

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**TEK KANALLI YAYGIN AKCIĞER SESLERİNDEN SOLUNUM
DÖNGÜLERİNİN OTOMATİK ALGILANMASI VE SINIFLANDIRILMASI**

DOKTORA TEZİ

Elektronik Yük. Müh. Selim ARAS

**MART 2018
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

TEK KANALLI YAYGIN AKCİĞER SESLERİNDEN SOLUNUM
DÖNGÜLERİNİN OTOMATİK ALGILANMASI VE SINIFLANDIRILMASI

Elektronik Yüksek Müh. Selim ARAS

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (ELEKTRONİK MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih :14/02/2018
Tezin Savunma Tarihi :08/03/2018

Tez Danışmanı : Prof. Dr. Ali GANGAL

Trabzon 2018

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik-Elektronik Mühendisliği Anabilim Dalında
Selim ARAS Tarafından Hazırlanan

TEK KANALLI YAYGIN AKCİĞER SESLERİNDEN SOLUNUM DÖNGÜLERİNİN
OTOMATİK ALGILANMASI VE SINIFLANDIRILMASI

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 20 /02 /2018 gün ve 1741 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
DOKTORA TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. İnan GÜLER

Üye : Prof. Dr. Temel KAYIKÇIOĞLU

Üye : Prof. Dr. Ali GANGAL

Üye : Prof. Dr. Cemal KÖSE

Üye : Doç. Dr. Burhan ERGEN

inan guler
Temel Kayikcioglu
Ali Gangal
Cemal Kose
Burhan Ergen

Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

ÖNSÖZ

Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik–Elektronik Mühendisliği Anabilim Dalı, Doktora Programı çerçevesinde hazırlanmış olan bu tezde, oskültasyon prosedürüne uygun olarak tek kanallı kaydedilen akciğer seslerinden, solunum döngülerinin otomatik olarak algılanması ve sınıflandırılması için literatürde ilk kez bir yöntem önerilmiştir. Geliştirilen yöntem sayesinde, tek kanallı akciğer sesleri için sınıflandırma çalışmalarının otomatik bir şekilde gerçekleştirilmesi mümkün hale getirilmiştir. Ayrıca bu tez çalışmasında geliştirilen yöntem sayesinde, tek kanallı akciğer seslerinin gerçek zamanlı olarak sınıflandırılma uygulamaları üzerine yapılacak çalışmaların önü açılmıştır.

Bu doktora tezi, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TUBİTAK) 116E003 nolu proje desteği ve Trabzon Klinik Araştırmalar Etik Kurul Başkanlığı'nın 30.04.2015 tarih ve 24237859-293 sayı numaralı izni ile gerçekleştirilmiştir.

Tez çalışmam süresince bilimsel desteği ve değerli düşünceleriyle bana her aşamada yardımcı olan danışmanım Sayın Prof. Dr. Ali GANGAL'a, jüri olarak katkılarını sunan değerli hocalarım Prof. Dr. Temel KAYIKÇIOĞLU'na ve Prof. Dr. Cemal KÖSE'ye, akciğer ses kayıtlarının toplanması aşamasında özverili çalışmaları nedeniyle Prof. Dr. Yılmaz BÜLBÜL'e teşekkürlerimi sunmak isterim. Bugüne kadar değerli vakitlerinden çaldığım en büyük destekçim olan aileme de teşekkürlerimi ve şükranlarımı sunarım.

Bu tezin, tek kanallı akciğer sesleri için bundan sonra yapılacak otomatik sınıflandırma ve gerçek zamanlı çalışmaların temelini oluşturacağına inanıyor ve konu hakkında çalışan diğer araştırmacılara katkıda bulunmasını temenni ediyorum.

Selim ARAS

Trabzon 2018

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum “Tek Kanallı Yaygın Akciđer Seslerinden Solunum Döngülerinin Otomatik Algılanması ve Sınıflandırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Ali GANGAL’ın sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, başka kaynaklardan aldıđım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdıđimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 08/03/2018.

Selim ARAS

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	X
SEMBOLLER DİZİNİ	XI
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Solunum Sisteminin Yapısı	2
1.3. Akciğer Oskültasyonu	4
1.4. Solunum Sesleri	4
1.4.1. Normal Solunum Sesleri.....	4
1.4.1. Anormal Solunum Sesleri.....	5
1.5. Otomatik Akciğer Ses Tanıma Yönteminin Bileşenleri	6
1.5.1. Akciğer Ses Sinyallerinin Kaydedilmesi	6
1.5.2. Önışleme	7
1.5.3. Akciğer Ses Sinyallerinden Solunum Döngülerinin Ayrıştırılması	8
1.5.4. Solunum Döngülerinden Veri Setlerinin Oluşturulması.....	8
1.5.5. Öznitelik Çıkarma.....	8
1.5.6. Temel Bileşen Analizi	9
1.5.7. Sınıflandırma	9
1.6. Literatür Araştırması.....	9
1.7. Tezin Kapsamı	21
2. YAPILAN ÇALIŞMALAR.....	23
2.1. Materyal.....	23
2.1.1. Kullanılan Kayıt Cihazı	23
2.2. Yöntem	24

