

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**AKCİĞER SESLERİNİN HASTALIKLI VE SAĞLIKLI OLARAK
İKİ SINIFA AYRILMASI**

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisi Mehmet CİNEL

**HAZİRAN 2019
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**AKCİĞER SESLERİNİN HASTALIKLI VE SAĞLIKLI OLARAK
İKİ SINIFA AYRILMASI**

Elektrik-Elektronik Müh. Mehmet CİNEL

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"ELEKTRONİK YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 20 / 05 / 2019

Tezin Savunma Tarihi : 28 / 06 / 2019

Tez Danışmanı : Prof. Dr. Ali GANGAL

Trabzon 2019

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**Elektrik-Elektronik Mühendisliği Anabilim Dalında
Mehmet CİNEL Tarafından Hazırlanan**

AKCİĞER SESLERİNİN HASTALIKLI VE SAĞLIKLI OLARAK İKİ SINIFA AYRILMASI

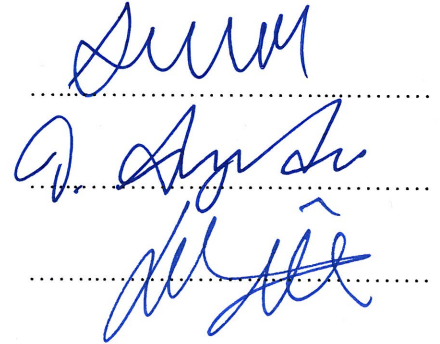
**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 14/ 06/ 2019 gün ve 1807 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.**

Jüri Üyeleri

Başkan : Prof. Dr. Ali GANGAL

Üye : Doç. Dr. Önder AYDEMİR

Üye : Doç. Dr. İbrahim Yücel ÖZBEK



**Prof. Dr. Asim KADIOĞLU
Enstitü Müdürü**

ÖNSÖZ

Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Programı çerçevesinde hazırladığım bu tezde dijital bir stetoskop ve dijital ses kaydedici kullanarak, uzman doktorlar tarafından kaydedilen akciğer seslerinin sınıflandırılmasında kullanılan yöntemlerin ayrı ayrı ve birbirine entegre olarak kullanıldığında, sınıflandırma üzerindeki etkisini belirten bir çalışma yapılmıştır.

Bu yüksek lisans tezi çalışmaları, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TÜBİTAK) 116E003 nolu projede bursiyer olarak yer alınarak sürdürülmüştür.

Tez çalışmalarım süresinde bilimsel ve manevi anlamda yardımlarını esirgemeyen danışmanım Sayın Prof. Dr. Ali GANGAL'a ve bana her daim destek olup kendilerine gönül borcum bulunan kıymetli aileme saygı ve sevgilerimi sunarım.

Bu tezin, vatana, millete ve devlete hayırlı olmak için çalışan herkese, hedefi doğrultusunda amacına ulaşabilmesi için bir basamak olmasını umut ediyorum.

Mehmet CİNEL

Trabzon 2019

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Akciğer Seslerinin Hastalıklı ve Sağlıklı Olarak İki Sınıfa Ayrılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Ali GANGAL’ın sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 28/06/2019.

Mehmet CİNEL

İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ	X
SEMBOLLER DİZİNİ.....	XI
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Solunum	1
1.3. Akciğer Sesleri ve Oskültasyon	2
1.4. Solunum Sesleri.....	3
1.4.1. Bronşial, Veziküler ve Bronkoveziküler Sesler	3
1.4.2. Raller	3
1.4.2.1. İnce Raller	4
1.4.2.2. Kaba Raller.....	4
1.4.3. Ronküs.....	4
1.5. Akciğer Seslerinin Kaydedilmesi.....	5
1.6. Veri Seti.....	5
1.7. Öznitelikler.....	5
1.8. Sınıflandırma	6
1.9. Literatür	6
1.10. Tezin Kapsamı.....	9
2. ÇALIŞMALAR.....	11
2.1. Materyal	11
2.2. Yöntem	11
2.2.1. Önışleme.....	12
2.2.2. Solunum Döngülerinin Tespit Edilmesi	13
2.2.3. Veri Setlerinin Oluşturulması.....	16
2.2.4. Mel Frekansı Kepstrum Katsayıları	17

2.2.5.	Sınıflandırma	20
2.2.5.1.	k – En Yakın Komşuluk	20
2.2.5.2.	Destek Vektör Makineleri	21
3.	BULGULAR	24
3.1.	MFKK'nın Ortalamasıyla Elde Edilen Öznitelik Vektörünün Sınıflandırma Bulguları	24
3.2.	MFKK Katsayılarının Standart Sapmasıyla Elde Edilen Öznitelik Vektörünün Sınıflandırma Bulguları	24
3.3.	MFKK Katsayılarının Basıklığıyla Elde Edilen Öznitelik Vektörünün Sınıflandırma Bulguları	25
3.4.	MFKK Katsayılarının Çarpıklığıyla Elde Edilen Öznitelik Vektörünün Sınıflandırma Bulguları	25
3.5.	MFKK Katsayılarının Entropisiyle Elde Edilen Öznitelik Vektörünün Sınıflandırma Bulguları	26
4.	SONUÇLAR	27
5.	ÖNERİLER VE TARTIŞMA	28
6.	KAYNAKLAR.....	30
	ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

AKCİĞER SESLERİNİN HASTALIKLI VE SAĞLIKLI OLARAK İKİ SINIFA
AYRILMASI

Mehmet CİNEL

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Ali GANGAL
2019, 33 Sayfa

Akciğer sesleri, insanın çeşitli solunum yolu rahatsızlıklarına göre değişebilmektedir. Bu sesleri inceleyebilmek için oskültasyon olarak adlandırılan bir sistem geliştirilmiştir. Bu sistemde akciğer seslerini deri üzerinden duymaya yarayan cihaza stetoskop adı verilmiştir. Medikal elektroniğin de gelişmesiyle bu konudaki araştırmaların sayısı oldukça artmıştır. Bu tez çalışmasında, analog akciğer seslerini, elektronik stetoskop vasıtasıyla alınmış, dijital ses kaydedici ile bilgisayar ortamına kaydedilmiş ve üzerinde MFKK katsayılarının ana parametre olduğu çeşitli öznelik çıkarma yöntemleriyle yüksek sınıflandırma doğruluğu elde edilebilen yöntem geliştirilmiştir. Sınıflandırıcı olarak k-EYK ve DVM kullanılmıştır. Elde edilen sonuçlara göre en yüksek sınıflandırma doğruluğu performansı gösteren kombinasyon, MFKK katsayıları hesaplanan akciğer seslerinin ortalaması alınarak oluşturulan öznelik vektörüdür. Bundan sonra sınıflandırma performansı olarak standart sapma ve entropi gelmektedir.

Anahtar Kelimeler: Akciğer sesleri, Mel-Frekansı Kepstrum Katsayıları, Öznelik çıkarma, Sınıflandırma, k-EYK, DVM

Master Thesis

SUMMARY

CLASSIFICATION OF LUNG SOUNDS TO TWO CLASSES AS
UNHEALTHY AND HEALTHY

Mehmet CİNEL

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program
Supervisor: Prof. Dr. Ali GANGAL
2019, 33 Pages

Lung sounds are changeable by some respiratory deflections of human. In order to examine these sounds, a system was developed which called auscultation. In this system, used to hear lung sounds as a non-invasive device named stethoscope. The number of studies has increased in this area while growing medical electronic. Analogue lung sounds taken by an electronic stethoscope and saved a computer via digital voice recorder and practised to get the best way of classification of these sounds while MFCC coefficients are the main parameter of some feature extraction paths. k-NN and SVM used as a classifier. According to this study's results, the combination with the highest classification accuracy performance is the set of attributes that calculated by taking the average of MFCC coefficients and calculated lung sounds. After that, the classification performance comes as standard deviation and entropy.

Key Words: Lung Sounds, Mel-Frequency Cepstral Coefficients, Feature extraction, Classification, k-NN, SVM

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.	Akciğer Seslerini Oskültasyonla Dinleme Prosedürü	2
Şekil 2.	Solda Analog Stetoskop Sağda Elektronik Stetoskop.....	3
Şekil 3.	Akciğer Ses Çeşitleri.....	4
Şekil 4.	İnce Ral ses kayıt örneği	11
Şekil 5.	Sinyalden alınan bir çerçeveye Hamming pencere uygulaması.....	12
Şekil 6.	Model ve test paternlerinin belirlenmesi.....	14
Şekil 7.	Öznitelik Çıkarma Diagramı	17
Şekil 8.	Mel Ölçeğinin Frekans Düzlemindeki Karşılığı	18
Şekil 9.	Mel Üçgen Filtre Bankası	18
Şekil 10.	MFKK Katsayılarını Elde Etme Yöntemi.....	20
Şekil 11.	k- En Yakın Komşuluk Sınıflandırıcı Örneği	21
Şekil 12.	Destek Vektör Makineleri Örneği.....	21

TABLÖLAR DİZİNİ

Sayfa No

Tablo 1.	Akciğer Seslerinden Oluşan Veri Sınıfları.....	16
Tablo 2.	MFKK'nın Ortalamasının Sınıflandırma Sonuçları	24
Tablo 3.	MFKK'nın Standart Sapmasının Sınıflandırma Sonuçları	25
Tablo 4.	MFKK'nın Basıklığının Sınıflandırma Sonuçları.....	25
Tablo 5.	MFKK'nın Çarpıklığının Sınıflandırma Sonuçları.....	26
Tablo 6.	MFKK'nın Entropisinin Sınıflandırma Sonuçları	26
Tablo 7.	Sınıflandırma sonuçlarının 10 tekrar için ortalamaları	27

SEMBOLLER DİZİNİ

- bM_L^i : i . modelin alt sınır indeksi
- bM_U^i : i . modelin üst sınır indeksi
- $bt_L^{i,r}$: i . model ile karşılaştırmak için seçilen test paterninin alt sınır indeksi
- $bt_U^{i,p}$: i . model ile karşılaştırmak için seçilen test paterninin üst sınır indeksi
- $M_i[n]$: i . model için seçilen patern
- $T_{i,p}[n]$: i . model ile karşılaştırılmak için seçilen p . patern
- DZB : Dinamik Zaman Bükme
- k-EYK : k-En Yakın Komşuluk
- DVM : Destek Vektör Makineleri
- MFKK : Mel Frekanslı Kepstrum Katsayıları

1. GENEL BİLGİLER

1.1. Giriş

Akciğer sesleri, diyafram kasının hareketiyle havanın akciğerlere alınması ve bırakılması sırasında dokularda oluşan titreşimin çıkardığı seslerdir. Bu seslerin insan kulağıyla duyulması oldukça zordur. Bu nedenle stetoskop kullanılır. Akciğer seslerini dinleme tekniğine de oskültasyon denir. Günümüzde de halen kullanılmakta olan stetoskoplar, oskültasyon prosedürü için vazgeçilmez kabul edilir.

