134	
	Üfleme	34	118	
	AH	5	17	
	ÇPD	7	23	

• **AAD veri tabanı:** Aalborg Üniversitesi'nde yapılan çalışma kapsamında tarafından oluşturulmuştur [20]. Kalp sesleri Littman elektronik stetoskop kullanılarak toplanmıştır. Toplam 151 katılımcı bulunmakta olup, bunlardan 30 kadarının kalp kapakçık problemi bulunmaktadır. Çalışmanın temel amacı koroner arter hastalığını tespit etmek olduğu için kalp kapakçık problemi olduğu bilinen hastalardan kayıtlar toplanmıştır. Kayıtların çoğunluğu sekiz saniye civarında bir uzunlukta toplanmıştır. Katılımcı sayısı, kayıt sayısı ve kayıt cihazı özellikleri Çizelge 3.2.'de gösterilmektedir.

Çizelge 3.2. AAD kalp sesi veri tabanı detaylı özellikleri

Veri tabanı	Bulgu	Katılımcı sayısı	Kayıt sayısı	Örnekleme frekansı
AAD	Normal	121	544	4 000 Hz, 3M Littmann
	KAH	30	151	

• **AUTH veri tabanı:** Aristotle Üniversitesi'nde Dr. Chryse D. Papadantil ve arkadaşları tarafından Thessaloniki Hastanesi'nde 45 katılımcı ile kalp sesleri kayıt altına alınmıştır. Kayıtlar 10 saniye ile 122 saniye arasında değişmekte olup, göğüs bölgesinden kayıt yapılmıştır. Veri seti hakkında detaylı bilgiler Çizelge 3.3.'te gösterilmektedir.

Çizelge 3.3. AUTH kalp sesi veri tabanı detaylı özellikleri

Veri tabanı	Bulgu	Katılımcı sayısı	Kayıt sayısı	Örnekleme frekansı
AUTH	Normal	11	11	4 000 Hz, Audioscope
	MY	17	17	
	AH	17	17	

• **TUT veri tabanı:** Toosi Teknik Üniversitesi tarafından gerçekleştirilen çalışma kapsamında 2013 yılında oluşturulmuştur [28]. Katılımcıların hastalık durumlarının etiketlenmesi için kalp sesleri kaydedilmeden önce elektrokardiyogram kayıtları da alınmış ve teşhis için kullanılmıştır. Kayıt esnasında dört farklı odak noktası kullanılmış olup, 15 saniye uzunluğunda 174 adet kayıt elde edilmiştir. TUT veri seti için detaylı bilgiler Çizelge 3.4.'de gösterilmektedir.

Çizelge 3.4. TUT kalp sesi veri tabanı detaylı özellikleri

Veri tabanı	Bulgu	Katılımcı sayısı	Kayıt sayısı	Örnekleme frekansı
TUT	Normal	28	174	8 000 Hz
	ÇPD	16		

• **UHA veri tabanı:** Bu veri setindeki kalp sesleri Infral Corporation'nın ürettiği prototip stetoskoplar ile 2013 yılında Dr. Ali Moukadem ve arkadaşları tarafından kayıt altına alınmıştır. Toplam 79 kayıt bulunmakta olup, norma kayıtlar iki farklı gruptan toplanmıştır. Normal katılımcılar sırasıyla; NHC olarak isimlendirilen gruptaki 18-40 yaş aralığındaki 19 kişi ile Avrupa Uzay Ajansı tarafından fonlanan MARS500 projesinde görevli 6 astronot bulunmaktadır. Anormal kayıtlar ise Strasburg Hastanesi'nde tedavi gören 30 katılımcıya aittir. Bu katılımcıların 10'u bayan 20'si erkek ve tamamı 44 ile 90 yaş aralığındadır. Kayıtlar mitral ve aortik bölgeden alınmış olup, ECG ve görüntüleme

yöntemleri ile hastaların ritmik bozukluklar ve kalp kapak hastalıkları olduğu teyit edilmiştir.

Çizelge 3.5. UHA kalp sesi veri tabanı detaylı özellikleri

Veri tabanı	Bulgu	Katılımcı sayısı	Kayıt sayısı	Örnekleme frekansı
UHA	Normal: NHC	19	19	8 000 Hz
	Normal: MARS500	6	20	
	Pathologic	30	40	

• **DLUT veri tabanı:** Bu veri setindeki kalp sesleri Dalian Teknoloji Üniversitesi'nde 2011 yılında gerçekleştirilen çalışma kapsamında oluşturulmuştur [24]. Yaşları 4 ile 35 arasında değişen 174 sağlıklı katılımcı ile yaşları 10 ile 88 arasında değişen 335 kalp hastasından ses kayıtları toplanmıştır. Kayıtlar 5 saniye ile 98 saniye arasında değişen uzunluklardadır.

Çizelge 3.6. DLUT kalp sesi veri tabanı detaylı özellikleri

Veri tabanı	Bulgu	Katılımcı sayısı	Kayıt sayısı	Örnekleme frekansı
DLUT	Normal	174	338	8 000 Hz, 3M Littmann
	KAH	335	335	

• **SUA veri tabanı:** Shiraz Üniversitesinde 2015 yılında gerçekleştirilen çalışma kapsamında oluşturulmuş olup, bu veri setinde sadece yetişkinler olduğu için Shiraz Üniversitesi erişkin veri seti olarak da isimlendirilmektedir. [39]. Yaşları 16 ile 88 arasında değişen 69 kadın ve 43 erkek katılımcıdan oluşan bir grup içerisinde kayıtlar toplanmıştır. Kalp sesi kayıtları göğüs apex bölgesinden ve katılımcılar dinlenme halinde iken alınmıştır. Kayıt uzunlukları 30 saniye ile bir dakika arasında değişmekte olup çoğunlukla her katılımcıdan tek kayıt alınmıştır.

Çizelge 3.7. SUA kalp sesi veri tabanı detaylı özellikleri

Veri tabanı	Bulgu	Katılımcı sayısı	Kayıt sayısı	Örnekleme frekansı
SUA	Normal	79	81	8 000 Hz, JABES stetoskop
	Pathologic	33	33	

• **SUF veri tabanı:** Bu veri seti de SUA veri seti ile aynı çalışma kapsamında 2015 yılında Shiraz Üniversitesindeki çalışmada oluşturulmuştur [39]. Veri seti, yaşları 16 ile 47 arasında değişen 109 hamile katılımcıdan elde edilen kayıtlar ile oluşturulmuştur. Kayıt esnasında stetoskop cihazı maternal bölgeye odaklanmış olup, ikiz çocuk bekleyen yedi hamile katılımcıdan iki farklı bölgeden iki farklı kayıt alınmıştır. Kayıtlar ortalama 90 saniye uzunluğundadır.

Çizelge 3.8. SUF kalp sesi veri tabanı detaylı özellikleri

Veri tabanı	Bulgu	Katılımcı sayısı	Kayıt sayısı	Örnekleme frekansı
SUF	Fetal	116	119	8 000 Hz, JABES stetoskop
	Maternal	109	92	

• **SSH veri tabanı:** Bu veri seti, Danimarka Skejby Sygehus Hastanesi'ndeki hastalardan elde edilmiştir. Toplam 35 katılımcıdan göğüs bölgesinden kayıtlar alınmıştır. Kayıt uzunlukları 15 saniye ile 69 saniye arasında değişmektedir.

Çizelge 3.9. SSH kalp sesi veri tabanı detaylı özellikleri

Veri tabanı	Bulgu	Katılımcı sayısı	Kayıt sayısı	Örnekleme frekansı
SSH	Normal	12	12	8 000 Hz
	Pathologic	23	23	

3.1.2. Ankara Şehir Hastanesi veri seti

Mobil uygulama Ankara Şehir Hastanesi Kardiyoloji Bölümü'nde 162 katılımcı üzerinde test edilmiştir. Mobil uygulama her beş saniyede bir tahmin üretmektedir ve bu esnada

kalp sesleri mobil cihaz donanımı üzerinde kaydedilebilmektedir. Mobil uygulamanın kayıt özelliği kullanılarak 162 adet kalp sesi kaydedilmiştir. Kayıt esnasında ThinkLabs marka dijital stetoskop göğüs bölgesinde dört farklı odak noktası üzerine konumlandırılmış olup, kalp sesleri 25 saniye ile 45 saniye arasında değişen sürelerde kaydedilmiştir. Veri seti sağlıklı ve hasta olarak iki temel grupta uzman kardiyologlar tarafından etiketlenmiştir. Öncelikle, mobil uygulama ve sayısal stetoskop kullanılarak kardiyologlar tarafından dinlenme yapılmış ve kayıt yapılmıştır. Daha sonra, ilk safhada uzman doktorlar ve mobil uygulama tarafından hasta olarak belirlenen tüm katılımcıların hastalık durumlarının teyit edilmesi için ECG ve görüntüleme teknikleri vb. yöntemler kullanılmıştır. Bu veri setine ilişkin detaylı bilgiler Çizelge 3.10.'da sunulmaktadır.

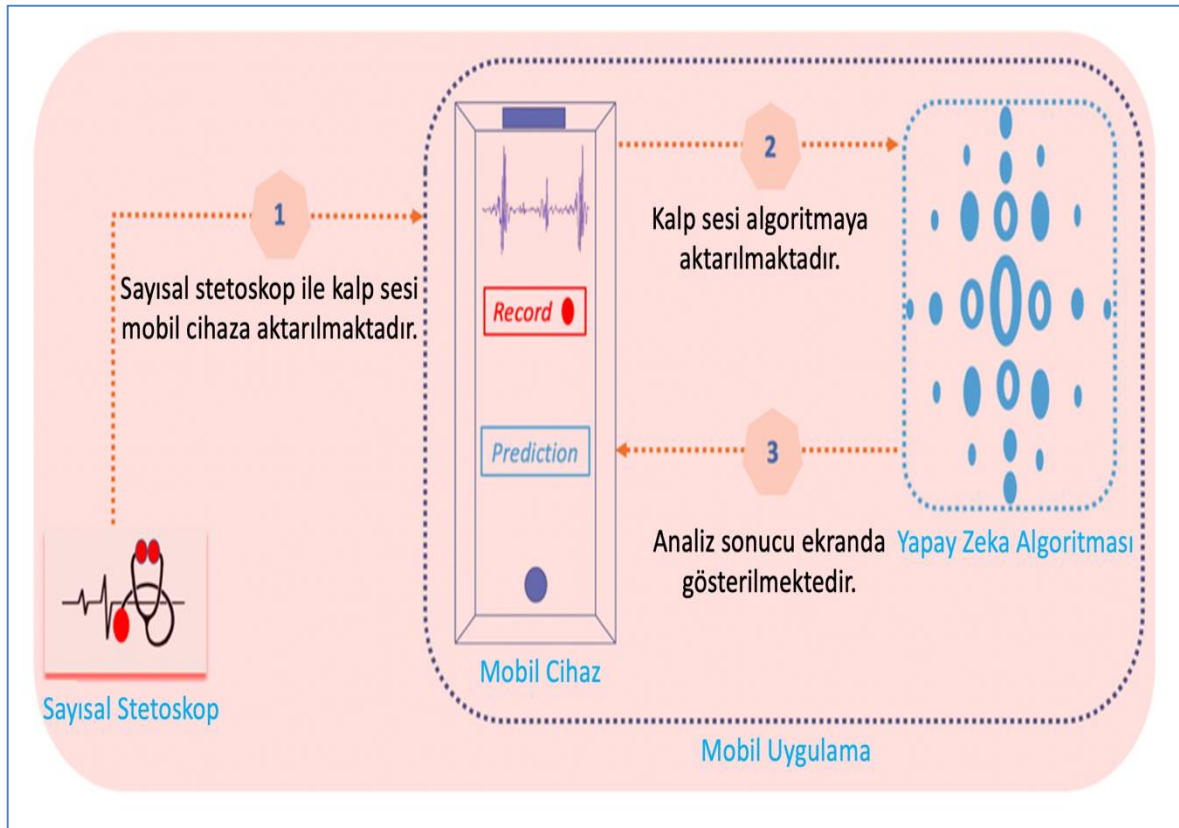
Çizelge 3.10. Ankara Şehir Hastanesi kalp sesi veri tabanı detaylı özellikleri

Bulgu	Stetoskop ile teşhis sonucu	Diğer tetkikler ile teşhis sonucu	Yaş (Yıl)	Süre (Saniye)	Kayıt Cihazı
Sağlıklı	88	-	15-70	25-45	ThinkLabs sayısal stetoskop, 44 100 Hz
Hasta	74	74	15-70	25-45	ThinkLabs sayısal stetoskop, 44 100 Hz

3.2. Mobil Uygulama

Mobil uygulama, sayısal stetoskop ile alınan kalp seslerinin yapay zekâ algoritması ile analiz edilerek hastalık teşhis sonucunun kullanıcıya sunulduğu bir sistemdir. Mobil uygulama ağ bağlantısı ile sunucu sisteme bağlanma ihtiyacı duymadan, tamamen mobil cihaz donanımını kullanarak hesaplama ve analiz yapmaktadır. Analizler anlık olarak yapılmakta ve her beş saniyede bir analiz sonucu mobil cihaz ekranında gösterilmektedir. Ayrıca ekran kaydırıldığında anlık olarak kalp ses sinyali grafiği ekranda çizdirilmekte ve dinamik olarak akmaktadır. Bu grafik özellikle uzman doktorların normal ses grafiğine ait olmayan kalp hastalığının kaynaklı örüntüleri gözlemlemesine ve duydukları anormal örüntüleri anlık olarak görsel grafikte eşleştirmelerine yardımcı olmaktadır. Mobil uygulama cep telefonları ve tablet cihazlar için iki farklı tasarım ile oluşturulmuştur. Daha

önce ifade edildiği üzere algoritma beş saniye uzunluğundaki kalp seslerinden öznitelikler çıkartarak hastalık tahmini yapmaktadır. Dolayısıyla, her beş saniyede yeni hastalık tahmin sonucu ekranda gösterilmekte ve önceki tahminler silinmektedir. Tablet sürümünde önceki tahmin sonuçlarının da karar sürecine eklenmesi ve hafızalı bir bellekte kaydedilen tahminlerin çoğunluk oylama yöntemi ile sunulmasına yönelik bir ihtiyaç uzman hekimler tarafından talep edilmiştir. Bu nedenle tablet sürümüne son beş tahmine ait bilgiyi gösterecek şekilde hafızalı destekli teşhis sonucu da eklenmiştir. Uygulama, hastalık tahmin sonucu ve anlık kalp sesi grafiğinin ekranda sunulmasının yanında kalp sesinin mobil cihaz donanımına kaydedilebilmesine de imkân sağlamaktadır. Mobil uygulamanın nasıl çalıştığına ilişkin çerçeve Şekil 3.1.'de sunulmaktadır.