2.2.1.	Otomatik Akciğer Oskültasyon Yöntemi	24
2.2.1.1.	Akciğer Ses Sinyallerinin Kaydedilmesi	24
2.2.1.2.	Önişleme	26
2.2.1.3.	Akciğer Seslerinden Solunum Döngülerinin Ayrıştırılması.....	28
2.2.1.4.	Solunum Döngülerinden Veri Setlerinin Oluşturulması.....	32
2.2.1.4.1.	Kullanılan Öznitelik Çıkarma Yöntemleri.....	35
2.2.1.4.2.	Zaman Bölgesi Parametreleri	38
2.2.1.4.3.	Frekans Bölgesi Parametreleri.....	41
2.2.1.4.4.	Mel Frekansı Kepstrum Katsayıları.....	42
2.2.1.4.5.	Doğrusal Öngörülü Kodlama.....	45
2.2.1.4.6.	İstatistiksel Öznitelikler	50
2.2.1.4.7.	Temel Bileşen Analizi	51
2.2.1.5.	Sınıflandırma	52
2.2.1.5.1.	Doğrusal Ayırma Ayırıcı	53
2.2.1.5.2.	Destek Vektör Makineleri.....	55
2.2.1.5.3.	Naive Bayes	58
2.2.1.5.4.	k-En Yakın Komşuluk Yöntemi	60
2.2.1.6.	Ardışıl İleri Yönlü Öznitelik Seçme yöntemi.....	61
3.	BULGULAR.....	62
3.1.	Akciğer Seslerinden Solunum Döngülerinin Ayrıştırılması Bulguları.....	62
3.2.	Öznitelik Parametreleri	65
3.3.	Tam Solunum Döngüsü Seslerinin Sağlıklı/Patolojik Akciğer Sesleri İçin Sınıflandırma Bulguları	66
3.4.	Tam Solunum Döngüsü Seslerinin Yaygın Akciğer Sesleri İçin Sınıflandırma Bulguları	69
3.5.	İnspirasyon Seslerinin Sağlıklı/Patolojik Akciğer Sesleri İçin Sınıflandırma Bulguları	72
3.6.	İnspirasyon Seslerinin Yaygın Akciğer Sesleri İçin Sınıflandırma Bulguları..	75
3.7.	Ekspirasyon Seslerinin Sağlıklı/Patolojik Akciğer Sesleri İçin Sınıflandırma Bulguları	78
3.8.	Ekspirasyon Seslerinin Yaygın Akciğer Sesleri İçin Sınıflandırma Bulguları.	81
4.	SONUÇLAR.....	84
5.	ÖNERİLER VE TARTIŞMA.....	89
6.	KAYNAKLAR	93

ÖZGEÇMİŞ

Doktora Tezi

ÖZET

TEK KANALLI YAYGIN AKCİĞER SESLERİNDEN SOLUNUM DÖNGÜLERİNİN
OTOMATİK ALGILANMASI VE SINIFLANDIRILMASI

Selim ARAS

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik–Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Ali GANGAL
2018, 102 Sayfa

Akciğer seslerinin stetoskop ile dinlenilmesi (oskültasyon) yöntemi, akciğer hastalıklarının ön teşhisi için kullanılan non-invaziv bir yöntemdir. Son yıllarda geliştirilen elektronik stetoskoplar sayesinde, bu seslerin analizi ve tanınması üzerine çalışmalar yapılabilmektedir. Konu üzerine birçok çalışma yapılmış olmasına rağmen, çalışmaların belirli bir standardizasyona sahip olmaması nedeniyle sonuçların karşılaştırılmasında sorunlar yaşanmış ve günümüze kadar akciğer seslerini otomatik olarak tanıyan bir ürün henüz geliştirilememiştir. Bu çalışmada belirli bir standart yakalamak amacıyla akciğer sesleri, oskültasyon prosedürüne uygun olan bir yöntemle tek kanallı olarak kaydedilmiştir. Tek kanallı akciğer seslerinden solunum döngülerini otomatik olarak algılayan yeni bir yöntem geliştirilmiştir. Literatürde ilk kez sunulan bu yöntem sayesinde otomatik algılanan solunum döngülerinden, sağlıklı/patolojik ve yaygın akciğer seslerinden oluşan veri setleri de otomatik olarak oluşturulmuştur. Veri setleri üzerinde geniş kapsamlı bir öznitelik araştırması yapılmış ve sınıflandırma aşamasında da dört farklı sınıflandırma yöntemi kullanılmıştır. Sonuçlar Ardışıl İleri Yönlü Öznitelik Seçim Yöntemiyle geliştirilmiş ve başarımları artırılmıştır. Sonuç olarak Sağlıklı/patolojik akciğer sesleri için $97,68 \pm 0,75$, yaygın akciğer sesleri için ise $87,61 \pm 1,67$ sınıflandırma doğruluğu elde edilmiştir.

Anahtar Kelimeler: Akciğer sesleri, Solunum döngüsü, Örüntü tanıma, Öznitelik çıkarma, Sınıflandırma, Ardışıl ileri yönlü öznitelik seçim yöntemi

PhD. Thesis

SUMMARY

AUTOMATIC DETECTION AND CLASSIFICATION OF RESPIRATORY CYCLES
FROM COMMON LUNG SOUNDS in SINGLE CHANNEL

Selim ARAS

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program
Supervisor: Prof. Dr. Ali GANGAL
2018, 102 Pages

Listening to lung sounds with a stethoscope (auscultation) is a non-invasive method used for the preliminary diagnosis of lung diseases. Thanks to electronic stethoscopes developed in recent years, it is possible to work on the analysis and recognition of these sounds. Although a lot of work has been done on the subject, problems have been encountered in comparing the results due to the lack of standardization of the studies, and a product that automatically recognizes lung sounds is not yet developed yet. To be able to establish a specific standard in the field, lung sounds were recorded in a way appropriate for the auscultation procedure in single channel. A new method has been developed that automatically detects respiratory cycles from single-channel lung sounds. With this method, which is presented for the first time in the literature, data sets consisting of healthy/pathological and common lung sounds are generated automatically from the automatically detected respiratory cycles. A comprehensive search of discriminative features has been performed on the data sets and four different classification methods have been used in the classification phase. The results were improved by Sequential Advanced Directional Feature Selection and performance was improved. As a result, a classification accuracy of $97,68 \pm 0,75$ for healthy/pathological lung sounds and $87.61 \pm 1.67\%$ for common lung sounds were obtained.

Key Words: Lung sounds, Respiratory cycle, Pattern recognition, Feature extraction, Classification, Sequential forward feature selection method