Oskültasyon, izlenilmesi gereken kurallar dizini olarak kabul edilebilir. Bu kurallardan en önemlileri, hastanın akciğerlerinden gelen sesleri duyabilmek ve ayırt edebilmektir. Bu noktada henüz oskültasyon becerisi elde etmemiş doktorların ya da bu ihtiyacı giderebilecek herhangi birinin bulunmaması durumu bir sorun oluşturmaktadır. Akciğer seslerinin anlamlarının bilinmesiyle erken teşhis mümkün olabilmekte ve gerekli tedavi uygulanarak hastanın hastalığının daha ilerlemeden sağlığına kavuşmasının önünü açmaktadır.

Elektronik stetoskoplar yardımıyla akciğer sesleri kaydedilebilmektedir. Bu sayede sayısal ortamda üzerinde işlem yapılabilir bir hale getirilmiş olur. Bu tez çalışmasında uzmanları tarafından kaydedilmiş ve uygun olarak etiketlenmiş olan akciğer seslerinin sayısal ortamdaki sınıflandırması işleminin, hangi öznelik çıkarma yöntemiyle ne kadar yapılabildiğini oransal olarak gösterip, en iyi şekilde sınıflandırmanın hangi işlemlerle yapılabileceğini gözler önüne sermektedir.

Bu çalışmanın amacı, oskültasyon prosedürü, standart bir stetoskobu kullanmak kadar kolay hale gelip, bir uzman olmaksızın hastalık teşhisinin mümkün olabilmelerini sağlamaktır.

1.2. Solunum

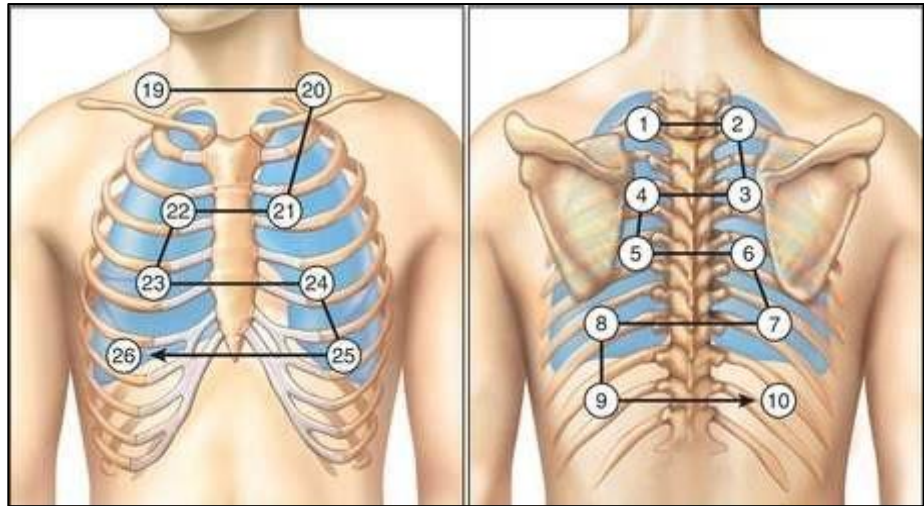
İnsan vücudundaki hücrelerin çalışabilmesi için gerekli olan oksijeni atmosferden alan ve hücrelerin bu oksijeni kullanarak gerçekleştirdiği oksidasyonla üretmiş olduğu atıklardan olan karbondioksiti atmosfere bırakan organ akciğerlerdir.

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 oksijenle 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.

1.3. Akciğer Sesleri ve Oskültasyon

İnsanların akciğerlerinden gelen seslerin stetoskop adı verilen dinleme aracıyla Şekil 1'deki gibi belirli noktalardan ve belirli sırada dinlenmesi işlemine oskültasyon denir. Bu işlem yüzyıllardır farklı araçlarla dahi olsa kullanılmakta olup, gelişerek günümüze kadar gelmiş ve halen kullanılmaktadır [1]. Bugün bu dinleme işlemi dünyada en yaygın olarak Şekil 2'de de gösterildiği gibi stetoskoplar yardımıyla yapılmaktadır.



Şekil 1. Akciğer Seslerini Oskültasyonla Dinleme Prosedürü



Şekil 2. Solda Analog Stetoskop Sağda Elektronik Stetoskop

1.4. Solunum Sesleri

Sağlıklı insandaki akciğer sesleriyle solunum yollarında herhangi bir rahatsızlığa sahip bir bireyde oluşan akciğer sesleri farklılık göstermektedir [2]. Bu hastalıklı seslerden yaygın olanları, Amerikan Toraks Cemiyeti tarafından ince ral, kaba ral, ronküs ve wheeze olarak adlandırılmıştır. Şekil 3'te bu seslerin bazıları gösterilmiştir.

1.4.1. Bronşial, Veziküler ve Bronkoveziküler Sesler

Sağlıklı bir bireyde duyulan akciğer sesleridir. Bu seslerin haricindeki sesler normal olmayan sesler olarak sınıflandırılırlar. Şekil 3'te bahsedilen akciğer seslerinden bir kısmı gösterilmiştir. Normal olmayan seslerden çalışmamızda konu edindiğimiz sesler aşağıda tanımlanmıştır.

1.4.2. Raller

Genellikle nefes alma sırasında duyulan seslerdir. Akciğerlerin belirli bölgelerinde sıvı birikmesi ve buna istinaden hava akışı sırasında sıvı dolu bölgelerin açılmasıyla gelen seslerdir.

1.4.2.1. İnce Raller

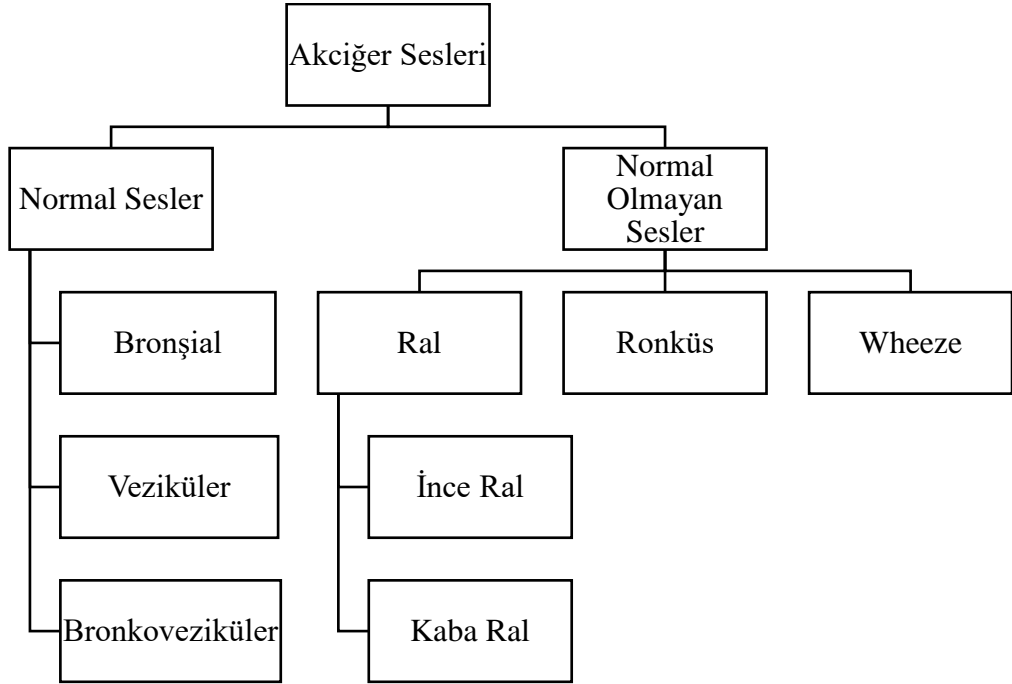
Alveollerde biriken sıvıların oluşturduğu, “çıtırtı” benzeri seslerdir. Öksürme ile kaybolmazlar.

1.4.2.2. Kaba Raller

Akciğer oskültasyonunda nefes alma esnasında duyulan, “gargara” sesine benzer bir sestir. İnce rallere göre daha yüksek miktarda sıvının birikimi söz konusudur. Öksürmek suretiyle nispeten kaybolabilirler.

1.4.3. Ronküs

Nefes alış ve veriş esnasında duyulabilirler. Yalnızca sıvı birikimi değil, tümör ve benzeri oluşumların da sebep olabildiği seslerdir. Bu seslerin oluşma nedeni, havanın akış güzergahındaki sıkışma ve daralmalardır. “horlama” ya benzer, kaba bir sestir.



Şekil 3. Akciğer Ses Çeşitleri

1.5. Akciğer Seslerinin Kaydedilmesi

Oskültasyon prosedürüne göre hasta dik konumda oturtulur ve dinleme sırasıyla sistem uygulanır. Hastadan derin nefes alıp vermesi istenir. Duruma göre hasta öksürtülür ve tekrar derin nefes alıp vermesi suretiyle oskültasyon işlemi uygulanır. Ses kayıtlarında, stetoskobun insan derisine teması sırasında oluşması muhtemel olan gürültü üzerinde bir de çevreden ses gürültüsünü eklememek veya gürültü seviyesini aşağı çekmek amacıyla kayıtlar mümkün oldukça sessiz bir ortamda alınır. Akciğer sesleri, elektronik stetoskop (Thinklabs ds - 32a+) ve bu seslerin frekans aralığında [3] kayıt yapabilen bir dijital ses kaydedici yardımıyla bilgisayar ortamına aktarılır.

1.6. Veri Seti

Elektronik Oskültasyon ile Kayıt Edilen Akciğer Seslerinin Otomatik Tanınması İçin Etkin Bir Öznitelik Çıkarma ve Sınıflandırma Yöntemi Geliştirme adlı ve 116E003A kodlu, TÜBİTAK projesinde Aras tarafından geliştirilen, solunum döngülerini birbirinden ayıran algoritmayla[4] solunum periyotları belirlenmiştir.

Toplamda elde edilen 157 adet akciğer sesinden 37'si ince ral, 60'ı ronküs ve 60'ı sağlıklı akciğer sesidir. Başlangıç ve bitiş noktalarını belirlediğimiz bu seslerin her biri için MFKK katsayılarını hesaplayarak veri seti oluşturulmuştur. Bu çalışmamızda akciğer sesleri, hastalıklı ve sağlıklı olarak iki sınıfta incelenmiştir.

