



**YENİDEN ÖRNEKLEME VE MAKİNE ÖĞRENİMİ TEKNİKLERİ İLE
SOLUNUM SESLERİNİN OTOMATİK SINIFLANDIRILMASI**

Hüseyin Cihad GÜLER

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2021

ETİK BEYAN

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

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

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

Hüseyin Cihad GÜLER

22/06/2021

YENİDEN ÖRNEKLEME VE MAKİNE ÖĞRENİMİ TEKNİKLERİ İLE SOLUNUM SESLERİNİN OTOMATİK SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

Hüseyin Cihad GÜLER

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2021

ÖZET

İnsan akciğerlerinden yayılan solunum sinyalleri, bir hastanın akciğerlerinin sağlık durumu hakkında hayati ve belirleyici bilgiler verir. Geleneksel klinik yöntemler, profesyonel göğüs hastalıkları uzmanlarının bu tür sinyalleri doğru şekilde teşhis etmesini gerektirir. Bilgisayar destekli tanım sistemleri bu alanda sıklıkla kullanılmaktadır. Ancak Bilgisayar Destekli Tanım sistemlerinin yüksek başarımlar için yeterli miktarda veri kritik öneme sahiptir. Önerilen bu çalışmada, yeniden örneklenmiş solunum ses verilerinden normal/anormal sınıflandırması için otomatik bir tanı sistemi önerilmiştir. Öncelikle, yeniden örneklenmiş ses verilerinden 200'den fazla ses özelliği çıkarımı yapılmış, ardından öznitelik seçim yapılarak tahmin modeline sunulmuştur. Tahmin modelleri için k-En Yakın Komşu, Destek Vektör Makinesi, Naive Bayes, Karar Ağacı ve Rastgele Orman gibi geleneksel Makine Öğrenmesi modelleri kullanılmıştır. Her bir sınıflandırma yöntemi için 10-Kat Çapraz Geçerleme yapılmış, %93-%95 arasında sonuçlar elde edilmiştir.

Bilim Kodu : 92431
Anahtar Kelimeler : Solunum ses analizi, ses analizi, denetimli sınıflandırma, makine öğrenmesi
Sayfa Adedi : 47
Danışman : Doç. Dr. Oktay Yıldız

AUTOMATIC CLASSIFICATION OF RESPIRATORY SOUNDS WITH
RESAMPLING AND MACHINE LEARNING TECHNIQUES

(M. Sc. Thesis)

Hüseyin Cihad GÜLER

GAZİ UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2021

ABSTRACT

Respiratory signals emitted from human lungs provide vital and decisive information about the health status of a patient's lungs. Traditional clinical methods require professional pulmonologists to accurately diagnose such signals. Computer aided identification systems are frequently used in this field. However, sufficient data is critical to the high performance of Computer Aided Identification systems. In this proposed study, an automatic diagnostic system for normal/abnormal classification from resampled respiratory sound data is proposed. First, more than 200 sound features were extracted from the resampled sound data, and then the feature was selected and presented to the prediction model. Traditional Machine Learning models such as k-Nearest Neighbor, Support Vector Machine, Naive Bayes, Decision Tree and Random Forest are used for prediction models. For each classification method, 10-fold Cross Validation was performed and results between 93% and 95% were obtained.

Science Code : 92431
Key Words : Breathing sound analysis, sound analysis, supervised classification, machine learning
Page Number : 47
Supervisor : Assoc. Prof. Dr. Oktay YILDIZ

TEŞEKKÜR

Çalışmam boyunca değerli fikirlerini ve yardımını esirgemeyen danışman hocam sayın Doç. Dr. Oktay YILDIZ'a teşekkürü borç bilirim. Yüksek lisans eğitimi almamda beni destekleyen ve motive eden Havelsan A.Ş.'e teşekkür ederim. Ayrıca her konuda beni destekleyen, her zaman yanımda olan annem Suna GÜLER'e ve babam Mahmut GÜLER'e teşekkür ederim. Ayrıca tez çalışmamı yaparken yapmış olduğu fedakarlık ve vermiş olduğu emekler ile bana güç veren biricik eşim Özge GÜLER'e teşekkür ederim.

Bu çalışmadaki solunum verileri, Hacettepe Üniversitesi Girişimsel Olmayan Klinik Araştırma Etik Kurulu tarafından GO18/631-45 Karar No ile onaylı proje kapsamında toplanmış, sonrasında aynı veriler 2021/13-79 Karar no ile bu tezde açıklanan yöntemlerle tekrar kullanılmıştır. Verileri toplayan ve koordinasyonu sağlayan tüm araştırmacılara ve kullanımına onay veren Hastalara teşekkür ederiz.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	x
ŞEKİLLERİN LİSTESİ.....	xi
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI	3
3. GENEL BİLGİLER	7
3.1. Solunum Sistemi	7
3.2. Solunum Sistemi Hastalıklarının Teşhis Aşamaları.....	8
3.3. Solunum Sesleri	9
3.3.1. Normal solunum sesleri	9
3.3.2. Anormal solunum sesleri	10
3.4. Solunum Sistemi Hastalıkları.....	11
3.4.1. Astım	11
3.4.2. Kronik obstrüktif akciğer hastalıkları (KOAH).....	12
3.4.3. Akut bronşit	12
3.4.4. Bronşiolit	13
3.4.5. Sarkoidoz	13
3.4.6. Konjestif kalp yetmezliği.....	13
3.4.7. Pnömoni.....	13
3.4.8. Atelektazi.....	14

	Sayfa
3.4.9. Bronşektazi	14
3.4.10. İdiyopatik pulmoner fibrozis (İPF)	14
3.4.11. Akciğer ödemi	15
3.4.12. Amfizem	15
4. BİLİMSEL ARKA PLAN.....	17
4.1. Ses Verisinin Özellikleri	17
4.1.1. Zaman domaini	17
4.1.2. Frekans Domaini.....	18
4.1.3. Cepstrum domain.....	19
4.1.4. Derin öznitelikler	20
4.1.5. Resim tabanlı öznitelikler	21
4.1.6. Seyreklik tabanlı öznitelikler	21
4.1.7. Dalga tabanlı öznitelikler.....	22
4.2. Özellik Çıkarımı.....	22
4.3. Özellik Seçimi	22
4.4. Makine Öğrenmesi Yöntemleri.....	23
4.4.1. Karar ağacı.....	23
4.4.2. K-en yakın komşu (KNN)	25
4.4.3. Naive bayes.....	26
4.4.4. Rastgele orman sınıflandırıcısı	27
4.4.5. Destek vektör makinesi	27
5. AKCİĞER SES ANALİZİ İLE HASTALIK TESPİTİ.....	29
5.1. Veri Seti	29
5.2. Yeniden Örnekleme ile Veri Oluşturma	32
5.3. Özellik Çıkarımı.....	33
5.4. Özellik Seçimi	34

	Sayfa
5.5. Sınıflandırıcı Ön İşlemleri ve Doğrulama Kriterleri	35
6. DENEYSEL SONUÇLAR VE İRDELEME	37
7. SONUÇ VE ÖNERİLER	41
KAYNAKLAR	43
ÖZGEÇMİŞ	47



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 5.1. Deneysel çalışmanın uygulandığı veri setleri	31
Çizelge 6.1. Sınıflandırma yönteminin doğruluk değerleri ve çapraz doğrulama değerleri.....	37
Çizelge 6.2. Sınıflandırma yöntemlerinin kesinlik değerleri	37
Çizelge 6.3. Sınıflandırma yöntemlerinin duyarlılık değerleri	38
Çizelge 6.4. Sınıflandırma yöntemlerinin fl-ölçüm değerleri	38
Çizelge 6.5. Karar ağacı karışıklık matrisi.....	38
Çizelge 6.6. KNN karışıklık matrisi	39
Çizelge 6.7. Naive Bayes karışıklık matrisi.....	39
Çizelge 6.8. Rastgele Orman karışıklık matrisi	39
Çizelge 6.9. DVM karışıklık matrisi.....	39
Çizelge 6.10. Her faz için 10-çapraz doğruluk değerleri	40

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Solunum döngüsü	7
Şekil 3.2. Akciğer sesleri	9
Şekil 4.1. 4 farklı öznelik içimn 3 farklı sınıfın tespitini örnekleyen karar ağacı modeli örneği	24
Şekil 4.2. KNN 3 sınıftan oluşan örnek gösterimi	26
Şekil 4.3. Destek vektör makineleri genel yapısı.....	28
Şekil 5.1. Sistemin blok şeması	29
Şekil 5.2. Toraks bölgesinin insan vücudundaki konumu.	30
Şekil 5.3. Python librosa kütüphanesi ile normal, ral ve ronküs seslerinin waveplot görünümü	30
Şekil 5.4. Python numpy kütüphanesi ile normal, ral ve ronküs seslerinin fast fourier transform görünümü.....	30
Şekil 5.5. Python librosa kütüphanesiyle çıkarılmış pyplot ile görselleştirilmiş normal, ral ve ronküs seslerinin görünümü.....	31
Şekil 5.6. Python librosa ile normal, ral, ronküs spectrogram görünümü.....	31
Şekil 5.7. Normal, ral ve ronküs sesler için sırasıyla gerçek veri, pitch shift ve time shift verilerinin waveform görseli.....	32
Şekil 5.8. Normal, ral ve ronküs sesler için sırasıyla gerçek veri, pitch shift ve time shift verilerinin spectrogram görseli.	33
Şekil 5.9. jAudio kullanıcı arayüzü.....	34
Şekil 5.10. Karışıklık matrisi	35

SİMGELER VE KISALTMALAR

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

Simgeler	Açıklamalar
Σ	Genel Toplam Operatörü
Kısaltmalar	Açıklamalar
AD	Attach, Delay
ADSR	Attach, Delay, Sustain, Release
ANN	Artificial Neural Network
CART	Classification and Regression Trees
CELP	Code Exited Linear Prediction
CNN	Convolutional Neural Network
DN	Doğru Negative
DP	Doğru Pozitive
DVM	Destek Vektör Makinesi
EKG	Elektrokardiyografi
EMG	Elektromiyografi
EMS	Envelope Modulation Spectrum
FF	Fundamental Frequency
FFT	Fast Fourier Transform
GDF	Group Delay Function
GFCCs	Greenwood Function Cepstral Coefficients
GMM	Gaussian Mixture Model
GTCCs	Gammatone Cepstral Coefficients
KNN	K-Nearest Neighbor
KOAH	Kronik Obstrüktif Akciğer Hastalığı
LAT	Log Attack Time
LBP	Local Binary Patterns
LDA	Linear Discriminant Analysis
LPC	Linear Predictive Coding

Kısaltmalar	Açıklamalar
LSF	Linear Spectral Frequency
LTAS	Long-term Average Spectrum
MFCC	Mel-frequency cepstral coefficient
MSAF	Method of Selection of Amplitudes of Frequency
OBSC	Octave Based Spectral Contrast
PLP	Perceptual Linear Prediction
RASTA-PLP	Relative-Spectral Perceptual Linear Prediction
SMOFS	Shortened Method of Frequencies Selection
SPSF	Stereo Panning Spectrum Feature
STFT	Short Time Fourier Transform
WAV	Waveform Audio File Format
YN	Yanlış Negative
YP	Yanlış Pozitive
ZCR	Zero Crossing Rate

1. GİRİŞ

Yapay öğrenme yöntemleri toplanmış veriler üzerinde inceleme yaparak yeni veriler için uygun model oluşturmayı amaçlamaktadır. Böylece veriler istenilen bilgiye ulaşmak için anlamlı hale getirilmiş olur. Günümüzde birçok alanda karar verme aşamasında yapay öğrenme yöntemleri kullanılmaktadır. Bu alanlara görüntü işleme, ses işleme, askeriye ve tıp örnek olarak verilebilir.

Yapay öğrenme yöntemleri ile hastalıklar için ön teşhis günümüzde yaygın olarak araştırılan konuların başında gelmektedir. Geliştirilen sistemler sayesinde doktorların kararsız kaldığı çeşitli zorluklardaki hastalık tiplerine tanı koymak için kara destek sistemleri oluşturulmaktadır.

Solunum sesleri, insanın nefes alışverişi yaptığı anda hava basıncında meydana gelen değişim ile iç dokularda titreşimler meydana getirmesi nedeniyle oluşur ve göğüs duvarında meydana gelen titreşim ile belirginleşir [1]. Akciğerler ile göğüs duvarı arasında bulunan katmanlardan dolayı bu sesler insan kulağı ile duyulamayacak kadar zayıflamaktadır. Bu nedenle bu seslerin duyulması için stetoskop kullanılmaktadır. Akciğer seslerini dinleme tekniğine de oskültasyon denir. Stetoskoplar, oskültasyon prosedürü için vazgeçilmez kabul edilir. Oskültasyon, ile hastanın akciğerlerini dinlemek belirli kurallar dizini ile gerçekleştirilir. Bu kurallar ile hastanın akciğerlerinden gelen sesleri duyabilmek ve ayırt edebilmek için bir disiplin oluşturulur. Oluşturulan bu kuralların uygulanması belirli bir uzmanlık gerektirdiği için bu disipline sahip olan yetkinlikte doktorun olmaması sorun teşkil etmektedir. Akciğer seslerinin anlamlarının bilinmesiyle erken teşhise olanak sağlanmakta ve gerekli tedavi yöntemleri ile hastalık fazlaca ilerlemeden hastanın sağlığına kavuşma ihtimali artmaktadır. Fakat akciğer seslerinin stetoskop ile dinlenerek yorumlanması için uzman deneyimine ihtiyaç vardır.