Şekil 3.1. Mobil uygulamanın temel bileşenleri ve çalışma tasarımı

Uygulama Android tabanlı işletim sistemlerine sahip mobil cihazlarda çalışacak şekilde derlenmiş olup, uygulamanın temel bileşeni olan yapay zekâ algoritması MATLAB ortamında geliştirilmiştir. Algoritmanın geliştirilmesinden sonra uygulamayı oluşturan tüm bileşenler Mobil Cihazlar için Simulink Destek Paketi kullanılarak sistem olarak tasarlanmış ve derlenmiştir. Bu paket MATLAB fonksiyonları ve MATLAB Simulink

bileşenlerini kullanılarak yapay zekâ modelleri ile mobil uygulama tasarlamaya ve derlemeye imkân sağlamaktadır. Bu tez çalışması kapsamında geliştirilen ve klinik ortam başarı testleri yapıldıktan sonra kullanıma sunulan mobil uygulama da bu platform kullanılarak gerçekleştirilmiştir.

Mobil uygulamaya ait MATLAB Simulink modeli Şekil 3.2.'de sunulmakta olup, bu şekildeki kırmızı baloncuklar uygulamanın ekranda görünen butonlarını, sayısal çıktı değerlerini, kalp sesi grafiği ve kayıt zamanı gibi görselleri içermektedir. Mavi renkli baloncuklar ise sırasıyla; kalp sesinin alınmasını, özelliklerin çıkartılması için kullanılan fonksiyonları, hastalık teşhisi için kullanılan sınıflandırma algoritmasını ve hastalık tahmin sonucu ile bu sonuca ilişkin resmin ekranda gösterilmesi işlemlerinin yapıldığı alanları içermektedir.



Şekil 3.2. Mobil uygulamaya ait MATLAB Simulink modeli

İlerleyen bölümlerde mobil uygulamada kullanılan modeli oluşturan Simulink ifadelerini daha geniş bir şekilde ele alırsak; Şekil 3.2.'de mavi renkli baloncuklar ile işaretlenen girdi, özniteliklerin çıkartılması, sınıflandırma ve çıktı blokları ile sırasıyla açıklanacaktır.

3.2.1. Girdi bloğu

Mobil uygulama kalp sesi sinyalini sayısal bir stetoskop cihazın mobil cihazın kulaklık girişine bağlanması ile almaktadır. Çalışma kapsamında kullanılan stetoskop ThinksLabs marka ve saniyede 44 100 Hz örnekleme frekansına sahip bir cihazdır. Bu cihazdan gelen kalp sesi sinyalinin mobil uygulama ile alınabilmesi için AUDIO_CAPTURE isimli bir Simulink bloğu eklenmiş ve uyumlu çalışması için örnekleme frekansı 44 100 Hz olarak ayarlanmıştır. Bu blok stetoskoptan gelen sinyali girdi olarak kabul etmekte olup, sinyali üç farklı hedefe göndermektedir. Girdi sinyalinin gönderildiği hedefler sırasıyla; dosya yazma bloğu (FILE_WRITE), akan sinyalin biriktirildiği BUFFER bileşeni ve son olarak akan sinyal grafiğinin çizdirildiği PHONOCARDIOGRAM_GRAPH bileşenidir.

Giriş bloğu iki kanallı bir yapıya sahip olduğu için her saniyede birbirinin aynısı olan kanallardan 44 100'er adet örnek akmaktadır. Akan sinyal birinci balondan gelen bir kontrol sinyali ile FILE_WRITE bloğu tarafından mobil cihazın dahili hafıza birimine Recorded_PCG_Signal.wav ismiyle, wav formatında kaydedilmektedir. Dahili hafızaya kaydetme işlemini yapan blok, Mobil Cihazlar için Simulink Destek Paketi'nin yüklenmesi ile MATLAB Simulink kütüphanesinden eklenebilecek bileşenlerinden birisidir. Kayıt yeri, kayıt ismi, örnekleme frekansı ve kontrol girişi gibi parametreler değiştirilebilmektedir.


Kayıt işlemini kontrol eden sinyal birinci balonda bulunan START_RECORDING isimli buton ile tetiklenmekte ve durdurulmaktadır. Bu buton da Simulink kütüphanesinden seçilebilmekte olup, durum tabanlı Boolean tipinde bir değer üretilmektedir. Eğer buton kapalı konumda ise False, açık konumda ise True değeri üretilerek gönderilmektedir. Elde edilen buton değerinin Integer değere, yani sıfır ve bir değerine çevrilmesi için BUTTON_VALUE isimli bir fonksiyon kullanılmaktadır. Bu fonksiyon değeri hem yazma bloğunu hem de kayıt zamanını gösteren bloğu beslemektedir.

Kayıt zamanını gösteren blok ise birinci balonda yer alan RECORDING_TIME isimli bloktur. Bu blok, giriş portunda beslendiği sayacın değerini sürekli ekrana basmaktadır. Eğer sayaç bir değeri ile beslenirse, yani iki durumlu kayıt başlama butonu açık konumda olursa sayacın değeri sürekli artar ve salise hassasiyetinde kayıt zamanını artırır.

Şekil 3.2.'de kırmızı renk ile belirtilen ikinci balondaki bileşen ile kalp sesi grafiği anlık olarak çizdirilebilmektedir. Grafik çizdirmek için kullanılan bileşen Simulink kütüphanesinde bulunmakta olup, düzgün bir grafik çizdirilebilmesi için giriş sinyalinin değeri ve tipi, grafik boyutu, grafik maksimum değerleri, dinamik ölçekleme vb. parametrelerin doğru tanımlanması gerekmektedir. Giriş bloğundan gelen akan sinyal iki kanal halinde her saniyede $2 \times 44\,100$ boyutundaki bir matris oluşturur. İki kanal grafik olarak çizdirmek ve işlemek için gereksizdir. Bu nedenle ikinci balonun beslendiği porttan hemen önce akan sinyal STEREO_TO_MONO isimli fonksiyon ile $1 \times 44\,100$ boyutuna indirilmektedir. Ayrıca, bu fonksiyon ile tek kanala indirgenen kalp sesi sinyali işlenmek üzere beş saniyelik bölümler halinde depolanacağı BUFFER isimli bir depolama bloğuna aktarılır. Simulink kütüphanesinde bulunan bu blok örnek sayısına göre istenen büyüklükte sinyal oluşturmak için kullanılır. Blok belirlenen örnekleme frekansına göre çalışır ve anlık olarak akan sinyal değerlerini tutar. Bu blokta ilk giren örnek ilk çıkar (FIFO). Beş saniye uzunluğunda bir sinyal elde edilmek istendiğinden, toplam örnek sayısı $220\,500$ olarak belirlenmiştir. Burada basit fakat önemli bir noktaya temas etmek gerekmektedir; mobil cihazların ve stetoskop gibi güncel kayıt cihazlarının çoğunun kabul edilen tanımlı örnekleme frekansı $44\,100$ 'dür. Fakat farklı örnekleme frekansına sahip bir stetoskop veya kayıt cihazı kullanılacaksa ve giriş bloğunda bir uyumlaştırma yapılmadıysa, giriş kaynağından akan sinyalin örnekleme frekansı beş ile çarpılarak BUFFER bloğunun değerinin kaynak kodlarda güncellenmesi gerekecektir.

3.2.2. Özniteliklerin çıkartılması bloğu

Girdi bölümünden akan sinyal beş saniyelik çerçeveler halinde ele alınmış olup, Şekil 3.2.'de görülmekte olan EXTRACT_FEATURES isimli blok içerisindeki MATLAB fonksiyonu kullanılarak her çerçeveden zaman, frekans, enerji ve yüksek seviye istatistik tabanlı öznitelikler ile Mel frekansı katsayılarından elde edilen öznitelikler çıkartılmıştır. Bu kısımda gerçekleştirilen öznitelik çıkartma sürecine ilişkin akış diyagramı Şekil 3.3.'de sunulmaktadır.




Şekil 3.3. Öznitelik çıkartma süreci

Veri ön işleme safhasında iki temel işlem gerçekleştirilmektedir. Bunlardan ilki gürültüden temizleme işlemi, ikincisi ise temel kalp seslerine ayırma yani bölümlendirme işlemidir.

• **Gürültüden temizleme:** Eğitim için kullanılan veri setindeki kalp sesleri hem klinik ortamda hem de ev ziyaretleri gibi klinik dışı ortamlarda kayıt altına alınmıştır. Ayrıca, veri setini oluştururken veri tabanları bağımsız çalışmalar ile oluşturulduğu için kayıt odak noktası farklıdır, kullanılan kayıt cihazlarının kalitesi farklıdır. Bu durum kalp seslerinde hem organlardan kaynaklanan iç ortam gürültülerinin hem de çevresel faktörlerden kaynaklanan dış ortam gürültülerinin bulunmasına neden olmaktadır. Kalp seslerini oluşturan temel bileşenler birinci ve ikinci kalp sesleri olarak ifade edilmektedir. Temel kalp sesleri 20 ile 150 Hz aralığındaki alt frekans bantlarında yer almakta olup, organlardan kaynaklanan gürültüler ile kayıt esnasında ortamdan kaynaklanan diğer gürültüler yüksek frekans bantlarına aittir [40]. Dolayısıyla, kalp seslerini gürültüden temizlemek için alçak frekansları geçiren bir filtre kullanmak faydalı olacaktır. Bu çalışma kapsamında kesim frekansı 150 Hz olan butterworth tipinde bir filtre tüm kalp seslerine hem eğitim safhasından önce hem de algoritmanın özniteliklerin çıkartılması safhasında kullanılan fonksiyon içerisinde uygulanmaktadır.

• **Bölümleme:** Kalp sesleri, kalbin mekanik olarak kasılması ve gevşemesi ile kan akışından kaynaklanan iki temel ses örüntüsünü içermektedir. Bu sesler sırasıyla, birinci kalp sesi (S1) ve ikinci kalp sesi (S2) olarak isimlendirilmektedir. Birinci kalp sesi ile ikinci kalp sesi arasındaki bölüm Systole ve ikinci kalp sesi ile birinci kalp sesi arasındaki bölüme ise Diastole adı verilmektedir.



Şekil 3.4. Temel kalp sesleri, periyotlar ve gürültü örüntüleri.

Temel kalp sesleri hastalık tespiti için kullanılan faydalı örüntülerdir. Sağlıklı kalp sesleri sadece temel kalp seslerini içermektedir. Hasta bireylere ait kalp sesleri ise kalbin mekanik hareketinin düzgün olmaması nedeniyle ilave gürültülü örüntüler barındırmaktadır. Kalp sesleri periyodik sinyaller olup, bir kalp atışı birinci kalp sesi, ikinci kalp sesi, systolic ve diastolic periyotları kapsar. Sağlıklı bireylerde, dinlenme pozisyonunda kalp atış hızı dakikada 60-80 arasındadır [41, 42]. Şekil 3.4.'de üst kısımdaki grafikte temel kalp sesleri, periyotlar ve bir kalp atışı uzunluğu gösterilmekte olup, alt kısımdaki grafikte kırmızı daireler içerisinde belirtilen gürültülü örüntüler gösterilmektedir.

Temel kalp seslerinin tespit edilmesi, yani bölümlene yapılabilmesi için birçok teknik ve yöntem kullanılmaktadır [32]. Bu yöntemleri dört temel grupta toplamak mümkündür. Sırasıyla; sinyalinin zarfının çıkartılması tabanlı, öznelilik tabanlı, makine öğrenmesi yöntemleri tabanlı ve saklı Markov modeli kullanılarak gerçekleştirilen yöntemler olarak gruplanabilir.


