

Osman BALLI



İSKENDERUN TEKNİK
ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**YÜKSEK
LİSANS
TEZİ**

**OSKÜLTASYON CİHAZ
TASARIM VE KARAR
DESTEK SİSTEMİ**

Osman BALLI

**BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

ARALIK 2022

ARALIK 2022



OSKÜLTASYON CİHAZ TASARIM VE KARAR DESTEK SİSTEMİ

Osman BALLI

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

Aralık 2022

Osman BALLI tarafından hazırlanan “OSKÜLTASYON CİHAZ TASARIM VE KARAR DESTEK SİSTEMİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Yakup KUTLU

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.

.....
.....
...

Başkan: Doç. Dr. Sertan ALKAN

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.

.....
.....
...

Üye: Dr. Öğr. Üye. Mustafa YENİAD

Bilgisayar Mühendisliği Anabilim Dalı, Ankara Yıldırım Beyazıt Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.

.....
.....
...

Tez Savunma

Tarihi: 22 / 12 / 2022

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ersin BAHÇECİ

Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülediğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
 - 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.

İmza

Osman BALLI

22 / 12 / 2022

OSKÜLTASYON CİHAZ TASARIM VE KARAR DESTEK SİSTEMİ
(Yüksek Lisans Tezi)

Osman BALLI

İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Aralık 2022

ÖZET

Vücut içi seslerinin analizi, vücudun durumu hakkında ön bilgi vermekte ve ilk muayene olarak yapılan klasik bir işlemdir. Bu işleme oskültasyon denilmekte ve işlem için stetoskop kullanılmaktadır. Stetoskopun icadından günümüze kadar geldiği süreçte çok fazla gelişim göstermiştir. Elektronik stetoskopun icadı ve kullanılmaya başlanması sağlık alanında işlemlerin daha hızlı ve pratik olması sağlamıştır. Bu stetoskopların veri kaydedebilme özelliği sayesinde yapay zeka destekli önemli çalışmaların önünü açmıştır.

Tez çalışması iki aşamadan oluşmaktadır: Öncelikle yeni bir giyilebilir çok kanallı oskültasyon donanımı geliştirmek ve ölçülen ses verilerini yapay zeka destekli analizinin yapılması sağlamaktır.

İlk aşama olan giyilebilir oskültasyon cihazı geliştirilmesi sağlanmıştır. geliştirilen donanımın kablosuz haberleşme modülü sayesinde sağlık çalışanları için uzaktan tedavi imkanı sunmaktadır. Çok kanallı bir oskültasyon cihazı oluşturduğumuz sistemde kullanıcı arayüzü sayesinde sağlık personeli ve hasta arasında uzaktan iletişim kurulabilecektir. kaydedilen ses kayıtları gönderildiğinde sesin hangi bölgeye ait olduğu ve olası hastalıkları sağlık personeline listeleyecek bir yapay zeka modeli geliştirilmiştir. Ayrıca kullanıcı arayüzü sayesinde farklı uzmanlardan görüş almak için veri paylaşımlı uzaka bağlantı modülü olarak da kullanılabilir. Model farklı veri setleri birleştirilerek yeni bir veri setini oluşturulması ve bu veri setinin eğitilmesi ile oluşturulmuştur. Sistem Ses verilerini önce bölgesel olarak tanımaktadır. Bölge tanımından sonra sesin sağlıklı ya da hasta olduğunu belirlemektedir. Eğer ses verileri hastaya ait ise bu hastalığın hangi hastalığa ait olduğu bulunmaktadır. Bu sistem evde tedavi hizmetinin gelişimini sağlayacaktır.

Anahtar Kelimeler : Oskültasyon, tele tedavi, yapay zeka

Sayfa Adedi : 70

Danışman : Doç. Dr. Yakup KUTLU

OSCULTATION DEVICE DESIGN AND DECISION SUPPORT SYSTEM
(M. Sc. Thesis)

Osman BALLI

ISKENDERUN TECHNICAL UNIVERSITY
INSTITUTE OF GRADUATE STUDIES

December 2022

ABSTRACT

Analysis of body sounds gives preliminary information about the state of the body and is a classical procedure performed as the first examination. This process is called auscultation and stethoscope is used for the procedure. From the invention of the stethoscope to the present day, it has shown a lot of development. The invention and use of the electronic stethoscope has made the procedures in the field of health faster and more practical. Thanks to the data recording feature of these stethoscopes, it has paved the way for important studies supported by artificial intelligence.

The thesis work consists of two stages: First of all, it is to develop a new wearable multi-channel auscultation hardware and to provide artificial intelligence support analysis of the measured sound data.

The first stage was the development of a wearable auscultation device. Thanks to the wireless communication module of the developed hardware, it offers remote treatment for healthcare professionals. In the system where we have created a multi-channel auscultation device, remote communication between the healthcare personnel and the patient will be possible thanks to the user interface. When the recorded voice recordings are sent, an artificial intelligence model has been developed that will list the region to which the voice belongs and possible diseases to the health personnel. It can also be used as a data sharing remote connection module to get opinions from different experts thanks to its user interface. The model was created by combining different data sets, creating a new data set and training this data set. The system first recognizes the Voice data regionally. After the region definition, it determines whether the voice is healthy or sick. If the voice data belongs to the patient, it is found that this disease belongs to which disease. This system will enable the development of home treatment service.

KeyWords : Oscultation, Tele-treatment, artificial intelligence
PageNumber : 70
Supervisor : Doç. Dr. Yakup KUTLU

TEŐEKKÜR

Yıllardır danışmanlıđımı, akıl hocalıđımı yapan ve her zaman daha iyisini hedefleme mi sađlayan Doç. Dr. Yakup Kutlu hocama, desteklerini her zaman yanımda hissettiđim aileme, tez sürecinde yardımlarını esirgemeyen arkadaşım Kaan ALPTÜRK'e teşekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ	1
2. GENEL BİLGİLER	3
2.1. Oskültasyon Nedir?	3
2.2. Kalbin Yapısı ve Fizyolojisi.....	4
2.2.1. Kalp sesleri.....	6
2.3. Akciğerlerin Yapısı ve Anatomisi.....	8
2.3.1. Akciğer sesleri	10
2.4. Bağırsak Yapısı ve Anatomisi	14
2.5. Literatür İncelemesi.....	16
2.6. Tezin Amacı.....	18
3. MATERYAL VE METOT.....	20
3.1. Verilerin Toplanması.....	21
3.2. Öznitelik Çıkarımı	22
3.3. Sınıflandırma	23
3.3.1. K en yakın komşu	23
3.3.2. Karar ağacı	24
3.3.3. Rastgele orman.....	24
3.3.4. Aşırı gradyan artırma	24
3.3.5. Destek vektör makineleri	26

	Sayfa
3.3.6. Navie bayes	27
3.3.7. Evriřimli sinir ađı.....	28
3.3.8. Performans ölçüm yöntemleri.....	31
3.4. Donanımın Hazırlanması.....	32
3.4.1. Analog sinyal işleme birimi	33
4. ARAřTIRMA BULGULARI	40
4.1. Sınıflandırma	41
4.1.1. Kalp, akciđer ve batın seslerinin sınıflandırması.....	41
4.1.2. Kalbe ait sađlıklı ve hasta ses verilerinin sınıflandırılması	43
4.1.3. Kalp hastalıklarının sınıflandırılması.....	45
4.1.4. Aort darlıđının sınıflandırılması	47
4.1.5. Mitral darlıđının sınıflandırılması.....	49
4.1.6. Mitral yetersizliđi sınıflandırılması.....	50
4.1.7. Triküspit yetersizliđi sınıflandırılması.....	52
4.1.8. Akciđerlere sit sađlıklı ve hasta ses verilerinin sınıflandırılması	54
4.1.9. Akciđer hastalıklarının sınıflandırılması.....	55
4.1.10. KOAH sınıflandırılması.....	57
4.1.11. Batın sınıflandırılması.....	59
4.2. Donanım.....	60
5. SONUÇ VE ÖNERİLER.....	63
KAYNAKLAR	65

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Solunum seslerinin klinik özellikleri ve korelasyonları	13
Çizelge 3.1. Sınıflandırma Doğruluk Tablosu	32
Çizelge 3.2. Raspberry Pi Model 3B' nin Teknik Özellikleri	37
Çizelge 4.1. Bölgesel ses sınıflandırılması başarımları	42
Çizelge 4.2. Kalbe ait hasta ve sağlıklı verilerinin sınıflandırma başarımları.....	44
Çizelge 4.3. Kalp hastalık verilerinin sınıflandırma başarımları.....	45
Çizelge 4.4. Aort darlığı verilerinin sınıflandırma başarımları	48
Çizelge 4.5. Mitral darlığı verilerinin sınıflandırma başarımları.....	49
Çizelge 4.6. Mitral yetmezliği verilerinin sınıflandırma başarımları	51
Çizelge 4.7. Triküspit yetmezliği verilerinin sınıflandırma başarımları	53
Çizelge 4.8. Akciğere ait hasta ve sağlıklı verilerinin sınıflandırma başarımları	54
Çizelge 4.9. Akciğer hastalık verilerinin sınıflandırılma sonuçlarına ait doğruluk tablosu	56
Çizelge 4.10. KOAH verilerinin sınıflandırma başarımları	58
Çizelge 4.11. Batın verilerinin sınıflandırma başarımları	60

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Mekanik Stetoskop	4
Şekil 2.2. Elektronik Stetoskoplar	4
Şekil 2.3. Kalbin ön taraftan görünümü.....	5
Şekil 2.4. Kalp dinleme odakları.....	6
Şekil 2.5. Kalpteki basınç, EKG ve PCG'nin zamanla değişimi	7
Şekil 2.6. Birinci, ikinci, üçüncü ve dördüncü kalp sesleri.....	8
Şekil 2.7. Solunum sisteminde yer alan organlar.....	9
Şekil 2.8. Akciğerlerin önden görünümü	10
Şekil 2.9. Akciğer dinleme odakları.....	11
Şekil 2.10. Batın Bölgesi ve Dinleme Noktaları.....	15
Şekil 3.1. Dinleme noktalarında oluşabilecek örnek sinyaller.....	20
Şekil 3.2. Sistem Genel Şeması	21
Şekil 3.3. MFKK' nin Blog Diyagramı	23
Şekil 3.4. Konvolüsyon Katmanında Uygulanan Filtrenin Detaylı Gösterimi	29
Şekil 3.5. Evrişimli sinir ağı maksimum havuzlama katmanı detaylı gösterimi	30
Şekil 3.6. Tam Bağlantılı Katman detaylı gösterimi.....	31
Şekil 3.7. Devre şeması.....	34
Şekil 3.8. Yüksek Geçiren Filtre Kesim Frekans Grafiği	35
Şekil 3.9. Alçak Geçiren Filtre Kesim Frekans Grafiği	35
Şekil 3.10. Elektret Mikro fonu Çıkışından Elde Edilen Sinyal	36
Şekil 3.11. Devre Çıkışından Elde Edilen Sinyal	36
Şekil 3.12. Raspberry Pi Model 3B	37
Şekil 3.13. Ses Kartı.....	38
Şekil 3.14. Arayüz Tasarımı	39
Şekil 4.1. Tanı Sistemi Şeması	41
Şekil 4.2. Kalp, Akciğer ve Batın için Kullanılan Sınıflandırmaların Başarım Sonuçları.....	43

Şekil	Sayfa
Şekil 4.3. Kalbe Ait Sağlıklı ve Hasta Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları	44
Şekil 4.4. Kalbe Ait Sağlıklı ve Hasta Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları	47
Şekil 4.5. Aort Darlığına Ait Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları	48
Şekil 4.6. Mitral Darlığına Ait Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları	50
Şekil 4.7. Mitral Yetersizliğine Ait Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları	52
Şekil 4.8. Triküspit Yetersizliğine Ait Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları	53
Şekil 4.9. Akciğere Ait Hasta ve Sağlıklı Veriler için Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları	55
Şekil 4.10. Akciğere Ait Hasta Verileri Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları	57
Şekil 4.11. KOAH Verileri Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları.....	59
Şekil 4.12. Batın Verileri Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları.....	60
Şekil 4.13. Donanımın Vücut Üzerindeki Görüntüsü	61
Şekil 4.14. Arayüzde Sinyallerin Görüntülenmesi	62

SİMGELER VE KISALTMALAR

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

Simgeler

Hz

KHz

MHz

Açıklamalar

Hertz

Kilohertz

Megahertz

Kısaltmalar

AGA

DVM

ESA

KA

k-EYK

MFKK

NB

RO

Açıklamalar

Aşırı Gradyan Artırma

Destek Vektör Makinesi

Evrişimli Sinir Ağı

Karar Ağacı

k En Yakın Komşu

Mel Frekanslı Kepstral Katsayıları

Navie Bayes

Rastgele Orman

1. GİRİŞ

Hayatın en önemli parçası sağlıkır. Sağlıklı bir birey hayatını iyi bir şekilde devam ettirirken sağlığı kötü olan birey için hayat zorlaşmaktadır. Canlılık hayatının sağlıklı bir şekilde sürdürülebilmesi için birçok çalışma yapılmaktadır. Biyomedikal alanında yapılan teknolojik gelişmeler ise bu konuyu doğrudan ilgilendirmektedir. Biyomedikal cihazlarının geliştirilmesi sağlık alanında çözümlerin artırılmasını sağlamaktadır.

Steteskopun cilde yerleştirilmesiyle hava akımının bronşlar ve alveollerde oluşturduğu titreşimin dinlenmesi ile yapılan muayeneye oskültasyon denir (Aydemir, 2011). Oskültasyon vücut içi sesleri dinlenerek, organların işleyişini kontrol etme işlemidir. Bu işlem sayesinde vücudun durumu hakkında ön bilgi edinilebilmektedir. Göğüs oskültasyonu, Hipokrat'a dayanan uzun bir süredir tıp dünyasındadır. 1816'da René Laënnec tarafından steteskop üretilmiş ve göğüs oskültasyonu daha kullanışlı ve hijyenik hale getirilmiştir (Bohadana ve diğerleri, 2014). Solunum sistemi ile ilgili klinik bilgilerin hızlı, kolay ve neredeyse evrensel olarak kabul edilmiş bir biçimde mevcut araçlarla edinilmesini sağlayan hiçbir klinik prosedür oskültasyondan iyi değildir (Bohadana ve diğerleri., 2014). Ayrıca oskültasyon, hasta ile minimum düzeyde işbirliği yapılmasını gerektirir (Bohadana ve diğerleri, 2014). Bu durum, tıbbi teşhisi kolaylaştıracaktır.

Oskültasyonun vazgeçilmez parçası steteskoptur. Klasik steteskop ile basit ve ucuz bir yolla ölçüm yapılabilirken bazen harici parazit seslere maruz kalılabilmekte, 120 Hz üzerindeki ses bileşenleri zayıflayabilmekte ve oskültasyon yapılırken vücuttan alınması istenen ses frekanslarında bir filtreleme yapılmadığından tamamen doğru bilgilere erişilememektedir (Abella ve Formolo, 1992). Ayrıca oskültasyon sırasında sinyal analizini olumsuz etkileyen bazı faktörler vardır. Bunlar: hastanın yaşı ve kilosu, akciğerlerde değişen hava hacmi, ses yakalama konumu, solunum akışı, hastanın pozisyonu, ölçüm ekipmanının özellikleridir (Bahoura, 1999). Çoğu stetoskop algılanan sesleri kaydedemez, bu da oskültasyon seslerinin diğer sağlık personeli ile paylaşılmasını zorlaştırır (Lee ve diğerleri, 2022).

Stetoskop ile vücut sesleri dinlenirken hem vücut içi hem de dinlemenin yapıldığı çevreden kaynaklı birçok gürültü oluşmaktadır. Oskültasyonda elde edilen seslerin analizi teşhisi yapan sağlık personelinin bilgi ve tecrübesine dayalı olarak değişmektedir (Kim ve diğerleri, 2021).

Bu durumda objektif bir yorumun yapılabilmesi için yeni teknolojilerin desteği şarttır. Gürültü önleme durumlarına göre farklı çeşitlilikte stetoskop bulunmaktadır. Ayrıca elektronik stetoskoplarda günümüzde sık sık kullanılmaktadır. Elektronik stetoskopların ses kayıt özelliklerinin bulunması birçok veri setinin oluşturulmasını sağlamıştır. Bu veri setleri üzerinde yapılan çalışmalar da sağlık alanında geliştirilen teknolojilere yön vermektedir.

Vücut sesleri hastalık teşhisinde çok önemlidir. Tıbbi teşhislerin doğru bir şekilde konulması için normal solunum sesleri ile hırıltı gibi anormal sesler arasındaki ayrımın sağlanabilmesi gerekmektedir. Bu sesler aracılığı ile akciğerlere ait fizyolojik ve patolojik bilgiler ile hava yolu obstrüksiyonu hakkında bilgiler elde edilebilir (Sovijarvi ve diğerleri, 2000). Hırıltı sesleri bazı hastalıkların tanısında ve takibinde önem taşır (Athanzio, 2012), çıtırtılı seslerin fibrozis ve pulmoner ödem tanısında önemi vardır (Kim ve diğerleri, 2021). Stridor seslerinden ise üst solunum yolları ile ilgili tıkanma rahatsızlıkları teşhis edilebilir (Nath ve diğerleri, 2021). S1 ve S2 bölgelerinde ses bölünmesi varsa kalp kapağı ile ilgili hastalıklar ya da hipertansiyondan şüphelenilebilir (Maganti ve diğerleri, 2010). Ayrıca S3 ve S4'te ses varsa kalp yetmezliği ve akut koroner hastalıkları düşünülebilir (Tseng ve diğerleri, 2012). Bu seslere ait detaylı bilgilere tezin 2.1 numaralı bölümünde değinilecektir.

İnsan ses dinleme eşiği ile vücut seslerini kıyasladığımız zaman aradaki farklılıklar gürültü oluşturmaktadır. Asıl duyulması gereken frekans aralıklarına farklı frekansların eklenmesi sesi etkilemektedir. Bu yüzden teşhis sırasında hatalı sonuçlar veya net olmayan kararlar verilebilmektedir. Gürültülerin filtrelenmesi yapılacak teşhislerin kolaylaştırılmasını sağlayacaktır. Elektronik stetoskoplar filtreleme ve kayıt işlemi yapmaktadır. Genel olarak tek kanallı olan bu cihazlar yaygın olarak kullanılmaktadır.

Projenin amacı oskültasyon seslerinin analizi için bir hibrit sistem üretmektir. Bölgesel olarak başlayıp belirli hastalıkların tanısına kadar kademeli olarak teşhis işlemi yapılmaktadır. Bu sistemde sağlanan aşamalı tanı sayesinde doktora yardımcı bir sistem üretilirken olası hatalı etiketlenen verilerin de önüne geçinilmesi sağlanacaktır. Ayrıca oluşturulan donanım, sağlık çalışanları ve hastalar arasında uzaktan iletişim sağlamaktadır. Hazırlanan sistem sağlık çalışanının belirlediği doğrultuda hastanın yaptığı işlemlerin kontrol edilmesini sağlamaktadır.

2. GENEL BİLGİLER

2.1. Oskültasyon Nedir?

Yüzyıllardır insanlar vücut seslerini dinlemekte ve bu sesleri anlamlandırmaya çalışmaktadır. Bu sesler vücut hakkında tedavi için ön bilgi vermektedir. Vücut seslerini dinleme işlemine oskültasyon denir. Oskültasyon işlemi için stetoskop kullanılmaktadır. Kalp, akciğer, bağırsak ve karın sesleri bi cihaz yardımı olmadan da duyulabilmektedir. Fakat zamanla bu seslerin daha net algılanabileceği ve iyi analiz yapılabileceği anlaşılmıştır. Bu sayede stetoskop gelişmeye başlamıştır.

Stetoskop, tüm doktorlar için ortak olan tek araç denebilir. Stetoskop kelimesi, Yunanca göğüs anlamına gelen stethos ve keşfetmek anlamına gelen skopein kelimelerinden gelir. Stetoskopun icadı 1800' lü yıllara dayanmaktadır. Rene Theophile Hyacinthe Laennec, stetoskobu 1816 yılında icat etti. 1819'da oskültasyon, L'auscultation Mediate üzerine tezini yazdı. Laennec'in fikirleri yavaş yayıldı ve tezin 1821'de John Forbes tarafından İngilizce'ye çevrilmesiyle desteklendi. 1826'da Laennec'in ölümü sırasında stetoskopların kabulü yaygınlaştı. 1828 yılında Piorry stetoskopta huni şeklindeki çan, aydınlatılmış bir gövde ve daha iyi bir sızdırmazlık için daha ince kulaklık kullandı. 1843'e kadar tek kulaklık kullanılmıştır. 1843 yılında Williams İlk çift kulaklıklı stetoskopu geliştirdi. 1945 – 1946 yıllarında Rappaport, Sprague ve Groom tarafından modern binaural stetoskopun ideal özellikleri belirlemek için çeşitli tasarımlarla deneyler yapıldı. Örneğin, düşük iç hacme sahip kısa boru ve iyi oturan kulaklıklar gibi özellikler denendi. 1956 sonrasında Litmann, Leatham gibi kardiyologlar günümüzde kullanılacak şekilde düzenlemeler yapmışlardır (Tamas ve diğerleri, 2016).

Mekanik stetoskoplarda (Şekil 2.1) genel olarak diyafram, tüp ve kulaklık bulunur. Stetoskopta bulunan diyafram hastanın dinleneceği bölgeye yerleştirilir ve vücut sesleri diyaframı titreştirir. Bu sayede stetoskop hortumunda akustik basınç dalgaları oluşturur. Oluşan bu dalgalar dinleyen kişiye iletilir. Mekanik stetoskoplar taşınabilir ve kullanımının kolay olmasına rağmen uzman kişiler tarafından yorumlanabilecek veriler sunar.



Şekil 2.1. Mekanik Stetoskop

Dijital sağlık sensörlerinin geliştirilmesi ile otomatik analiz, grafiklerin görselleştirilmesi, verilerin depolanması ve bu depolama ile bilgisayar destekli izleme ve tanılama sağlanmıştır (George ve diğerleri, 2021). Teknolojinin gelişmesi stetoskopların üzerinde de etki göstermiştir. Klasik stetoskopların yerini yavaştan elektronik stetoskoplar almaya başlamıştır. Elektronik stetoskoplar aldıkları sesi yükseltip filtreleyerek daha anlaşılır hale getirmektedir. Ayrıca sesi dijital ortama aktarabilmesi sayesinde veriler üzerinde analiz yapılmasını sağlamaktadır. Bu sayede sadece uzman değil bu alanda acemi kişiler de kolay analiz yapabilmektedir. Şekil 2.2’de bazı elektronik stetoskop resimleri gösterilmiştir.

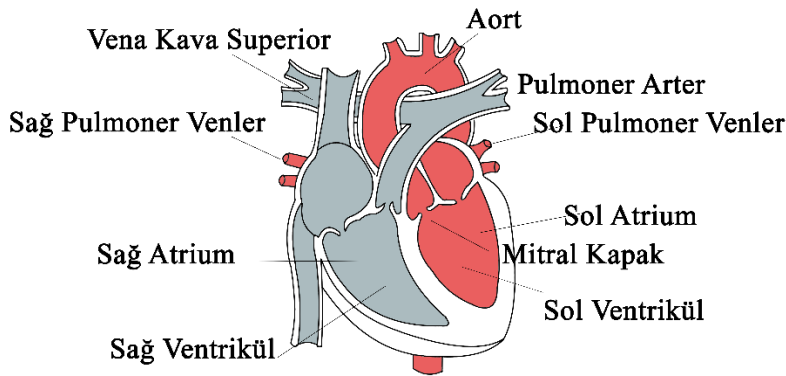


Şekil 2.2. Elektronik Stetoskoplar

Oskültasyon işlemi kalp, akciğer ve batın olmak üzere 3 bölgede yapılmaktadır. Bu bölgelerin belirli dinleme noktaları ve stetoskop yardımı ile vücut hakkında daha iyi bilgi alınabilmektedir.