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Akciğerler ve solunum yolları [6]	3
Şekil 2. Yaygın olarak duyulan akciğer sesleri [7].....	4
Şekil 3. Otomatik akciğer ses tanıma yönteminin bileşenleri	7
Şekil 4. Çok kanallı kayıt yöntemleri	11
Şekil 5. Tek kanallı kayıt yöntemleri.....	12
Şekil 6. Kayıt alımında kullanılan elektronik stetoskop ve ses kayıt cihazı.....	23
Şekil 7. Akciğer oskültasyonda izlenen sıra [74]; A, Akciğerlerin arkadan görünümü. B, Akciğerlerin önden görünümü. C, Akciğerlerin yandan görünümü.....	25
Şekil 8. Frotman sesi için önışleme süreci örneđi	27
Şekil 9. Model ve test paternlerinin belirlenmesi	28
Şekil 10. Kullanılan özniteliklerin elde edilış süreci.....	36
Şekil 11. (a) 32ms uzunluklu akciğer ses çerçevesi, (b) 32ms uzunluğunda Hamming penceresi, (c) Akciğer ses işaretinin pencere fonksiyonu uygulanmış hali	38
Şekil 12. Bir öznitelik matrisinden istatistiksel parametrelerin hesaplanması	39
Şekil 13. Frekans ve Mel skalası arasındaki iliřki.....	43
Şekil 14. MFKK hesaplama süreci akış diyagramı	44
Şekil 15. Sınıflandırma sürecinin akış şeması	54
Şekil 16. (a) İki sınıflı bir problem için hiper-düzlemler, (b) Optimum hiper-düzlem ve destek vektörleri.....	56
Şekil 17. Doğrusal olarak ayrılamayan iki sınıflı problem örneđi	58
Şekil 18. k-EYK sınıflandırma yöntemi için bir örnek	61
Şekil 19. Ardışıl ileri yönlü öznitelik seçme (AİYÖS) yönteminin akış şeması.....	62
Şekil 20. Yedi farklı akciğer ses örneğinden otomatik olarak algılanan solunum döngüleri	64
Şekil 21. Otomatik solunum döngüsü algılama yöntemi sonuçlarının istatistiksel özeti	85

TABLULAR DİZİNİ

Sayfa No

Tablo 1. Sağlıklı/patolojik akciğer sesleri için tam solunum döngülerinden oluşturulan veri seti-2'nin içerdiği sesler.....	33
Tablo 2. Yaygın akciğer sesleri için tam solunum döngülerinden oluşturulan veri seti-3'ün içerdiği sesler	33
Tablo 3. Sağlıklı/patolojik akciğer sesleri için inspirasyon seslerinden oluşturulan veri seti-4'ün içerdiği sesler.....	34
Tablo 4. Yaygın akciğer sesleri için inspirasyon seslerinden oluşturulan veri seti-5'in içerdiği sesler	34
Tablo 5. Sağlıklı/patolojik akciğer sesleri için ekspirasyon seslerinden oluşturulan veri seti-6'nın içerdiği sesler	35
Tablo 6. Yaygın akciğer sesleri için ekspirasyon seslerinden oluşturulan veri seti-7'nin içerdiği sesler	35
Tablo 7. Otomatik solunum döngüsü belirleme algoritmasının istatistiksel sonuçları	65
Tablo 8. Türetilen öznitelikler ve kısa adları.....	66
Tablo 9. Tam solunum döngülerinden elde edilen sağlıklı/patolojik akciğer ses sınıflandırma bulguları (%)	68
Tablo 10. Tam solunum döngülerinden elde edilen yaygın akciğer ses sınıflandırma bulguları (%).....	71
Tablo 11. İspirasyon seslerinden elde edilen sağlıklı/patolojik akciğer ses sınıflandırma bulguları (%)	74
Tablo 12. İspirasyon seslerinden elde edilen yaygın akciğer ses sınıflandırma bulguları (%).....	77
Tablo 13. Ekspirasyon seslerinden elde edilen sağlıklı/patolojik akciğer ses sınıflandırma bulguları (%)	80
Tablo 14. Ekspirasyon seslerinden elde edilen yaygın akciğer ses sınıflandırma bulguları (%).....	83
Tablo 15. Sağlıklı/Patolojik akciğer seslerinin sınıflandırma sonuçları.....	86
Tablo 16. Yaygın Akciğer seslerinin sınıflandırma sonuçları.....	88
Tablo 17. Akciğer seslerinden nefes döngülerinin otomatik olarak algılanması ve sınıflandırılması yönteminin kısa sonuç özeti.....	89
Tablo 18. Önerilen yöntem ile literatürdeki çalışmaların (özet) karşılaştırılması.....	92

SEMBOLLER DİZİNİ

bM_L^i	: i . modelin alt sınır indeksi
bM_U^i	: i . modelin üst sınır indeksi
$bt_L^{i,r}$: i . model ile karşılaştırmak için seçilen test paterninin alt sınır indeksi
$bt_U^{i,p}$: i . model ile karşılaştırmak için seçilen test paterninin üst sınır indeksi
C_i	: Spektral Merkez
$M_i[n]$: i . model için seçilen patern
$T_{i,p}[n]$: i . model ile karşılaştırmak için seçilen p . test paterni
DAA	: Doğrusal Ayırma Ayırıcı
DÖK	: Doğrusal Öngörü Katsayıları
DVM	: Destek Vektör Makineleri
DZB	: Dinamik Zaman Bükme Algoritması
GKM	: Gauss Karışım Modeli
$f1$: Zaman bölgesinden türetilen özneliklerin minimum değeri
$f2$: Zaman bölgesinden türetilen özneliklerin maksimum değeri
$f3$: Zaman bölgesinden türetilen özneliklerin aritmetik ortalaması
$f4$: Zaman bölgesinden türetilen özneliklerin standart sapması
$f5$: Zaman bölgesinden türetilen özneliklerin varyansı
$f6$: Zaman bölgesinden türetilen özneliklerin çarpıklık değeri
$f7$: Zaman bölgesinden türetilen özneliklerin basıklık değeri
$f8$: Zaman bölgesinden türetilen özneliklerin ortanca değeri
$f9$: Frekans bölgesinden türetilen özneliklerin minimum değeri
$f10$: Frekans bölgesinden türetilen özneliklerin maksimum değeri
$f11$: Frekans bölgesinden türetilen özneliklerin aritmetik ortalaması
$f12$: Frekans bölgesinden türetilen özneliklerin standart sapması
$f13$: Frekans bölgesinden türetilen özneliklerin varyansı

