



**FATİH SULTAN MEHMET VAKIF ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI  
BİYOMEDİKAL MÜHENDİSLİĞİ PROGRAMI**

**ELEKTRONİK STETOSKOP İLE İNSANLARDA  
PNÖMATİK SOLUNUM BOZUKLUĞUNUN TESPİTİ  
VE ANALİZİ**

**YÜKSEK LİSANS TEZİ**

**SENA BİLİR**

**İSTANBUL, 2022**



**FATİH SULTAN MEHMET VAKIF ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI  
BİYOMEDİKAL MÜHENDİSLİĞİ PROGRAMI**

**ELEKTRONİK STETOSKOP İLE İNSANLARDA  
PNÖMATİK SOLUNUM BOZUKLUĞUNUN TESPİTİ  
VE ANALİZİ**

**YÜKSEK LİSANS TEZİ**

**SENA BİLİR**

**Tez Danışman**

**(DOÇ. DR. SADULLAH ÖZTÜRK)**

**İSTANBUL, 2022**

12/01/2022

**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜNE**

Biyomedikal Mühendisliği Anabilim Dalı'nda 190231001 numaralı Sena BİLİR'in hazırladığı "Elektronik Stetoskop Kullanımı İle İnsanlarda Pnömatik Solunum Bozukluğunun Tespiti ve Analizi" konulu yüksek lisans tezi ile ilgili Tez Savunma Sınavı, 12/01/2022 Çarşamba günü saat 10:30'da yapılmış, sorulara alınan cevaplar sonunda adayın tezinin **KABULÜNE/REDDİNE** karar verilmiştir.

**Düzeltilme verilmesi halinde:**

Adı geçen öğrencinin Tez Savunma Sınavı .../.../20... tarihinde, saat ...:... da yapılacaktır.

**Tez Adı Değişikliği Yapılması Halinde:** Tez adının **Elektronik Stetoskop ile İnsanlarda Pnömatik Solunum Bozukluğunun Tespiti ve Analizi** şeklinde değiştirilmesi uygundur.

<b>Jüri Üyesi</b>	<b>Tarih</b>	<b>İmza</b>
<b>(Danışman)</b> Prof. Dr. Bahattin KARAGÖZOĞLU	12/01/2022	<b>KABUL</b>
Dr. Öğr. Üyesi Orhan ÖZHAN	12/01/2022	<b>KABUL</b>
Doç. Dr. Sadullah ÖZTÜRK	12/01/2022	<b>KABUL</b>
<b>(İkinci Danışman) *</b> .....	.../.../20...	.....
*.....	.../.../20...	.....

\*2. Danışman varsa doldurulacak

## **ETİK BİLDİRİM**

Bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bağlı olduğum üniversite veya bir başka üniversitedeki başka bir çalışma olarak sunulmadığını beyan ederim.

Sena BİLİR

İmza

## TEŐEKKÜR

Yüksek lisansımı yapmama imkan tanıyan okulum Fatih Sultan Mehmet Vakıf Üniversitesine, her zaman ilgisi ve desteęiyle yanımda olan danışman hocam Doç. Dr. Sadullah Öztürk'e teşekkürlerimi borç bilirim.

Bugünleri gösteren Rabbime hamdolsun. Beni sevgileriyle, maddi ve manevi destekleriyle yetiştiren sevgili anne ve babama; hayatıma neşe, renk ve tüm ilginçlikleri katan canım kardeşlerime; hayatın zorluklarını paylaştığım sevgili eşime; gözümün nuru oğluma benim kahrımı çektikleri, hep yanımda oldukları ve yaşattıkları mutluluklar için çok teşekkür ederim.

Sena BİLİR

İmza

# ELEKTRONİK STETOSKOP İLE İNSANLARDA PNÖMATİK SOLUNUM BOZUKLUĞUNUN TESPİTİ VE ANALİZİ

**Sena Bilir**

## ÖZET

Akciğer seslerinin analizlerini kolaylaştırmak amacıyla bazı terimler kullanılmaktadır. Buna göre, sağlıklı insanların seslerine normal sesler, hasta insanların seslerine anormal sesler denir. Anormal sesler, normal seslerin üzerine eklenen sürekli veya süresiz ek seslerdir. Süresiz ek seslerden biri olan ral, ince ve kaba ral sesleri olmak üzere iki çeşittir. İnce ral, pnömoni belirtisi olan ek sestir. Bu çalışmada pnömoni hastalığının otomatik olarak belirlenmesi amaçlanmıştır. Günümüzde elektronik stetoskoplar sayesinde akciğer sesleri kaydedilebilmekte ve bilgisayarlara aktarılabilir. Böylece akciğer seslerini analiz etmek mümkün hale gelmiştir. Yapılan çalışmada elektronik stetoskop yardımıyla kaydedilmiş hazır akciğer ses verileri kullanılmıştır. Bu ses verilerine Kaggle sitesinden ulaşılmıştır. Akciğer sesleri arasından normal ve üç tip anormal ses seçilmiştir. Anormal sesler pnömoni, bronşektazi ve KOAH hastalarına aittir. *MATLAB* yardımıyla üç farklı filtre (Butterworth, Chebyshev ve Eliptik bandgeçiren filtreleri) tasarlanmıştır. Bu filtrelerin her biri akciğer seslerine uygulanmıştır. Daha sonra dalgacık dönüşümü uygulanarak elde edilen alt bantlardan öznitelikler elde edilmiştir. Öznitelikler elde edildikten sonra akciğer verileri "Normal-Anormal" olarak , ardından anormal veriler "Pnömoni Var veya Yok" olarak etiketlenmiştir. Böylece her filtre için iki farklı veri seti oluşturulmuştur. Ayrıca bu veri setlerine PCA analizi uygulanmış ve PCA analizinin sınıflandırmaya etkisi gözlemlenmiştir. PCA'lı ve PCA'sız veri setleri kNN ve SVM ile sınıflandırılmış, elde edilen sonuçlar birbirleriyle kıyaslanmıştır.

**Anahtar kelimeler;** Pnömoni, Ral, PCA, kNN, DVM, Filtreler , SVM

# **DETECTION AND ANALYSIS OF HUMAN PNEUMATIC RESPIRATORY DISORDER WITH THE AN ELECTRONIC STETHOSCOPE**

**Sena BİLİR**

## **ABSTRACT**

Some terms are used to facilitate the analysis of lung sounds. Accordingly, the sounds of healthy people are called normal sounds, and the sounds of patient people are called abnormal sounds. Abnormal sounds are continuous or discontinuous additional sounds added on top of normal sounds. Rale, which is one of the discontinuous additional sounds, is of two types as fine and coarse ral sounds. Fine rales are an additional sound that is a sign of pneumonia. In this study, it was aimed to determine the pneumonia automatically. Today, thanks to electronic stethoscopes, lung sounds can be recorded and transferred to computers. Thus, it has become possible to analyze lung sounds. In the study, ready-to-use lung sound data were recorded with the help of an electronic stethoscope. These sound data were obtained from the Kaggle site. Among the lung sounds, normal and three types of abnormal sounds were selected. Abnormal sounds belong to patients with pneumonia, bronchiectasis, and COPD.

Three different filters (Butterworth, Chebyshev, and Elliptic bandpass filters) were designed with the help of *MATLAB*. Each of these filters was applied to lung sounds. Then, the features were obtained from the subbands obtained by applying the wavelet transform. After the features were obtained, the lung data were labeled "Normal-Abnormal" followed by abnormal data "Pneumonia Yes or No". Thus, two different data sets were created for each filter. In addition, PCA analysis was applied to these data sets, and the effect of PCA analysis on classification was observed. Data sets with and without PCA were classified with kNN and SVM, and the results were compared with each other.

**Keywords;** Pneumonia, Ral, PCA, kNN, SVM, Filters

## ÖNSÖZ

Pnömoni, dünya genelinde insanların sağlığını tehdit eden ölümcül ve bulaşıcı hastalıklardan biridir. Bu durum pnömoni teşhisinin önemini arttırmaktadır. Günümüzde teşhisin doğruluğunu arttırmak amacıyla bilgisayarlar yardımıyla teşhis yapma çalışmaları önem kazanmıştır. Bu çalışmada da pnömoniyi akciğer sesleri kullanarak otomatik olarak belirlemek amaçlanmıştır. Karşılaşılan zorluklardan biri, akciğer seslerine ulaşmak olmuştur. Hastanelerden veri elde etmek meşakkatli bir iş olduğundan Kaggle sitesinde paylaşılan isimsiz veriler kullanılmıştır. Diğer bir zorluk ise siteden elde edilen akciğer seslerinin farklı stetoskoplarla ve vücudun farklı bölgelerinden kaydedilmiş olmasıdır. Bunlar da çalışmanın doğruluğunu etkileyen önemli faktörlerdir. Bu süreç benim için zorlu geçmiş olsa da oldukça verimli ve öğretici geçmiştir.



# İÇİNDEKİLER

ÖZET.....	v
ABSTRACT.....	vi
ÖNSÖZ.....	vii
ŞEKİLLER LİSTESİ.....	x
TABLolar LİSTESİ.....	xii
KISALTMALAR .....	xiii
GİRİŞ .....	1
BİRİNCİ BÖLÜM.....	4
1. GENEL BİLGİLER.....	4
1.1. SOLUNUM SİSTEMİ.....	4
1.1.1. Üst Solunum Yolu Organları .....	6
1.1.2. Alt Solunum Yolu Organları.....	6
1.1.3. Akciğerler.....	7
1.1.4. Diyafram .....	8
1.2. SOLUNUM SESLERİ .....	9
1.2.1. Normal Solunum Sesleri .....	9
1.2.1.1. Trakeal ve Bronşiyal Solunum Sesleri.....	10
1.2.1.2. Veziküler Solunum Sesleri.....	10
1.2.1.3. Bronkoveziküler Solunum Sesleri.....	10
1.2.2. Anormal Solunum Sesleri.....	10
1.2.2.1. Sürekli Ek Sesler .....	11
1.2.2.2. Süreksiz Ek Sesler .....	11
1.3. PNÖMONİ (ZATÜRRE) .....	14
1.4. STETOSKOP .....	15
1.5. AKCİĞER SESLERİNİN FİLTRELENMESİ .....	19
1.5.1. Butterworth Bantgeçiren Filtre .....	19
1.5.2. Chebyshev Bantgeçiren Filtre.....	20
1.5.3. Eliptik Bantgeçiren Filtre (Cauer Filtre).....	20
1.5.4. Dalgacık Dönüşümü (Wavelet Transform) Tabanlı Gürültü Giderme .....	21

1.5.4.1. Dalgacık Dönüşümü Nedir .....	21
1.5.4.2. Ayırık Dalgacık Dönüşümü (DWT) .....	23
1.6. ÖZİNİTELİK ÇIKARIM YÖNTEMLERİ.....	26
<b>İKİNCİ BÖLÜM .....</b>	<b>29</b>
<b>2. MAKİNE ÖĞRENMESİ ALGORİTMALARI .....</b>	<b>29</b>
2.1. Destek Vektör Makineleri (DVM) .....	29
2.1.1. Doğrusal (Lineer) Destek Vektör Makinesi.....	29
2.1.1.1. Doğrusal Sınıflandırıcı: Ayrılabilir Doğrusal.....	30
2.1.1.2. Doğrusal Sınıflandırıcı: Ayrılabilir Doğrusal .....	33
2.1.2. Doğrusal (Lineer) Olmayan Destek Vektör Makinesi .....	33
2.1.2.1. Özellik Uzayı .....	34
2.1.2.2. Kernel Hilesi .....	34
2.2. K-En Yakın Komşular (KNN) .....	36
2.3. Temel Bileşen Analizi (PCA).....	38
2.4. Hata Matrisi (Confusion Matrix).....	40
<b>ÜÇÜNCÜ BÖLÜM .....</b>	<b>43</b>
<b>3. YÖNTEM VE BULGULAR.....</b>	<b>43</b>
3.1. YÖNTEM .....	43
3.2. BULGULAR .....	44
<b>DÖRDÜNCÜ BÖLÜM .....</b>	<b>57</b>
<b>4. TARTIŞMA .....</b>	<b>57</b>
<b>SONUÇ VE ÖNERİLER.....</b>	<b>61</b>
<b>KAYNAKLAR .....</b>	<b>62</b>
<b>EKLER.....</b>	<b>68</b>

## ŞEKİLLER LİSTESİ

### Sayfa

Şekil 1. Akciğer Havayolu Sistemi .....	5
Şekil 2. Nefes Alıp-Verme Mekanığı.....	6
Şekil 3. Hava yollarının soluk borusu ve diğer ana dalları burada gösterilmiştir. Trakeanın etrafındaki kıkırdak halkalar rijitlik sağlar ve çökmesini engeller. Ana dallar, sol ve sağ bronşu (sağ bronş gösterilmemiştir), terminal bronşiyolları ve alveolleri içerir.....	8
Şekil 4. Akciğer hacmini ve basıncını değiştiren solunum kasları .....	9
Şekil 5. (a) Laënnec'in stetoskopu: 1) alet montajı; 2) ve 3) uzunlamasına kesitte aletin iki kısmı; 4) ayrılabilir göğüs parçası; 5) kulak parçası sökülmüş; 6) enine kesit. (b) Laennec ve stetoskopu. Resim Robert A. Thom(1915-1979) [33].....	17
Şekil 6. Littmann Klasik Stetoskop (sol), Littmann elektronik stetoskop(sağ) .....	18
Şekil 7. Değişen derecelere göre kazanç frekans grafiği[32].....	20
Şekil 8. Bazı dalgacıkların görünümü.....	22
Şekil 9. (A) Dalgacık Özellikleri (B) Dalgacık, sinyal ve dönüşüm.....	23
Şekil 10. Ayrık Dalgacık Dönüşü alt bantları; $h[n]$ yüksek geçiren filtre, $g[n]$ alçak geçiren filtre [38] .....	25
Şekil 11. Temel Dalgacık Şekilleri .....	26
Şekil 12. Lineer olarak ayrılabilen ve ayrılmayan destek vektör makineleri.....	30
Şekil 13. Lineer ayrılabilir DVM [44] .....	33
Şekil 14. Polinomial kernel örneği.....	35
Şekil 15. RBF kernel örneği.....	36
Şekil 16. (a)Kırmızı yuvarlak ve mavi kare üyelerin bulunduğu uzay (b) Uzaya yeni üyenin eklenmesi (c) Yeni üyenin diğer üyelere göre mesafelerinin ölçülmesi ve sınıflandırılması .....	37

Şekil 17. Hata Matrisi .....	41
Şekil 18. Ham akciğer verileri ve eliptik filtre ile filtrelenmiş veriler.....	45
Şekil 19. Ham akciğer verileri ve Chebyshev filtre ile filtrelenmiş veriler .....	45
Şekil 20. Ham akciğer verileri ve butterworth filtre ile filtrelenmiş veriler .....	46
Şekil 21. Filtrelenmiş hasta verilerin kıyası.....	46
Şekil 22. Filtrelenmiş sağlıklı verilerin kıyası .....	47
Şekil 23. Sağlıklı ses verisine uygulanan dalgacık dönüşümü sonuçları.....	48
Şekil 24. KOAH ses verisine uygulanan dalgacık dönüşümü sonuçları.....	48
Şekil 25. Bronşektazi ses verisine uygulanan dalgacık dönüşümü sonuçları .....	49
Şekil 26. Pnömoni ses verisine uygulanan dalgacık dönüşümü sonuçları.....	49
Şekil 27. “Normal-Anormal” sınıfına uygulanan PCA analizi sonucu.....	50
Şekil 28. “Pnömoni Var veya Yok” sınıfına uygulanan PCA analizi sonucu.....	50
Şekil 29. Butterworth filtre kullanılarak normal-anormal akciğer sesleri ayırımında sınıflandırma sonuçları .....	51
Şekil 30. Butterworth filtre kullanılarak pnömonili akciğer sesleri ayırımında sınıflandırma sonuçları .....	52
Şekil 31. Eliptik filtre kullanarak normal-anormal akciğer sesleri ayırımında sınıflandırma sonuçları .....	53
Şekil 32. Eliptik filtre kullanarak pnömonili akciğer sesleri ayırımında sınıflandırma sonuçları.....	54
Şekil 33. Chebyshev filtre kullanarak normal-anormal akciğer sesleri ayırımında sınıflandırma sonuçları .....	55
Şekil 34. Chebyshev filtre kullanarak pnömonili akciğer sesleri ayırımında sınıflandırma sonuçları .....	56

## TABLolar LİSTESİ

### Sayfa

Tablo 1: Normal Solunum Sesleri ve Özellikleri.....	12
Tablo 2: Ek Sesler ve Özellikleri .....	13
Tablo 3. “Normal-Anormal” sınıflandırma sonuçları .....	59
Tablo 4. “Pnömoni Var veya Yok” sınıflandırma sonuçları .....	59

## KISALTMALAR

CO <sub>2</sub>	Karbondioksit
DVM	Destek Vektör Makineleri
DWT	Ayrık Dalgacık Dönüşümü
FN	False Negatif
FP	False Pozitif
kNN	k- En Yakın Komşular
KOAH	Kronik Obstrüktif Akciğer Hastalığı
O <sub>2</sub>	Oksijen
PCA	Temel Bileşen Analizi
PSD	Güç Spektrum Yoğunluğu
SVM	Support Vector Machines
TN	True Negatif
TP	True Pozitif

## GİRİŞ

Oskültasyon ile hastalık teşhisi günümüzde yaygın olarak kullanılan bir yöntemdir. Oskültasyon, hastalık teşhisinde, organların işleyişini kontrol etmek amacıyla stetoskop kullanarak vücut içi seslerin dinlenilmesidir. Bu tıbbi dinleme işlemi, dolaşım sistemi, solunum sistemi ve gastrointestinal sistemi incelemek amacıyla yapılır. Fiziksel muayenelerin olmazsa olmazıdır ve sağladığı bilgilerle, hastadaki patolojik sorunların teşhisini kolaylaştırır.

Klasik stetoskop ile yapılan muayenelerde hatalı teşhisler yapılabilmektedir. Oskültasyon tıbbi personelin duyma ve tecrübesine bağlı bir süreç olduğu için, personelin stres, yorgunluk, tecrübe eksikliği veya dikkatsizlik gibi durumlarda hatalı teşhis yapması kaçınılmazdır. Ayrıca klasik stetoskoplar 120 Hz üzerindeki ses bileşenlerini zayıflatmaktadır; bu da teşhiste zorluklar yaşanmasına sebep olmaktadır. Bu zorlukların üstesinden gelebilmek amacıyla, elektronik stetoskoplar üretilmiştir. Bu stetoskoplar ile vücut içi sesler kayıt edilerek bilgisayarlara aktarılabilir. Bu sayede sesler yeniden dinlenebilir, görüntülenebilir ve başka kişilerle paylaşılabilir. Bilgisayarlara aktarılabildiği için de üzerinde sinyal işleme teknikleri uygulanabilmektedir. Bu teknikler ile otomatik hastalık teşhisi yapılabilmekte bu da teşhiste yardımcı olmaktadır.

Akciğer sesleri sıklıkla öğretim amacıyla kaydedilir ve araştırma için analiz edilir. Bu tür araştırmaların diğer amacı, akciğer ses sinyalinin önemli fizyolojik veya patolojik süreçlerle ilgili niteliksel veya niceliksel bilgileri çıkarmaktır. Bu seslerin kolayca ve invaziv olmayan bir şekilde kaydedilebilmesi, yaklaşımın önemini arttırmaktadır [1]. 1950'li yıllarda akciğer ve kalp sesleri gibi biyolojik ses sinyallerinin kayıt edilmesine ve analizinin yapılmasına McKusick ve arkadaşları tarafından başlanmıştır [2]. Kaydedilen biyolojik ses sinyallerinden öznelik çıkartımı yapılarak, bu seslerin sınıflandırılması yapılmaktadır. Bu öznelikler zaman, frekans, zaman-frekans alanları kullanılarak elde edilmektedir. En çok kullanılan öznelik çıkartma teknikleri; Otoresif Model (AR), Hızlı Fourier

Dönüşümü (HFD), Kısa Zamanlı Fourier Dönüşümü (KZFD), Mel-Frekansı Kepstral Katsayıları (MFKK), Dalgacık Dönüşümü gibi yöntemlerdir [3].

Literatüre bakıldığında bu konuda yapılmış bir çok çalışma mevcuttur. Tezin amacına uygun olarak, sadece akciğer sesleri üzerinde yapılmış çalışmalar incelenmiştir. Yapılan çalışmalar çeşitli filtreler ve yöntemlerle ek sesleri belirlemeyi amaçlamıştır.

Li ve arkadaşları, wheeze ek sesi üzerinde çalışmıştır. 150-1000 Hz kesme frekansında analog filtre kullanmış, öznitelik çıkartmak için sinyal segmentasyonu, Güç Spektrum Yoğunluğu (PSD) ve Fast Hızlı Fourier Dönüşümü (FFT) yöntemlerini kullanmıştır. Sınıflandırma yöntemi olarak Fischer diskriminant analizi tercih etmişlerdir [4] .