2.2. Kalbin Yapısı ve Fizyolojisi

Kalp, kanı pompalayan hayati bir organdır. Kas dokusundan oluşmuştur. Göğüs kafesinin tam ortasında, iki akciğerin arasında, göğüs duvarının arkasında bulunur. Kalbin ön taraftan görünümü Şekil 2.3’de verilmiştir.



Şekil 2.3. Kalbin ön taraftan görünümü

Kalpte dört boşluk bulunur. Bunlar; sağda ve solda birer kulakçık (sağ ve sol atrium) ve karıncıktır (sağ ve sol ventrikül). Kalp kapakları, kanın tek yönlü akmasını sağlar. Bu sayede kanın geri kaçışının da önünü geçmiştir olur. Triküspit kapak, sağdaki kulakçık ve karıncığı, mitral kapak ise soldaki kulakçık ve karıncığı ayırır. Aort kapağı kalbin sol karıncığının bitimi ile kalpten çıkan aort damarının arasında bulunur. İnsanın en büyük atardamarı aort damarıdır. Pulmoner kapak ise benzer bir şekilde pulmoner damar ile sağ karıncık arasındadır. Mitral kapak, sol karıncık ve sol kulakçık arasında bulunmaktadır (alpman, 2022).

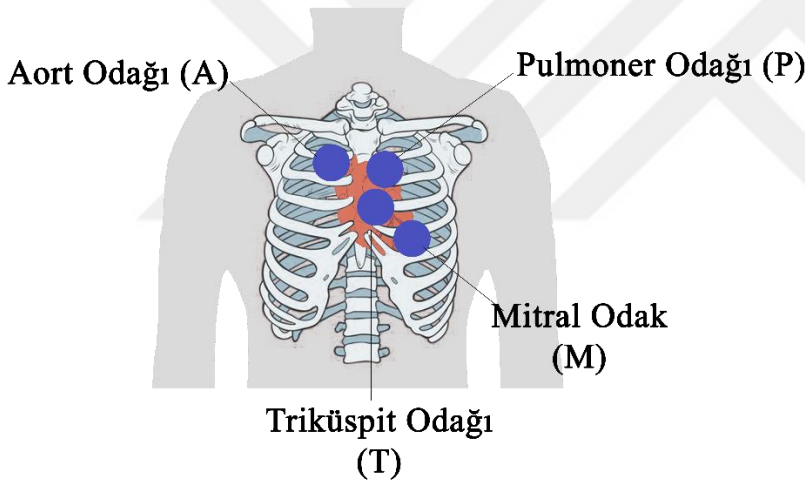
Bir kalp atımı, özelleşmiş bir hücre demetinden oluşan sağ kulakçığın üst tarafında bulunan sinotatrial düğümün elektriksel bir uyarı vermesi ile başlar. Bu hücreler belirli bir hızda ve eşit aralıklarla uyarı verirler. Sinotatrial düğümünden çıkan bu uyarı aşağıya doğru özelleşmiş iletim yolları ile yayılır. Bu uyarı ile kulakçıkların içlerindeki kan kasılarak karıncıklara gider. Daha sonra uyarı kulakçıklar ile karıncıklar arasında bulunan atrioventriküler düğüme gelir. Elektrik iletisi atrioventriküler düğüme kısa bir süre bekletilir ve kulakçıklarla karıncıklar aynı anda kasılması engellenir. His-Purkinje sistemi adı verilen elektriksel ağ ile atrioventriküler düğümden geçen akım karıncıklara yayılır.

Karıncıklar içlerindeki kanı kasılarak akciğerlere ve vücuda pompalarlar. Daha sonra sinotatrial düğüm başka bir uyarı çıkararak yeni bir döngüyü başlatır (Barry, 2004). Kalbin pompalanması ile kan dolaşımı başlar. Pulmoner dolaşımına küçük kan dolaşımı da denmektedir. Sağ karıncıktan çıkan kirli kan akciğer atar damarını takip ederek akciğere gelir. Kanın akciğerde temizlenmesi sonucunda kalbin sol kulakçık bölümüne dökülmesi ile pulmoner dolaşım tamamlanır. Sistemik dolaşım ise oksijenlenmiş kanı vücudun farklı bölümlerine götürür ve kalbe kirli kan getirir (alpman, 2022)

2.2.1. Kalp sesleri

Kalp sesleri kanın kardiyovasküler sistemde hareketi ve kalp kapakçıklarının açılıp kapanması ile meydana gelir. Hem sistolik ve diastolik kalp sesleri hem de kalp üfürümlerin mikrofon sayesinde alınabilmektedir. Alınan sinyaller bir kuvvetlendirici ile kuvvetlendirilebilir analog veya dijital filtre yardımıyla belirli frekans aralığı seçilerek kullanılabilir ve bu işlemlere fonokardiografi denir.

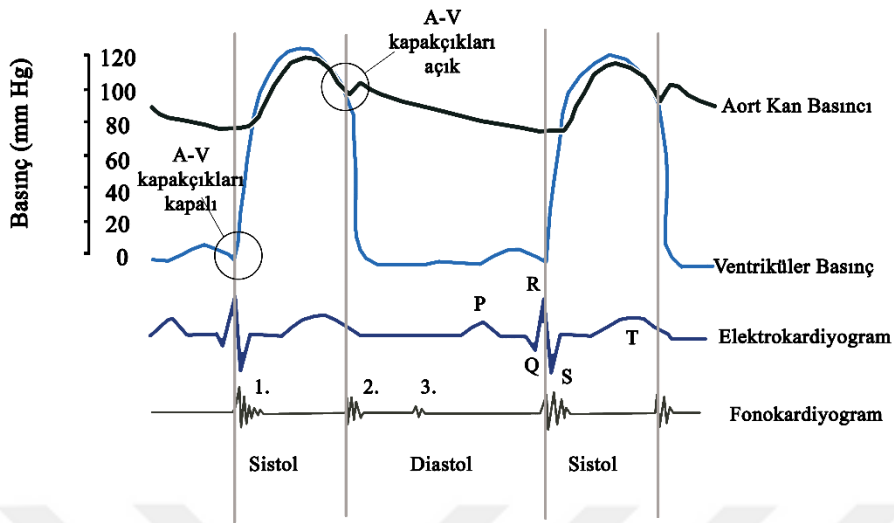
Stetoskopun göğüs duvarına temas ettirilmesiyle kalp sesleri dinlenebilir. Bu bir oskültasyon yöntemidir. Kalp dört bölüme ayrılmış ve adlandırılmıştır. Böylece her bölümden sesler dinlenerek, diğer bölümlerle karşılaştırılabilir. Sorunlu bölge bu sayede tespit edilmiş olur. Bölgeler kalp kapakçıklarından geçen kanın akış yönüne göre belirlenmiştir. Bölgeler baş harfleri ile gösterilmektedir (M-Mitral, T-Triküspid, P-Pulmoner ve A-Aort) (Şekil 2.4).



Şekil 2.4. Kalp dinleme odakları

Normal kalp sesleri

Normal bir kalp birinci kalp sesi (S1) ve ikinci kalp sesini (S2) oluşturur. S1, Triküspit ve mitral kapağın kapanma sesidir. Dolgun ve frekansı yüksek bir sestir. “lub” sesini çıkarır. S2 ise Aortik ve pulmonik kapağın kapanma sesidir. Kısa ve keskin bir sestir. “dub” sesini çıkarır. Bu sesler kalbin çalışması esnasında sistol ve diastol evrelerini gösterir. Kalp kaslarının kasılmasına sistol, gevşeyerek kalbin kanla dolmasına ise diastol denir. Kan pulmoner arter ve aorta pompalanır. AV kapakları kapandığında sistol başlar ve S1 sesi burada ortaya çıkar. AV kapakları açıldığında ise sistol biter ve diastol başlar(Li ve diğerleri, 2019). S2 sesi de burada oluşur. (Şekil 2.5)



Şekil 2.5. Kalpteki basınç, EKG ve PCG'nin zamanla değişimi


Anormal kalp sesleri

Anormal kalp sesleri, kalbin hastalık durumu hakkında bilgi veren önemli parametrelerdendir. Kalpte normal sesler olan S1 ve S2 den farklı seslerin ortaya çıkması kalpte bir sorun olduğu anlamı taşımaktadır. Birçok anormal ses oskültasyon işlemi sırasında algılanabilir. Bu seslerin çoğu anlamlandırılmış ve isimlendirilmiştir. Bunlardan üçüncü kalp sesi (S3) ve dördüncü kalp sesi (S4) hem normal hem de anormal seslerde duyulabilmektedir.

Mitral ve triküspit kapaklar açılınca karıncıklar kanla dolmaya başlar. Erken diastolde ventrikülün hızlı doluşu ile karıncık kaslarının titreşmesi S3'ü oluşturur. Gençlerde normal olarak duyulabilmektedir. Yaşlılarda ise miyokard fonksiyon bozukluğunun göstergesidir. Üçüncü sesin belirgin bir şekilde görülmesi bazı hastalıkların habercisi olabilmektedir. Bunlardan bazıları sol ventrikül yetersizliği veya volüm yüklenmesidir. Ayrıca S3, taşikardi ile birlikte, klinik konjestif kalp yetersizliğinin ve sağ ventriküler sistolik yetersizliğin en önemli dinleme bulgusudur. S3 ventriküler galo olarak da adlandırılır. S3, M ve T noktalarında daha iyi duyulur. S2' den 0.15 saniye sonra duyulur ve düşük perdeli tok bir sestir.

S4 ise kulak ile duyulamayan bir sestir. Atriyal galo olarakta adlandırılır. Ventriküllerin dolu olmasıyla basınç oluşmaktadır. Bu basıncın atriumlara atılması aşamasında kan dalgalanır ve S4 açığa çıkar (Kemaloğlu ve Kara, 2002). S1' den hemen önce duyular. M noktasından

dinlenebilir. Akut miyokard infarktüsünde S4 duyulabilir. Ayrıca uzun süre hipertansiyonu olan bazı hastalarda da bu ses duyulur. S1, S2, S3 ve S4 ün kalp sesi döngüsünde oluşabilecek görüntüsü Şekil 2.6’te verilmiştir (aksın ve Ergün, 2009).

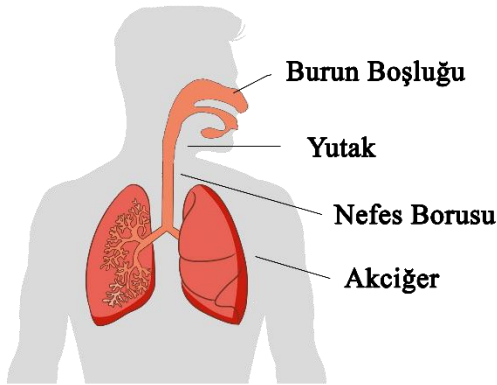


Şekil 2.6. Birinci, ikinci, üçüncü ve dördüncü kalp sesleri (Güraksm, 2009)

Anormal seslerden bir diğeri ise üfürümlerdir. Üfürüm, kalpteki kanın normal akımında bozulmaya bağlı oluşan ses titreşimlerinin göğüs duvarına yansması olarak adlandırılır. Bu bozulmaya kalp kapaklarındaki ve ana damarlardaki darlıklar, kalpteki delikler yol açabilir (Memorial, 2023). Bir stetoskop kullanılarak duyulabilmektedir. Üfürümler, yaklaşık 600 Hz'e kadar olan frekans bandında duyulabilir. Bir kalp üfürümünün yoğunluğu, kanın aktığı deliğin büyüklüğüne, delik boyunca basınç gradyanına ve alan boyunca akan kan hacmine bağlıdır. Kalp üfürümleri, sistolik, diyastolik veya sürekli (hem sistol hem de diyastolü kapsayan) görüldükleri kalp döngüsünün bölgesi ile tanımlanır. Bu nedenle, bir üfürüm yalnızca hem S1 hem de S2 sesleri doğru tanımlandıktan sonra sınıflandırılabilir. Üfürümler genellikle patolojinin bir göstergesi olsa da, aynı zamanda “masum” ve fizyolojik olarak normal olabilirler. Çeşitli üfürümlerin ve etiyolojilerinin bir açıklaması takip eder (Springer, 2015).

2.3. Akciğerlerin Yapısı ve Anatomisi

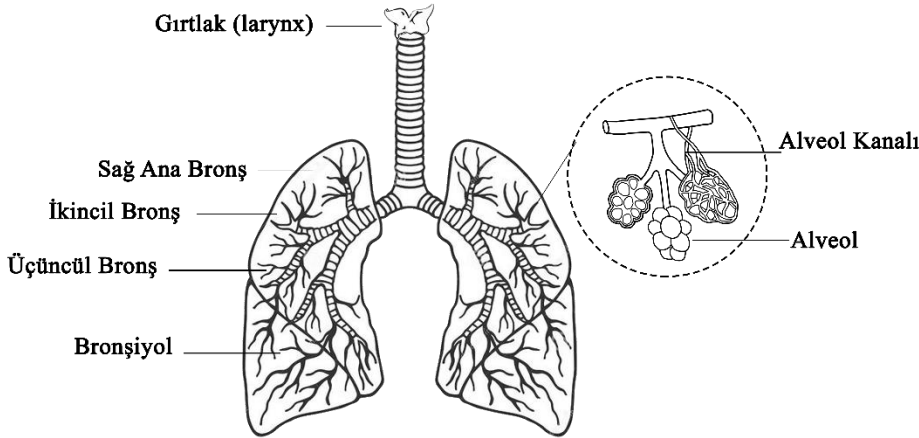
Solunum sistemi, hücrelere gerekli oksijeni sağlayan sistemdir. Bu sistemde temel organ akciğerlerdir. Nefes aldığımızda vücudumuza giren hava akciğerlerde temizlenir. Kirli hava tekrar dışarı atılırken oksijen vücutta ihtiyacı olan organlara dağıtılır. Solunum sisteminde yer alan organlar Şekil 2.7’de gösterilmiştir.



Şekil 2.7. Solunum sisteminde yer alan organlar

Vücudumuzda iki adet akciğer bulunur. Bunlardan biri sağda diğeri ise soldadır. Esnek ve süngerimsi bir yapıya sahiptirler. Akciğerler göğüs boşluğunda yer alırlar. Plevra zarı ile sarılmışlardır ve göğüs kafesi sayesinde korunurlar. Sağ akciğer sol akciğere göre daha yukarıdadır. Bunun sebebi sağ akciğerin altında yer alan karaciğerin yukarı doğru itmesidir. Sağ akciğerde üç lob, sol akciğerde iki lob bulunur. Loblar da segmentlere ayrılmıştır. Sağda on solda on olmak üzere toplam yirmi tane segment bulunur. Herbirinin bronşu, veni ve arteri vardır. Kalp bulunduğundan dolayı sağ akciğer sol akciğerden daha büyüktür.

Akciğerler, bronşlar, bronşçuklar, terminal bronşçuklar, alveal kanalları ve alveoller şeklinde dallanmıştır (Şekil 2.8). Bu dallanma ile ağaç görüntüsü oluşturmaktadır (Uysal, 2014). Bronşlar soluk borusunun alt ucu birinci göğüs kemiği civarında, biri sağ diğeri sol akciğerin içine doğru uzanan 2 kola ayrılır. Bronşlar defalarca dallanarak bronşçukları meydana getirir. Bronşçuklar da dallanarak çok küçük hava cepleriyle sonlanan alveol kanallarını meydana getirir.

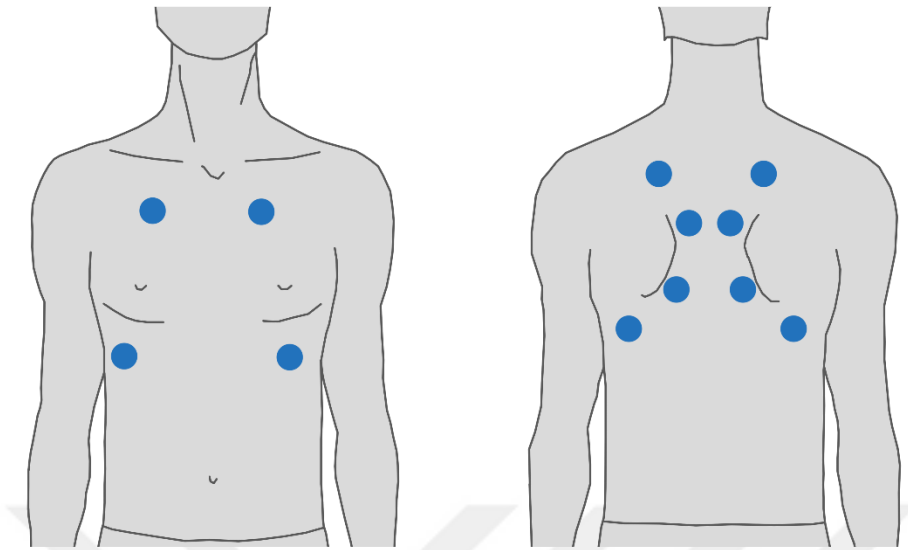


Şekil 2.8. Akciğerlerin önden görünümü

2.3.1. Akciğer sesleri

Solunum aktiviteleri, sağlık durumunu gösteren önemli bir belirtidir. Bronşit, zatürre, koronavirüs gibi hastalıklar solunum bozukluklarına sebep olur. Bu gibi hastalıkların teşhisinde stetoskop desteği ile akciğer oskültasyonu kullanılır (George ve diğerleri, 2021). Akciğer sesleri; göğüs duvarı üzerinde veya göğüs içinde duyulan veya tespit edilen tüm solunum seslerini, bu konumda tespit edilen nefes sesleri ve tesadüfi sesler dahil olmak üzere çeşitli sesleri kapsar (Reichert ve diğerleri, 2008). Oskültasyon yapılırken stetoskopun diyafram kısmı cilt ile tamamen temas durumunda olmalıdır. Akciğerin dinlendiği noktalar için en az bir inspiriyum ve ekspiriyum dahil edilmelidir ve bu hizalama simetrik olmalıdır (Aydemir, 2011). Doğru bir tıbbi tanı için normal solunum sesleri ile anormal sesler (çatırtı, hırıltı gibi) arasındaki ayrım önemlidir. Solunum sesleri, akciğerlerin ve solunum yolu tıkanıklığının fizyolojisi ve patolojileri hakkında önemli bilgiler içermektedir.

Solunum sesi oskültasyonu için birçok farklı nokta bulunmaktadır. Akciğerlerin herbir lobundan alınacak sesler o lobun durumu hakkında bilgi vermektedir. Akciğerlerin üst, orta ve alt loblarını kapsayacak şekilde dinleme yapılmalıdır. Akciğerler en az 8 noktadan dinlenebilir. Göğüs kemiği temel alınarak her iki taraftan karşılıklı olmalıdır. Şekil 2.9' da akciğer dinleme odakları gösterilmiştir. Burada L harfi sol, R harfi sağ demektir. Bölgeler, posterior-üst akciğer (L1-R1), posterior-orta akciğer (L2-R2), posteriorlower akciğer (L3-R3), posterior-kostofrenik açılı akciğer (L5-R5) ve anterior-alt akciğer (L6-R6) olarak adlandırılmaktadır (Altan ve diğerleri, 2017).



Şekil 2.9. Akciğer dinleme odakları

Normal akciğer sesleri

Normal akciğer sesleri, sağlıklı insanların göğüs duvarı üzerinde tespit edilen solunumdan kaynaklanan sesler olarak tanımlanır. İspirasyon (nefes alma) sırasında sessiz, düşük frekanslı bir ses ile karakterize edilirler ve ekspirasyon (nefes verme) sırasında neredeyse hiç duyulmazlar. Normal solunum sesleri duyuldukları yerlere 4' e ayrılır. Bunlar veziküler, bronkoveziküler, bronşial ve trakeal seslerdir.

Veziküler sesler, havanın normal akciğer dokusundan geçerken oluşturduğu seslere denir. Titreşim sıklığı 100-1000 arasında değişmektedir. Akciğerlerin etrafındaki hemen hemen bütün bölgelerden duyulabilirler. Bu sesler inspirasyonda, ekspirasyona kıyasla daha kuvvetli işitilir. İspirasyon evresi Ekspirasyona göre daha uzun sürmektedir. frekansı ve yoğunluğu bronşial seslere göre daha azdır (Polat, 2006) (Emeksiz ve Bostancı, 2018).

Bronkoveziküler sesler, bronşial ve veziküler seslerin karışımı olarak duyulmaktadır. Bronşial sesler kadar güçlü değildir. Frekansı bronşial seslere göre daha düşüktür. İspiryum ve ekspiryumda eşit olarak duyulur. Bu sesler veziküler sesler gibi her bölgeden duyulmazlar. Normalde göğüs üzerinden birinci ve ikinci interkostal boşlukları yakınında ve sırtta kürek kemiği arasından duyulabilir ve her iki bölgede sağ ve soldan daha iyi bir şekilde işitilirler (Polat, 2006) (Emeksiz ve Bostancı, 2018).

Bronşial sesler, ana bronşlardaki titreşimden kaynaklanan seslerdir. Bu seslere soluk borusu sesleri de denmektedir. Manibrium sterni üzerinde duyulur. İnspiryumda ekspiryuma göre daha şiddetli ve daha uzun olarak iştilir. Bu sesin akciğer periferinde duyulması patolojik olarak tanımlanır.

Trakeal sesler ise farenks, glottik ve subglottik alanlardaki türbülant akımdan kaynaklanmaktadır. 2 farklı bölgeden duyulur. Bunlar; Ekstratorasik trakea üzeri ve sternal çentiktir. En şiddetli ve yüksek perdeli sestir. 100-5000 Hz frekans aralığına sahiptir. Hem inspiyum hemde expiryumda işitebilmektedir (Emeksiz ve Bostancı, 2018).

Ek akciğer sesleri

Normalde olmaması gereken bazı patofizyolojik durumlar sonrasında oluşan seslerdir. Ek sesler sürekli ek sesler ve kesintili ek sesler şeklinde sınıflandırılır. Sürekli sesler Ronküs ve Hırıltıdan oluşurken, kesintili sesler ince çırtı ve kaba çırtıdan oluşmaktadır.

Ronküs, süresi 100 ms'den uzun ve frekansı 300 Hz'den küçük seslerdir (Reichert ve diğerleri, 2008). Akciğerdeki hava yollarının daralmasından kaynaklanır. Hem inspirasyon sırasında hem de ekspirasyon sırasında duyulabilir. Müzikal ve kaba seslerdir. Sekresyona bağlı ronküsler öksürükle kaybolurlar. Yaygın olarak görüldüğü hastalıklar Astım ve KOAH' tır.

Hırıltı, stetoskopsuz bile ekspirasyon sırasında duyulabilen ısıklık şeklinde seslerdir. Hırıltı esasen tek bir frekans içeriyorsa, hırıltıya monofonik denir. Birkaç frekans içeriyorsa, buna polifonik hırıltı denir. Genellikle frekansı 100 Hz' in üzerinde ve süresi 100 ms' den fazladır (Reichert ve diğerleri, 2008). Hırıltıya genel olarak astım hastalarında karşılaşılmaktadır. Ayrıca konjestif kalp yetmezliği, kronik bronşit ve KOAH rahatsızlıklarının da sebep olduğu solunum sesleridir.