Akciğer sesleri üzerinden yapılan incelemelerle, Parkinson, astım, hiper tansiyon, bronşit, amfizem, tüberküloz ve pnömoni gibi birçok rahatsızlığın erken tanısı yapılabilmektedir.

Oskültasyon aşamasında kullanılan elektronik stetoskoplar aracılığı ile göğüs duvarının ve sırt bölgesinin geçmişten gelen tecrübelerle belirlenmiş farklı noktaları üzerinden solunum eylemine ait ses verisi alınarak, kayıt altına alınabilmektedir. Fakat elektronik stetoskoplar solunum eylemine ait ses verisini kayıt ederken vücut üzerindeki konumlarına göre farklı

patalojik sesleri de gürültü olarak alabilmektedir. Bu bilgi ışığında toplanan ses kayıtlarının kayıt aşamasında veya kayıt sonrasında gürültüden arındırarak şekilde kontrol veya ön işlem uygulanması sınıflandırma işlemini güçlendirecektir. Ayrıca ayrıştırılması gereken solunum seslerinin tespiti tek bir solunum döngüsü ile anlaşıldığı durumlar için her ses verisi solunum döngülerine ayrılarak daha fazla veri üzerinde çalışma yapılabilecek veri kümesi oluşturulabilir.

Bu çalışmada sağlıklı bireye ait normal solunum sesi ve akciğer ek seslerinden raller ve ronküs sınıflarına ait hasta bireylerden toplanmış 3 farklı sınıf içeren 3 farklı veri seti kullanılmıştır. Hastalıklı bireylere ait akciğer ek seslerinden raller sınıfı ince, orta ve kalın raller ayrımı yapılmadan bir sınıf olarak kullanılmıştır. İnce ral alanında uzman hekimlerce incelendiğinde patlayıcı yüksek perdeli bir ses olarak ifade edilir. Bir hasta için kayıt altına alınan solunum sesinde her bir solunum döngüsünde tekrarladığı görülmektedir. Bu ses hasta öksürme veya derin nefes alma eylemi sonrasında da aynı kalmaktadır [2,3]. Akciğer ek seslerinden ince raller yaygın olarak pulmoner fibrozis, allerjik alveolit (hipersensitivite pnömonisi)i akciğer ödemi, bronşektazi, pnömonik konsolidasyon ve kistik fibrozis gibi hastalıklarla ilişkilidir. Akciğer ek seslerinden kaba raller ise akciğerdeki büyük hava yollarında bulunan mukusta havada oluşan kabarcıktan kaynaklanan ve gargara sesine benzeyen ses türüdür [3]. Kaba raller sesi ince raller sesinden farklı olarak kişi öksürdüğünde veya derin nefes aldığı kaybolan bir ses türüdür(bronşektazi hariç). Kronik obstrüktif akciğer hastalığı (KOA), akciğer apsesi, pnömoni, bronşektazi ve tüberküloz kavitesi hastalıkları ile ilişkilidir[4].

Ronküs nefes alıp verme esnasında devamlı olarak duyulan, horlama sesine benzeyen gürültülü bir akciğer ek sesidir. Bronşlarda tümör oluşması veya sekresyon birikmesi gibi sebeplerle kendini gösteren akciğer ek sesi ronküs, kaba raller sesi gibi sıklıkla kişi öksürdüğünde kaybolur [5]. Genel olarak astım ve KOAH hastalarında bu sese rastlanır.

Sınıflandırma işlemlerine başlamak için ses verileri üzerinde analiz işlemi, solunum sesleri üzerinde gerçekleştirilmiş analiz çalışmaları üzerinde inceleme yapılmıştır. İncelemeler ile elde edilen bilgiler doğrultusunda kullanılan 3 farklı özgün veri seti üzerinde 200'den fazla ses özelliği çıkarımı yapılmıştır. Elde edilen özellikler, sayısal yapıları doğrultusunda öznitelik seçim yöntemleri uygulanarak, literatürde en sık rastlanan sınıflandırma algoritmalarına uygulanmış ve sonuçlar detaylıca incelenmiştir.

2. LİTERATÜR TARAMASI

Literatür taramasında tek kanallı ve çok kanallı olarak toplanan akciğer veri setlerinin makine öğrenmesinin yanı sıra yapay sinir ağları ve derin öğrenme teknikleri ile sınıflandırılmasına ilişkin incelemeler yapılmıştır. Farklı ses sınıflarının ayrıştırılması üzerine yapılan değerlendirmelerin yanı sıra öz nitelik çıkarmaya veya solunum döngüsü tespitine ilişkin veri ön işleme odaklı çalışmalar da incelenmiştir.

Don'un 2020 yılında sunmuş olduğu analizde, 85 örnekten oluşan akciğer ses veri setinde Naive Bayes, DVM ve KNN gibi yaygın kullanılan makine öğrenme yöntemleri kullanarak sınıflandırma işlemi yapmıştır. Çalışmada öz nitelik seçimine odaklanılmıştır. Bu kapsamda iki farklı öz nitelik seçim yöntemi ve çıkarılan 15 öz niteliğin tamamı 3 farklı sınıflandırıcıya uygulanmıştır. Uygulama sonuçlarını değerlendirmek için hassasiyet, geri çağırma ve f ölçümleri hesaplanarak performans ölçütleri sunulmuştur. Yapılan sınıflandırma işlemleri için en yüksek hassasiyet değeri 94.1 ile KNN, geri çağırma değeri 3 seçim için de 100 olarak Naive Bayes ve f ölçümleri 94.1 olarak KNN sınıflandırıcısı ile elde edildiği sunulmuştur [6].

Demir ve arkadaşlarının 2020 yılında yapmış olduğu çalışmada ICBHI 2017'de sunulmuş 6898 solunum döngüsüne ait 4 sınıftan oluşan veri seti üzerinden öncelikle spectrogram resimleri elde etmişlerdir. Elde edilen spectrogram resimleri üzerinde AlexNet, ResNet-50 ve VGG16 gibi derin öğrenme yöntemleri kullanılarak özellik çıkarımı işlemi yapılmıştır. Çıkarılan özellikleri kullanarak yaygın kullanılan makine öğrenme yöntemlerinden DVM kullanılarak sınıflandırma yapılmıştır. Sınıflandırıcı performansı olarak hespladığı doğruluk değerlerinde en yüksek başarıyı DVM ile %65,50 olarak tespit etmiştir [7].

İslam ve arkadaşlarının 2018'de sunmuş olduğu analiz çalışmasında 30 sağlıklı ve 30 astım hastası bireye ait solunum ses verilerine ek olarak vücut kitle indeksini kullanarak sınıflandırma işleminin doğruluğunu arttırmaya çalışmıştır. Solunum döngüleri çıkarıldıktan sonra güç spektral öz niteliğine ilişkin ortalama, varyans, kurtosis ve çarpıklık değerleri üzerinden DVM ve ANN yöntemleri ile sınıflandırma uygulanmıştır. 4 farklı kanaldan alınan ses verileri için 1, 2, 4 numaralı kanallardan alınan ses verilerine uygulanan sınıflandırma yöntemlerinden DVM ile %93,3'lük doğruluk değerini en başarılı sonuç olarak sunmuştur [8].

Bardoua ve arkadaşları 2018’de sunmuş olduğu analiz çalışmasında kullanılan solunum sesleri veri setinden CNN, LBP ve MFCC için spectrogram özellikleri çıkararak sınıflandırma işlemlerinde kullanılmıştır. GMM, KNN ve DVM gibi yaygın kullanılan makine öğrenme yöntemleri kullanarak yapılan sınıflandırma işleminde en başarılı doğruluk değerini CNN üzerinden çıkardığı özellikler ile %95 olarak elde etmiştir [9].

Aras ve arkadaşları yapmış olduğu çalışmada 21 normal 27 patolojik akciğer ses kaydı üzerinden birer ve üçer periyotluk olarak iki ayrı veri seti oluşturulmuştur. Mel frekans kepsrum katsayısı ile üretilen öz nitelikler üzerinde kNN makine öğrenmesi yöntemi kullanılmıştır. Üçer periyotluk veri kümesi üzerinde %100’lük başarı değeri elde edilmiştir [10].

Aras ve arkadaşları 2017’de sunmuş oldukları bir diğer çalışmada sağlıklı bireye ait normal ve akciğer ek seslerine ait ral ve ronküs veri sınıflarından 70’er adet olacak şekilde, toplam 210 ses verisi üzerinde çalışma yapılmıştır. Bu veri setileri üzerinde KNN, LDA, DVM ve Naive Bayes gibi makine öğrenmesi yöntemleri kullanılarak sınıflandırma yapılmıştır. Sınıflandırıcılar üzerinden elde ettiği doğruluk değerleri incelendiğinde En başarılı olarak %99,05 olan KNN sınıflandırma yöntemini tespit etmiştir [11].

Li ve arkadaşlarının 2016 yılında sunmuş olduğu analiz çalışmasında 70 crackle ve 70 sağlıklı akciğer sesi olmak üzere 5 saniyeden oluşan, yaklaşık 2 solunum döngüsüne sahip bir veri seti kullanılmıştır. Kullanılan veriler üzerinde DVM makine öğrenmesi yöntemi ile %97,14-%100 doğruluk değerleri tespit edilmiştir [12].

Ulukaya ve arkadaşlarının 2016 yılında sunmuş olduğu sınıflandırma çalışmasında 9600 adet akciğer ses verisinde Q-faktör üzerinden çıkarılan öz nitelikler için DVM ve KNN gibi makine öğrenmesi yöntemleri ile crackle, wheeze ve normal ses sınıflarına ayırtırma yapılmıştır. Crackle için % 95, hırıltı için % 97, normal için % 93.50 ve toplam ses sinyali türleri için % 95.17 doğruluk değeri tespit edilmiştir [13].

Datta ve arkadaşları 2017’de sunmuş oldukları analiz çalışmasında 52 adet akciğer ses verisi üzerinden spektral, spectrogram, kepsral ve dalgacık öznitelikleri üzerinden yaygın kullanılan DVM yöntemi ile sınıflandırma yapılmıştır. Sınıflandırıcının veri setindeki başarısını %80 olarak tespit etmişlerdir [14].

Naves ve arkadaşlarının 2016'da sunmuş oldukları çalışmada 7 ince ral, 13 kaba ral, 4 monofonik hırıltı ve 4 polifonik hırıltıdan oluşan 36 örnek veri kullanılmıştır. Veri ön işleme ile oluşturulan 320 örnek üzerinde KNN ve Naive Bayes makine öğrenme yöntemleri ile sınıflandırma yapılmıştır. Çalışmanın ilk aşamasında KNN ile vesicular, wheezes, crackles sınıfları ayrımı yapılmış, ardından wheezes ve crackles alt sınıflarını Naive Bayes yöntemi ile ayrılmıştır. Eğitimde %98,1, doğrulamada %94,6 seviyesinde doğruluk değeri tespit edilmiştir [15].

Haider ve arkadaşları 2019'da sunmuş oldukları sınıflandırma çalışmasında DVM, KNN, Karar ağacı, Lojistik regresyon gibi yaygın kullanılan makine öğrenmesi denetimli sınıflandırma yöntemleri kullanmıştır. Yapılan çalışmada akciğer seslerine ait 39 farklı özellik çıkarımı yapılarak sınıflandırıcılarda kullanılmıştır. Yapılan deneysel çalışma sonucunda sınıflandırma işlemlerinin doğruluk değerini %88-%100 arasında tespit edildiğini sunmuşlardır [16].

Ballı ve Kutlunun 2019 yılında yapmış oldukları çalışmada akciğer seslerinin sınıflandırılmasında ses verisinin uzunluğunun önemi üzerinde durulmuştur. Farklı uzunluklardaki ses verileri için MFCC ile çıkarılan özellikler KNN algoritması ile sınıflandırılmış ve en yüksek doğruluk değeri olarak 2-10 saniye arasında olan ses verileri için %92.06 doğruluk değeri tespit edilmiştir [17].

Rocha ve arkadaşlarının 2021'de sundukları çalışmada akciğer seslerinden hırıltı olarak ifade edilen ses sınıfının saptanmasında ses örneğinin uzunluğunun etkisi üzerinde durulmuştur. Hırıltı sesi düzensiz oluşması ve ses verisi üzerinde hırıltısız verinin artmasının sınıflandırıcılar üzerindeki etkisine yoğunlaşmıştır. MIR Toolbox kullanılarak özellik çıkarımı uygulanmıştır. Her yaştan 126 kişinin bulunduğu, toplamda 920 ses dosyasından oluşan 5.5 saatlik bir kayıt üzerinde çalışma yapılmıştır. Sınıflandırıcı olarak LDA, Linear DVM, Gaussian DVM, Boosted Tree ve CNN kullanılmıştır. Değerlendirme olarak doğruluk, kesinlik, hassaslık, f1 ölçümleri, specificity ve MatthewsCorrCoef kullanılmıştır. Değişken parametreler atanmadan önce doğruluğu %95-%98 arasında olan veri setinde parametreler ve hırıltısız ses sürelerinde yapılan değişimler ile %55 ve %76 doğruluk değerleri elde etmişlerdir [18].