Zarf tabanlı yöntemlerde Shannon enerjisi ile zarf çıkartmak kullanılan yöntemlerden birisidir [5]. Bu yöntemde, düşük yoğunluktaki ses bileşenleri zayıflatılarak, orta yoğunluk seviyesindeki ses bileşenleri vurgulanmaktadır. Başka bir çalışmada, Shannon zarfı

çıkartılmadan önce dalgacık dönüşümü yapılmıştır [6]. Bir diğer çalışmada, Hilbert dönüşümü kullanılarak kompleks sinyal reel ve sanal kısımlarına ayrılmış, daha sonra sanal kısımdan anlık frekanslar çıkartılarak zarf süzölmüştür [43]. Bu yöntem S1 ve S2 zirvelerinin karakteristiği olarak da bilinmektedir. MHS veri tabanındaki veriler üzerinde çalışma yapılmış ve ortalama %97 civarında bir bölümlene başarısı elde edilmiştir.

Öznitelik tabanlı yöntemler de ise frekans, zaman ve genlik temelli öznitelikleri kullanarak bölümlenmektedir. Dalgacık dönüşümü yapıldıktan sonra frekans temelli öznitelikler çıkartılarak yapılan bölümlene neticesinde %98 doğruluk yakalanmıştır. Benzer şekilde Shannon entropi ve zaman uzayından elde edilen öznitelikler ile yapılan bölümlene çalışmaları da bulunmaktadır.

Makine öğrenmesi yöntemleri kullanılarak yapılan çalışmalarda sinir ağları sıklıkla kullanılmaktadır [7]. Sık kullanılan bir diğer yöntem K-means kümeleme yöntemidir [19].

Saklı Markov modeli temelli yöntemlerde, olasılıksak sonlu durum makineleri kullanılarak S1 ve S2 tespiti yapılan çalışmalar bulunmaktadır [8]. Bölümlene çalışmalarında en çok kullanılan yöntemlerden birisi de 2010 yılında gerçekleştirilen saklı yarı Markov modelidir [18]. Bu çalışmada öncelikle elle S1 ve S2 noktaları işaretlenmiş, daha sonra systolic ve diastolic periyotların ortalamaları hesaplanarak S1 ve S2 durumlarının Gauss dağılımındaki beklenen yerleri çıkartılmıştır. Toplam dört durum bulunmakta olup, bunlar, S1, S2, systolic ve diastolic olarak isimlendirilmektedir.



Şekil 3.5. Aday zirveler ve eleme sonrası kalan S1-S2 temsilci zirve noktaları.

Bu çalışmada kullanılan bölümlleme yöntemi ise zarf tabanlı bir yöntemdir. Sinyalin zarfı alındıktan sonra en büyük zirve noktası tespit edilmektedir. S1 ve S2 noktalarını bulmak için en büyük genlik değeri olan zirve değerinin %30'u eşik seviye kabul edilerek bu değerden büyük olan tüm zirveler aday zirve noktası olarak alınmaktadır. Aday zirveler ile fazla zirvelerin elenmesinden sonra kalan S1-S2 örüntülerini temsil eden zirveler Şekil 3.5.'de gösterilmektedir.

Eleme algoritması uygulandıktan sonra her S1 ve S2 örüntüsünü temsil etmek üzere bir tane zirve noktası kalır (Şekil 3.5.). Dolayısıyla, bu temsilciler kullanılarak systolic ve diastolic periyot uzunlukları hesaplanabilir. Periyotlar ve temel kalp sesleri belirlendikten sonra, yani kalp seslerinde bölümlleme işlemi gerçekleştirildikten sonra zaman uzayı, frekans uzayı ve istatistiksel temelli öznitelikler çıkartılabilir. Bu çalışma kapsamında geliştirilen bölümlleme algoritması dört adım halinde uygulanmaktadır. Bu adımlar sırasıyla;

Birinci adımda aralarında 50 milisaniyeden az olan zirveler kontrol edilmektedir. Eğer iki komşu zirve arasındaki süre 50 milisaniyeden az ise genlik değeri küçük olan elenir, diğer zirve ise saklanır.

İkinci adımda kalp atım sayısı kullanılarak bir varsayım ortaya konulmaktadır. Sağlıklı bireylerde beklenen dakikadaki kalp atım sayısı 60-80 arasındadır. Bu değer dikkate alınarak, sırasıyla systolic periyot, diastolic periyot ve S1-S2'leri içeren bir kalp atımının dakikada en az 40, en fazla 140 olabileceği kabul edilmiş ve zirve hesaplamaları buna göre yapılmıştır. Dolayısıyla, kalp atışı en kısa 400 milisaniye, en uzun 1500 milisaniye arasında değişen sürelerde olmalıdır.

Üçüncü adımda kalp atım sayısı varsayımı kullanılarak aralarında 400 milisaniyeden az fakat 50 milisaniyeden uzun zaman aralığı olan zirvelerden genlik değeri küçük olan elenir ve büyük olan saklanır.

Son adımda ise aralarında 1500 milisaniyeden uzun zaman aralığı olan zirveler aranır. Yukarıda ifade edilen kalp atım sayısı varsayımına göre iki zirve arasında bu kadar uzun bir süre olamaz ve tespit edilemeyen zirveler olması gerekmektedir. Bu nedenle

gözlemlenemeyen zirve noktalarını bulmak için eşik değeri aşağı çekilerek yeni zirve noktaları aranır ve ilk üç adım tekrarlanır.

• **Öznitelikler:** Veri ön işleme safhasından sonra zaman, frekans, istatistiksel özellikler ve Mel frekansı katsayıları kullanılarak 33 adet öznitelik hesaplanmaktadır. Bu özniteliklere ait detaylı bilgiler Çizelge 3.11.'de sunulmaktadır. Yukarıda bahsedilen 33 özniteliğin 13'ü Mel frekansı katsayıları kullanılarak elde edilmiştir. Mel frekansı katsayıları ses işleme uygulamalarında sıklıkla kullanılmaktadır [44]. Bu katsayılar hesaplanırken öncelikle, sinyal çerçevelere ayrılarak güç spektrumu çıkartılmaktadır. Bu işlem gelen seslerin frekansına bağlı olarak farklı şiddette titreşerek işitmeye yardımcı olan insan kulağındaki koklea isimli organı taklit etmek için yapılır. Daha sonra, 0 Hz frekansının yakınında ne kadar enerji olduğunu gösteren dar bant geçiren bir filtre kullanılır. İnsanlar düşük frekanslarda işitmede konusunda iyidir, bu nedenle bu özelliği taklit etmek için logaritmik bir ölçek kullanılır. Logaritma alındıktan sonra, ayrık kosinüs dönüşümü gerçekleştirilir ve 13 katsayı Mel frekansı katsayıları olarak alınır.

Çizelge 3.11. Öznitelikler.

Sıra No	Matematiksel Gösterim	Açıklamalar
1	$\frac{(\sum_{i=1}^{T*fs} X(i))}{T * fs}$	Sinyalin ortalama değeri hesaplanmaktadır.
2	$\frac{(X((T * fs)/2)) + X((T * fs)/2 + 1))}{T * fs}$	Sinyalin ortanca değeri hesaplanmaktadır.
3	$\sqrt{\frac{\sum_{i=1}^{T*fs} ((X(i)) - \mu)^2}{T * fs}}$	Sinyalin standart sapma değeri hesaplanmaktadır.
4	$\frac{\sum_{i=1}^{T*fs} (X(i)) - \mu }{T * fs}$	Ortalama Mutlak Sapma (OMS) değeri hesaplanmaktadır.
5	İlk çeyrek (Ç1)	En küçük sayı (minimum) ile veri setinin ortanca değeri arasındaki orta sayı olarak tanımlanır. Verilerin %25'i bu noktanın altında olduğu için, 25. ampirik çeyrek olarak da bilinir.

Çizelge 3.11. (devam) Öznitelikler.

Sıra No	Matematiksel Gösterim	Açıklamalar
6	Üçüncü çeyrek (Ç3)	Veri setinin medyan ve en yüksek değeri (maksimum) arasındaki orta değerdir. Verilerin %75'i bu noktanın altında kaldığından, üst veya 75. ampirik çeyrek olarak bilinir.
7	Ç3 – Ç1	Üçüncü çeyrekteki terim ile ilk çeyrekteki terim arasındaki fark.
8	$\sum_{i=1}^N ((X(i) - \mu)/\sigma)^3 \cdot \frac{1}{N}$	Sinyalin çarpıklık değeri hesaplanmaktadır. X(i) sinyalin anlık değerini, μ tüm değerlerin ortalamasını, σ değerlerin standart sapmasını, N ise sinyaldeki değerlerin sayısını temsil etmektedir.
9	$\sum_{i=1}^N ((X(i) - \mu)/\sigma)^4 \cdot \frac{1}{N}$	Sinyalin basıklık değeri hesaplanmaktadır. X(i) sinyalin anlık değerini, μ tüm değerlerin ortalamasını, σ değerlerin standart sapmasını, N ise sinyaldeki değerlerin sayısını temsil etmektedir.
10	$\sum_{i=0}^{T*fs} X(i) * \log(X(i))$	Shannon entropi değeri hesaplanmaktadır.
11	$\sum_{f=0}^N X(f) * \log(X(f))$	Hızlı Fourier Dönüşümü alındıktan sonra sinyalin Shannon enerjisi hesaplanmaktadır. X(f) sinyalin Fourier dönüşümünü göstermektedir.
12	$\text{Max}(\sum_{i=0}^{N-1} X(i) e^{-\frac{i2\pi kn}{N}}) \text{ Hz}$	Hızlı Fourier Dönüşümü alındıktan sonra, maksimum frekans değeri hesaplanır (Hz).
13	$\text{Max}(\sum_{i=0}^{N-1} X(i) e^{-\frac{i2\pi kn}{N}}) \text{ Spektrum değeri}$	Hızlı Fourier Dönüşümü alındıktan sonra, maksimum frekansa ait spektrum değeri hesaplanır.
14	$\frac{\text{Enerji}[\text{Max}(\sum_{i=0}^{N-1} X(i) e^{-\frac{i2\pi kn}{N}})]}{\text{Toplam Enerji}}$	Maksimum enerjinin toplam enerjiye oranı hesaplanmaktadır.

Çizelge 3.11. (devam) Öznelikler.

Sıra No	Matematiksel Gösterim	Açıklamalar
15-27	$P_j(f) = X_j(f) ^2$ $\text{Mel}(f) = 1127 \log\left(1 + \frac{f}{700}\right)$	Mel Frekansı Katsayıları: - Sinyal küçük çerçevelere ayrılarak her çerçeve için spektral güç yoğunluğu hesaplanır. - Spektral güce Mel filtresi uygulanır. Bunun için her tüm filtrelerin logaritması alınmaktadır. Daha sonra Ayrık Kosinüs Dönüşümü hesaplanarak 13 katsayı alınmaktadır.
28	$\frac{\text{abs}(\sum_{i=1}^N S1(i) - S2(i))}{N}$	Systolic periyot ortalama değeri.
29	$\frac{\text{abs}(\sum_{i=1}^N S2(i) - S1(i + 1))}{N - 1}$	Diastolic periyot ortalama değeri.
30	$\sqrt{\frac{\sum_{i=1}^N ((S1(i) - S2(i)) - T12(a))^2}{N}}$	Systolic periyot standart sapması.
31	$\sqrt{\frac{\sum_{i=1}^N ((S2(i) - S1(i + 1)) - T21(a))^2}{N - 1}}$	Diastolic periyot standart sapması.
32	$\frac{\text{Eleme sonrasındaki zirve sayısı}}{\text{Toplam zirve sayısı}}$	Eleme algoritmasından sonra kalan zirve sayısının toplam zirve sayısına oranı hesaplanmaktadır.
33	$\frac{\text{Eleme sonrasındaki zirvelerin genlik ortalamaları}}{\text{Tüm zirvelerin genlik ortalamaları}}$	Eleme algoritması uygulandıktan sonra kalan zirvelerin genlik ortalamalarının tüm zirvelerin genlik ortalamalarına oranıdır.

3.2.3. Sınıflandırma bloğu

Bu kısımda elde edilen öznitelikler kullanılarak literatürde bilinen yöntemler sınıflandırma başarısı bakımından test edilmiştir.

• **Literatürde kullanılan sınıflandırma yöntemleri:** Sınıflandırma yöntemlerini dört kategoriye ayırmak mümkündür, sırasıyla; yapay sinir ağları tabanlı, destek vektör makinaları tabanlı, saklı Markov modeli ve kümeleme tabanlı olarak gruplanabilir.

Yapay sinir ağları tabanlı bölümlleme en çok kullanılan yöntemdir. Bölümlleme için kalp seslerinin dalgacık dönüşümü yapıldıktan sonra ortalama değer, varyans, çarpıklık ve eğiklik gibi bazı istatistiksel değerler ile kan basıncı, yaş, ağırlık, cinsiyet gibi kişisel veriler yapay sinir ağlarına girdi olarak sunulmaktadır [4]. Bu çalışmalara ilave olarak, Hızlı Fourier Dönüşümü ile frekans uzayından enerji spektrumu alınmış ve yapay sinir ağlarına girdi olarak verilmiştir [10, 45].