Çatırtılar ise belki de klinik tanı için en yararlı olanlardır. İnspirasyon ve ekspirasyon sırasında çok daha sık duyulan minyatür patlamalardır. 100–2000 Hz arasında frekans bandına görülürler. Süreleri 20 ms den daha kısa olan seslerdir. Bir çatırtı, ince (kısa süreli) veya kaba (uzun süreli) olarak toplam süresi ile karakterize edilebilir. Akciğer seslerinde çatırtı oluşumu genellikle pulmoner doku veya hava yollarındaki patolojik bir süreci yansıtır. İnce çırtırtılar kısa zaman aralıkları ile oluşurlar. Havanın küçük hava yolları ve alveollerden geçerken

çıkardığı yüksek perdeli, düşük yoğunluklu seslerdir. Akciğer ödemi, pnömoninin konjesyon ve rezolüsyon döneminde duyulabilir. Hatta uzun süre sırt üstü yatağa bağımlı hastalarda da duyulur. Kaba çıtırtılar ise havanın bronşiyol, bronş ve trakeadan geçerken çıkardığı düşük perdeli, yüksek yoğunluklu, uzun süreli seslerdir. Erken inspiryumda başlar orta inspiryuma kadar devam eder. Hatta ekspiryumda bile duyulabilir. Kaba çıtırtıların duyulduğu hastalıklar arasında KOAH, bronşiektazi, bronkopnömoni, konjesif kalp yetmezliği, pulmoner ödem yer alır (Emeksiz ve Bostancı, 2018). Solunum seslerinin klinik özelliklerine dair bilgiler Çizelge 2.1’de gösterilmiştir(Bohadana ve diğerleri, 2014 kaynağından uyarlanmıştır.).

Çizelge 2.1. Solunum seslerinin klinik özellikleri ve korelasyonları

Solunum Sesi	Klinik Özellikleri	Klinik Korelasyon
Normal trakeal ses	Yankı yapan ve müzikal olmayan bir sestir, solunum döngüsünün her iki aşamasında da net bir şekilde duyulur.	Üst solunum yolu açıklığını gösteren intrapulmoner sesleri taşır; üst hava yolu açıklığı değiştirilirse rahatsız edici olabilir (örneğin daha gürültülü veya hatta müzikal hale gelebilir); uyku apnesini izlemek için kullanılır, bronşiyal solunumun iyi bir modeli olarak hizmet eder
Normal akciğer sesi	Yumuşak, müzikal olmayan bir sestir. Yalnızca nefes alma ve nefes vermede duyulur	Ses oluşumunu (örn. hipoventilasyon, hava yolu daralması) veya ses iletimini (örn. akciğer yıkımı, plevral efüzyon, pnömotoraks) etkileyen faktörler tarafından azaltılır.
Bronşiyal solunum	Yumuşak, müzikal olmayan bir sestir. Solunum döngüsünün her iki fazında da duyulur.	Konsolide akciğer dokusu (örn., pnömoni) veya fibrozis ile çevrili açık hava yolunu gösterir.
Kaba Hırıltı	Müzikal, tiz, üst solunum yollarında veya steteskop olmadan uzaktan duyulabilir.	Üst hava yolu tıkanıklığını gösterir.
Hırıltı	Müzikal, yüksek perdeli bir sestir. Nefes almada, nefes vermede veya her iki aşamada da duyulur.	Lokalize olduğunda (örneğin yabancı cisim, tümör) hava yolunun daralması veya tıkanması olduğunu düşündürür.
Ronkus	Müzikal, tiz, horlamaya benzer; hırıltıdan daha düşük perdededir. Nefes almada, nefes vermede veya her ikisinde de duyulur.	Akışkan filmlerinin yırtılması ve anormal hava yolu çökebilirliği ile ilişkilidir; genellikle öksürükle iyileşir.

Çizelge 2.1. (Devam) Solunum seslerinin klinik özellikleri ve korelasyonları (Bohadana ve diğerleri, 2014 kaynağından uyarlanmıştır.)

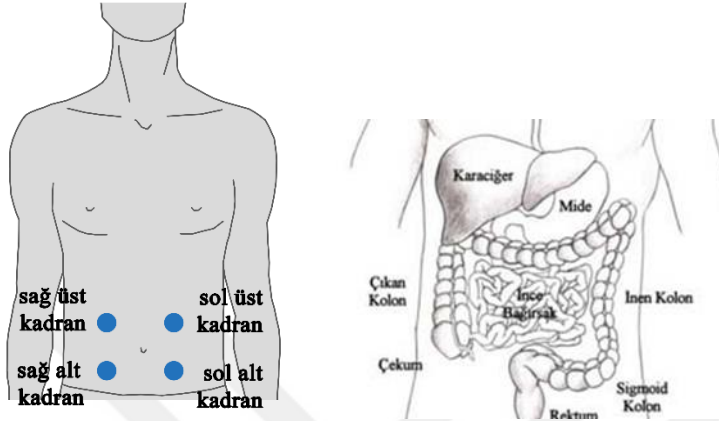
İnce Çatırtı	Müzikal olmayan, kısa, anlık yükselen bir sestir. Orta-geç nefes almada bazen de nefes vermede duyulur. Öksürükten etkilenmez.	Salgılarla ilgisi olmayan; çeşitli hastalıklarla ilişkili (örneğin, interstisyel akciğer fibrozu, konjestif kalp yetmezliği, pnömoni); hastalığın en erken belirtisi olabilir.
Kaba Çatırtı	Müzikal olmayan, kısa, anlık yükselen seslerdir. Erken nefes almada ve nefes verme boyunca duyulur. Öksürükten etkilenir.	Aralıklı hava yolu açıklığını gösterir, sekresyonlarla ilgili olabilir (örn. kronik bronşitte)
Plevral Sürtünme Sesi	Müzikal olmayan, anlık patlayan, genellikle iki fazlı seslerdir. Tipik olarak bazal bölgelerde duyulur.	Plevral inflamasyon veya plevral tümörlerle ilişkili olabilir.
Ciyaklama	Kısa hırıltıların müzikal seslerle birleşmiş hali ya da öncesinde hırıltıların eşlik ettiği karışık sestir.	Distal hava yollarını etkileyen durumlarla ilişkilidir.

2.4. Bağırsak Yapısı ve Anatomisi

Bağırsaklar, mideden sonra gelen sindirim organlarıdır. İnce ve kalın bağırsak olarak sindirim sistemini tamamlar (Haspolat ve diğerleri, 2016). Bağırsak sesleri, kaydedilen, ölçülen ve hatta analiz edilen ve bu şekilde de ilişkili fenomenlerle bağlantı kurulabilen fiziksel uyarılardır (Watson ve Knox, 1967). İlk olarak Cannon, abdominal oskültasyon ile gastroenterolojik hastalıkların ilişkisini önermiştir (Cannon, 1905). Bağırsak seslerinin oskültasyonunun, karın bölgesinin değerlendirilmesi ve hastalık teşhisinde yalnızca 30 saniyelik bir oskültasyonda bile yararlı bir yöntem olduğu kanıtlanmıştır (Gu ve diğerleri, 2010).

Bağırsaklar sürekli olarak aktif çalışmaktadır, bu sebeple guruldama sesleri çıkar. Ancak bu seslerin normal sesler olup olmadığını belirlemek öznel bir yorum olarak kalmaktadır (Baid, 2009). Bağırsak sesleri sindirim süreçleri hakkında bilgi verse de bu seslerin özgünlüğü yorumunu zorlaştırmaktadır. Bağırsak sesleri düzensiz aralıklarda görünebilir, farklı karın bölgelerinden yayılabilir. Bu sebeple hastaya bağlıdır ve uzun süreli analiz gerektirmektedir (Ranta ve diğerleri, 2004). Öte yandan sağlık personelinin bağırsak sesleri için kullandıkları oskültasyon tekniklerinin uygulanma şekilleri ve karın bölgesinin fiziksel değerlendirilmesi ile bu olguların literatürdeki tarifleri arasında büyük farklar bulunmaktadır (Baid, 2009). Bu

sebeple gelişen teknolojinin yardımı gerekmektedir. Ayrıca bağırsak aktivitesinin takibinde kullanılacak teknolojilerle çevresel gürültünün ayrışması ve hastalarda sürekli gözlem yapılabilmesi mümkün kılınmaktadır (Öztaş ve diğerleri, 2015). Batın bölgesi ve bu bölgeye ait oskültasyon noktaları Şekil 2.10'da verilmiştir.



Şekil 2.10. Batın Bölgesi ve Dinleme Noktaları

En iyi oskültasyon işlemi yemekler arası yapılır. Sağlık çalışanı karnı, bağırsak hareketleri ve vasküler sesleri dinlemek için oskulte eder. Stetoskopun diyaframı kadrana yerleştirilir. Normalde hava ve sıvı bağırsakta hareket eder. Her kadranda 5-35 s aralıklarla gümbürtü ve fokurtu oluşur ve bu sesler düzenli değildir. Dakikada 4-6 defa tekrarlayan bağırsak sesleri duyulur.

Bağırsak aktivitelerinin tespiti, hastalarda oluşabilen pankreas iltihabı, anastomoz kaçağı gibi komplikasyonların tespitini sağlamaktadır (Windsor ve diğerleri, 1998). Literatürde bağırsak seslerinin normal sınırlarının belirlenmesinde çeşitli önermeler vardır. Bunlardan en geçerli olanı, bağırsak seslerinin hiç olmamasının anormallik teşkil etmesidir. Bu tespit, bağırsak obstrüksiyonu, bağırsak iskemisi, paralitik ileus ve peritonit gibi hastalıkların belirtisi olabilmektedir (Jarvis, 2008). Bağırsaklardaki yalnızca anormal seslerin değil, aktif çalışıp çalışmama durumunun tespiti de önemlidir. Örneğin hastanede kalan bir hastanın aktif bağırsak hareketinin tespiti onun beslenme sürecinin başlatılabileceğine, dolaylı yoldan ise hastanede kalma süresinin kısılacığına işaretir (Schroeder, 1991).

2.5. Literatür İncelemesi

Solunum sesleri üzerine yapılan çalışmalar veri setlerinin fazlaşması ile artış göstermiştir. Bu alanda birçok çalışma bulunmaktadır. Literatüre bakıldığında donanımsal alanda farklı çalışmalar bulunmaktadır. Düzgün kalp seslerinin dinlenmesi üzerine bir cihaz geliştirmiş ve dinlediği seslere filtre uyguladığı bir sistem tasarımı yapmıştır (Düzgün, 2007). Uysal hazırladığı tezde vücut seslerinin dinlendiği bir gömülü bilgisayar tasarlamıştır (Uysal, 2014). Çınar ise yaptığı tez çalışmasında solunum ve kalp seslerinin dinlenmesi ve işlenmesi üzerine bir çalışma yapmıştır (Çınar, 2019). Ovacık kalp seslerinin dinlenmesi ve depolanması üzerine geliştirdiği sistemde farklı sensörlerin (piezoelektrik sensör, ivme sensör ve mikrofon) etkisini incelemiştir. (Ovacık, 2014). Karaseker'in yaptığı çalışmada ise farklı filtreler kullanılarak S1 ve S2 sinyallerinin ayrıştırılması üzerine bir çalışma yapılmıştır (Karaseker, 2009). Donanımsal çalışmaların yanı sıra bazı çalışmalarda Litmann gibi elektronik stetoskoplar ile veri setleri toplanmış ve veriler üzerinde araştırmalar yapılmıştır. Liu ve arkadaşları solunum yolu hastalıklarıyla ilgili adventif solunum seslerinden hırıltı ve çattırtıyı tespit etmek ve tanımlamak için çalışma yapmıştır. Uluslararası Biyomedikal ve Sağlık Bilişimi Konferansı (ICBHI) tarafından sağlanan ve 126 denekten oluşan kamuya açık veri tabanı ve 222 denekten oluşan kaydedilmiş pediatrik oskültasyon verileri olmak üzere toplam 2 adet veri seti kullanılmıştır. Veri setini karışık olarak kullanarak yapılan eğitim sonucunda eğitim başarımı %96, validation başarımı %76 olarak sonuçlanmıştır. Test başarımı ise %61.02 olarak elde edilmiştir (Liu ve diğerleri, 2019). Jayalakshmy ve arkadaşları KOAH varlığı ve hırıltı, çattırtı ve rhonchi gibi anormal nefes sesleri çok sınıflı sınıflandırıcı kullanılarak sınıflandırılmıştır. Deneysel ve sınıflandırma için bu çalışmada toplam 596 akciğer ses sinyali ele alınmıştır. Doğrusal spektrumdan spektral tanımlayıcı özellikler ve Mel spektrumundan MFCC çıkarılmıştır. Sonuçlara bakıldığında çok sınıflı sınıflandırıcıya (Karar ağacı) sahip ESA'nin, 0.15'ten daha az minimum kayıpla ve %96.7 doğruluk sağlayarak daha iyi performans gösterdiğini kanıtlamıştır (Jayalakshmy ve diğerleri, 2020). Messner ve arkadaşları çok kanallı akciğer ses analizine bütüncül bir yaklaşım sunmuştur. Akciğer ses kayıtlarından spektrogram özellikleri çıkartılmış ve sağlıklı ve patolojik olmak üzere iki sınıflandırma için farklı derin sinir ağı mimarilerini karşılaştırmıştır. ConvBiGRNN, %92 F-skoru ile diğer mimarilerden daha iyi performans göstermiştir (Messner ve diğerleri, 2020). Rizal ve arkadaşları 5 sınıftan oluşan akciğer ses verilerinin 7 entropi kombinasyonunu öznelik olarak belirlemiştir. Çok katmanlı algılayıcılar kullanılarak %94.95 başarımla elde edilmiştir (Rizal ve diğerleri, 2017). Balli ve Kutlu yaptıkları çalışmada 103 kişiden oluşan veri seti kullanmıştır. 210x210'lük

matrise dönüştürülen verilerin transfer learning ile öz nitelikleri çıkarılmıştır. ANN, KNN, SVM, DT yöntemlerinin denendiği uygulamada eğitim sonucu ANN'de %96, KNN'de %89, SVM'de %96 ve DT'de %100 başarımlar elde edilmiştir. Test sonuçlarına bakıldığında ise ANN'de %87, KNN'de %80, SVM'de %85 ve DT'de %76 olduğu görülmüştür (Balli ve Kutlu, 2020). Balli ve Kutlu'nun solunum seslerinin bölgelerinin tespiti için yaptığı çalışmada MFKK ile öz nitelik çıkarımı yapılmış ve bu öz nitelikler ESA ile eğitilmiştir. Eğitim sonucunda %98 başarımlar elde edilirken %85 validation başarımları elde edilmiştir (Balli ve Kutlu, 2021). Arslan ve Yıldız'ın yaptığı çalışma, kalp üfürümlerini teşhis etmek ve kategorize etmek için Mel Frekanslı Keprstral Katsayısı (MFKK), BaumWelch parametre yeniden tahmini ve Gizli Markov Modelinin bir kombinasyonu kullanmıştır. Sınıflandırma deneyleri, 6 farklı üfürüm türünden oluşan 84 yüksek kaliteli kalp sesi verisi ile gerçekleştirilmiştir. HMM'nin 5 durumu ve çerçeve boyutu 25ms olduğunda ortalama % 98.8 doğru sınıflandırma oranı elde edilmiştir (Arslan ve Yıldız, 2018). Chauhan ve arkadaşları öz nitelik çıkarmak ve sinyal sınıflandırması için Gizli Markov Modeli (GMM) ve MFKK kullanılmıştır. Bu sistem gerçek ve simüle edilmiş, normal ve anormal alanların 1381 veri setine uygulanmıştır. Sınıflandırma için bilinen test verilerini kullanan Tanıma Doğru Yüzdesi (RCP), eğitilmiş modelleri değerlendirmek için kullanılmıştır. Normal ve anormal kalp sesleri için sınıflandırma oranları olasılıksal karşılaştırma yaklaşımıyla sürekli üfürümlerde %95.7, sistolik üfürümlerde %96.25 ve diyastolik üfürümlerde %90 olarak bulunmuştur (Chauhan ve diğerleri, 2008). Maglogiannis ve arkadaşları hem sağlıklı tıbbi vakalardan hem de en yaygın dört kalp kapağı hastalığından (aort darlığı (AS), aort yetersizliği (AR), mitral darlığı (MS) ve mitral yetersizliği (MR)) muzdarip vakalardan gelen 198 kalp ses sinyalinin temsili bir küresel veri setinde uygulamıştır. Tüm sınıflandırma aşamalarında, Gauss ve üstel radyal temel fonksiyonlara sahip SVM sınıflandırıcıları oldukça iyi bir performans göstermiştir. Sistolik gevşeme durumunda toplam doğruluk %76,48 iken diyastolik hastalıklarda %77,94'tür (Maglogiannis ve diğerleri, 2009). Bağırsak sesleri ile ilgili çalışmalara bakıldığında ise Sitaula ve arkadaşları spesifik olarak, peristalsis ve peristalsis olmayan sesleri sınıflandırmak için bir Konvolüsyonel Sinir Ağı önermiştir. Sınıflandırma daha sonra bir Laplace Gizli Yarı Markov Modeli kullanılarak optimize edilmiştir. 49 yenidoğan bebeğin karın sesleri üzerinde doğrulanmıştır. Sonuçlar, yöntemin bağırsak seslerini doğruluk ve eğri altındaki alan (AUC) skoru sırasıyla %89,81 ve %83,96 ile etkili bir şekilde tespit edebilmiştir (Sitaula ve diğerleri, 2022). Zhao ve arkadaşları spesifik olarak önerilen tanıyıcı, MFKK'lar çerçeve çerçeve hesaplayarak ilk olarak her bir tek boyutlu parçayı iki boyutlu bir spektrograma dönüştürür ve ardından parçanın kategorisini anlamak için spektrogramı bir ESA'den geçirir. ESA tabanlı bağırsak sesi tanıyıcısının

doğrulamak için, 955 bağırsak sesi-mevcut segment ve 725 bağırsak sesi-yok segment içeren 28 dakikalık bir bağırsak seslerinden oluşan veri seti yapılmıştır. Veri setindeki deneysel sonuçlar, tanıyıcının "denekler arası değil" ve "denekler arası" doğrulama için sırasıyla %91,25 ve %90,83 ortalama doğruluklara ulaştığını göstermektedir (Zhao ve diğerleri, 2020). Liu ve arkadaşları, MFKK özelliklerini kullanan LSTM sinir ağı tarafından bağırsak sesini (BS) tespit etmek için bir yöntem önermiştir. Büyük miktarda bağırsak sesi verisi kaydedilmiştir. Yöntem farklı durumlarda test edilmiştir. Test verilerinin kayıt ortamı eğitim verilerinininkiyle aynı olduğunda, bu yöntem %90,92 hassasiyete ve %92,56 toplam doğruluğa ulaşabilir. Kayıt ortamı farklı olduğunda hassasiyet etkilenmiş ve %62,1'e düşmüştür, ancak özgüllük yine de %96,2'de tutulmuştur ve toplam doğruluk %94,2 olarak elde edilmiştir (Liu ve diğerleri, 2018). Qiau ve arkadaşları, bağırsak sesleri için giyilebilir bir cihaz tasarımı yapmışlardır. Elde edilen bağırsak seslerini diğer seslerden ayırmada %85,7 başarımla elde etmişlerdir (Qiau ve diğerleri, 2021).

2.6. Tezin Amacı

Biyomedikal cihaz teknolojilerinin gelişmesi ile bu sektörde kullanılan donanımların niteliklerinde artış görülmeye başlanmıştır. İlk başlarda stetoskopun diyaframından alınan sesler direkt dinleyici tarafından dinlenmesi iken, elektronik stetoskopların geliştirilmesi ile alınan sesler filtreli ve daha anlaşılır bir şekilde dinleyiciye iletimi sağlanmıştır.

Stetoskop ile alınan veriler; stetoskopun göğüs, sırt ve karn üzerindeki değişen pozisyonuna göre veri toplama sırasında istenmeyen sürtünmelere ve bundan kaynaklanan insan hatalarına sebep olur. Özellikle evde kullanılan stetoskopların elde ettiği sonuçlar ya da deneyim eksikliği olan sağlık personelinin elde ettiği sonuçlar göz önünde bulundurulduğunda insan hatası önemli bir endişe kaynağıdır (Lee ve diğerleri, 2022).

Düşük ve orta gelirli ülkelerde sağlık hizmetlerine erişim ve mevcut cihazların satın alınabilirliği problemlidir. Bu yüzden bu ülkelerdeki hastaların hastalıklarının takibi zorlaşmaktadır (Arts ve diğerleri, 2020). Hastalıkların teşhisi için veri toplayan sensör cihazları, hastaların evde ya da hastanede uzun süreli denetlenebilmesine ve izlenebilmesine imkan tanır. Bu imkan sağlık erişimi sınırlı olan ülkeler için yararlı bir çözüm olacaktır (Earis ve Cheetham, 2000).


Karn bölgesinden ameliyat geçiren hastalarda kalp, akciğer ve bağırsak aktivitesinin gerçek

zamanlı tespiti hastanın iyileşme süreci için büyük önem taşımaktadır. Bu amaçla oskültasyon seslerinden anlık olarak dinlenmesi ve tespit yapılması oldukça önemlidir.

Tüm bu durumlar değerlendirildiğinde bu çalışmada herkesin rahatlıkla kullanabilecekleri giyilebilir bir donanım geliştirilmesi amaçlanmıştır. Ayrıca donanım ile anlık olarak ses sinyallerinin dinlenmesi sağlanırken, alınan ses sinyalleri ile sağlık çalışanlarının analiz yapabilecekleri, sonradan dinleyebilecekleri, eğitimlerde veya farklı uzmanlardan görüş alabilecekleri bir sistem geliştirilecektir. Vücut sesleri için giyilebilir oskültasyon donanımı ve son kullanıcı için kullanabilecekleri arayüze sahip bir sistem tasarlanmış olacaktır. Çok katmanlı hiyerarşik bir sınıflandırma sistemine sahip olacak olan yapay zeka destekli bu sistem, vücut seslerini bölgelerine göre sınıflandırabilecek ve ardından normal (sağlıklı) ve anormal olarak ayırabilecek ve son aşamada ise anormal olarak belirlenen kayıtları hastalık türünün belirlenmesi yapılabilecektir. Bu sayede sağlık çalışanları tarafından yapılacak teşhis için bir karar destek sistemi üretilmiş olacaktır. Ek olarak etiketlenmemiş veya yanlış etiketlenmiş verilerin analizi yapılabilecektir. Geliştirilecek giyilebilir stetoskoplar çoklu bölgeden anlık dinleme veya ses kaydı alma sağlanarak sonradan dinleme imkanı sunacaktır. Böylece sağlık bölümlerinde öğrencilerin eğitimlerinde, tecrübesiz yeni mezun sağlık personellerinin pratiklerinde kullanabilecekleri bir araç olacaktır.


3. MATERYAL VE METOT

Oskültasyon yüzyıllardır yapılmakta olan ve hastalık teşhisinde kullanılan en temel yöntemlerdendir. Oskültasyon işleminde stetoskop kullanılır. Kolay taşınabilir ve hafif olması oskültasyon ile teşhis yapacaklar için stetoskobu en uygun cihaz konumuna getirmektedir. Diyafram, tüp ve kulaklıktan oluşan mekanik stetoskoplar diyaframdan alınan ses sinyallerini kulağa iletmektedir. En çok kullanılan cihazlardan biri olmasına rağmen birçok hastalık teşhisi sadece uzmanlar tarafından anlaşılmaktadır. Bu alanda yeni çalışan kişilerin doğru bir analiz yapabilmesi durumu uzmanlara göre daha azdır. Bu eksikliğini gidermek için elektronik stetoskoplar üretilmiştir. Küçük frekanslı ses sinyallerini yükselterek ve gürültüleri filtreleyerek daha doğru analiz yapılmasını sağlamaktadır. Ayrıca sesleri kaydedebilmesi dijital ortamda farklı filtrelerin uygulanmasına olanak tanımaktadır. Dinleme noktaları ve örnek kayıt sinyalleri Şekil 3.1’de verilmiştir.