1.7. Öznitelikler

Asıl ses verisinden daha küçük ancak sesin önemli karakteristik özelliklerini gösteren vektörü oluşturma işlemidir. Sınıflandırma işleminin en verimli şekilde yapılabilmesi için yöntemlerin özenle belirlenmesi gerekir. Öznitelik seçimi, sınıflandırma sonucunu direkt etkileyeceğinden, seçilirken veri setine uygun olmasına dikkat edilmelidir. Seçilen öznitelğin, çalışmalara devam edilebilmesi için uygun olduğunu saptayabilmek, denemeler yaparak mümkün olabilmektedir.

1.8. Sınıflandırma

Önceden etiketi belirlenmiş olan ses işaretlerinden oluşan bir öznitelik kümesiyle yine etiketi bilinen başka bir ses işaretinin sınıflandırıcının verdiği etiketleri kıyaslanarak, sınıflandırma işleminin performansı gözlenir. Ötüşmenin yüksek olması, yani sınıflandırıcının, sinyalin orijinal etiketini sağlayabilmesi, yüksek doğrulukta sınıflandırma yapıldığı anlamına gelir.

1.9. Literatür

Akciğer seslerini sınıflandırmaya yönelik literatürde çeşitli çalışmalar yapılmıştır. Bunlar, üzerinde çalışılan akciğer seslerinin kayıt yöntemine bağlı olarak tek kanallı ve çok kanallı kayıt yöntemleri olarak ikiye ayrılmıştır. Çok kanallı kayıt yönteminde, akciğer seslerini birden fazla kanal yardımıyla eş zamanlı olarak kaydederek yürütülen çalışmalardır. Tek kanallı kayıtlar ise bizim de çalışmamızda izlediğimiz yol olan oskültasyon prosedürüne uygun olacak şekilde tek bir kanal yani kayıt elemanı ile kayıt yapılan çalışmalardır.

Tek kanallı akciğer ses kayıtları kullanılarak yapılmış sınıflandırmaların büyük bir kısmı zaten herhangi bir araç olmadan çıplak kulakla duyulabilen “wheeze(hırıltı)” sesi ayırıştırma üzerinedir. Bu çalışmalara örnek olarak Bokov ve arkadaşları [5] wheeze’i ayırştırmak için DVM kullanarak sınıflandırma yapmıştır. Yaklaşık 20 aylık olan bebeklerin ağızlarından çıkan solunum seslerini kaydederek yöntemlerini uyguladılar. Toplamda 186 örnek almışlardır. Aldıkları kayıtları bölümlere ayırarak en iyi sınıflandırma sonucunu DVM ile elde etmişlerdir. (Duyarlılık %71,40 Özgüllük %88,90)

Chamberlain ve arkadaşları [6] kişilerin göğüs ve sırt bölgelerinde farklı noktalardan elektronik stetoskop yardımıyla kaydettikleri 171’i normal, 33’ü wheeze, 19’u ral ve 4’ü wheeze ve ral olan akciğer seslerini semi-supervised deep learning kullanarak yöntemlerini uyguladılar. (Wheeze: %64 özgüllük, %90 duyarlılık)(Ral: %44 özgüllük, %90 duyarlılık)

Matsutake ve arkadaşları [7] normal solunum ve normal olmayan solunumu ayırt etmeye yarayan saklı markov modelleri kullandıkları yöntemlerini uyguladılar. Normal ve normal olmayan solunumun olasılıklarını hesapladıkları bu yöntemde 66

anormal ve 64 sağlıklı akciğer sesini, elektronik stetoskop kullanarak elde ettiler. Wheeze sesini sınıflandırma sonuçları, duyarlılık: %94,6 özgüllük: %100.

Mazić ve arkadaşları [8] wheeze seslerini ayırt eden yöntemlerinde MFKK, entropi ve kurtosis kullanarak öznelik çıkarmışlardır. Akselerometre yardımıyla elde ettikleri akciğer seslerinin sınıflandırılmasında iki adet paralel DVM kullanılmıştır. DVM sınıflandırma sonuçlarının çarpımıyla elde edilen sonuçlara göre aktarılan performans güvenilirliği %97,68'dir.

Mendes ve arkadaşları [9] elektronik stetoskop yardımıyla elde ettikleri 24 adet akciğer kaydından wheeze sesini algılamak için Random Forest Algorithm kullandılar. Cross validation yardımıyla elde ettikleri sonuçlar duyarlılık: %90,9(yaklaşık) özgüllük: %99,4(yaklaşık)

Yu ve arkadaşları [10] kullandıkları elektronik stetoskop yardımıyla kişilerin boynundan elde ettikleri 25 wheeze ve 34 sağlıklı akciğer sesini belirledikleri bir sınır ve korelasyon katsayısını da öznelik olarak kullanarak %88 duyarlılık ve %88 duyarlılık elde etmişlerdir.

Jin ve arkadaşları [11] sağlıklı olarak 100 ve wheeze olarak da 86 akciğer sesini dar bant olarak filtrelenmiş akciğer seslerini örnek entropi histogramı yardımıyla wheeze seslerini ayırtıran bir çalışma yaptılar. Nefes alırken doğruluk %85,3 verirken %97,90

Aykanat ve arkadaşları [12] elektronik stetoskop yardımıyla DVM'de MFKK ve konvolüsyonel sinir ağında spektrogram görüntüleri şeklinde iki algoritma oluşturdu. 4 veri kümesi ile akciğer seslerini sınıflandırmaya çalışmışlardır. Bütün ses türleri ile sınıflandırmada konvolüsyonel sinir ağı %62 ve DVM %62 başarılı, tekli solunum sesi tipi sınıflandırmada konvolüsyonel sinir ağı %80 ve DVM %80 başarılı, ral, ronküs ve normal ses sınıflandırmasında konvolüsyonel sinir ağı %76 DVM %75 başarılı, sağlıklı ve patolojik ses sınıflandırmasında konvolüsyonel sinir ağı %86 ve DVM %86 başarılı olmuştur.

Pinho ve arkadaşları [13] elektronik stetoskolla elde ettikleri akciğer seslerinden ralleri ayırt edebilmek için iki veri seti kullanmışlardır. Kistik fibroz ve pnomoni hastalarından aldıkları 24 akciğer ses kaydı sınıflandırmasında fraktal eşiklemeyle literatürle daha önceden yapılmış başka sınıflandırma tekniklerini kullanmış ve yaklaşık %89 duyarlılık ve yaklaşık %95 pozitif öngörü elde ettiklerini belirtmişlerdir.

Zhang ve arkadaşları [14] elektronik stetoskop ile kaydettikleri akciğer seslerini ral sınıflandırması için bir ralin matematiksel ifadesini kullanarak bir algoritma elde etmişlerdir. 50 ral ve 50 sağlıklı akciğer sesinden oluşan veri setiyle ulaştıkları sonuç %86 duyarlılık ve %92 özgüllük elde etmişlerdir.

İçer ve arkadaşları [15] elektronik stetoskopla aldıkları 60 akciğer ses kaydından ral ve ronküs sınıflandırması için frekans oranı, anlık frekans ortalaması, değişim zamanı ve özdeğerler kullanılmıştır. DVM ve 5 katlı çapraz doğruluk kullanılarak yapılan çalışmada %80'in üzerinde doğruluk elde ettiklerini ifade ettiler.

Jin ve arkadaşları [16] ses kayıtlarını trake üzerine yerleştirilen mikrofonla 339 kayıt alınmıştır. Wheeze, stridor ve ronküs sınıflandırması için örnek entropi, kurtosis ve ayırt edici fonksiyonlar kullanılmıştır. DVM ve ileri öznitelik seçimi algoritmasıyla %98 doğruluk seviyelerindeydi.

Mondal ve arkadaşları [17] sağlıklı ve hasta olarak sınıflandırdığı wheeze, ronküs, ral, squawk ve sağlıklı akciğer seslerini trake üzerine yerleştirilen mikrofonla elde etmişlerdir. Aşırı öğrenme makinası ve beş kat çapraz doğrulama tekniğinin birlikte kullanılmasıyla %86,30 duyarlılık ve %86,90 özgüllük elde ettiklerini ifade etmişlerdir.

Emmanouilidou ve arkadaşları [18] elektronik stetoskop ile kaydettikleri 28 akciğer sesini sınıflandırmak için kortikal bir modellemeyle DVM kullanılmıştır. 10 wheeze, 8 ral ve 10 normal sesin sınıflandırmasıyla duyarlılık %89,44 ve özgüllük %80,50 elde ettiklerini belirtmişler.

Himeshima ve arkadaşları [19] elektronik stetoskop ile 63 anfizemi hastası olan ve 63 sağlıklı bireyden akciğer sesi kaydettiler. Birini dışarıda bırak çapraz doğrulama kullanarak sağlıklı ve hastalıklı olarak sınıflandırma sonuçları %88,7 duyarlılık, %91,5 özgüllük şeklindedir.

Kahya ve arkadaşları [20] akciğer seslerinin anlık enerji ortalamasını eşik olarak ralleri sınıflandırdı. Zaman ve frekans özellikleri kullanarak ralleri ince ral ve kaba ral olarak ayırt etti. Sınıflandırma sonuçları %100 doğruluk şeklindedir.

Becker ve arkadaşları [21] tüberküloz hastalığına sahip bireylerin boyun, sırt ve göğüsü üzerinden aldıkları ral ve wheeze seslerini analiz etmek için çalışma yapmışlardır. Modellerinde eğitim kümesi için topladıkları ses sinyallerinden elde ettikleri verilerin dörtte üçünü kullanmışlardır. Elde ettikleri sonuç tüberküloz hastalığının analizi için % 80 özgüllük ve %80 duyarlılık şeklindedir.

Serbes ve arkadaşları [22] hastaların göğüsleine yerleştirdikleri on dört mikrofonla kaydettikleri ral ve sağlıklı akciğer seslerini sınıflandırma üzerine çalışma yapmışlardır. 26 farklı ses kaydını sınıflandırmak için çok katlı algılayıcı, DVM ve k-NN en yakın komşuluk yöntemlerini kullanmışlardır. En yüksek performansa sahip olan DVM'nin doğruluk değeri %97,50, hassaslığı ise %97,30'dur.

Martinez ve arkadaşları [23] geri yayımlı sinir ağı kullanarak 10 sağlıklı ve 19 hasta bireyden aldıkları sesleri, içinde ral olan ve olmayan akciğer sesi şeklinde sınıflandırmışlardır. Sonuç olarak %80,70 duyarlılık ve %84,21 özgüllük elde etmişlerdir.