İçer ve Gengeç crackle ve ronküs sesleri üzerinde çalışmışlardır. 150-1800 Hz kesme frekansına sahip IIR (infinite impulse response) Buterworth bantgeçiren filtre (BPF) kullanmışlar, PSD ve Welch metodu ile öznitelikleri elde etmişlerdir. Sınıflandırma yöntemleri içinden Destek Vektör Makineleri (SVM) tercih etmişlerdir [5].

Serbes ve arkadaşları crackle ek sesleri ile çalışmışlardır. 80-4000 Hz aralığında Butterworth bpf ve Bessel hpf kullanmışlar, öznitelikleri zaman-frekans ve zaman ölçekleme analizi ile elde etmişlerdir. SVM, K en yakın komşular (KNN) ve çok katmanlı algılayıcı (multi-layer perception) sınıflandırma yöntemlerini seçmişlerdir [6].

Rielle ve Nahoma wheeze ek sesi üzerinde çalışmışlar. 20-4000 Hz kesme frekansına sahip finite impulse response (FIR) LPF ve IIR Butterworth HPF kullanmışlar, spektral izdüşüm (spectral projection) ile öznitelik çıkartıp, Yapay Sinir Ağları (ANN) ile sınıflandırma yapmışlardır [7].

Güler ve arkadaşları wheeze ve crackle ek sesleri ile çalışmışlar, 80-2000 Hz kesme frekanslarına sahip Bessel HPF ve Butterworth LPF kullanmışlar. Öznitelikleri PSD ile çıkartıp sınıflandırmayı çok katmanlı algılayıcı (multi-layer perception) ile yapmışlardır [8].



Piirilab ral seslerinin frekans yoğunluğu seviyelerinde önemli farklılıklar olduğunu gözlemlemiştir [9].

Kandaswamy ve arkadaşları akciğer seslerini dalgacık dönüşümünü kullanarak yapay sinir ağları ile sınıflandırmışlardır. Akciğer seslerini dalgacık dönüşümünü kullanarak alt frekans bantlarına ayırmışlar ve eğitim verileri ile %100 test verileri ile %91.67 doğrulukla sınıflandırmışlardır [3].

Bu çalışmada kullanılan akciğer sesi verileri Kaggle web sitesinden alınmıştır. Toplam 920 ses verisi vardır. Aralarından KOAH, pnömoni, bronşektazi hastalarına ve sağlıklı kişilere ait sesler seçilerek 198 ses verisi içeren bir veri seti oluşturulmuştur. Kronik obstrüktif akciğer hastalığı (KOAH), semptomları nefes almada zorluk, öksürük, mukus (balgam) üretimi ve wheeze (hırıltı)dir. Bronşektazi, belirtisi kaba ral'dir (coarse crackle). Zatürre, belirtisi ise ince ral (fine crackle) [10]. Akciğer seslerine Chebyshev, Butterworth ve Eliptik filtreler ile dalgacık dönüşümü uygulanmıştır. Elde edilen verilerden öznitelik çıkarımı yapılmıştır. İlk önce normal ve anormal sesler sınıflandırılmış sonrasında anormal sesler kendi aralarında sınıflandırılmıştır. KOAH ve bronşektazi "Pnömoni Yok" olarak, pnömoni ise "Pnömoni Var" olarak etiketlenmiştir. Ardından bu özellikler kNN ve DVM makine öğreticilerine verilerek sınıflandırma yapılmıştır. Bu çalışmanın farklılığı, akciğer seslerini önce normal-anormal olarak ayırmak ardından anormal sesleri pnömoni hastalığı olup olmasına göre sınıflandırmaktır. Diğer çalışmalar ek seslerin ayrımını yaparken, bu çalışmada spesifik olarak pnömoni hastalığının belirlenmesi hedeflenmiştir. Ayrıca üç farklı filtre sonucu elde edilen özniteliklerin hem PCA analizi yapılmış hem de yapılmamış haliyle, DVM ve kNN sınıflandırıcıları ile dört farklı sınıflandırma yapılmıştır. Böylece filtreler ve sınıflandırıcılar kıyaslanırken, PCA'nın sınıflandırmaya olan etkisi de incelenmiştir. Böylece hem normal-anormal akciğer sesi ayırımında hem de pnömoni teşhisinde tıbbi personele yardımcı olmak amaçlanmıştır.


# BİRİNCİ BÖLÜM

## 1. GENEL BİLGİLER

### 1.1. SOLUNUM SİSTEMİ

Solunum sistemi, canlı organizmalarda enerji gereksinimlerini karşılamak için oksijeni alıp karbondioksiti dışarı atan sistemdir. Canlı organizmada, karbon içeren moleküllerin oksidasyonu yoluyla karbondioksit ile birlikte enerji açığa çıkar. Solunum terimi, organizma ile içinde yaşadığı ortam ve vücudun hücreleri ile onları yıkayan doku sıvısı arasındaki solunum gazlarının (oksijen ve karbondioksit) değişimini ifade eder.

Akciğer ise gaz alışverişini sağlayan bir organdır. Hassas dokularının zarar görmemesi için kemikli ve kaslı bir yapıya sahip olan göğüs kafesine yerleştirilmiştir. Vücuttaki dokulara sürekli olarak bir oksijen akışı sağlar ve kanı gaz halindeki atık ürün olan karbondioksitten temizler. Bu gaz alışverişi hava yolu adı verilen bir boru sistemi aracılığıyla gerçekleşir. Hava yolları üst ve alt hava yolları sistemleri olarak ayrılabilir. Bu iki sistem arasındaki geçiş Şekil 1’de görüldüğü gibi, solunum ve sindirim sistemlerinin kesiştiği yer olan larinksin (gırtlak) hemen üst kısmında yer alır.



Şekil 1. Akciğer Havayolu Sistemi

Üst solunum yolu sistemi, burun ve paranasal boşluklar (veya sinüsler), farenks (veya boğaz) ve kısmen de ağız boşluğunu içerir. Alt hava yolu sistemi, gırtlak, soluk borusu, kök bronşlar ve akciğerler içinde yoğun olarak dallanan tüm hava yollarından oluşur, intrapulmoner bronşlar, bronşiyoller ve alveolar kanallar gibi. Solunum için diğer organ sistemleriyle beraber çalışması gereklidir.

Ana solunum kası olan diyafram ve göğüs duvarının interkostal kasları, merkezi sinir sisteminin kontrolü altında akciğerde pompalama eylemi oluşturarak önemli bir rol oynar. Kaslar göğüs kafesinin genişleyip daralmasını yani nefes alıp vermeyi sağlar. Bu genişleme-daralma eylemi şu şekilde gerçekleşir: Basınç değişimleri sebebiyle hava akciğerlere girip çıkabilir. Alveolar boşluklardaki hava basıncı atmosfer basıncının altına düştüğünde, gırtlakın açık olması koşuluyla hava akciğerlere girer (inspirasyon); alveollerdeki hava basıncı atmosfer basıncını aştığında, akciğerlerden hava üflenir (ekspirasyon). Nefes alıp verme mekaniği Şekil 2'de gösterilmiştir.



Şekil 2. Nefes Alıp-Verme Mekanikliği

### 1.1.1. Üst Solunum Yolu Organları

**Burun:** Burun, solunum yollarının dış ortamla bağlantısını sağlayan ve koku alma organını içeren bir yapıdır. İç yüzeyinde bulunan dokudaki kıllar ve mukus tabakası soluma ile alınan havayı toz ve mikroplardan arındırır, havayı nemlendirir ve ısıtır.

**Farenks (Yutak):** Yutak, ağız ve burun boşluklarının kesişme noktasında bulunur. Soluk alma ile alınan havayı soluk borusuna; soluk verirken atılan havayı ise ağız ve burun boşluklarına ileten yapıdır.

### 1.1.2. Alt Solunum Yolu Organları

**Larenks (Gırtlak):** Ses kutusu olarak da adlandırılan gırtlak, soluk borusunun (trakea) tepesine bağlı içi boş, boru şeklinde bir yapıdır. Hava akciğerlere giderken gırtlaktan geçer. Gırtlak ayrıca vokal sesler üretir. Yiyeceklerin ve diğer yabancı parçacıkların alt solunum yollarına geçişini engeller.


**Soluk Borusu (Trakea):** Trakea omurgalılarda ve omurgasızlarda hava taşıyan bir tüp veya tüp sistemidir. Havayı gırtlaktan iki ana bronşa iletir ve nihai varış yeri akciğerler ve hava keseleridir. Trakea yaklaşık 15 santimetre uzunluğunda ve 2 ila 3 santimetre çapındadır. Hava için geçiş görevi görür, akciğerlere giden havayı nemlendirir ve ısıtır ayrıca solunum yüzeyini yabancı partiküllerin birikmesinden

korur. Soluk borusu, silia adı verilen küçük saç benzeri çıkıntılar içeren hücrelerden oluşan nemli bir mukoz membran tabakası ile kaplıdır. Silia, partikülleri yakalamak için trakeanın kanalına çıkıntı yapar. Mukoza zarında mukus damlacıkları ve su molekülleri salgılayan hücreler ve kanallar da vardır.

### **1.1.3. Akciğerler**

Akciğerler, göğüs boşluğunda bulunan ve kandaki oksijen-karbondioksit alışverişini sağlayan solunum organlarıdır. Plevra ismi verilen ince zarlı bir kese içinde bulunur. Her biri ana bronşuyla soluk borusuna ve arterlerle kalbe bağlıdır. Her akciğer, bir doku fissürü ile birbirinden ayrılan loblara bölünmüştür. Sağ akciğerin üç ana lobu vardır; kalbin asimetrik yerleşimi nedeniyle biraz daha küçük olan sol akciğerin iki lobu vardır. Dahili olarak, her lob ayrıca yüzlerce lobüle bölünür. Her lobül bir bronşiyol ve bağlı dallar, ince bir duvar ve alveol kümeleri içerir [11].

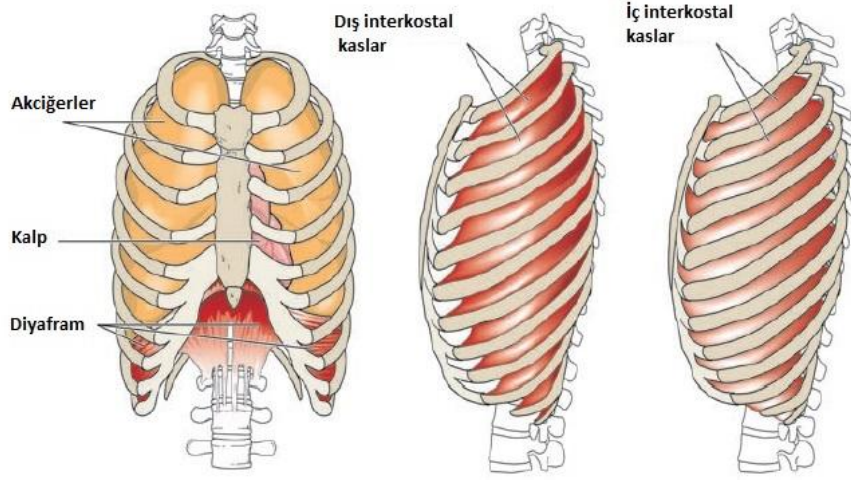
Bronşlar ve bronşiolde trakeadan geçen hava, akciğer yüzeyine giden, giderek daha küçük çaplı dallara ayrılan bronş ağacına girer. Bu bronş dallarının en büyüğü olan sağ ve sol birincil bronşlar , sırasıyla sağ ve sol akciğerlere hava sağlar. Birincil bronşlar,yapı olarak trakeaya benzer. Solunum tüpleri, bronşiyoller olarak bilinen daha küçük çaplı tüplere dallanır. Bronşiyollerin son kısmı solunum bronşiyolleridir. Bunlar, alveol adı verilen mikroskobik hava ceplerinde veya keselerde sonlanan alveolar kanallara ayrılır. Alveoller, oksijen ve kan arasında solunum gazları olan O<sub>2</sub> ve CO<sub>2</sub> gazlarının alışverişinin yapıldığı yerdir. Her bir hava dolu alveolar kesenin dış yüzeyi pulmoner kılcal damarlarla kaplıdır. Bu küçük damarlar O<sub>2</sub> alıp CO<sub>2</sub> verirler. İnsan akciğerinde gaz alışverişi için toplam alveolar yüzeyin 70 m<sup>2</sup> olduğu tahmin edilmektedir.



Şekil 3. Hava yollarının soluk borusu ve diğer ana dalları burada gösterilmiştir. Trakeanın etrafındaki kıkırdak halkalar rijitlik sağlar ve çökmesini engeller. Ana dallar, sol ve sağ bronşu (sağ bronş gösterilmemiştir), terminal bronşiyolleri ve alveolleri içerir.

#### 1.1.4. Diyafram

Diyafram, göğüs boşluğunu karın boşluğundan ayıran tabaka benzeri bir kastır. Göğüs boşluğu ayrı bir kompartman olduğundan ve de akciğer dokusu çok ince ve elastik olduğundan göğüs boşluğunun hacmindeki değişiklikler akciğerin hacmini etkiler. Diyafram ve dış interkostallar, beyin sapındaki solunum kontrol merkezinden uyarıcı bir sinyal geldiğinde kasılırlar. Diyaframın kasılmasıyla karın boşluğu ve burada bulunan organlar düzleşir ve aşağı doğru itilir. Dış interkostal kasların kasılmasıyla göğüs kafesi yukarı ve dışa doğru genişler. Hem diyaframın hem de kaburga kaslarının bu hareketleri akciğer hacminin artmasına dolayısıyla akciğer basıncının düşmesine sebep olur [12].



Şekil 4. Akciğer hacmini ve basıncını değiştiren solunum kasları

## 1.2. SOLUNUM SESLERİ

Solunan havanın göğüs duvarı, trakea ve bronşlara çarpması sonucunda oluşan türbülans ile duyulan seslere solunum sesleri denir. Soluk alma (inspirasyon) ve soluk verme (ekspirasyon) esnasında oluşan hava akımı sebebiyle akciğerler tarafından ses sinyalleri üretilir. Bu sinyaller solunum sisteminin durumu hakkında önemli bilgiler içerir [13]. Solunum sesleri normal ve anormal solunum sesleri olarak sınıflandırılır. Normal solunum sesleri, sağlıklı bireylerde görülürken anormal solunum sesleri akciğerlerde meydana gelen problemler sonucunda görülür [14].

### 1.2.1. Normal Solunum Sesleri

Normal solunum sesleri, genel olarak sağlıklı bir kişinin göğüs duvarından duyulan solunum sesleri olarak tanımlanır. Bu seslere ağızda duyulan seslerin yanı sıra trakeal, bronşiyal, veziküler ve bronkoveziküler sesler de dahildir. Oskültasyon sırasında duyulan normal sesleri; sesin kaynağı ile göğüs duvarı arasındaki mesafe, ses iletim yolu ve sesin yeri olmak üzere üç değişken etkiler. Normal nefes sesleri, hava yollarındaki ilişkili basınç değişiklikleri, doku titreşimleri ve hava akımı paternleri, tarafından üretilir.

#### 1.2.1.1. Trakeal ve Bronşiyal Solunum Sesleri

Trakea üzerinden duyulan normal nefes sesleri (trakeal nefes sesleri) ve ana bronşlar (bronşiyal nefes sesleri) türbülanslı hava akımı paternleri tarafından üretilir. Trakeal nefes sesleri trakea üzerinden duyulabilir. Ayrıca trakeal sesler sert ve tiz sesler olarak tanımlanır. Bronşiyal solunum sesleri yüksek ve tiz olarak tanımlanır ve trakeanın yanında duyulabilir. Soluk alma ile vücuda giren hava, bu büyük hava yollarından kolayca geçer.

Trakeal solunum sesleri dinlenirken, inspirasyonun sonunda kısa bir duraklama duyulabilir. Ekspirasyon inspirasyondan daha uzun sürer. İnspiratuar-ekspiratuar (I:E) oranı 1:2 ila 1:3'tür. Bu solunum seslerinin ses frekanları 200 ila 2.000 Hz aralığındadır [19].

#### 1.2.1.2. Veziküler Solunum Sesleri

Veziküler solunum sesleri akciğer dokusu ve göğüs duvarı yoluyla iletilir. Bu normal sesler trakeal ve bronşiyal seslerden daha az duyulur. İnspirasyon net bir şekilde duyulur ve ekspirasyon inspirasyonu hemen takip eder. I:E oranı 3:1 ila 4:1'dir. Bu normal nefes seslerinin ses frekans dağılımı 200 ila 600 Hz'dir [19].

#### 1.2.1.3. Bronkoveziküler Solunum Sesleri

Bronkoveziküler solunum sesleri merkezi büyük hava yollarının önünde ve arkasında duyulur. Perdeleri ve süreleri veziküler nefes sesleri ile bronşiyal seslerinkinin tam ortasındadır; I:E 1:1 oranı ile eşittir [15].

### 1.2.2. Anormal Solunum Sesleri

Anormal solunum sesleri, seslerin duyulmaları gereken yerlerde olmaması veya yoğunluğunun azalmasıdır. Buna ek olarak, olmaması gereken seslerin yanı sıra ek seslerin de duyulmasıdır. Bu sesler, iltihaplanma veya tıkanıklık gibi bir akciğer sorununa işaret edebilir.

Ek sesler, normal solunum seslerinin üzerine bindirilmiş seslerdir. Sürekli (hırıltı gibi) veya süreksiz (ral gibi) olabilirler ve bazıları her ikisi de (ciyaklama gibi) olabilir. Bu tür sesler genel olarak bir pulmoner bozukluğun göstergesidir [16].



#### 1.2.2.1. Sürekli Ek Sesler

**Stridor:** Stridor, üst solunum yolunun daralmış bir bölümünde oluşan türbülanslı hava akımı sonucunda üretilen tiz, müzikal bir sestir [17]. Genellikle bir stetoskop yardımı olmadan da net bir şekilde duyulur. Ses analizinde, genellikle birkaç harmonik eşliğinde, yaklaşık 500 Hz'lik bir temel frekansa sahip düzenli, sinüzoidal salınımlar ile karakterize edilir. Yetişkinlerde stridorun diğer nedenleri arasında akut epiglottit, cihazın çıkarılmasından sonra hava yolu ödemi, anafilaksi, ses teli disfonksiyonu, yabancı cisim inhalasyonu, laringeal tümörler, tiroidit ve trakeal karsinom bulunur [18].

**Hırıltı (Wheeze):** Hırıltı en kolay ayırt edilebilen ek sestir. Tipik olarak 100 milisaniyeden uzun sürer. Ses analizinde hırıltı, 100 ila 1000 Hz aralığında ses enerjisine ve ara sıra 1000 Hz'i aşan harmoniklere sahip sinüzoidal salınımlar olarak görünür [19]. Astım ve KOAH' ta, göğsün her tarafında hırıltı duyulabilir. Lokalize hırıltı, genellikle bir yabancı cisim, mukus tıkaçı veya tümör tarafından tıkanma ile ilişkilidir [18].

**Cıyıklama(Squawk):** Cıyıklama, inspiratuar fazda duyulabilen ek seslerdir. Ses, hem sürekli hem de sürekli olmayan bir karışımıdır. [20]. Frekans aralığı 200–300 Hz arasındadır [18]. Distal hava yollarını etkileyen durumlarla ilişkilidir.

#### 1.2.2.2. Süreksiz Ek Sesler

**Ral (Crackle):** Raller, inspirasyon ve bazen de ekspirasyon sırasında duyulan kısa, patlayıcı, müzikal olmayan seslerdir [21]. İki ral kategorisi tanımlanmıştır: ince ral ve kaba ral. Oskültasyonda, genellikle orta-geç inspirasyon sırasında ince raller duyulur. Öksürükten etkilenmeyen ince raller yerçekimi ile değişir. Vücut pozisyonundaki değişikliklerle (örn. Öne eğilme) değişir veya kaybolur. Kaba raller, inspirasyon sırasında ve ekspirasyon boyunca erkenden ortaya çıkma eğilimindedir. Herhangi bir akciğer bölgesinde duyulabilir, öksürük ile değişebilir veya kaybolabilir ve vücut pozisyonundaki değişikliklerden etkilenmezler. Ses analizinde, raller, tekrarlayan bir desenle hızla sönümlenen dalga sapmaları olarak görünür. Kaba rallerin tepe frekansları 800 Hz'in altındadır ve düşük perdeli değerlere sahiptir.

İnce rallerin tepe frekansları 800 Hz'in üstündedir ve yüksek perdeli değerlere sahiptir [22][23]. İnce ral sesleri genellikle zatürre, konjestif kalp yetmezliği ve akciğer fibrozu ile ilişkilidir. Kaba ral sesleri ise kronik bronşit, bronşektazi ve aynı zamanda KOAH hastalarında duyulabilir [24].