Destek vektör makinaları da yapay sinir ağları gibi güdümlü makine öğrenmesi yöntemlerinden olduğu için yapay sinir ağları ile gerçekleştirilen bölümlleme çalışmalarına benzer özellikler kullanılmaktadır. Özellikle dalgacık dönüşümü sıklıkla kullanılmıştır [21]. Ayrıca, Shannon enerjisi ve frekans uzayından elde edilen özelliklerin kullanıldığı çalışmalar da bulunmaktadır [18].

Saklı Markov modeli ile yapılan sınıflandırma çalışmalarında öznitelikler zaman uzayından, hızlı Fourier dönüşümü ile frekans uzayında ve Mel Frekanslı katsayılarında elde edilmektedir. Bu yöntem kullanılarak gerçekleştirilen çalışmalar sayı ve içerik bakımından henüz tam bir olgunluğa erişmemiştir. Kümeleme tabanlı sınıflandırma algoritmalarında k-en yakın komşuluk sınıflandırıcı ile güdümlü öğrenme uygulanmaktadır. Hem temel kalp seslerinden elde edilen morfolojik öznitelikler hem de ayrık dalgacık dönüşümünde elde edilen öznitelikler sınıflandırma algoritmasını beslemek için kullanılmıştır [46].

• **Gerçekleştirilen sınıflandırma testleri:** Toplam yedi farklı yöneme ait 25 algoritma sınıflandırma başarısı bakımından test edilmiştir. Söz konusu testler sonucunda en iyi sınıflandırma başarısının elde edildiği algoritma; alt uzay sayısı sekiz ve en yakın


komşuluk tipinde 30 farklı öğrenici algoritmanın kullanıldığı topluluk (ensemble) modelidir. En başarılı sınıflandırma modeli kaydedilerek Şekil 3.2.'de PREDICT_CLASS isimli blok içerisindeki MATLAB fonksiyonunda çağrılmaktadır. Bu kullanım için öncelikle sınıflandırma algoritması MATLAB ortamında eğitilmeli daha sonra kaydedilmelidir. Daha sonra, eğitilmiş algoritma MATLAB Coder kullanılarak veya elle C/C++ kodlarına çevrilmelidir. En başarılı algoritmanın belirlenmesi için gerçekleştirilen testlerde kullanılan yöntemler ve testlere ilişkin detaylı bilgi dördüncü bölümde sunulmaktadır.

3.2.4. Çıktı bloğu


Mobil uygulama cep telefonu ve tablet olmak iki farklı çıktı ekranına sahiptir. Bu iki ekran arasındaki tek fark tablet ekranında bulunan bellek destekli teşhis bölümüdür.

Ekran tasarımı sağ üst köşeden başlayarak sırasıyla; anlık olarak üretilen hastalık teşhis tahmin sonucu PREDICTED DIAGNOSE başlığı ile bir veya sıfır rakamları ile gösterilmekte, bu sonucun hemen altında tablet ekranında bellek destekli teşhis MEMORY BOOSETED DIAGNOSE başlığı ile sıfır veya bir rakamı ile gösterilmekte, ses kayıt butonuna basıldığında kayıt süresi RECORDING TIME başlığı ile saniye cinsinden gösterilmekte, bir alt kısımda START RECORDING başlığı ile ses kayıt butonu bulunmakta, bu kısım kaydırıldığında ise dinamik olarak değişmekte olan öznitelikler ekrana basılmaktadır.

Ekranın sol yarısında ise hastalık teşhis tahminine ait sağlıklı veya hasta ifadesini gösteren bir figür basılmaktadır. Bu kısım sola doğru kaydırıldığında figür kaybolarak kalp sesi sinyaline ait anlık ses grafiği ekranda dinamik olarak görülmektedir. Ekran tasarımına ait görseller cep telefonu ve tablet olmak üzere Şekil 3.6. ve Şekil 3.7.'de sunulmaktadır.




Şekil 3.6. Cep telefonuna ait mobil uygulama ekranı.



Şekil 3.7. Tablet cihazına ait mobil uygulama ekranı.

4. SINIFLANDIRMA ALGORİTMALARI VE SINIFLANDIRMA BAŞARIMI TEST SONUÇLARI

Öznitelik çıkartma safhasında belirtilen 33 özneliğin taşıdığı bilgi miktarını tespit etmek için komşuluk analizi uygulanmıştır. Komşuluk analizi sonucunda elde edilen sonuçlar Şekil 4.1.'de sunulmaktadır. Bu şekildeki sıra numarası gösterilen öznelikler Çizelge 3.11.'de belirtilen özneliklerin sıra numaraları ile aynıdır. Şekilden görüldüğü üzere, özellikle 15-27. sıradaki öznelikler olan Mel frekansı katsayıları diğer özneliklere oranla daha fazla bilgi taşımaktadır. Fakat, frekans ve zaman uzayından elde edilen öznelikler ile temel kalp sesleri baz alınarak çıkartılmış özneliklerin fazla bilgi taşımadığı tespit edilmiştir.



Şekil 4.1. Komşuluk analizi sonrasında özneliklerin taşıdıkları bilgi seviyeleri.

Sınıflandırma testlerinde PhysioNet veri seti kullanılmış olup, eğitim için verilerin %70'lik kısmı ve doğrulama için geri kalan %30'luk kısmı kullanılmıştır. Ayrıca, sınıflandırma testlerinde komşuluk analizi sonrasında fazla bilgi taşıdığı tespit edilen ve Çizelge 4.1.'de belirtilen öznelik setleri kullanılmıştır.

Çizelge 4.1. Test için kullanılan öznelik setleri.

Öznitelik Sayısı	Açıklama
33	Çizelge 3.11.'de belirtilen tüm öznelikler.
15	Çizelge 3.11.'de belirtilen 9, 12 ve 15-27. sıradaki öznelikler.

Sınıflandırma başarısını ölçerken doğruluk, hata oranı, seçicilik ve hassasiyet metrikleri kullanılmıştır. Bu metriklerle ilişkin hata matrisi aşağıdaki gibi oluşturulmuştur.

Çizelge 4.2. Test için kullanılan hata matrisi.

		ALGORİTMANIN TAHMİNİ (Predicted Class)	
		Hasta (Abnormal)	Sağlıklı (Normal)
GERÇEK DURUM (True Class)	Hasta (Abnormal)	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Sağlıklı (Normal)	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Çizelge 4.2'deki tanımlardan sınıflandırma başarısının ölçülmesinde kullanılan metrikleri elde etmek için kullanılmakta olup, hata matrisi olarak da bilinmektedir. Bu metrikler aşağıdaki eşitliklerde belirtildiği gibi hesaplanmaktadır;

$$\text{Doğruluk} = (DP + DN) / (DP + YP + YN + DN) \quad (4.1)$$

$$\text{Hassasiyet} = DP / (DP + YN) \quad (4.2)$$

$$\text{Seçicilik} = DN / (DN + YP) \quad (4.3)$$

Sınıflandırma algoritmaları toplam yedi makine öğrenmesi tekniği başlığı altında incelenmiştir. Bu makine öğrenmesi yöntemleri sırasıyla; lojistik regresyon analizi, diskriminant analiz, naive bayes, karar ağaçları, destek vektör makinaları, topluluk öğrenme ve k-en yakın komşuluk sınıflandırıcıdır.

4.1. Lojistik Regresyon Analizi Algoritması

Lojistik regresyon, doğrusal sınıflandırma problemlerinde kullanılan ve ikili sonuç üreten bir makine öğrenmesi yöntemidir. Dolayısıyla, hasta ve sağlıklı olarak sonuç üretmesini beklediğimiz modelimizde kullanılması mümkündür. Lojistik regresyon bir veya daha fazla bağımsız değişkeni kullanarak sonuç üreten istatistiksel bir yöntemdir. Bu yöntemde

bağımsız değişkenler yani öznitelikler ile sonuç arasındaki ilişkiyi tanımlamak için en uygun modeli bulmak amaçlanmaktadır. Model sigmoid fonksiyonunu olasılık sonuçlarını üretmek için kullanılmaktadır. Lojistik regresyon kullanılarak elde edilen sınıflandırma başarımı Çizelge 4.3.'te ve hata matrisi Şekil 4.2. ile Şekil 4.3'te sunulmaktadır.

Çizelge 4.3 Lojistik regresyon algoritmasına ait sınıflandırma metrikleri.

Algoritma	Başarım Metriği	Öznitelik sayısı	
		33	15
Model 1: Lojistik Regresyon	Doğruluk	%85,9	%79,6
	Hassasiyet	%63,8	%39,4
	Seçicilik	%93	%92,5

Model 1			
True Class		Abnormal	Normal
	Abnormal	604	343
	Normal	207	2750
		Abnormal	Normal
		Predicted Class	

Şekil 4.2. Lojistik regresyon analizine ilişkin hata matrisi (33 öznitelik).

		Model 1	
True Class	Abnormal	373	574
	Normal	221	2736
		Abnormal	Normal
		Predicted Class	

Şekil 4.3. Lojistik regresyon analizine ilişkin hata matrisi (15 öznitelik).


4.2. Diskriminant Analizi Algoritmaları

Diskriminant analizi, üzerinde ölçüm yapılan bir bireyi sonlu sayıda bilinen farklı kitleden birine atanmasını gerçekleştiren istatistiksel bir tekniktir. K_1 ve K_2 birbirinden farklı iki kitle olmak üzere, birey üzerinde ölçümlere karşılık gelen $X = (x_1, x_2, \dots, x_n)$ n boyutlu rastgele bir örneğin hangi kitleye ait olduğunu tespit etmek için; X 'in olasılık yoğunluk fonksiyonu $f_i(x, \theta_i)$, burada θ_i parametre vektörü ve $x \in \mathcal{R}^n$ 'dir. X 'in aldığı değerler n boyutlu $\mathcal{R}^n$ örneklem uzayında olmak üzere, sınıflandırma sonucunda bu uzay keşişim kümesi sıfır olan B_1 ve B_2 isimli iki bölgeye ayrılır. Eğer X 'in gözlem değeri B_1 'de ise örnek K_1 kitlesine değil ise K_2 kitlesine atama yapılır.

Lineer diskriminant analizi öznitelikler uzayı ile gösterilen verilerin doğrusal bir çizgi ile ayrıştırılabildiği varsayımı ile çalışmaktadır. Tüm sınıfların Gauss dağılımına ait olduğu ve ortak kovaryans matrisine sahip olduğu farz edilir. Bir diğer analiz yöntemlerinden olan quadratic analizde ise tüm sınıfların ortak bir kovaryans matrisine sahip olmadığı ve her sınıfın kendi kovaryans matrisi olduğu farz edilir. Bu durumda lineer analizden farklı olarak sınıfları ayıran sınır çizgisi hiper bir düzlem değildir yani lineer bir çizgi ile ayrıştırılamazlar. Diskriminant analiz ile elde edilen başarımlar metrikleri ve hata matrisi Çizelge 4.4.'te ve Şekil 4.4.- Şekil 4.6'da sunulmaktadır.

Çizelge 4.4. Diskriminant analiz algoritmalarına ait başarımları metrikleri.

Algoritma	Başarımları Metriği	Öznitelik sayısı	
		33	15
Model 2.1: Lineer Diskriminant Analizi	Doğruluk	%85,6	%80,0
	Hassasiyet	%63,9	%44,1
	Seçicilik	%92,5	%91,5
Model 2.2: Quadratic Diskriminant Analizi	Doğruluk	-	%81,3
	Hassasiyet	-	%50,7
	Seçicilik	-	%91,1



Şekil 4.4. Lineer diskriminant analizine ilişkin hata matrisi (33 öznitelik).

		Model 2.1	
True Class	Abnormal	418	529
	Normal	252	2705
		Abnormal	Normal
		Predicted Class	

Şekil 4.5. Lineer diskriminant analizine ilişkin hata matrisi (15 öznitelik).

		Model 2.2	
True Class	Abnormal	480	467
	Normal	263	2694
		Abnormal	Normal
		Predicted Class	

Şekil 4.6. Quadratic diskriminant analizine ilişkin hata matrisi (15 öznitelik).

4.3. Naive Bayes Algoritmaları

Bu algoritma Bayes olasılık hesaplama modelini baz alan bir sınıflandırma yöntemidir. Sade bir yapısı olmasına rağmen Bayes olasılık hesabı gerçek dünyada oldukça başarılı sonuçlar üreten bir teoremdir. Bayes bir rastgele değişken için koşullu olasılıklar ile önsel olasılıklar arasındaki ilişkiyi açıklamaktadır. Teorem aşağıdaki eşitlikte gösterilmekte olup, sırasıyla; $P(A|B)$ B olayı gerçekleştiğinde A olayı olma olasılığını, $P(B|A)$ A olayı gerçekleştiğinde B olayı olma olasılığını, $P(A)$ ve $P(B)$ ise A ve B olaylarının önsel olasılıklarını ifade etmektedir.

$$P(A|B) = P(B|A) * P(A)/P(B) \quad (4.4)$$

Bayes algoritmaları kullanılarak elde edilen sınıflandırma başarımları Çizelge 4.5.'te ve hata matrisleri Şekil 4.7.-Şekil 4.10.'da gösterilmektedir.

Çizelge 4.5. Naive Bayes algoritmalarına ait başarımların metrikleri.