Aras ve arkadaşları [24] 60 normal, 60 ral ve 60 ronküs akciğer sesini zaman bölgesi öznitelikleri, frekans bölgesi öznitelikleri ve MFKK katsayılarını öznitelik olarak kullanarak NB, LDA ve DVM sınıflandırma yöntemleriyle sınıflandırmışlardır. Bu sınıflandırma sonucunda doğruluk performansı %92,22 ile MFKK katsayılarının ortalaması en iyi sonuç olmuştur.

Aras ve arkadaşları [25] kaydettikleri toplamda 300 adet akciğer sesinden, 100 normal, 100 ral ve 100 ronküs sesini, zaman bölgesi öznitelikleri, frekans bölgesi öznitelikleri ve MFKK katsayılarını öznitelik olarak kullanmışlardır. Sınıflandırma işlemi için de DVM, NB ve k-NN sınıflandırıcılarını tercih etmişlerdir. Sınıflandırma sonuçlarına göre doğruluk performansı en yüksek olanı yaklaşık %96,15 ile MFKK katsayılarının kullanıldığı ve k-NN sınıflandırıcının sınıflandırdığı yöntemdir.

1.10. Tezin Kapsamı

Çalışmamızda tek kanallı olarak elde edilen akciğer seslerinin öznitelik çıkarma tekniklerinin sınıflandırma üzerindeki etkisi incelenmiştir. Kullanılan akciğer sesleri, Karadeniz Teknik Üniversitesi Göğüs Hastalıkları bölümüne hasta olarak giden yetişkin bireylerden alınmıştır. Aras'ın akciğer seslerinin döngülerini otomatik olarak belirleyen yöntemi [4] kullanılarak veri setleri oluşturulmuştur. Başlangıç ve bitiş noktaları belirlenen akciğer ses verilerine MFKK uygulanmış ve elde edilen bu katsayılardan çeşitli (ortalama, standart sapma, kurtosis, skewness, entropi) öznitelik çıkarma teknikleriyle veri setleri elde edilmiştir. k-EYK (k-En

Yakın Komşuluk) ve DVM (Destek Vektör Makineleri) sınıflandırma teknikleriyle test kümesi elemanlarının hangi sınıfa ait oldukları tespit edilmeye çalışılmıştır.



2. ÇALIŞMALAR

2.1. Materyal


Tek kanallı olarak kaydedilen sesler için Thinklabs – ds32a+ stetoskop kullanılmıştır. Stetoskobun ses çıkışı bağlantısı ile bir dijital ses kaydediciye bağlanıp kaydedilmiş oradan bilgisayar ortamına aktarılmıştır. Dijital ses kaydedicinin akciğer sesleri frekans bandında (80-20000 Hz [26]) kayıt yapabilme özelliğine sahiptir. Bu sayede doktorun stetoskop yardımıyla duyduğu sesin üzerinde sınıflandırma çalışmaları yapılabilmesi için sayısal ortama aktarımı sağlanmıştır.

2.2. Yöntem

Oskültasyon olarak adlandırılan akciğer dinleme yöntemi, genel olarak analog stetoskop yardımıyla dinlenmektedir [27]. Ancak tez çalışmamız için akciğer seslerinin kaydedilip işlenebilmesi adına elektronik stetoskop kullanılmıştır.

Akciğer seslerinin alınabilmesi için Tübitak 116E003 kodlu projede Karadeniz Teknik Üniversitesi Göğüs Hastalıkları Anabilim Dalı öğretim üyelerinden hizmet alımı şeklinde yapılmıştır. Kayıtlar Trabzon Klinik Araştırmalar Etik Kurul Başkanlığı'nın 30.04.2015 tarih ve 24237859-293 sayılı izniyle alınmış olup ses örnekleri yetişkin bireyler arasından seçilmiştir. Seslerin hangi sınıfta olduklarına dair etiketleri, bu seslerin kaydını alan uzman doktorlar tarafından yapılmıştır.


Şekil 4'te ince ral hastalığına sahip olan bir bireyin akciğer ses kaydı verilmiştir.



Şekil 4. İnce Ral ses kayıt örneği

2.2.1. Önişleme

Akciğer seslerinden her biri için birbiriyle %99 oranında örtüşen çerçeveler oluşturulur. $x[n]$ ve $w[n]$ N uzunluklu bir çerçeve ve Hamming pencere fonksiyonudur. $x_p[n] = x[n].w[n]$ denklemiyle Hamming pencere fonksiyonu uygulanmış sinyal olarak elde edilmiş olur. (Şekil 5)



Şekil 5. Sinyalden alınan bir çerçeveye Hamming pencere uygulaması

Hamming pencereleme uygulanmış ayrık sinyalin Fourier dönüşümü Denklem 1'de gösterilmiştir.

$$X[k] = \sum_{n=0}^{N-1} x_p[n] \cdot e^{-j2\pi kn/N} \quad (1)$$

$k=0,1,2,3,\dots,N-1$ 'dir. Hamming pencere Denklem 2'de verilmiştir.

$$w[n] = \begin{cases} 0,54 - 0,46 \cos\left(\frac{2\pi n}{N_w}\right), & 0 \leq n \leq N_w - 1 \\ 0, & N_w - 1 < n < 0 \end{cases} \quad (2)$$

Spektrogramın elde edilmesi için kullandığımız Fourier Dönüşümü fonksiyonu Denklem-1’de verilmiştir. Bu aşamadan sonra minimum ve maksimum frekans değerleri (80 – 1000 Hz) arasındaki Ayırık Fourier Katsayıları ile enerji hesaplanmıştır (Denklem 3).

$$E_k = |X_k|^2 \quad (3)$$

Akciğer seslerinin kaydedilmesi sırasında gürültü etkeni ile karşı karşıya kalınmaktadır. Bu gürültü etkisini en aza indirmek için önce medyan filtre, sonrasında da kayan ortalama filtre kullanılmıştır. Kullanılan filtreler, “smooth” fonksiyonu olarak Denklem 4’te gösterilmiştir.

$$X_s[n] = \text{smooth}(p[n]) \quad (4)$$


Enerji sinyalinin düzeltilmiş hali, solunum döngülerinin sınırlarını belirten minimum noktaları içermektedir. Denklem 5’te gösterilen “*minInd*” fonksiyonu minimum noktalarının indeksini bulunduran vektörü ifade eder. İkinci türevin pozitif olma şartıyla minimum noktaların tespiti yapılabilmektedir.

$$\text{minInd}[j] = \frac{dX_s[n]}{dn} = 0, \quad \left(\frac{d^2X_s[n]}{dn^2} > 0 \text{ olmalıdır.} \right) \quad (5)$$

2.2.2. Solunum Döngülerinin Tespit Edilmesi

Önişleme sonrasında daha düzgün şekle sahip olan $X_s[n]$ sinyalinin minimum noktalarından ve solunum döngülerinin benzerliğinden faydalanılmaktadır [4]. Solunum döngülerinin sınır noktaları, sinyalin birinci türevinin sıfır, ikinci türevinin de pozitif olduğu noktalara denk gelmektedir. Solunum döngülerinde bulunan pikler, döngülerin sınırlarına karşılık gelmektedir. Gürültü seviyesi açısından iyileştirilen sinyalin başlangıcından itibaren sırasıyla iki döngü saptayacak kadar bir uzunluk tespit edecek bir örüntü modellenmektedir. Bu sayede modellenen örüntü diğer

minimum noktalar arasında bulunan test örüntüleriyle kıyaslanabilir. Birbirine olan benzerliği en fazla olan örüntülerden sınırlar belirlemiş olur. Bu benzerlik, Dinamik Zaman Bükme (DZB) algoritmasıyla saptanmaktadır.



Şekil 6. Model ve test paternlerinin belirlenmesi

İlk olarak döngüleri ifade eden kalıpların model (M_i) ve test ($T_{i,p}$) için oluşturulmasıdır. Şekil 6' da sürecin işleyişi ve temel indisler gösterilmiştir. i . modelin sınırları bM_L^i ve bM_U^i olarak ifade edilmiştir. Buna göre iki minimum nokta arasında bulunan bir solunum döngüsünün temsil eden paternin bulunacağı aralık $1 \leq bM_L^i \leq bM_U^i \leq 2L_{max}$ olmalıdır. Yapılan çalışmalardan elde edilen tecrübeye dayanılarak $L_{max} = 5.5$ saniye olarak belirlenmiştir. Seçilen model paterninin uzunluğu da $L_{min} \leq bM_U^i - bM_L^i \leq L_{max}$ olmalıdır. Bu sınırlamalar doğrultusunda sürecin karmaşıklığı en aza indirgenmektedir. Bu konuyla ilgili yapılan çalışmalarda L_{min} değeri, en kısa solunum döngüsünden daha kısa olması gerekmektedir. Çalışmamızda yine tecrübelerle dayanılarak $L_{min} = 1.25$ saniye olarak belirlenmiştir. Denklem 6'te modelin alt sınır indeksi hesaplanmıştır.

$$f(bM_L^i) = \begin{cases} \minInd[1] = 1, & i = 1 \\ bM_U^{i-1}, & i > 1 \end{cases} \quad (6)$$

Modelin paterni $bM_L^i \leq n \leq bM_U^i$ aralığında seçilir. Seçilen $X_s[n]$ sinyali örneklerinin sayısı, DZB algoritmasının işlem karmaşıklığını azaltmak adına örnek sayısı N_s kadar olmalıdır. Örnekleme frekansı, $f_s = 2f_{max}$ alınarak N_s belirlenmelidir.