Yapılmış akademik çalışmalar incelendiğinde akciğer sesleri üzerinde sınıflandırma işlemi yaparak hastalıklara ilişkin tanı destek sunmaya çalışan birçok çalışma yer aldığı görülmüştür. Sunulmuş akademik çalışmalar farklı özellik seçme yöntemleri / farklı öğrenme yöntemleri kullanarak farklı odak noktaları ile sınıflandırıcıların ve veriler üzerinde yapılan işlemlerin çeşitli üstünlüklerini sunmuşlardır. Sunduğum bu çalışma, literatürde yaygın kullanılan makine öğrenmesi denetimli sınıflandırma yöntemlerinden Naive Bayes, DVM ve KNN sınıflandırıcılarının yanında karar ağacı ve rastgele orman yöntemleri ile sınıflandırıcı performansları karşılaştırılmıştır. Ayrıca literatürden farklı olarak 3 sınıftan oluşan 3 farklı özgün veri seti için 200'ün üzerinde özellik içinden özellik seçim yöntemi uygulanarak en yüksek başarı verecek 5 özellik ile sınıflandırma işlemi yapılarak sunulmuştur.


3. GENEL BİLGİLER

3.1. Solunum Sistemi

Yaşamsal faaliyetlerini sürdürülebilmek için enerjiye ihtiyaç duyan canlı organizmalar, besinlerin oksijenle tepkimeye girmesi ile ihtiyaç duyulan enerjiyi elde etmektedir. Vücudun enerji ihtiyacını karşılayabilmek için havadaki serbest O₂ moleküllerinin alınması ve yaşamsal faaliyetler sonucu dokularda biriken CO₂ moleküllerinin dışarı atılmasına solunum, bu işlemi gerçekleştiren sisteme ise solunum sistemi denir.

İnsan vücudundaki hücrelerin çalışabilmesi için gerekli olan oksijeni atmosferden alan ve hücrelerin bu oksijeni kullanarak gerçekleştirdiği oksidasyonla üretmiş olduğu atıklardan olan karbondioksiti atmosfere bırakan organ akciğerlerdir.

Diyafram kasının hareketiyle akciğerler hava ile dolar ve boşalır. Bu süreçte akciğerlere alınan hava burun ve ağızdan geçerek vücuda girmiş olur. Soluk borusu, bronş, bronşçukları geçmesinin ardından alveollere ulaşır. Burada karbondioksitçe zengin olan kanda gaz değişimi yapılarak taşıdığı karbondioksitten arındırılır ve oksijence zenginleştirilir. Bu aşamada alveollerde bulunan karbondioksitli hava, girdiği yolu takip ederek yine ağız ve burundan dışarı atılır. Tüm bu süreç gerçekleşirken havanın geçtiği yollarda titreşimler oluşur. Bu titreşimler akciğer sesleri olarak adlandırılır. Bu sesler, kişinin solunum yollarında olabilecek tabii olmayan bir durumla değişebilmektedir.



Şekil 3.1. Solunum döngüsü

3.2. Solunum Sistemi Hastalıklarının Teşhis Aşamaları

Nefes alma ve verme eylemi insan hayatının devam edebilmesi için gerekli bir işlem olduğundan solunum sistemine ilişkin bir hastalığın erken teşhis edilerek doğru tedavi uygulanması yüksek öneme sahip olduğunu gösterir. Solunum sistemi ile ilgili hastalıklarda teşhis konulurken sadece solunum sesi dinlenerek elde edilen sesin yapısı, solunum döngü hızı veya süresine bakılması teşhis koymak ve doğru tedaviyi uygulamak için yeterli değildir. Doğru bir teşhis için fiziksel muayene inspeksiyon, palpasyon, perküsyon ve oskültasyon tekniklerinin uygulanması gerekmektedir. Bunların yanında hastanın geçmiş bilgisi, geçmiş hastalıkları, sigara kullanma durumu gibi bilgileri göz önüne alınarak değerlendirilmelidir.

İnspeksiyon hastanın göğüs duvarına ait deri ve göğüsün anatomik yapısının gözle inceleme anlamına gelmektedir. Bu muayene ile deride lekelenmeler, anatomik yapıda şekil bozukluklarının yanı sıra nefes alma süresi ve hızı gibi bilgiler elde edilir. Herhangi bir araç kullanılmaz.


Palpasyon göğüs duvarına elle dokunarak muayene anlamına gelmektedir. Bu muayene yöntemi ile akciğer yapılarının boyutu, yoğunluğu, sıcaklığı ve fonksiyonel durumları değerlendirilmesine ilişkin verileri elde edilir. Genellikle göğüs ağrısının kaynağının belirlenmek için kullanılan bu muayenede herhangi bir araç kullanılmaz.

Perküsyon göğüs duvarının yüzeyine parmaklarla vurularak yapılan muayenedir. Solunum ve konuşma esnasında göğüs duvarının doğrudan veya stetoskop yardımı ile dinlenmesi ile gerçekleştirilen muayene yöntemidir. Göğüs duvarına vurulduğunda oluşan sesin hissedilmesi ve dinlenmesi ile göğüs içerisindeki dokuların yoğunlukları hakkında bilgi edinilir.

Oskültasyon belirli kurallarla tanımlanmış standartları olan bir dinleme muayenesidir. Bu kurallar dahilinde göğüs duvarında belirli noktalar üzerine baskı uygulayarak stetoskop aracılığı ile dinleme işlemi yapılmaktadır. Ön, yan ve arka göğüs loblarını kapsayacak şekilde yapılmaktadır. Bu muayene ile akciğer seslerine ilişkin normal ve anormal ses verileri tespit edilmektedir. Fakat anormal ses verilerinin tespiti için uzman nitelikte doktor deneyimine ihtiyaç vardır.

3.3. Solunum Sesleri

Akciğer sesleri Şekil 3.2’de verilen sınıflardan oluşmaktadır.



Şekil 3.2. Akciğer sesleri [19]

Sağlıklı insandaki akciğer sesleriyle solunum yollarında herhangi bir rahatsızlığa sahip bir bireyde oluşan akciğer sesleri farklılık göstermektedir [20].

3.3.1. Normal solunum sesleri

Normal solunum sesleri akciğerlerdeki hava geçiş yollarının dinlenildiği yerlere ve bu hava yollarının genişliğine bağlı olarak veziküler, bronşial veya ikisinin ara noktalarında duyulan bronkoveziküler sesler olarak üç farklı şekilde duyulabilir [2]. Akciğerden gelen normal seslerden veziküler ses, sağlıklı bir akciğerden duyulan, çekme ya da hafif hışırdamaya benzer, yumuşak ve düşük perdeden bir sestir. Bu sesi alabilmek için akciğerlerin uç noktalarına yakın yerlere oskültasyon uygulanmalıdır. Bir solunum döngüsü için nefes alma veya verme sırasında duraklama olmadan bu ses tekrar eder. Akciğerlerden gelen normal seslerden bronşial ses bir solunum döngüsü sırasında nefes alıp verme gerçekleşirken duraklamanın duyulabileceği yüksek perdeden bir sestir. Havanın bir borudan geçerken çıkardığı seslere benzemektedir. Akciğerlerden gelen normal seslerden bronkoveziküler ses, bronşial ve veziküler seslerinin karışımı olarak duyulur. Solunum döngüsünde nefes alış ve veriş sürelerinin yaklaşık olarak birbirine eşit duyulduğu normal ses türüdür.

3.3.2. Anormal solunum sesleri

Oskültasyon ile dinlenen bir akciğer üzerinden elde edilen anormal sesler bir hastalığın belirtisi olabilmektedir. Uzun yıllardır doktorların tecrübeleri göstermektedir ki anormal solunum sesleri çoğu kez bireyin hasta olup olmadığını belirlemek için yeterli değildir. Akciğer seslerine ek olarak göğüs röntgen filmi veya solunum testi gibi ek testlere ihtiyaç duyulabilir. Oskültasyon ve ek testler ile elde edilen veriler üzerinde inceleme yapıp bir değerlendirme ortaya koyabilmek için uzman doktorların işlem yapması gerekmektedir. Yaygın olarak duyulan anormal solunum sesleri ral ve ronküs ile normal solunum sesleri veri seti olarak ele alınmıştır. Bu seslerden ral ince ve kalın ral olmak üzere iki alt kırılıma sahiptir. Fakat bu çalışma kapsamında ince ve kalın ral ayrımı yapılmadan sınırlandırma uygulanmıştır.

Hastalıklı bireylere ait akciğer ek seslerinden raller sınıfı ince, orta ve kalın raller ayrımı yapılmadan bir sınıf olarak kullanılmıştır. İnce ral alanında uzman hekimlerce incelendiğinde patlayıcı yüksek perdeli bir ses olarak ifade edilir. Bir hasta için kayıt altına alınan solunum sesinde her bir solunum döngüsünde tekrarladığı görülmektedir. Bu ses hasta öksürme veya derin nefes alma eylemi sonrasında da aynı kalmaktadır [2,3]. Akciğer ek seslerinden ince raller yaygın olarak pulmoner fibrozis, allerjik alveolit (hipersensitivite pnömonisi) akciğer ödemi, bronşektazi, pnömonik konsolidasyon ve kistik fibrozis gibi hastalıklarla ilişkilidir. Akciğer ek seslerinden kaba raller ise akciğerdeki büyük hava yollarında bulunan mukusta havada oluşan kabarcıklanmadan kaynaklanan ve gargara sesine benzeyen ses türüdür [3]. Kaba raller sesi ince raller sesinden farklı olarak kişi öksürdüğünde veya derin nefes aldığında kaybolan bir ses türüdür(bronşektazi hariç). Kronik obstrüktif akciğer hastalığı (KOA), akciğer apsesi, pnömoni, bronşektazi ve tüberküloz kavitesi hastalıkları ile ilişkilidir[4].

Ronküs nefes alıp verme esnasında devamlı olarak duyulan, horlama sesine benzeyen gürültülü bir akciğer ek sesidir. Bronşlarda tümör oluşması veya sekresyon birikmesi gibi sebeplerle kendini gösteren akciğer ek sesi ronküs, kaba raller sesi gibi sıklıkla kişi öksürdüğünde kaybolur [5]. Genel olarak astım ve KOAH hastalarında bu sese rastlanır.

3.4. Solunum Sistemi Hastalıkları

Bu bölümde mevcut veri seti üzerindeki sınıflandırma ile hekimlere teşhisine destek verilen hastalıklar hakkında bilgi verilecektir. Bu hastalıkların detaylı incelenmesi yapılan çalışmanın önemini ortaya koyacaktır.

Ronküs sesi sibilan ronküs ve sonor ronküs olarak iki ek sestten oluşmaktadır. Yapılan çalışmada oluşturulmuş veri setinde bu ayrım yoktur. Ronküs sesi tespit edilen ve bu bölümde incelenen yaygın görülen hastalıklar aşağıda listelenmiştir.

- Astım
- KOAH
- Akut Bronşit
- Bronşiolit
- Sarkoidoz
- Konjestif Kalp Yetmezliği

Ral sesi bazı çalışmalarda ince ve kaba olarak ikiye ayrılırsa bazı çalışmalarda orta ral de eklenerek üç farklı ses olarak eline alınmıştır. Yapılan çalışmada oluşturulmuş veri setinde bu ayrım yoktur. Ral sesi tespit edilen yaygın görülen ve bu bölümde incelenen hastalıklar aşağıda listelenmiştir.

- Pnömoni
- Atelektazi
- Bronşektazi
- Idiopatik Pulmoner Fibrozis
- Akciğer ödemi
- Konjestif Kalp Yetmezliği
- Amfizen

3.4.1. Astım

Ülkemizde yaklaşık 3.5 milyon ve dünyada yaklaşık 300 milyon kişiyi etkileyen astım yakın geçmişte çocuklarda ve yetişkinlerde yaygın olarak görülmektedir. Kronik hava yolu

inflamasyonu olan astım hastalığı çeşitli uyaranlara karşı hava yolunda gerçekleşen aşırı duyarlılık halidir. Kronik inflamasyon hırıltı, göğüste sıkışma, öksürük, nefes darlığı gibi solunum semptomları ve ekspiratuar hava akımı kısıtlılığı ile ilişkilidir [21]. Günümüzde bu rakamların 5 milyona yaklaştığı farklı kaynaklarda ifade edilmiştir.

Astım hastalığı genetik, bağışıklılık sistemi ve çevresel faktörlere bağlı oluşmaktadır. Çevresel faktörlerin başında hava kirliliği, kişi için alerjen olan maddeler ve sigara dumanı gelmektedir. Astım hastalığı fizyolojik, klinik ve patolojik özelliklerine göre tanımlanmaktadır. Ekspiratuar hava akımı kısıtlılığı ve hava yolu daralması fizyolojik; nefes darlığı, hırıltı ve öksürük klinik; kronik hava yolu inflamasyonu ise patolojik özelliğine örnek verilebilir. Astım hastalığında oskültasyon aşamasında ronküs sesi duyulmaktadır [22].