f_{14}	: Frekans bölgesinden türetilen özniteliklerin çarpıklık değeri
f_{15}	: Frekans bölgesinden türetilen özniteliklerin basıklık değeri
f_{16}	: Frekans bölgesinden türetilen özniteliklerin ortanca değeri
f_{17}	: MFKK'dan türetilen türetilen özniteliklerin minimum değeri
f_{18}	: MFKK'dan türetilen türetilen özniteliklerin maksimum değeri
f_{19}	: MFKK'dan türetilen türetilen özniteliklerin aritmetik ortalaması
f_{20}	: MFKK'dan türetilen türetilen özniteliklerin standart sapması
f_{21}	: MFKK'dan türetilen türetilen özniteliklerin varyansı
f_{22}	: MFKK'dan türetilen türetilen özniteliklerin çarpıklık değeri
f_{23}	: MFKK'dan türetilen türetilen özniteliklerin basıklık değeri
f_{24}	: MFKK'dan türetilen türetilen özniteliklerin ortanca değeri
f_{25}	: DÖK'den türetilen türetilen özniteliklerin minimum değeri
f_{26}	: DÖK'den türetilen türetilen özniteliklerin maksimum değeri
f_{27}	: DÖK'den türetilen türetilen özniteliklerin aritmetik ortalaması
f_{28}	: DÖK'den türetilen türetilen özniteliklerin standart sapması
f_{29}	: DÖK'den türetilen türetilen özniteliklerin varyansı
f_{30}	: DÖK'den türetilen türetilen özniteliklerin çarpıklık değeri
f_{31}	: DÖK'den türetilen türetilen özniteliklerin basıklık değeri
f_{32}	: DÖK'den türetilen türetilen özniteliklerin ortanca değeri
H_E	: Etkinlik parametresi
H_K	: Karmaşıklık parametresi
H_H	: Hareketlilik parametresi
H_i	: Enerjinin entropisi
K	: Basıklık değeri
k-EYK	: k-En Yakın Komşuluk
KOAH	: Kronik Obstrüktif Akciğer Hastalığı
KZFD	: Kısa Zamanlı Fourier Dönüşümü
MFKK	: Mel Frekanslı Kepstrum Katsayıları
NB	: Naive Bayes
sgn	: Signum fonksiyonu
SGO	: Sıfır Geçiş Oranı
YSA	: Yapay Sinir Ağı

σ	: Standart sapma
σ^2	: Varyans
\bar{x}	: Aritmetik ortalama
S	: Çarpıklık değeri
S_i	: Spektral yayılım
ϕ_c	: Mel ölçeğindeki merkez frekans



1. GENEL BİLGİLER

1.1. Giriş

Akciğer sesleri, nefes alış verişi sırasında hava basıncının hızlı bir şekilde değişmesine bağlı olarak iç dokularda oluşan titreşimler nedeniyle ortaya çıkar ve göğüs duvarının titreşimiyle belirginleşir [1]. Fakat bu sesler göğüs duvarına zayıflayarak ulaştığından, sesleri duymak oldukça zorlaşır. Dolayısıyla, akciğer seslerinin çok azı herhangi bir dinleme yöntemi kullanılmadan dışarıdan insan kulağıyla duyulabilmektedir. Oskültasyon, akciğer seslerinin dinlenilmesi tekniğidir ve akciğer hastalıkları için önemli bilgiler verir. Oskültasyon, stetoskobun icadından bu yana yaklaşık 200 yıldır stetoskop yardımıyla gerçekleştirilmektedir. Stetoskobun icadından önce ise oskültasyon, kulağın direk olarak hastanın vücuduna dayandırılarak yapılıyordu. Anlaşıldığı üzere oskültasyon, çok eski dönemlerden bu yana olduğu gibi günümüzde kullanılan ve halen akciğer hastalıklarının teşhisinde ilk olarak başvurulan ön teşhis yöntemidir.

Oskültasyon, göğüs hastalıklarının ön teşhisinde önemli bulgular verebilmektedir. Fakat akciğer seslerinin doğru bir şekilde yorumlanabilmesi oskültasyonu yapan doktorun duyma yeteneğine, eğitimine ve bu alandaki tecrübe birikimine bağlıdır. Günümüzde lisans derecesini yeni almış doktorlar yaygın olarak duyulan akciğer seslerini bile tanımlamada zorlanmaktadırlar. Hatta Amerika Birleşik Devletleri'ndeki sağlık çalışanlarıyla yapılan bir araştırmada, iç hastalıkları uzmanının ve aile hekimlerinin bir dizi akciğer ses kaydından yalnızca wheeze sesinin yaklaşık %80'ini tespit edebildikleri [2] bildirilmiştir. Ayrıca eğitilmiş doktorların daha az yetiştirildiği gelişmekte olan ülkelerde, oskültasyon doğruluğunun çok daha kötü olması, yanlış tanı almış ve tanısı konmamış akciğer hastalıklarına yol açtığı bildirilmiştir [3,4]. Bu sorun, teşhisi geciktirmekte, hasta sevklerini artırmakta, hem hastaya hem de milli sağlık sistemine fazladan yükler getirmektedir. En önemlisi de tedavi için zaman kaybına neden olmaktadır. Oskültasyondaki başarının, oskültasyonu yapan kişinin bireysel yeteneklerine bağlı olması oskültasyonun başarısında kişilerarası ortak bir standart yakalamayı zorlaştırır. Akciğer oskültasyonunda kişilerden bağımsız bir standart yakalamak ise ancak oskültasyon yapabilme yeteneğine sahip bir cihaz geliştirmekle mümkündür. Son yıllarda geliştirilen elektronik stetoskopların akıllı stetoskoplara dönüştürülmesiyle ve çeşitli bilgisayar analizleri yardımıyla akciğer seslerini otomatik

olarak algılama potansiyeline sahip olacağı yaygın bir görüştür. Günümüzde elektronik stetoskoplar aktif olarak genellikle duyulması zor akciğer seslerini yükseltmek amacıyla, duyma kaybı yaşayan doktorlara yardımcı olması amacıyla veya kayıt imkânları sayesinde hekimlerin eğitimi amacıyla kullanılmaktadır. Ancak, hâlihazırda geliştirilmiş olan elektronik stetoskoplar henüz akciğer seslerini otomatik teşhis etme yeteneğine sahip değildir. Bu tez çalışmasının amaçlarından birisi de bu yeteneğe katkıda bulunmaktır.