Şekil 3.1. Dinleme noktalarında oluşabilecek örnek sinyaller

Bu amaçlar dahilinde genel yapısı Şekil 3.2 de gösterilmiş olan donanım ve karar destek sistemi geliştirilmesi düşünülmüştür. Burada giyilebilir bir donanım geliştirilecek ve bu donanım WiFi ile bilgisayar veya uzak bilgisayara bağlanma imkanı sağlayacaktır. Kullanıcıların online olarak veya mobilden bu donanımdan kaydedilen verileri dinleme ve değerlendirme imkanı verilecektir.



Şekil 3.2. Sistem Genel Şeması

3.1. Verilerin Toplanması

Çalışmada oluşturulan hibrit sistemi için 5 farklı veri seti kullanılmıştır. Bölgesel teşhis için 12 kişiden ses verileri alınmıştır. Veri seti, 12 akciğer, 4 kalp ve 4 batın olmak üzere toplamda 20 farklı oluşmaktadır. Herbir bölgeden alınan seslerin süresi 20s'dir. Kayıtlar 3M Littmann marka stetoskop ile yapılmıştır. Kayıtların örnekleme frekansı 4000'dir.

ICBHI veri seti, iki farklı ülkedeki iki araştırma ekibi tarafından birkaç yıl boyunca bağımsız olarak toplanan ses örneklerini içermektedir. Veri tabanı 126 denekten 920 ses örneğinde 6898 solunum döngüsü içeren toplam 5,5 saatlik kayıttan oluşmaktadır ve 1 astım, 7 bronşektazi, 6 bronşiyolit, 64 KOAH, 2 alt solunum yolu enfeksiyonu (ASYE), 6 zatürre (Pnimonisi), 14 üst solunum yolu enfeksiyonu (ÜSYE) hastalığına sahip kişilerin yanı sıra 26 sağlıklı kişileri içermektedir. Kayıtlar farklı ekipmanlar (AKG C417L Mikrofon (AKGC417L), 3M Littmann Classic II SE Stetoskop (LittC2SE), 3M Littmann 3200 Elektronik Stetoskop (Litt3200), WelchAllyn Meditron Master Elite Elektronik Stetoskop (Meditron)) kullanılarak toplanmıştır ve süreleri 10 ile 90s arasında değişmektedir. Toplamda 1840 ses kaydı bulunmaktadır. Sesler 7 farklı lokasyondan (Nefes borusu, ön sol (arterior left), ön sağ (arterior right), arka sol (posterior left), arka sağ (posterior right), yanal sol (lateral left), yanal sağ (lateral right)) alınmıştır (Rocha ve diğerleri, 2019).

Multimedya solunum veritabanı, sağlıklı, KOAH ve astım verilerinden oluşmaktadır. KOAH verileri çok düşük, düşük, orta, şiddetli ve çok şiddetli olmak üzere 5 farklı seviyeden oluşmaktadır. Kayıt süreleri en az 17 s'dir. 12 akciğer ve 4 kalp bölgesinden ses verileri alınmıştır (Altan ve diğerleri, 2017).

Bu çalışmada, St. Luke's Episcopal Hastanesi'nden Robert J.ha tarafından oluşturulan açık kaynaklı kalp sesleri veritabanından alınmıştır. Veri tabanı 14 aort darlığı (AS), 8 aort yetersizliği (AR), 6 mitral darlığı (MS), 12 mitral yetersizliği (MR), 4 Pulmoner Kapak Darlığı (PS) ve 2 Triküspit Yetersizliğinden (TR) oluşan 6 tipik kalp sesi sinyallerini içermektedir. Toplamda 46 ses verisi içermektedir (Texas Heart Institute, 2022).

Kalp sesleri için kullanılan bir diğer veri seti ise Fırat Üniversitesi Hastanesi Kardiyoloji Bölümüne devam eden hastalardan prospektif olarak alınmıştır. Veri seti, dokuz kalp kapak hastalığı sınıfına ve bir sağlıklı sınıfa ayrılan 651 denekten oluşan 10.366 kalp sesinden oluşmaktadır. Her ses, örnekleme frekansı 4 kHz olan Littmann 3200 dijital stetoskop kullanılarak 2 sn sabit bir süre ile kaydedilmiştir. Her denek için tanısal kalp kapak hastalığı sınıfı önceden ekokardiyografide tespit edilmiştir. Her ses sinyalinin uzunluğu 2 s'dir. Veri setinde düşük ve şiddetli aort darlığı, düşük ve orta mitral darlığı, düşük, orta ve şiddetli mitral yetersizliği, orta ve şiddetli Trisküspit yetersizliği verileri bulunmaktadır (Barua ve diğerleri, 2022).

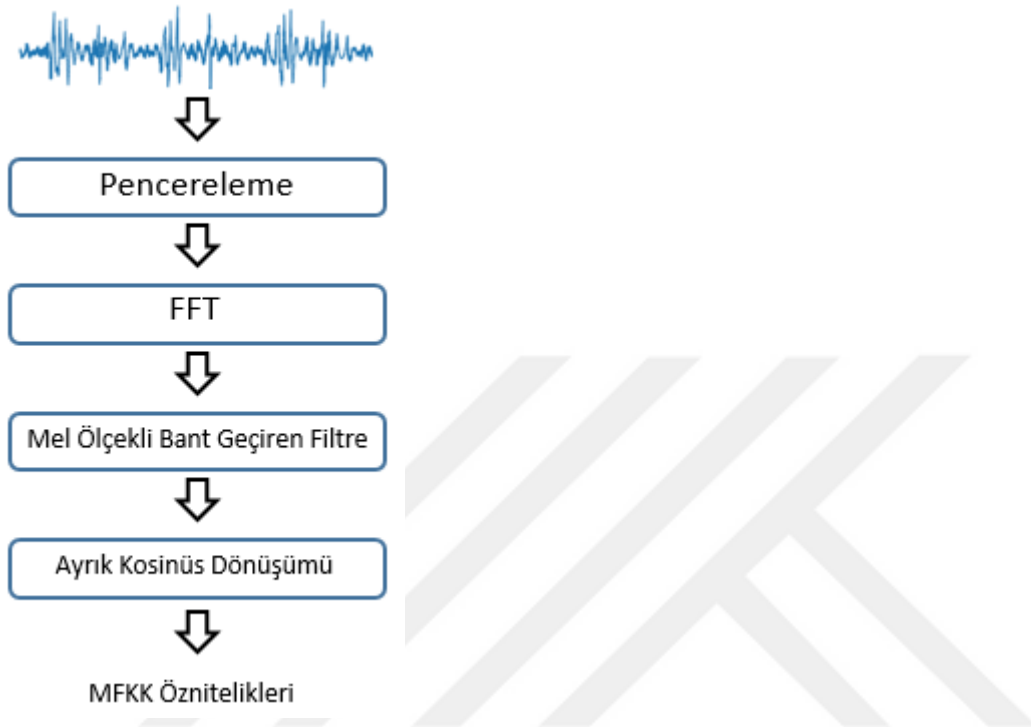
3.2. Öznitelik Çıkarımı

Bu çalışmada öznitelik çıkarımı için MFKK uygulanmıştır (Şekil 3.3). MFKK mel frekans spektrumu kullanılarak katsayıların oluşturulduğu bir öznitelik çıkarma yöntemidir. MFKK'nin adımlarına baktığımızda ilk olarak solunum sesi sinyaline pencereleme yöntemi uygulanır. Pencereleme boyutuna göre elde edilen çıktıları Hızlı Fourier Dönüşümü (FFT) uygulanarak yeni katsayılar elde edilir. Katsayılara mel ölçekli filtre bankası olarak bilinen üçgen bant geçiren filtre uygulanır. Mel frekans denklemi (1) kullanılarak,

$$Mel(f) = 2595 \log\left(1 + \frac{f}{735}\right) \quad (3.1)$$

elde edilen gerçek frekans ölçeği Mel logaritmik ölçeğine dönüştürülür. Logaritmik ölçek daha

sonra ayrı bir kosinüs dönüşümü kullanılarak zamana dönüştürülür ve elde edilen çıktı Mel Frekans katsayıları kümesidir. Solunum seslerinden elde edilen MFKK'ler, farklı sınıflandırıcılar kullanılarak eğitilebilirler (Ballı ve Kutlu, 2021).



Şekil 3.3. MFKK'nin Blog Diyagramı

Bu çalışmada her veriden toplamda 128 tane katsayı elde edilmiştir.

3.3. Sınıflandırma

3.3.1. K en yakın komşu

En yakın komşu bir denetimli öğrenme yöntemidir. Bu yöntemde sınıfı bilinmeyen bir verinin eğitim kümesinde yer alan her bir veriye olan mesafesi belirlenir. Mesafe yöntemleri olarak Minkowski, Öklid, Manhattan, Chebyshev, Dilca uzaklık yöntemleri kullanılabilir. Genellikle Öklid mesafesi kullanılır, ancak güçlü bir şekilde ilişkili değişkenler için korelasyona dayalı ölçümler tercih edilir (Berrueta ve diğerleri, 2007). Uzaklık mesafelerinin en düşükten yükseğe doğru sıralanır. kNN'de, bilinmeyen veriye en yakın k tane veri seçilir. Bilinmeyen veri k tane verinin çoğunluğunun ait olduğu grupta sınıflandırılır. Farklı k değerleri ile tahmin sonuç oranlarını değiştirebilmektedir (Mitchell, 1997).

3.3.2. Karar ağacı

Karar ağaçları, örnekleri ağaçta kökten bazı yaprak düğümlere kadar sıralayarak sınıflandırır. Bu da örneğin sınıflandırılmasını sağlar. Ağaçtaki her düğüm, örneğin bazı özniteliklerinin testini belirtir. Bu düğümden inen her dal, bu öznitelik için olası değerlerden birine karşılık gelir. Bir örnek, ağacın kök düğümünden başlayarak, bu düğüm tarafından belirtilen özniteliği test ederek ve ardından verilen örnekteki özniteliğin değerine karşılık gelen ağaç dalından aşağı inerek sınıflandırılır. Bu işlem daha sonra yeni düğüme köklenen alt ağaç için tekrarlanır (Mitchell, 1997).

3.3.3. Rastgele orman

Rastgele Orman, karar ağaç topluluğundan oluşmaktadır. Bu toplulukları büyütmek için, genellikle topluluktaki her ağacın büyümesini yöneten rastgele vektörler üretilir. Rastgele ormanlar, her ağacın bağımsız olarak örneklenen ve ormandaki tüm ağaçlar için aynı dağılıma sahip rastgele bir vektörün değerlerine bağlı olduğu ağaç tahmincilerinin bir kombinasyonudur. Orman topluluğunda bulunan her bir ağaçtan elde edilen sınıfların sonuçlarına bakılır ve test edilen veri fazla olan sınıfa ait olarak sınıflanır (Breiman, 2001). Karar ağacına göre büyük verilerde daha yüksek başarımlar elde edilebilir. Overfittingi azaltmaktadır.

3.3.4. Aşırı gradyan artırma

Aşırı Gradyan Artırma (XGBoost (Extreme Gradient Boosting)), ilk olarak 2011 yılında Tianqi Chen ve Carlos Guestrin tarafından önerilen ve birçok bilim insanının takip çalışmasında sürekli olarak optimize edilmiş ve geliştirilmiş bir modeldir (Chen ve Guestrin, 2016). Model, Boosting Tree modellerine dayalı bir öğrenme çerçevesidir.

Geleneksel Boosting Tree modelleri yalnızca birinci türev bilgisini kullanır. n'inci ağacı eğitirken, eski n-1 ağaçlarının kalıntıları kullanıldığı için dağıtılmış eğitimi uygulamak zordur. XGBoost, kayıp işlevinde ikinci dereceden bir Taylor genişletmesi gerçekleştirir ve paralel bilgi işlem için CPU'nun çoklu iş parçacıklı kullanımını otomatik olarak kullanabilir. Ayrıca XGBoost, aşırı öğrenmeyi önlemek için çeşitli yöntemler kullanır.

İlk olarak toplam K ağacı varsayarak ağaç modelini toplama yöntemiyle entegre edilir. Temel

ağaç modelini temsil etmek için F kullanılır:

$$\hat{y}_i = \sum_{k=1}^k f_k(x_i), f_k \in F \quad (3.2)$$

Amaç fonksiyonu:

$$L = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (3.3)$$

burada l, tahmin değeri ile gerçek değer arasındaki hatayı temsil eden kayıp fonksiyonudur; Ω , aşırı uydurmayı önlemek için düzenleme için kullanılan işlevdir:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (3.4)$$

burada T, ağaç başına düşen yaprak sayısını, w ise her bir ağacın yapraklarının ağırlığını temsil eder.

t'inci yinelemeden sonraki tahmini değeri temsil eder, o zaman:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(x_i) \quad (3.5)$$

Bu nedenle, amaç fonksiyonu şu şekilde ifade edilebilir:

$$L^{(t)} = \sum_i l(\hat{y}_i^{(t-1)} + f_t(x_i), y_i) + \Omega(f) \quad (3.6)$$

Amaç fonksiyonunun ikinci dereceden Taylor açılımı şu şekildedir:

$$L^{(t)} = \sum_i [l(y_i, \hat{y}_i^{(t-1)} + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i))] + \Omega(f) \quad (3.7)$$

$$g_i = \partial_{\hat{y}_i^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)}) \quad (3.8)$$

$$h_i = \partial_{\hat{y}_i^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)}) \quad (3.9)$$

Sabit terimi yoksayarsak denklem şu şekilde yazılabilir:

$$L^{(t)} = \sum_i [g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f) \quad (3.10)$$

j'inci yaprak düğümü $I_j = \{i | q(x_i) = j\}$ olarak tanımlarsak denklem şu şekilde yazılabilir:

$$\begin{aligned} L^{(t)} &= \sum_i [g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \\ &= \sum_{j=1}^T [(\sum_{i \in I_j} g_i) w_j + \frac{1}{2} (\sum_{i \in I_j} h_i + \lambda) w_j^2] + \gamma T \end{aligned} \quad (3.11)$$

Amaç fonksiyonunun türevi 0'a eşit olduğunda, optimal ağırlık:

$$w_j^* = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (3.12)$$

$w_j = w_j^*$ olduğunda, amaç fonksiyonu şu şekildedir:

$$L^{(t)}(q) = -\frac{1}{2} \sum_{j=1}^T \frac{(\sum_{i \in I_j} g_i)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (3.13)$$

I_L , her bölmeden sonra tüm sol düğümlerin kümesini temsil eder ve I_R , her bölmeden sonra tüm sağ düğümlerin kümesidir, ardından her bölmeden sonra, amaç fonksiyonunun bilgi kazancı:

$$Gain = \frac{1}{2} \left[\frac{(\sum_{i \in I_L} g_i)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{(\sum_{i \in I_R} g_i)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{(\sum_{i \in I} g_i)^2}{\sum_{i \in I} h_i + \lambda} \right] - \gamma \quad (3.14)$$

3.14'ten görülebileceği gibi, ağacın büyümesini bastırmak ve modelin aşırı öğrenmesini önlemek için bir bölme eşiği γ eklenir. Yaprak düğümün bölünmesine ancak ve ancak bilgi kazancı γ 'den büyükse izin verilir. (Chen ve Guestrin, 2016).

Ek olarak, deneyde fazla uydurmayı önlemek için aşağıdaki iki mükemmel XGBoost tekniğini de kullandık:

- Yaprak düğümlerdeki tüm numune ağırlıkları eşiğin altındaysa bölme durdurulur. Bu, modelin özel eğitim örneklerini öğrenmesini engeller.
- Her ağacı oluştururken özellikleri rastgele örnekler.

Bu yöntemlerin tümü, XGBoost'u daha genelleştirilebilir hale getirir ve pratik uygulamalarda daha iyi performans elde eder (Li ve ark., 2019).

3.3.5. Destek vektör makineleri

DVM denetimli bir öğrenme yöntemidir. Veri analizi ve sınıflandırma için iyi bir araçtır. DVM sınıflandırıcı, büyük verilerde bile hızlı bir öğrenme hızına sahiptir. DVM, iki veya daha fazla sınıf sınıflandırma problemi için kullanılır. Destek Vektör Makinesi, karar düzlemleri kavramına dayanmaktadır. Bir karar düzlemi, farklı sınıf üyeliklerine sahip bir dizi öge arasında ayırım yapan bir düzlemdir. Beyin tümörünün sınıflandırılması ve tespiti, Destek Vektör Makinesi tekniği kullanılarak yapıldı. DVM'nin kullanımı, eğitim ve test olmak üzere iki temel

adımı içerir (Parven ve Singh, 2015).

DVM'de sınıfların ± 1 olarak tanımlandığı varsayılır ve karar sınırı $y=0$ olarak tahmin edilir. Yani denklemi kullanarak:

$$y = \sum_{i=1}^N \omega_i x_i + b = x_i \omega + b \quad (3.15)$$

x_i 'nin giriş modelleri olduğu yerde, w ağırlık vektörüdür, b ofsettir. Sınıflar ± 1 olarak tanımlandığından, sınıfları bölen çizginin denklemi şöyle olacaktır:

$$\begin{aligned} x_i \omega + b &\geq 1 \text{ when } y = +1 \\ x_i \omega + b &\leq -1 \text{ when } y = -1 \end{aligned} \quad (3.16)$$

Hiper plandan ($x_i \omega + b = 0$) orijine olan mesafe $-b$ 'dir, burada $\|w\|$, w 'nin normudur. $\|w\|$ hiper düzleminden orijine olan mesafe:

$$M = \frac{2}{\|w\|} \quad (3.17)$$

Burada M kenar boşluğudur. Böylece maksimum marj, $\|w\|$ 'yi en aza indirerek elde edilir. Sınıflandırma, belirli bir test örneğine eğitim sırasında sınıflandırıcı tarafından bir sınıf atandığı süreçtir (Gupta and Tiwari, 2014.).

3.3.6. Naive bayes

Naive Bayes, köklü bir sınıflandırma algoritmasıdır ve çeşitli problemlere başarıyla uygulanmıştır. Özelliklerin bağımsız olduğu varsayımıyla Bayes teoremine (Denklem 1) dayanmaktadır.

$$P(y|X) = \frac{P(X|y)P(y)}{P(X)} \quad (3.17)$$

l 'de y etiketleri ve X özellikleri temsil ediyor. X 'in boyutu, histogramdaki kutu sayısına karşılık gelir.

Eğer:

$$X = (x_1, x_2, x_3, \dots, x_n) \quad (3.18)$$

Formül bu şekilde gösterilir.

$$P(y|x_1, x_2, x_3, \dots, x_n) = \frac{P(x_1|y)P(x_2|y) \dots P(x_n|y)P(y)}{P(x_1)P(x_2) \dots P(x_n)} \quad (3.19)$$

Genel bir formda,

$$P(y|x_1, x_2, x_3, \dots, x_n) \propto \prod_{i=1}^n P(x_i|y) \quad (3.20)$$

Son olarak, n kullanılarak tahminler yapılabilir.

$$y = \operatorname{argmax}_y P(y) \prod_{i=1}^n P(x_i|y) \quad (3.15)$$

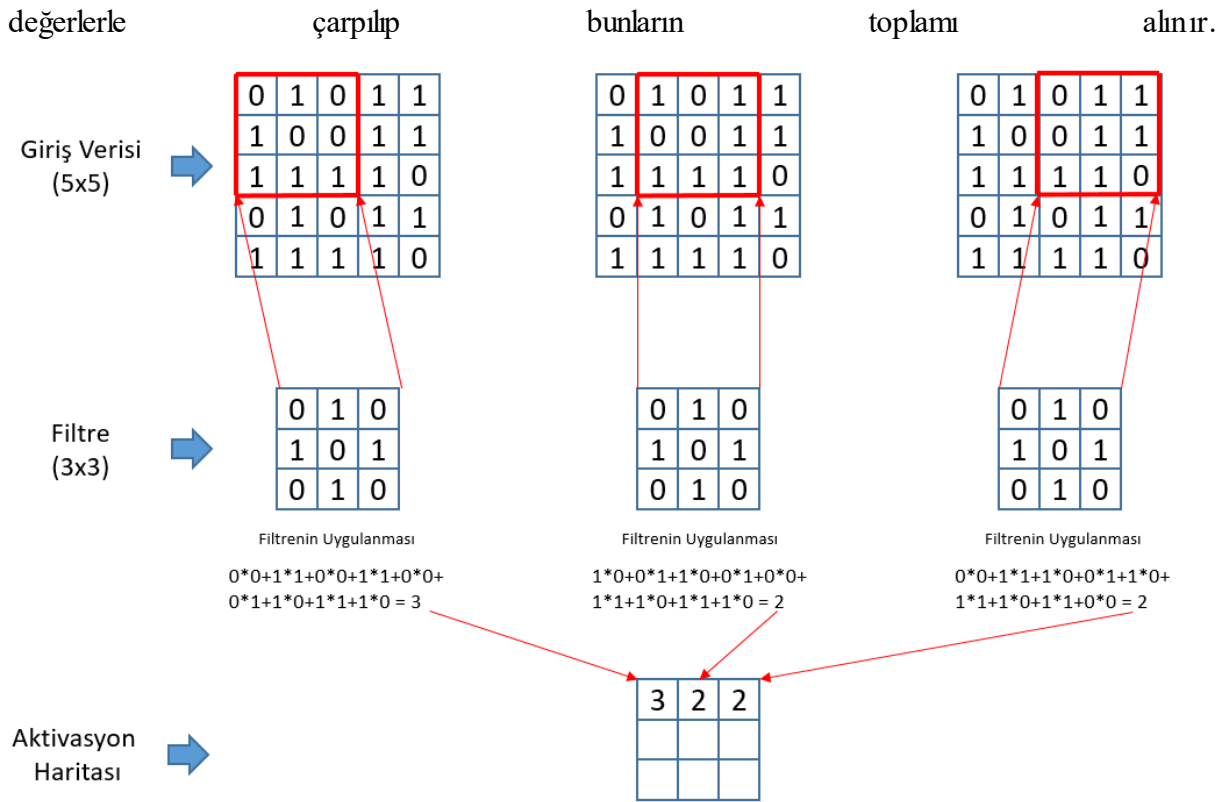
3.3.7. Evrişimli sinir ağı

Evrişimsel Sinir Ağı (ESA) bir derin öğrenme metodudur. Girdi olarak verilen verilere filtreler uygulanır. Elde ettiği ağırlık değerlerine göre yapay sinir ağında eğitilir ve sınıflandırılır. Konvolüsyon, kümeleme ve sınıflandırma katmanından oluşmaktadır. Kullanılacak veriye veya işlem gücüne göre filtre yapıları ve katman sayısı belirlenir.

ESA 2 bölümden oluşur. Giriş verisi Özellik Öğrenme bölümünde yer alan Konvolüsyon ve Havuzlama Katmanlarında işlem görür. 2. Bölüm ise bu öğrenilen özelliklere göre sınıflandırma yapan sınıflandırma katmanıdır.