3.4.2. Kronik obstrüktif akciğer hastalıkları (KOAİ)

Kronik Obstrüktif Akciğer Hastalığına Karşı Küresel Girişim Topluluğu (GOLD) tarafından “KOAİ; tam olarak geri dönüşümü olmayan ve yavaş ilerleme gösteren hava akımı sınırlamasıyla karakterize edilen, önlenabilen ve tedavi edilebilen akciğer hastalığı” olarak tanımlanmıştır.

Kronik öksürük, balgam çıkarma ve nefes darlığı semptomlarıyla ortaya çıkan hastalığın başlıca nedenleri arasında sigara kullanımı, iş ortamında kimyasal maddelere ve tozlara maruz kalma, hava kirliliği ve genetik faktörler gelmektedir. KOAİ tanısının konulabilmesi için spirometri testi yapılmalıdır. Spirometri testinde çeşitli parametreler değerlendirilerek teşhis konulmaktadır. Oskültasyon aşamasında yaygın olarak ronküs sesleri duyulmaktadır [23,24].

3.4.3. Akut bronşit

Akut bronşit virüs veya bakteri kaynaklı olarak trakeobronşial ağacın akut inflamasyonudur. Inflamasyon vücudun herhangi bir zarara karşı verdiği yanıttır. Akut bronşit üst solunum yolu enfeksiyonuna bağlı oluşmaktadır. En belirgin semptomu öksürük olan hastalıkta göğüste yanma, halsizlik, hırıltı gibi semptomlarda görülmektedir. Oskültasyonda ekspiryumda ronküs ve hırıltı duyulmaktadır [22].

3.4.4. Bronşiolit

Bronşiolit, akciğer bronşiollerinin inflamasyonudur. Çocuklarda viral enfeksiyon kaynaklı, yetişkinlerde ise gaz ve iritan maddelerin solunması sonucu bronşiollerde inflamasyon oluşmaktadır. Klinik belirtileri hırıltı, hızlı solunum, hafif ya da yüksek ateştir. Oskültasyonda ekspiryumda ronküsle neden olmaktadır [25].

3.4.5. Sarkoidoz

Yüz yılı aşkın süredir bilinmesine rağmeni nedini tam belirlenemeyen sarkoidoz hastalığı başta akciğerler olmak üzere beyin, kalp, göz, deri, lenf bezleri gibi organları etkileyen sistemik enflamatuvar bir hastalıktır. Uzun süreli ve düşük yoğunluklu antijenik bir uyarının bağışıklık sistemini harekete geçirmesi sonucu oluşmaktadır. Hastalığın oluşmasında etkili olduğu tespit edilmiş genetik ve çevresel faktörler vardır. Hastalığa sahip kişilerde akciğer etkilenir ise nefes darlığı, öksürük ve göğüs ağrısına neden olmaktadır [26].

3.4.6. Konjestif kalp yetmezliği

Konjestif kalp yetmezliği, kalbin çeşitli nedenlerden dolayı kan pompalama gücünde azalma ve buna bağlı olarak dokularda meydana gelen dolaşım bozukluğudur. Kalp kanı olması gereken etkinlikte pompalayamadığı için kan vücut içine birikmektedir. Kanın vücut içinde birikme konumu eğer kalbin sağ tarafının gerisine doğru olursa ayaklarda ve ayak bileklerinde şişmeye neden olur. Akciğerlerden kalbe gelen temiz kan pompalanamayıp geriye doğru birikirse pulmoner basıncın artması sonucu akciğerde ödeme neden olur. Oskültasyon aşamasında ral veya ronküs sesinin duyulmasına neden olur. Konjestif kalp yetmezliği nefes darlığı ve öksürük gibi klinik özelliklere sahiptir [26].

3.4.7. Pnömoni

Pnömoni dünya üzerinde her yıl yaklaşık 450 milyon kişiyi etkileyen ve 4 milyon kişinin ölümüne neden olan enfeksiyonel bir hastalıktır. Etki alanı yüksek kişi gruplarında; beş yaş altı çocuklar, 65 yaş üstü erişkinler ve yapısal akciğer bozukluğu bulunan hastalar bulunmaktadır. Pnömoni, alt solunum yollarına ulaşan bakteri, virüs veya mantar gibi mikroorganizmaların neden olduğu akciğer enfeksiyonudur. Akciğerde meydana gelen enfeksiyon alveollerin inflamasyon sıvısı ve kan damarlarından gelen serum sıvısıyla

dolması nedeniyle alveollerin hava içeriğini kaybetmesiyle sonuçlanmaktadır. Yüksek ateş, öksürük, yoğun balgam ve solunum güçlüğü klinik belirtileriyle ortaya çıkan hastalık oskültasyon sırasında rallere neden olmaktadır[27].

3.4.8. Atelektazi

Atelektazi, hava boşluklarının yetersiz genişlemesine bağlı olarak akciğerin hacim kaybıdır [22]. Atelektazi akciğerde bir veya daha fazla segmentin, tüm bir lobun veya akciğerin tamamının hacminin küçülmesidir. Atelektazi bronş veya bronşiollerin tıkanması ya da alveol epitelinde yüzey gerilimini azaltan sürfaktan madde eksikliğinden kaynaklanmaktadır. Hipoksemi, solunum seslerinde azalma ve solunum güçlüğü klinik belirtileriyle ortaya çıkmaktadır. Oskültasyonda yaygın olarak raller sesi gözlemlenmektedir.

3.4.9. Bronşektazi

“Bronşektazi, bronşların elastik dokusunun ve kas yapısının bozulmasına bağlı olarak bronşların bir daha normal şeklini alamayacak şekilde oluşan bronş genişlemesi ve distorsiyonudur”[22]. Genellikle orta çaptaki bronşları etkileyen bronşektazi hastalığının nedenleri arasında uzun süreli enfeksiyonlar, kalıtsal yapı ve akciğerde fibrozis sayılabilir. Bronşektaziler en hafiften en ağıra silindirik, variköz, kistik bronşektazisi olarak sıralanmaktadır. Klinik belirtileri arasında nefes vermede güçlük, öksürük ve balgam mevcuttur. Oskültasyon sırasında raller duyulmaktadır [26].

3.4.10. İdiyopatik pulmoner fibrozis (İPF)

İdiyopatik pulmoner fibrozis, alveol duvarlarının kalınlaşıp sertleşmesiyle ortaya çıkan bir hastalıktır. Bu hastalık kronik kolarak devam eden ve ilerleyen bir hastalıktır. İPF’de alveol duvarları kalınlaştığı için oksijen kan damarlarına ulaşamamakta ve dokuların ihtiyacı olan oksijen sağlanamadığı için doku fonksiyonlarında bozulmalar meydana gelmektedir. Sıklıkla 50 yaş üstü erkeklerde görülmektedir. İPF’in başlıca nedenleri arasında sigara tüketimi, viral enfeksiyonlar, gastro-özofajiyel reflü ve zararlı gaz veya tozların solunması vardır. Hastalığın yaygın görülen klinik belirtileri kuru öksürük, nefes darlığı, hızlı soluk alıp-vermedir. Oskültasyon aşamasında ral sesleri duyulmaktadır.

3.4.11. Akciğer ödemi

Akciğer ödemi, çeşitli nedenlerden dolayı alveollerin hava yerine sıvıyla dolmasıdır. Bu nedenle akciğerin yerine getirmesi gereken gaz alışverişi sağlanamaz veya yavaşlar. Hastalığın nedenleri arasında kalp yetmezliği, akut miyokard enfarktüsü, hipertansiyon, kardiyomiyopati, kalp krizi gibi kardiyolojik nedenler veya böbrek yetmezliği, boğulma, toksik gaz solunumu gibi non-kardiyolojik nedenler sayılabilir. Yaygın görülen klinik belirtileri arasında şiddetli solunum sıkıntısı, öksürük, pembe köpüklü balgam, taşikardi ve hipoksemi bulunmaktadır. Oskültasyon sırasında ral sesi duyulmaktadır [22].

3.4.12. Amfizem

Amfizem, akciğerlerin terminal bronşiollerinin distalindeki hava yollarının genişlemesidir. Bu genişleme sonucu alveolleri birbirinden ayıran ince duvarlar yırtılarak akciğerde esneklik kaybına neden olur. Akciğerlere hava girişi ve alveollerde oksijen-karbondioksit dengesi bozulmaktadır. Sürekli öksürük, balgam, hırıltılı solunum gibi klinik belirtilerle ortaya çıkan hastalığın nedenleri arasında tütün dumanı, kimyasal dumanlar ve tozlara maruziyet vardır. Oskültasyon aşamasında ral sesi duyulmaktadır [22].



4. BİLİMSEL ARKA PLAN

Bu bölümde yapılan deneysel çalışmanın bilimsel arka planı hakkında bilgi verilecektir. Mevcut çalışmanın veri seti ses verisinden oluşmaktadır. Ses verisine ait özellikler ve bu özelliklerin çıkarım şekli hakkında bilgi verildikten sonra sınıflandırıcıların teorik incelemesi sunulacaktır.

4.1. Ses Verisinin Özellikleri

Özellik bir veriye ait en baskın ve ayırt edici bilginin ortaya çıkarılması olarak tanımlanabilir. Gelişen teknoloji ile ses verileri üzerinden özellik çıkarma yöntemleri de paralel olarak gelişmeye devam etmiştir.

4.1.1. Zaman domaini

Ses zaman ve genlik eksenlerine sahip bir sinyaldir. Sinyal üzerinde belirli zaman aralıkları ile uygulanan pencereleme(akış doğrultusunda örneklerle ses sinyalini yeniden düzenleyen bir yöntemdir.) yöntemleri ile ses verisinden özellikler elde edilir. Ses verisi üzerinden elde edilen zaman domaini özellikleri aşağıdaki gibidir.[20]

- ZCR basit bir ifadeyle sinyalin bir saniye aralığında sıfır seviyesine geçme sayısıdır.
- Genliğe dayalı özellikler; AD uyarlanabilir eşik aracılığı ile yüksek ve düşük genliklerden sinyal segmentlerinin sürelerinin değişimini göz önünde bulunduran bir özelliktir. ADSR genellikle müzik analizi ve müzik türlerinin sınıflandırılmasında kullanılan genlikte ki değişimlerin zaman ile ilişkisi ile hesaplanan bir özelliktir. LAT başlangıç zamanı ile sesin kararlı kısmına ulaştığı zaman farkının logaritma 10 tabanındaki değeridir, müziksel başlangıç tespiti ve çevre seslerini tanımlamada kullanılır. Shimmer bir dalga biçimindeki genlikte çevrimler arası değişimi hesaplayan bir özelliktir.
- Enerjiye dayalı özellikler; Kısa zaman enerjisi, Hacim, Geçici ağırlık merkezi
- Oto korelasyona dayalı özellikler
- Ritme dayalı özellikler

4.1.2. Frekans Domaini

Zaman genlik ekseninde tanımlanan ses verisinin frekans incelemesi ile elde edilen özelliklerini frekans domaini özellikleri olarak ele alırız. Fourier dönüşümü veya otomatik regresyon analizi kullanılarak ses verisi frekans alanı sinyaline dönüştürülür. Bu veri üzerinden özellik çıkarımı işlemleri yapılır. Ses verisi üzerinden elde edilen frekans domaini özellikleri aşağıdaki gibidir.[20]

- Otomatik regresyona dayalı özellikler; LPC bir sinyalden fazlalığı kaldırıp önceki bilinen katsayıları doğrusal olarak birleştirerek sonraki değerleri tahmin etmeye dayalı bir özelliktir. CELP üç aşamalı bir konuşma kodlama algoritmasıdır. LSF ses kanalı üzerinden iletim için doğrusal tahmin katsayılarını temsil etmek için kullanılan bir özelliktir.
- Tepe Frekansı
- MSAF-MULTIEXPANDED FFT spektrumları arasındaki farkları ayıklayan akustik bir özelliktir. Özellikle endüstriyel motorlardaki arıza tespiti için kullanılan bir özelliktir.
- SMOFS-MULTIEXPANDED Endüstriyel motorlardaki arıza tespiti için kullanılan bir diğer özelliktir.
- STFT/Zaman-Frekans'a Dayalı: zaman-frekans matrisi, alt band enerji oranı, spectrum envelope, SPSF ses verisindeki sol ve sağ kanalın STFT'sine dayalı olarak farklı frekanslar için stereo kaydırma bilgilerini hesaplamayı hedefleyen bir özelliktir. GDF minimum, maximum ve karma fazlı grup gecikme fonksiyonları üzerinden elde edilen bir özelliktir.
- EMS tabanlı özellikler, sinyaldeki yavaş genlik modülasyonlarını ve belirli frekanslar boyunca genlik dalgalanmalarında enerjinin dağılımını temsil eder
- LTAS tabanlı özellikler, sinyalden atipik spektral bilgileri yakalar
- Chroma ilişkili özellikler, tüm spektrumun müzikal oktavın 12 yarım tonunu temsil eden 12 kutuya eşlendiği müzik sesinin ilginç ve güçlü temsidir. Ses sinyalinin logaritmik kısa süreli fourier dönüşümünden hesaplanabilir.
- Ton tabanlı özellikler; FF, adım histogramı, adım profili, harmoniklik, harmonik-gürültü oranı, titreme
- Spectrum tabanlı özellikler; spektral merkezilik, Spectral centre, spektral yuvarlanma, spektral yayılma, çarpıklık, basıklık, spektral eğim, spektral azalma, bant genişliği, spektral düzlük, spektral tepe faktörü, entropi, akı, oktav tabanlı spektral kontrast(OBSC)

4.1.3. Cepstrum domain

Sinyalin spektrumunun logaritmasının ters Fourier dönüşümü alınarak bir cepstrum elde edilir. Cepstrum üzerinde yapılan analizlerle elde edilen özellikler aşağıdaki gibidir.