Tablo 1: Normal Solunum Sesleri ve Özellikleri

Solunum Sesleri	Solunum Seslerinin Özellikleri	Klinik Korelasyon
Trekeal Ve Bronşial Solunum Sesleri	İnspiratuar-ekspiratuar (I:E) oranı 1:2 ila 1:3'tür. Bu solunum seslerinin ses frekansları 200 ila 2.000 Hz aralığındadır.	Trakeal nefes sesleri sert ve tiz olarak tanımlanır ve trakea üzerinden duyulabilir. Bronşiyal solunum sesleri yüksek ve tiz olarak tanımlanır ve trakeanın yanında duyulabilir.
Veziküler Solunum Sesleri	I:E oranı 3:1 ila 4:1'dir. Bu normal nefes seslerinin ses frekans dağılımı 200 ila 600 Hz'dir.	Trakeal ve bronşiyal seslerden daha az duyulur.
Bronkoveziküler Solunum Sesleri	Perdeleri ve süreleri veziküler nefes sesleri ile bronşiyal seslerinkinin tam ortasındadır; I:E 1:1 oranı ile eşittir	Bronkoveziküler solunum sesleri merkezi büyük hava yollarının önünde ve arkasında duyulur.

Tablo 2: Ek Sesler ve Özellikleri

<b>Ek Solunum Sesleri</b>	<b>Ek Seslerin Özellikleri</b>	<b>Alakalı Oldukları Hastalıklar ve Durumlar</b>
<b>Stridor</b>	Tiz, müzikal bir sestir. Ses analizinde, genellikle birkaç harmonik eşliğinde, yaklaşık 500 Hz'lik bir temel frekansa sahip düzenli, sinüzoidal salınımlar ile karakterize edilir.	Yetişkinlerde stridorun nedenleri arasında akut epiglottit, cihazın çıkarılmasından sonra hava yolu ödemi, anafilaksi, ses teli disfonksiyonu, yabancı cisim inhalasyonu, laringeal tümörler, tiroidit ve trakeal karsinom bulunur
<b>Hırıltı (Wheeze)</b>	Tipik olarak 100 milisaniyeden uzun sürer. 100 ila 1000 Hz aralığında ses enerjisine ve ara sıra 1000 Hz'yi aşan harmoniklere sahip sinüzoidal salınımlar olarak görünür	Astım ve KOAH'ta, göğüsün her tarafında hırıltı duyulabilir. Lokalize hırıltı, genellikle bir yabancı cisim, mukus tıkaçı veya tümör tarafından tıkanma ile ilişkilidir
<b>İnce ral (Fine Crackle)</b>	İnce raller 5 milisaniye süreli, 100-2000 Hz civarında frekansa sahip seslerdir.	Zatürre, konjestif kalp yetmezliği ve akciğer fibrozu ile ilişkilidir
<b>Kaba ral (Coarse Crackle)</b>	Kaba raller ise 15 ms süreli ve 100-2000 Hz civarı frekansa sahip olan seslerdir	Kronik bronşit, bronşektazi ve aynı zamanda KOAH hastalarında duyulabilir
<b>Ciyaklama (Squawk)</b>	Ciyaklama, inspiratuar fazda duyulabilen ek seslerdir. Ses, hem sürekli hem de sürekli olmayan bir karışımıdır	Distal hava yollarını etkileyen durumlarla ilişkili.

### 1.3. PNÖMONİ (ZATÜRRE)

Rene Theophile-Hyacinthe Laennec (1781–1826) pnömoni hakkında arařtırmalar yapmıř ve 1819’da pnömoni tanısı koymak için stetoskop kullanımının uygun olduđunu bildirmiřtir. Pnömoni ve diđer solunum yolu hastalıklarının tanısında ıslak raller, boř nefes alma, pectoriloquy ve aegophony tanımlamıřtır. Pnömoniyi, akciđer dokusundan ziyade plevral membranların iltihabı olarak tanıdıđı plöreziden ayırmaya alıřmıřtır. Laennec’in parlak tanımları akciđer hastalıklarına yaklařımda ve ayrıca i hastalık iin fizik muayene kavramlarının geliřtirilmesinde ok etkili olmuřtur. Modern pnömoni kavramı Laennec’in aıklamaları sayesinde bugünkü anlamını kazanmıřtır [25].

Pnömoni anlayıřındaki geliřmeler 19. Yüzyılın ortalarında devam etmiřtir. Josef Skoda (1805-1881) mükemmel bir teřhis uzmanıydı ve 1839’da perküsyon ve oskültasyon üzerine bir incelemede Auenbrugger ve Laennec’in gözlemlerini iletmiř ve pnömoni ve perikardiyal efüzyon (skodaik rezonans) ile duyulan davul benzeri sesi tanımlamıřtır. Thomas Addison (1793 – 1860), 1843’te pnömoni üzerine bir inceleme olan, “Pnömoni Üzerine Gözlemler”i yazmıř ve pnömoninin parankimden ziyade akciđerlerin hava hücrelerinden kaynaklandıđını kaydetmiřtir. Carl von Rokitansky (1804 – 1897) 1849’da lobar pnömoniyi bronkopnömoniden ayırt etmiřtir [25].

Pnömoninin tanımına bakılacak olursa, pnömoni bir mikroorganizmanın akciđerlere ulařması ve burada ođalması sonucunda akciđerlerde oluřan yangısal bir süreçtir. Akciđerler, sađlıklı bir insan nefes aldıđında havayla dolan alveol adı verilen küçük keselerden oluřur. Bir kiři pnömoniyeye sahip olduđunda, alveoller, nefes almayı ađrılı hale getiren ve oksijen alımını sınırlayan irin ve sıvı ile doldurulur. Ayrıca pnömoninin geliřmesi iin akciđer ve bađıřıklık sisteminde de bazı durumların olması gereklidir. Bunlar akciđerin temizleme mekanizması olan öksürük refleksinin, mukosliyer klirensin (burun akıntı mekanizması), alveolar makrofajların ve bađıřıklık sisteminin düzgün alıřmaması gibi sebeplerdir. Pnömonide alveoller iltihap ile dolarken bronřlar aık kalmaktadır. Bu yüzden solunum yollarında oluřan sesler, alveollerde filtrasyona veya kırılmaya maruz kalmadan toraks duvarına ulařır. Santral bronřlar ile toraks duvarı arasındaki akciđer parankiminin tümüyle konsolide olduđu olgularda tüber suflı duyulabilir.

Peribronşiyal bölgelerde oluşan ödem, hücre infiltrasyonu vb sebeplerden dolayı periferik hava yolları ekspiryum sonunda kapanır ve inspiryumun sonuna doğru yeniden açılırlar. Bunun sonucunda ral sesleri duyulur.

Dünya genelinde, çocuklarda görülen en ölümcül bulaşıcı hastalık pnömonidir. Bu hastalık, 2017 yılında 5 yaş altı 808.694 çocuğun ölümüne sebep olmuş ve beş yaşın altındaki tüm ölümlerin %15'ini oluşturmuştur. Pnömoniye virüsler, bakteriler ve mantarlar dahil olmak üzere bir dizi enfeksiyöz ajan neden olur. En yaygın olanları şunlardır [26]:

- Streptococcus pnömoni: Çocuklarda bakteriyel pnömoninin en yaygın nedeni
- Haemophilus influenzae tip b (Hib): Bakteriyel pnömoninin ikinci en yaygın nedeni
- Solunum sinsityal virüsü: Pnömoninin en yaygın viral nedenidir
- Pneumocystis jiroveci: HIV ile enfekte bebeklerdeki tüm zatürre ölümlerinin en az dörtte birinden sorumlu olan en yaygın pnömoni nedenlerinden biridir.

#### 1.4. STETOSKOP

Stetoskop, vücut içinde oluşan sesleri dinlemek amacıyla kullanılan tıbbi bir cihazdır. Genel olarak üç ana kısımdan oluşur:

- Diyafram
- Tüp (elastik boru şeklinde)
- Kulaklık

Bazı stetoskoplarda çan adı verilen bir kısım daha bulunur. Çan, alçak perdeden sesleri yükseltmeye yaramaktadır. Diyafram, stetoskobun tüp kısmının ucunda bulunur. Dinlenmek istenen vücut bölgesine temas ettirilen yassı koni şeklinde bir parçadır. Bu parçanın içinde bulunan zar, ortamdaki yalıtılmıştır. Yüzeydeki sesle titreten zar konik parça içindeki havaya basınç uygular ve bu basınç tüp içinden kulaklığa kadar ulaşır. Uygun yapıdaki kulaklık parçaları, sesin kulak içinde yayılmasını sağlar. Basit bir mantıkla çalışan stetoskop, bir nevi mekanik yükselticidir. Stetoskop ile kalp, akciğerler, bağırsak ve mide sesleri dinlenilebilir [27].

Steteskop, tüm doktorların kullandığı ortak bir alettir. Stetoskop kelimesi, Yunanca göğüs anlamına gelen stethos ve keşfetmek anlamına gelen skopein kelimelerinden gelmektedir. Mucidi Doktor Rene Theophile Hyacinthe Laennec'dir.

Oskültasyon kulağı göğse dayayarak yapılmaktaydı ve Laennec kadınları bu şekilde muayene etmekten rahatsız olmuştur. Bu yüzden farklı bir yol deneyerek, bir kâğıdı sıkıca sarıp bir ucunu hastanın göğsüne diğerini kulağına dayayarak oskültasyon yapmayı denemiştir. Bu şekilde hem hastayla daha mesafeli olabiliyor hem de sesleri daha net duyabilmiştir. Laennec, kalp seslerinin de doğrudan oskültasyon yerine aracılı oskültasyon kullanılarak daha net ve yüksek sesle duyulabileceğini keşfetmiştir. Laennec sonraki 3 yılını tüp yapmak için çeşitli materyal türlerini test ederek, tasarımını mükemmelleştirerek ve pnömoni hastalarının göğüs bulgularını dinleyerek geçirmiştir. Dikkatli deneylerden sonra Laennec, modern stetoskopun öncüsü olan 3,5 cm çapında ve 25 cm uzunluğunda Şekil 5'te görüldüğü gibi içi boş bir ahşap boruya karar vermiştir. Alet, kalbi dinlemek ve portatif hale getirmek için demonte edilebilir parçalar halinde yapılmıştır. Laennec, icadıyla kalp ve akciğerlerin çıkardığı sesleri araştırmış ve teşhislerinin otoposilerde yaptığı gözlemlerle desteklendiğini bulmuştur. 1819'da, 38 yaşında "De l'auscultation médiante ou Traité du Diagnostic des Maladies des Poumon et du Coeur" başlıklı vücut seslerini dinlemenin kullanımına ilişkin ilk çığır açan çalışmayı yayınlamıştır [28] [29].



Şekil 5. (a) Laënnec'in stetoskopu: 1) alet montajı; 2) ve 3) uzunlamasına kesitte aletin iki kısmı; 4) ayrılabilir göğüs parçası; 5) kulak parçası sökümü; 6) enine kesit. (b) Laennec ve stetoskopu. Resim Robert A. Thom(1915-1979) [33].

Stetoskopun icadından sonra hızla gelişmeye başladı. Bugün kullanılan klasik stetoskop, Harvard Tıp Okulu profesörü, seçkin kardiyolog ve elektrokardiyografide otorite olarak tanınan Dr. David Littmann tarafından tasarlandı. Günümüzde en yaygın kullanılan 3M Littmann stetoskoplarıdır. Klasik stetoskopun ardından da elektronik stetoskoplar kullanılmaya başlanmıştır. Sesler vücut üzerinden mikrofonlar sayesinde alınmaktadır. Alınan seslerin içinden, ortam gürültüsü, kas sesi, sürtünme gibi istenmeyen sesler otomatik olarak filtrelenmekte ve sayısal hale getirilmektedir.



Şekil 6. Littmann Klasik Stetoskop (sol), Littmann elektronik stetoskop(sağ)

Elde edilen sayısal veriler mikroişlemciler yardımıyla kaydedilebilmekte ve istenirse bilgisayar üzerinden görüntülenebilmektedir.



## 1.5. AKCİĞER SESLERİNİN FİLTRELENMESİ

Solunum seslerinin yaygın olarak kullanıldığı bant aralığı göğüs üzerinden kaydedildiğinde (akciğer sesleri) 60-100 Hz ile 2 kHz aralığında ve soluk borusu üzerinden kaydedildiğinde 60-100 Hz ile 4 kHz aralığında bulunmaktadır. Ek sesler ise 60-100 Hz ile 6 kHz frekans aralığındadır. [30].

Elektronik stetoskop ile akciğer sesleri kaydedilirken gürültüler de kaydedilebilir. Örneğin kalp sesleri, konuşma sesleri, çevreden gelen gürültüler gibi. Bu istenmeyen sesleri yok etmenin en etkili yolu filtre uygulaması yapmaktır. Akciğer seslerine alçak geçiren filtre uygulayarak aliasing azaltılırken yüksek geçiren filtre uygulayarak kalp sesi, sürtünme ve kas sesleri azaltılabilir. Bu iki filtrenin birlikte uygulanmasına izin veren bantgeçiren filtrelerdir. Bu çalışmada üç farklı bantgeçiren filtre tasarlanmıştır:

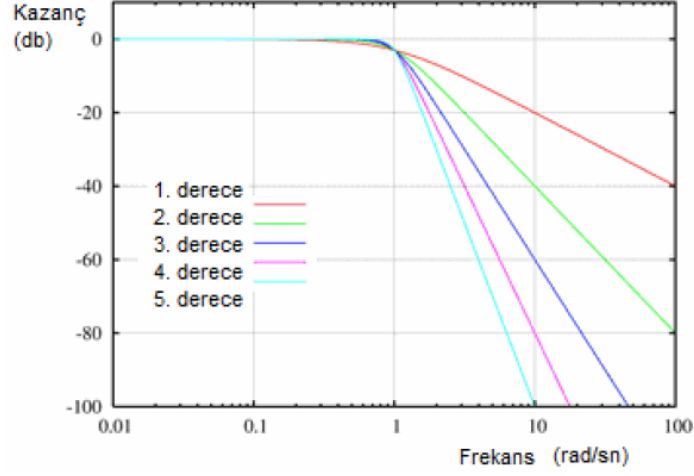
- Butterworth Bantgeçiren Filtre
- Chebyshev Bantgeçiren Filtre
- Eliptik Bantgeçiren Filtre

Tasarlanan filtreler 10. Dereceden bantgeçiren filtrelerdir, 1 dB dalgalanmaya sahiptir. Kesim frekansları tezin amacına uygun olarak 100 Hz ile 2 kHz aralığında seçilmiştir. Bantgeçiren filtre uygulamasından sonra da Dalgacık Dönüşümü tabanlı gürültü giderme tekniği uygulanmıştır.

### 1.5.1. Butterworth Bantgeçiren Filtre

Butterworth standart filtre çeşitleri içerisinde en düz geçiş bandına sahip olan ve dalgalanmanın neredeyse hiç olmadığı bir filtre cevabıdır. Bu sebeple maksimum düzlüklü filtre cevabı olarak da anılır [31].

Butterworth süzgeç diğer süzgeçlerden farklı olarak, filtre derecesi arttığında durma bandındaki sert düşüş dışında frekans genlik eğrisinde şeklini korur. Butterworth filtre, Chebyshev ve Eliptik filtrelere göre daha geniş geçiş bölgesine (transition region) sahiptir bu nedenle durma bandı özelliklerinin doğru olarak uygulanabilmesi için yüksek derecelere ihtiyaç duyar. Chebyshev ve Eliptik filtrelere göre daha doğrusal bir frekans tepkisine sahiptir [32]. Butterworth fitrenin değişik filtre dereceleri için kazanç-frekans gösterimi Şekil 7'dedir. Filtrenin derecesi arttığında geçiş bandı kısalmaktadır.



Şekil 7. Değişen derecelere göre kazanç frekans grafiği[32]

### 1.5.2. Chebyshev Bantgeçiren Filtre

Geçirme bandı Butterworth filtreye göre daha dardır ve geçirme (veya durdurma) bandında dalgalıklar vardır. Chebyshev filtre, dalgalıklar dışında bu özelliği sayesinde ideal filtreye daha yakındır. Eğer filtrede bulunan dalgalıklar geçirme bandında ise bu Chebyshev 1. Tipi filtredir. Eğer dalgalıklar durdurma bandında ise Chebyshev 2. Tip filtredir. Eğer dalgalıklar her iki bantta da bulunuyorsa ortaya çıkan filtreye Eliptik filtre denir [32].

### 1.5.3. Eliptik Bantgeçiren Filtre (Cauer Filtre)


Eliptik filtre, geçirme ve durma bandında sayıları birbirinden bağımsız olarak değiştirilebilen, eş dalgalıklar barındıran bir elektronik süzgeç çeşididir. Aynı dereceden başka bir süzgece göre geçiş bölgesi daha kısadır [32].

#### **1.5.4. Dalgacık Dönüşümü (Wavelet Transform) Tabanlı Gürültü Giderme**

Akciğer seslerindeki gürültünün giderilmesi ile akciğer hastalıklarının teşhisi kolaylaşmaktadır. Gürültülerin giderilmesi amacıyla tasarlanan bantgeçiren filtreler yeterli olamamaktadır bu nedenle “Dalgacık Tabanlı” gürültü giderme tekniği kullanılmıştır. Bunun için Matlab programı yardımıyla filtrelenmiş akciğer seslerinin dalgacık dönüşümü alınmıştır. Ardından dalgacık katsayılarının doğrusal olmayan daraltımı gerçekleştirilmiştir. Bunun için Stein’s Unbiased Risk Estimate (SURE) yöntemi kullanılmıştır. SURE yöntemi, deneysel dalgacık katsayılarını eşikleyerek gürültüyü yok etmektedir. Bu yöntem hataları bulmak için ortalama karesel hata fonksiyonunu kullanır ve gürültü giderme işleminde optimum daraltma faktörünü belirlemek için kullanılır [33]

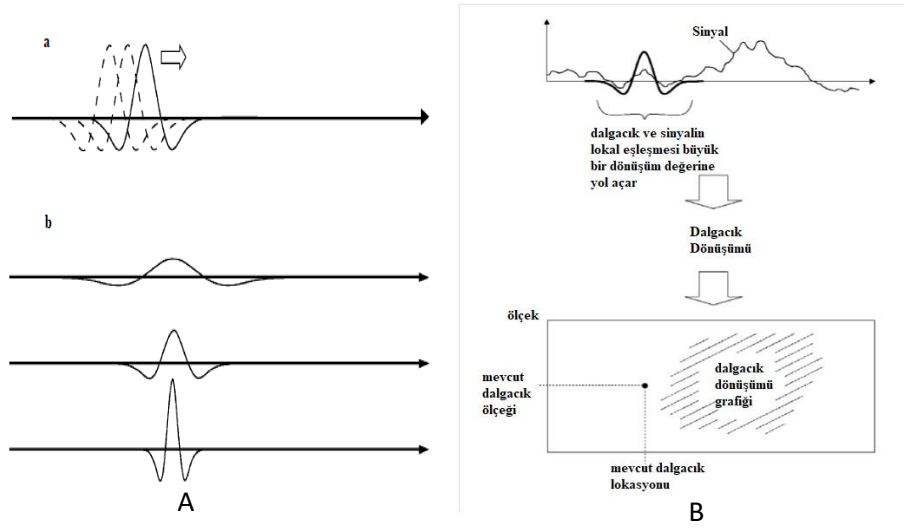
##### **1.5.4.1. Dalgacık Dönüşümü Nedir**

Dalgacık dönüşümünün (WT), en iyi periyodik olmayan, gürültülü, aralıklı, geçici vb. olarak tanımlanabilecek sinyalleri analiz etmek için özellikle yararlı olduğu bulunmuştur. Sinyali, geleneksel kısa süreli Fourier dönüşümünden (STFT) farklı bir şekilde hem zaman hem de frekansta aynı anda incelemesi sayesinde, sinyal işleme ve sorgulama için bir dizi karmaşık dalgacık tabanlı yöntem üretmiştir. Dalgacık dönüşümü analizi, iklim analizinden finansal endekslerin analizine, kalp izlemeden dönen makinelerin durum izlemesine, sismik sinyal gidermeden astronomik görüntülerin gürültüsünü gidermeye, video görüntü sıkıştırmasından tıbbi sinyal kayıtlarının sıkıştırılmasına kadar çok sayıda farklı fiziksel olgunun araştırılmasında uygulanmaktadır. Dalgacık dönüşümü analizi, dalgacıklar olarak bilinen küçük dalga benzeri fonksiyonları kullanmaktadır. Aslında ‘yerel’ dalga benzeri fonksiyon, bir dalgacığın daha doğru bir tanımıdır. Şekil 8’de uygulamada yaygın olarak kullanılan birkaç dalgacık örneğini göstermektedir.



Şekil 8. Bazı dalgacıkların görünümü

Dalgacıklar, incelenen sinyali, sinyal bilgisini daha kullanışlı bir biçimde sunan başka bir gösterime dönüştürmek için kullanılmaktadır. Sinyalin bu dönüşümü dalgacık dönüşümü olarak bilinmektedir. Matematiksel olarak konuşulursa, dalgacık dönüşümü sinyal ile dalgacık fonksiyonunun bir evrişimi (konvolüsyon) dir. Dalgacık iki şekilde manipüle edilebilir: sinyal üzerinde çeşitli konumlara taşınabilir (şekil 9A (a)) ve gerilebilir veya sıkıştırılabilir (şekil 9A (b)). Şekil 9B, temel olarak dalgacığın sinyalle lokal eşleşmesini nicelleştiren dalgacık dönüşümünün bir şemasını göstermektedir.