Konvolüsyon katmanı

Konvolüsyon Katmanı Evrişimli Sinir Ağı'nın temelini oluşturmaktadır. Bu katmanda belirli bir filtre tüm verilerin üzerinde dolaşır. Filtre boyutları 2x2, 3x3, 5x5 gibi farklı değerlerde olabilir. Konvolüsyon işlemi sonrasında aktivasyon haritası (Özellik Haritası) oluşur. Aktivasyon haritası, her bir filtreye özgü özelliklerin keşfedildiği bölgelerdir. Eğitim esnasında eğitim kümesindeki her öğrenme yinemesiyle filtrelerin katsayıları değişir. Bu sayede ağ, verinin hangi bölgelerinin önem taşıdığı belirlenmiş olur. Bir filtrenin giriş verisi üzerinde uygulanması Şekil 3.4'te gösterilmiştir. Giriş verisi 5x5 bir matris olduğu düşünülürse giriş veri boyutu 5x5x1 olacaktır. Konvolüsyon işlemi için Şekil 3.4'te 3x3'lük bir filtre belirlenmiştir. Filtre, giriş verisi üzerinde sağa veya sola doğru belirli Adım(Stride) kayarak dolaşır. Dolaşma esnasında matris sınırına gelindiğinde ise bir basamak aşağı kayıp tekrar devam eder. Bu dolaşma işlemi giriş verisinin tümü üzerinde yapılır. Filtre katsayıları veriler üzerindeki

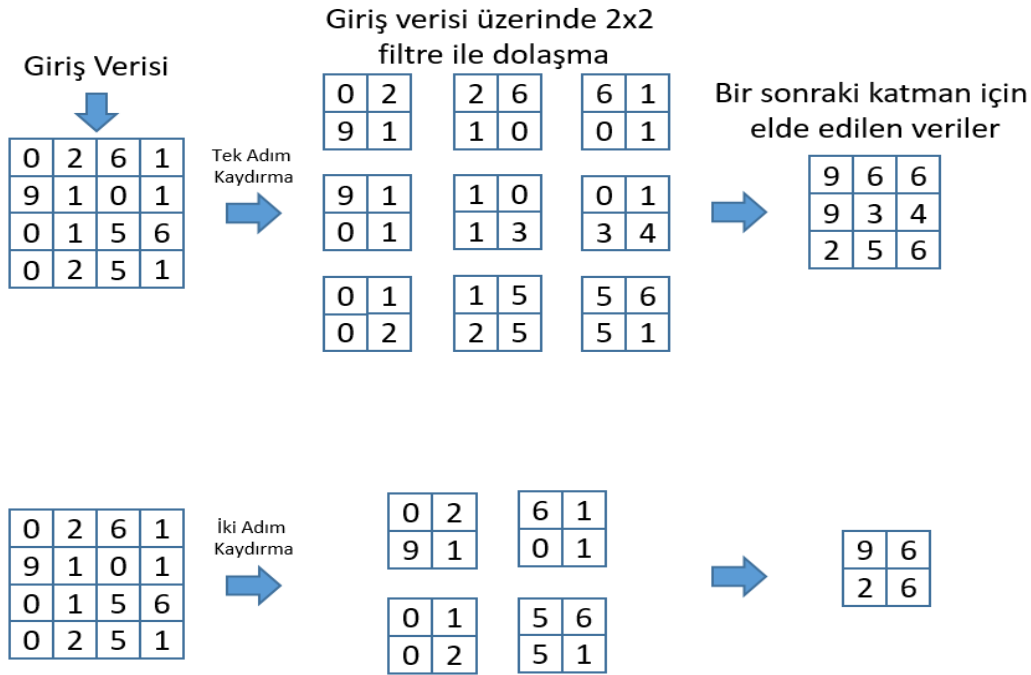


Şekil 3.4. Konvolüsyon Katmanında Uygulanan Filtrenin Detaylı Gösterimi

Havuzlama katmanı

Havuzlama katmanının temel amacı sonraki konvolüsyon katmanı için giriş boyutunu azaltmaktır. Bu işlemde verideki derinlik boyutu etkilenmez. Fakat katman sonucunda boyutta azalma olur. Bu da bilgi kaybına yol açar. Böyle bir kayıp hem bir sonraki ağ katmanları için daha az hesaplama yükü oluşturur hem de sistemin ezberlemesinin önüne geçilir. Havuzlama katmanında belli filtreler tanımlanır. Maksimum, minimum ve ortalama havuzlama olmak üzere 3 türü bulunmaktadır. Bu filtreler giriş verileri üzerinde belli bir adım atma değerine göre gezdirilir. Havuzlama işlemi, konvolüsyon katmanı sonucu oluşan filtre sayısı kadar olan verilerin hepsi için gerçekleştirilir. Havuzlama işlemi isteğe bağlıdır. Bazı mimarilerde birden çok kez kullanılırken bazılarında bu işlemi gerçekleştirmez.

Şekil 3.5'te giriş verisi üzerinden tek ve iki adım kaydırma ile 2x2' lik maximum havuzlama katmanı gösterilmiştir. Filtre boyutunda yer alan verilerin içerisinde en yüksek olan değer bir sonraki katmana aktarılır.



Şekil 3.5. Evrişimli sinir ağı maksimum havuzlama katmanı detaylı gösterimi

Bırakma katmanı

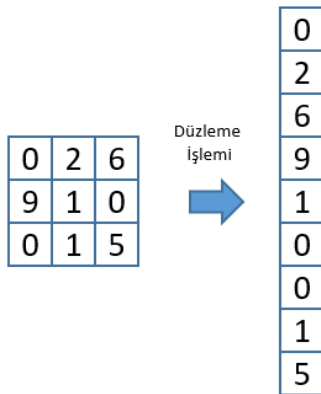
Temelde tam bağlı katmanlar için bir düzenleme türü olarak gösterilen Bırakma Katmanı, çeşitli derin sinir ağları biçimleriyle başarıyla kullanılmıştır ve çeşitli tanıma görevlerinde performanslarını kanıtlar. Bu yöntem ile eğitim yapılırken, bir katmanın çıktısının tüm öğeleri p olasılıkla bırakılır, aksi halde olasılıkla sıfıra değiştirilir. Çok sayıda veri ve parametrenin kullanılması nedeniyle aşırı uyum meydana gelebilir. Bırakma ile bir birimin ağıdan geçici olarak çıkarılır. Çıkarılan birim, sadece eğitim sırasında rastgele seçilir.

Tam bağlantılı katman

Giriş verisi birçok konvolüsyon ve havuzlama katmanından oluşan bir yapıya girdikten sonra çok boyutlu bir matris elde edilir. Bu veriler sınıflandırma katmanına bağlanır. Bağlantı için çok boyutlu matris tek boyut olarak düzenlenir. Şekil 3.6'te 3x3'lük matrisin düzleme sonucu oluşan 1x9' luk matrisin oluşum aşaması gösterilmiştir.

Farklı mimarilerde bu katmanın sayısı değişebilir. Örneğin ESA mimarisinde en son katmanın üretmiş olduğu matris boyutu $25 \times 25 \times 256 = 160000 \times 1$ olduğunu varsayalım. Tam bağlantılı katmandaki matris boyutu 4096×1 olarak seçilirse toplamda 160000×4096 ağırlık matrisi

oluşur. Yani her bir 160000 nöron 4096 nöron ile bağlanmaktadır. Bu sebepten dolayı bu katmana tam bağlantılı katman denilmektedir.



Şekil 3.6. Tam Bağlantılı Katman detaylı gösterimi

Sınıflandırma katmanı

Sınıflandırma Katmanı, Tam Bağlı Katmandan sonra gelir. Bu katmanın çıkış değeri, sınıflandırması yapılacak nesne sayısı ile aynıdır. Eğitim aşamasında TB’de bulunan nöronlar, ağırlıkları her bir etikete göre değerlendirir. Yüksek doğruluğu olan etiketler seçilir. Çoğunlukla başarısından dolayı softmax sınıflandırıcı tercih edilir. Sınıflandırmada 0-1 aralığında belli bir değerde çıkış üretilir. 1’e yakın sonucu üreten çıkış, ağırlık tahmin ettiği sınıftır.

3.3.8. Performans ölçüm yöntemleri

Sınıflandırıcı performanslarının hesaplanmasında performans ölçümleri kullanılır. Sınıflandırma başarımını ölçmek için kesinlik (precision), hassasiyet (recall), fl-skor (f1-score), karmaşıklık matrisi, Jaccard İndeksi, zar katsayısı (dice coefficient), Accuracy (Doğruluk), Özgünlük (Specifity) gibi birçok farklı metrikten faydalanılmaktadır (Hossin ve Sulaiman 2015). Sınıflandırıcı performansına bakılırken metriğe bakılması sonucun doğru değerlendirilmesi açısından önemlidir. Çalışmada sınıflandırma başarımını ölçmek için kesinlik, hassasiyet, özgüllük, doğruluk, fl-skor ve karmaşıklık matrisi değerlerine bakıldı.

Bir sınıflandırıcıyla ilişkili $n \times n$ boyutunda bir karışıklık matrisi, tahmin edilen ve gerçek sınıflandırmayı gösterir; burada n , farklı sınıfların sayısıdır. Çizelge 3.1, girişleri aşağıdaki anlamlara sahip olan $n = 2$ için bir karışıklık matrisini göstermektedir:

Çizelge 3.1. Sınıflandırma Doğruluk Tablosu

		Tahmin Edilen Değer	
		Pozitif	Negatif
Gerçek Değer	Pozitif	Gerçek Pozitif (GP)	Yanlış Negatif(YN)
	Negatif	Yanlış Pozitif (YP)	Gerçek Negatif(GN)

- Gerçek Pozitif (GP): Verinin gerçek sınıfı ve tahmin edilen sınıf doğrudur.
- Gerçek Negatif (GN): Verinin gerçek sınıfı yanlış ve tahmin edilen sınıf yanlıştır.
- Yanlış Negatifler (YN): Verinin gerçek sınıfı doğru ve tahmin edilen sınıf yanlıştır.
- Yanlış Pozitifler (YP): Verinin gerçek sınıfı yanlış ve tahmin edilen sınıf doğrudur.

Sınıflandırma performansı için belirlenen doğruluk, doğru sınıflandırılan sınıfların tüm sınıflara oranını ifade etmektedir. Kesinlik, pozitif bir sınıftaki toplam öngörülen biçimlerden doğru şekilde öngörülen pozitif kalıpları ölçmek için kullanılır. Hassasiyet, Gerçek pozitiflerin gerçek pozitif ve yanlış negatif toplamına oranıdır. f1-skor, kesinlik ve hassasiyet kavramları üzerinden hesaplanır. Doğruluk, Kesinlik, Hassasiyet ve f1-skor değerleri Tablo 3.1'deki değerlere bağlı olarak aşağıdaki gibi hesaplanmaktadır.

$$\text{Doğruluk} = (TP + TN)/(TP + TN + FP + FN) \quad (3.16)$$

$$\text{Kesinlik} = TP/(TP + FP) \quad (3.17)$$

$$\text{Hassasiyet} = TP/(TP + FN) \quad (3.18)$$

$$f1 - \text{skor} = 2 * (\text{Hassasiyet} * \text{Kesinlik})/(\text{Hassasiyet} + \text{Kesinlik}) \quad (3.19)$$

3.4. Donanımın Hazırlanması

Günümüzde vücut seslerinden oluşan veri setleri üzerinde yapılan analizler ve çalışmalar oldukça fazladır. Bu çalışmada kalp ve akciğer seslerini dinleyip kaydedebilen 4 kanallı giyilenilir stetoskop tasarımı yapılmıştır. Kanallardan alınan seslere bant geçiren filtre uygulandıktan sonra veriler ses kartına aktarılır. Ses kartı gömülü bilgisayara bağlı halde bulunur. Ses kartı mono jack' tan aldığı verileri gömülü bilgisayara usb portu ile aktarır. Gömülü bilgisayar aldığı verileri 32 bit ve 44100 Hz örnekleme frekansı ile sesleri dijital veriye dönüştürür ve arayüzün bulunduğu bilgisayara eş zamanlı olarak gönderir. Verilerin gönderilmesi sırasında TCP/IP kullanılır. Aktarılmış verilerin arayüz ile analizi yapılabilir, kaydedilebilir, hastalığın belirgin olduğu bölümler etiketlenebilir. Bu sayede bir veri seti oluşturmanın yanı sıra, tekrar dinlenebilir ve analiz edilebilir sistem yapısı da oluşturulmuştur.

3.4.1. Analog sinyal işleme birimi

Sinyal işleme birimi alınan sinyallerin filtrelenip yükseltilmesi ile daha kaliteli sinyalin oluşturulması için kullanılmıştır. Çalışmada stetoskop başlığı ve ona bağlı olan bir elektret mikrofon kullanılmıştır. Bu mikrofon 20- 20000 Hz aradıkları sinyalleri algılamaktadır. Stetoskop başlığının diyaframında bulunan elektret mikrofonu iletilir. Elektret mikrofon aldığı sinyalleri yaklaşık 200mv genlik ile yüksek geçiren filtreye iletir. Kalp sesleri için 20Hz akciğer sesleri için 100Hz yüksek geçiren filtre uygulanmıştır. Filtrelerden geçen sinyaller AD620 opampı ile 50 kat yükseltilir. Yükselteç çıkışında alçak geçiren filtre bulunur. Kalp sinyalleri için 500 Hz akciğer sesleri için 1000 Hz kesim frekansı uygulanmıştır. Son oluşan sinyal gömülü sisteme iletilir.

Filtre ve yükselteç devresi

Bu çalışmada kalp ve akciğerler için ayrı filtre tasarımı yapılmıştır. 20-500Hz arası geçiren bir filtre tasarımı yapılmıştır. Şekil 3.8’de kalbe bağlanan 2 elektret mikrofonu için oluşturulan devre şeması verilmiştir. Yükseltme işlemi için AD620 kullanılmıştır. AD620 için kazanç formülü;

$$G = \frac{49.4k\Omega}{R_G} + 1 \quad (3.20)$$

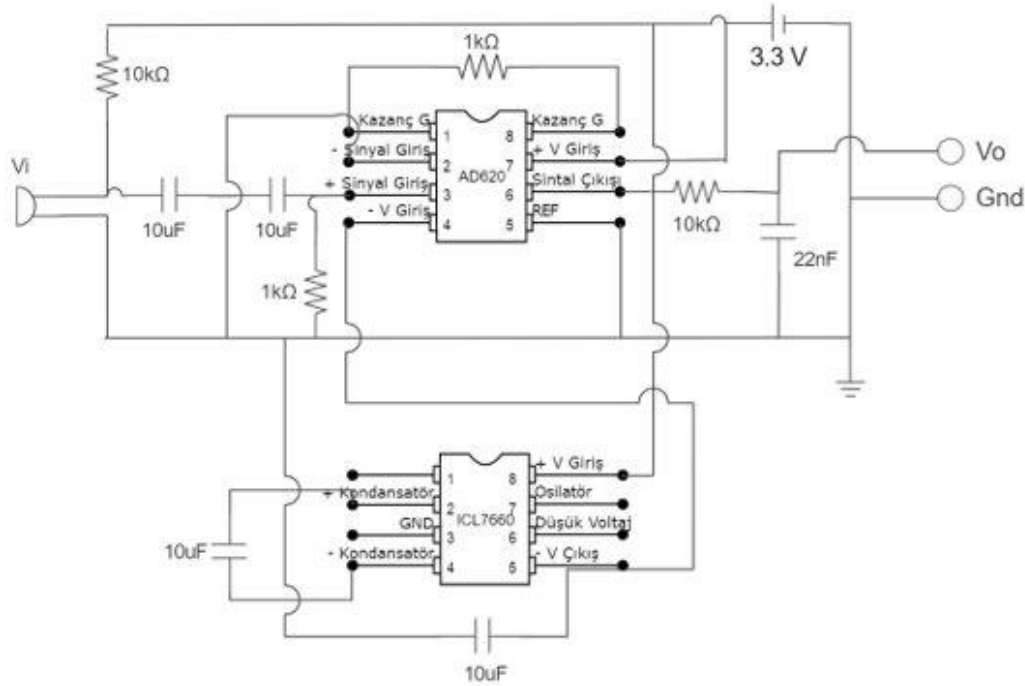
şeklinde dir. R_G , AD620’ nin kazanç için kullanıldığı dirençtir. Devremizde 1k direnç kullanılmış ve yaklaşık 50 kat kazanç (G) elde edilmiştir. Yaklaşık 100mV olarak alınan sinyal 5V seviyesine yükseltilmiştir. Filtrelerin kesim frekansı;

$$f_c = \frac{1}{2\pi RC} \quad (3.3)$$

formülü ile hesaplanmaktadır.


Oskültasyon için 20-600 Hz arasındaki sinyalleri geçiren bir filtre devresi tasarımı yapılmıştır. Şekil 3.7’de devre şeması gösterilmiştir. ICL7660 negatif gerilim kaynağı oluşturmaktadır.

AD620 ise ses sinyallerini yükseltmektedir. Devre şeması incelendiğinde AD620 nin kullanıldığı devre donanımımızın içerisinde 4 adet bulunmaktadır. ICL7660 diğer 4 opmapı -3.3V ile beslemektedir. Devredeki tüm opamplar 3.3V ile çalışmaktadır. Alınan gerilim tüm devreyi beslemektedir. Elektret mikrofon 10uF çıkışına 100mV gerilim vermektedir.




Şekil 3.7. Devre şeması

Frekansın 20Hz ve üstünü geçirebilmesi için bir RC yüksek geçiren filtre tasarlanmıştır. 10 uF kondansatör ve 1 kohm resistör kullanılan filtrenin kesim frekansı Şekil 3.8’da verilmiştir. AD620 ile 50 kat yükseltileen sinyale alçak geçiren filtre uygulanmıştır. Tasarlanan RC alçak geçiren filtre için 10 kohm resistör ve 22 nF kondansatör kullanılmıştır ve devrenin kesim frekansı Şekil 3.9’da verilmiştir.




Şekil 3.8. Yüksek Geçiren Filtre Kesim Frekans Grafiği




Şekil 3.9. Alçak Geçiren Filtre Kesim Frekans Grafiği

Tasarlanan devrenin ilk giriş sinyali ve filtreleme ve yükseltme işlemleri sonrasında elde edilen sinyaller osiloskop yardımı ile görüntülenmiştir. Şekil 3.10'da elektret mikrofonu sinyal çıkışı verilirken Şekil 3.11'de devre çıkışında elde edilen sinyal verilmiştir. Kalp dinleme noktaları üzerinden alınan bu sinyalde devre çıkışında kalp seslerine ait tepe noktaları net bir şekilde görülmektedir.



Şekil 3.70. Elektret Mikrofonu Çıkışından Elde Edilen Sinyal



Şekil 3.81. Devre Çıkışından Elde Edilen Sinyal

Gömülü sistem

Bu çalışmada, günümüzde çok popüler olan ve bilgisayarda yapılabilecek birçok işlemin yapılmasını sağlayan Raspberry Pi kullanılmıştır. Raspberry Pi Vakfı tarafında 2009 yılında geliştirilmeye başlanmıştır. İlk sürümü 2012 yılında piyasaya sürülmüştür. Bir mini bilgisayar olması, çok fonksiyonlu ve küçük boyutta olması sayesinde birçok çalışmada tercih edilmektedir.

Raspberry Pi' nin 2012' den bu yana birçok modeli çıkmıştır. Teknolojinin gelişimiyle performansı yüksek parçalar yeni modellere entegre edilmiştir. Bu sayede işlem kapasitesi yüksek, uzun süreli çalışmalarda da kullanılmaktadır. Tez çalışmasında Raspberry Pi Model 3B (Şekil 3.12) kullanılmıştır.

Cihaz Linux işletim sistemi ile çalışmaktadır. Sistem SD karta yüklenmektedir. Raspberry

üzerinde bulunan SD kart yuvasına takıldığı zaman işletim sistemi kullanılabilir duruma gelmektedir. Raspberry' nin güç tüketimi oldukça düşüktür. Cihazı aktifleştirmek için ise 5V yeterlidir. Ayrıca giriş-çıkış pinleri 2'şer adet 3.3V ve 5V luk beslemeler bulunmaktadır. Model 3B' nin teknik özellikleri Çizelge 3.2'de verilmiştir.



Şekil 3.12. Raspberry Pi Model 3B

Çizelge 3.2. Raspberry Pi Model 3B' nin Teknik Özellikleri

İşlemci	Broadcom BCM2837
CPU Çekirdeği	Quadcore ARM Cortex-A53, 64Bit
Saat Hızı	1.2GHz (Pi2'den kabaca %50 daha hızlı)
RAM	1 GB
GPU	400 MHz VideoCore IV®
Ağ Bağlantısı	1 x 10 / 100 Ethernet (RJ45 Port)
Kablosuz Ağ Bağlantısı	802.11n wireless LAN (WiFi) ve Bluetooth 4.1
USB Portları	4 x USB 2.0
GPIolar	2 x 20 Pinli Header
Kamera Arayüzü	15-pinli MIPI
Ekran Arayüzü	DSI 15 Pin / HDMI Çıkış/Kompozit RCA
Güç sarfiyatı(Çekilen akım)	2.5 A

Sinyallerin iletimi

Ses sinyallerinin dijital ortama iletimi Raspberry' nin ses kartı ve Raspberry'nin USB portları aracılığı ile yapılmaktadır. Sesler elektret mikrofön ile alınmaktadır. Filtre ve yükselteç uygulandıktan sonra elde edilen analog sinyal dijitale ses kartı (Şekil 3.13) aracılığı ile

dönüştürülmüştür. Jack aracılığı analog sesler ses kartına iletilmektedir. Ses kartında 1 mikrofön girişı ve 1 mikrofön girişı bulunmaktadır. Ses kartının dijital ortam ile iletişimi usb port ile sağlanmaktadır. Raspberry' de bulunan Port girişlerine bağlanarak Raspberry' e veri iletimi sağlanmaktadır.



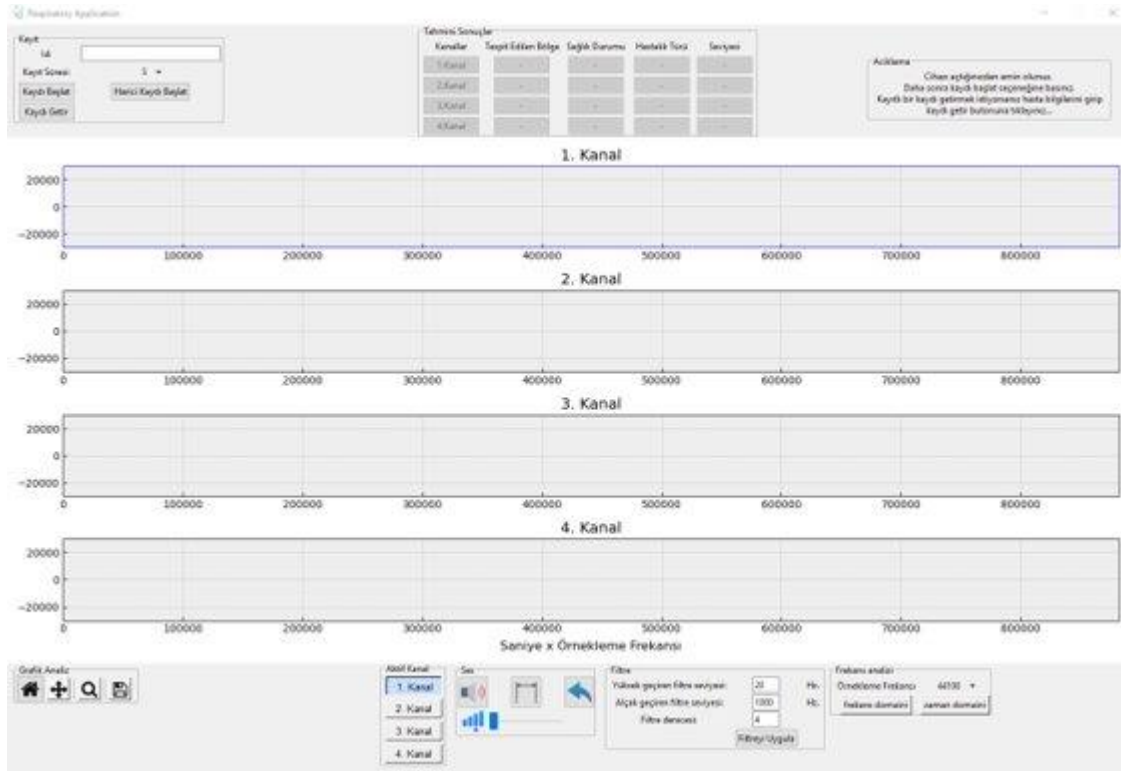
Şekil 3.13. Ses Kartı

Raspberry ses kartından aldığı verileri TCP/IP protokolü ile bilgisayara iletmektedir. Bu protokolde istemci ve sunucu bulunmaktadır. İstemci, sunucu ile internet ağı üzerinden haberleşmektedir. Ağa bağlanan istemci aynı ağda bulunan sunucuya bağlantı isteği gönderir. Bağlantı onaylandıktan sonra veriler gönderilebilir. Python dili ile hazırlanan kod sayesinde bu bağlantılar sağlanmaktadır. Verilerin gönderimi binary olarak yapılmaktadır. Verileri alan sunucu, bulundurduğu arayüz ile veriler üzerinde işlemler yapılmasını sağlayacaktır.