- Mel Frekans Cepstral Değerleri (MFCCs)
- Doğrusal Tahmin Cepstral Katsayıları
- Algısal Doğrusal Tahmin (PLP) Cepstral Katsayılar
- RASTA-PLP kısa süreli gürültü değişimlerini yumuşatmak ve konuşma sinyalindeki statik spektral renklenmeden kaynaklanan herhangi bir sabit kaymayı ortadan kaldırmak için her bir frekans alt bandındaki enerjiye bir bant geçiren filtre uygulayan bir tekniğe RASTA denir.
- GFCCs genişletilmiş bir MFCC formu olarak sunulan bu özellik hayvan sesleri ve çevre seslerinin sınıflandırılması için kullanılan bir özelliktir.
- GTCCs gammaton filtre bankalarına dayanır, bu filtre bankaları aslında bir ses sinyalinin frekans-zaman gösterimi olan kokleagramı çıktı olarak verir. MFCC'ler gibi türevleri ile yeni özellikler elde edilebilir.

Bu çalışmada çıkarımı yapılan özellikler içinde özellik seçim yöntemi uygulandı ve 5 farklı özellik seçildi. Seçilen 5 özellik aşağıdaki gibidir.

- MFCC'lerin Momentlerinin Alan Yöntemi Genel Standart Sapma 3. Boyut
- MFCC'lerin Momentlerinin Alan Yöntemi Toplam Ortalama 1. 2. 5. 8. Boyutlar

Sırasıyla MFCC, standart sapma ve MFCC'ler için momentlerin alan yöntemi toplam ortalama hesaplarının literatüre nasıl girdiğini ve algoritmik yapısını inceleyeceğiz.

Mel frekans cepstral katsayıları (mfcc'ler)

MFCC'ler, bir ses klbinin cepstral gösteriminden türetilir. MFCC'ler, doğrusal olmayan bir erime ölçeğinde log güç spektrumunun ayırık kosinüs dönüşümüne dayanan bir ses klbinin kısa süreli güç spektrumunu temsil eder. Bir çok ses sınıflandırma problemleri için anlamlı bir öz nitelikdir. MFCC aşağıdaki algoritmik akış ile elde edilir [20].

- Ses sinyali x olarak giriş verilir.
- Sinyal kısa çerçevelerle çerçevelendirilir.
- Her kare için, güç spektrumunun periodogram tahminini hesaplanır.
- Mel filtre bankasını güç spektrumuna uygulanır, her filtredeki enerji toplanır.
- Filtre bankası enerjilerinin logaritmasını ele alınır.
- Günlük filtresi-banka enerjilerinin Ayrik kosinüs dönüşümünü (DCT) alınır.
- 2–13 DCT katsayısı tutulur, gerisi atılır.

Standart sapma

Verilerin ortalamaya ne kadar yakın olduğunu hesaplamak için kullanılır. Verilerin dağılımı hakkında bilgi sahibi olmamızı sağlar. Matematiksel hesaplaması aşağıdaki gibidir.

$$std = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (4.1)$$

n değeri alınan örneklem sayısı olarak ifade edilir. Her bir değerın ortalama değeri ile arasındaki fark alınarak kareleri toplamı işlemi uygulanır. Farkın kareleri toplamından farkın karelerinin ortalaması bulunur. Elde edilen değeri varyansın karesidir. Karekök içine alınarak standart sapma elde edilir.

Area method of moments feature

Bu sınıf, Fujinaga [28] tarafından uygulanan 2 boyutlu istatistiksel moment yöntemlerini uygular. Birinin karşısında düzenleyebileceği ardışık pencerelerin sayısı düzenlenebilir bir özelliktir. Ayrıca, bu sınıfın pencere özelliği, genel pencere boyutu değişikliklerinden etkilenir. Bu varyant, dikey boyut için FFT kutuları yerine MFCC'leri kullanır.

4.1.4. Derin öznitelikler

Ses verisine derin öğrenme yöntemleri uygulanarak özellik elde etmek mümkündür. Ses verisine uygulanan derin öğrenme yöntemlerinin bazıları aşağıdaki gibi listelenebilir.

- CNN Özellikleri
- Derin Sinir Ağları
- Tekrarlı Sinir Ağları
- Derin yığılmalı otomatik kodlayıcı
- Tek yönlü uzun kısa süreli bellek ağı
- Çift yönlü uzun kısa süreli hafıza

4.1.5. Resim tabanlı öznitelikler

Ses verisinin spectrogram olarak resim çevirimi sonrasında yapılan analizlerle elde edilen özniteliklerdir.

- Yerel İkili Örüntüler
- Yerel Üçlü Modeller
- Histogram ve gradyanlar özellikleri
- Ölçekle değişmeyen özellik dönüşümü

4.1.6. Seyreklik tabanlı öznitelikler

Sayısal analizinde ele alınan sinyalin çok sayıda sıfır olan değere sahip olmasına seyrek matris denir. Ses sinyalleri için de çok sayıda sıfır değeri barındırdığı durumlar için seyreklik tabanlı özellikler ayırt edici olarak kullanılabilir. Örneğin, saf bir ton sinyali, frekans alanında tek bir artışla temsil edilebilir, dolayısıyla sinyalin frekans alanında seyrek olduğunu söyleyebiliriz. Bu nedenle, seyrekliği olan bir sinyali temsil etmek için çok daha az sayıda özellik gerekir. Seyreklik, örneğin zaman alanı, frekans alanı, zaman frekansı alanı, dalgacık alanı, cepstral alanı vb. gibi herhangi bir alanda elde edilebilir. Alanların herhangi birinde seyreklik elde edildiğinde, alana özgü özellikler çıkarılabilir ve analiz edilebilir. Ses verisine uygulanarak özellik çıkarımı yapılabilecek bazı seyreklik yöntemleri aşağıdaki gibidir [20].

- Eşleştirme Takibi
- Ortogonal eşleştirme takibi
- Sahne bilge açgözlü yöntem
- Temel takip

- Koordinat İnişi

4.1.7. Dalga tabanlı öznelikler

Ses verisi üzerine dalgacık dönüşümü uygulanarak elde edilen çıktı üzerinde yapılan analiz ile tespit edilen özellikleridir. Dalgacık dönüşümü ayırık veya sürekli olarak iki tiptir.

- Sürekli dalgacık dönüşümüne dayalı özellikler
- Ayırık dalgacık dönüşümüne dayalı özellikler
- Dalgacık dönüşümü tabanlı özellikler
- Dalgacık paket ayrıştırma tabanlı

4.2. Özellik Çıkarımı

Bölüm 4.1 de ifade edilen ses özelliklerinin algoritmalarını her bir ses verisi için ayrı ayrı uygulandığında seslere ait özellik elde edilmiş olur. Bu algortimalar bölüm 5 de detayı verilen jaudio gibi birçok farklı araçla herhangi bir geliştirme yapmadan hızlı bir şekilde elde edilebilir. Elde edilen sayısal sonuçlar ses verisine ait baskın, ayırt edici özelliğin tespit edilip yüksek doğruluk değeri elde edilecek sınıflandırıcı özellikleri olarak kullanılır. Jaudio sunulduğundan günümüze kadar birçok akademik çalışmada kabul edilen bir özellik çıkarma yöntemi olarak kabul görmüştür [29-34].

Bu çalışma kapsamında kullanılan özneliklerin algoritmik açıklaması ve matematiksel modellemesi 4.1.3. Bölümünde sunulmuştur.

4.3. Özellik Seçimi

Özellik seçimi işlemleri çok sayıda özelliğe sahip veriler üzerinde sınıflandırma işlemi uygulanırken tercih edilir. Sınıfların ayrıştırılması için en yüksek başarı gösterecek özelliklerin seçimi yapılması için uygulanır. Bu çalışmada Sklearn kütüphanesine ait SelectKBest yöntemi ile f_regression fonksiyonu uygulanarak 5 özellik seçimi yapılmıştır. SelectKBest özellik seçim tekniği doğası gereği tek değişkenlidir. Farklı tek değişkenli istatistiksel testleri kullanarak, özellik setinden k tane en iyi özellikleri seçer. Bu çalışma, k en iyi özelliklerini seçmek için f_regression testine dayalı bir yöntem kullanılmıştır.

F_regression birden fazla özellik içerisinde her bir özelliğin etkisini puanlayarak etki alanını hesaplayan bir doğrusal modeldir. İki adımda gerçekleştirilmektedir.[35]

1. Bu yaklaşım F dağılımına dayanır ve aşağıdaki formüle göre her bağımsız özellik X'in [:i] bağımlı değişken y ile korelasyonunu hesaplar:

$$p_i = \frac{(X[:, i] - \text{mean}(X[:, i])) * (y - \text{mean}(y))}{\text{std}(X[:, i]) * \text{std}(y)} \quad (4.2)$$

2. Bir F puanına ve ardından bir p değerine dönüştürülür.

$$F_i = \frac{p_i^2}{1 - p_i^2} * (n - 1) \quad (4.3)$$

Öznitelik seçimi olarak bu yöntem ses verisi sınıflandırma konusunda literatürde kabul görmüş bir yöntemdir [36].

4.4. Makine Öğrenmesi Yöntemleri

Çalışma kapsamında yapılan öz nitelik çıkarımı ile elde edilen verilerden en iyi sonuç vereceği tespit edilen öz nitelikler için aşağıdaki sınıflandırma yöntemleri uygulanmıştır.


- Karar Ağacı
- KNN
- Naive Bayes
- Rastgele Orman Sınıflandırıcısı
- DVM

4.4.1. Karar ağacı

Karar ağaçları, kullanılan verilere ait özellik ve yapılacak sınıflandırmaya ait sınıflara göre sınıflara yönlendiren karar verici düğümler ve sınıf bilgisi olarak işaretlenen yaprak düğümlerden oluşan ağaç veri yapısı şeklinde bir model çıkaran bir denetimli sınıflandırma

yöntemidir. Karar ağacı modelini oluşturan algoritma, analiz edilecek veri setini küçük parçalara ayırarak ağaç modelini geliştirilir. Karar ağacı modeli içinde bir kara karar düğümü tek veya birden fazla alt dal içerebilir. Karar ağaçları 1968’de ID3 (Iterative Dichotomiser) ile başlayıp, günümüze kadar C4.5, C5.0 ve CART(Classification and Regression Trees) algoritmaları ile geliştirilmiştir. [37] Bu çalışma kapsamında kullanılan karar ağacı hazır kütüphanesi CART algoritmasının optimize edilmiş bir versiyonunu kullanmaktadır. Kategorik değişkenler için destek vermemektedir. CART algoritmasında ağaç oluşumu aşağıdaki algorithmada verilmiştir [38].

1. Kök düğümünden başlanır.
2. Sıralı her değişken X için, düğümdeki değerlerini az sayıda aralıkta gruplandırarak sıralanmamış bir değişken X' e dönüştürülür. X sıralanmamışsa, $X' = X$ olarak ayarlanır.
3. Düğümdeki veriler üzerinde her X' değişkeninin Y 'ye karşı bir chi kare bağımsızlık testi yapılır ve önem olasılığı hesaplanır.
4. En küçük önem olasılığına sahip X ile ilişkili X^* değişkeni seçilir.
5. Gini dizinlerinin toplamını en aza indiren bölünmüş küme $\{X^*\} S^*$ bulunur ve düğümü iki alt düğüme ayırmak için kullanılır.
6. Durdurma ölçütüne ulaşırsa, çıkılır. Aksi takdirde, her bir alt düğüme 2-5. Adımları uygulayın.
7. Ağacın CART yöntemiyle düzenlenmesi sağlanır.



Şekil 4.1. 4 farklı öznelik içimn 3 farklı sınıfın tespitini örnekleyen karar ağacı modeli örneği [39]

4.4.2. K-en yakın komşu (KNN)


k En Yakın Komşu Algoritması veri setindeki eğitim örneklerinin yakınlığına dayanarak verileri sınıflandıran danışmanlı ve parametrik olmayan bir sınıflama yöntemidir. Algoritma eğitim gerektirmemesi, kolay gerçekleştirilebilir olması, yerel bilgilere uyarlanabilir olması ve gürültülü eğitim verilerine dirençli olması gibi avantajları ile makine öğrenmesi yöntemleri içerisindeki popülerliğini yıllardır korumaktadır.