Algoritma	Başarımların Metriği	Öznitelik sayısı	
		33	15
Model 3.1: Gaussian Naive Bayes	Doğruluk	%70,1	%79,9
	Hassasiyet	%84,8	%63,1
	Seçicilik	%65,4	%85,3
Model 3.2: Kernel Naive Bayes	Doğruluk	%85,2	%80,8
	Hassasiyet	%80,6	%72,9
	Seçicilik	%86,7	%83,3

		Model 3.1	
True Class	Abnormal	803	144
	Normal	1022	1935
		Abnormal	Normal
		Predicted Class	

Şekil 4.7. Gaussian Naive Bayes hata matrisi (33 öznitelik).

		Model 3.1	
True Class	Abnormal	598	349
	Normal	436	2521
		Abnormal	Normal
		Predicted Class	

Şekil 4.8. Gaussian Naive Bayes hata matrisi (15 öznitelik).

		Model 3.2	
True Class	Abnormal	763	184
	Normal	393	2564
		Abnormal	Normal
		Predicted Class	

Şekil 4.9. Kernel Naive Bayes hata matrisi (33 öznitelik).

		Model 3.2	
True Class	Abnormal	690	257
	Normal	494	2463
		Abnormal	Normal
		Predicted Class	

Şekil 4.10. Kernel Naive Bayes hata matrisi (15 öznitelik).

4.4. Karar Ağacı Algoritmaları

Bu sınıflandırma algoritmasında özellikler karar düğümleri ve alt bileşen yaprak düğümleri olarak ayrıştırılır. Bir karar düğümü birden çok alt dalları içerebilir. Bu ilk düğüm noktasına ana düğüm veya kaynak düğüm de denilmektedir. Karar ağacı veri yapısı hem kategorik hem de sayısal veriler içerebilir. Ağaç yapısı oluşturulduktan sonra bilgi kazancı ölçülerek en ayırt edici nitelik bulunur. Bilgi ölçümünde entropi özelliği kullanılır. Entropi belirsizliği ve beklenmeyen durumun ortaya çıkma olasılığını gösterir ve aşağıdaki eşitlik kullanılarak hesaplanır.

$$\sum_{i=1}^n p(X_i) \log_2(1/p(x_i)) \quad (4.5)$$

Ana düğümden başlanarak alt dallara doğru entropi hesaplanır ve en çok bilgi taşıyan özellikler tespit edilir. Karar ağaçlarını oluşturmak nispeten kolaydır ve süreç içerisinde dolaylı olarak öznitelik kıymetlendirme ve eleme de yapılmaktadır. Küçük ağaç yapılarını yorumlamak kolaydır ve hem sürekli hem de ayırık değerler için kullanılabilir. Lineer ayırlamayan örneklerle ait sorunların çözümünde oldukça iyidir.

Fakat sınıf sayısı çok ve örnek sayısı az olduğunda iyi sonuçlar üretilemez. Kesikli değerlerde daha iyi sonuç üretilebilirken sürekli değerlerde iyi sonuçlar çıkmayabilir. Ayrıca, nitelik sayısı artınca ağaç yapısı oluşturmak karmaşık bir hal alır ve entropi hesaplayarak eleme yapmak yani budama olarak tabir edilen işlem hesap yoğun bir hal alarak işlemci ve hesaplama maliyeti ortaya çıkarır.

Karar ağaçları yapısında karşılaşılan sorunlardan birisi de algoritmanın veriyi ezberlemesi yani aşırı öğrenmesi problemidir. Bu sorunu engellemek için yapılması gereken yöntemlerden birisi ağaç yapısının geliştirilmesinin bir noktada kesilmesidir. Bu nokta genellikle eğitim veri setinin mükemmel şekilde sınıflandırılmasından önceki noktadır. Karar ağaçları kullanılarak elde edilen sınıflandırma başarımları Çizelge 4.6.'da hata matrisleri ise sırasıyla Şekil 4.11.-Şekil 4.16.'da gösterilmektedir.

Çizelge 4.6. Karar ağacı algoritmalarına ait başarımları metrikleri.

Algoritma	Başarımları Metriği	Öznitelik sayısı	
		33	15
Model 4.1: Fine Tree	Doğruluk	%89,7	%86,8
	Hassasiyet	%77,7	%73,6
	Seçicilik	%93,6	%91,0
Model 4.2: Medium Tree	Doğruluk	%88,4	%85,9
	Hassasiyet	%72,5	%66,4
	Seçicilik	%93,5	%92,2
Model 4.3: Coarse Tree	Doğruluk	%81,6	%82,6
	Hassasiyet	%71,1	%41,1
	Seçicilik	%85,0	%95,9

Model 4.1			
True Class		Abnormal	Normal
		Abnormal	Normal
Abnormal		736	211
Normal		190	2767

Şekil 4.11. Fine Tree algoritmasına ait hata matrisi (33 öznitelik).

		Model 4.1	
True Class	Abnormal	697	250
	Normal	265	2692
		Abnormal	Normal
		Predicted Class	

Şekil 4.12. Fine Tree algoritmasına ait hata matrisi (15 öznitelik).

		Model 4.2	
True Class	Abnormal	687	260
	Normal	193	2764
		Abnormal	Normal
		Predicted Class	

Şekil 4.13. Medium Tree algoritmasına ait hata matrisi (33 öznitelik).

Model 4.2		
True Class	Abnormal	Normal
	Abnormal	Normal
Abnormal	629	318
Normal	231	2726

Şekil 4.14. Medium Tree algoritmasına ait hata matrisi (15 öznitelik).

Model 4.3		
True Class	Abnormal	Normal
	Abnormal	Normal
Abnormal	673	274
Normal	445	2512

Şekil 4.15. Coarse Tree algoritmasına ait hata matrisi (33 öznitelik).

		Model 4.3	
True Class	Abnormal	389	558
	Normal	120	2837
		Abnormal	Normal
		Predicted Class	

Şekil 4.16. Coarse Tree algoritmasına ait hata matrisi (15 öznitelik).

4.5. Topluluk Öğrenmesi Algoritmaları

Topluluk Öğrenmesi (Ensemble Learning) birçok sınıflandırıcı algoritmanın aynı eğitim setini veya bu eğitim setinin alt kümelerini kullanarak eğitilmesi ve her bir algoritmanın sonuçlarının sınıflandırmada kullanılması ilkesine dayanmaktadır. Dolayısıyla, yapılan işlem farklı sınıflandırma algoritmalarından elde edilen sonuçların birleştirilmesi ile daha doğru sonuç elde etme stratejidir. Farklı algoritmalarından elde edilen sonuçlar oylama veya ortalama alma gibi yöntemler ile birleştirilmektedir. Böylece, tek bir sınıflandırıcının verdiği karardan daha doğru sonuçlar elde etmek mümkün olmaktadır.

Topluluk öğrenmesi ezberleme veya aşırı öğrenme olarak ifade edilen sorunu da ortadan kaldırmaktadır. Bunun yanı sıra sapma ve diğer hataları da azaltmaktadır. Topluluk yöntemlerin bu sayılan faydaları her durumda geçerli değildir. Çünkü bu yöntemlerde birden fazla sınıflandırma algoritması kullanıldığı için başarıyı ciddi bir oranda artırması beklenir aksi takdirde ilave hesaplama yükü ve kod karmaşıklığı ortaya çıkar. Dolayısıyla, elde edilecek başarımların ilave hesap yapmaya değmeli anlamlı bir fark ortaya çıkmalıdır. Topluluk öğrenme yöntemleri; Torbalama, Random Subsample, Boosting olarak gruplandırılabilir.


Torbalama (Bootstrap Aggregation) yönteminde, veri eğitim ve test için ikiye ayrılır, genellikle oran %60 eğitim ve %40 test civarındadır. Daha sonra her sınıflandırıcı algoritma için eğitim setinden bir alt küme seçilir. Bir sınıflandırıcıda kullanılan örnek diğer sınıflandırıcı için tekrar seçilebilecek şekilde tekrar seçime dahil edilir. Dolayısıyla, bazı elemanlar birden çok alt küme için seçilmiş olabilir, yani alt kümeler bir oranda birbirine benzer olabilir. Daha sonra her sınıflandırma algoritması eğitilir ve test verisi için algoritmaların kararları oylama, ortalama gibi yöntemler ile kararlaştırılır.

Random Subsample yönteminde ise eğitim için kullanılan örneklerde herhangi seçim veya kısıtlama yoktur. Burada örnekleri tarif özneliklerin üzerinde bir kısıtlama uygulanmaktadır. Genellikle özneliklerin yarısı eğitim için kullanılır. Dolayısıyla, her sınıflandırıcı algoritma aynı örnekleri farklı öznelikler ile sınıflandırmış olur.

Artırma (Boosting) yönteminde ise Torbalama (Bagging) yönteminde olduğu gibi eğitim veri setinden alt kümeler oluşturulur fakat burada Torbalama yönteminin aksine örnekler seçilirken eşit olasılıklar kullanılmaz. Bir sınıflandırıcı rastgele ilk sınıflandırıcı olarak atanır ve alt küme ile sınıflandırma yapılır. Bu sınıflandırıcının yanlış olarak atadığı örneklerin seçilme olasılıkları yükseltilerek bir sonraki sınıflandırma algoritmasında kullanılacak alt kümede yer alma ihtimali artırılır. Topluluk kararında daha az hata yapılması için diğer sınıflandırıcının yanlış tahminleri yeni algoritmada kullanılır ve yanlış karar telafi edilmeye çalışılır. En sık kullanılan artırma yöntemleri sırasıyla; Uyarlanabilir Artırma (AdaBoost, Adaptive Boost) ve Eğimli Artırma (Gradient Boost) metotlarıdır. Uyarlanabilir yöntemde her iterasyonda bir önceki sınıflandırma da yanlış etiketlenen örneklere yoğunlaşarak o örneklerin ağırlık değerleri değiştirilir. Eğimli yöntemde ise, sınıflandırma fonksiyonunun sonucundaki tahmin ile hedefler arasındaki farkı gösteren bir fonksiyon tanımlanarak her iterasyonda bu fark sınıflandırma fonksiyonu ile birleştirilerek tahminler ile hedefler arasındaki fark sıfıra indirilmeye çalışılır. Ayrıca, RUSBoosting (Random Under sampling Boosting) isimli bir yöntem daha kullanılmaktadır. Bu yöntemde eğitim verisindeki örneklere ait sınıflardan en az sayıda örnek içeren sınıftaki örnek sayısı kadar her sınıftan alt küme oluşturulur. Topluluk öğrenmesi algoritmaları kullanılarak elde edilen sınıflandırma başarımları Çizelge 4.7.'de ve hata matrisleri Şekil 4.17.-Şekil 4.26.'da sunulmaktadır.

Çizelge 4.7. Topluluk öğrenmesi algoritmalarına ait başarımların metrikleri.

Algoritma	Başarımların Metriği	Öznitelik sayısı	
		33	15
Model 5.1: Boosted Trees	Doğruluk	%90,6	%88,0
	Hassasiyet	%79,5	%69,0
	Seçicilik	%94,2	%94,1
Model 5.2: Bagged Trees	Doğruluk	%92,7	%90,8
	Hassasiyet	%86,4	%79,9
	Seçicilik	%94,7	%94,3
Model 5.3: Subspace Discriminant	Doğruluk	%84,1	%76,1
	Hassasiyet	%54,7	%19,6
	Seçicilik	%93,5	%94,1
Model 5.4: Subspace KNN	Doğruluk	%92,9	%92,6
	Hassasiyet	%84,3	%84,1
	Seçicilik	%95,7	%95,4
Model 5.5: RUSBoosted Trees	Doğruluk	%88,2	%82,6
	Hassasiyet	%88,8	%88,0
	Seçicilik	%88,1	%80,8



Şekil 4.17. Boosted Trees algoritmasına ait hata matrisi (33 öznitelik).

		Model 5.1	
True Class	Abnormal	653	294
	Normal	174	2783
		Abnormal	Normal
		Predicted Class	

Şekil 4.18. Boosted Trees algoritmasına ait hata matrisi (15 öznitelik).

		Model 5.2	
True Class	Abnormal	818	129
	Normal	157	2800
		Abnormal	Normal
		Predicted Class	

Şekil 4.19. Bagged Trees algoritmasına ait hata matrisi (33 öznitelik).

		Model 5.2	
True Class	Abnormal	757	190
	Normal	170	2787
		Abnormal	Normal
		Predicted Class	

Şekil 4.20. Bagged Trees algoritmasına ait hata matrisi (15 öznitelik).

		Model 5.3	
True Class	Abnormal	518	429
	Normal	193	2764
		Abnormal	Normal
		Predicted Class	

Şekil 4.21. Subspace Discriminant algoritmasına ait hata matrisi (33 öznitelik).

		Model 5.3	
True Class	Abnormal	186	761
	Normal	174	2783
		Abnormal	Normal
		Predicted Class	

Şekil 4.22. Subspace Discriminant algoritmasına ait hata matrisi (15 öz nitelik).

		Model 5.4	
True Class	Abnormal	798	149
	Normal	128	2829
		Abnormal	Normal
		Predicted Class	

Şekil 4.23. Subspace KNN algoritmasına ait hata matrisi (33 öz nitelik).

Model 5.4		
True Class	Abnormal	Normal
	796	151
True Class	Abnormal	Normal
	136	2821
Predicted Class		

Şekil 4.24. Subspace KNN algoritmasına ait hata matrisi (15 öznitelik).