Şekil 9. (A) Dalgacık Özellikleri (B) Dalgacık, sinyal ve dönüşüm

Dalgacık, Şekil 9B 'nin en üst grafiğinde olduğu gibi, belirli bir ölçekte ve konumda sinyalin şekliyle iyi eşleşirse, büyük bir dönüşüm değeri elde edilmektedir. Bununla birlikte, dalgacık ve sinyal arasında iyi bir korelasyon yoksa, dönüşümün düşük bir değeri elde edilir. Dönüştürme değeri daha sonra Şekil 9B 'nin alt kısmında gösterilen (siyah nokta ile gösterilen) iki boyutlu dönüştürme düzleminde bulunmaktadır. Dönüşüm, sinyalin çeşitli konumlarında ve dalgacığın çeşitli ölçekleri için hesaplanmakta, böylece dönüşüm düzlemi doldurulur: bu, sürekli dalgacık dönüşümü (CWT) için düzgün sürekli bir tarzda veya ayrık dalgacık dönüşümü için ayrık adımlarla yapılmaktadır (DWT). Dalgacık dönüşümünün çizilmesi, çeşitli ölçeklerde ve konumlarda dalgacık ile sinyal arasındaki korelasyonun bir resminin oluşturulmasına izin vermektedir [34].

#### 1.5.4.2. Ayrık Dalgacık Dönüşümü (DWT)

Ayrık Dalgacık Dönüşümü (DWT), Mallat tarafından filtreler kullanılarak geliştirilmiştir. Sürekli Dalgacık Dönüşümde hesap yükü çok fazladır bu nedenle hesap yükünü azaltmak amacıyla Ayrık Dalgacık Dönüşümü kullanılır. Temel düşünce, sürekli dalgacık dönüşümüyle aynıdır. Sayısal filtreleme teknikleri

kullanılarak sayısal işaretin zaman-ölçek temsili elde edilmektedir. Sürekli Dalgacık Dönüşümü, farklı ölçeklerdeki dalgacık ile işaret arasındaki ilişkiyi (korelasyonu) belirtmektedir. Burada benzerlik ölçütü ölçek ya da frekanstır. Ayrık Dalgacık Dönüşümü formülü aşağıda verilmiştir:

$$\Psi_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} \Psi\left(\frac{t-nb_0a_0^m}{a_0^m}\right) \quad (1.1)$$

Sürekli Dalgacık Dönüşümü'ne bağlı olarak, ölçekleme parametresi  $a$ ,  $a = a_0^m$  şeklinde ayrıştırılır ve zamanda öteleme bu ölçeklendirme parametresi ile orantılı olarak gerçekleştirilerek ( $b = nb_0a_0^m$ ) ile elde edilir. Burada:

T: Zaman ifadesi

m: Dalgacık genişlemesini kontrol eder

n: Dalgacık ötelenmesini kontrol eder

$a_0$ : 1'den büyük bir değere ayarlanmış belirli bir sabit genişleme adımı parametresidir

$b_0$ : Sıfırdan büyük olması gereken konum parametresidir [34].

Alçak frekansları analiz eden geniş pencereler büyük adımlarla ( $b = nb_0a_0^m$ ) ve yüksek frekansları analiz eden dar pencereler, işaretteki hızlı değişimleri yakalamak için küçük adımlarla ötelenmiş olur. Ayrık dalgacık fonksiyonları yalnızca ayrık adımlarla ölçeklendirilebilir ve ötelenebilirler. Ayrık dalgacık olarak isimlendirilmelerine karşın aslında parçalı sürekli fonksiyonlardır. M ve n, tamsayı olup,  $a_0$  ise  $a_0 > 1$  aralığında olmak şartıyla sabit genişleme adımıdır. Genelde  $a_0 = 2$ ,  $b_0 = 1$  olarak alınır (ikici (dyadic) zaman örnekleme).

Buna göre Ayrık Dalgacık Dönüşümü formülü yeniden düzenlenirse:

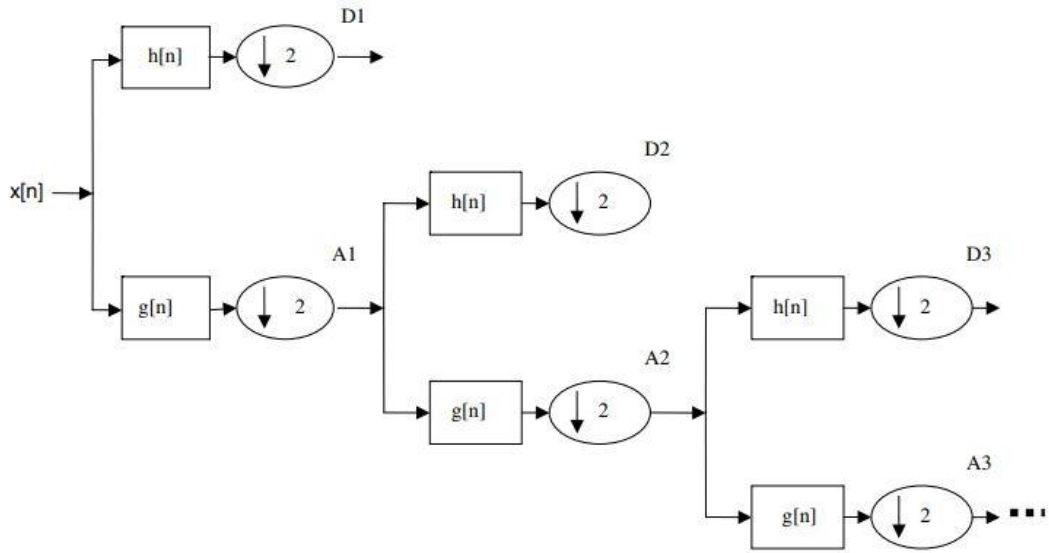
$$T_{m,n} = \int_{-\infty}^{\infty} x(t) \frac{1}{a_0^{m/2}} \Psi\left(\frac{t-nb_0a_0^m}{a_0^m}\right) dt \quad (1.2)$$

İkinci zaman-ölçek uzayına göre yazılırsa:

$$T_{m,n} = \int_{-\infty}^{\infty} x(t) \frac{1}{2^{m/2}} \Psi\left(\frac{t-n2^m}{2^m}\right) dt \quad (1.3)$$

Burada  $m$  ölçek parametresini belirtirken,  $n$  ise öteleme parametresini ifade etmektedir [35],[36].


İşaretteki yüksek frekansları analiz etmek için yüksek geçiren filtreler, alçak frekansları analiz etmek için ise alçak geçiren filtreler kullanılır. Alçak geçiren filtre çıkışındaki işaretin alt örneklemeyle elde edilen işaret, yaklaşıklık katsayıları (approximations=A) olarak adlandırılır. Yüksek geçiren filtre çıkışındaki işaretin alt-örneklemeyle elde edilen işaret ise ayrıntı katsayıları (details=D) olarak adlandırılır. Ayrık Dalgacık Dönüşümü işlemi uygulanmış  $X$  sinyali Şekil 12’de görüldüğü gibi eşit sayıda alt frekans bileşenine yani yaklaşımlara (A) ve yüksek frekans bileşenine yani detaylara (D) ayrıştırılmaktadır [37].



Şekil 10. Ayrık Dalgacık Dönüşümü alt bantları;  $h[n]$  yüksek geçiren filtre,  $g[n]$  alçak geçiren filtre [38]

Dalgacık dönüşümünde en önemli etken dalgacıktır. Fourier dönüşümündeki pencere fonksiyonunun yaptığı işi, dalgacık dönüşümünde ana dalgacık fonksiyonları yapar. Dalgacık, küçük dalga anlamında kullanılmaktadır. Buradaki küçüklük belirli bir uzunluktaki pencere fonksiyonu olarak adlandırılabilir. Ana kelimesinden kasıt ise bir ana fonksiyondan dönüşüm tekniği ile türetilen ve değişik alanlarda destek sağlamak için oluşturulan fonksiyonlardır [39]. Genel olarak kullanılan beş farklı ana dalgacık tipi Şekil 11’de gösterilmiştir ve isimleri şunlardır:

- Haar
- Meyer
- Morlet
- Daubechies-4
- Meksika şapkası



Şekil 11. Temel Dalgacık Şekilleri

İşaret ile ana dalgacık ne kadar benzerse çıkış o kadar büyük olur. Bu nedenle işaret ile ana dalgacığın benzerliği çok önemlidir. Bu çalışmada Daubechies-7 dalgacık kullanılmıştır.

#### 1.6. ÖZNETELİK ÇIKARIM YÖNTEMLERİ

Öznitelik çıkarma işleminde, Discrete wavelet transform sonucunda elde edilen alt bantlardan 200-2000 Hz frekans aralığındakiler seçilmiştir. Akciğer seslerinin sınıflandırılmasında her bir alt bandın mutlak maksimum değeri, standart sapması, varyansı ve komşu alt bantların mutlak değerlerinin ortalamasının oranı kullanılmıştır. Komşu alt bantların oranı için her alt bandın mutlak değerinin ortalaması alınmış ve bu alt bantların her biri kendisine komşu olan alt banda bölünerek öznitelikler elde edilmiştir [40]. Ayrıca sadece filtrelenmiş olan verinin, güç spektrum yoğunluğu (PSD) değeri bulunarak bunun en küçük, en büyük, entropi, enerji, standart sapma, ortalama, eğrilik, basıklık ve enerji değerleri özniteliklere eklenmiştir.

- 1) Standart sapma: Dağılımdaki her bir değer in ortalamaya göre ne uzaklıkta olduğunu, diğer bir deyişle dağılımın ne yaygınlıkta olduğunu gösteren bir ölçüdür. Standart sapmanın büyük olması veri noktalarının ortalamadan daha uzak yayıldıklarını; küçük bir standart sapma ise



ortalama etrafında daha yakın gruplaştıklarını gösterir. A bir vektör veya matris, N ise eleman sayısıdır.  $\mu$  A'nın ortalama değeridir [41].

$$s = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2}$$

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i$$

- 2) Varyans: Bir dizi sayının ne kadar uzaklıkta dağıldığını gösterir. Varyans standart sapmanın karesine eşittir [42].

$$V = \frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2$$

- 3) Çarpıklık: Örnek ortalama etrafındaki verilerin asimetrisinin bir ölçüsüdür. Çarpıklık negatifse, veriler sağdan ziyade ortalamının soluna yayılır. Çarpıklık pozitifse, veriler daha çok sağa doğru yayılır. Normal dağılımın (veya herhangi bir mükemmel simetrik dağılımın) çarpıklığı sıfırdır. Burada  $\mu$ , x (Veri) 'in ortalamasıdır,  $\sigma$ , x'in standart sapmasıdır ve E(t), t miktarının beklenen değerini temsil eder.

$$s = \frac{E(x - \mu)^3}{\sigma^3}$$

- 4) Basıklık: Bir dağılımın ne kadar aykırı değere meyilli olduğunun bir ölçüsüdür. Normal dağılımın basıklığı 3'tür. Normal dağılıma göre aykırı değere daha yatkın olan dağılımların basıklığı 3'ten büyüktür; Daha az uç değere eğilimli dağılımlar 3'ten daha az basıklığa sahiptir. Bazı basıklık tanımları, hesaplanan değerden 3 çıkarır, böylece normal dağılımın basıklığı 0 olur. Basıklık işlevi bu kuralı kullanmaz.

$$k = \frac{E(x - \mu)^4}{\sigma^4}$$

5) Ortalama Karekök (RMS): Bir  $x$  vektörünün ortalama karekök değeri, belirtilen boyut boyunca gerçekleştirilen toplamadır. Genlik ile değişken bir akım veya gerilimin büyüklüğü ifade edilebilir. Fakat, genlik akım veya gerilimin tepe değerini verir. Bazen, ortalama değeri bilmek daha faydalıdır ancak basit bir şekilde tüm değerlerin ortalamasını almak fayda vermez bu nedenle RMS değeri kullanılır.

$$x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_n|^2}$$

## İKİNCİ BÖLÜM

### 2. MAKİNE ÖĞRENMESİ ALGORİTMALARI

#### 2.1. Destek Vektör Makineleri (DVM)

Destek Vektör Makineleri (DVM), büyük veri sınıflandırma problemlerini çözmeye yardımcı olabilecek klasik makine öğrenme tekniklerinden biridir. Özellikle büyük veri ortamında çok alanlı uygulamalara yardımcı olabilir. Bununla birlikte, destek vektör makinesi matematiksel olarak karmaşık ve hesaplama açısından pahalıdır. Üç farklı çeşidi bulunmaktadır: (1) bir doğrusal (lineer) destek vektör makinesinin modellenmesi; (2) doğrusal (lineer) olmayan bir destek vektör makinesinin modellenmesi ve (3) Lagrange destek vektör makinesi algoritması ve uygulamaları. Bu tezde sadece lineer ve lineer olmayan destek vektör makineleri ele alınmıştır.

#### 2.1.1. Doğrusal (Lineer) Destek Vektör Makinesi

Destek vektör makinesi doğrusal ve doğrusal olmayan modellere ayrılabilir. Veri alanı, orijinal alandaki sınıfları ayırmak için doğrusal olarak bölünebiliyorsa (örneğin, düz çizgi veya hiperdüzlem) doğrusal destek vektör makinesi olarak adlandırılır. Veri alanı doğrusal olarak bölünemiyorsa ve veri alanının sınıfları ayırmak için doğrusal olarak bölünebildiği özellik alanı adı verilen bir alana dönüştürülebiliyorsa, doğrusal olmayan destek vektör makinesi olarak adlandırılır.

Doğrusal destek vektör makinesinde veri alanının bir yanıt kümesine eşlenmesi ve veri alanının bölünmesi gerçekleştirilir. Doğrusal olmayan destek vektör makinelerinde ise bir kernel fonksiyonu kullanılarak veri alanının bir özellik uzayına eşlenmesi, özellik uzayı alanının yanıt kümesine eşlenmesi ve ardından veri alanının bölünmesi gerçekleştirilir. Dolayısıyla matematiksel olarak, doğrusal bir destek vektörü makinesinin modellemesinin  $y = wx' + \gamma$  doğrusal denklemini benimsediğini ve doğrusal olmayan bir destek vektörü makinesinin modellemesinin doğrusal olmayan  $y = w\phi(x') + \gamma$  denklemini benimsediği söyleyebilmektedir. Denklemdaki ifadelerin anlamları aşağıda sıralanmıştır:

w: çoklu düzlemin normali (ağırlık vektörü)

x: veri noktası


y: veri noktasının sınıfı

$\gamma$  :bias


$\phi$ : kernel fonksiyonu

Kernel fonksiyonu onu doğrusal olmayan hale getirmektedir. Bir destek vektör makinesi kullanan sınıflandırma tekniği, parametrelendirme ve optimizasyon hedeflerini içermektedir. Bu hedefler temel olarak veri alanındaki topolojik sınıf yapısına bağlıdır. Yani, sınıflar lineer olarak ayrılabilir veya lineer olarak ayrılamaz olabilir. Bununla birlikte, doğrusal olarak ayrılabilir sınıflar, doğrusal olmayan bir şekilde ayrılabilir olabilir. Bu nedenle, veri alanına odaklanan parametreleştirme ve optimizasyon hedefleri bu sınıf özelliklerini dikkate almalıdır.

Lineer olarak ayrılabilenler;



Lineer olarak ayrılamayanlar;



Şekil 12. Lineer olarak ayrılabilen ve ayrılmayan destek vektör makineleri

#### 2.1.1.1. Doğrusal Sınıflandırıcı: Ayrılabilir Doğrusal

Bu bölümde, yalnızca destek vektör makineleri öğrenimi modellerini kullanan ikili sınıflandırmaya odaklanılmıştır. Önce lineer durum ele alınırsa, destek vektör makinesi için aşağıdaki gibi bir düz çizgi denklemi kullanılmaktadır:

$$w\mathbf{x}' + \gamma = 0 \quad (2.1)$$

Bir veri alanı göz önüne alındığında, bu parametrelili düz çizgi, veri alanını iki alt alana böler ve bunlar sol alt alan ve sağ alt alan olarak adlandırılabilir. Bunları D1 ve D2 ile ifade edilebilir ve aşağıdaki gibi tanımlanabilir:

$$D1 = \{\mathbf{x} : w\mathbf{x}' + \gamma \leq 0\} \quad (2.2)$$

$$D2 = \{\mathbf{x} : w\mathbf{x}' + \gamma > 0\} \quad (2.3)$$

Bu alt alanlara düşen noktalar, D1 alt alanı için 1 ve D2 alt alanı için -1 etiketleri ile ayırt edilebilir. Bu nedenle, destek vektör makinesinin parametreleştirme amacı aşağıdaki gibi tanımlanabilir:

$$w\mathbf{x}' + \gamma = 1, \quad \mathbf{x} \in D1 \quad (2.4)$$

$$w\mathbf{x}' + \gamma = -1, \quad \mathbf{x} \in D2 \quad (2.5)$$

Parametreleştirme hedeflerinde, sınıflar arasındaki sınırları tanımlamaya yardımcı olabilecek iki düz çizgi (veya hiper düzlem) modellenir. Optimizasyon amacı, bir amaç fonksiyonu (bu durumda, düz çizgiler arasındaki mesafe) tanımlamak ve mesafeyi maksimize eden parametre değerlerini aramaktır. Bu çizgiler birbirine paraleldir; bu nedenle, iki paralel çizgi  $y = mx+b_1$  ve  $y = mx+b_2$  arasındaki standart uzaklık formülü aşağıdaki gibi kullanılabilir:

$$d = \frac{b_2 - b_1}{\sqrt{m^2 + 1}} \quad (2.6)$$

burada düz çizgilerin eğimleri  $m = w$  ve kesişmeleri  $b_1 = \gamma + 1$  ve  $b_2 = \gamma - 1$ 'dir. Bu değişkenleri değiştirerek aşağıdakiler kurulabilir:

$$d = \frac{\mp 2}{\sqrt{ww' + 1}} \quad (2.7)$$

Sonuç olarak, bu uzaklık formülü oluşturulacak optimizasyon probleminin ölçüsü olacaktır; bu nedenle, genelliği kaybetmeden aşağıdaki gibi yeniden yazılabilir:

$$\mathbf{d} = \frac{\mp 2}{\sqrt{\mathbf{w}\mathbf{w}'}} \quad (2.8)$$

Uygulamada, destek vektörü makine optimizasyon problemi matematiksel norm gösterimi kullanılarak yazılır, bu nedenle yukarıdaki denklem aşağıdaki gibi yeniden yazılır:

$$\mathbf{d} = \frac{\mp 2}{\|\mathbf{w}\|^2} \quad (2.9)$$

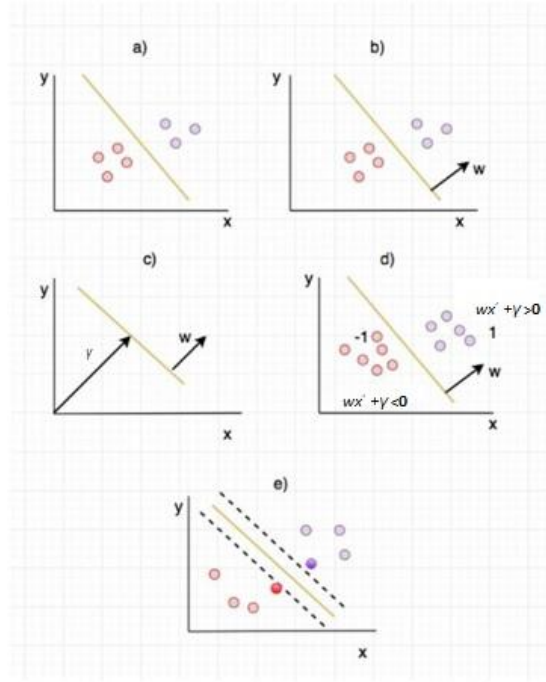
Denklem 9'un her iki tarafının karesi alınarak ve ardından denklemin her iki tarafı 2 değerine bölünerek aşağıdaki basit matematiksel ilişki elde edilir:

$$\frac{d^2}{2} = \frac{1}{\frac{\|\mathbf{w}\|^2}{2}} \quad (2.10)$$

Uzaklık fonksiyonu  $d^2/2$ 'yi maksimize etmek yerine  $\|\mathbf{w}\|^2/2$ 'yi minimize edilebileceğini belirtir. Başka bir deyişle, yukarıdaki sınıflandırıcıya göre tahmin hatası, aralarındaki mesafe en üst düzeye çıkarılırken en aza indirilebilir (bu, optimizasyon hedefidir). Bu nedenle,  $\mathbf{x} \in D$  ve yanıt değişkenleri  $\mathbf{y}$  arasındaki tahmin hatası için aşağıdaki matematiksel ifade tanımlanabilir:

$$\mathbf{e} = \mathbf{1} - \mathbf{y}(\mathbf{w}\mathbf{x}' + \gamma) \quad (2.11)$$

Bu hata fonksiyonu, destek vektör makinesi için bir optimizasyon probleminin geliştirilmesinde önemli bir rol oynar [43].