Arayüzün hazırlanması

Bu tez çalışmasında, donanım kullanıcılarının rahat analiz yapabilmesi için bir arayüz tasarımı (Şekil 3.14) yapılmıştır. Arayüz de hasta bilgilerinin girildiği bölüm bulunmaktadır. Bu kısmı kullanarak kaydedilmiş veriler tekrar çağrabilir. Kayıt süresi kısmından kaydının alınacağı toplam süre belirlenir. Kaydı başlat butonu ile raspberry' e komut gider ve raspberry aldığı ses verilerini arayüzün bulunduğu sunucuya gönderir. 4 kanaldan alınan verilerin grafiği ait olduğu kanal isminin altında gösterilir. Alt kısımda bulunan Grafik Analiz bölümünde elde edilen grafikleri başa alma, hareket ettirme, yakınlaştırma ve kaydetme butonları bulunmaktadır. Aktif Kanal bölümünde işlem yapılacak kanal seçilmektedir. Ses kanalında seçili kanaldaki sesin tamamını veya seçili alanı dinleme özelliği bulunmaktadır. Seçili alanın geri alınabilmesi için de geri al butonu bulunmaktadır. Ses kanalının altında bulunan bar, dinlenecek sesin seviyesini belirlemektedir. Filtre bölümünde belirlenen kesim frekanslarına göre filtreleme işlemi yapılır.

Frekans Analizi bölümünde sinyalleri frekans domaininde ve zaman domaininde görüntülenmesi sağlanır. Tahmini sonuçlarda ise kanallardaki ses sinyallerinin yapay zeka modelleri ile tahmin edilen sonuçları gösterilmektedir.

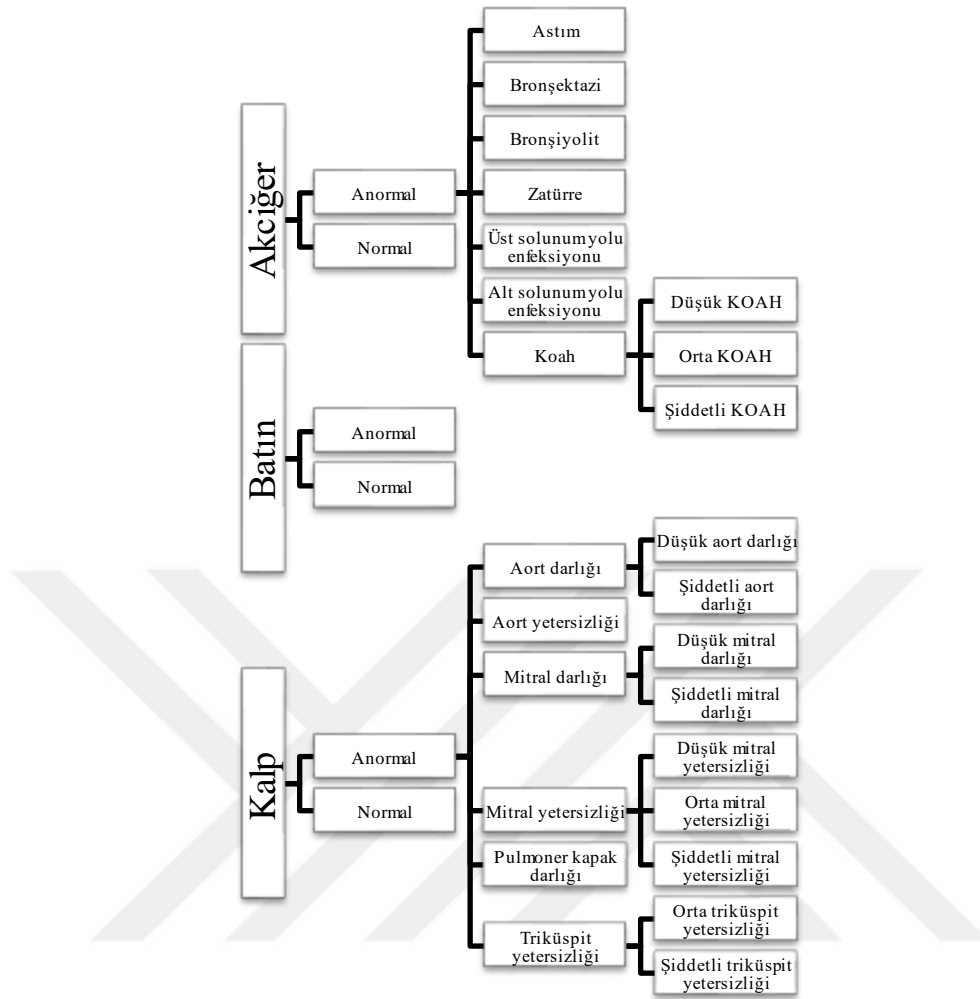


Şekil 3.4. Arayüz Tasarımı

4. ARAŞTIRMA BULGULARI

Vücut sesleri ile yapılan çalışmalarda genel olarak belirli bölge ve rahatsızlıklara odaklanıldığı görülmüştür. Vücut seslerinin etiketlenmemesi, yanlış etiketlenmesi veya uzaktan ses dinlenmesi durumunda hangi bölgeden ses verisinin geldiğinin sistem tarafından anlaşılması gibi durumlarda ses verilerinin kademeli analizine ihtiyaç duyulmaktadır. Çalışmada geliştirilen tanı sistemi vücudun farklı bölgelerinden alınan seslerin tanınmasında yardımcı olacaktır. Şekil 4.1’de sistemde kullanılan verilerin sınıfları görülmektedir. Ses verisi sisteme girildiğinde genelden özele doğru tanıma işlemi yapılmaktadır. İlk olarak sesin vücuttaki bölgesini tespit eden sistem daha sonra hastalığa sahip olup olmadığını kontrol etmektedir. Hastalık teşhisi halinde hangi hastalığa sahip olduğu belirlenmektedir. Sistemde bazı hastalıklara ait seviye bilgileri yer almaktadır. Hastalığın teşhis edilmesi halinde bu seviyelerin tespiti de yapılmaktadır.

Ses ilk olarak kalp, akciğer ve bağırsak olmak üzere 3 sınıfa göre tanıma yapmaktadır. Bölgesel tanımanın yanı sıra kalp, akciğer ve batin bölgeleri için hasta ve sağlıklı ayrımı yapılmaktadır. Sistem akciğer seslerinde 7 farklı hastalığı tanımaktadır. Ayrıca KOAH bulunan verinin tespit edilmesi halinde 5 farklı şiddete göre KOAH tanımlaması yapılmaktadır. Kalp sisteminde ise Hasta tespiti halinde 6 farklı sınıfa göre tanımlama yapılmaktadır. Bu 6 sınıftan 4’ünün tespiti halinde şiddet analizi yapılabilmektedir.



Şekil 4.1. Tanı Sistemi Şeması

4.1. Sınıflandırma

Bu çalışmada 5 farklı veri seti ile 11 farklı sınıflandırma yapılmıştır. Sınıflandırmada KNN, SVM, Karar Ağacı, Rastgele Orman, XGBoost, ESA kullanılmış ve başarımları kıyaslanmıştır.

4.1.1. Kalp, akciğer ve batın seslerinin sınıflandırması

Tanı sisteminin ilk aşaması kalp, akciğer ve batın seslerinin sınıflandırılmasından oluşmaktadır. 12 kişiden 20 farklı bölgeden alınan her bir ses kaydı 20s sürelidir. Her ses verisi 1s olarak ayrılmış ve sınıflandırmada kullanılmıştır. Her sınıftan 960 veri olmak üzere toplamda 2880 veri bulunmaktadır. 2016 veri eğitimde kullanılırken 864 veri testte kullanılmıştır. 7 farklı sınıflandırma yöntemi denenmiş ve sonuçları kıyaslanmıştır. ESA modeli oluşturulurken 128 MFKK katsayısı 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 500 epoch sonunda elde edilen elde edilen sonuç baz alınmıştır.


Sınıflandırma sonuçlarının analizi

Çizelge 4.1’de bölgesel teşhis için kesinlik, hassasiyet ve f1-skor değerlerine ait veriler verilmiştir. Sonuçlara bakıldığında AGA ve RO sınıflandırma sonuçları diğer sınıflandırma yöntemlerine göre daha yüksek başarımlar elde edilmiştir. Bu 2 sınıflandırma kıyaslandığında ise bağırsak seslerine ait sonuçların aynı değerde olduğu görülmektedir. Genel olarak akciğer ve kalp verilerinin ise AGA sınıflandırmasında daha yüksek sonuçlara ulaşılmıştır.

Çizelge 4.1. Bölgesel ses sınıflandırılması başarımları

Sınıflandırma Yöntemi	Bölge	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	Akciğer	0.76	0.77	0.77
	Kalp	0.81	0.83	0.82
	Batın	0.89	0.87	0.88
Rastgele Orman	Akciğer	0.87	0.90	0.88
	Kalp	0.92	0.90	0.91
	Batın	0.96	0.95	0.96
Navie Bayes	Akciğer	0.67	0.73	0.70
	Kalp	0.77	0.80	0.79
	Batın	0.91	0.79	0.85
Destek Vektör Makinesi	Akciğer	0.74	0.77	0.76
	Kalp	0.83	0.84	0.83
	Batın	0.90	0.85	0.87
Aşırı Gradyan Artırma	Akciğer	0.86	0.92	0.89
	Kalp	0.94	0.89	0.91
	Batın	0.96	0.95	0.96
K En Yakın Komşu	Akciğer	0.81	0.87	0.84
	Kalp	0.89	0.85	0.87
	Batın	0.92	0.89	0.91
Evrişimli Sinir Ağı	Akciğer	0.73	0.94	0.82
	Kalp	0.95	0.71	0.81
	Batın	0.96	0.92	0.94

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımları Aşırı Gradyan Artırma yönteminde elde edilmiştir. Navie Bayes sınıflandırması sonucu alınan en düşük sonuçtur. Başarımlar genel olarak %80’in üzerindedir. %90’ın üzerinde Rastgele Orman ve Aşırı Gradyan Artırma olmak üzere 2 sınıflandırma bulunmaktadır. Şekil 4.2’de başarımların sonuçları tek bir grafikte verilmiştir.



Şekil 4.2. Kalp, Akciğer ve Batın için Kullanılan Sınıflandırmaların Başarım Sonuçları

4.1.2. Kalbe ait sağlıklı ve hasta ses verilerinin sınıflandırılması

Bölgesel teşhis yapıldıktan sonra kalbe ait bir verinin bulunması halinde bu verinin hasta bir bireye mi yoksa sağlıklı bir bireye ait olduğu konusunu öğrenmek için eğitilmiş modele verilir. Bu sınıflandırma sonucu eğer hasta ise hastalık tanıma işlemine geçilir. Veri seti oluşturulurken firat üniversitesi ait kalp verisetinin yanı sıra multimedya solunum veri tabanı ve St. Luke's Episcopal Hastanesi'nden Robert J.ha tarafından oluşturulan açık kaynaklı kalp sesleri veri tabanından yararlanılmıştır. Ses verileri 2s süreli veriler olarak ayrılmış ve öznitelikleri çıkarılmıştır. Her ses verisinden 128 MFKK özniteliği oluşturulmuş ve eğitilmiştir. Toplamda 8962 tane 128 özniteliğe sahip veri elde edilmiştir. 3351 tane veri sağlıklılardan oluşurken 5611 tane veri hastalardan oluşmaktadır. Eğitimlerin daha doğru sonuç vermesi açısından sağlıklı ses verileri kadar hasta veriler kullanılmıştır. Toplamda 6702 veri eğitimler için ayrılmıştır. Verilerin 4691 tanesi ile eğitim, 2011 tanesi ile test yapılmış ve sonuçları karşılaştırılmıştır. 128 veri 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 150 epoch sonunda elde edilen baz alınmıştır.


Sınıflandırma sonuçlarının analizi

Çizelge 4.2'de Kalbe ait hasta ve sağlıklı verilerinin sınıflandırma sonuçlarının doğruluk tablosu verilmiştir. Sonuçlara bakıldığında en yüksek sonuçların AGA yönteminden elde edildiği görülmüştür.

Çizelge 4.2. Kalbe ait hasta ve sağlıklı verilerinin sınıflandırma başarımları

Sınıflandırma Yöntemi	Durum	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	Hasta	0.97	0.96	0.97
	Sağlıklı	0.97	0.97	0.97
Rastgele Orman	Hasta	0.97	0.99	0.98
	Sağlıklı	0.99	0.97	0.98
Navie Bayes	Hasta	0.70	0.91	0.79
	Sağlıklı	0.88	0.63	0.73
Destek Vektör Makinesi	Hasta	0.90	0.93	0.91
	Sağlıklı	0.93	0.90	0.91
Aşırı Gradyan Artırma	Hasta	0.98	0.99	0.99
	Sağlıklı	0.99	0.98	0.98
K En Yakın Komşu	Hasta	0.91	0.93	0.92
	Sağlıklı	0.93	0.91	0.92
Evrişimli Sinir Ağı	Hasta	0.96	0.99	0.97
	Sağlıklı	0.99	0.96	0.97

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımları Aşırı Gradyan Artırma yönteminde elde edilmiştir. Navie Bayes sınıflandırması sonucu alınan en düşük sonuçtur. Başarımlar genel olarak %90'ın üzerindedir. En kötü sonuç 0.77 ile Navie Bayes sınıflandırmasında elde edilmiştir. Şekil 4.3'te başarımları tek bir grafikte verilmiştir.



Şekil 4.3. Kalbe Ait Sağlıklı ve Hasta Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarımları

4.1.3. Kalp hastalıklarının sınıflandırılması

Bu çalışmada 6 farklı kalp rahatsızlığı dikkate alınmıştır. Bunlar aort darlığı, aort yetersizliği, mitral darlığı, mitral yetersizliği, pulmoner kapak darlığı ve triküspit yetersizliğidir. Veri seti için firat üniversitesi ait kalp veri seti ve St. Luke's Episcopal Hastanesi'nden Robert J.ha tarafından oluşturulan açık kaynaklı kalp sesleri veri tabanı birleştirilmiştir. Eğitimde toplamda 7354 tane 2s süreli verilerden 128 öznitelik çıkarımı yapılmıştır. Eğitim için 1241 aort darlığı, 1199 mitral darlığı, 1139 mitral yetersizliği, 1524 triküspit yetersizliği, 31 aort yetersizliği, 13 pulmoner kapak darlığı kullanılmıştır. Test için ise 525 aort darlığı, 513 mitral darlığı, 503 mitral yetersizliği, 646 triküspit yetersizliği, 14 aort yetersizliği, 6 pulmoner kapak darlığı verisi kullanılmıştır. 7 farklı sınıflandırma yönteminin sonuçları kıyaslanmıştır. 128 veri 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 150 epoch sonunda elde edilen sonuçlar baz alınmıştır.

Sınıflandırma sonuçlarının analizi

Çizelge 4.3'e bakıldığında kalp hastalıklarının sınıflandırılmasının doğruluk sonuçları görülmektedir. MD seslerinde en iyi sonuç RO'da görülürken diğer anormal seslerde AGA sınıflandırma yöntemi en iyi sonucu vermektedir.


Çizelge 4.3. Kalp hastalık verilerinin sınıflandırma başarımları sonuçları

Sınıflandırma Yöntemi	Hastalık	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	AD	0.91	0.88	0.89
	MD	0.95	0.97	0.96
	MY	0.92	0.91	0.91
	TY	0.94	0.97	0.95
	AY	0.38	0.36	0.37
	PKD	0.25	0.17	0.20
	Rastgele Orman	AD	0.94	0.93
MD		0.96	0.98	0.97
MY		0.94	0.94	0.94
TY		0.98	0.98	0.98
AY		0.91	0.71	0.80
PKD		1.00	0.17	0.29
Navie Bayes		AD	0.52	0.23
	MD	0.56	0.36	0.44

Çizelge 4.3. (devam) Kalp hastalık verilerinin sınıflandırma başarımları

	MY	0.47	0.67	0.56
	TY	0.60	0.82	0.69
	AY	0.27	1.00	0.42
	PKD	0.44	0.67	0.53
Destek Vektör Makinesi	AD	0.69	0.74	0.72
	MD	0.69	0.70	0.70
	MY	0.69	0.64	0.67
	TY	0.84	0.83	0.83
	AY	0.78	1.00	0.87
	PKD	0.57	0.67	0.62
Aşırı Gradyan Artırma	AD	0.95	0.93	0.94
	MD	0.94	0.98	0.96
	MY	0.98	0.93	0.95
	TY	0.98	0.99	0.99
	AY	0.70	1.00	0.82
	PKD	0.50	0.67	0.57
K En Yakın Komşu	AD	0.82	0.76	0.79
	MD	0.84	0.88	0.86
	MY	0.78	0.76	0.77
	TY	0.87	0.92	0.89
	AY	0.71	0.88	0.77
	PKD	0	0	-
Evrişimli Sinir Ağı	AD	0.90	0.84	0.87
	MD	0.82	0.91	0.86
	MY	0.88	0.84	0.86
	TY	0.95	0.96	0.95
	AY	0.77	0.71	0.74
	PKD	0.56	0.83	0.67

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımlar AGA ve RO yöntemlerinde elde edilmiştir. Navie Bayes sınıflandırması sonucu alınan en düşük sonuçtur. En kötü sonuç 0.54 ile Navie Bayes sınıflandırmasında elde edilmiştir. Şekil 4.4'da başarımları tek bir grafikte verilmiştir.



Şekil 4.4. Kalbe Ait Sağlıklı ve Hasta Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarımlar Sonuçları

4.1.4. Aort darlığının sınıflandırılması

Aort Darlığı sınıflandırılması için firat üniversitesine ait kalp veri setinde yer alan veriler kullanılmıştır. Veriler düşük ve şiddetli aort darlığı olmak üzere 2 sınıftan oluşmaktadır. Düşük aort darlığına ait 958, şiddetli aort darlığına ait 738 ses verisi bulunmaktadır. Ses verileri 2s sürelidir. MFKK ile her veriden 128 öznitelik çıkartılmıştır. Eğitim için 678 düşük aort darlığı ve 509 şiddetli aort darlığı verileri kullanılmıştır. Test için ise 280 düşük aort darlığı ve 230 şiddetli aort darlığı kullanılmıştır. MFKK ile elde edilen 128 veri 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 150 epoch sonunda elde edilen sonuçlar baz alınmıştır.


Sınıflandırma sonuçlarının analizi

Çizelge 4.4'e bakıldığında AD sınıflandırılmasının doğruluk sonuçları görülmektedir. Kesinlik, hassasiyet ve fl-skor sonuçlarına bakıldığında en iyi sınıflandırma yöntemi AGA'dır.

Çizelge 4.4. Aort darlığı verilerinin sınıflandırma başarımları sonuçları

Sınıflandırma Yöntemi	Seviye	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	Düşük AD	0.99	0.93	0.96
	Yüksek AD	0.92	0.99	0.95
Rastgele Orman	Düşük AD	0.99	0.98	0.99
	Yüksek AD	0.98	0.99	0.98
Navie Bayes	Düşük AD	0.80	0.96	0.87
	Yüksek AD	0.93	0.70	0.80
Destek Vektör Makinesi	Düşük AD	0.95	0.97	0.96
	Yüksek AD	0.96	0.94	0.95
Aşırı Gradyan Artırma	Düşük AD	0.99	0.99	0.99
	Yüksek AD	0.98	0.99	0.99
K En Yakın Komşu	Düşük AD	0.94	0.93	0.93
	Yüksek AD	0.91	0.92	0.92
Evrişimli Sinir Ağı	Düşük AD	0.99	0.96	0.98
	Yüksek AD	0.96	0.99	0.97

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımları Aşırı Gradyan Artırma yönteminde elde edilmiştir. Navie Bayes sınıflandırması sonucu alınan en düşük sonuçtur. 6 sınıflandırmada başarımlar %92'nin üzerindedir. En kötü sonuç 0.84 ile Navie Bayes sınıflandırmasında elde edilmiştir. Şekil 4.5'te başarımları tek bir grafikte verilmiştir.



Şekil 4.5. Aort Darlığına Ait Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarımları Sonuçları

4.1.5. Mitral darlığına sınıflandırılması

Mitral Darlığı sınıflandırılması için firat üniversitesine ait kalp veri setinde yer alan veriler kullanılmıştır. Veriler düşük ve şiddetli mitral darlığı olmak üzere 2 sınıftan oluşmaktadır. Düşük mitral darlığına ait 635, şiddetli mitral darlığına ait 1035 ses verisi bulunmaktadır. Ses verileri 2s süreli dir. MFKK ile her veriden 128 öznitelik çıkartılmıştır. Eğitim için 451 düşük mitral darlığı ve 732 şiddetli mitral darlığı verileri kullanılmıştır. Test için ise 204 düşük mitral darlığı ve 303 şiddetli mitral darlığı kullanılmıştır. 128 veri 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 150 epoch sonunda elde edilen sonuçlar baz alınmıştır.


Sınıflandırma sonuçlarının analizi

Çizelge 4.5'e bakıldığında MD sınıflandırılmasının doğruluk sonuçları görülmektedir. Kesinlik, hassasiyet ve f1-skor sonuçlarına bakıldığında KA, RO ve AGA yöntemlerinde en iyi sonuçlar elde edilmiştir.

Çizelge 4.5. Mitral darlığı verilerinin sınıflandırma başarımları

Sınıflandırma Yöntemi	Seviye	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	Düşük MD	1.00	0.99	0.99
	Yüksek MD	0.99	1.00	0.99
Rastgele Orman	Düşük MD	1.00	0.99	0.99
	Yüksek MD	0.99	1.00	0.99
Navie Bayes	Düşük MD	0.62	0.80	0.70
	Yüksek MD	0.83	0.67	0.74
Destek Vektör Makinesi	Düşük MD	0.91	0.76	0.83
	Yüksek MD	0.85	0.95	0.90
Aşırı Gradyan Artırma	Düşük MD	1.00	0.99	0.99
	Yüksek MD	0.99	1.00	0.99
K En Yakın Komşu	Düşük MD	0.91	0.90	0.90
	Yüksek MD	0.93	0.94	0.94
Evrişimli Sinir Ağı	Düşük MD	0.96	0.90	0.93
	Yüksek MD	0.94	0.97	0.96

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımlar Aşırı Gradyan Artırma, DT ve RF yöntemleri ile elde edilmiştir. 5 sınıflandırmada başarımlar %92'nin üzerindedir. En kötü sonuç 0.72 ile Navie Bayes sınıflandırmasında elde edilmiştir. Şekil 4.6'da başarımlar sonuçları tek bir grafikte verilmiştir.