Alınan ses kayıtlarında, aynı kişiden elde edilen ancak hastanın farklı kuvvetlerde nefes alış-verişiyle farklı genliklerde oluşan kayıtların DZB algoritmasının sonuç performansını olumsuz etkilememesi adına model paternine normalizasyon (Denklem 7) uygulanır.

$$M_i[n] = \frac{X_s \left(\text{round} \left(bM_L^i + n \left(\frac{bM_U^i - bM_L^i}{N_s - 1} \right) \right) \right)}{X_{sm}^i} \quad (7)$$

Alt ve üst sınırların arasındaki maksimum genlik değeri X_{sm}^i ile gösterilmiştir. Test paternleri aynı alt sınıra sahip olan alt test modellerinden seçilir. Model olarak belirlenen paternden sonra sırasıyla seçilen test modellerinden ilkinin alt sınırı ($bt_L^{p,r}$) modelin üst sınırına eşit olacaktır. Test modelinin alt sınırı sabit tutularak $L_{min} \leq bt_U^{p,r} - bt_L^{p,r} \leq L_{max}$ kuralına uygun olan alt test kalıplarının sayısı r -sayısı belirlenir. Alt test paternlerinin hepsine genlik normalizasyonu uygulanır ve N_s adet örnek seçilir. Ardından seçilen örnekler DZB algoritmasında normalize edilmiş model ile karşılaştırılır. Karşılaştırma sonucunda DZB değeri en küçük olan test paterni, modelden sonra gelen ilk test paterni olarak belirlenmiş olur. Ardından bu test paterninin ardından yeni bir test paterni belirlemek için sen test paterninin alt sınır indeksi, yeni belirlenecek olan test paterninin üst sınır indeksi olacak şekilde kabul edilir. Bu işlem $X_s[n]$ sinyalinin sonuna kadar sürdürülür. i .inci modelin p .inci test modelini ($T_{i,p}[n]$) saptamak için seçilen alt test modellerinin ($t_{p,r}[n]$) alt limit indeksleri Denklem 8'deki gibi hesaplanır.

$$f(bt_L^{p,r}) = \begin{cases} bM_U^i, & p = 1 \\ bt_L^{i,p-1}, & p > 1 \end{cases} \quad (8)$$

Alt test paternlerinin sayısının “ r ” ile gösterilmiştir.

$$t_{p,r}[n] = \frac{X_s \left(\text{round} \left(bt_L^i + n \left(\frac{bt_U^i - bt_L^i}{N_s - 1} \right) \right) \right)}{X_{st}^i} \quad (9)$$

Denklem 9’da X_s ’in test paterninin alt ve üst sınırları arasındaki maksimum genlik değeri X_{st}^i ’dir. Belirlenen r -adet alt test paterni DZB algoritmasıyla normalize edilmiş model paterni ile karşılaştırılır. Karşılaştırma sonucu en az olan sonuca sahip olan alt test paterninin sınırları belirlenmiş olur.

DZB algoritmasıyla model ve test paternleri, sınırları solunum döngülerinin sınırları olacak şekilde bu döngüleri temsil eden paternler olarak belirlenir. Sonuç olarak kaydedilen akciğer sesi içinden solunum döngüleri ayrıştırılmış olur.

2.2.3. Veri Setlerinin Oluşturulması

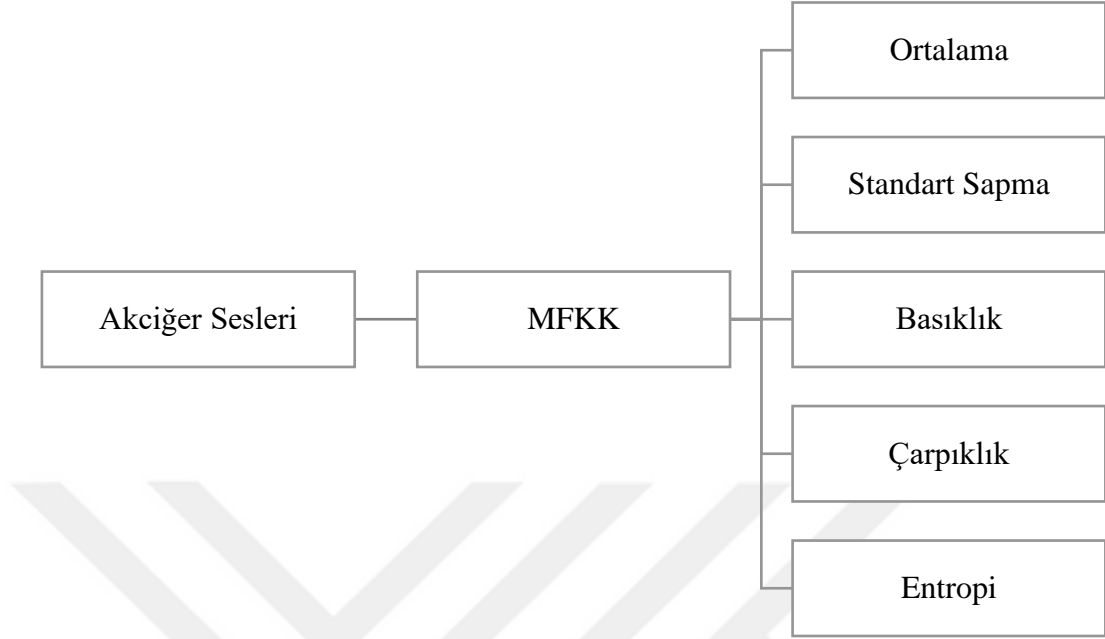
Solunum döngüleri belirlenen ses işaretlerinin etiketleri üzere iki grupta incelenmiştir. İnce ral, kaba ral ve ronküs bir sınıf, sağlıklı akciğer sesi diğer sınıf olacak şekilde düzenleme yapılmıştır. Toplamda Tablo-1’de gösterildiği gibi 37 ince ral, 60 ronküs ve 60 sağlıklı ses, 97 hastalıklı ve 60 sağlıklı olmak üzere iki sınıfta incelenmiştir.

Toplamda 157 adet ses kaydının tamamının Mel Frekansı Kepstrum Katsayıları hesaplanmış ve matris halinde kaydedilmiştir. Kaydedilen matris öğelerinin her biri için ayrı ayrı ortalama, standart sapma, basıklık, çarpıklık ve düzensizlik özellikleri çıkarılmış ve öznitelik vektörleri elde edilmiştir.

Eğitim ve test kümelerini belirlemek için bu 157 akciğer sesinden 79’u eğitim, 78’i test kümesi elemanı olacak şekilde alınmıştır. Kümelerin elemanları seçilirken her sınıftan eşit ya da yakın sayıda kayıt alınmıştır. İkinci sınıf içinde iki adet hastalık olması sebebiyle eğitim ve test kümelerinde her hastalıktan eşit sayıda alınmış olup kümeler oluşturulmuştur. Şekil 7’te yöntem görsel olarak sunulmuştur. Sırasıyla sınıf bilgisiyle etiketlenen bu matrisler karışık olarak tekrar dizilmiştir. Bu karıştırma işlemiyle, eğitim kümesi elemanlarının hep aynı ses kayıtları olmasının önüne geçilmiştir.

Tablo 1. Akciğer Seslerinden Oluşan Veri Sınıfları

Veri Seti		
1. sınıf	2. sınıf	
İnce Ral sesleri	Ronküs sesleri	Sağlıklı akciğer sesleri
37 adet akciğer sesi	60 adet akciğer sesi	60 adet akciğer sesi

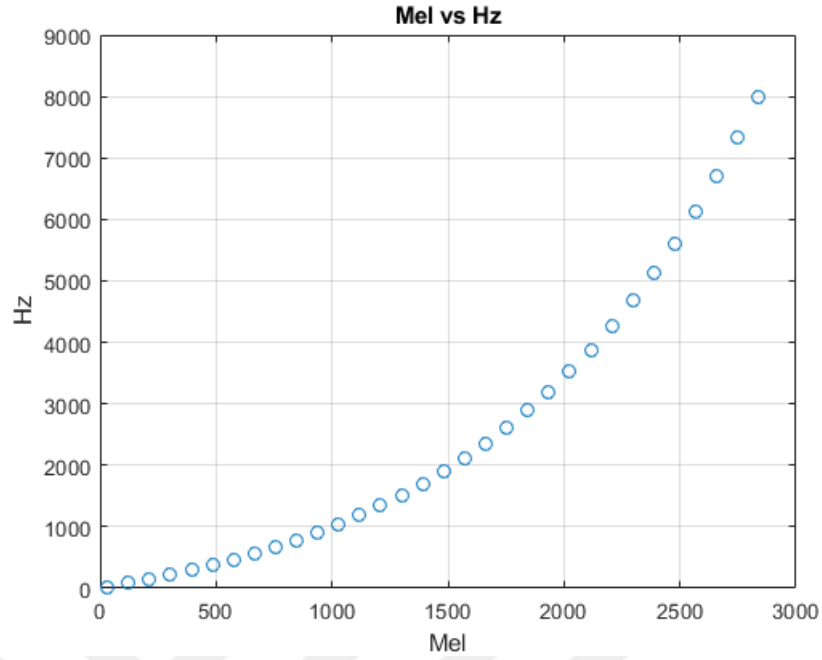


Şekil 7. Öznitelik Çıkarma Diagramı

2.2.4. Mel Frekanslı Kepstrum Katsayıları

MFKK'nin uygulama alanı, ses tanıma çalışmalarıdır. “Mel”, “melodi”nin kısaltılmasıdır. Kepstrum, kelime anlamı olarak “spektrum”un tersi anlamına gelir. Bir sinyalin fourier dönüşümünün logaritmasının ters fourier dönüşümüyle elde edilir. Bundan ilk defa Stevens ve arkadaşları [28] söz etmiştir. “Mel ölçeği” denilen, insan kulağının duyma seviyelerinin Şekil 8’teki gibi belirli bir frekans değerine kadar doğrusal olup her değerden sonra logaritmik değişiyor olması nedeniyle buna uygun modelleme yapılabilmesi için oluşturulmuş bir skaladır. İnsan kulağı tepkisini Mel ölçeğine çevirebilmek için kullanılan, akustik frekansı algılanan frekansa dönüştüren O’shaughnessy’nin matematiksel ifadesi [29] Denklem 10 aşağıda verilmiştir.

$$f_{mel} = 2595 \log_{10} \left(\frac{f}{700} + 1 \right) \quad (10)$$




Şekil 8. Mel Ölçeğinin Frekans Düzlemindeki Karşılığı

İnsan kulağına gelen sesler, seslerin kulak zarında oluşturduğu titreşimleri sinyale dönüştürerek beyne iletimini sağlayan salyangoz adı verilen organa gelir. Bu sistemin sayısal ortamda bir modellemesini yapmak için akciğer seslerinde hangi frekansların mevcut olduğunu belirlemek gerekmektedir. Bunun için genlik spektrumu (Denklem 11) kullanılır.

$$G_i(k) = |X_i(k)| \quad (11)$$

Elde ettiğimiz genlik spektrumu, Şekil 9'da gösterilen Mel filtre bankası çarpanıyla ölçeklendirilir.