Model 5.5		
True Class	Abnormal	Normal
	841	106
True Class	Abnormal	Normal
	353	2604
Predicted Class		

Şekil 4.25. RUSBoosted Trees algoritmasına ait hata matrisi (33 öznitelik).

		Model 5.5	
True Class	Abnormal	833	114
	Normal	567	2390
		Abnormal	Normal
		Predicted Class	


Şekil 4.26. RUSBoosted Trees algoritmasına ait hata matrisi (15 öznitelik).

4.6. Destek Vektör Makinaları Algoritmaları


Destek vektör makinaları (SVM, Support Vector Machines) eğitim veri setindeki örneklerin sınıfları arasında eşit uzaklıkta bir hiper uzay sınırı çizmeye yaramaktadır. Doğrusal olarak ayrılabilen örneklerde bu çizgi düz iken doğrusal olmayan verilerde herhangi bir noktadaki iki farklı sınıfa ait örnekleme eşit uzaklıktan geçen bir sınır çizgisi olarak düşünülebilir. Dolayısıyla, destek vektör makinaları iki sınıflı bir veri setini ayrıştırabilir. Bu yöntemde ezberleme ve aşırı öğrenme gibi bir sorun söz konusu değildir. Şekil 4.27.'de gösterildiği gibi lineer olarak ayrılabilen örnek veri setlerinde H_1 ve H_2 olarak ifade edilen iki yüzey sınıfları birbirinden ayırmakta olup, bunlara destek vektörleri denilmektedir. H_0 ise bu iki yüzey arasındaki ortalama mesafeyi tarif eder sınır çizgisi olarak her iki sınıfı birbirinden ayırır. Eğer veriler doğrusal olarak ayrıştırılamıyorsa, yani lineer değilse, Şekil 4.28.'de gösterildiği gibi veriler farklı bir uzaya taşınabilir ve doğrusal olarak ayrıştırılabilir. Destek vektör makinaları hesaplanırken $x_i \cdot x_j$ ürünleri hesaplanmaktadır. Eğer, ϕ gibi bir fonksiyon kullanıldığında $\phi(x_i) \cdot \phi(x_j)$ ürünlerinin hesaplanması gerekir. Fakat, bu hesaplama işlemi işlem yoğun ve zaman alıcı olabilir hatta tam olarak dönüşüm fonksiyonu bilinmiyor da olabilir. Bu nedenle, $K(x_i, x_j)$ olarak ifade edilen bir kernel fonksiyonu kullanıldığında Eş. 4.6'daki gibi bir dönüşümden

bahsedilebilir. Dolayısıyla, kernel fonksiyonları dönüştürülmüş uzaydaki verileri gösterilmekte veya benzerliği tarif etmektedir.

$$K(x_i, x_j) = \phi(x_i) * \phi(x_j) \quad (4.6)$$



Şekil 4.27. Lineer ayrıştırılabilen örneklerdeki destek vektör makinasının çizilmesi.



Şekil 4.28. Lineer ayrıştırılamayan örneklerdeki destek vektör makinasının çizilmesi.

MATLAB uygulamasında kernel fonksiyonlarının değiştirilmesinden elde edilmiş olan altı farklı destek vektör makinası algoritması bulunmaktadır. Bu algoritmalar kullanılarak elde edilen hata matrisleri Şekil 4.29.-Şekil 40.'da sunulmaktadır.

Model 6.1

True Class	Abnormal	647	300
	Normal	213	2744
		Abnormal	Normal
		Predicted Class	

Şekil 4.29. Lineer SVM algoritmasına ait hata matrisi (33 öznitelik).

Model 6.1

True Class	Abnormal	408	539
	Normal	220	2737
		Abnormal	Normal
		Predicted Class	

Şekil 4.30. Lineer SVM algoritmasına ait hata matrisi (15 öznitelik).

Model 6.2		
True Class	Abnormal	Normal
	754	193
True Class	Abnormal	Normal
	204	2753
Predicted Class		

Şekil 4.31. Quadratic SVM algoritmasına ait hata matrisi (33 öznitelik).

Model 6.2		
True Class	Abnormal	Normal
	672	275
True Class	Abnormal	Normal
	237	2720
Predicted Class		

Şekil 4.32. Quadratic SVM algoritmasına ait hata matrisi (15 öznitelik).

Model 6.3

True Class	Abnormal	777	170
	Normal	188	2769
		Abnormal	Normal
		Predicted Class	

Şekil 4.33. Cubic SVM algoritmasına ait hata matrisi (33 öznitelik).

Model 6.3

True Class	Abnormal	734	213
	Normal	222	2735
		Abnormal	Normal
		Predicted Class	

Şekil 4.34. Cubic SVM algoritmasına ait hata matrisi (15 öznitelik).

		Model 6.4	
True Class	Abnormal	242	705
	Normal	21	2936
		Abnormal	Normal
		Predicted Class	

Şekil 4.35. Fine Gaussian SVM algoritmasına ait hata matrisi (33 öznitelik).

		Model 6.4	
True Class	Abnormal	410	537
	Normal	25	2932
		Abnormal	Normal
		Predicted Class	

Şekil 4.36. Fine Gaussian SVM algoritmasına ait hata matrisi (15 öznitelik).

Model 6.5

True Class	Abnormal	741	206
	Normal	163	2794
		Abnormal	Normal
		Predicted Class	

Şekil 4.37. Medium Gaussian SVM algoritmasına ait hata matrisi (33 öznitelik).

Model 6.5

True Class	Abnormal	728	219
	Normal	171	2786
		Abnormal	Normal
		Predicted Class	

Şekil 4.38. Medium Gaussian SVM algoritmasına ait hata matrisi (15 öznitelik).

Model 6.6

True Class	Abnormal	644	303
	Normal	187	2770
		Abnormal	Normal
		Predicted Class	

Şekil 4.39. Coarse Gaussian SVM algoritmasına ait hata matrisi (33 öznitelik).

Model 6.6

True Class	Abnormal	575	372
	Normal	186	2771
		Abnormal	Normal
		Predicted Class	

Şekil 4.40. Coarse Gaussian SVM algoritmasına ait hata matrisi (15 öznitelik).

Destek vektör makinaları kullanılarak oluşturulan algoritmalara ilişkin elde edilen sınıflandırma başarımları Çizelge 4.7.'de sunulmaktadır.

Çizelge 4.8. Destek vektör makinası algoritmalarına ait başarımlar metrikleri.

Algoritma	Başarımlar Metriği	Öznitelik sayısı	
		33	15
Model 6.1: Lineer SVM	Doğruluk	%86,9	%80,6
	Hassasiyet	%68,3	%43,1
	Seçicilik	%92,8	%92,6
Model 6.2: Quadratic SVM	Doğruluk	%89,8	%86,9
	Hassasiyet	%79,6	%71,0
	Seçicilik	%93,1	%92,0
Model 6.3: Cubic SVM	Doğruluk	%90,8	%88,9
	Hassasiyet	%82,0	%77,5
	Seçicilik	%93,6	%92,5
Model 6.4: Fine Gaussian SVM	Doğruluk	%81,4	%85,6
	Hassasiyet	%25,8	%43,3
	Seçicilik	%99,3	%99,2
Model 6.5: Medium Gaussian SVM	Doğruluk	%90,5	%90,0
	Hassasiyet	%78,2	%76,9
	Seçicilik	%94,5	%94,2
Model 6.6: Coarse Gaussian SVM	Doğruluk	%87,4	%85,7
	Hassasiyet	%68,0	%60,7
	Seçicilik	%93,7	%93,7

4.7. K-En Yakın Komşuluk Algoritmaları

K-En Yakın Komşuluk (KNN, K-Nearest Neighbor) algoritması yeni bir örneğin sınıfına karar vermek için eğitim veri setindeki “K” adet en yakındaki komşu örneğin sınıfına bakar. Diğer sınıflandırma algoritmalarına göre uygulanması daha kolaydır ve yaygın kullanımı vardır. Algoritma eğitim safhasında verilerinin karakteristiğini öğrenmez bunun yerine veri setindeki örnekleri ezberler. Bu nedenle ihtiyaç duyulan bellek alanı fazladır. Kaç tane örneğe bakılacağına “K” parametresi ile karar verilir. Genellikle üç veya beş adet komşuya bakılır, ancak hesaplama zamanı ve bellek tahsis sorunu yoksa 10 veya 100 örnek gibi daha fazla sayıdaki komşuya da bakılabilir. Komşular arasındaki mesafe hesaplanırken genellikle Öklid uzaklığı kullanılmakta olup, Manhattan, Minkowski ve Hamming mesafesi de uygulanan diğer yöntemlerdendir. En yakın komşuluk sınıflandırıcı, gürültülü veriler ile iyi sonuçlar üretmektedir. Fakat veri seti ve öznitelik boyutu arttıkça hesaplama maliyeti artmaktadır. Bu algortmada gerçekleştirilmeden önce uygulanması gereken yöntemlerden birisi de özniteliklerin maksimum ve minimum değerleri ile normalize edilmesidir. Bazı özniteliklerin sınır aralıkları diğer özniteliklerden çok büyük olabilir, bu durumda mesafe hesaplanırken bir veya birkaç öznitelik diğer özniteliklerin etkisini sönümleyebilir. Ayrıca, bazı komşular çok yakın iken bazı komşular uzak mesafede olabilir. Yakın olan komşuların sınıf tahmininde daha baskın olması için mesafe ile orantılı bir ağırlık katsayısı da sıklıkla kullanılmaktadır. Genellikle mesafe ile ters orantılı veya mesafenin karesi ile ters orantılı olacak şekilde bir ağırlık katsayısı kullanılır. MATLAB ile gerçekleştirilen KNN algoritmalarının özellikleri Çizelge 4.8’de sunulmaktadır.

Çizelge 4.9 KNN algoritmalarının Parametreleri.

Algoritma	Komşu Sayısı (K)	Mesafe Metriği	Ağırlık Katsayısı
Fine KNN	1	Öklid	Eşit
Medium KNN	10	Öklid	Eşit
Coarse KNN	100	Öklid	Eşit
Cosine KNN	10	Cosine	Eşit
Cubic KNN	10	Minkowski (Cubic)	Eşit
Weighted KNN	10	Öklid	$1/(\text{Mesafe})^2$

K-En Yakın Komşuluk algoritmaları ile gerçekleştirilen testlere ait sınıflandırma başarımları sonuçları Çizelge 4.9’da ve hata matrisleri Şekil 4.41-Şekil 4.52’de gösterilmektedir.

Çizelge 4.10 KNN algoritmalarına ait başarımları metrikleri.

Algoritma	Başarımları Metriği	Öznitelik sayısı	
		33	15
Model 7.1: Fine KNN	Doğruluk	%92,5	%92,9
	Hassasiyet	%83,8	%85,0
	Seçicilik	%95,3	%95,4
Model 7.2: Medium KNN	Doğruluk	%90,7	%90,6
	Hassasiyet	%80,3	%82,8
	Seçicilik	%94,0	%93,1
Model 7.3: Coarse KNN	Doğruluk	%87,3	%86,9
	Hassasiyet	%63,8	%65,9
	Seçicilik	%94,9	%93,6
Model 7.4: Cosine KNN	Doğruluk	%90,6	%89,3
	Hassasiyet	%82,8	%75,9
	Seçicilik	%93,1	%93,6
Model 7.5: Cubic KNN	Doğruluk	%90,1	%90,1
	Hassasiyet	%78,5	%81,6
	Seçicilik	%93,9	%92,8
Model 7.6: Weighted KNN	Doğruluk	%91,5	%91,9
	Hassasiyet	%79,3	%82,3
	Seçicilik	%95,5	%95,0

		Model 7.1	
True Class	Abnormal	794	153
	Normal	139	2818
		Abnormal	Normal
		Predicted Class	

Şekil 4.41. Fine KNN algoritmasına ait hata matrisi (33 öznitelik).

		Model 7.1	
True Class	Abnormal	805	142
	Normal	137	2820
		Abnormal	Normal
		Predicted Class	

Şekil 4.42. Fine KNN algoritmasına ait hata matrisi (15 öznitelik).

		Model 7.2	
True Class	Abnormal	760	187
	Normal	178	2779
		Abnormal	Normal
		Predicted Class	

Şekil 4.43. Medium KNN algoritmasına ait hata matrisi (33 öznitelik).

		Model 7.2	
True Class	Abnormal	784	163
	Normal	203	2754
		Abnormal	Normal
		Predicted Class	

Şekil 4.44. Medium KNN algoritmasına ait hata matrisi (15 öznitelik).

		Model 7.3	
True Class	Abnormal	604	343
	Normal	151	2806
		Abnormal	Normal
		Predicted Class	

Şekil 4.45. Coarse KNN algoritmasına ait hata matrisi (33 öznitelik).

		Model 7.3	
True Class	Abnormal	624	323
	Normal	190	2767
		Abnormal	Normal
		Predicted Class	

Şekil 4.46. Coarse KNN algoritmasına ait hata matrisi (15 öznitelik).

Model 7.4

True Class	Abnormal	784	163
	Normal	204	2753
		Abnormal	Normal
		Predicted Class	

Şekil 4.47. Cosine KNN algoritmasına ait hata matrisi (33 öznitelik).

Model 7.4

True Class	Abnormal	719	228
	Normal	189	2768
		Abnormal	Normal
		Predicted Class	

Şekil 4.48. Cosine KNN algoritmasına ait hata matrisi (15 öznitelik).