Şekil 13. Lineer ayrılabilir DVM [44]

### 2.1.1.2. Doğrusal Sınıflandırıcı: Ayrılmaz Doğrusal

Doğrusal ayrılmayan sınıflarda, eğitim verilerinin bir kısmının optimum hiper düzlemin diğer tarafında kalmasından dolayı meydana gelen problem pozitif bir yapay değişken ( $\zeta$ ) tanımlanması ile çözülür. Sınır maksimum hale getirilir. Yanlış sınıflandırma hatalarının minimum hale getirilmesi arasındaki denge, pozitif değerler alan ve  $C$  ile gösterilen bir düzenleme parametresi ( $0 < C < \infty$ ) tanımlanarak kontrol edilebilir.

### 2.1.2. Doğrusal (Lineer) Olmayan Destek Vektör Makinesi

Dağılım grafiklerinin, alan bölmelerini kolaylaştırarak sınıflandırmada önemli bir rol oynadığı görülmüştür. Dağılım grafiklerinde, boyut (yani her eksen) bir özellik tarafından tanımlanır ve özellik tarafından tanımlanan uzaya vektör uzayı denir. Dağılım grafiği, özellikler arasındaki ilişkiyi tanımlar ve böylece vektör uzayında ilişkili ve ilişkisiz veri noktaları tanımlanabilir. Sınıflandırma, ya bir vektör uzayında ya da bir özellik uzayında gerçekleştirilebilir; burada vektör uzayı, orijinal özelliklerin dağılım grafiğini içeren uzay olarak tanımlanır ve özellik uzayı, kernel

işlevleri kullanılarak dönüştürülen özelliklerin dağılım grafiğini içeren alan olarak tanımlanır.

#### 2.1.2.1. Özellik Uzayı

Özellik uzayının avantajı, vektör uzayındaki ayrılmaz sınıfların, doğru bir kernel seçimi kullanılarak ayrılabilir sınıflara dönüştürülebilmesidir. Ancak, bir kernel bulmak ve böyle bir dönüşüm oluşturmak kolay değildir.

$$\Phi : \mathbf{R}^p \rightarrow \mathbf{R}^d$$

burada  $\mathbf{R}^p$  vektör uzayıdır (orijinal etki alanı) ve  $\mathbf{R}^d$  yüksek boyutlu olan özellik uzayıdır (genellikle  $d \gg p$ ). Vektör uzayını, sınıfların lineer olarak ayrılabilir olduğu bir özellik uzayına dönüştürmeye yardımcı olan  $\phi$  bulmak mümkündür. Bu nedenle, özellik uzayındaki destek vektörü makine sınıflandırıcısı aşağıdaki gibi yazılabilir:

$$\text{Minimize } w, \gamma: \frac{\|w\|^2}{2}$$

$$\text{Karşılık gelir: } \mathbf{s}(w \phi(\mathbf{x}') + \gamma \mathbf{I}) \geq \mathbf{I}$$

Ancak,  $\phi(\mathbf{x})$  yüksek boyutludur, dolayısıyla hesaplama çok karmaşık hale gelir. Bu, kernel hilesi adı verilen bir yaklaşım kullanılarak çözülebilir [43].

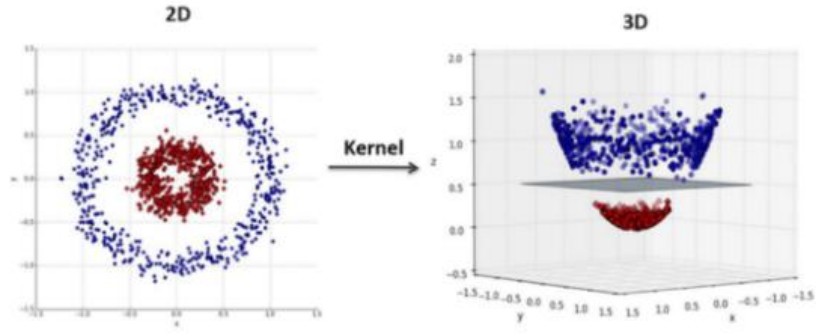
#### 2.1.2.2. Kernel Hilesi

Karmaşık veri setlerini sınıflandırırken düşük boyutlar yeterli olmayabilir. Eğer boyut sayısı arttırılırsa bu kez işlem yükü çok fazla olacaktır. İşte böyle durumlar için Kernel hilesi kullanılmaktadır. Eldeki koordinatlar belirli kernel fonksiyonları ile çarpılarak daha anlamlı hale getirilebilir. Bu amaç için en çok kullanılan kernel çeşitleri, Lineer kernel, Polinomial kernel ve Gauss RBF (Radyal Temel Fonksiyon) kerneldir.

#### Polinomial Kernel

Bu yöntemde problemi çözmek için 2 boyuttan çıkıp 3 veya daha fazlası boyutta işlem yapıyormuş gibi hareket edilir.



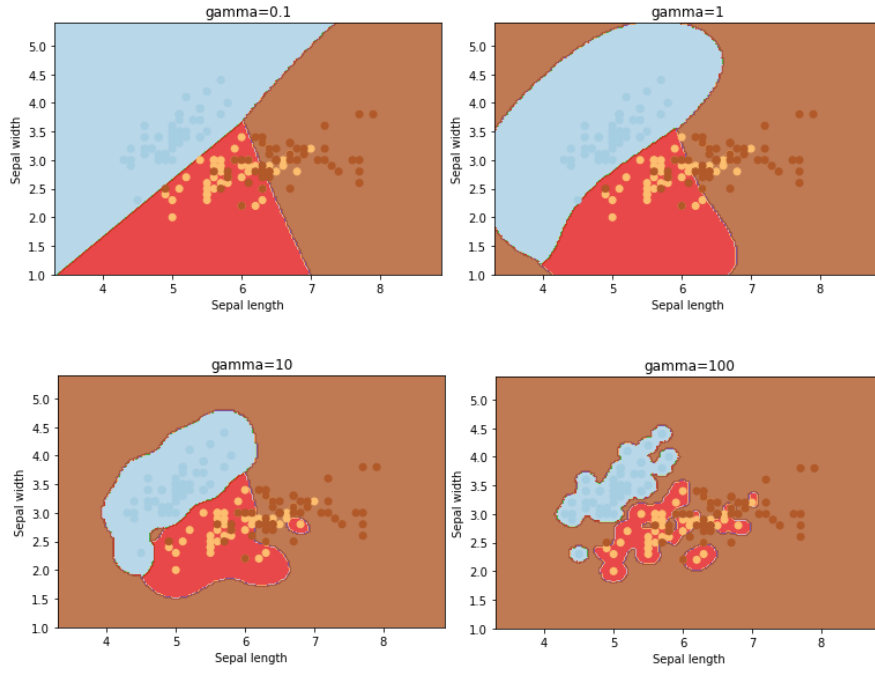


Şekil 14. Polinomiyal kernel örneđi

Şekil 14'te soldaki (2 boyut) dađılımı bir doğru ile sınıflandırmak mümkün deđildir. Bunun için bu gibi problemlerde Polinomiyal Kernel kullanılabilir. Üçüncü boyutta işlem yapılırken sınıflara ayırmak için doğru yerine bir düzlem kullanılır böylece çok daha düzgün bir şekilde sınıflandırma gerçekleştirilir.

#### Gauss RBF (Radyal Temel Fonksiyon) Kernel

Sonsuz boyuttaki DVM'lerini bulur ve her bir noktanın belirli bir noktaya ne kadar benzediđini normal dađılım ile hesaplar ve ona göre sınıflandırır. Dađılımın genişliđi gamma hiperparametresi ile kontrol edilir. Gamma ne kadar küçükse dađılım o kadar geniş olur [45].



Şekil 15. RBF kernel örneği


## 2.2. K-En Yakın Komşular (KNN)

Temel seviyelerinde, en yakın komşu yöntemleri çok basittir:  $y$  girdi vektörü ile yeni bir nesneyi sınıflandırmak için, basitçe  $y$ 'ye en yakın  $k$  eğitim veri set noktası incelenir ve nesne, bu  $k$  noktalarının çoğuna sahip olan sınıfa atanır. “Yakın” burada  $p$  – boyutlu girdi uzayı cinsinden tanımlanır. Bu nedenle, eğitim verilerinde girdi değişkenleri açısından yeni nesneye en çok benzeyen nesnelere aranır ve ardından yeni nesne bu en benzer nesnelere arasında en yoğun temsil edilen sınıfa dahil edilir.

Teorik olarak,  $x$  merkezli ve yarıçapı  $k$ . En yakın komşuya olan uzaklığı olan değişkenler uzayının küçük bir hacmi alınır. Daha sonra, bu küçük hacimdeki bir noktanın her sınıfa ait olma olasılığının maksimum olabilirlik tahmin edicileri, bu hacimdeki her sınıfa ait eğitim puanlarının oranı ile verilir. En yakın komşu yöntemi, tahmin edilen en büyük olasılığa sahip sınıfa yeni bir nokta atar [46].

Örneğin  $k = 3$  için yeni bir eleman sınıflandırılmak istensin. Bu durumda eski sınıflandırılmış elemanlardan en yakın üç tanesi alınır. Bu elemanlar hangi sınıfa

dahilse, yeni eleman da o sınıfa dahil edilir. Mesafe hesabından genelde öklit mesafesi (euclid distance) kullanılabilir.



Şekil 16. (a) Kırmızı yuvarlak ve mavi kare üyelerin bulunduğu uzay (b) Uzaya yeni üyenin eklenmesi (c) Yeni üyenin diğer üyelere göre mesafelerinin ölçülmesi ve sınıflandırılması

Yukarıdaki şekilde kırmızı yuvarlak ve mavi kare olarak ayrılan bir örnek uzayı bulunmaktadır. Bu uzaya yeni bir üye geldiğinde  $kNN$  algoritması ile sınıflandırma yapılmak isteniyor. Bu yeni gelen üyenin en yakın olduğu üç üye (3 nearest neighbors) tespit edilir.

En yakın üç üyenin iki tanesi kırmızı yuvarlak üyeler olduğuna göre yeni üyenin de kırmızı yuvarlak gruba ait olduğu söylenebilir [47].

Öklit ve diğer kullanılan uzaklık ölçüm formülleri şu şekildedir:

- $\sqrt{\sum_{i=1}^k (x_i - y_i)^2}$  Öklit Uzaklığı
- $\sum_{i=1}^k |x_i - y_i|$  Manhattan Uzaklığı
- $(\sum_{i=1}^k (|x_i - y_i|)^q)^{1/q}$  Minkovski Uzaklığı
- $\cos \theta = \frac{\vec{a} \cdot \vec{b}}{\|\vec{a}\| \|\vec{b}\|}$  Kosinüs Uzaklığı

Kosinüs uzaklık ölçüsü esas olarak iki vektör arasındaki benzerliği hesaplamak için kullanılır. İki vektör arasındaki açının kosinüsü ile ölçülür ve iki vektörün aynı

yönü gösterip göstermediğini belirler. kNN ile kullanıldığında bu mesafe bir iş problemine yeni bir bakış açısı verir ve yukarıdaki iki uzaklık matrisini kullanarak verilerde bazı gizli bilgileri bulmamızı sağlar. Bu formülü kullanarak iki vektör arasındaki benzerliği anlatan bir değer elde edilir ve  $1 - \cos \theta$  onların kosinüs uzaklığını verir. Bu mesafeyi kullanarak 0 ile 1 arasında değerler elde edilir; burada 0, vektörlerin birbirine %100 benzediği ve 1 ise hiç benzer olmadığı anlamına gelir [48].

### 2.3. Temel Bileşen Analizi (PCA)

Büyük veri kümeleri genellikle birçok değişken üzerinde ölçümler içerir. Orijinal veri kümesindeki bilgilerin çoğunu korurken değişkenlerin sayısını önemli ölçüde azaltmak mümkündür. Bunu yapmak için bir dizi boyut küçültme tekniği mevcuttur ve temel bileşen analizi muhtemelen bunların içinde en yaygın kullanılanıdır [49]. X matrisi eğitim verileri içeren bir denklem ise buna göre:

$$X = \begin{bmatrix} x_1^1 & x_1^2 & \dots & x_1^M \\ x_2^1 & x_2^2 & \dots & x_2^M \\ \vdots & \vdots & \ddots & \vdots \\ x_N^1 & x_N^2 & \dots & x_N^M \end{bmatrix}$$

Çok değişkenli analizde, çoğu zaman değişkenlerin ölçü birimleri birbirinden oldukça farklıdır ve bazı durumlarda verilerin aynı ölçü biriminde olması gerekir. Bunun için, ilk önce değişken değerleri merkezleştirilerek aynı birime dönüştürülür. Bunun için veri ortalaması sıfıra çekilmelidir. Eğitim verilerinin ortalaması m eşitlik 2.12'deki gibi hesaplanır ardından hesaplanan bu ortalama vektörü her bir vektörden çıkartılarak değişkenlerin sıfır ortalamalı hali elde edilir. Sıfır ortalamalı veri matrisi  $\tilde{X}$  biçiminde gösterilirse ortalaması çıkarılmış gözlem vektörleri eşitlik 2.13, sıfır ortalamalı gözlem matrisi de eşitlik 2.14 ve 2.15'de gösterildiği gibi belirlenir.

$$\mathbf{m} = \frac{1}{M} \sum_{i=1}^M \mathbf{x}^i = \begin{bmatrix} \mathbf{m}_1 \\ \mathbf{m}_2 \\ \vdots \\ \mathbf{m}_N \end{bmatrix} \quad (2.12)$$

$$\tilde{\mathbf{x}}^i = \mathbf{x}^i - \mathbf{m}, \forall i \quad (2.13)$$

$$\tilde{\mathbf{X}} = [\tilde{\mathbf{x}}^1 | \tilde{\mathbf{x}}^2 | \dots | \tilde{\mathbf{x}}^M] \quad (N \times M) \quad (2.14)$$

$$\tilde{\mathbf{X}} = \begin{bmatrix} x_1^1 - m_1 & x_1^2 - m_1 & \dots & x_1^M - m_1 \\ x_2^1 - m_2 & x_2^2 - m_2 & \dots & x_2^M - m_2 \\ \vdots & \vdots & \ddots & \vdots \\ x_N^1 - m_N & x_N^2 - m_N & \dots & x_N^M - m_N \end{bmatrix} \quad (2.15)$$

Sonraki aşamada sıfır ortalamalı gözlem verisinin kovaryans matrisi, eşitlik 2.16 yardımıyla hesaplanır ve eşitlik 2.17 elde edilir.

$$\mathbf{C} = \tilde{\mathbf{X}}\tilde{\mathbf{X}}^T \quad (2.16)$$

$$\tilde{\mathbf{X}} = \begin{bmatrix} (x_1^1 - m_1)^2 & (x_1^2 - m_1)(x_2^1 - m_2) & \dots & (x_M^2 - m_1)(x_N^1 - m_N) \\ (x_2^1 - m_2)(x_1^2 - m_1) & (x_2^2 - m_2)^2 & \dots & (x_M^2 - m_2)(x_N^1 - m_N) \\ \vdots & \vdots & \ddots & \vdots \\ (x_N^1 - m_N)(x_1^M - m_1) & (x_N^2 - m_N)(x_2^M - m_2) & \dots & (x_N^M - m_N)^2 \end{bmatrix} \quad (2.17)$$

Köşegen üzerinde bulunan katsayılar varyans, diğer katsayılar kovaryans değerleridir. Varyans diğer boyutlardan bağımsız olarak yalnızca bir boyuttaki verinin ortalama etrafındaki dağılımı hakkında bilgi vermektedir. Kovaryans ise bir değişkenin diğer değişkenlerle birlikte nasıl bir değişim gösterdiği hakkında bilgi verir. Daima iki değişken arasında hesaplanır. Değişkenler arasında doğrusal bir ilişki varsa yani birinin değeri artıyorken diğeri de artıyor veya birinin değeri

azalırken diğeri de azalıyorsa iki değışken arasındaki kovaryans değıeri pozitifdir. Değışkenler arasında ters bir ilişki varsa yani birinin değıeri artarken diğerrinin değıeri azalıyor ya da birinin değıeri azalırken diğerrinin değıeri artıyorsa kovaryans değıeri negatiftir. Eđer değışkenler arasında belirgin bir ilişki yoksa, kovaryans değıeri sıfırdır [50].

TBA için kovaryans matrisinin özdeğer-özvektör ayrıştırması eşitlik 2.18 kullanılarak yapılır.  $C$ ,  $N \times N$  boyutlu bir matris,  $\lambda$  herhangi bir skaler ve  $v$  sıfırdan farklı bir sütun vektör iken, eşitlik 7'yi sağlayan  $\lambda$  sayısı  $C$ 'nin özdeğıeri ve  $v$  de  $\lambda$  ile ilişkili özvektördür.

$$Cv = \lambda v \quad (2.18)$$

Özdeğerler büyükten küçüğe doğru sıralanır, sıralı özdeğerlere karşılık gelen özvektörlerden ilk  $P$  tanesi bir matrisin sütunlarını oluşturacak şekilde dizilir. En iyi izdüşümü gerçekleştiren  $W$  izdüşüm matrisi eşitlik 2.19'deki gibi elde edilir. Veri örneklerinin öznitelikleri de özvektörlerin belirlediğı uzay üzerine izdüşüm alınarak eşitlik 2.20'deki gibi hesaplanır.

$$W = [w_1 \quad w_2 \quad \dots \quad w_p] \quad (2.19)$$

$$y^i = W^T x^i, i = 1, 2, \dots, M \quad (2.20)$$

Özniteliklerin belirlenmesiyle eğitim aşaması tamamlanır. Eğitim aşamasından sonra sınıflandırma aşaması gelir. Sınıflandırma aşaması, eğitimde kullanılmamış bir test verisi girildiğinde, eğitim aşamasındaki öznitelikler kullanılarak test verisinin hangi sınıfa ait olduğı belirlenir.

#### 2.4. Hata Matrisi (Confusion Matrix)

Makine öğrenmesinde kullanılan sınıflandırma modellerinin başarısını değıerlendirmek amacıyla hedef özelliğe ait tahminlerin ve gerçek değıerlerin karşılaştırıldığı hata matrisi yaygın olarak kullanılmaktadır. Sınıflandırma tahminleri dört değıerlendirmeden birine sahip olacaktır. Bu değıerlendirmeler şunlardır: [51]

- *True Negatif (TN)*: Yanlışa yanlış demek
- *True Pozitif (TP)*: Doğruya doğru demek
- *False Negatif (FN)*: Doğruya yanlış demek
- *False Pozitif (FP)*: Yanlışa doğru demek

		TAHMİN		TOPLAM
		YOK	VAR	
GERÇEK	YOK	T N 100	F P 20	120
	VAR	F N 10	T P 200	210
TOPLAM		110	220	

Şekil 17. Hata Matrisi

Doğruluk (Accuracy): Doğru sınıflandırmanın toplama bölümüdür. Yani;  $TN+TP / \text{Toplam}$ . Ayrıca esas köşegenin toplama oranı da denilebilir. Sınıflandırma modelinin ne sıklıkla doğru tahmin ettiğini belirler.

Hata Oranı (Error Rate / Misclassification Rate): Yanlışların toplama oranıdır. Yani;  $FN + FP / \text{Toplam}$  veya  $1-\text{Doğruluk}$ . Ayrıca yedek köşegenin toplama oranıdır da denilmektedir.

Hassasiyet: Tüm gerçek pozitif vakalardan kaç tanesinin sınıflandırıcı tarafından doğru pozitif olarak ettiğini belirler.

$$\text{Hassasiyet (Sensitivity)} = \frac{\text{True Pozitifler}}{\text{True Pozitifler} + \text{False Negatifler}}$$

Özgüllük: Tüm gerçek negatif durumlardan kaç tanesinin sınıflandırıcı tarafından doğru olarak negatif olarak ettiğini belirler.

$$\text{Özgüllük (Specificity)} = \frac{\text{True Negatifler}}{\text{True Negatifler} + \text{False Pozitifler}}$$

Kesinlik (Precision): Sınıflandırıcı pozitif öngördüğünde, ne sıklıkla tahmin ettiğini belirler.

$$\text{Kesinlik (Precision)} = \frac{\text{True Pozitifler}}{\text{True Pozitifler} + \text{False Pozitifler}}$$

Kappa Değeri: Cohen'in kappa katsayısı iki değerleyici arasındaki karşılaştırmalı uyuşmanın güvenilirliğini ölçen bir istatistiksel bir yöntemdir.

$$p1 = \frac{TP + FN}{TP + TN + FP + FN} \qquad p2 = \frac{TP + FP}{TP + TN + FP + FN}$$

$$\text{Rastgele Doğruluk} = p1 * p2 + (1 - p1) * (1 - p2)$$

$$\text{kappa} = \frac{\text{Doğruluk} - \text{Rastgele Doğruluk}}{1 - \text{Rastgele Doğruluk}}$$



## ÜÇÜNCÜ BÖLÜM

### 3. YÖNTEM VE BULGULAR

#### 3.1. YÖNTEM

Bu çalışmada kullanılan veriler Kaggle sitesinden alınmıştır. Seçilen veri grubunda sağlıklı kişilere ve hasta kişilerden pnömoni, KOAH ve bronşektazi hastalarına ait akciğer sesleri seçilmiş ve analiz edilmiştir. Akciğer seslerine üç farklı filtre olan Butterworth, Chebyshev ve Eliptik bantgeçiren filtreler uygulanmış ve Dalgacık Dönüşümü kullanılarak öznelikler elde edilmiştir. Bu öznelikler, Temel Bileşen Analizi (PCA) kullanılmışken ve kullanılmamışken sınıflandırılmıştır. Sınıflandırma işlemi için k-En Yakın Komşular (kNN) ve Destek Vektör Makineleri (DVM) kullanılmıştır. Literatürdeki çalışmalar ek sesleri ayırt etmek üzerine yapılmışken, bu çalışma özellikle pnömoni hastalığını teşhis etmek için yapılmıştır. Ayrıca filtrelerin ve PCA analizinin iki farklı sınıflandırma algoritması üzerindeki etkileri de analiz edilmiştir. Tüm işlemlerin gerçekleştirilmesinde *MATLAB* programı kullanılmıştır.