Şekil 9. Mel Üçgen Filtre Bankası

Mel filtre bankasıyla ölçeklendirme işlemi her çerçeve için Denklem 12’de ifade edildiği gibidir.

$$X'_i(m) = \ln\left(\sum_{k=0}^{N-1} G_i(k) H(k, m)\right) \quad (12)$$

Mel filtre bankasındaki üçgen filtreler Denklem 13’deki gibi ifade edilmektedir.

$$f(x) = \begin{cases} 0, & f(k) < f_c(m-1) \\ \frac{f(k)-f_c(m-1)}{f_c(m)-f_c(m-1)}, & f_c(m-1) \leq f(k) < f_c(m) \\ \frac{f(k)-f_c(m+1)}{f_c(m)-f_c(m+1)}, & f_c(m) \leq f(k) < f_c(m+1) \\ 0, & f(k) \geq f_c(m+1) \end{cases} \quad (13)$$

Mel ölçeğinin üçgen filtre merkezleri aşağıdaki Denklem 14’deki gibi hesaplanır.

$$\Delta\phi = (\phi_{max} - \phi_{min})/(M + 1) \quad (14)$$

ϕ_{max} , frekans boyutundaki f_{max} ’ın mel frekansı ölçeğindeki karşılığıdır. Aynı şekilde ϕ_{min} ’de f_{min} ’in mel ölçeğindeki karşılığına denk gelir. Mel ölçeği merkez frekansları Denklem 15’deki gibi hesaplanır.

$$\phi_c(m) = m \cdot \Delta\phi \quad (15)$$

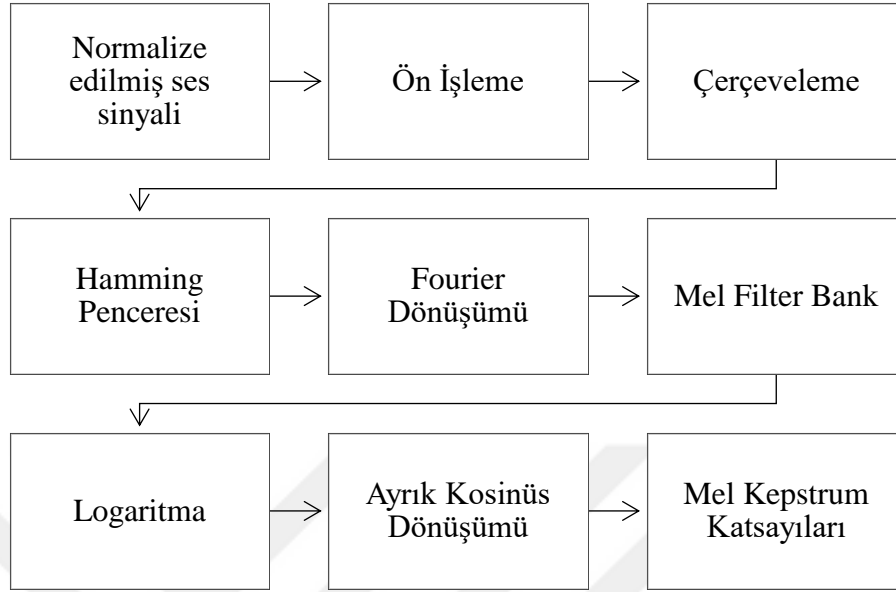
Mel ölçeğinden tekrar frekans ölçeğine dönmek için Denklem 16 kullanılır.

$$f_{Hz} = 700(10^{f_{mel}/2595-1}) \quad (16)$$

MFKK, $X'_i(m)$ ’nin ayrık kosinüs dönüşümüyle elde edilir (Denklem 17).

$$c(l) = \sum_{m=1}^M X'_i(m) \cos\left(l \frac{\pi}{M} \left(M - \frac{1}{2}\right)\right) \quad (17)$$

MFKK katsayılarının elde edilme şeması Şekil 10’da gösterilmiştir.




Şekil 10. MFKK Katsayılarını Elde Etme Yöntemi

2.2.5. Sınıflandırma

Eğitim kümesi oluşturulurken farklı sayıda eleman seçimiyle elemanların miktarının sonuca etkisi gözlenmiştir. İki ayrı sınıflandırıcı kullanılmıştır. Sınıflandırma sonuçlarının ortalamaları hesaplanmış ve performansları incelenmiştir.

2.2.5.1. k – En Yakın Komşuluk

Test kümesi verilerinden birinin, kendisine en yakın “k” tane komşusu eğitim kümesi üzerinden seçilir. Seçilen komşuların etiketlerine bakılır ve hangi kümeden daha çok komşu seçilmişse test verisinin o kümeye ait olduğunu kabul eden bir sınıflandırma yöntemidir [30]. Şekil 11’de k değeri ‘3’ olarak seçilmiştir ve “o” ile gösterilen test elemanına en yakın üç komşu belirlenmiştir. Bu durumda en yakın üç komşunun ikisi 1. sınıf elemanı olduğundan sınıflandırma sonucu, test elemanı 1. sınıfa ait olacak şekildedir.

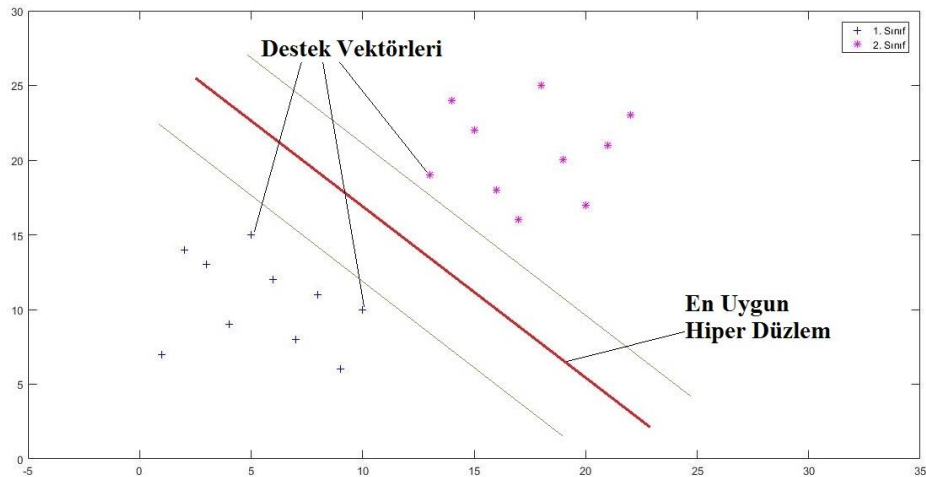


Şekil 11. k- En Yakın Komşuluk Sınıflandırıcı Örneği

2.2.5.2. Destek Vektör Makineleri

Denetimli bir sınıflandırma tekniği olan DVM, istatistiksel öğrenme teorisini temel almaktadır. Vapnik' in [31] geliştirdiği bu yöntem, eğitim kümesi elemanlarıyla bir model oluşturmaktadır. Bu model, sınıfları ayıran bir karar çizgisi belirlenerek oluşturulmaktadır.

Şekil 12'da görüldüğü gibi sınıfları birbirinden ayıran en geniş hiper-düzlem belirlenir ve burada iki sınıfa da en uzak noktadan sınır geçer.



Şekil 12. Destek Vektör Makineleri Örneği

DVM sınıflandırıcısıyla iki sınıflı doğrusal ayrılabilen veriler için, eğitim kümesinden elde edilen karar fonksiyonuyla ikinci dereceden denklem çözümü yapılır. Eğitim kümesi eleman sayısı “k” için DVM eşitsizlikleri sırasıyla gösterilmektedir.

$$wx_i + b \geq +1 \quad y_i = +1 \quad (18)$$

$$wx_i + b \leq -1 \quad y_i = -1 \quad (19)$$

Denklem 18 ve Denklem 19’de gösterilen “y” parametresi, DVM sınıflandırıcısının çıktısı olan etiket vektörüdür. “x” parametresi destek vektörlerini, “w” ağırlık vektörünü, “b” de eğilimi gösterir. Sınıfları birbirinden en iyi şekilde ayıracak olan iki hiper-düzlem denklemi Denklem 20’deki gibidir.

$$wx_i + b = \pm 1 \quad (20)$$

$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (21)$$

İki hiper-düzlemin birbirine uzaklığı “ $\frac{2}{\|w\|}$ ” ise en iyi hiper-düzlem Denklem 21’deki gibi olacaktır.

Eşitlikler düzenlenerek Denklem 22 elde edilir.

$$y_i(wx_i + b) \geq 1 \quad (22)$$

Lagrange denkleminde yararlanılarak Denklem 23 çözülür.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha_i y_i (wx_i + b) + \sum_{i=1}^k \alpha_i \quad (23)$$

$$f(x_i) = \text{sign}(wx_i + b) = \begin{cases} +1, & y_i = +1 \\ -1, & y_i = -1 \end{cases} \quad (24)$$

Denklem 23'te α_i , Lagrange çarpanlarını ifade etmektedir. Denklem 24'de de en iyi hiper-düzlemin matematiksel ifadesi verilmiştir.

Doğrusal olmayan hiper-düzlem elde edebilmek için doğrusal olmayan çekirdek fonksiyonları kullanılır. En iyi hiper-düzlem belirlenmiş olsa dahi, eğitim kümesi elemanlarından bazıları yanlış tarafta kalabilmektedir. Bu problem, Denklem 25'da gösterildiği gibi çözümlenir.

$$\min \left[\frac{1}{2} \|w\|^2 \right] + C \sum_{i=1}^r \xi_i \quad (25)$$

Yapay değişken $\xi \geq 0$ ve $i = 1, 2, \dots, N$ olmak üzere sınırlamalar Denklem 26'deki gibi ifade edilir.

$$y_i(wy_i + b) \geq 1 - \xi_i \quad (26)$$

Denklem 27'deki ifade, doğrusal olmayan ayırma işlemleri için kullanılan Kernel fonksiyonunu göstermektedir.

$$\varphi(x_i)\varphi(x_j) = K(x_i, x_j) \quad (27)$$

Yukarıdaki ifadede yer alan "K", Kernel fonksiyonlarını ifade eder. Birçok çalışmada verdiği iyi sonuçlar doğrultusunda bu çalışmada da RBF (Radyal Bazlı Fonksiyon) kullanılmıştır[84]. (Denklem 28)

$$K_{(RBF)} = e^{-\left(\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)} \quad (28)$$

K, Çekirdek fonksiyonu ve $z = \varphi(x)$ dönüşümü yapılarak elde edilen karar fonksiyonu Denklem 29'teki gibi olmaktadır.

$$f(x_i) = \text{sign}(wz + b) = \text{sign} \left[\frac{1}{2} \sum_{i=1}^{N_s} y_i \alpha_i K(x_i, x) + b \right] \quad (29)$$

3. BULGULAR

3.1. MFKK'nın Ortalamasıyla Elde Edilen Öznitelik Vektörünün Sınıflandırma Bulguları

Veri kümesinden elde edilen hastalıklı ve sağlıklı akciğer seslerini sınıflandırmak için kullanılan MFKK katsayılarının ortalaması alınarak oluşturulan öznitelik vektörünün k-EYK ve DVM sınıflandırıcılarıyla yapılan sınıflandırma sonucu Tablo 2'deki gibidir.