Algoritma, yeni bir veriyi sınıflamak için hangi sınıfa dâhil olduğu bilinen eğitim verilerinin k tanesinin yakınlığına bakarak işlem yapmaktadır. k değeri algoritmanın başında sezgisel olarak tanımlanmaktadır. Yakınlık hesabı için Manhattan, Hamming, Öklid ve Minkowski gibi uzaklık denklemleri kullanılmaktadır. Bu çalışma kapsamında uzaklık ölçüm fonksiyonu olarak Minkowski kullanılmıştır. Minkowski uzaklık hesaplaması aşağıdaki denklem ile hesaplanır. [40]

$$\left(\sum_{i=1}^N |X_i - Y_i|^p \right)^{1/p} \quad (4.4)$$

N öznitelik sayısı, i her bir veriyi temsil ederken X ve Y birbirinden farklı iki veriye ait noktayı temsil eder. P'nin varsayılan değeri 2 olarak bırakılmış yani oklid uzaklığı kullanılmıştır.

Aşağıdaki resimde 3 sınıftan oluşan bir veri seti için k=5 ile sınıflandırılmasına ilişkin örnek sunulmuştur.



Şekil 4.2. KNN 3 sınıftan oluşan örnek gösterimi [41]

4.4.3. Naive bayes

İsmi İngiliz matematikçi Thomas Bayes' ten alan Naive Bayes Sınıflayıcı, Bayes karar teorisine dayanan tanıda yüksek performansa sahip basit olasılıksal bir sınıflama yöntemidir. Naive Bayes sınıflandırıcıda niteliklerin hepsinin aynı derecede önemli olduğu ve niteliklerin hepsinin birbirinden bağımsız olduğu kabul edilmektedir.

Öğreticili bir öğrenme metodu kullanılan Bayes sınıflayıcı için sisteme sınıfları bilinen öğretilmiş veri sunulur. Öğretilmiş veriler üzerinde olasılık hesaplamaları yapılır. Elde edilen olasılık değerlerine göre test verilerinin hangi sınıfa ne kadar olasılıkla dâhil olduğu hesaplanmaya çalışılır. [40]

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)} \quad (4.5)$$

$P(c|x)$ = x olayı gerçekleştiğinde c olayının gerçekleşme olasılığı

$P(c)$ = c olayının gerçekleşme olasılığı

$P(x|c)$ = c olayı gerçekleştiğinde x olayının gerçekleşme olasılığı

$P(x)$ = x olayının gerçekleşme olasılığı


4.4.4. Rastgele orman sınıflandırıcısı

Rastgele Orman yaygın olarak kullanılan denetimli makine öğrenmesi algoritmalarındandır. Mevcut verilerin sınıflandırmasının yanı sıra regresyon işlemi için de kullanılabilir. Algoritmanın verilere uygulanması kolay olduğu kadar bir o kadar da esnektir. Algoritmanın ismindende anlaşılacağı gibi sınıflandırma işlemini yapmak için birden fazla ağaç veri modeli oluşturur ve bu modelleri rastgele oluşturur. Ne kadar çok ağacı varsa, o kadar sağlam bir orman olduğu söylenir. Rastgele ormanlar kullanılacak veri örnekleri içinde rastgele seçimler yaparak denetimli öğrenme yöntemlerinden karar ağaçlarından oluşturur, her karar ağacından yeni veri için bir tahmin belirler ve belirlenen tahminin doğruluğuna göre en iyi çözümü seçer. Rastgele orman çok sayıda karar ağacı üzerinden değerler elde eder ve bu karar ağaçlarının daha doğru ve istikrarlı olmasını sağlamak için elde ettiği birbirinden farklı karar ağaçlarını birleştirir. Ayrıca özellik öneminin oldukça iyi bir göstergesidir. Rastgele ormanlar, öneri motorları, görüntü sınıflandırma ve özellik seçimi gibi çeşitli uygulamalara sahiptir. Bunların yanı sıra akciğer ses analizlerinde %99 seviyelerinde doğruluk elde edilme sonuçlarına ulaştırabilmektedir. [42]

4.4.5. Destek vektör makinesi

Temeli istatistiksel öğrenme kuramına dayanan Destek Vektör Makineleri(DVM) yöntemi 1992 yılında Vladimir Vapnik tarafından geliştirilmiştir. Danışmanlı bir öğrenme algoritması olan DVM sınıflandırma, regresyon analizi ve doğrusal olmayan fonksiyon yaklaşımı problemlerini çözmek amacıyla kullanılmaktadır [43]. Bioinformatik problemlerin çözümünde, metin, ses, yazı, nesne ve görüntü tanıma problemlerinde yüksek sınıflama ve yüksek genelleme performansı sağlamaktadır [44].

DVM, sınırlı sayıda öğrenme örüntüsü için iyi bir genelleme elde etmeyi amaçlamaktadır. Karmaşık veri setlerinde, çözümlemesi zor örüntülerin tanınmasında kullanışlı bir öğrenme algoritmasını uygulamaktadır. Algoritma, önceden gözlenmemiş verilerin sınıflandırma kestirimi için örneklerden ayırt edebilen bir sınıflandırma öğrenmesini gerçekleştirmektedir. DVM 'de amaç verileri optimal olarak farklı kategorilere ayıran n boyutlu hiperdüzlem oluşturmaktadır. Yapay sinir ağlarına benzeyen DVM modelleri, sigmoid bir kernel fonksiyonu kullanan iki katmanlı, ileri beslemeli bir yapay sinir ağına sahiptir [45].




Şekil 4.3. Destek vektör makineleri genel yapısı

Şekil 5’de verilen yapıda, $K(x, x_m)$ çekirdek fonksiyonlarını ve α ise Lagrange katsayılarını göstermektedir. Çekirdek fonksiyonları girdilerin iç çarpımlarını hesaplanmak için kullanılan fonksiyonlardır. Lagrange çarpanları ise ağırlıkları ifade etmektedir. DVM ‘de bir örneğe ilişkin çıktı değeri, girdilerin iç çarpımları ile Lagrange çarpanlarının bağımsız kombinasyonlarının toplamına eşittir.

DVM, veri setinin doğrusal olarak ayrılıp ayrılamama durumuna göre doğrusal sınıflandırıcılar ve doğrusal olmayan sınıflandırıcılar olmak üzere ikiye ayrılmaktadır.

5. AKCİĞER SES ANALİZİ İLE HASTALIK TESPİTİ

Bu bölümde yapılan deneysel çalışma adımları aşağıda verilen sistem blok şeması doğrultusunda nasıl yapıldığına ait detaylı bilgi verilecektir.




Şekil 5.1. Sistemin blok şeması

5.1. Veri Seti


Daha önce hiçbir çalışmada kullanılmamış 60 kişiye ait sağlıklı bireylere ait normal olarak etiketlenmiş veriler ve hasta bireylere ait ral ve ronküs olarak etiketlenmiş veriler kullanılacaktır. Verileri sağlıklı ve hasta bireylere aynı koşullarda uygulanmış oskültasyon aşamasında toplanmıştır. Bu kapsamda spirometre esaslı hava akışı ölçüme veya biyoelektrik sinyal (EKG, EMG) veri toplama yöntemi olarak kabul edilmemiştir. Oskültasyon aşamasında toplanan veriler thorax bölgesinden toplanmıştır. Hazırlanan veri setinin her biri

15 saniye olacak şekilde düzenlenmiştir. Sinyaller 16 bit derinliğe sahip 40kHz hız ile sayısallaştırılmış ve WAV formatında kayıtlar oluşturulmuştur. Şekil 5.2.'de ses verisinin insan vücudundan toplama bölgesi belirtilmiştir.




Şekil 5.2. Toraks bölgesinin insan vücudundaki konumu.


Veri seti üzerinde görselleştirme çalışmaları yapılarak farklarının gözle görünebilir olması sağlanmıştır. Bu kapsamda dalga boyu, fast fourier transform, mel frekans kepstrum katsayısı ve spectrogram görümleri oluşturulmuştur.




Şekil 5.3. Python librosa kütüphanesi ile normal, ral ve ronküs seslerinin waveplot görünümü



Şekil 5.4. Python numpy kütüphanesi ile normal, ral ve ronküs seslerinin fast fourier transform görünümü.



Şekil 5.5. Python librosa kütüphanesiyle çıkarılmış pyplot ile görselleştirilmiş normal, ral ve ronküs seslerinin görünümü.



Şekil 5.6. Python librosa ile normal, ral, ronküs spectrogram görünümü

Faz-1 için kullanılan veri seti üzerinde yapılan veri görselleştirme çalışması kapsamında Şekil 5.3.'de dalga boyu görünümü, Şekil 5.4.'de FFT görünümü, Şekil 5.5'de librosa kütüphanesinde sunulan pyplot görünümü ve Şekil 5.6.'da spectrogram görünümü sunulmuştur.

Yapılan deneysel çalışmada veri görselleştirme, özellik çıkarımı, özellik seçimi ve sınıflandırma işlemleri 3 farklı veri setine uygulanmıştır. Faz-1 ilk teslim edilen gerçek veri setini temsil etmektedir. Faz-2 yeniden örnekleme ile veri oluşturma işlemi sonrasında oluşan toplam veri setini temsil etmektedir. Faz-3 ise Faz-1 de mevcut gerçek veri setine ek her sınıftan gelen 39x3 yeni gerçek verilerin eklenmiş halini temsil etmektedir.

Çizelge 5.1. Deneysel çalışmanın uygulandığı veri setleri

Sınıf	Faz-1	Faz-2	Faz-3
Normal	20	60	59
Ral	20	60	59
Ronküs	20	60	59


5.2. Yeniden Örnekleme ile Veri Oluşturma

Mevcut veri setinin sınırlı sayıda olması yapılan deneysel çalışma sonuçlarının tutarlılığı ile ilgili tereddüt oluşturduğu için yeniden örnekleme ile veri oluşturma yöntemleri uygulanarak, deneysel sonuçların tekrar değerlendirmesine ilişkin çalışma yapılmıştır. Literatür incelendiğinde solunum sesi sınıflandırılması için yeniden örneklem oluşturma yöntemleri Kabul görmüş bir yaklaşım olarak görülmektedir [46-48].

Ses verileri üzerinde zaman genişletme ve frekans verisinin y ekseninde kaydırılması uygulanarak yeniden örnekleme işlemi yapılmıştır.


Zaman genişletme uygulanarak ses verisinin genlik ve frekans değerlerinin değiştirilmeden ses tekrarı sağlanarak ses verisinin süresi arttırılmıştır. Mevcut 60 adet veri setine ek 60 adet yeniden örnekleme yöntemi ile veri üretilmiştir.

Pitch shifting uygulanarak ses verisinde frekans bilgisinde y düzleminde hareket ettirilme işlemi uygulanarak yeni örnekleme uygulanarak veri oluşturulur. Mevcut 60 adet veri setine ek 60 adet yeniden örneklenmiş veri üretilmiştir.



Şekil 5.7. Normal, ral ve ronküs sesler için sırasıyla gerçek veri, pitch shift ve time shift verilerinin waveform görseli.

Şekil 5.7.'de Faz-1 veri setindeki ilk işaretlenmiş normal, ral ve ronküs sesleri için ayrı ayrı perde değişimi ve zaman genişletme işlemlerinin sonucunda oluşan yeniden örnekleme ile oluşturulmuş yapay verilerin dalga boyu görünümü sunulmuştur.




Şekil 5.8. Normal, ral ve ronküs sesler için sırasıyla gerçek veri, pitch shift ve time shift verilerinin spectrogram görseli.

Şekil 5.8.'de Faz-1 veri setindeki ilk işaretlenmiş normal, ral ve ronküs sesleri için ayrı ayrı perde değişimi ve zaman genişletme işlemlerinin sonucunda oluşan yeniden örnekleme ile oluşturulmuş yapay verilerin spectrogram görünümü sunulmuştur.

5.3. Özellik Çıkarımı

Yapılan çalışmada iki farklı özellik çıkarımı uygulanmıştır. Bunlardan ilki python ile librosa kütüphanesi kullanılarak yapılmıştır. Bu kapsamda 12 farklı özneliğin en yüksek, en düşük ve ortalama değerleri alınarak toplam 36 özellik içerisinde seçilen özellikler ile %60 seviyelerinde sınıflandırma başarısı sağlanmıştır. Bu başarı seviyesinin düşük olmasından dolayı daha fazla özellik çıkarımı için hazır araç kullanımına başvurulmuştur. Bu kapsamda jAudio kullanılarak çalışma kapsamında tüm veri setleri için 72 farklı özellik çıkarımı uygulanmıştır.

Özellik çıkarımı aşağıda verilen arayüze eklenen ses verisinin sağ tarafta çıkarılabilecek özellikler üzerinden seçim yapılarak xml formatında çıktı üretilmektedir.



Şekil 5.9. jAudio kullanıcı arayüzü

Üretilen xml formatı csv formatına çevirilerek en sonuna bir sütun eklenerek veri setine ilişkin sınıflara işaret edecek şekilde 0=normal, 1=ral ve 2=ronküs olarak eklenmiştir. Ayrıca ses özelliklerinin açıklamasını içeren sütunlar silinerek ses özellik değerlerini içeren sütunların başına eklenmiştir. Bu işlemlerin sonunda özellik seçimi ve sınıflandırma için kullanılan matematiksel veri seti oluşturulmuştur.