Akciğer seslerinin otomatik tanınması üzerine yapılmış çalışmalarda ağırlıklı olarak çok kanallı kayıt yöntemleri kullanılmıştır. Tek kanallı kayıt yöntemleri ile yapılan çalışmaların sayısı ise çok kanallı kayıt yöntemi kullanan çalışmalara oranla oldukça azdır. Geçmişte birçok değerli çalışma yapılmış olmasına rağmen, bu çalışmaların sonuçları, standardizasyon farklılıkları nedeniyle ortak bir platformda karşılaştırılamamaktadır. Ancak, özetle; tek kanallı akciğer ses kayıt yöntemlerinin oskültasyon prosedürüne daha uygun olduğu, dolayısıyla başarılı bir oskültasyon yeteneğine sahip yöntem geliştirebilmek için literatürde tek kanallı kayıt sistemi üzerine yapılacak çalışmalara daha fazla ihtiyaç duyulduğu söylenebilir. Bu yüzden bu tez çalışmasında tek kanallı kayıt yöntemi kullanılmıştır.

Bu tez çalışmasının temel amacı, oskültasyon prosedürüne uygun, tek kanallı kayıt yöntemlerine yönelik olarak, akciğer seslerini otomatik tanıyacak bir yöntem geliştirmektir. Bu amaçla çalışmamızda öncelikle akciğer ses kayıtlarından solunum döngülerinin manuel yardım olmadan otomatik algılanması hususunda tek kanallı kayıt yöntemleri için önemli bir metot geliştirilmiştir. Bu metot ile akciğer ses kayıtlarından solunum döngüleri otomatik algılanarak veri setleri oluşturulmuştur. Oluşturulan veri setleri üzerinde geniş bir öznitelik ve sınıflandırma yöntemi araştırması yapılmıştır. Önce hastalıklı/sağlıklı sesleri, daha sonra ise yaygın akciğer seslerini sınıflandırma çalışmaları yapılmıştır. Sonuçta tek kanallı olarak otomatik oskültasyon yapabilen bir yöntem geliştirilmiştir.

1.2. Solunum Sisteminin Yapısı

İnsan vücudundaki hücreler sürekli olarak oksijen akışına ihtiyaç duyarlar. Çünkü metabolik gereksinimlerini sağlayabilmek ve canlı kalabilmek için oksijene ihtiyaçları vardır. Akciğerler, vücudun hücrelerine oksijen sağlarken, aynı zamanda hücresel metabolizmanın ölümcül olabilecek bir artığı olan karbondioksitin de vücuttan dışarı

atılmasını sağlamaktadır. Aslında bu işlev, nefes alınmasına yardımcı inspiratuar kasların kasılması, havanın trakea ve bronşlardan akciğer alveollerine akımı ile sonuçlanan, karmaşık bir süreç aracılığıyla gerçekleşir. Burada alveoler hava ile akciğer kılcal kanı, aradaki ince bir zarla çok yakın temas halindedir. Oksijen zardan kana yayılırken karbondioksit ise aksi yönde geçer [5]. Böylece solunum gerçekleştirilmiş olur. Akciğerler ve solunum yolları Şekil-1’de gösterilmektedir.



Şekil 1. Akciğerler ve solunum yolları [6]

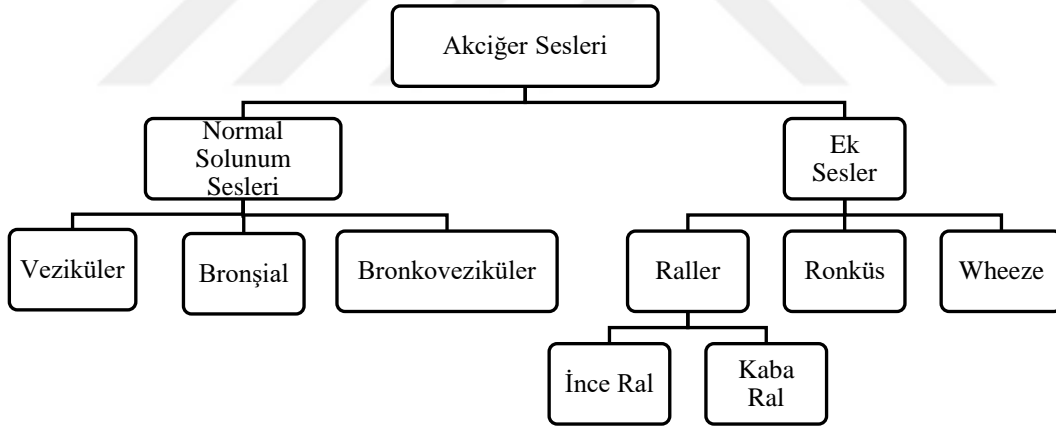
Vücutta gaz değişimi öncelikle hava yolları üzerinden sağlanır. Ağız veya burun yoluyla vücuda giren hava Şekil-1’de de görüldüğü üzere önce trakea, sonra bronş ve bronşiyallerden oluşan iletici hava yollarından akciğer alveollerine kadar ulaşır. Daha sonra ise, gaz değişimi nedeniyle ortaya çıkan karbondioksit de aynı yolu takip ederek dışarı atılır. Solunum sırasında hava basıncı hızlı bir şekilde değiştiğinden, trakea, bronş ve bronşiyaller farklı çaplarda olduğundan, bu yollardaki dokularda oluşan titreşimler nedeniyle akciğer sesleri ortaya çıkar. Bu sesler, akciğerlerin patolojik durumuna göre ortaya çıkan deformasyon, genişleme, küçülme, sıvı, sekresyon vb. nedenleriyle dışarıdan farklı bir şekilde duyulur. Bu durum farklı türde akciğer seslerinin ortaya çıkmasına neden olur.

1.3. Akciğer Oskültasyonu

Akciğer oskültasyonu, akciğerlerden gelen seslerin stetoskop ile dinlenilmesi yöntemidir. Oskültasyon, antik çağlarda hekimlerin kulağını hastanın göğüs kısmına veya sırt bölgesine dayayarak akciğer seslerini dinlemeye çalışmasıyla başlamıştır [5]. Bu teknik, on dokuzuncu yüzyılda stetoskobun icadına kadar kullanılmıştır. Akciğer oskültasyonunun günümüzde halen klasik stetoskop kullanarak gerçekleştirilmektedir.

1.4. Solunum Sesleri

Solunum sesleri normal ve anormal solunum sesleri (ek sesler) olarak iki kategoriye ayrılır. Yaygın olarak duyulan anormal solunum sesleri, yani ek sesler, Amerikan Toraks Cemiyeti tarafından 1980’de ince ral, kaba ral, ronküs ve wheeze olarak belirlenmiştir. Bu tanıma uygun olarak, normal akciğer sesleri de dahil olmak üzere yaygın olarak duyulan akciğer sesleri Şekil-2’de gösterilmiştir.