Tablo 2. MFKK'nın Ortalamasının Sınıflandırma Sonuçları

Tekrar Sayısı	k-EYK			DVM
	k _{m1}	k _{m3}	k _{m5}	
1	100	100	98,72	100
2	100	100	100	100
3	100	100	100	100
4	100	100	100	100
5	100	100	100	100
6	100	98,72	97,44	100
7	100	100	98,72	100
8	100	98,72	97,44	100
9	100	98,72	98,72	100
10	100	98,72	98,72	100

3.2. MFKK Katsayılarının Standart Sapmasıyla Elde Edilen Öznitelik Vektörünün Sınıflandırma Bulguları

Veri kümesindeki elemanların MFKK katsayılarının standart sapmasıyla elde edilen öznitelik vektörünün sınıflandırma sonuçları Tablo 3'teki gibidir.

Tablo 3. MFKK'nın Standart Sapmasının Sınıflandırma Sonuçları

Tekrar Sayısı	k-EYK			DVM
	knn1	knn3	knn5	
1	100	98,72	94,87	97,44
2	98,72	93,59	92,31	94,87
3	98,72	97,44	94,87	97,44
4	98,72	97,44	100	96,15
5	97,44	93,59	91,03	91,03
6	97,44	98,72	97,44	91,03
7	98,72	100	94,87	93,59
8	98,72	98,72	98,72	94,87
9	100	98,72	96,15	94,87
10	97,44	96,15	93,59	93,59

3.3. MFKK Katsayılarının Basıklığıyla Elde Edilen Öznitelik Vektörünün Sınıflandırma Bulguları

Veri kümesindeki elemanların MFKK katsayılarının basıklığı hesaplanarak elde edilen öznitelik vektörünün sınıflandırma sonucu Tablo 4'teki gibidir.

Tablo 4. MFKK'nın Basıklığının Sınıflandırma Sonuçları

Tekrar Sayısı	k-EYK			DVM
	knn1	knn3	knn5	
1	92,31	96,15	93,59	88,46
2	88,46	88,46	85,90	88,46
3	85,90	87,18	87,18	88,46
4	88,46	87,18	85,90	85,90
5	91,03	89,74	89,74	84,62
6	88,46	92,31	91,03	91,03
7	89,74	89,74	84,62	79,49
8	88,46	91,03	88,46	83,33
9	89,74	87,18	85,90	87,18
10	82,05	85,90	84,62	84,62

3.4. MFKK Katsayılarının Çarpıklığıyla Elde Edilen Öznitelik Vektörünün Sınıflandırma Bulguları

Veri kümesindeki elemanların MFKK katsayılarının çarpıklığıyla elde edilen öznitelik vektörünün sınıflandırma sonuçları Tablo 5'teki gibidir.

Tablo 5. MFKK'nın Çarpıklığının Sınıflandırma Sonuçları

Tekrar Sayısı	k-EYK			DVM
	knn1	knn3	knn5	
1	93,59	94,87	92,31	93,59
2	93,59	93,59	94,87	94,87
3	93,59	93,59	92,31	91,03
4	91,03	89,74	91,03	91,03
5	94,87	92,31	92,31	94,87
6	92,31	94,87	96,15	94,87
7	97,44	97,44	97,44	93,59
8	91,03	93,59	93,59	97,44
9	91,03	91,03	91,03	92,31
10	94,87	92,31	91,03	89,74

3.5. MFKK Katsayılarının Entropisiyle Elde Edilen Öznitelik Vektörünün Sınıflandırma Bulguları

Veri setindeki akciğer ses kayıtlarının MFKK katsayılarının entropisi hesaplanarak elde edilen öznitelik vektörünün sınıflandırma sonuçları Tablo 6'daki gibidir.

Tablo 6. MFKK'nın Entropisinin Sınıflandırma Sonuçları

Tekrar Sayısı	k-EYK			DVM
	knn1	knn3	knn5	
1	93,59	96,15	97,44	98,72
2	100	98,72	98,72	98,72
3	92,31	96,15	97,44	98,72
4	98,72	96,15	96,15	98,72
5	98,72	97,44	97,44	97,44
6	98,72	100	98,72	100
7	97,44	97,44	97,44	100
8	98,72	98,72	98,72	100
9	98,72	97,44	97,44	97,44
10	98,72	97,44	97,44	97,44

4. SONUÇLAR

Yaptığımız çalışmalara göre eğitim kümesinin elemanı miktarı kademe kademe artırılarak, kullanılan her bir öznelik yöntemi üzerindeki etkisi gözlenmiştir. Sonuç itibariyle en iyi sonucu MFKK katsayılarının ortalamasıyla elde edildi. Bu tez çalışmasıyla tek kanalla kaydedilmiş toplamda 157 akciğer sesi, literatürde fazla rastlanamayan, yüksek bir doğrulukta sınıflandırma başarımı elde edilmiştir.

Sınırları belirlenmiş akciğer ses sinyallerinin MFKK katsayıları alınıp her bir ses sinyali için ayrı ayrı ortalama, standart sapma, basıklık, çarpıklık ve entropi değerleri hesaplandı. Sınıflandırma işlemi için k-EYK ve DVM sınıflandırıcıları kullanıldı. Her bir öznelik için sınıflandırma sonuçları elde edildi ve doğrulukları hesaplandı. Bu işlemler 10'ar defa tekrarlandı. Her tekrardan elde edilen sonuçların ortalaması hesaplandı. Elde edilen sonuçlar Tablo 7'deki gibidir.

Tablo 7. Sınıflandırma sonuçlarının 10 tekrar için ortalamaları

Sınıflandırıcılar	Ortalama	Standart Sapma	Basıklık	Çarpıklık	Entropi	
k-EYK	k = 1	100	98,59	88,46	93,33	97,56
	k = 3	99,49	97,31	89,49	93,33	97,56
	k = 5	98,97	95,38	87,69	93,2	97,69
DVM	100	94,49	86,15	93,33	98,72	

5. ÖNERİLER VE TARTIŞMA

Literatürde bulunan çalışmalarla sonuçlar karşılaştırılırsa, Bokov ve arkadaşlarının yaptığı çalışmada [5] yaşları ortalama 20 aylık olan bebeklerin ağızları kenarına yerleştirdiği mikrofon sayesinde kaydettiği sesleri, içinde wheeze olan ve olmayan şekilde sınıflandırmıştır. Akciğer seslerinin alındığı yer itibarıyla oskültasyona uygun olmaması ve sınıflandırmak için kullandığı akciğer sesi, wheeze olduğundan çalışmamızla farklılıkları vardır. Ancak bu çalışmasıyla bizim çalışmamız arasındaki ortak özellik, akciğer seslerini iki sınıfa ayırmaktır. Bu bağlamda doğruluk performansı açısından bu tez çalışmasında daha iyi bir sonuç ortaya koymuştur.

Chamberlain ve arkadaşlarının yapmış olduğu çalışma [6] da bu tez çalışması gibi yeterli kabiliyete ve ya tecrübeye sahip olmayan sağlık çalışanlarına yardımcı olması ve insanların hasta olup olmadığına dair kendilerini kontrol edebilmelerine imkan sağlayacak sistemlerin öncüsü olabileceğine sahiptir. Çok sayıda akciğer ses kaydı alınan bu çalışmada (11627 adet akciğer sesi), bir cep telefonu uygulamasıyla sınıflandırma işlemini gerçekleştirmektedir. Çalışmalarında yarı-denetimli derin öğrenme yöntemiyle wheeze ve ral seslerine odaklanmışlardır. Bu iki ses için iki ayrı DVM sınıflandırıcı kullanmışlardır. Akciğer ses kayıtlarını iki sınıfta incelemeleri, bu tez çalışmasında da ortak noktası olmuştur. Ancak sınıflandırıcı sonuçlarına bakıldığında, bu tez çalışmasında çok daha yüksek performansta sınıflandırma doğruluğu elde ettiği görülmektedir.

Mazić ve arkadaşlarının yaptıkları detaylı çalışma [8], bronşial astım belirtisi olan wheeze sesini ayırt etme üzerinedir. Makine öğrenmesi ve DVM sınıflandırıcısı kullandıkları çalışmada 12 MFKK katsayısıyla yaptıkları sınıflandırmanın en yüksek doğruluğu %99,9280 iken bu sonucun güvenilirliği %97,68 olarak aktarılmıştır. Bizim çalışmamızla ortak noktaları öznelik seçimi yapılırken MFKK kullanılmış olması ve akciğer seslerini hastalıklı ve sağlıklı olarak iki sınıfta incelenmiş olmasıdır. Bu sonuçlara göre bu tez çalışmasındaki sınıflandırma işlemi daha başarılıdır.

Aykanat ve arkadaşlarının yapmış oldukları çalışmayla [12] bu tez çalışması bir çok konuda kesişmektedir. MFKK katsayıları öznitelikleriyle DVM, spektrogram görüntüleriyle de katlamalı sinir ağları şeklinde iki çeşit makine öğrenmesi algoritmasıyla sınıflandırma işlemlerini yürütmüşlerdir. Her KSA(katlamalı sinir ağları) ve DVM için dörder adet data seti oluşturmuşlardır. Bu setlerden biri, bizim de sınıflandırmak üzere çalışmamızda kullandığımız sağlıklı ve hastalıklı akciğer sesleridir. Yaptıkları çalışmanın sonucu KSA ile %86, DVM ile %86 doğruluk vermektedir. Buradan da anlaşılacağı üzere çalışmamızla bu doğruluk değerlerinin üzerinde sonuç elde ettik.

Yapılan bu çalışmada kullanılan ve geliştirilen yöntemle literatürde bulunan diğer akciğer sesi sınıflandırma yöntemlerine göre başarılı olduğu gerçeği ortadadır. Ayrıca bu çalışmayla, akciğer sesleri üzerine yapılabilecek daha detaylı araştırmalar ve hastalıkların tespiti konusundaki doğruluğun yüksek olmasıyla hem ticari bir ürün geliştirilerek katma değer sağlamak hem de benzer konularda da aşama kaydedilebilmesi adına büyük önem taşımaktadır.