		Model 7.5	
True Class	Abnormal	743	204
	Normal	181	2776
		Abnormal	Normal
		Predicted Class	

Şekil 4.49. Cubic KNN algoritmasına ait hata matrisi (33 öznitelik).

		Model 7.5	
True Class	Abnormal	773	174
	Normal	212	2745
		Abnormal	Normal
		Predicted Class	

Şekil 4.50. Cubic KNN algoritmasına ait hata matrisi (15 öznitelik).

		Model 7.6	
True Class	Abnormal	751	196
	Normal	134	2823
		Abnormal	Normal
		Predicted Class	

Şekil 4.51. Weighted KNN algoritmasına ait hata matrisi (33 öznitelik).

		Model 7.6	
True Class	Abnormal	779	168
	Normal	147	2810
		Abnormal	Normal
		Predicted Class	

Şekil 4.52. Weighted KNN algoritmasına ait hata matrisi (15 öznitelik).

5. MOBİL UYGULAMA İLE GERÇEKLEŞTİRİLEN DOĞRULAMA TEST SONUÇLARI

Üçüncü bölümde mobil uygulamanın nasıl geliştirildiğine ait yöntem açıklanmış ve dördüncü bölümde ise mobil uygulamanın en önemli bileşenlerinden olan sınıflandırma algoritması modülünde kullanılan yapay zekâ algoritmasının geliştirilmesi süreci açıklanmıştır. Bu süreç sonucunda en iyi sınıflandırma başarısını gösteren k-en yakın komşuluk sınıflandırıcı tipindeki topluluk algoritmasının %92,9 doğrulukla verileri tahmin edebildiği tespit edilmiştir. Söz konusu algoritma mobil uygulamanın sınıflandırma modülünde kullanılarak uygulama oluşturulmuştur. Bu bölümde, geliştirilen mobil uygulamanın deneysel başarı sonuçları ile Ankara Şehir Hastanesi'nde gerçekleştirilen doğrulama testi sonucunda elde edilmiş olan gerçek durum başarısı karşılaştırılmaktadır.

Açık kaynak veri seti olan PhysioNet verileri ile elde edilen %92,9 oranındaki sınıflandırma doğruluğu stetoskop kullanılarak sadece iyi eğitilmiş uzman kardiyologlar tarafından elde edilebilir [47]. Uzmanlık seviyesinde eğitimi olmayan ve yeterli tecrübesi bulunmayan uzman doktorların sadece stetoskop cihazı kullanarak hastalık tespit etme oranı oldukça düşüktür [48]. Örneğin, pratisyen hekimler kalp kapak hastalıklarını %43 hassasiyet ve %69 seçicilik oranı ile tespit edebilirler. İyi eğitilmiş kardiyologlar stetoskop ile kalp hastalıklarını yüksek bir oranda anlayabilseler bile bireysel farklılıklar oldukça fazladır [49, 50]. Stetoskop kullanılarak kalp hastalığı tespiti konusunda literatürde yer alan başarımlar durumu Çizelge 5.1.'de detaylı olarak sunulmaktadır.

Çizelge 5.1. Literatürde belirtilen stetoskop ile kalp hastalığı tespit başarımları.


	Hassasiyet	Seçicilik
Pratisyen Hekimler [47]	%24,0	%24,0
Pratisyen Hekimler [48]	%31,0	%81,0
Acil Tıp Uzmanları [49]	%80,2	%94,3
Uzman Kardiyologlar [50]	%69,2	%98,2

Bu konuda daha fazla fikir vermesi açısından; kalp hastalıklarının yapay zekâ algoritmaları ile tespitine yönelik piyasada satılan ticari ürünlere ait başarımların metrikleri de Çizelge 5.2.'de gösterilmektedir. Bu ürünlerin başarımların hesaplanırken kendi veri tabanlarındaki örnekler kullanıldığı için PhysioNet veri seti sonuçları ile kıyas etmek mümkün değildir.


Çizelge 5.2. Ticari ürünlere ilişkin kalp hastalığı tespit başarımları.

	Hassasiyet	Seçicilik
Sensikardiac	%58,3	%58,3
Eko AI Software	%87,6	%87,8

Geliştirilen mobil uygulama doğrulama için test edilirken 1.2 GHz quad-core işlemcisi olan, 2 GB RAM kapasiteli ve Android 4.4 işletim sistemi olan oldukça mütevazı donanıma sahip bir cihaz kullanılmıştır. Bu cihazda kullanılan mobil uygulama sürümü tablet cihazlar için olan sürümdür (CardiacAI_v1). Tablet uygulamasına ait ekran görüntüleri Şekil 5.1. ve Şekil 5.2.'de sunulmaktadır.




Resim 5.1. Kalp sesi grafiği ile tablet cihaza ait mobil uygulama ekranı.



Resim 5.2. Hastalık tahmin görseli ile tablet cihaza ait mobil uygulama ekranı.

Kalp seslerinin kaydedilmesi ve mobil cihaz üzerinden uygulamaya aktarılması için Thinkslabs marka dijital stetoskop kullanılmıştır. Bu stetoskop geleneksel cihazlardan farklı olarak mobil cihaz ile kablolu olarak bağlantı kurabilir. Dolayısıyla, kalp sesleri hem doktorlar tarafından dinlenebilir hem de anlık olarak mobil uygulama ile grafik gösterilmesi, hastalık analizi yapılması ve mobil cihaza kaydedilmesi mümkündür. Kullanılan dijital stetoskop cihazı 44 100 Hz örnekleme frekansına sahiptir. Dijital stetoskop için görseller Şekil-5.2.'de sunulmaktadır.



Resim 5.3. Doğrulama testlerinde kullanılan dijital stetoskop cihaz.

Üçüncü bölümde bahsedildiği üzere hem akıllı cep telefonları için hem de tablet cihazlar için mobil uygulama geliştirilmiş olup, sınıflandırma algoritması ve çıkartılan öz nitelikler gibi hesaplama işlemleri tamamen aynıdır. İki sürüm arasındaki fark; doğrulama testlerinde kesin sonucu hesaplamak için kullanılan hafıza destekli sonuç çıktısıdır. Şekil 5.1 ve Şekil 5.2.’de “2. MEMORY BOOSTED DIAGNOSE” olarak gösterilen hafıza destekli sonuç, son beş tahmini bellekte tutarak çoğunluk sonucunu ekrana basan bir oylama fonksiyonunun sonucudur.

Doğrulama testleri klinik ziyaret için Ankara Şehir Hastanesine gelen 162 kişi üzerinde gerçekleştirilmiştir. Mobil uygulama, klasik muayenede kullanılan stetoskop cihazı ile kalp sesi dinlenme sürecini tekrarladığı için pasif bir işlemdir. Katılımcılar süreç hakkında sözlü olarak bilgilendirilmiş olup, katılımcıların kalp sesleri hem uzman doktorlar tarafından hem de mobil uygulama ile aynı zamanda analiz edilmiştir. Mobil uygulama ile elde edilen sonuçlar, hafıza destekli sonuç ile üretilen çıktılar baz alınarak kayıt altına alınmıştır. Uzman doktorlar tarafından kalp seslerinin anormal olduğu düşünülen katılımcılar ECG, görüntüleme teknikleri vb. ilave tetkikler ile muayene edilerek hastalık durumları netleştirilmiştir.

Değerlendirmelerin sonucunda 162 katılımcıdan 88’inin kalp hastalığı olduğu ve 74’ünün sağlıklı olduğu tespit edilmiştir. Veri seti kesin sınıflar ile etiketlendikten sonra, mobil uygulama ile elde edilen sonuçlar, kesin sınıf etiketleri ile karşılaştırılmıştır. Yapılan doğrulama testleri sonucunda hassasiyet oranı, yani hasta olanları yakalayabilme gücü %81,0 ve sağlıklı olanları yakalayabilme gücü olarak ifade edilen seçicilik değeri %92 olarak tespit edilmiştir. Sınıflandırma algoritmasının bilgisayar ortamında PhysioNet veri seti ile elde edilen başarısı ve mobil uygulama kullanılarak Ankara Şehir Hastanesinde elde edilen başarımları Çizelge 5.3.’de karşılaştırılmaktadır.

Çizelge 5.3. Sınıflandırma algoritmasının başarımının karşılaştırılması.

	Seçicilik	Hassasiyet	Veri Seti
Bilgisayar (MATLAB)	%96,0	%83,7	PhysioNet, 3905 örnek
Tablet (Mobil Uygulama)	%92,0	%81,0	Ankara Şehir Hastanesi, 162 örnek

Çizelge 5.3.'te sunulan karşılaştırma tablosu her ne kadar farklı büyüklükteki ve özellikteki veri setleri ile gerçekleştirilmiş olsa da aynı sınıflandırma algoritmasının mobil uygulamanın bir bileşeni olarak tablet cihazda ve klinik ortamda başarısını gösterdiği için önemlidir. Görüldüğü üzere, mobil uygulamanın doğrulama testlerinde, algoritmanın eğitimi ve testleri safhasında tespit edilen sonuçlara çok yakın bir sınıflandırma başarısı elde edilmiştir.

6. SONUÇ VE ÖNERİLER

Doğrulama testlerinden elde edilen sonuçlar neticesinde mobil uygulamanın gerçek durum şartlarında neredeyse uzman doktorlar kadar iyi bir şekilde teşhis yapabileceği ortaya konulmuştur. Stetoskop ile kalp hastalıklarının teşhis edilmesi ancak uzman doktorların veya iyi eğitilmiş hekimlerin başarılı olarak yapabileceği süreçtir [47-50]. Bu nedenle hem kardiyologlar hem de pratisyen hekimlerin karar destek sistemlerine ihtiyaçları vardır.

Kalp seslerini analiz eden Sensicardiac ve EKO AI isimli yazılımlar bulunmaktadır. Her iki ürün de uç cihazda bir servis gibi çalışmakta olup, hesaplama işlemleri bulut üzerindeki algoritmada bulut donanım kaynakları ile gerçekleştirilmektedir. Oysa, tez kapsamında geliştirilen uygulama internet bağlantısına ve ilave donanım gereksinimine ihtiyaç duymaz. Bu yazılımların başarımlar oranları kendi veri setleri ve kayıt cihazları ile elde edilmiş olup, mevcut başarımlar sonuçları uzman doktorlara yakındır. Proje kapsamında geliştirilen mobil uygulamanın sınıflandırma başarımları da mevcut ticari ürünlere benzerdir. Farklı veri setleri ile elde edilmiş sonuçlar olmasına rağmen fikir vermesi açısından karşılaştırma sonuçları Çizelge 6.1.'de sunulmaktadır.

Çizelge 6.1. Mobil uygulama ve mevcut ticari yazılımların karşılaştırılması.

	Mobil Uygulama (CardiacAI)	Sensicardiac	EKO AI
Seçicilik	%92,0	%58,3	%87,8
Hassasiyet	%81,0	%58,3	%87,6

Mobil uygulamanın mevcut yazılımlardan farklı olan yanlarından birisi de internet bağlantısına ihtiyaç duymadan mobil cihaz donanımı üzerinde çalışmasıdır. Diğer yazılımlar ise kalp seslerini buluta göndermekte ve yapay zekâ analizi yapıldıktan sonra sonuçlar kullanıcıya sunulmaktadır. Dolayısıyla, proje kapsamında gerçekleştirilen algoritma kullanıcıların kalp seslerinin paylaşılmasını engellemektedir. Kişisel verilerin paylaşılması konusu günümüzde en hassas konulardan birisidir. Bu nedenle, mobil uygulama, kişilerin sağlık durumu hakkındaki verinin üçüncü şahıs veya şirketler ile paylaşılması konusunda oluşabilecek sorunların da önüne geçmektedir. İnternet bağlantısına ihtiyaç duyulmaması da esnek bir şekilde kullanılması anlamına gelmektedir.

Uygulamanın bir diğer önemli özelliği de verileri en baştan kabul etmesi ve öngörülen tanı sonucunu beş saniyelik periyotlarla sürekli olarak çıkarmasıdır. Gelecekteki çalışmalarda, bu özellik, bir anormallik algılandığında alarm tetiklemek için yoğun bakım ünitelerine uyarlanabilir. Kardiyak olay monitörleri, hastanın kalp fonksiyonlarının düzgün olarak devam edip etmediğine karar vermek için elektrokardiyogram sinyallerini kontrol eder. Bu sürece kalp sesi dinleme yöntemini entegre edilirse hasta izleme sistemlerinin etkinliği artırılabilir. Küresel ölçekte bir salgın hastalık olduğu göz önüne alındığında, sağlık sistemi tüm dünyada büyük bir baskı altındadır. Ayrıca, doktorlar Korona Virüs (COVID-19) hastalığının neden olduğu artan hasta sayısından bunalmış durumdadır. Bu çalışmada sunulan sistemler benzeri tele tıp araçları, hastalara ön tanı ve muayene imkânı sağlayarak sağlık kontrolü nedeniyle hastaneye gelen sağlıklı bireylerin sayısını azaltabilir. Böylece, sağlık sistemin etkinliği artırılabilir.