5.4. Özellik Seçimi

Sınıflandırıcının başarısını yüksek tutmak için python sklearn kütüphanesi üzerinden SelectKBest yöntemine, f_regression fonksiyonu ile en iyi özellikler tespit edilmiştir. Sklearn üzerinden en iyi öz niteliklerin tespiti için 10 adet fonksiyon sağlanmaktadır.[13] Fakat bu fonksiyonların içinde seçilenlerin dışındaki yöntemler negatif sayılar için uygulanabilir

değildir. Kullanılan yöntem ile her bir özelliğin sınıflandırma başarısı için puanlandırma yapılmaktadır. En yüksek puan alan özellik seçimi yapılmaktadır.

Özellik çıkarma yöntemi olarak uygulanan jAudio aracının ürettiği özellikler içerisinde en yüksek başarı değerini verecek olan 5 özellik aşağıdakilerdir.

- MFCC'lerin Momentlerinin Alan Yöntemi Genel Standart Sapma 3. Boyut
- MFCC'lerin Momentlerinin Alan Yöntemi Toplam Ortalama 1. 2. 5. 8. Boyutlar

5.5. Sınıflandırıcı Ön İşlemleri ve Doğrulama Kriterleri

Bütün veri setlerinde uygulanan sınıflandırıcıların başarı değerleri aynı parametreler ile hesaplanmıştır. Bu doğrultuda sınıflandırıcıların doğruluk değerlerini hesaplamak için test ve eğitim seti ayrıştırması 70:30 olarak yapılmıştır. Doğruluk değerlerine ek olarak literatürde kabul görmüş olan çapraz doğrulama değerleri hesaplanmıştır. Literatürde en çok kabul gören 10'luk çapraz doğrulamaların yanında 4 ve 5 çapraz doğrulamaların da hesaplaması yapılarak Faz-1 verilerine uygulanmıştır. Her faz için sonuçların karşılaştırılması 10'luk çapraz doğrulama üzerinden yapılmıştır.

Ayrıca sınıflar üzerindeki sınıflandırıcı sonuçlarının daha detaylı değerlendirilmesi için fl-ölçümleri, duyarlılık, kesinlik hesaplamaları çıktı olarak üretilmiştir.

	Tahminlenen	
	Doğru Pozitif(DP)	Yanlış Negatif(YN)
Gerçekleşen	Yanlış Pozitif(YP)	Doğru Negatif(DN)

Şekil 5.10. Karışıklık matrisi

Aşağıdaki denklemde yukarıdaki verilen karışıklık matrisindeki değerler doğrultusunda doğruluk hesabı verilmiştir.

$$Doğruluk = \frac{DP + DN}{DP + YP + DN + YN} \quad (5.1)$$

Aşağıdaki denklemde yukarıdaki verilen karışıklık matrisindeki değerler doğrultusunda kesinlik hesabı verilmiştir.

$$Kesinlik = \frac{DP}{DP + YP} \quad (5.2)$$

Aşağıdaki denklemde yukarıdaki verilen karışıklık matrisindeki değerler doğrultusunda duyarlılık hesabı verilmiştir.

$$Duyarlılık = \frac{DP}{DP + YN} \quad (5.3)$$

Aşağıdaki denklemde yukarıdaki verilen karışıklık matrisindeki değerler doğrultusunda f1-ölçüm hesabı verilmiştir.

$$f1\text{ölçümleri} = 2 * \frac{kesinlik * duyarlılık}{kesinlik + duyarlılık} \quad (5.4)$$

6. DENEYSEL SONUÇLAR VE İRDELEME

Bu bölümde 3 fazdan oluşan veri setine bölüm 5.5 de anlatılan yöntemlerle elde edilmiş değerlerin irdelenmesi sunulacaktır. Çalışmanın faz-1 olarak ifade edilen 20 normal, 20 ronküs, 20 ral sesi için 70:30 olarak eğitim ve test verisi üzerinden hesaplanan doğruluk değeri ve çapraz doğrulama değerlerinin sınıflandırma yöntemleri için elde edilen sonuçları Çizelge 6.1. de sunulmuştur. Deneysel sonuçlar incelendiğinde sınıflandırma yöntemlerinden karar ağacı ve rastgele orman yöntemlerine ait doğruluk değerleri %94 elde edildiği görülmektedir. Ayrıca literatürde kabul görmüş 10'luk çapraz doğrulama değerleri göz önüne alındığında sınıflandırma yöntemlerinden Naive Bayes %95'lik önemli bir doğruluk değeri tespitini ortaya koymuştur.

Çizelge 6.1. Sınıflandırma yönteminin doğruluk değerleri ve çapraz doğrulama değerleri

Sınıflandırma Yöntemi	Doğruluk	4-çapraz	5-çapraz	10-çapraz
Karar Ağacı	0.94	0.83	0.86	0.93
KNN	0.88	0.83	0.86	0.93
Naive Bayes	0.88	0.83	0.86	0.95
Rastgele Orman	0.94	0.83	0.86	0.93
DVM	0.88	0.83	0.86	0.93

Çalışmanın faz-1 olarak ifade edilen 20 normal, 20 ronküs, 20 ral sesi için kesinlik değerleri aşağıdaki çizelgede sunulmuştur. Sınıflandırıcıların kesinlik değerlerinin sunulduğu Çizelge 6.2 incelendiğinde Normal ve Ronküs akciğer ses sınıflarında kesinlik değeri 1 olarak elde edilmiştir. Ral akciğer ses sınıfı için Karar ağaçları ve rastgele orman sınıflandırıcısı için kesinlik değeri 0.88 ile en yüksek değer olarak hesaplanmıştır.

Çizelge 6.2. Sınıflandırma yöntemlerinin kesinlik değerleri

Sınıf	Karar Ağacı	KNN	Naive Bayes	Rastgele Orman	DVM
Normal	1	1	1	1	1
Ral	0.88	0.78	0.78	0.88	0.78
Ronküs	1	1	1	1	1

Çalışmanın faz-1 olarak ifade edilen 20 normal, 20 ronküs, 20 ral sesi için duyarlılık değerleri aşağıdaki çizelgede sunulmuştur. Sınıflandırıcıların duyarlılık değerlerinin sunulduğu Çizelge 6.3. incelendiğinde Normal ve Ral akciğer ses sınıflarında duyarlılık

değeri 1 olarak elde edilmiştir. Ronküs akciğer ses sınıfı için karar ağacı ve rastgele orman sınıflandırıcısı için 0.83 olarak en yüksek değer elde edilmiştir.

Çizelge 6.3. Sınıflandırma yöntemlerinin duyarlılık değerleri

Sınıf	Karar Ağacı	KNN	Naive Bayes	Rastgele Orman	DVM
Normal	1	1	1	1	1
Ral	1	1	1	1	1
Ronküs	0.83	0.67	0.67	0.83	0.67

Çalışmanın faz-1 olarak ifade edilen 20 normal, 20 ronküs, 20 ral sesi için fl-ölçüm değerleri aşağıdaki çizelgede sunulmuştur. Sınıflandırıcıların fl-ölçüm değerlerinin sunulduğu Çizelge 6.4. incelendiğinde Normal akciğer ses sınıfları için 1 değeri elde edilmiştir. Ral akciğer ses sınıfı için en yüksek fl-ölçüm değerini 0,93 olarak karar ağaçları ve rastgele orman sınıflandırıcılarında hesaplanmıştır. Ronküs akciğer ses sınıfı için ise en yüksek fl-ölçüm değeri 0,91 olarak karar ağaçları ve rastgele orman sınıflandırıcılarında hesaplanmıştır.

Çizelge 6.4. Sınıflandırma yöntemlerinin fl-ölçüm değerleri

Sınıf	Karar Ağacı	KNN	Naive Bayes	Rastgele Orman	DVM
Normal	1	1	1	1	1
Ral	0.93	0.88	0.88	0.93	0.88
Ronküs	0.91	0.8	0.8	0.91	0.8

Çalışmanın faz-1 olarak ifade edilen 20 normal, 20 ronküs, 20 ral sesi için Karar Ağacı sınıflandırıcısına ait karışıklık matris değerleri aşağıdaki çizelgede sunulmuştur.

Çizelge 6.5. Karar ağacı karışıklık matrisi

Sınıf	Normal	Ral	Ronküs
Normal	5	0	0
Ral	0	7	0
Ronküs	0	1	5

Çalışmanın faz-1 olarak ifade edilen 20 normal, 20 ronküs, 20 ral sesi için KNN sınıflandırıcısına ait karışıklık matris değerleri aşağıdaki çizelgede sunulmuştur.

Çizelge 6.6. KNN karışıklık matrisi

Sınıf	Normal	Ral	Ronküs
Normal	5	0	0
Ral	0	7	0
Ronküs	0	2	4

Çalışmanın faz-1 olarak ifade edilen 20 normal, 20 ronküs, 20 ral sesi için Naive Bayes sınıflandırıcısına ait karışıklık matris değerleri aşağıdaki çizelgede sunulmuştur.

Çizelge 6.7. Naive Bayes karışıklık matrisi

Sınıf	Normal	Ral	Ronküs
Normal	5	0	0
Ral	0	7	0
Ronküs	0	2	4

Çalışmanın faz-1 olarak ifade edilen 20 normal, 20 ronküs, 20 ral sesi için Rastgele Orman sınıflandırıcısına ait karışıklık matris değerleri aşağıdaki çizelgede sunulmuştur.

Çizelge 6.8. Rastgele Orman karışıklık matrisi

Sınıf	Normal	Ral	Ronküs
Normal	5	0	0
Ral	0	7	0
Ronküs	0	1	5

Çalışmanın faz-1 olarak ifade edilen 20 normal, 20 ronküs, 20 ral sesi için Destek Vektör Makinesi sınıflandırıcısına ait karışıklık matris değerleri aşağıdaki çizelgede sunulmuştur.

Çizelge 6.9. DVM karışıklık matrisi

Sınıf	Normal	Ral	Ronküs
Normal	5	0	0
Ral	0	7	0
Ronküs	0	2	4

Uygulanan makine öğrenmesi sınıflandırma yöntemlerine ait karışıklık matrislerinin değerleri incelendiğinde akciğer ek seslerinden ronküs ses sınıfına ait bazı verilerin ral sınıfı olarak hatalı işaretlenmiş olabileceği kanısı oluşmaktadır. Ya da ronküs ses sınıfları

içerisinde sınıflandırmaya dahil edilmemesi gereken veriler olabileceğine ilişkin bir kanı oluşturmaktadır.

Uygulanan deneysel metodoloji açık kaynak hayvan sesleri üzerinde test edilerek elde edilen sonuçlar doğrultusunda mekanizmanın doğruluğu teyit edilmiştir. Her bir sınıflandırıcının mevcut veriler üzerinde elde ettiği sınıflandırıcı başarıları incelendiğinde çalışma yönteminin tutarlı olduğunu ortaya koyar. Hata sınıfları incelendiğinde Ronküs akciğer ek ses sınıfından bazı verilerin Ral akciğer ek ses sınıfı olarak sınıflandırılması ile oluşan yanlış sınıflandırmalar Ronküs veri setinin detaylı olarak incelenmesi gerektiği kanısı ortaya çıkmıştır. Diğer bir yandan sağlıklı kişilere ait normal ses sınıfına ait tüm verilerin %100 doğru işaretlenmesi ve bunun yanında herhangi bir ek sınıfın normal olarak işaretlenmemesi önemli bir çıktı olarak değerlendirilmektedir. Bu sayede hasta olmayan bir kişi için hasta veya hasta olan bir kişi için sağlıklı olarak yanlış çıktı üretilmemektedir.

Çalışma kapsamında tüm faz verileri için 10-çapraz doğruluk değerleri aşağıdaki çizelgede sunulmuştur. Faz-2 için KNN yöntemi %94.4 ile en yüksek değeri verirken Faz-1’de en yüksek değere sahip Naive Bayes yönteminde bir düşüş olduğu gözlemlenmiştir. Faz-3 için Karar ağaçları ve DVM sınıflandırıcılarında değerlerde yükselme olmasına rağmen diğer sınıflandırıcıların değerlerinde düşüş gözlemlenmiştir.

Çizelge 6.10. Her faz için 10-çapraz doğruluk değerleri

Sınıflandırma Yöntemi	Faz-1	Faz-2	Faz-3
Karar Ağacı	0.931	0.938	0.937
KNN	0.933	0.944	0.931
Naive Bayes	0.950	0.922	0.930
Rastgele Orman	0.933	0.938	0.931
DVM	0.933	0.938	0.937

Faz-3 veri seti için tüm sınıflandırıcıların doğruluk değeri %100 olarak hesaplandığı görülmüştür.

7. SONUÇ VE ÖNERİLER

Çalışma kapsamında 60-180-177 olarak 3 fazlı veri seti üzerinde jaudio kullanılarak 200'ün üzerinde ses öz nitelik çıkarım işlemi yapılmıştır. Literatürde karşılaşılan çalışmalarda sesin farklı domain özelindeki özellikler üzerinden sınıflandırma işlemi yapıldığı görülmektedir. Bu çalışma ise jaudio ile çıkarılabilen tüm ses öz nitelikleri içinde en yüksek başarı verecek öz nitelik seçimi uygulanmıştır. Uygulamanın sonucunda 5 farklı makine öğrenmesi sınıflandırma yöntemi uygulanarak %85-%100 arasında doğruluk değerleri elde edilmiştir.

Literatürde kabul görmüş 10'lu çapraz doğrulama yöntemine ait ortalama değerlerin tüm sınıflandırıcılarda yakın değerler üretmesi deneysel metodun tutarlılığını ortaya koymaktadır.