Bu tez çalışmasında kullanılan akciğer sesleri tek kanallı kaydedilmiş olup, literatürdeki diğer çok kanallı yapılmış olan çalışmalara olan üstünlüğü, oskültasyon prosedürüne daha uygun olmuş olmasıdır. Özellikle daha pratik olmasının yanı sıra, çok kanallı kayıtlarda kullanılan kayıt ekipmanlarının her vücut yapısına uygun olmamasından kaynaklanacak olan kayıt bozukluklarını ortadan kaldırmış olmaktadır.

Çalışmaya başlama aşamasında hedeflediğimiz, MFKK katsayılarının diğer öznitelik çıkarma yöntemleriyle sınıflandırılması neticesinde başarılarının izlenmesi konusundaki sonuçlara ulaşılmıştır. Çalışmaların devamı için hem daha fazla tek kanallı kaydedilmiş akciğer sesi kullanılmalı hem sınıflandırıcılar çeşitlendirilmeli hem de öznitelik vektörleri büyütülüp sayıları artırılmalıdır. Ayrıca yapılacak olan çalışmanın ekseni oranında kullanılacak olan cihazların ve hastalık çeşitliliğinin artırılması da kapsamlı çalışmaları daha mümkün kılacak ve doğruluğu daha da artırılmış sınıflandırma sonuçlarına ulaşılacaktır.

6. KAYNAKLAR

1. Lehrer, S. ve Nowey Donald, W., Akçiğer Sesleri Klavuzu, Çeviren: Topalcan, A. ve Öztürk, C., Ankara, 2007.

2. <http://file.toraks.org.tr/TORAKSFD23NJKL4NJ4H3BG3JH/kisokul2009-ppt-pdf/08.00-08.45%20Hayati%20Bilgic.pdf> Solunum Sistemi Hastalıklarında Anamnez, Fizik Muayene ve Semptomlar, Antalya, 2008.

3. Le C., Collet, C. ve Salzenstein, F., Acoustical Respiratory Signal Analysis and Phase Detection, International Conference on Acoustics, Speech and Signal Processing (ICASSP), Mart 2008, Las Vegas, NY, U.S.A., 3629-3632.

4. Aras, S., Tek Kanallı Yaygın Akçiğer Seslerinden Solunum Döngülerinin Otomatik Algılanması ve Sınıflandırılması, Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon, 2018.

5. Bokov,P., Mahut, B., Flaud, P. ve Delclaux, C., Wheezing Recognition Algorithm Using Recordings of Respiratory Sounds at the Mouth in A Pediatric Population, Computers in Biology and Medicine, 70, (2016) 40-50.

6. Chamberlain, D., Kodgule, R., Ganelin, D., Miglani, V. ve Fletcher R. R., Application of Semi-Supervised Deep Learning to Lung Sound Analysis, Engineering in Medicine and Biology Society (EMBS), Ağustos 2016, Florida, U.S.A., 804-807.

7. Matsutake, S., Yamashita, M. ve Matsunaga, S., Abnormal-Respiration Detection by Considering Correlation of Observation of Adventitious Sounds, Signal Processing Conference (EUSIPCO), Ağustos 2015, Nice, France, 634-638.

8. Mazić, I., Bonković, M. ve Džaja, B., Two-Level Coarse-to-Fine Classification Algorithm for Asthma Wheezing Recognition in Children's Respiratory Sounds, Biomedical Signal Processing and Control, 21, (2015) 105-118.
9. Mendes, L., Vogiatzis, I. M., Perantoni, E., Kaimakamis, E., Chouvarda, I., Maglaveras, N., ... ve Paiva, R. P., Detection of Wheezes Using Their Signature in the Spectrogram Space and Musical Features, Engineering in Medicine and Biology Society (EMBS), Ağustos 2016, Florida, U.S.A., 5581-5584.
10. Yu, C., Tsai, T. H., Huang, S.I. ve Lin, C. W., Soft Stethoscope for Detecting Asthma Wheeze in Young Children, Sensors, 13, 6(2013) 7399-7413.
11. Jin, F., Sattar, F. ve Goh, D.Y., Automatic Wheeze Detecting Using Histograms of Sample Entropy, Engineering in Medicine and Biology Society (EMBS), Ağustos 2008, Vancouver, Canada, 1890-1893.
12. Aykanat, M., Kılıç, Ö., Kurt, B. ve Saryal, S., Classification of Lung Sounds Using Convolutional Neural Networks, EURASIP Journal on Image and Video Processing 1, (2017) 65.
13. Pinho, C., Oliviera, A., Jácome, C., Rodrigues, J. ve Marques, A., Automatic Crackle Detection Algorithm Based on Fractal Dimension and Box Filtering, Procedia Computer Science, 64,(2015) 705-712.
14. Zhang, K., Wang, X., Han, F. ve Zhao, H., The Detection of Crackles Based on Mathematical Morphology in Spectrogram Analysis, Technology and Health Care, 23, s2,(2015) 489-494.
15. İçer, S. ve Gengeç, Ş., Classification and Analysis of Non-Stationary Characteristics of Crackle and Rhonchus Lung Adventitious Sounds, Digital Signal Processing, 28, (2014) 18-27.

16. Jin, F., Sattar, F. ve Goh, D. Y., New Approaches for Spectro-Temporal Feature Extraction with Applications to Respiratory Sound Classification, Neurocomputing, 123, (2014) 362-371.

17. Mondal, A., Bhattacharya, P. ve Saha, G., Detection of Lungs Status Using Morphological Complexities of Respiratory Sounds, The Scientific World Journal, (2014).

18. Emmanouilidou, D. , Patil, K., West, J. ve Elhilali, M., A Multiresolution Analysis for Detection of Abnormal Lung Sounds, Engineering in Medicine and Biology Society (EMBS), Ağustos 2012, San Diego, California, U.S.A., 3139-3142.

19. Himeshima, M., Yamashita, M., Matsunaga, S. ve Miyahara, S., Detection of Abnormal Lung Sounds Taking into Account Duration Distribution for Adventitious Sounds, Signal Processing Conference (EUSIPCO), Ağustos 2012, Bucharest, Romania, 1821-1825.

20. Kahya, Y. P., Güler, E. Ç., Sankur, B. ve Engin, T., Detection and Clustering Analysis of Crackles in Respiratory Sounds, Engineering in Medicine and Biology Society, Ekim 1992, São Paulo, Brazil, 6, 2527-2528.

21. Becker, K. W., Scheffer, C., Blanckenberg, M. M. ve Diacon, A. H., Analysis of Adventitious Lung Sounds Originating From Pulmonary Tuberculosis, Engineering in Medicine and Biology Society (EMBS), Temmuz 2013, Osaka, Japan, 4334-4337. IEEE.

22. Serbes, G., Sakar, C. O., Kahya, Y. P. ve Aydin, N., Pulmonary Crackle Detection Using Time Frequency and Time-Scale Analysis, Digital Signal Processing, 23, 3(2013) 1012-1021.

23. Martinez-Hernandez, H. G., Aljama-Corrales, C. T., Gonzalez-Camarena, R., Charleston-Villalobos, V. S. ve Chi-Lem, G., Computerized Classification of Normal and Abnormal Lung Sounds by Multivariate Linear Autoregressive Model,

Engineering in Medicine and Biology Society (EMBS), Eylül 2005, Shangai, China, 5999-6002.

24. Aras, S.,Gangal, A. ve Cinel, M., Investigation of an Appropriate Feature Extraction Methods Based on Single Channel Lung Sounds, 25th. Signal Processing and Communications Applications Conference (SIU), Mayıs 2017, Antalya, Türkiye.

25. Aras, S.,Gangal, A. ve Cinel, M., Classification of Commonly Heard Lung Sounds Recorded in Single Channel, 5th. International Conference on Advanced Technology & Sciences (ICAT), Mayıs 2017, İstanbul, Türkiye.

26. Vannuccini, L., Earis, J. E., Helisto, P., Cheetham, B. M. G., Rossi, M., Sovijarvi, A. R. A. ve Vanderschoot, J., Capturing and Preprocessing of Respiratory Sounds, European Respiratory Review, 10,77(2000) 616-620.

27. Sarkar, M., Madabhavi, I., Niranjan, N. ve Dogra, M., Auscultation of The Respiratory System, Annals of Thoracic Medicine, 10,3 (2015) 158.

28. Stevens, S. S., Volkman, J. ve Newman, E. B., A Scale for The Measurement of The Psychological Magnitude Pitch, The Journal of The Acoustical Society of America, 8, 3 (1937) 185-190.

29. O'shaughnessy, D., Speech Communication: Human and Machine, Universities Press, 1987.

30. Aydemir, Ö. ve Kayıkçıoğlu, T., EEG Tabanlı Beyin Bilgisayar Arayüzleri, Akademik Bilişim'09-XI. Akademiş Bilişim Konferansı Bildirileri, 11-13 Şubat 2009, Harran Üniversitesi.

31. Vapnik, V., The Nature of Statistical Learning Theory, Springer,1995

ÖZGEÇMİŞ

1989 Trabzon doğumludur. Karadeniz Teknik Üniversitesi Elektrik - Elektronik Mühendisliği Bölümünde Lisans eğitimini almış ve 2015 yılında Elektrik - Elektronik Mühendisi unvanı olarak mezun olmuştur. 116E003 numaralı Tübitak 3001 projesinde araştırmacı bursiyer olarak çalışmıştır. Ardından Trabzon Büyük Sanayi Sitesinde elektronik kartlar ve yazılım üzerine çalışmıştır. Şubat 2019 itibariyle Türk Telekom çatısı altında çalışmalarına devam etmektedir.

Uluslararası bilimsel toplantılarda sunulan ve bildiri kitabında basılan bildiriler

Aras, S., Cinel, M. ve Gangal, A., Classification of Commonly Heard Lung Sounds Recorded in Single Channel, 5th International Conference on Advanced Technology & Sciences (ICAT 17), Mayıs 2017, İstanbul, Türkiye.

Ulusal bilimsel toplantılarda sunulan ve bildiri kitabında basılan bildiriler

Aras, S., Cinel, M., ve Gangal, A., Tek Kanallı Akciğer Seslerine Dayalı Uygun Öznitelik Çıkarma Yöntemlerinin Araştırılması, IEEE 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU), Mayıs 2017, Antalya, Türkiye.

Görev aldığı projeler

Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK)

Projedeki Görevi: Yüksek Lisans Öğrencisi (Stajyer)

Proje Kodu/No: TÜBİTAK 3001 / 116E003

Projenin Adı: Elektronik Oskültasyon ile Kayıt Edilen Akciğer Seslerinin Otomatik Tanınması İçin Etkin Bir Öznitelik Çıkarma ve Sınıflandırma Yöntemi Geliştirme

Proje Yürütücüsü: Prof. Dr. Ali GANGAL