Uzman hekimler, stetoskop ile kalp sesi dinlerken Aortik bölge, Pulmonik bölge, Mitral bölge vb. bazı odak noktalarını kullanırlar. Ankara Şehir Hastanesi'ndeki doğrulama testlerinde kayıt cihazı bu odak noktaları ile göğüs üzerinde kalp bölgesine yakın muhtelif noktalara odaklanmıştır. Bu şekilde değişik odak noktalarının kullanılmasındaki amaç uzman hekimlerin dışında sıradan kullanıcı davranışını taklit etmektir. Doğrulama veri seti sıradan kullanıcı davranışını içeren verileri de içerdiğinde mobil uygulamanın tıp eğitimi olmayan kişiler tarafından da kullanılabileceği değerlendirilmektedir. Doğrulama testlerinde kullanılan stetoskop cihazının diğer organlardan kaynaklanan gürültüleri filtreleyen bir özelliği bulunmaktadır. Ayrıca mobil uygulama da veri ön işleme safhasında kalp seslerini gürültüden temizlemektedir. Elde edilen sonuçlardaki başarının gürültü temizleme yönteminin ve kullanılan cihazın kalitesinden de kaynaklandığı ifade edilebilir.

Sonuç olarak, stetoskop cihazları ile kalp seslerini dinlemek ve hastalık teşhisi yapmak kullanılan en eski ve yaygın yöntemlerden birisidir. Fakat yeterli tecrübe ve eğitimi olmayan hekimlerin stetoskop kullanarak kalp hastalıklarını analiz etmesi zordur. Gelişen hesaplama gücü, dijital stetoskoplar gibi bağlantı sağlayabilen kayıt cihazlarının geliştirilmesi ve güçlü yapay zekâ yöntemleri ile bu sürecin makinalar ile gerçekleştirilmesi mümkündür. Bu tez çalışmasında da yukarıda ifade edilen motivasyon ile kalp seslerini analiz eden yapay zekâ destekli bir mobil uygulama geliştirilmiş ve hastane ortamında gerçek durum şartlarında başarısı doğrulanmıştır. Elde edilen yüksek başarımlı seviyesi mobil uygulamanın gücünü ortaya koymuştur. Ayrıca, doğrulama veri seti sıradan kullanıcı davranışını da sergilediği için hem uzman hekimler hem de tıp eğitimi olmayan kişiler tarafından kullanılabilir.

KAYNAKLAR

- Liu, C.Y., Springer, D., Li, Q., Moody, B., Juan R.A., Chorro F.J., Roig J.M., Silva, I., and Johnson, A. (2016). An open access database for the evaluation of heart sound algorithms. *Physiological Measures*, 2181-2213.
- Castillo, M., Conte, B., Hinkes, S., Mathew, M., Na, C.J., Norindr, A., Serota, D.P., Forrest, D.W., Deshpande, A.R., Bartholomew, T.S. (2020). Implementation of a medical student-run telemedicine program for medications for opioid use disorder during the COVID-19 pandemic. *Harm Reduction Journal*, 1-6.
- Mansouri, F. (2021). Role of Telemedicine and Telegenetics Framework for the Management of Cancer Patients During the COVID-19 Pandemic. *Biointerface Research in Applied Chemistry*, 8773–8779.
- Seferovic, P.M., Ponikowski, P., Anker, S.D., Bauersachs, J., Chioncel, O., Cleland, J.G.F. de Boer, R.A., Drexel H., Ben Gal T., and Hill L. (2019) Clinical practice update on heart failure 2019: Pharmacotherapy, procedures, devices, and patient management. An expert consensus meeting report of the Heart Failure Association of the European Society of Cardiology. *European Journal of Heart Failure*, 1169–1186.
- Akay, Y.M., Akay, M, Welkowitz W., and Kostis J. (1994). Noninvasive detection of coronary artery disease. *IEEE Engineering in Medicine and Biology*, 761-764.
- Liang, H., Lukkarinen, S., and Hartimo, I. (1997). Heart sound segmentation algorithm based on heart sound envelopogram. *Computing in Cardiology*, 105-108.
- Liang H., Sakari, L., and Liro, H. (1997). A heart sound segmentation algorithm using wavelet decomposition and reconstruction. *19th Annual International Conference of the IEEE Engineering in Medical and Biology Society*, 1630-1633.
- Oskiper, T., and Watrous, R. (2002). Detection of the first heart sound using a time-delay neural network. *Computing in Cardiology*, 537-540.
- Gamero, L., and Watrous, R. (2003). Detection of the first heart sound and second heart sound using probabilistic models. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2877-2880.
- Gill, D., Gavrieli, N., and Intrator, N. (2005). Detection and identification of the heart sounds using homomorphic envelopogram and self-organizing probabilistic model. *Computers in Cardiology*, 957-960.
- Bhatikar, S., DeGroff, C., and Mahajan R. (2005). A classifier based on the artificial neural network approach for cardiologic auscultation in pediatrics. *Artificial Intelligence in Medicine*, 251-260.
- Nigam, V., and Priemer, R., (2005) Accessing heart Dynamics to estimate durations of heart sounds. *Physiological Measurement*, 1005-1018.

- Ahlstrom, C., Hilt, P., Rask, P., Karlsson, JE., Nylander, E., Dahlstrom, U., and Ask, P. (2006). Feature extraction for systolic heart murmur classification. *Annals of Biomedical Engineering*, 1666-1677.
- Jiang, Z., and Choi, S. (2006). A cardiac sound characteristic waveform method for in-home heart disorder monitoring with electric stethoscope. *Expert Systems with Applications*, 286-298.
- Kumar, D., Carvalho, P., Antunes, M., and Henriques J. (2006). Detection of S1 and S2 heart sounds by high frequency signatures. *Annual International Conference of the IEEE Engineering on Medicine and Biology Society*, 1410-1416.
- Gupta, C., Palaniappan, R., Swaminathan, S., and Krishnan, S. (2007) Neural network classification of the homomorphic segmented heart sounds. *Applied Soft Computing*, 286-297.
- Chauhan, S., Wang, P., Sing, C., and Anantharaman, V. (2008). A computer aided MFCC-based HMM system for automatic auscultation. *Computational Biology and Medicine*, 221-233.
- Choi, S., and Jiang, Z. (2008). Comparison of envelope extraction algorithms for cardiac sound signal segmentation. *Expert Systems with Applications*, 1056-1069.
- Maglogiannis, I., Loukis, E., Zafiropoulos, E., and Stasis, A. (2009). Support vector machine-based identification of heart valve diseases using heart sounds. *Computer Methods and Programs in Biomedicine*, 45-61.
- Chen, T., Kuan, K., Celi, L., and Clifford, GD. (2009). *Intelligent heart sound diagnostics on a cellphone using a hands-free kit*. Spring Symposium on Artificial Intelligence for Development, 26-31.
- Schmidt, SE., Holst-Hansen, C., Graff, C., Toft, E., Struijk, J. (2010). Segmentation of heart sound recordings by duration-dependent hidden Markov model. *Physiological Measurement*, 513-529.
- Ari, S., Hembram, K., and Saha, G. (2010). Detection of cardiac abnormality from PCG signals using LMS based least square SVM classifier. *Expert Systems with Applications*, 8019-8026.
- Avendano-Valencia, LD., Godino, JI., Blanco, M., and Castellanos, G. (2010). Feature extraction from parametric time-frequency representation for heart murmur detection. *Annals of Biomedical Engineering*, 2716-2732.
- Gharehbaghi, A., Dutoir, T., Sepehri, A., Hult, P., and Ask, P. (2011). An automatic tool for pediatric heart sounds segmentation. *Computing in Cardiology*, 37-40.
- Li, T., Tang, H., Qui, T., and Park, Y. (2011). Best subsequence selection of heart sound recording based degree of sound periodicity. *Electronics Letters*, 841-843.

- Moukadem, A., Dieterlen, A., Hueber, N., and Brandt C. (2011). *Localization of heart sounds based On S-Transform and radial basis function neural network*. Nordic-Baltic Conference on Biomedical Engineering and Medical Physics, 168-171.
- Castro, A., Vinboza, T., Mattos, S., and Coimbra, M. (2013). Heart sound segmentation of pediatric auscultations using wavelet analysis. *Annual conference of the IEEE Engineering in Medicine and Biology Society*, 3909-3912.
- Moukadem, A., Dieterlena, A., Hueberb, N., and Brandtc, C. (2013). A robust heart sounds segmentation module based on S-transform. *Biomed Signal Process Control*, 273-281.
- Naseri, H., Homaeinezhad, MR., and Porkhajeh, H. (2013). Noise/spike detection in phonocardiogram signal as a cyclic random process with non-stationary period interval. *Computers in Biology and Medicine*, 1205-1213.
- Papadaniil, CD., and Hadjileontiadis, LJ. (2014). Efficient heart sound segmentation and extraction using ensemble empirical mode decomposition and kurtosis features. *IEEE J Biomedical and Health Informatics*, 1138-1152.
- Pedrosa, J., Castro, A., and Vinhoza, T. (2014). Automatic heart sound segmentation and murmur detection in pediatric phonocardiograms. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2294-2297.
- Patidar, S., Pachori, RB., and Garg N. (2015). Automatic diagnosis of septal defects based on tunable-Q wavelet transform of cardiac sound signals. *Expert Systems with Applications*, 3315-3326.
- Liu C.Y., Springer, D., Li, Q., Moody, B., Juan, R.A., Chorro, F.J. Castells, F., Roig, J.M., Silva, I., and Johnson, A.E.W. (2016). An open access database for the evaluation of heart sound algorithms. *Physiological Measurement*, 2181–2213.
- Chengyu, L. Springer, D., Li, Q., Moody, B., Juan, R., Chorro, F., Castells, JM., and Gari D Clifford (2016). An Open Access Database for Evaluation of Heart Sound Algorithms. *Physiological Measurement*, 2181-2213.
- Latif S., Usman M., Rajip R., Quadir J. (2018). Phonocardiographic Sensing using Deep Learning for Abnormal Heartbeat Detection. *IEEE Sensors Journal*, 9393-9400
- Juan, P., Angel, F., Manuel, J., and Gabriel J.M. (2018). Deep neural networks for the recognition and classification of heart murmurs using neuromorphic auditory sensors. *IEEE Transactions on Biomedical Circuits and Systems*, 24-34.
- Yu T., Tzu, L., Fei, C., Yun, C., Chui, C., and Kun, T, (2019). Robust S1 and S2 heart sound recognition based on spectral restoration and multi-style training. *Biomedical Signal Processing and Control*, 173-180.
- Syed, Z., Leeds, D., Curtis, D., Nesta, F., Levine, RA., and Guttag, J. (2007). A framework for the analysis of acoustical cardiac signals. *IEEE Trans Biomedical Engineering*, 651-662.

- Samieinasab, M., and Sameni, R. (2015). *Fetal phonocardiogram extraction using channel blind source separation*. 23rd Iranian Conference on electrical Engineering, 78-83.
- Phua, K., Chen, J., Dat, T., and Shue, L. (2008). Heart sound as a biometric. *Pattern Recognition*, 906–919.
- Jiang, Z., Miyamoto, A., Wei, Y., and Yan, Z. (2010). The moment segmentation analysis of heart sound pattern. *Computer Methods and Programs in Biomedicine*, 140-150.
- Jiang, Z., and Choi, S. (2006). A cardiac sound characteristic waveform method for in-home heart disorder monitoring with electric stethoscope. *Expert Systems with Applications*, 286–298.
- Sun, S., Jiang, Z., Wang, H., Fang, Y. (2014). Automated moment segmentation and peak detection analysis of heart sound pattern via short-time modified Hilbert transform. *Computer Methods and Programs in Biomedicine*, 219-230.
- Davis, S., and Mermelstein, P. (1980). Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 357–366.
- Zewodie, A.W., Luque, J., and Hernando J. (2018). The use of long-term features for GMM- and i-vector-based speaker diarization systems. *EURASIP Journal on Audio, Speech, and Music Processing*, 1-11.
- De Vos, J., and Blanckenberg, M. (2007). Automated pediatric cardiac auscultation. *IEEE Transactions on Biomedical Engineering*, 244-252.
- Quiceno-Manrique, AF., Godino-Llorente, JI., Blanco-Velasco, M., and Castellanos-Dominguez, G. (2010). Selection of dynamic features based on time-frequency representation for heart murmur detection from phonocardiographic signals. *Annals of Biomedical Engineering*, 118-137.
- Haney, I., Ipp, M., Feldman, W., and McCrindle, B.W. (1999) Accuracy of clinical assessment of heart murmurs by office based (general practice) pediatricians. *Archives of Disease Childhood*, 409–412.
- Gardezi, S.K.M., Myerson, S.G., Prendergast, B., Prothero, A., Prendergast, A., Loudon, and M., D’Arcy J. (2017). Cardiac auscultation in diagnosing valvular heart disease: A comparison between general practitioners and cardiologists. *European Heart Journal*, 1155-1155.
- Rushmer, R.F., Sparkman, D.R., Polley, R.F., Bryan, E.E., Bruce, R.R., Welch, G.B., and Bridges, W.C. (1952). Variability in detection and interpretation of heart murmurs; a comparison of auscultation and stethography. *The American Journal of Diseases of Children*, 740–754.
- Leach, R.M., and McBrien, D.J. (1990). Brachioradial delay-A new clinical indicator of the severity of aortic-stenosis. *The Lancet Journal*, 1199–1201.



GAZİ GELECEKTİR..