Şekil 4.6. Mitral Darlığına Ait Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarım Sonuçları

4.1.6. Mitral yetersizliği sınıflandırılması

Mitral yetersizliği sınıflandırılması için firat üniversitesine ait kalp veri setinde yer alan veriler kullanılmıştır. Veriler düşük, orta, şiddetli yetersizliği darlığı olmak üzere 3 sınıftan oluşmaktadır. Düşük mitral yetersizliği ait 1337, orta mitral yetersizliği ait 1077, şiddetli mitral yetersizliği ait 792 ses verisi bulunmaktadır. Ses verileri 2s sürelidir. MFKK ile her veriden 128 öznitelik çıkartılmıştır. Eğitim için 914 düşük yetersizliği darlığı, 786 orta mitral yetersizliği ve 544 şiddetli mitral yetersizliği verileri kullanılmıştır. Test için ise 423 düşük yetersizliği darlığı, 291 orta mitral yetersizliği ve 248 şiddetli mitral yetersizliği kullanılmıştır. MFKK ile elde edilen 128 veri 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 150 epoch sonunda elde edilen sonuçlar baz alınmıştır.


Sınıflandırma sonuçlarının analizi

Çizelge 4.6'e bakıldığında MY sınıflandırılmasının doğruluk sonuçları görülmektedir. Kesinlik, hassasiyet ve fl-skor sonuçlarına bakıldığında AGA yönteminde en iyi sonuç elde edilmiştir.

Çizelge 4.6. Mitral yetmezliği verilerinin sınıflandırma başarımları sonuçları

Sınıflandırma Yöntemi	Seviye	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	Düşük MY	0.97	0.96	0.96
	Orta MY	0.97	0.97	0.97
	Yüksek MY	0.93	0.95	0.94
Rastgele Orman	Düşük MY	0.99	0.98	0.98
	Orta MY	0.99	1.00	0.99
	Yüksek MY	0.98	0.98	0.98
Navie Bayes	Düşük MY	0.80	0.78	0.79
	Orta MY	0.79	0.74	0.76
	Yüksek MY	0.65	0.73	0.69
Destek Vektör Makinesi	Düşük MY	0.86	0.88	0.87
	Orta MY	0.83	0.89	0.86
	Yüksek MY	0.84	0.73	0.76
Aşırı Gradyan Artırma	Düşük MY	0.98	0.99	0.98
	Orta MY	1.00	0.99	0.99
	Yüksek MY	0.98	0.98	0.98
K En Yakın Komşu	Düşük MY	0.86	0.83	0.85
	Orta MY	0.88	0.82	0.85
	Yüksek MY	0.73	0.84	0.78
Evrişimli Sinir Ağı	Düşük MY	0.91	0.94	0.92
	Orta MY	0.98	0.87	0.92
	Yüksek MY	0.85	0.92	0.88

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımları Aşırı Gradyan Artırma ve RF yöntemleri ile elde edilmiştir. 4 sınıflandırmada başarımlar %90'nin üzerindedir. En kötü sonuç 0.75 ile Navie Bayes sınıflandırmasında elde edilmiştir. Şekil 4.7'da başarımları tek bir grafikte verilmiştir.



Şekil 4.7. Mitral Yetersizliğine Ait Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarımları

4.1.7. Triküspit yetersizliği sınıflandırılması

Triküspit yetersizliği sınıflandırılması için firat üniversitesine ait kalp veri setinde yer alan veriler kullanılmıştır. Veriler orta ve şiddetli triküspit yetersizliği olmak üzere 3 sınıftan oluşmaktadır. Orta triküspit yetersizliği ait 1076, yüksek triküspit yetersizliği ait 1080, ses verisi bulunmaktadır. Ses verileri 2s sürelidir. MFKK ile her veriden 128 öznitelik çıkartılmıştır. Eğitim için 742 orta triküspit yetersizliği, 767 yüksek triküspit yetersizliği verileri kullanılmıştır. Test için ise 334 orta triküspit yetersizliği, 313 yüksek triküspit yetersizliği verileri kullanılmıştır. MFKK ile elde edilen 128 veri 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 150 epoch sonunda elde edilen sonuçlar baz alınmıştır.


Sınıflandırma sonuçlarının analizi

Çizelge 4.7'e bakıldığında TY sınıflandırılmasının doğruluk sonuçları görülmektedir. Kesinlik, hassasiyet ve fl-skor sonuçlarına bakıldığında KA, RO, AGA yöntemlerinde 1,00 başarımları elde edilmiştir.

Çizelge 4.7. Triküspit yetmezliği verilerinin sınıflandırma başarımları

Sınıflandırma Yöntemi	Seviye	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	Orta TY	1.00	1.00	1.00
	Yüksek TY	1.00	1.00	1.00
Rastgele Orman	Orta TY	1.00	1.00	1.00
	Yüksek TY	1.00	1.00	1.00
Navie Bayes	Orta TY	0.83	0.95	0.89
	Yüksek TY	0.94	0.79	0.86
Destek Vektör Makinesi	Orta TY	0.98	0.97	0.97
	Yüksek TY	0.97	0.98	0.97
Aşırı Gradyan Artırma	Orta TY	1.00	1.00	1.00
	Yüksek TY	1.00	1.00	1.00
K En Yakın Komşu	Orta TY	0.98	0.94	0.96
	Yüksek TY	0.94	0.98	0.96
Evrişimli Sinir Ağı	Orta TY	1.00	0.99	0.99
	Yüksek TY	0.99	1.00	0.99

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımları Aşırı Gradyan Artırma, RF ve DT yöntemleri ile elde edilmiştir. 6 sınıflandırmada başarımlar %96'nin üzerindedir. En kötü sonuç 0.87 ile Navie Bayes sınıflandırmasında elde edilmiştir. Şekil 4.8'da başarımları tek bir grafikte verilmiştir.



Şekil 4.8. Triküspit Yetersizliğine Ait Verileri için Kullanılan Sınıflandırma Yöntemlerinin Başarımları

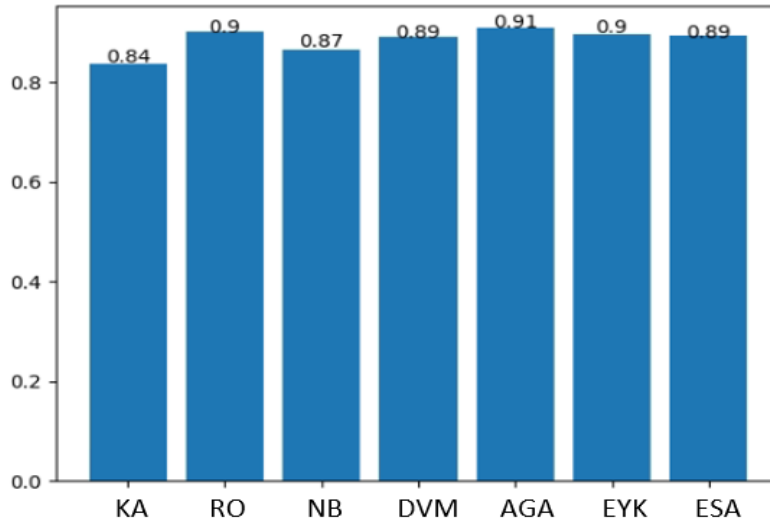
4.1.8. Akciğerlere ait sağlıklı ve hasta ses verilerinin sınıflandırılması

Bölgesel teşhis yapıldıktan sonra akciğerlere ait bir verinin bulunması halinde bu verinin hasta bir bireye mi yoksa sağlıklı bir bireye mi ait olduğu konusunu öğrenmek için eğitilmiş modele verilir. Bu sınıflandırma sonucu eğer hasta ise hastalık tanıma işlemine geçilir. Veri seti oluşturulurken ICHBI veri seti ve multimedya solunum veri tabanından yararlanılmıştır. Ses verileri 2s süreli veriler olarak ayrılmış ve öznitelikleri çıkarılmıştır. Her ses verisinden 128 MFKK özniteliği oluşturulmuş ve eğitilmiştir. Toplamda 16427 tane 128 özniteliğe sahip veri elde edilmiştir. 5992 tane veri sağlıklılardan oluşurken 10433 tane ver hastalardan oluşmaktadır. Eğitimlerin daha doğru sonuç vermesi açısından sağlıklı ses verileri kadar hasta veriler kullanılmıştır. Toplamda 11984 veri eğitimler için ayrılmıştır. Hastalara ait verilerin 4229'u eğitim 1833 tanesi test için kullanılırken sağlıklı kişilere ait verilerin 4159'u eğitim 1763 tanesi test için kullanılmıştır. MFKK ile elde edilen 128 veri 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 300 epoch sonunda elde edilen sonuçlar baz alınmıştır.

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımları Aşırı Gradyan Artırma ve RF yöntemleri ile elde edilmiştir. Çizelge 4.8'e bakıldığında kesinlik, hassasiyet ve F1-skor değerlerinde en yüksek sonuçların AGA'da elde edilmiştir. 2 sınıflandırmada başarımlar %90'nin üzerindedir. En kötü sonuç 0.837 ile Karar Ağacı sınıflandırmasında elde edilmiştir. Şekil 4.9'de başarımların sonuçları tek bir grafikte verilmiştir.

Çizelge 4.8. Akciğere ait hasta ve sağlıklı verilerinin sınıflandırma başarımları

Sınıflandırma Yöntemi	Seviye	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	Hasta	0.83	0.84	0.84
	Sağlıklı	0.84	0.84	0.84
Rastgele Orman	Hasta	0.95	0.85	0.90
	Sağlıklı	0.87	0.96	0.91
Navie Bayes	Hasta	0.93	0.79	0.85
	Sağlıklı	0.82	0.94	0.88
Destek Vektör Makinesi	Hasta	0.96	0.82	0.88
	Sağlıklı	0.85	0.97	0.90
Aşırı Gradyan Artırma	Hasta	0.95	0.86	0.90
	Sağlıklı	0.87	0.96	0.92
K En Yakın Komşu	Hasta	0.94	0.84	0.89
	Sağlıklı	0.86	0.95	0.90
Evrişimli Sinir Ağı	Hasta	0.91	0.87	0.89
	Sağlıklı	0.88	0.92	0.90



Şekil 4.9. Akciğere Ait Hasta ve Sağlıklı Veriler için Kullanılan Sınıflandırma Yöntemlerinin Başarımlar Sonuçları

4.1.9. Akciğer hastalıklarının sınıflandırılması

Bu çalışmada 7 farklı akciğer rahatsızlığı dikkate alınmıştır. Bunlar bronşektazi, bronşiyolit, KOAH, alt solunum yolu enfeksiyonu (ASYE), zatürre (Pnimoni), üst solunum yolu enfeksiyonu (ÜSYE) ve astımdır. Veri seti için multimedya veriseti ve ICHBI veri seti kullanılmıştır. ICHBI veri setindeki astım verilerinin azlığı multimedya veri seti ile giderilmiştir. Veriler 2s olarak bölünmüştür. Bölünme sonucunda 176 bronşektazi, 130 bronşiyolit, 20 ASYE, 370 zatürre, 230 ÜSYE, 8663 KOAH, 844 astım verisi elde edilmiştir. Eğitimde 126 bronşektazi, 87 bronşiyolit, 12 ASYE, 257 zatürre, 176 ÜSYE, 276 KOAH ve 280 astım verisi kullanılmıştır. Tes verilerinde ise 124 KOAH, 120 astım, 113 zatürre, 60 ÜSYE, bronşektazi 51, 43 bronşiyolit, 8 ASYE verisi kullanılmıştır. MFKK ile elde edilen 128 veri 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 300 epoch sonunda elde edilen sonuçlar baz alınmıştır.

Sınıflandırma sonuçlarının analizi

Çizelge 4.9'de sınıflandırmalara ait doğruluk tablosu verilmiştir. Bronşektazi, bronşiyolit, ASTE en iyi sonuçlar Destek Vektör Makinesine aittir. Zatürre sonuçlarında en yüksek sonuç Evrişimli Sinir Ağına Aittir.


Çizelge 4.9. Akciğer hastalık verilerinin sınıflandırılma sonuçlarına ait doğruluk tablosu

Sınıflandırma Yöntemi	Hastalık Türü	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	Bronşektazi	0.84	0.90	0.87
	Bronşiyolit	0.53	0.40	0.45
	ASTE	0.29	0.25	0.27
	Zatürre	0.76	0.74	0.75
	ÜSYE	0.43	0.50	0.47
	Astım	0.88	0.89	0.88
	KOAH	0.86	0.86	0.86
Rastgele Orman	Bronşektazi	0.96	0.96	0.96
	Bronşiyolit	0.90	0.44	0.59
	ASTE	1.00	0.12	0.22
	Zatürre	0.85	0.88	0.86
	ÜSYE	0.62	0.82	0.71
	Astım	0.94	0.95	0.95
	KOAH	0.89	0.93	0.91
Navie Bayes	Bronşektazi	0.78	1.00	0.88
	Bronşiyolit	0.70	0.53	0.61
	ASTE	0.20	0.50	0.29
	Zatürre	0.72	0.86	0.79
	ÜSYE	0.80	0.40	0.53
	Astım	0.84	0.90	0.87
	KOAH	0.87	0.76	0.81
Destek Vektör Makinesi	Bronşektazi	1.00	1.00	1.00
	Bronşiyolit	0.76	0.72	0.74
	ASTE	0.50	0.75	0.60
	Zatürre	0.89	0.88	0.89
	ÜSYE	0.72	0.78	0.75
	Astım	0.97	0.93	0.95
	KOAH	0.93	0.93	0.93
Aşırı Gradyan Artırma	Bronşektazi	1.00	0.98	0.99
	Bronşiyolit	0.84	0.60	0.70
	ASTE	1.00	0.25	0.40
	Zatürre	0.87	0.92	0.89
	ÜSYE	0.69	0.83	0.76
	Astım	0.96	0.94	0.95
	KOAH	0.95	0.97	0.96

Çizelge 4.9. (Devam) Akciğer hastalık verilerinin sınıflandırılma sonuçlarına ait doğruluk tablosu

K En Yakın Komşu	Bronşektazi	0.96	0.96	0.96
	Bronşiyolit	0.76	0.58	0.66
	ASTE	0.80	0.50	0.62
	Zatürre	0.89	0.96	0.93
	ÜSYE	0.77	0.82	0.79
	Astım	0.91	0.98	0.94
	KOAH	0.96	0.89	0.93
	Evrişimli Sinir Ağı	Bronşektazi	0.93	1.00
Bronşiyolit		0.70	0.77	0.73
ASTE		0.00	0.00	0.00
Zatürre		0.90	0.91	0.90
ÜSYE		0.79	0.77	0.78
Astım		0.97	0.94	0.96
KOAH		0.92	0.94	0.93

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımlar 0.888 ile Destek Vektör Makinesine aittir. 5 sınıflandırmada başarımlar %85'in üzerindedir. En kötü sonuç 0.773 ile Navie Bayes sınıflandırmasında elde edilmiştir. Şekil 4.10'de başarımların sonuçları tek bir grafikte verilmiştir.



Şekil 4.10. Akciğere Ait Hasta Verileri Kullanılan Sınıflandırma Yöntemlerinin Başarımların Sonuçları

4.1.10. KOAH sınıflandırılması

KOAH sınıflandırılmasında multimedya veriseti kullanılmıştır. Veri setinde 5 farklı seviyede KOAH verisi bulunmaktadır. Bu çalışmada düşük, orta ve yüksek olmak üzere 3 seviyede ele

alınmıştır. Bu 3 sınıf 7 farklı sınıflandırıcıda sınıflandırılmıştır. 1623 tane düşük, 1812 tane orta, 1973 tane yüksek seviyede KOAH 1s süreli KOAH verileri kullanılmıştır. Eğitim verileri olarak 1147 tane düşük, 1277 tane orta ve 1361 tane yüksek seviyede KOAH verisi ayrılırken test verileri olarak 476 tane düşük, 535 tane orta ve 612 tane yüksek KOAH verisi ayrılmıştır. MFKK ile elde edilen 128 veri 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 300 epoch sonunda elde edilen sonuçlar baz alınmıştır.

Sınıflandırma sonuçlarının analizi


Çizelge 4.10'a bakıldığında KOAH sınıflandırılmasının doğruluk sonuçları görülmektedir. Kesinlik, hassasiyet ve f1-skor sonuçlarına bakıldığında RO yönteminde en iyi sonuç elde edilmiştir.

Çizelge 4.10. KOAH verilerinin sınıflandırma başarımları sonuçları

Sınıflandırma Yöntemi	Seviye	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	Düşük KOAH	0.46	0.45	0.45
	Orta KOAH	0.48	0.52	0.50
	Yüksek KOAH	0.52	0.49	0.51
Rastgele Orman	Düşük KOAH	0.68	0.58	0.62
	Orta KOAH	0.62	0.65	0.64
	Yüksek KOAH	0.68	0.73	0.70
Navie Bayes	Düşük KOAH	0.41	0.58	0.48
	Orta KOAH	0.53	0.46	0.49
	Yüksek KOAH	0.58	0.46	0.51
Destek Vektör Makinesi	Düşük KOAH	0.50	0.48	0.49
	Orta KOAH	0.54	0.54	0.54
	Yüksek KOAH	0.56	0.58	0.57
Aşırı Gradyan Artırma	Düşük KOAH	0.66	0.60	0.63
	Orta KOAH	0.62	0.63	0.63
	Yüksek KOAH	0.67	0.71	0.69
K En Yakın Komşu	Düşük KOAH	0.49	0.60	0.54
	Orta KOAH	0.58	0.51	0.54
	Yüksek KOAH	0.61	0.57	0.59
Evrişimli Sinir Ağı	Düşük KOAH	0.62	0.51	0.56
	Orta KOAH	0.54	0.77	0.63
	Yüksek KOAH	0.71	0.55	0.62

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımları Aşırı Gradyan Artırma ve RF yöntemleri ile elde edilmiştir. 2 sınıflandırmada başarımlar %60'ın üzerindedir.

En kötü sonuç 0.49 ile Karar Ağacı ve Navie Bayes sınıflandırmasında elde edilmiştir. Şekil 4.11'de başarımlar sonuçları tek bir grafikte verilmiştir.



Şekil 4.11. KOAH Verileri Kullanılan Sınıflandırma Yöntemlerinin Başarımlar Sonuçları

4.1.11. Batın sınıflandırılması

Bu bölümde normal ve anormal bağırsak seslerinin sınıflandırılması yapılmıştır. Sınıflandırmada 12 kişiden alınan 4 karın oskültasyon bölge sesi ve internetten alınan anormal sesler (Pixabay, 2022) bulunmaktadır. Sesler 1s olarak bölünmüştür. 612 normal ve 612 anormal ses olmak üzere toplamda 724 ses sınıflandırmada kullanılmıştır. 439 tane anormal ses ve 417 tane normal ses eğitim için kullanılırken 173 tane anormal ve 195 tane normal ses test verilerinde kullanılmıştır. MFKK ile elde edilen 128 veri 16x8 olarak ESA modelinin eğitimi için giriş katmanında verilmiştir. 300 epoch sonunda elde edilen sonuçlar baz alınmıştır.

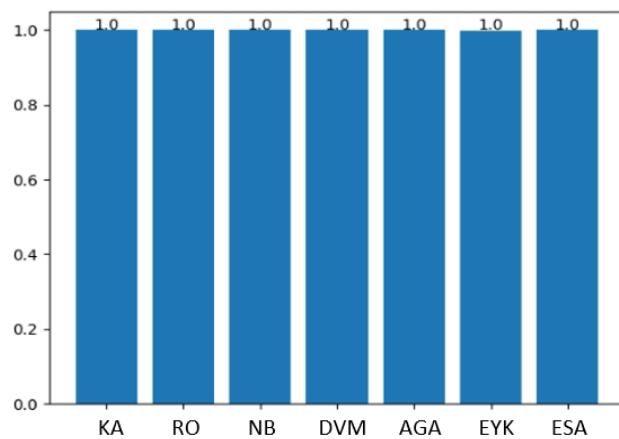
Sınıflandırma sonuçlarının analizi

Çizelge 4.11'e bakıldığında bağırsak sınıflandırılmasının doğruluk sonuçları görülmektedir. Kesinlik, hassasiyet ve f1-skor sonuçlarına bakıldığında En Yakın Komşu analizinde %99 sonuç alınırken kalan sınıflandırma yöntemlerinde normal ve anormal verilerin hepsini doğru tahmin edilmiştir.

Çizelge 4.11. Batın verilerinin sınıflandırma başarımları sonuçları

Sınıflandırma Yöntemi	Durum	Kesinlik	Hassasiyet	F1-skor
Karar Ağacı	Hasta	1.00	1.00	1.00
	Sağlıklı	1.00	1.00	1.00
Rastgele Orman	Hasta	1.00	1.00	1.00
	Sağlıklı	1.00	1.00	1.00
Navie Bayes	Hasta	1.00	1.00	1.00
	Sağlıklı	1.00	1.00	1.00
Destek Vektör Makinesi	Hasta	1.00	1.00	1.00
	Sağlıklı	1.00	1.00	1.00
Aşırı Gradyan Artırma	Hasta	1.00	1.00	1.00
	Sağlıklı	1.00	1.00	1.00
K En Yakın Komşu	Hasta	0.99	0.99	0.99
	Sağlıklı	0.99	0.99	0.99
Evrişimli Sinir Ağı	Hasta	1.00	1.00	1.00
	Sağlıklı	1.00	1.00	1.00

Tüm sınıflandırma yöntemlerinin başarımlarına bakıldığında en yüksek başarımları Aşırı Gradyan Artırma ve RF yöntemleri ile elde edilmiştir. 2 sınıflandırmada başarımlar %60'ın üzerindedir. En kötü sonuç 0.49 ile Karar Ağacı ve Navie Bayes sınıflandırmasında elde edilmiştir. Şekil 4.12'de başarımları tek bir grafikte verilmiştir.



Şekil 4.12. Batın Verileri Kullanılan Sınıflandırma Yöntemlerinin Başarımları Sonuçları

4.2. Donanım

Sağlık çalışanlarının uzaklık, çalışmalarındaki yoğunluk sebepleri ile hastaların yanına gitmekte güçlük çekebilmektedirler. Aynı şekilde hastalar için özellikle yaş ilerledikçe hastaneye gitmek zor olmaktadır. Bu sebeple bu çalışmada giyilebilir donanım ve donanım

kullanımı için bir arayüz tasarımı yapılmıştır. Sağlık çalışanı belirli noktaları hastanın yanına gitmeden dinleyebilecektir. Bu sayede hem sağlık çalışanı hastayı uzaktan dinleyerek hasta yanına gitmesi gereken zamandan başka hastalar için ayırabilecektir.

Donanımın iç kısmına yerleştirilmiş stetoskop başlıklarının iç kısmında yer alan elektret mikrofonlar yarımı ile sesi almaktadır. Ses filtrelenip yükseltildikten sonra raspberry ortamına aktarılır ve TCP/IP protokolü ile arayüze gönderilir. Donanımın vücut üzerindeki görüntüsü Şekil 4.13'te verilmiştir.