Şekil 2. Yaygın olarak duyulan akciğer sesleri [7]

1.4.1. Normal Solunum Sesleri

Normal solunum sesleri akciğerlerdeki hava geçiş yollarının dinlendiği yerlere ve bu hava yollarının genişliğine bağlı olarak veziküler, bronşiyal veya ikisinin ara noktalarında duyulan bronkoveziküler sesler olarak üç farklı şekilde duyulabilir [5].

Normal Veziküler Ses sağlıklı bir akciğerde duyulan, iç çekme ya da hafif hışırdamaya benzer, yumuşak ve düşük perdeden bir sestir. Akciğerlerin uç noktalarına yakın yerlerden duyulur. Soluk alış verişi arasında duraklama yoktur.

Bronşial ses soluk alış verişi sırasında duraklamanın duyulabileceği yüksek perdeden bir sestir. Havanın bir borudan geçerken çıkardığı seslere benzemektedir.

Bronkoveziküler ses, bronşiyal ve veziküler seslerinin karışımı olarak duyulur. Nefes alış ve verişi sürelerinin aşağı yukarı eşit olarak duyulduğu normal ses türüdür.

1.4.2. Anormal Solunum Sesleri

Oskültasyonda duyulan anormal solunum sesleri akciğerlerdeki bir hastalık belirtisi olabilir. Çünkü anormal solunum sesleri çoğu kez bireyin hasta olup olmadığını belirlemek için yeterli değildir. Göğüs röntgen filmi veya solunum testi gibi ek testlere ihtiyaç duyulabilir. Anormal solunum seslerine neden olabilecek çok çeşitli koşullar oluşabildiğinden oskültasyonun ve ek testlerin değerlendirilmesi konusunda uzman doktorlar tarafından yapılmalıdır. Yaygın olarak duyulan anormal solunum sesleri bu proje çalışmasında geniş bir çeşitlilikte ince ral, kaba ral, ronküs, wheeze, frotman ve tuber sufl olarak ele alınmıştır. Bu seslerin kısa özetleri bölümün devamında açıklanmaktadır.

İnce ral patlayıcı yüksek perdeli seslerdir ve her solunum döngüsünde tekrarlanır. Dolayısıyla öksürükten veya derin nefes aldıktan sonra değişmez [5,8]. İnce raller pulmoner fibrozis, akciğer ödemi, allerjik alveolit (hipersensitivite pnömonisi), bronşektazi, kistik fibrozis ve pnömonik konsolidasyon ile ilişkilidir.

Kaba ral, büyük hava yollarındaki mukusta havanın kabarcıklaşmasından kaynaklandığı düşünülen ve gargara sesini andıran bir akciğer ek ses türüdür [8]. Kaba ral sesi derin nefes alarak veya öksürerek kaybolabilir (bronşektazi hariç). Kronik obstrüktif akciğer hastalığı (KOA), pnömoni, akciğer apsisi, tüberküloz kavitesi ve bronşektazi ile ilişkilidir.

Ronküs soluk alıp verme sırasında sürekli olarak duyulan, horlama sesini andıran gürültülü bir akciğer sesidir. Bronşlarda sekresyon birikmesi ya da tümör oluşması gibi nedenlerle ortaya çıkan ronküs, kaba ral gibi genellikle öksürükle kaybolur [9]. Yaygın olarak astım ve KOA'da duyulur.

Solunum hava yollarının daralması ve yaklaşan dokuların titreşmesiyle ortaya çıkan wheeze sesi ıslığa benzer. Dışarıdan kulakla bile duyulabilir [5,8]. Astım, KOAH, kanser (yetişkin) hastalıkları veya çocukların solunum yolundaki yabancı cisim ile ilişkilidir.

Frotman, plevranın enflamasyonlu yüzeyleri arasındaki düzensizliğin neden olduğu sürtünme nedeniyle ya da plevra boşluğu içindeki kayganlığı sağlayıcı sıvının kaybıyla oluşan, öksürükle kaybolmayan kaba seslerdir [9]. Daha çok karda yürüme sesini andırır. Frotman genellikle plöretik ağrı ile ilişkilidir ve pulmoner enfarktüs, pnömoni veya vaskülitte iltihaplı plevra alanlarında duyulabilir.