Faz-1 veri setine uygulanan deneysel sonuçlar tekil bir ses verisinin oluşturduğu sapmadan dolayı veri setinin incelenmesi gerektiğini ortaya koymuştur.

Faz-3 için veri setinde 100%'lük doğruluk değerinin tüm algoritmalarla elde edilmesi veri setinde bir belirsizlik oluşturmuştur. Bu belirsizlik kusursuz bir veri seti olabileceği gibi aynı verilerin hasta bazında veya solunum döngüsü bazında tekrarlı olarak aynı oluşturulmuş olabileceği kanısı oluşturmuştur.

Çalışma kapsamında literatürde incelenen çalışmalardan farklı olarak çok az sayıda solunum döngüsü içeren akciğer ses verisi üzerinde sınıflandırma yapılmıştır. Veri kümesinin küçük olması sınıflandırma problemlerinde yanıltıcı sonuçlar doğurabilmektedir. Ayrıca yine literatürde benzeri olmayan yeniden örnekleme yöntemleri uygulanarak veri artırma yöntemi uygulanarak sınıflandırıcıların değerlendirilmesi yapılmıştır.

Akciğer ses verilerinin doğru bir şekilde oluşturulan solunum döngüleri ve işaretlenmiş verileri ile makine öğrenmesiyöntemleri kullanılarak yüksek doğruluk değeri elde edilebileceği ortaya konmuştur.

Ses verilerine ait resim tabanlı özellikler ve derin özelliklerin çıkarımı yapılarak sınıflandırıcı olarak derin öğrenme yöntemleri uygulanıp deneysel sonuçların incelenmesi önerilmektedir.

Önerilen yeni sınıflandırıcıların değerlendirmelerini yaparken veri setindeki fazlandırma yapısı kullanılması önerilmektedir. Deneysel sonuçlardaki değişim fazlar doğrultusunda kontrol edilerek mevcut çalışmanın çıktıları ile karşılaştırılması önerilmektedir.

Sınıflandırıcıların birbirine tutarlı sonuçlar üretmesi uygulanan sistemin hem akademik hem de ticari olarak fayda sağlayacağı ortaya konmuştur.



KAYNAKLAR

1. Mondal, A., Bhattacharya, P., and Saha, G. (2014). Detection of lungs status using morphological complexities of respiratory sounds. *The Scientific World Journal*, 2014(1) 1-9.
2. Lehrer, S., Nowey Donald, W., Topalcan, A. ve Öztürk, C. (2007). *Akciğer sesleri kılavuzu*. Hekimler Yayın Birliği, Ankara.
3. Bohadana, A., Izbicki, G. and Kraman, S. S. (2014). Fundamentals of lung auscultation. *New England Journal of Medicine*, 370(8), 744-751.
4. Güler, H. C., Yıldız O., Baysal, U., Cinyol F. B., Köksal, D., Babaoğlu, E., Ulaşlı, S. S. (2020, November). *Classification of Abnormal Respiratory Sounds Using Machine Learning Techniques*. In 2020 Medical Technologies Congress (TIPTEKNO). Antalya, Turkey.
5. Sarkar, M., Madabhavi, I., Niranjana, N. and Dogra, M. (2015). Auscultation of the respiratory system. *Annals of thoracic medicine*, 10(3), 158.
6. Don, S. (2020). Random subset feature selection and classification of lung sound. *Procedia Computer Science*, 167, 313-322.
7. Demir, F., Sengur, A. and Bajaj, V. (2020). Convolutional neural networks based efficient approach for classification of lung diseases. *Health Information Science and Systems*, 8(1), 1-8.
8. Islam, M. A., Bandyopadhyaya, I., Bhattacharyya, P. and Saha, G. (2018). Multichannel lung sound analysis for asthma detection. *Computer Methods and Programs in Biomedicine*, 159, 111-123.
9. Bardou, D., Zhang, K. and Ahmad, S. M. (2018). Lung sounds classification using convolutional neural networks. *Artificial Intelligence in Medicine*, 88, 58-69.
10. Aras, S., Gangal, A. and Bülbül, Y. (2015, May). *Classification of healthy and pathologic lung sounds recorded with electronic auscultation*. In 2015 23rd Signal Processing and Communications Applications Conference (SIU). Malatya, Türkiye.
11. Aras, S. and Gangal, A. (2017, July). *Comparison of different features derived from mel frequency cepstrum coefficients for classification of single channel lung sounds*. In 2017 40th International Conference on Telecommunications and Signal Processing (TSP). Barcelona, Spain.
12. Li, J. and Hong, Y. (2016, November). *Crackles detection method based on time-frequency features analysis and SVM*. In 2016 IEEE 13th International Conference on Signal Processing (ICSP). Chengdu, China.
13. Ulukaya, S., Serbes, G., Sen, I. and Kahya, Y. P. (2016, August). *A lung sound classification system based on the rational dilation wavelet transform*. In 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Orlando, FL, USA.

14. Datta, S., Choudhury, A. D., Deshpande, P., Bhattacharya, S. and Pal, A. (2017, July). Automated lung sound analysis for detecting pulmonary abnormalities. In *2017 39th Annual International Conference of the Ieee Engineering in Medicine and Biology Society (EMBC)*, Jeju, Korea (South).
15. Naves, R., Barbosa, B. H. and Ferreira, D. D. (2016). Classification of lung sounds using higher-order statistics: A divide-and-conquer approach. *Computer methods and programs in biomedicine*, 129, 12-20.
16. Haider, N. S., Singh, B. K., Periyasamy, R. and Behera, A. K. (2019). Respiratory sound based classification of chronic obstructive pulmonary disease: a risk stratification approach in machine learning paradigm. *Journal of medical systems*, 43(8), 255.
17. Balli, O. and Kutlu, Y. (2021). *Effect of Window Size for Detection of Abnormalities in Respiratory Sounds*. arXiv preprint arXiv:2101.08495.
18. Rocha, B. M., Pessoa, D., Marques, A., Carvalho, P. and Paiva, R. P. (2021, January). Influence of Event Duration on Automatic Wheeze Classification. In *2020 25th International Conference on Pattern Recognition (ICPR)*, Milan, Italy.
19. Polat, H. ve Darılmaz, M. (2003). Elektronik stetoskopun akciğer oskültasyon yeteneğinin incelenmesi ve akciğer seslerinin spektral analizi. *Politeknik Dergisi*, 6(4), 613-619.
20. Sharma, G., Umapathy, K. and Krishnan, S. (2020). Trends in audio signal feature extraction methods. *Applied Acoustics*, 158, 107020.
21. Derneği, T. T. (2016). Astım tanı ve tedavi rehberi güncellemesi. *Turkish Thorac Journal*, 17(1), 1-96.
22. Milli Eğitim Bakanlığı. (2011). *Solunum Sistemi Hastalıkları ve Solunum Sistemine Etkili İlaçlar*. Ankara: Millî Eğitim Bakanlığı Eğitim ve Kültür Yayınları.
23. Türk Toraks Derneği. (2017). *Türk Toraks Derneği ' nin GOLD 2017 Kronik Obstrüktif Akciğer Hastalığı (KOAH) Raporuna Bakışı*. Ankara: Bilimsel Tıp Yayınevi.
24. Singh, D., Agusti, A., Anzueto, A., Barnes, P. J., Bourbeau, J., Celli, B. R., ... and Vogelmeier, C. (2019). *Global strategy for the diagnosis, management, and prevention of chronic obstructive lung disease: the GOLD science committee report*. *European Respiratory Journal*, 53(5).
25. Mahmutoglu, A. S., Ertürk, Ş. M. ve Çelebi İ. (2013). Hava yolu hastalıkları. *Toraks Cerrahisi Bülteni*, 4(3), 157-162
26. İnternet: Kumbasar, Ö., Sarkoidoz, Ö., Sarkoidoz. URL:<http://file.lookus.net/TGHYK/tghyk.27.pdf>. Son erişim tarihi: Mayıs 2021.
27. Şen, N., Özhan, M. H. (2017). *Pnömoni*. TÜSAD Eğitim Kitapları Serisi, 7-9.
28. Fujinaga, I. (1997). *Uyarlamalı Optik Müzik Tanıma*, Doktora tezi, McGill Üniversitesi, Elektrik ve Bilgisayar Mühendisliği Bölümü, Kanada.

29. Zvarevashe, K. and Olugbara, O. O. (2020). Recognition of cross-language acoustic emotional valence using stacked ensemble learning. *Algorithms*, 13(10), 246.
30. Kim, T., Kim, J. W. and Lee, K. (2018). Detection of sleep disordered breathing severity using acoustic biomarker and machine learning techniques. *Biomedical Engineering Online*, 17(1), 1-19.
31. Baniya, B. K., Lee, J. and Li, Z. N. (2014, October). Audio feature reduction and analysis for automatic music genre classification. In *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, San Diego, CA, USA.
32. Adi, D. P., Junaedi, L., Gumelar, A. B. and Kristanto, A. A. (2021). Exploring the Time-efficient Evolutionary-based Feature Selection Algorithms for Speech Data under Stressful Work Condition. *EMITTER International Journal of Engineering Technology*, 9(1), 60-74.
33. Goyal, J., Khandnor, P. and Aseri, T. C. (2020). Classification, prediction, and monitoring of parkinson's disease using computer assisted technologies: a comparative analysis. *Engineering Applications of Artificial Intelligence*, 96, 103955.
34. da Costa, R. R., Gorgônio, A. C., Barreto, C. A. D. S., Lima, D. F. and Canuto, A. M. D. P. (2020). Detecção de Problemas Respiratórios através de Áudios Pulmonares utilizando Aprendizado de Máquina. *Anais do Encontro de Computação do Oeste Potiguar ECOP/UFERSA*, (4).
35. Kaliorakis, M., Chatzidimitriou, A., Papadimitriou, G. and Gizopoulos, D. (2018). Statistical analysis of multicore CPUs operation in scaled voltage conditions. *Institute of Electrical and Electronics Engineers Computer Architecture Letters*, 17(2), 109-112.
36. Aziz, N. A. A., Maarof, M. A., and Zainal, A. (2021, January). *Hate Speech and Offensive Language Detection: A New Feature Set with Filter-Embedded Combining Feature Selection*. In *2021 3rd International Cyber Resilience Conference (CRC)*. Langkawi Island, Malaysia.
37. Safavian, S. R., and Landgrebe, D. (1991). A survey of decision tree classifier methodology. *Institute of Electrical and Electronics Engineers Transactions on Systems, Man and Cybernetics*, 21(3), 660-674.
38. Loh, W. Y. (2011). Classification and regression trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1(1), 14-23.
39. Kavzoğlu, T. ve Çölkesen, İ. (2010). Karar ağaçları ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği. *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45.
40. Raj, R., Nehemiah, H. K., Elizabeth, D. S. and Kannan, A. (2018). A novel feature-significance based k-nearest neighbour classification approach for computer aided diagnosis of lung disorders. *Current Medical Imaging*, 14(2), 289-300.
41. Fan, G. F., Guo, Y. H., Zheng, J. M. and Hong, W. C. (2019). Application of the weighted k-nearest neighbor algorithm for short-term load forecasting. *Energies*, 12(5), 916.

42. Jaber, M. M., Abd, S. K., Shakeel, P. M., Burhanuddin, M. A., Mohammed, M. A. and Yussof, S. (2020). A telemedicine tool framework for lung sounds classification using ensemble classifier algorithms. *Measurement*, 162, 107883.
43. Vapnik, V. N. (1998). *Computational Learning Theory*. New York: Wiley.
44. Başer, F. ve Apaydın, A. (2015). Sınıflandırma amaçlı destek vektör makinelerinin lojistik regresyon ile karşılaştırılması. *Anadolu University of Sciences & Technology-B: Theoretical Sciences*, 3(2), 53-65.
45. Ayhan, S. ve Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
46. Zhao, X., Shao, Y., Mai, J., Yin, A. and Xu, S. (2020, December). *Respiratory Sound Classification Based on BiGRU-Attention Network with XGBoost*. In 2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Seoul, Korea (South).
47. Hazra, R. and Majhi, S. (2020, October). *Detecting Respiratory Diseases from Recorded Lung Sounds by 2D CNN*. In 2020 5th International Conference on Computing, Communication and Security (ICCCS). Patna, India.
48. Ma, Y., Xu, X. and Li, Y. (2020, October). *LungRN+ NL: An Improved Adventitious Lung Sound Classification Using Non-Local Block ResNet Neural Network with Mixup Data Augmentation*. In Interspeech, Online.
50. Kotsiantis, S. B., Zaharakis, I. D. and Pintelas, P. E. (2006). Machine learning: a review of classification and combining techniques. *Artificial Intelligence Review*, 26(3), 159-190.
51. Jindal, V., Agarwal, V., and Kalaivani, S. (2018, December). *Respiratory Sound Analysis for Detection of Pulmonary Diseases*. In 2018 IEEE Applied Signal Processing Conference (ASPCON). Kolkata, India.
52. Poreva, A., Karplyuk, Y. and Vaityshyn, V. (2017, November). *Machine learning techniques application for lung diseases diagnosis*. In 2017 5th IEEE Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE), Riga, Latvia.



GAZİ GELECEKTİR..