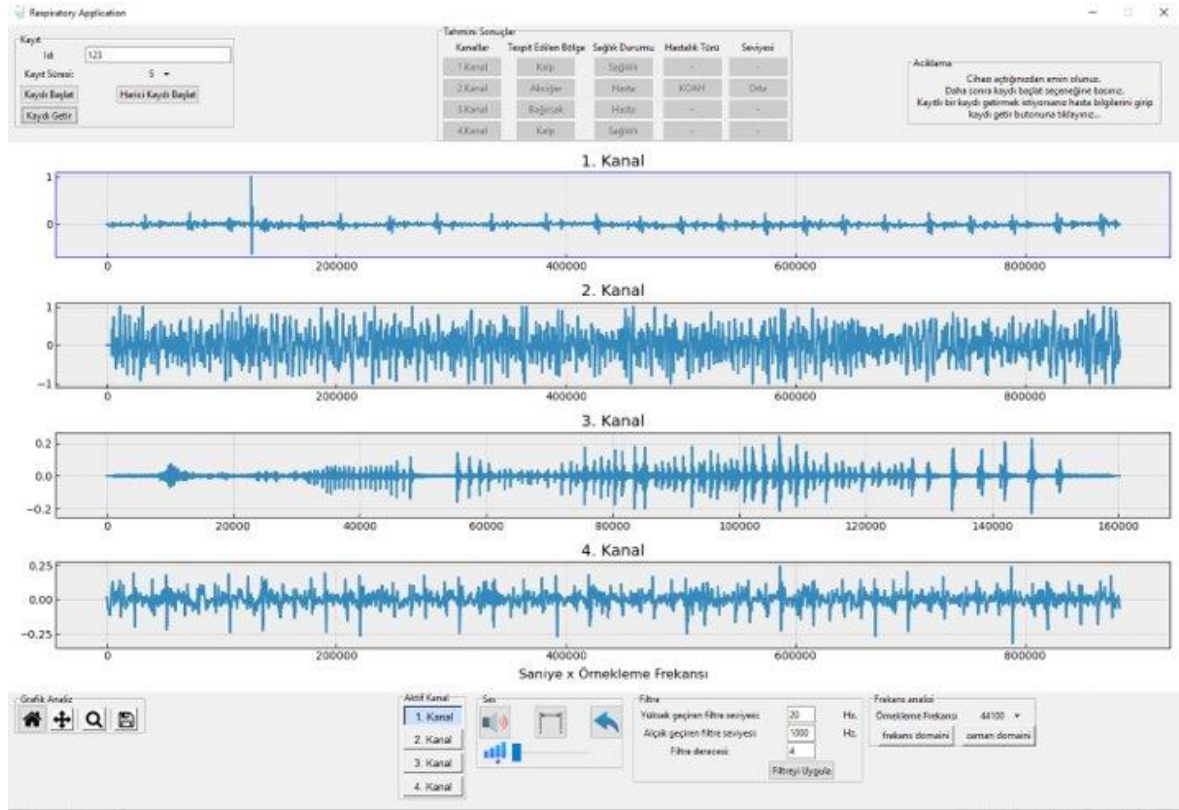


Şekil 4.13. Donanımın Vücut Üzerindeki Görüntüsü

Donanım 4 kanaldan oluşmaktadır. Kanalların yerlerinin değiştirilebilir olması sebebi ile birçok farklı noktadan dinleme yapılarak sağlık çalışanı hasta durumu hakkında daha detaylı bilgiye ulaşabilecek ve tanı koymasını kolaylaştıracaktır. Ayrıca ses verilerinin alınması ile sesin ilk olarak hangi bölgeye ait olduğu, daha sonra hasta veya sağlıklı olduğunun tanı sistemi incelemektir. Eğer hasta ise hangi hastalığa sahip olduğu ve hatta bazı hastalıkların şiddeti hakkında tanıma işlemi yapılabilmektedir. Bu durum sağlık çalışanlarına tanı koyarken yardımcı olacaktır.

Şekil 4.14'te sinyallerin arayüzde görüntülediği bir görsel bulunmaktadır. Bu görselde tahmini sonuçlar bölümüne baktığımızda sistemimiz 1.Kanalda bulunan verinin sağlıklı bir kalp verisi olduğunu söylemektedir. 2. Kanalda bulunan ses sinyalinde Orta şiddette bir KOAH hastalığını

saptamıştır. 3. Kanalda Hasta bir bağırsak verisi bulunurken 4. Kanalda sağlıklı bir kalp verisinin olduğu tahminini yapmıştır.



Şekil 4.14. Arayüzde Sinyallerin Görüntülenmesi

5. SONUÇ VE ÖNERİLER

Günümüzde yapay zekanın önem kazanması ile verilerin önemi artmıştır. Sağlık alanında verilerin düzgün işlenmesi, kaydedilmesi ve etiketlenmesi oldukça önemlidir. Sağlık alanında yapay zeka kullanımı insan sağlığını direkt etkileyeceği için bu alanda alınacak başarılı sonuçlar erken teşhis ve tedaviye olumlu yönde katkı sağlayacaktır.

Bu çalışmada alınan ses verilerinin bölgesel analizinin yanı sıra hastalık analizi de yapılabilmektedir. Hibrit bir sistemin oluşturulduğu tanı sisteminde genelden özele doğru verinin analiz edilmesi sağlanmıştır. 5 farklı veri seti ve 7 farklı sınıflandırma yönteminin kullanıldığı çalışma başarılı sonuçlar vermiştir. Özellikle Aşırı Gradyan Artırma yöntemi birçok sınıflandırmada yüksek sonuç vermiştir. Şekil 4.1’de bulunan tanı sistemi hiyerarşisine bakıldığında ilk aşamada bölge tanısının yapılması gerektiği görülmektedir. eğitim sonuçlarına göre kalp, akciğer ve batın sınıflarının tanımlanmasında AGA yöntemi ile en yüksek fl-skor değeri ve 0.92 başarımlar elde edilmiştir. Bu aşamada belirlenen bölgelere göre normal ve anormal teşhisi yapılmaktadır. Kalpte AGA sınıflandırıcısı, kesinlik, hassasiyet, fl-skor ve başarımda en yüksek sonuçları vermiştir. Akciğerde 0.91 ile AGA sınıflandırıcısı en yüksek başarımları vermiştir. Batın bölgesinde ise tüm sınıflandırıcılarda tam başarımlar sağlanmıştır. Bölgelerde belirlenen hastalık ve sağlık durumundan sonra hastalıkların teşhisi yapılmaktadır. Kalbe ait 6 farklı anormal ses sınıfı sınıflandırmasında 0.96 başarımla ile AGA sınıflandırıcısında en yüksek başarımla ulaşılmıştır. Kesinlik, hassasiyet ve fl-skor değerleri incelendiğinde MD teşhisinde RO sınıflandırıcısı en iyi değerleri verirken diğerlerinde AGA sınıflandırıcısı en yüksek değerleri vermiştir. Hiyerarşinin son aşamasında hastalık şiddetinin tespitine bakılmaktadır. AD ve MY şiddetlerinin tespitinde AGA sınıflandırıcısı kesinlik, hassasiyet, fl-skor ve başarımlar değerlerinde en yüksek sonucu vermiştir. MD ve TY hastalıklarının şiddetinin belirlenmesinde ise KA, RO ve AGA sınıflandırıcılarından 0.99 başarımlar elde edilmiştir. KOAH verilerinin sınıflandırılmasında ise en yüksek sonuç 0.66 ile RO sınıflandırıcısına aittir. MFKK ile elde edilen 128 öznitelik ile yapılan eğitimlerin sonuçlarına bakıldığında bu katsayıların vücut sesleri için avantajlı olduğu kanısına varılmıştır. Yanlış etiketlenmiş veya etiketlenmemiş verilerin de oluşumunu önlemek için kurulan tanı sistemimiz hangi seviyede hata olduğunun bilinmesini sağlayabilmektedir.

Çalışmada donanım ve arayüz oluşturularak sağlık çalışanları için kullanımı rahat bir analiz

sistemi oluşturulmuştur. Hasta yanına gitmeden dinleme işleminin yapılabilmesi sağlanmıştır.

Gelecek çalışmalar için önerimiz hastalık şiddetlerinin analiz etmeye yardımcı yeni veri setlerinin oluşturulmasıdır. Bu sayede hastalık teşhisinin yanı sıra aşamaları da detaylı bir şekilde öğrenilmiş olacaktır. Ayrıca bu çalışmanın devamı olarak giyilebilir donanımı daha küçük komponentler ile boyutunu düşürerek rahat bir kullanım sağlanabilir. Tahmini teşhis masaüstü uygulama yerine mobil uygulamalardan analiz edilerek kullanım kolaylığının daha da artırılması sağlanabilir. Sağlık alanında karar destek sistemlerinin artırılması sağlık çalışanları için faydalı olacaktır. Bunun için oskültasyon ile karar verilebilecek tüm hastalıklarının ses verilerinin bulunduğu bir veri seti oluşturulmalı ve bunun teşhisi için taşınabilir donanımların üretimi önem arz etmektedir.

KAYNAKLAR

- Abella M., Formolo J. (1992) Comparison of Acoustic Properties of Six Popular Stethoscopes, *J Acoust Soc Am*, vol. 91(4), p. 2224-2228.
- Altan, G., Kutlu, Y., Garbi, Y., Pekmezci, A. Ö., Nural, S. (2017). Multimedia Respiratory Database (RespiratoryDatabase@TR): Auscultation Sounds and Chest X-rays. *Natural and Engineering Sciences*, 2(3), 59–72.
- Arslan, A., Yildiz, O. (2018). Automated auscultative diagnosis system for evaluation of phonocardiogram signals associated with heart murmur diseases. *Gazi University Journal of Science*, 31(1), 112–124.
- Arts, L., Lim, E. H. T., Van De Ven, P. M., Heunks, L., Tuinman, P. R. (2020), The diagnostic accuracy of lung auscultation in adult patients with acute pulmonary pathologies: A meta-analysis. *Sci. Rep.* 10, 7347.
- Athanazio, R. (2012). Airway disease: Similarities and differences between asthma, COPD and bronchiectasis. *Clin. (Sao Paulo)* 67, 1335–1343.
- Baid, H. (2009). A critical review of auscultating bowel sounds. *Abdominal Assesment*. Vol 18. no 18.
- Balli, O., Kutlu, Y. (2020). Effect of Deep Learning Feature Inference Techniques on Respiratory Sounds. *Akıllı Sistemler ve Uygulamaları Dergisi*, 3(2), 134–137.
- Balli, O., Kutlu, Y. (2021). Regional Signal Recognition of Body Sounds. *Journal of Intelligent Systems with Applications*, 4(2), 157–160.
- Barry, W. H. (2004). *Heart Physiology From Cell to Circulation*, 4th ed.. Circulation (C. 110).
- Barua, P.D., Karasu, M., Kobat, M.A., Balık, Y., Kivrak, T., Baygin, M., Dogan, S., Demir, F.B., Tuncer, T., Tan, R.S., Acharya, U.R. (2022). An accurate valvular heart disorders detection model based on a new dual symmetric tree pattern using stethoscope sounds. *Comput Biol Med.* 2022 Jul;146:105599. doi: 10.1016/j.combiomed.2022.105599.
- Berrueta L.A., Alonso-Salces R.M., Héberger K. (2007). Supervised pattern recognition in food analysis. *J Chromatogr A.* 2007 Jul 27;1158(1-2):196-214. doi: 10.1016/j.chroma.2007.05.024. Epub 2007 May 13. PMID: 17540392.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Cannon, WB. (1905). Auscultation of the rhythmic sounds produced by the stomach and intestines. *Am J Physiol*;14:339–353.
- Ovacık, C. (2014). Kablosuz İletişim Kullanılarak Kalp Seslerinin Gerçek Zamanda Depolanması, Görüntülenmesi Ve Analizi. (Yüksek Lisans Tezi). (<http://hdl.handle.net/11527/15575>)
- Chauhan, S., Wang, P., Sing Lim, C., Anantharaman, V. (2008). A computer-aided MFCC-based HMM system for automatic auscultation. *Computers in Biology and Medicine*, 38(2), 221–233.

- Chen, T., and Guestrin, C. (2016). XGBoost. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '16. doi:10.1145/2939672.2939785
- Çınar, O. Y. (2019). A Multi-Channel Wireless Respiratory And Heart Sounds Acquisition And Processing System. (Yüksek Lisans Tezi) Boğaziçi University.
- Degtyarenko, I., Slyusarenko, K., Omelchenko, A., Riabov, V., Chyzyk, S. (2019). Low-power Continuous Heart and Respiration Rates Monitoring on Wearable Devices. In Proceedings of the ICASSP. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Brighton, UK, 12–17 May 2019.
- Dieffenderfer, J., Goodell, H., Mills, S., Mcknight, M., Yao, S., Lin, F., Beppler, E., Bent, B., Lee, B., Misra, V., Zhu, Y., Oralkan, O., Strohmaier, J., Muth, J., Peden, D., Bozkurt, A. (2016). Low-Power Wearable Systems for Continuous Monitoring of Environment and Health for Chronic Respiratory Disease. IEEE J. Biomed. Health Inform. 2016, 20, 1251–1264.
- Düzgün, Ö. O. (2007). Kalp Seslerinin Gerçek Zamanda Algılanması Ve Bilgisayarda Analiz Edilmesi. (Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi.
- Earis, J., and Cheetham, B. (2000). Future perspectives for respiratory sound research. European Respiratory Review. 10. 641-646.
- Emeksiz, Z. Ş., Bostancı, İ. (2018). Lung: Is there anyone who hears me?. Guncel Pediatri, 16(3), 79–84.
- George, U. Z., Moon, K. S., and Lee, S. Q. (2021). Extraction and Analysis of Respiratory Motion Using a Comprehensive Wearable Health Monitoring System.
- Gu, Y., Lim, H. J., Moser, M. A. J. (2010). How Useful Are Bowel Sounds in Assessing the Abdomen? Digestive Surgery. 27:422–426.
- Gupta, B. and Tiwari, S., (2014) Brain Tumor Detection using Curvelet Transform and Support Vector Machine, International Journal of Computer Science and Mobile Computing, vol. 3, no. 4, pp. 1259-1264, April 2014, ISBN 2320-088X.
- Güraksın, G. E. (2009). Normal Ve Normal Olmayan Kalp Seslerinin Yapay Sinir Ağları İle Sınıflandırılması. e-Journal of New World Sciences Academy, 4(10), 2176–2181.
- Haspolat, Y. K., Aktar, F., Yolbaş, İ. (2016). Adolesanda Beslenme. Cinius Yayınları.
- Hill, M. (2019). Respiratory System - Upper Respiratory Tract. UNSW Embryology, (January).
- Hossin M., and Sulaiman M.N., (2015). A review on evaluation metrics for data classification evaluations. International Journal of Data Mining & Knowledge Management Process 5.2 (2015): 1.
- İnternet: Texas Heart Institute, Heart Sounds and Murmurs, https://web.archive.org/web/20101226131759/http://texasheart.org/education/cme/explore/events/eventdetail_5469.cfm, Son Erişim Tarihi: 26.12.2022.
- İnternet: Pixabay, Stomach, <https://pixabay.com/sound-effects/search/stomach/>, Son Erişim Tarihi: 26.12.2022.

- Jarvis, C. (2008). *Physical Examination and Health Assessment*. 5th edn. Saunders Elsevier, St Louis.
- Jayalakshmy, S., Priya, B. L., Kavya, N. (2020). CNN based Categorization of respiratory sounds using spectral descriptors. *Proceedings of the 2020 IEEE International Conference on Communication, Computing and Industry 4.0, C2I4 2020*.
- Karasekreter, N. 2009. S1 Ve S2 Kalp Seslerinin Ayrıştırılmasında Ve Teşhisinde Sayısal Analiz Yöntemlerinin Uygulanması (Yüksek Lisans Tezi). Afyon Kocatepe Üniversitesi.
- Kemaloğlu, S. & Kara, S. (2002). Ekg İşaretleri İle Kalp Seslerinin Eşzamanlı Alınması İçin Ölçüm Düzenegi . *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi* , 18 (1) , 28-33 .
- Lee, S. H., Kim, Y. S., Yeo, M. K., Mahmood, M., Zavanelli, N., Chung, C., Heo, J. Y., Kim, Y., Jung, S. S., & Yeo, W. H. (2022). Fully portable continuous real-time auscultation with a soft wearable stethoscope designed for automated disease diagnosis. *Science Advances*, 8(21), eabo5867. <https://doi.org/10.1126/sciadv.abo5867>
- Li, W., Yin, Y., Quan, X., Zhang, H. (2019). Gene Expression Value Prediction Based on XGBoost Algorithm. *Front Genet.* 2019 Nov 12;10:1077. doi: 10.3389/fgene.2019.01077. PMID: 31781160; PMCID: PMC6861218.
- Li, X., Zhong, L., Luo, L., Zhu, S., Ni, K., Zhou, Q., ... Wang, X. (2019). Synchronization Control Of Pulsatile Ventricular Assist Devices By Combination Usage Of Different Physiological Signals. *Computer Assisted Surgery*, 24(sup1), 105–112.
- Liu, R., Cai, S., Zhang, K., Hu, N. (2019). Detection of Adventitious Respiratory Sounds based on Convolutional Neural Network. *ICIIBMS 2019 - 4th International Conference on Intelligent Informatics and Biomedical Sciences*, 298–303.
- Liu, J., Yin, Y., Jiang, H., Kan, H., Zhang, Z., Chen, P., Zhu, B., & Wang, Z. (2018). Bowel Sound Detection Based on MFCC Feature and LSTM Neural Network. *2018 IEEE Biomedical Circuits and Systems Conference (BioCAS)*, 1-4.
- Maganti, K., Rigolin, V. H., Sarano, M. E. Bonow, R. O. (2010). Valvular heart disease: Diagnosis and management. *Mayo Clin. Proc.* 85, 483–500.
- Maglogiannis, I., Loukis, E., Zafirooulos, E., Stasis, A. (2009). Support Vectors Machine-based identification of heart valve diseases using heart sounds. *Computer Methods and Programs in Biomedicine*, 95(1), 47–61.
- Messner, E., Fediuk, M., Swatek, P., Scheidl, S., Smolle-Jüttner, F. M., Olschewski, H., Pernkopf, F. (2020). Multi-channel lung sound classification with convolutional recurrent neural networks. *Computers in Biology and Medicine*, 122(May), 103831.
- Mitchell, T., (1997). *Machine Learning*, McGraw Hill, New York,
- Nath, M., Srivastava, S., Kulshrestha, N., Singh, D. (2021). Detection and localization of S1 and S2 heart sounds by 3rd order normalized average Shannon energy envelope algorithm. *Proc. Inst. Mech. Eng. H* 235, 615–624.
- Öztaş, A. S., Türk, E., Uluşar, Ü. D., Canpolat, M., Yaprak, M., Kazanır, S., Ögünç, G., Doğru,

- V., Canagir, O. C. (2015). Bağırsak Seslerinin Otomatik Tespiti İçin Biyoakustik Sensör Sistemi. 19th National Biomedical Engineering Meeting.
- Parveen, & Singh, A. (2015). Detection of brain tumor in MRI images, using combination of fuzzy c-means and SVM. 2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN). doi:10.1109/spin.2015.7095308
- Polat, H. (2006). PC Tabanlı Çok Kanallı Bir Elektronik Steteskop Tasarımı ve Gerçekleştirilmesi.(Doktora Tezi). Gazi Üniversitesi.
- Qiao, Y., Wang L. ve Tao, X. (2021). A Bowel Sound Detection Method Based on a Novel Non-speech Body Sound Sensing Device. in 2021 IEEE 45th Annual Computers, Software, and Applications Conference (COMPSAC), Madrid, Spain, 2021 pp. 785-793.
- Ranta, R., Louis-Dorr, V., Heinrich, C., Wolf, D., Guillemin, F. (2004). Principal component analysis and interpretation of bowel sounds. Proceedings of the 26th Annual International Conference of the IEEE EMBS.
- Reichert, S., Gass, R., Brandt, C., Andrès, E. (2008). Analysis of Respiratory Sounds: State of the Art. Clinical medicine. Circulatory, respiratory and pulmonary medicine, 2, CCRPM.S530.
- Rizal, A., Hidayat, R., Nugroho, H. A. (2017). Entropy measurement as features extraction in automatic lung sound classification. 2017 International Conference on Control, Electronics, Renewable Energy, and Communications, Proceedings, 2017-Janua, 93–97.
- Rocha, B.M., Filos, D., Mendes, L., Serbes, G., Ulukaya, S., Kahya, Y.P., Jakovljevic, N., Turukalo, T.L., Vogiatzis, I.M., Perantoni, E., Kaimakamis, E., Natsiavas, P., Oliveira, A., Jácome, C., Marques, A., Maglaveras, N., Paiva, P.R, Chouvarda, I., de Carvalho, P. (2019). An open access database for the evaluation of respiratory sound classification algorithms. *Physiol Meas.* 2019 Mar 22;40(3):035001. doi: 10.1088/1361-6579/ab03ea.
- Schroeder, D., Gillanders, L., Mahr, K. ve Hill, G. L. (1991). Effects of Immediate Postoperative Enteral Nutrition on Body Composition, Muscle Function, and Wound Healing. *J. Parenter. Enter. Nutr.*, c. 15, sayı 4, ss. 376–383.
- Sitaula, C., He, J., Priyadarshi, A., Tracy, M., Kavehei, O., Hinder, M., Withana, A., McEwan, A., & Marzbanrad, F. (2022). Neonatal bowel sound detection using Convolutional Neural Network and laplace hidden semi-markov Model. *IEEE/ACM Transactions on Audio Speech and Language Processing*, 30, 1853-1864. <https://doi.org/10.1109/TASLP.2022.3178225>
- Springer, D. B., Zühlke, L. J., Mayosi, B. M., Tarassenko, L. and Clifford, G. D. (2014) .Mobile phone-based rheumatic heart disease diagnosis. *Appropriate Healthcare Technologies for Low Resource Settings (AHT 2014)*, 2014, pp. 1-4, doi: 10.1049/cp.2014.0761.
- Tamas, W., Notton, G., Paoli, C., Nivet, M. L., Voyant, C. (2016). Hybridization of air quality forecasting models using machine learning and clustering: An original approach to detect pollutant peaks. *Aerosol and Air Quality Research*, 16(2), 405–416.
- Tseng, Y. L., P., Ko, Y., Jaw, F. S. (2012). Detection of the third and fourth heart sounds using Hilbert-Huang transform. *Biomed. Eng. Online* 11, 8.

- Uysal, H. (2014). Gömülü Bilgisayarlı Elektronik Stetoskop Yapımı. for Iris Recognition. *International Journal of Computer Science and Information Technology* Vol. 10, No. 2, Corpus ID: 51772790.
- Watson, W. C., Knox, E. C. (1967). Phonoenterography: the recording and analysis of bowel sounds. *GUT*. 8, 88.
- Windsor, A. C. J., Kanwar, S., Li, A. G. K., Barnes, E., Guthrie, J. A., Spark, J. I., Welsh, F., Guillou, P. J., ve Reynolds, J. V. (1998). “Compared with parenteral nutrition, enteral feeding attenuates the acute phase response and improves disease severity in acute pancreatitis”, *Gut*, c. 42, sayı 3, ss. 431–435.
- Zhao, K., Jiang, H., Yuan, T., Zhang, C., Jia, W., and Wang, Z. (2020). A CNN Based Human Bowel Sound Segment Recognition Algorithm with Reduced Computation Complexity for Wearable Healthcare System. 1-5. 10.1109/ISCAS45731.2020.9180432.



DİZİN

A

Akciğer · 10, 11, 12, 16
 aort darlığı · 17, 21, 45, 47
 aort yetersizliği · 17, 21, 45
 Arayüz · 38, 39
 Aşırı gradyan artırma · 24

B

başarım · ix, 16, 23, 42, 44, 45,
 46, 47, 48, 49, 50, 51, 52, 53,
 54, 56, 57, 58, 59

D

Destek vektör makineleri · 26
 Devre · 34

E

Evrişimli Sinir Ağı · xii, 27

F

Filtre · 28, 29, 33, 37

K

K en yakın komşu · 23
 Kalp · 3, 4, 5, 6, 8, 33
 Karar ağacı · 16, 23
 Katman · 29, 30
 KOAH · viii, ix, xi, 12, 13, 16,
 21, 40, 54, 55, 56, 57, 58, 61

M

MFKK · 16, 22, 64
 mitral darlığı · 17, 21, 45, 49
 mitral yetersizliği · 17, 21, 45, 50

N

Navie bayes · 27

O

Oskültasyon · iv, 1, 3, 4, 10, 20

Ö

Öznelik · 22

P

Pulmoner Kapak Darlığı · 21

R

Raspberry · 36, 37, 38
 Rastgele orman · 23

S

sensör · 16, 18

T

Triküspit Yetersizliğinden · 21



TEKNOVERSİTE



teknoversite **AYRICALIĞINDASINIZ**

İSTE