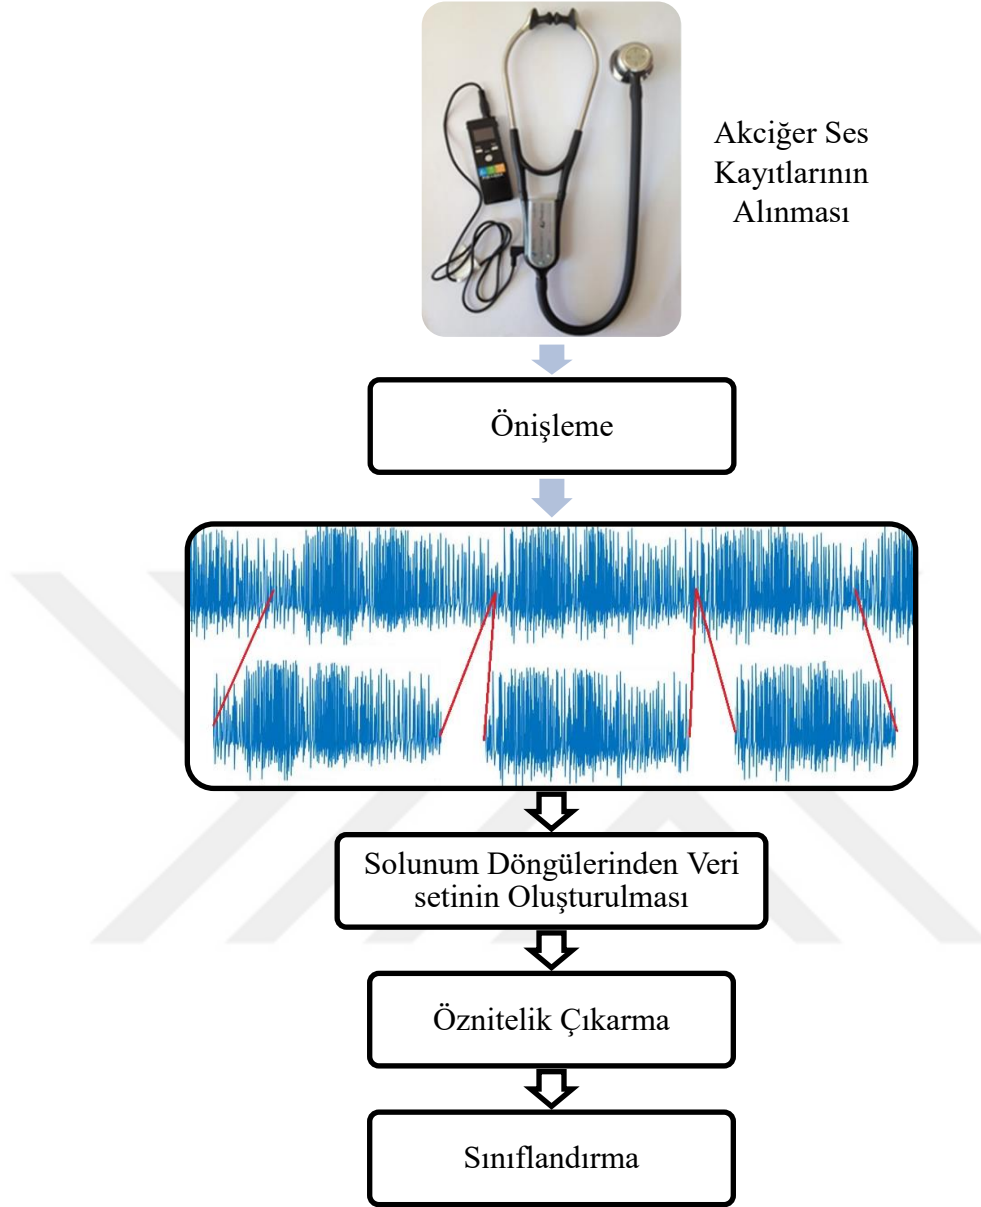
Alveoller sıvı ve kan gibi bileşenlerle dolduğunda hastalıklı bölge katılaşır ve böylece trakeal ses özelliğini çok az değiştirerek göğüs duvarına ulaşır. Bu sese Tubersufl denir. Yani solunum seslerinin şiddetinin artması durumu oluşur. Soluk alıp verme süresi aşağı yukarı eşittir ve aralarında belirgin bir duraklama vardır [9,10]. Konsolidasyon, akciğer çökmesi ve yoğun fibrozis ile ilişkilidir.

1.5. Otomatik Akciğer Ses Tanıma Yönteminin Bileşenleri

Otomatik akciğer ses tanıma yöntemi için ister tek kanallı ister çok kanallı olsun, elektronik oskültasyon cihazınının mikrofonunu/mikrofanlarını bireyin göğüs kısmına yerleştirilmek üzere her zaman bir operatöre ihtiyaç duyulur. Oskültasyon prosedürlerine uygun, tek kanallı bir kayıt yöntemine ve sınıflandırmaya dayalı otomatik oskültasyon yöntemi Şekil-3'te de gösterildiği üzere; akciğer ses sinyallerinin kaydedilmesi, ön işleme, akciğer seslerinden solunum döngülerinin ayrıştırılması, solunum döngülerinden veri setinin oluşturulması, öznitelik çıkarma ve sınıflandırma bileşenlerinden oluşmaktadır.

1.5.1. Akciğer Ses Sinyallerinin Kaydedilmesi

Otomatik oskültasyon yöntemi için akciğer ses sinyalleri belirli bir oskültasyon prosedürüne göre alınır. Kayıt alınmadan önce gürültüsüz ortam koşulları hazırlanmalıdır. Ayrıca hastanın uygun bir pozisyonda dik olarak oturması ve çevre gürültüsünün olmadığı bir yerde kayıtların alınması sağlanmalıdır. Kayıtların gürültüye maruz kalmadan, bozulmadan ham bir şekilde kaydedilmesi önem arz etmektedir.



Şekil 3.Otomatik akciğer ses tanıma yönteminin bileşenleri

1.5.2. Önişleme

Akciğerlerden gelen seslerin göğüs duvarına zayıflayarak ulaştıklarından dolayı oskültasyonda stetoskop ile dinlemeye ihtiyaç duyulmaktadır. Stetoskoplar çevresel ses gürültülerine duyarlı olduklarından akciğer ses kayıtları bu gürültülerden etkilenebilmektedir. Her ne kadar oskültasyonda sessiz ortamlar tercih edilse de hastane gibi ortamlarda sesten tamamen yalıtılmış bir ortam oluşturmak oldukça zordur. Bu nedenle yalnızca akciğer ses sinyallerinin özelliklerinin incelemesi ve diğer gürültü

kaynaklarının etkisinin minimuma düşürülebilmesi amacıyla çeşitli önışleme teknikleri akciğer ses sinyallerine uygulanmaktadır.

1.5.3. Akciğer Ses Sinyallerinden Solunum Döngülerinin Ayırışılması

Sınıflandırma tekniğine dayalı otomatik bir oskültasyon süreci geliştirebilmek için akciğer seslerindeki solunum döngüleri ayırışılmalıdır. Böylece her ses türü için bir solunum döngüsünden elde edilen öznitelikler karşılaştırılabilir ve sınıflandırma eşit koşullarda yapılabilir. Bu nedenle bu tez çalışmasında tek kanallı akciğer seslerinden solunum döngülerinin otomatik olarak algılanabilmesi için (literatürde ilk kez) bir yöntem geliştirilmiştir.

1.5.4. Solunum Döngülerinden Veri Setlerinin Oluşturulması

Sınıflandırma yöntemine dayalı tamamen otomatik bir oskültasyon yönteminden bahsedebilmek için veri setlerindeki solunum döngülerinin de otomatik olarak algılanmış olması gereklidir. Böylece solunum döngüleri kullanılarak uygun veri setleri oluşturulabilir. Bu tez kapsamında geliştirilen yöntem kullanılarak solunum döngüleri otomatik olarak ayırışılmış ve veri setleri de otomatik olarak oluşturulmuştur. Ayrıca, solunum döngülerinin inspirasyon ve ekspirasyon fazları manuel olarak ayırışılarak ayrı veri setleri de oluşturulmuştur. Böylece, bu tez çalışmasından sonra yapılabilecek olası çalışmalar da değerlendirilmiştir.