Akciğer seslerinin kaydedilmesi esnasında, çevreden gelen sesler, kas ve sürtünme sesleri, kalp sesleri gibi gürültüler kayıt altına alınabilir. Bu gürültüleri olabildiğince elimine etmek amacıyla filtreler kullanılır. Bu çalışmada, üç farklı filtre tasarlanmış ve uygulanmıştır. Bunlar Chebyshev, Eliptik ve Butterworth bantgeçiren filtrelerdir. Kesme frekansı aralığı 100-2000 Hz olarak belirlenmiştir.

Filtreleme işleminden sonra elde edilen veriye bu kez dalgacık dönüşümü uygulanmış ve elimine edilemeyen gürültülerin de ortadan kalkması sağlanmıştır. Bunun için daubechies 7 (db7) dalgacık türü seçilmiş ve 7. Seviyeye kadar ayrıştırma yapılmıştır. Dalgacık dönüşümü uygulanmamış olan filtrelenmiş ses verilerinden ve dalgacık daraltımı yapılan her bir alt banttın öznelik çıkarımı yapılmıştır. Öznelik çıkartmada kullanılan yöntemler şu şekildedir:

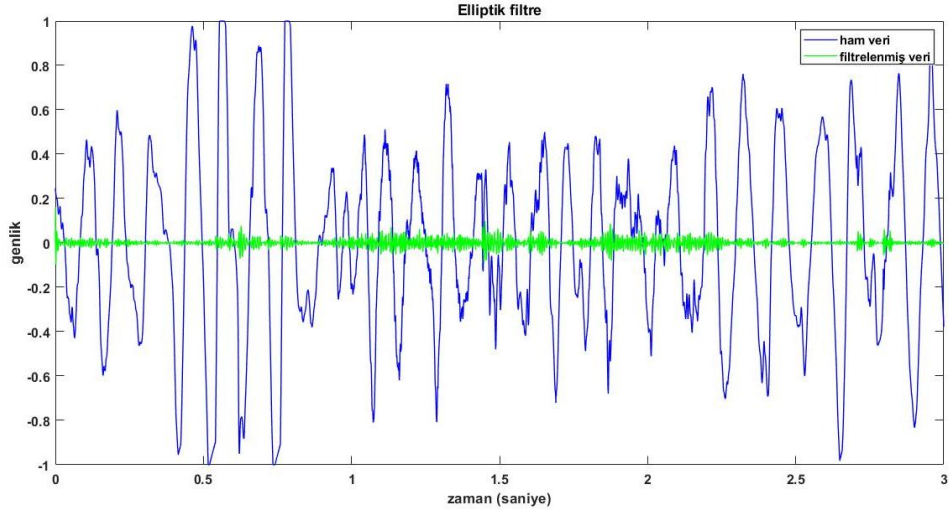
1. Her alt bandın maksimum değeri elde edilmiştir.
2. Her alt bandın standart sapması elde edilmiştir.

3. Her alt bandın varyansı elde edilmiştir.
4. Her alt bandın mutlak değerinin ortalaması alınmış ve elde edilen değerlerin her biri kendisine komşu olan alt banda bölünmüştür.
5. Welch metodunu kullanarak sadece filtrelenmiş ses verisinin (Dalgacık dönüşümü uygulanmamış hali) güç spektrum yoğunluğu (PSD) değerini elde edip sonrasında PSD değerinin;
  - Enerji
  - Entropi
  - Standart sapma
  - Ortalama
  - En küçük
  - En büyük
  - Çarpıklık
  - Basıklık
  - RMS değerleri bulunmuştur.


Elde edilen öznitelikler kullanılarak datasetler oluşturulmuştur. Her bir veri önce “Normal-Anormal” olmak üzere iki farklı şekilde etiketlenmiştir. Sonra anormal olan veriler kendi içinde “Pnömoni Var / Pnömoni Yok” olarak etiketlenmiştir. Böylece iki adımda pnömoni hastalığının belirlenmesi amaçlanmıştır. Bu veri setleri oluşturulduktan sonra PCA analizi uygulanan ve uygulanmayan olarak iki gruba ayrılmıştır. Bu iki grup da kNN ve DVM algoritmaları ile sınıflandırılmıştır. Böylece filtrelerin ve PCA analizinin sınıflandırmaya olan etkisi gözlemlenmiş, en iyi sınıflandırma sonucunun nasıl elde edileceği analiz edilmiştir.

### 3.2. BULGULAR

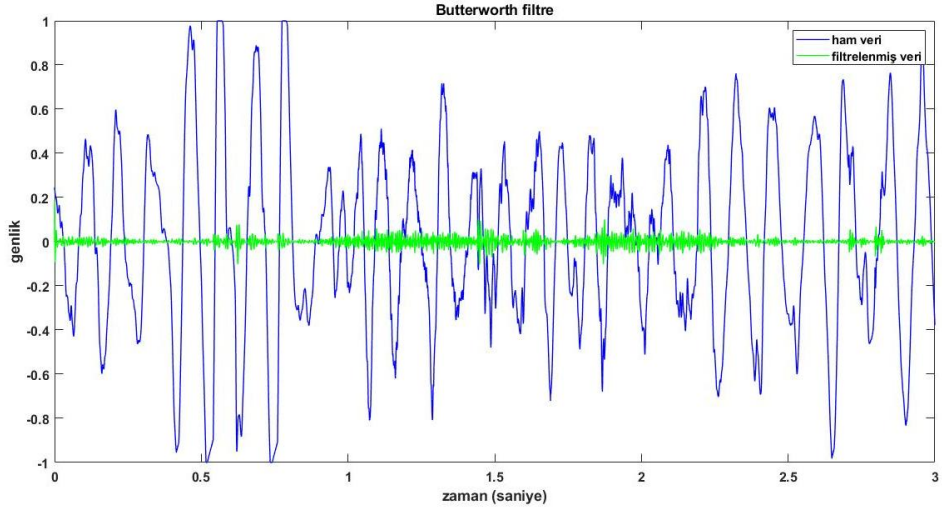
Butterworth, chebyshev ve eliptik filtreler, pnömonili bir hastanın ses verisine ayrı ayrı uygulanmış, ses verisinin ham hali ile filtrelenmiş hali üst üste çizdirilmiştir. Şekil 18-20’de, uygulanan filtrelerin sonuçlarının grafikleri gösterilmektedir. Grafiklerden de görüleceği gibi gürültülerin büyük bir kısmı elimine edilmiştir.



Şekil 18. Ham akciğer verileri ve eliptik filtre ile filtrenmiş veriler

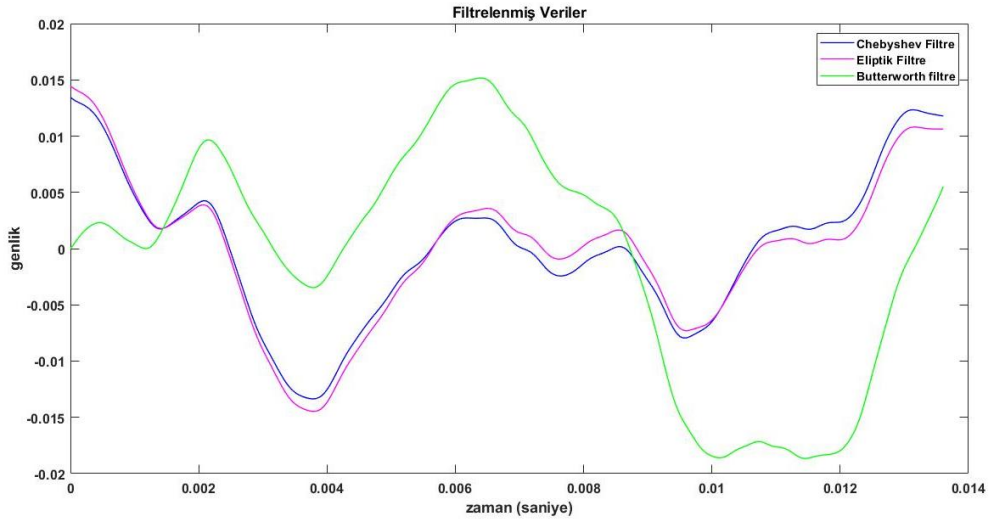


Şekil 19. Ham akciğer verileri ve Chebyshev filtre ile filtrenmiş veriler




Şekil 20. Ham akciğer verileri ve butterworth filtre ile filtrelenmiş veriler

Daha sonra kullanılan filtreleri kıyaslamak amacıyla, üç filtrenin filtreleme sonuçları genlik-zaman grafiği kullanılarak üst üste çizdirilmiş, Şekil 21 ve Şekil 22’de gösterilmiştir.



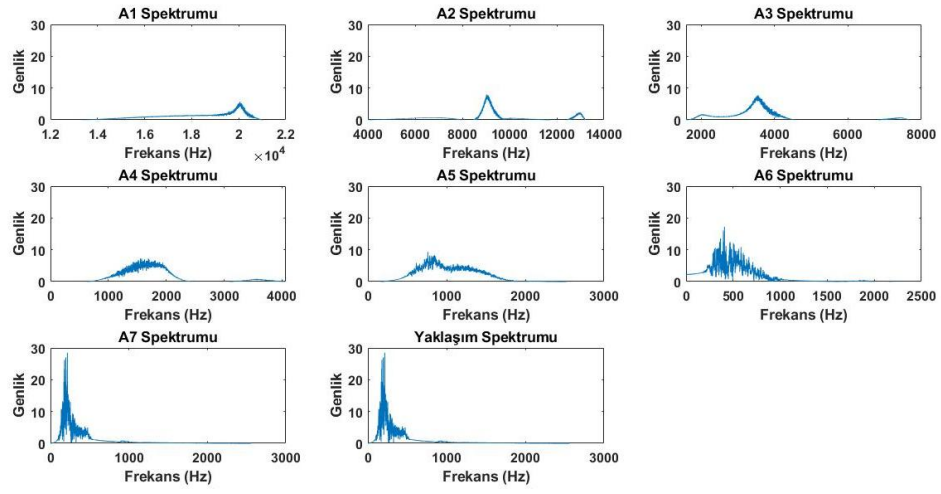
Şekil 21. Filtrelenmiş hasta verilerin kıyası



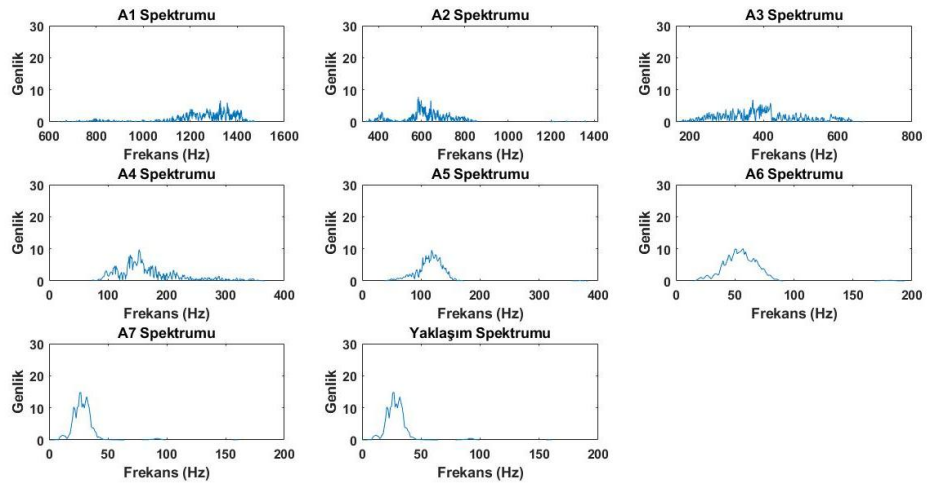
Şekil 22. Filtrelenmiş sağlıklı verilerin kıyası

Şekil 21’de hastaya ait bir ses verisinin filtreleme sonuçları görülürken, Şekil 22’de sağlıklı kişiye ait bir ses verisinin filtreleme sonuçları görülmektedir. Chebyshev ve eliptik filtre yaklaşık aynı sonuçları vermiştir. Butterworth filtre, diğer filtrelerden farklılık göstermiştir. Hasta ses verisinde genlik değerleri diğer filtrelere göre daha yüksek iken, sağlıklı ses verisinde genlik değerlerinin daha düşük olduğu görülmektedir. Bu da hasta ile sağlıklı ses verisi arasında daha büyük farklar oluşturmasını sağladığı düşünülmektedir.

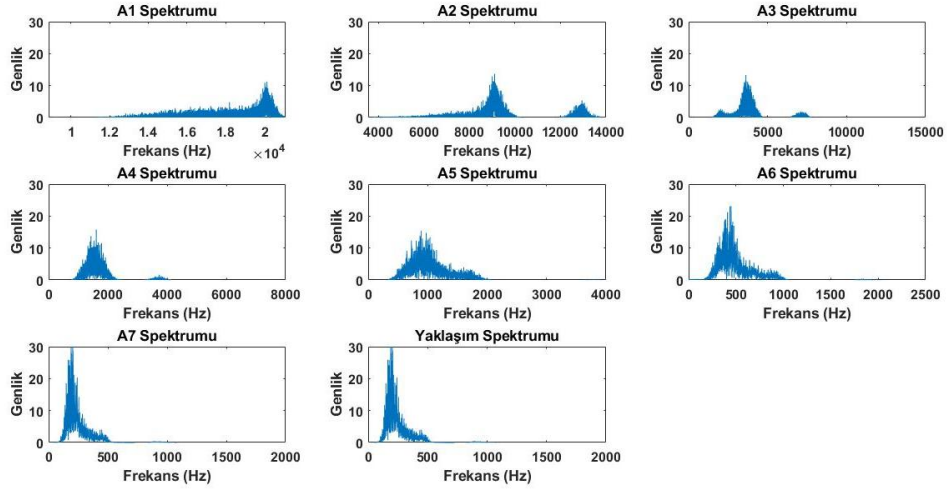
Filtreleme işleminden sonra elde edilen veriye bu kez dalgacık dönüşümü uygulanmış ve elimine edilemeyen gürültülerin de ortadan kalkması amaçlanmıştır. Bunun için daubechies 7 (db7) dalgacık türü seçilmiş ve 7. Seviyeye kadar ayrıştırma yapılmıştır. Hasta ve sağlıklı ses verilerinden seçilen birer örneğe dalgacık dönüşümü uygulandığında elde edilen grafikler Şekil 23-26’da gösterilmiştir. Burada A (Ayrıntı katsayıları/ Details) ve Yaklaşım katsayıları (Approximation) görülmektedir.



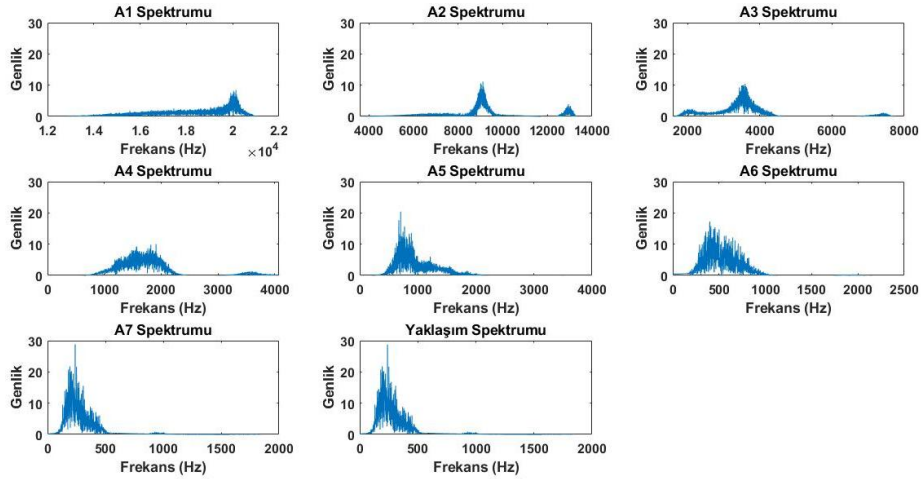
Şekil 23. Sağlıklı ses verisine uygulanan dalgacık dönüşümü sonuçları



Şekil 24. KOAH ses verisine uygulanan dalgacık dönüşümü sonuçları

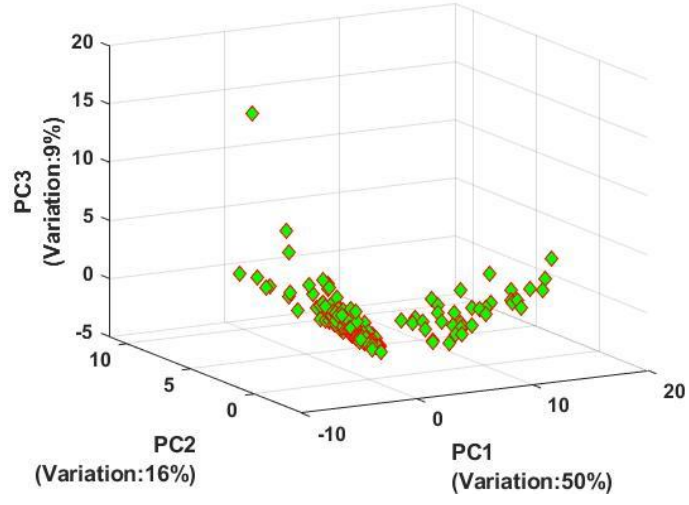


Şekil 25. Bronşektazi ses verisine uygulanan dalgacık dönüşümü sonuçları




Şekil 26. Pnömoni ses verisine uygulanan dalgacık dönüşümü sonuçları

Filtrelenmiş verilerden ve dalgacık dönüşümü sonucunda elde edilen altbantlardan çıkarılan öznelilikler ile datasetler oluşturulmuştur. Datasetler yöntemler kısmında anlatıldığı şekilde etiketlenmiştir. Datasetlere uygulanan PCA analizinin grafikleri elde edilmiş ve Şekil 27-28’de gösterilmiştir.




Şekil 27. “Normal-Anormal” sınıfına uygulanan PCA analizi sonucu




Şekil 28. “Pnömoni Var veya Yok” sınıfına uygulanan PCA analizi sonucu

PCA analizi uygulandıktan sonra, her bir filtre için DVM ve kNN algoritmaları kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Elde edilen sınıflandırma sonuçları hata matrisleri kullanılarak şekil 29-34’te gösterilmiştir.







**a**



**b**



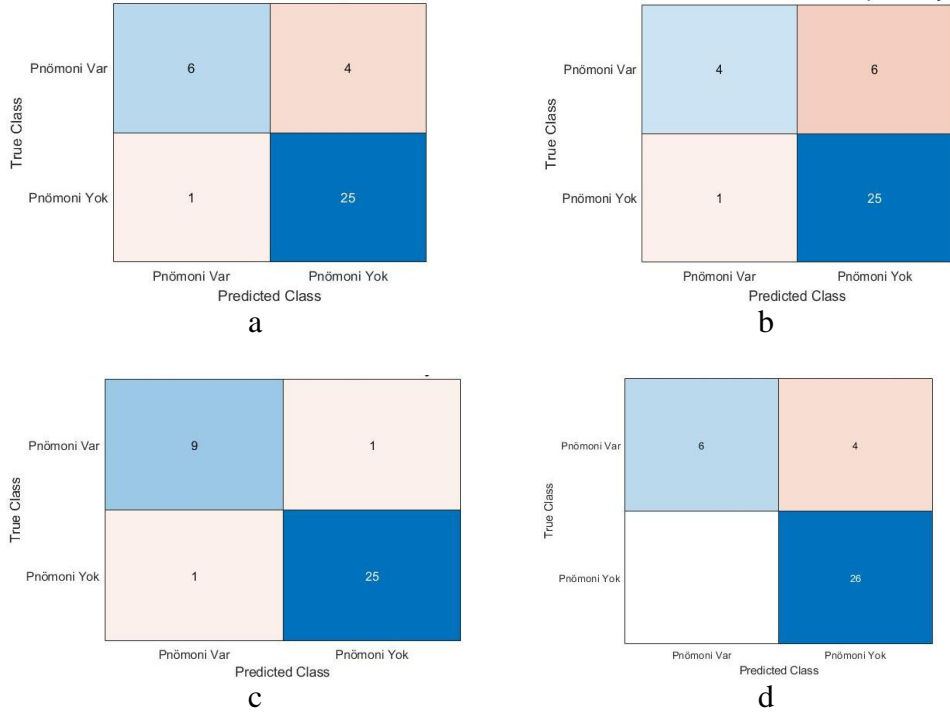
**c**



**d**


(a.KNN ile sınıflandırma b.DVM ile sınıflandırma c.PCA kullanarak kNN ile sınıflandırma d.PCA kullanarak DVM ile sınıflandırma)

Şekil 29. Butterworth filtre kullanılarak normal-anormal akciğer sesleri ayırımında sınıflandırma sonuçları




(a.KNN ile sınıflandırma b.DVM ile sınıflandırma c. PCA kullanarak kNN ile sınıflandırma d.PCA kullanarak DVM ile sınıflandırma)


Şekil 30. Butterworth filtre kullanılarak pnömonili akciğer sesleri ayırımında sınıflandırma sonuçları




**a**



**b**



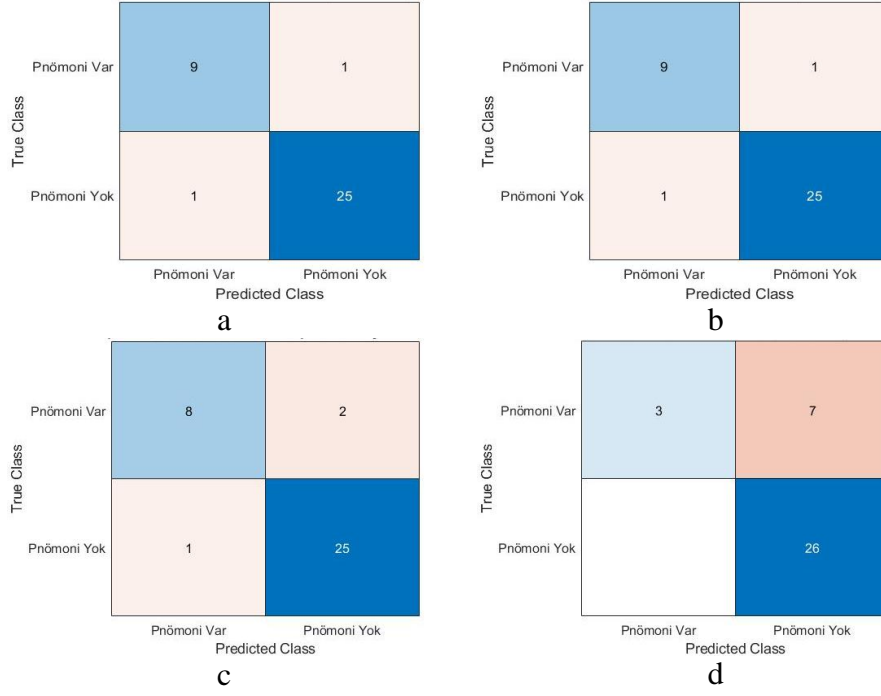
**c**



**d**

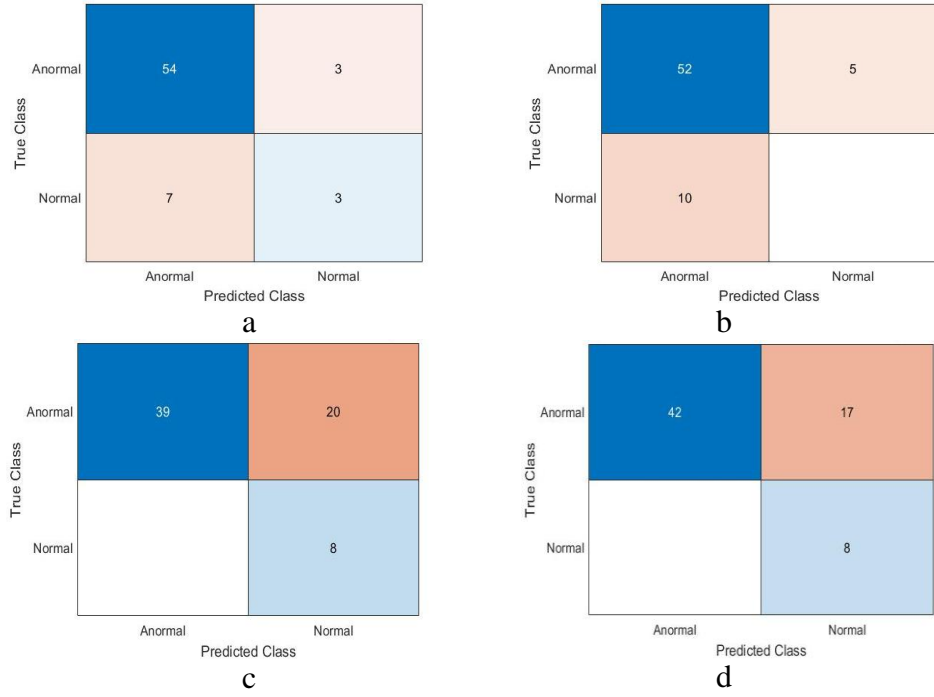
*(a.KNN ile sınıflandırma b.DVM ile sınıflandırma c.PCA kullanarak kNN ile sınıflandırma d.PCA kullanarak DVM ile sınıflandırma*

Şekil 31. Eliptik filtre kullanarak normal-anormal akciğer sesleri ayırımında sınıflandırma sonuçları




(a.KNN ile sınıflandırma b.DVM ile sınıflandırma c. PCA kullanarak kNN ile sınıflandırma d.PCA kullanarak DVM ile sınıflandırma)

Şekil 32. Eliptik filtre kullanarak pnömonili akciğer sesleri ayırımında sınıflandırma sonuçları




(a.KNN ile sınıflandırma b.DVM ile sınıflandırma c.PCA kullanarak kNN ile sınıflandırma d.PCA kullanarak DVM ile sınıflandırma)


Şekil 33. Chebyshev filtre kullanarak normal-anormal akciğer sesleri ayırımında sınıflandırma sonuçları




a



b



c



d

(a.KNN ile sınıflandırma b.DVM ile sınıflandırma c. PCA kullanarak kNN ile sınıflandırma d.PCA kullanarak DVM ile sınıflandırma)

Şekil 34. Chebyshev filtre kullanarak pnömonili akciğer sesleri ayırımında sınıflandırma sonuçları

## DÖRDÜNCÜ BÖLÜM

### 4. TARTIŞMA

Son dönemde yapılan çalışmalarda, hastalıkların bilgisayar analizleri sayesinde otomatik olarak belirlenmesi hedeflenmiştir. Bu çalışmada esas amaç dünya genelinde yaygın görülen ve ölümcül olabilen pnömoni hastalığının otomatik olarak belirlenmesidir. Pnömoni akciğerlerde gelişen bir hastalıktır. Bu nedenle yapılan çalışmada akciğer ses verileri kullanılmıştır. Verilere Kaggle sitesinden ulaşılmıştır. Hasta ve sağlıklı kişilere ait olan 198 adet akciğer sesi kullanılmıştır. Çeşitli hastalıklara ait verilerden pnömoni, bronşektazi ve KOAH verileri seçilmiştir. Ardından verilere *MATLAB* yardımıyla sinyal işleme teknikleri uygulanmaya başlanmıştır. İlk olarak gürültüleri gidermek için üç farklı filtre olan butterworth, chebyshev ve eliptik bantgeçiren filtreler tasarlanmıştır. Bu filtrelerin uygulandığı her bir ses verisi ile üç ayrı dataset oluşturulduktan sonra, datasetler etiketlenmiştir. Önce “Normal-Anormal” şeklinde bir eğitim ve test veri seti oluşturulmuştur. Sonra sadece hastaların bulunduğu dataset “Pnömoni Var” ve “Pnömoni Yok” şeklinde etiketlenerek eğitim ve test seti oluşturulmuştur. Daha sonra her bir dataset iki farklı sınıflandırma yöntemiyle sınıflandırılmıştır. Bu sınıflandırma yöntemleri; destek vektör makineleri (DVM) ve k-En yakın komşular (kNN)’dir. Sınıflandırma yapılırken datasetler PCA analizi uygulanmış ve uygulanmamış olarak iki gruba ayrılmıştır. kNN sınıflandırmasında “cosine” uzaklığı kullanılmış,  $k$  komşu sayısı 10 seçilmiştir. DVM sınıflandırmasında, lineer kernel seçilmiştir.

Bu çalışmadan beklenen sonuç, akciğer seslerinin analiz edilip kişinin sağlıklı mı yoksa hasta mı eğer hastaysa pnömoni hastası olup olmadığının tahmin edilmesidir. Yapılan tahminin doğruluğunun literatürde yapılmış olan çalışmalara göre kıyası yapıldığında başarılı bir sonuç elde edilmesi beklenmektedir.

Bulgular kısmında elde edilen dalgacık dönüşümü sonuçları incelendiğinde (Şekil 23-26) tüm alt bantlarda veriye ait bilgiler olduğu görülmektedir. Esas amaç pnömoniyi ayırt etmek olduğu için, en az 100 Hz en fazla 4000 Hz’e kadar uzanan

bant aralığı seçilmiştir. Çünkü pnömonide 2000 Hz üzerinde sinyallere de rastlanılabilir dolayısıyla bir esneklik payı bırakılmıştır. Bunun için A3-A6 alt bantlarının en uygun bant aralığı olduğuna karar verilmiştir. Sonrasında seçilen alt bantlara Stein's Unbiased Risk Estimate (SURE) yöntemi uygulanarak dalgacık daraltımı yapılmıştır. Bu sayede filtrelerle giderilemeyen gürültüler de elimine edilmiştir.

Sinyal işleme tekniklerinin ardından öznitelik çıkarım işlemleri gerçekleştirilmiştir. Filtrelenmiş verilerin PSD değerleri bulunup bunun en küçük, en büyük, entropi, enerji, standart sapma, ortalama, eğrilik, basıklık ve enerji değerleri elde edilmiştir. Ayrıca dalgacık dönüşümü sonucunda elde edilen ve frekans aralığına göre seçilmiş olan A3-A6 alt bantlarından da, her bir alt bandın mutlak maksimum değeri, standart sapması, varyansı ve komşu alt bantların mutlak değerlerinin ortalamasının oranı kullanılmıştır. Komşu alt bantların oranı için her alt bandın mutlak değerinin ortalaması alınmış ve bu alt bantların her biri kendisine komşu olan alt banda bölünerek öznitelik çıkarım işlemleri tamamlanmıştır. Çıkarılan tüm öznitelikler, normal ve anormal sesleri ayırt etmek için kullanılmıştır. Pnömoni hastalığı sınıflandırmasında PSD ile elde edilen bazı özellikler elenmiş ve deneysel olarak en etkili olan özellikler seçilmiştir. Buna göre entropi, ortalama, en küçük ve en büyük değerlerin kullanılması yeterli olmuştur. Öznitelikler kullanılarak datasetler oluşturulmuştur.

Datasetlere PCA analizi uygulanmıştır ve PCA grafikleri Şekil 27-28'de gösterilmiştir. Elde edilen bulgulara göre, normal-anormal sınıflandırmasında PC1, PC2 ve PC3 değişkenlerinin kurulan PCA modelindeki varyansın %75'ini açıkladığı görülmüştür. Aynı şekilde pnömoni var-yok sınıflandırmasında varyansın %70'ini açıkladığı anlaşılmıştır. PCA analizinin ardından kNN ve DVM ile sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırma sonuçları hata matrisi (confusion matrix) halinde Şekil 29-34'te gösterilmiştir. Normal-anormal sınıflandırmasında doğruluk değerlerine göre en başarılı filtre Butterworth filtre ve en başarılı sınıflandırma kNN olmuştur. Pnömoni Var-Yok sınıflandırmasında ise en başarılı filtre Chebyshev filtre ve en başarılı sınıflandırma PCA analizi uygulanmış kNN sınıflandırması olmuştur. Bu matrislerin yorumlanması için TN, TP, FN ve FP gibi özellikler



kullanılarak doğruluk, hassasiyet, duyarlılık, kesinlik ve kappa değerleri hesaplanmıştır. Hesaplama sonuçları Tablo 4 ve Tablo 5’te gösterilmiştir.

Tablo 3. “Normal-Anormal” sınıflandırma sonuçları

<b>Filtre</b>	<i>Doğruluk</i>	<i>Hassasiyet</i>	<i>Duyarlılık</i>	<i>Kesinlik</i>	<i>Kappa</i>
<b><i>Butterworth</i></b>					
<i>kNN</i>	91%	66%	96%	80%	0.67
<i>SVM</i>	85%	50%	89%	40%	0.35
<i>PCA (kNN)</i>	88%	57%	96%	80%	0.59
<i>PCA(DVM)</i>	85%	0%	85%	0%	0.005
<b><i>Chebyshev</i></b>					
<i>kNN</i>	85%	50%	88%	30%	0.29
<i>SVM</i>	77%	0%	83%	0%	0.14
<i>PCA (kNN)</i>	70%	28%	100%	100%	0.31
<i>PCA(DVM)</i>	74%	32%	100%	100%	0.35
<b><i>Eliptik</i></b>					
<i>kNN</i>	85%	50%	96%	80%	0.52
<i>SVM</i>	82%	37%	88%	30%	0.22
<i>PCA (kNN)</i>	86%	52%	98%	90%	0.57
<i>PCA(DVM)</i>	85%	0%	85%	0%	0.005

Tablo 4. “Pnömoni Var veya Yok” sınıflandırma sonuçları

<b>Filtre</b>	<i>Doğruluk</i>	<i>Hassasiyet</i>	<i>Duyarlılık</i>	<i>Kesinlik</i>	<i>Kappa</i>
<b><i>Butterworth</i></b>					
<i>kNN</i>	86%	71%	82%	50%	0.65
<i>SVM</i>	80%	80%	80%	40%	0.45
<i>PCA (kNN)</i>	94%	96%	90%	96%	0.85
<i>PCA(DVM)</i>	88%	86%	100%	100%	0.65
<b><i>Chebyshev</i></b>					
<i>kNN</i>	88%	100%	92%	80%	0.67
<i>SVM</i>	86%	85%	86%	60%	0.58
<i>PCA (kNN)</i>	97%	96%	100%	100%	0.92
<i>PCA(DVM)</i>	83%	88%	70%	88%	0.57
<b><i>Eliptik</i></b>					
<i>kNN</i>	94%	90%	96%	90%	0.85
<i>SVM</i>	94%	90%	96%	90%	0.85
<i>PCA (kNN)</i>	91%	92%	80%	96%	0.76
<i>PCA(DVM)</i>	80%	78%	100%	100%	0.36

PCA analizi olmadan yapılan sınıflandırma sonuçları incelendiğinde, "Normal-Anormal" akciğer seslerinin sınıflandırılmasında en başarılı filtrenin %91 doğrulukla Butterworth filtresi olduğu ve en başarılı sınıflandırma tipinin kNN olduğu görüldü. DVM ile yapılan sınıflandırmada, kNN'ye göre tüm filtrelerin doğruluk oranlarının düştüğü gözlenmiştir. Buna göre "Normal-Anormal" sınıflandırmasında en iyi sonuçların kNN ile elde edildiği söylenebilir. PCA analizi olmadan yapılan "Pnömoni Var veya Yok" sınıflandırmasında, eliptik filtrenin hem kNN hem de DVM algoritmaları için %94 doğrulukla en başarılı filtre olduğu görülmüştür. Butterworth ve chebyshev filtreleri incelendiğinde kNN ile daha başarılı sonuçlar elde edildiği görülmektedir. Genel olarak hem "Normal-Anormal" hem de "Pnömoni Var veya Yok" sınıflandırması kNN ile en yüksek başarı oranına sahiptir. Çalışma sonucunda, kNN ile yapılan sınıflandırmanın, PCA analizi kullanılmadan DVM ile yapılan sınıflandırmaya göre daha üstün olduğu söylenebilir.

PCA analiz sonuçları incelendiğinde "Normal-Anormal" akciğer sesleri sınıflandırmasında en yüksek başarı oranı %88'dir. kNN ile yapılan sınıflandırmada butterworth filtre, DVM ile yapılan sınıflandırmada ise butterworth ve eliptik filtreler %85 başarı oranına ulaşmıştır. PCA analizi olmadan yapılan sınıflandırma sonuçlarına göre en yüksek doğruluk oranı %91'den %88'e düşmüştür. kNN sınıflandırması incelendiğinde, PCA analizinin butterworth ve chebyshev filtreleri üzerinde olumsuz etki yaptığı ve eliptik filtrede %1'lik bir artışa neden olduğu görülmüştür. DVM sınıflandırması incelendiğinde, butterworth filtresinde herhangi bir değişiklik olmazken, chebyshev filtresinin başarı oranının düştüğü, eliptik filtrenin başarı oranının ise arttığı gözlemlendi.

PCA analizi ile yapılan "Pnömoni Var veya Yok" sınıflandırmasında en başarılı filtre %97 doğrulukla chebyshev filtresi, en başarılı sınıflandırma ise kNN olmuştur. PCA analizinin uygulandığı sınıflandırma sonuçlarına göre en yüksek doğruluk oranı %94'ten %97'ye çıkmıştır. kNN sınıflandırması incelendiğinde butterworth ve chebyshev filtrelerinde artış, eliptik filtrede ise azalma olduğu görülmüştür. DVM sınıflandırması incelendiğinde, butterworth filtresinde bir artış olduğu ancak chebyshev ve eliptik filtrelerin doğruluğunun düştüğü gözlemlendi. Butterworth ve chebyshev filtresi, PCA analizi ile başarı oranını artırmıştır. PCA

analizi olmadan yapılan sınıflandırma sonucuna göre başarı oranı oldukça yükselmiştir.

## SONUÇ VE ÖNERİLER

Bu çalışmada elde edilen sınıflandırma sonuçları literatürdeki sonuçlarla karşılaştırılmıştır. Literatürdeki çalışmalara göre İçer ve ark. DVM ile "Normal-Anormal" sınıflandırmada %92,5 başarı elde etmiştir. Elde edilen ral sesinin literatürdeki başarısı incelendiğinde Serbes ve arkadaşları kNN ile %78 ve SVM ile %81 doğruluk oranı elde etmişlerdir. İçer ve arkadaşları, DVM ile yapılan sınıflandırmada %95,3 doğruluk oranına ulaşmışlardır. Bu çalışmada sadece ral değil pnömoni göstergesi olan ince ral sınıflandırması da yapılmıştır. Buna göre normal-anormal sınıflandırma için kNN ile %91 doğruluk oranı elde edilmiştir. Ayrıca pnömoni sınıflandırmasında PCA-kNN ile %97 doğruluk oranı elde edilmiştir. Literatürdeki en yakın çalışma olan İçer ve diğerlerine göre sınıflandırma başarısının oldukça iyi olduğu gösterilmiştir.

PCA olmadan yapılan sınıflandırma sonuçlarına bakıldığında, Butterworth filtreli kNN algoritması, normal-anormal ses sınıflandırmasında en başarılı sonuca sahiptir. Pnömoni sınıflandırmasında hem DVM hem de kNN algoritmaları Eliptik filtre ile en başarılı sonuçlara sahiptir. PCA ile yapılan sınıflandırma sonuçlarına bakıldığında pnömoni sınıflandırmasında oldukça etkili olmuştur. PCA analizi olmadan sınıflandırma başarısı %94 iken, PCA analizi ile %97 başarı elde edildi.

Sonuç olarak PCA'sız kNN sınıflandırmasının DVM sınıflandırmasına göre daha başarılı olduğu söylenebilir. Genel olarak PCA analizi ile kNN sınıflandırmasının DVM' ye göre daha başarılı olduğu söylenebilir. Pnömoni sınıflamasına göre PCA analizinin kNN üzerinde olumlu etkisi olduğu gözlemlendi.

Eğer pnömoniyi tespit etmek için bir yazılım geliştirilirse, ilk etapta anormal olanları tespit etmek daha önemlidir. Çünkü anormali normal olarak belirlemek daha tehlikelidir. Bu nedenle, normal-anormal sınıflandırması için özgülük değerinin yüksek olması önemlidir. PCA'sız butterworth filtreli kNN 96% özgülük ve 0.67 kappa değeriyle en uygun filtredir. Pnömoni hastalığını belirlemek için chebyshev filtreli PCA analizi kullanılarak kNN sınıflandırması önerilir. Çünkü elde edilen tüm değerler 90%'nin üzerindedir.

## KAYNAKLAR

- [1] S. S. Kraman, G. R. Wodicka, G. A. Pressler, and H. Pasterkamp, "Comparison of lung sound transducers using a bioacoustic transducer testing system," *J Appl Physiol*, vol. 101, pp. 469–476, 2006, doi: 10.1152/jappphysiol.00273.2006.-Sensors.
- [2] M. VA, J. JT, and W. GN, "The acoustic basis of the chest examination; studies by means of sound spectrography," *Am. Rev. Tuberc.*, vol. 72, no. 1, pp. 12–34, Jul. 1955, doi: 10.1164/ARTPD.1955.72.1.12.
- [3] K. A, K. CS, R. RP, J. S, and M. N, "Neural classification of lung sounds using wavelet coefficients," *Comput. Biol. Med.*, vol. 34, no. 6, pp. 523–537, Sep. 2004, doi: 10.1016/S0010-4825(03)00092-1.
- [4] S. H. Li, B. S. Lin, C. H. Tsai, C. T. Yang, and B. S. Lin, "Design of wearable breathing sound monitoring system for real-time wheeze detection," *Sensors (Switzerland)*, vol. 17, no. 1, 2017, doi: 10.3390/s17010171.
- [5] S. İçer and Ş. Gengeç, "Classification and analysis of non-stationary characteristics of crackle and rhonchus lung adventitious sounds," *Digit. Signal Process. A Rev. J.*, vol. 28, no. 1, pp. 18–27, 2014, doi: 10.1016/j.dsp.2014.02.001.
- [6] G. Serbes, C. O. Sakar, Y. P. Kahya, and N. Aydın, "Pulmonary crackle detection using time-frequency and time-scale analysis," *Digit. Signal Process. A Rev. J.*, vol. 23, no. 3, pp. 1012–1021, 2013, doi: 10.1016/j.dsp.2012.12.009.
- [7] R. J. Riella, P. Nohama, and J. M. Maia, "Method for automatic detection of wheezing in lung sounds," *Brazilian J. Med. Biol. Res.*, vol. 42, no. 7, pp. 674–684, 2009, doi: 10.1590/S0100-879X2009000700013.

- [8] E. Ç. Güler, B. Sankur, Y. P. Kahya, and S. Raudys, “Two-stage classification of respiratory sound patterns,” *Comput. Biol. Med.*, vol. 35, no. 1, pp. 67–83, 2005, doi: 10.1016/j.compbiomed.2003.11.001.
- [9] P. Piirila and A. R. A. Sovijarvi, “Crackles: Recording, analysis and clinical significance,” *Eur. Respir. J.*, vol. 8, no. 12, pp. 2139–2148, 1995, doi: 10.1183/09031936.95.08122139.
- [10] “Mayo Clinic - Mayo Clinic.” <https://www.mayoclinic.org/> (accessed Aug. 02, 2021).
- [11] “human respiratory system | Description, Parts, Function, & Facts | Britannica.” <https://www.britannica.com/science/human-respiratory-system> (accessed Sep. 30, 2021).
- [12] H. Y. Sohn, S. K. Kim, and K. H. Kim, *Anatomy of the Respiratory System*, vol. 32, no. 1. 1985.
- [13] Z. Ş. Emeksiz and İ. Bostancı, “Akciğer: Sesimi Duyan Var Mı?,” *Güncel Pediatr.*, vol. 16, no. 3, pp. 79–84, Dec. 2018, doi: 10.32941/PEDIATRI.485522.
- [14] G. Altan and Y. Kutlu, “Makine Öğrenmesini Kullanarak Solunum Sesinin Analizinin Değerlendirilmesi,” *2016 20th Natl. Biomed. Eng. Meet. BIYOMUT 2016*, Feb. 2017, doi: 10.1109/BIYOMUT.2016.7849379.
- [15] J. S. Coviello, *Auscultation Skills*. .
- [16] P. S. Faustino, “Crackle and wheeze detection in lung sound signals using convolutional neural networks,” 2019.
- [17] R. P. Baughman and R. G. Loudon, “Stridor: Differentiation from Asthma or Upper Airway Noise,” <http://dx.doi.org/10.1164/ajrccm/139.6.1407>, vol. 139, no. 6, pp. 1407–1409, Dec. 2012, doi: 10.1164/AJRCCM/139.6.1407.

- [18] A. Bohadana, G. Izbicki, and S. S. Kraman, “Fundamentals of Lung Auscultation,” <https://doi.org/10.1056/NEJMra1302901>, vol. 370, no. 8, pp. 744–751, Feb. 2014, doi: 10.1056/NEJMRA1302901.
- [19] N. Gavriely, T. R. Shee, D. W. Cugell, and J. B. Grotberg, “Flutter in flow-limited collapsible tubes: a mechanism for generation of wheezes,” <https://doi.org/10.1152/jappl.1989.66.5.2251>, vol. 66, no. 5, pp. 2251–2261, 1989, doi: 10.1152/JAPPL.1989.66.5.2251.
- [20] M. Sarkar, I. Madabhavi, N. Niranjana, and M. Dogra, “Auscultation of the respiratory system,” *Ann. Thorac. Med.*, vol. 10, no. 3, p. 158, Jul. 2015, doi: 10.4103/1817-1737.160831.
- [21] F. P., “The functional basis of pulmonary sounds,” *Chest*, vol. 73, no. 3, pp. 399–405, 1978, doi: 10.1378/CHEST.73.3.399.
- [22] M. Munakata *et al.*, “Spectral and waveform characteristics of fine and coarse crackles,” *Thorax*, vol. 46, no. 9, pp. 651–657, Sep. 1991, doi: 10.1136/THX.46.9.651.
- [23] K. H. Y. M., H. S., I. Y., and T. K., “[Frequency analysis of crackles recorded with a stethoscope-equipped recorder],” *Nihon Kyobu Shikkan Gakkai Zasshi*, vol. 33, no. 12, pp. 1341–1347, 1995, Accessed: Sep. 06, 2021. [Online]. Available: <https://pubmed.ncbi.nlm.nih.gov/8821985/>.
- [24] R. X. A. Pramono, S. Bowyer, and E. Rodriguez-Villegas, “Automatic adventitious respiratory sound analysis: A systematic review,” *PLoS One*, vol. 12, no. 5, May 2017, doi: 10.1371/JOURNAL.PONE.0177926.
- [25] T. J. Marrie, Ed., “Community-Acquired Pneumonia,” 2001, doi: 10.1007/B111487.
- [26] “WHO | World Health Organization.” <https://www.who.int/> (accessed Sep. 30, 2021).

- [27] “Stetoskop - Vikipedi.” <https://tr.wikipedia.org/wiki/Stetoskop> (accessed Sep. 30, 2021).
- [28] S. A, “R T H Laënnec 1781--1826 his life and work: a bicentenary appreciation,” *Thorax*, vol. 36, no. 2, pp. 81–90, 1981, doi: 10.1136/THX.36.2.81.
- [29] K. P, “Laennec and the discovery of mediate auscultation,” *Am. J. Med.*, vol. 70, no. 2, pp. 275–278, 1981, doi: 10.1016/0002-9343(81)90762-2.
- [30] “(7) (PDF) Capturing and preprocessing of respiratory sounds.” [https://www.researchgate.net/publication/284698783\\_Capturing\\_and\\_preprocessing\\_of\\_respiratory\\_sounds](https://www.researchgate.net/publication/284698783_Capturing_and_preprocessing_of_respiratory_sounds) (accessed Aug. 18, 2021).
- [31] E. Arslan, “ANKARA ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ YÜKSEK LİSANS TEZİ MİKROŞERİT ALÇAK GEÇİREN FİLTRE TASARIMI VE ANALİZİ.”
- [32] A. E. Açoğlu, “Sayısal Süzgeç Tasarımı ve Uygulamaları, Yüksek Lisans Tezi,” pp. 1–126, 2008.
- [33] D. L. Donoho and I. M. Johnstone, “Adapting to unknown smoothness via wavelet shrinkage,” *J. Am. Stat. Assoc.*, vol. 90, no. 432, pp. 1200–1224, 1995, doi: 10.1080/01621459.1995.10476626.
- [34] P. S. Addison, “The illustrated wavelet transform handbook,” *Biomed. Instrum. Technol.*, p. 298, 2017, [Online]. Available: <https://lccn.loc.gov/2016033578>.
- [35] C. S. Burrus, “Introduction to Wavelets and Wavelet Transform—A Primer,” no. March, 2015.
- [36] M. Vetterli, S. Member, and C. Herley, “Wavelets and Filter Banks : Theory and Design,” vol. 40, no. 9, 1992.

- [37] S. BİLGİN, “Kalp hizi deęişkenlięinin dalgacık dönüşümü ve yapay sinir aęları kullanılarak analizi,” 2008.
- [38] A. Subasi, “EEG signal classification using wavelet feature extraction and a mixture of expert model,” *Expert Syst. Appl.*, vol. 32, no. 4, pp. 1084–1093, May 2007, doi: 10.1016/J.ESWA.2006.02.005.
- [39] İ. Volkan Öner, K. Yeşilyurt, and E. Ç. Yılmaz, “Wavelet Analiz Teknięi Ve Uygulama Alanları,” *Ordu Üniv. Bil. Tek. Derg.*, vol. 7, no. 1, pp. 42–56, 2017, [Online]. Available: <https://dergipark.org.tr/download/article-file/329350>.
- [40] S. Uysal, “SES ANALİZİ İLE HASTALIK TEŞHİSİ,” YILDIZ TEKNİK ÜNİVERSİTESİ, 2014.
- [41] “Standard Deviation: Simple Definition, Step by Step Video.” <https://www.statisticshowto.com/probability-and-statistics/standard-deviation/> (accessed Oct. 21, 2021).
- [42] “Variance Definition, Formula, & Calculation.” <https://www.investopedia.com/terms/v/variance.asp> (accessed Oct. 21, 2021).
- [43] S. Suthaharan, *Machine Learning Data Classification Algorithms for Big Models and Algorithms for Big Data Classification*. 2003.
- [44] “Makine Öğrenimi Bölüm-4 (Destek Vektör Makineleri) | by E. Kaan Ulgen | Medium.” <https://medium.com/@k.ulgen90/makine-ogrenimi-bolum-4-destek-vektor-makineleri-2f8010824054> (accessed Aug. 29, 2021).
- [45] “Nedir Bu Destek Vektör Makineleri? (Makine Öğrenmesi Serisi-2) | by Mehmet Fatih AKCA | Deep Learning Türkiye | Medium.” <https://medium.com/deep-learning-turkiye/nedir-bu-destek-vektor-makineleri-makine-ogrenmesi-serisi-2-94e576e4223e> (accessed Aug. 29, 2021).



- [46] D. Hand, H. Mannila, and P. Smyth, *Principles of Data Mining Cambridge*, vol. 2001. 2001.
- [47] “KNN (K nearest neighborhood, en yakın k komşu) – Bilgisayar Kavramları.” <http://bilgisayarkavramlari.com/2008/11/17/knn-k-nearest-neighborhood-en-yakin-k-komsu/?highlight=knn> (accessed Aug. 30, 2021).
- [48] J. Han, M. Kamber, and J. Pei, *Getting to Know Your Data*. 2012.
- [49] I. Jolliffe, B. S. Everitt, and D. C. Howell, “Principal Component Analysis.”
- [50] Işıl Yazar, “Temel Bileşen Analizi ve Bağımsız Bileşen Analizi Yöntemlerini Temel Alan Bazı Görüntü Tanıma Uygulamaları ve Karşılaştırmaları,” 2008.
- [51] “Hata Matrisini (Confusion Matrix) Yorumlama - Veri Bilimi Okulu - Veri Bilimi Okulu.” <https://www.veribilimiokulu.com/hata-matrisini-confusion-matrix-yorumlama/> (accessed Sep. 09, 2021).

## EKLER

### DVM ile “Normal-anormal” sınıflandırma örneği

```
clc;
clear all;
[veri fs]=audioread('1.wav');
hastalik_turu={'Anormal'};
veri=veri-mean(veri);
N = 10;
Fpass1 = 100;
Fpass2 = 2000;
Apass = 1
Astop = 80;
h = fdesign.bandpass('N,Fp1,Fp2,Ast1,Ap,Ast2', N, Fpass1, Fpass2, ...
    Astop, Apass, Astop, fs);
Hd = design(h, 'ellip');
display(Hd)
filtrelenmis_veri = filter(Hd,veri);

[c,l] = wavedec(filtrelenmis_veri ,7,'db7');
approx = appcoef(c,l,'db7');
[cd1,cd2,cd3,cd4,cd5,cd6,cd7] = detcoef(c,l,[1 2 3 4 5 6 7]);
lev = 7;
wname = 'db7';
dsig3 = wden(cd3,'rigrsure','h','mln',lev,wname);
dsig4 = wden(cd4,'rigrsure','h','mln',lev,wname);
dsig5 = wden(cd5,'rigrsure','h','mln',lev,wname);
```

```
dsig6 = wden(cd6,'rigrsure','h','mln',lev,wname);
```

```
%%Her bir alt bandın mutlak maksimum değeri alınır
```

```
maks3=max(abs(dsig3));
```

```
maks4=max(abs(dsig4));
```

```
maks5=max(abs(dsig5));
```

```
maks6=max(abs(dsig6));
```

```
%%Her bir alt bandın standart sapması
```

```
st3=std(dsig3);
```

```
st4=std(dsig4);
```

```
st5=std(dsig5);
```

```
st6=std(dsig6);
```

```
%%Her bir alt bandın varyansı
```

```
var3=var(dsig3);
```

```
var4=var(dsig4);
```

```
var5=var(dsig5);
```

```
var6=var(dsig6);
```

```
%%Komşu alt bantların oranı için D3-D7 aralığındaki her alt bandın mutlak
```

```
% değerinin ortalaması alınmış ve bu alt bantların her biri kendisine komşu olan alt  
banda
```

```
% bölünerek öznitelikler elde edilmiştir
```

```
abs3=mean(abs(dsig3));
```

```
abs4=mean(abs(dsig4));
```

```
abs5=mean(abs(dsig5));
```

```
abs6=mean(abs(dsig6));
```

```
o1=abs3/abs4;
```

```
o2=abs3/abs5;
```

```
o3=abs3/abs6;
```

```
o4=abs4/abs3;
```

```
o5=abs4/abs5;
```

```
o6=abs4/abs6;
```

```
o7=abs5/abs3;
```

```
o8=abs5/abs4;
```

```
o9=abs5/abs6;
```

```
o10=abs6/abs3;
```

```
o11=abs6/abs4;
```

```
o12=abs6/abs5;
```

```
%Welch metodu ile güç spektrum yoğunluğu (PSD)
```

```
pxx = pwelch(filtrelenmis_veri,256,128,256,'onesided','power');
```

```
psd_katsayi=10*log10(pxx);
```

```
% Öznitelik çıkarımı
```

```
enerji=sum(abs(psd_katsayi).^2)
```

```
entropi=-sum(psd_katsayi.*log2(psd_katsayi))
```

```
stdsapma=std(psd_katsayi)
```

```
ortalama=sum(psd_katsayi)/length(psd_katsayi)
```

```
enkucuk=min(psd_katsayi)
```

```
enbuyuk=max(psd_katsayi)
```

```
carpiklik=skewness(psd_katsayi)
```

```
basiklik=kurtosis(psd_katsayi)
```

```

power=rms(psd_katsayi);

%Verilerin yazdırılması
i=2;
row_header(i,1)=hastalik_turu;
row_header(i-1,1)={'tani'}

data=[maks3,maks4,maks5,maks6,st3,st4,st5,st6,var3,var4,var5,var6,o1,o2,o3,o4,o5,
o6,o7,o8,o9,o10,o11,o12,power,enerji,entropi,stdsapma,ortalama,enkucuk,enbuyuk,c
arpiklik,basiklik]

col_header={'maks3','maks4','maks5','maks6','st3','st4','st5','st6','var3','var4','var5','var
6','o1','o2','o3','o4','o5','o6','o7','o8','o9','o10','o11','o12','power','enerji','entropi','stdsap
ma','ortalama','enkucuk','enbuyuk','egrilik','basiklik'};

xlswrite('normal_anormal_test.xlsx',data,'Sayfa1',['B' num2str(i)] );
xlswrite('normal_anormal_test.xlsx',col_header,'Sayfa1','B1');
xlswrite('normal_anormal_test.xlsx',row_header,'Sayfa1','A1');

egitim=readtable('eliptik_normal_anormal_egitim.xlsx');
test=readtable('normal_anormal_test.xlsx');
t= templateSVM('Standardize',true,'KernelFunction','linear');
Mdl = fitcecoc(egitim,'tani','Learners',t,...
'Coding','onevsone','ClassNames',{'Anormal','Normal'});

cvp = cvpartition(height(egitim),'Kfold',5);
cross_validated_model = crossval(Mdl,'cvpartition',cvp);
Predictions1= predict(cross_validated_model.Trained{1},test);
tahmin=predict(Mdl,test);
dogrudur=strcmp(tahmin,test.tani)

```

```
accuracy=sum(dogrudur)/numel(dogrudur)
figure
cm=confusionchart(test.tani,tahmin)
cm.Title='Eliptik filtre kullanarak DVM ile normal-anormal ayrımı';
```

### **DVM ile “Pnömoni Var veya Yok” Sınıflandırma Örneği**

```
clc;
clear all;
[veri fs]=audioread('p35.wav');
hastalik_turu={'Pnömoni Var'};
veri=veri-mean(veri);

N = 10;
Fpass1 = 100;
Fpass2 = 2000;
Apass = 1;
Astop = 80; h = fdesign.bandpass('N,Fp1,Fp2,Ast1,Ap,Ast2', N, Fpass1, Fpass2,
...Astop, Apass, Astop, fs);
Hd = design(h, 'ellip');
display(Hd)
filtrelenmis_veri = filter(Hd,veri);

[c,l] = wavedec(filtrelenmis_veri ,7,'db7');
approx = appcoef(c,l,'db7');
[cd1,cd2,cd3,cd4,cd5,cd6,cd7] = detcoef(c,l,[1 2 3 4 5 6 7]);
lev = 7;
wname = 'db7';
```

```
dsig3 = wden(cd3,'rigrsure','h','mln',lev,wname);  
dsig4 = wden(cd4,'rigrsure','h','mln',lev,wname);  
dsig5 = wden(cd5,'rigrsure','h','mln',lev,wname);  
dsig6 = wden(cd6,'rigrsure','h','mln',lev,wname);
```

```
maks3=max(abs(dsig3));  
maks4=max(abs(dsig4));  
maks5=max(abs(dsig5));  
maks6=max(abs(dsig6));
```

```
st3=std(dsig3);  
st4=std(dsig4);  
st5=std(dsig5);  
st6=std(dsig6);
```

```
var3=var(dsig3);  
var4=var(dsig4);  
var5=var(dsig5);  
var6=var(dsig6);
```

```
abs3=mean(abs(dsig3));  
abs4=mean(abs(dsig4));  
abs5=mean(abs(dsig5));  
abs6=mean(abs(dsig6));
```

```
o1=abs3/abs4;  
o2=abs3/abs5;
```

```

o3=abs3/abs6;
o4=abs4/abs3;
o5=abs4/abs5;
o6=abs4/abs6;
o7=abs5/abs3;
o8=abs5/abs4;
o9=abs5/abs6;
o10=abs6/abs3;
o11=abs6/abs4;
o12=abs6/abs5;

pxx = pwelch(filtrelenmis_veri,256,128,256,'onesided','power');
psd_katsayi=10*log10(pxx);

entropi=-sum(psd_katsayi.*log2(psd_katsayi))
ortalama=sum(psd_katsayi)/length(psd_katsayi)
enkucuk=min(psd_katsayi)
enbuyuk=max(psd_katsayi)

i=2;
row_header(i,1)=hastalik_turu;
row_header(i-1,1)={'tani'}

data=[maks3,maks4,maks5,maks6,st3,st4,st5,st6,var3,var4,var5,var6,o1,o2,o3,o4,o5,
o6,o7,o8,o9,o10,o11,o12,entropi,ortalama,enkucuk,enbuyuk]

col_header={'maks3','maks4','maks5','maks6','st3','st4','st5','st6','var3','var4','var5','var
6','o1','o2','o3','o4','o5','o6','o7','o8','o9','o10','o11','o12','entropi','ortalama','enkucuk','e
nbuyuk'};

```



```

xlswrite('pnömoni_test.xlsx',data,'Sayfa1',['B' num2str(i)] );
xlswrite('pnömoni_test.xlsx',col_header,'Sayfa1','B1');
xlswrite('pnömoni_test.xlsx',row_header,'Sayfa1','A1');
egitim=readtable('eliptik_pnömoni_egitim.xlsx');
test=readtable('pnömoni_test.xlsx');

t = templateSVM('Standardize',true,'KernelFunction','linear');
Mdl = fitcecoc(egitim,'tani','Learners',t,...
    'Coding','onevsone','ClassNames',{'Pnömoni Var','Pnömoni Yok'});
cvp = cvpartition(height(egitim),'Kfold',5)
cross_validated_model = crossval(Mdl,'cvpartition',cvp);
Predictions= predict(cross_validated_model.Trained{1},test);
tahmin=predict(Mdl,test);
dogrudur=strcmp(tahmin,test.tani)
accuracy=sum(dogrudur)/numel(dogrudur)
figure
cm=confusionchart(test.tani,tahmin)
cm.Title='Eliptik filtre kullanarak DVM ile pnömoni ayrımı';

```