1.5.5. Öznitelik Çıkarma

Akciğer ses verilerinin tamamını kullanmak yerine onları temsil edebilecek en önemli özelliklerin çıkarılarak daha küçük boyutta öznitelik vektörünün çıkarılması işlemidir. Çıkarılan öznitelik vektörleri sınıflandırmanın başarısını direk olarak etkileyen faktörlerden biridir. Bu yüzden sınıflandırmanın başarısını artırmak için birçok öznitelik yönteminden faydalanmak, hatta bu öznitelik yöntemlerinin kombinasyonundan da yararlanarak genellikle geniş çaplı ve uzun süreli çalışmalar yapmak gerekir. Bazen öznitelikler tüm sınıfları ayırıştırmada yeterli olmayabilir. Böyle durumlarda farklı tür akciğer seslerini ayırmada başarılı olan özniteliklerin bileşiminden oluşan bir öznitelik

kombinasyonu kullanılır. Bu öznelik kombinasyonları sınıflandırma başarısını artırmaktadır.

1.5.6. Temel Bileşen Analizi

Veri setlerinden elde edilen özneliklerin, veri kümelerini ayırabilecek nitelikte olmaları istenir. Ancak öznelikler genellikle tek bir teknikle hesaplanmaz. En iyi özneliğin belirlenmesi için birden çok öznelik hesaplama yöntemi kullanılabilir. Hatta farklı öznelik yöntemlerinin birleştirilmesi ile başarıyı artıran öznelik seçme yöntemleri de bulunur. Öznelik boyutunun arttığı durumlarda sınıflandırmaya etkisi az olan ve başarıyı düşüren örneklerden kurtularak boyut azaltmak mümkündür. TBA, verileri bağımlılık yapısından kurtarmak ve boyut azaltmak amaçları için kullanılmaktadır.

1.5.7. Sınıflandırma

Sınıfları önceden belirlenmiş olan akciğer ses sinyallerinden çıkarılan öznelikler, sınıfı bilinmeyen başka bir akciğer sesinden çıkarılan özneliklerin sınıfının belirlenmesinde kullanılır. Sınıflandırma algoritmaları bu iki öznelik grubunu karşılaştırarak sınıfı belli olmayan sinyale ait özneliklerin en çok hangi sınıfın özneliklerine benzer olduğuna karar verir. Böylece belirlenen tahmini sınıf, test sinyalinin sınıfı olarak belirlenmiş olur.

1.6. Literatür Araştırması

Solunum döngülerinin otomatik olarak algılanması üzerine yapılan çalışmalar çeşitlilik göstermektedir. Önceki çalışmalarda araştırmacılar, solunum döngülerinin sınır noktalarını trakea sesi [11], solunum hava akışı [12], burun kenarına yerleştirilen mikrofon [13], Fotopletismografi [14] ya da piezorezistif kemer sensörü [15] gibi oskültasyonda yeri olmayan ve tek kanallı olarak kaydedilen sinyaller kullanarak belirlemeye çalışmışlardır. Bunun dışında, yukarıda bahsedilen farklı türdeki sinyaller yardımıyla, bu sinyallerle eş zamanlı olarak kaydedilen akciğer ses sinyallerindeki solunum döngülerinin sınırlarını belirlemek için yapılmış araştırmalar da mevcuttur. Bu araştırmalardaki ortak amaç, akciğer ses sinyallerinden otomatik olarak belirlenmesi zor olan solunum döngüsü

sınırlarının, farklı sinyaller üzerinden belirlenmesidir. Böylece eş zamanlı olarak kaydedilen akciğer ses sinyallerindeki solunum döngülerinin sınırları da eş zamanlı olarak bulunmuş olmaktadır. Sağlıklı bireylerden alınan akciğer sesleri ile yapılan çalışmalara bakıldığında sağlıklı akciğer sesleri ile birlikte eş zamanlı olarak kaydedilen trakea ses sinyali [16], burun yanına yerleştirilen bir mikrofon ile kaydedilen solunum ses sinyali ve akıllı telefonun kamerasıyla kaydedilen göğüs hareketlerinden alınan sinyallerin [17] kullanıldığı görülmektedir. Bu çalışmaların dışında Palaniappan ve ark. [18] uyku apneli hastalar için, akciğerlerden ve trakeadan gelen sesli sinyaller eşzamanlı olarak kaydederek, Alsmadi ve ark. [19] hava akışı sinyallerini sağlıklı ve anormal seslere sahip bireylerden alarak, başka bir çalışmada ise astım hastalardan alarak solunum döngülerinin sınırlarını belirlemeye çalışmışlardır. Dolayısıyla çalışmalar, akciğerlerden gelen sesleri kullanarak solunum döngülerini saptamak için çok kanallı veriler kullanmıştır. Fakat çok kanallı kayıt aşaması uzun zaman alan bir süreçtir ve çok fazla çaba gerektirdiğinden nispeten basit bir işlem olan oskültasyon prosedürünün oldukça dışına çıkılmasına neden olur.

Yalnızca tek kanallı akciğer seslerini kullanarak solunum döngülerinin sınırlarını belirlemeye çalışan çalışma sayısı oldukça azdır. Bu çalışmalardan; Mondal ve ark. [20], sağlıklı bireyler ve KOAH hastalığına sahip bireylerden aldıkları tek kanallı sesleri Hilbert dönüşümüne dayanan bir algoritma kullanarak birçok solunum döngüsü bulunan sesler içinden tek tam bir solunum döngüsü elde etmeye çalıştılar. Le Cam ve ark. [21] ise yine sağlıklı bireylerden elde edilen akciğer seslerini kullanarak bu seslerden solunum döngüsünü algılayabilmek için istatistiksel bir yöntem önermişlerdir. Ancak, kayıtların ne şekilde alındığına değinilmemiştir.


Şen [22], doktora tezinde akustik verileri kullanarak solunum sistemini anlamak için bugüne kadar yapılmış olan çalışmaları, hedefleri açısından aşağıdaki gibi dört kategoride özetlemiştir:

(i) Modelleme: İnsan akciğerleri için uygun fiziksel bir modelin geliştirilmesi veya akciğerlerdeki ses iletiminin karakteristiklerinin araştırılmasıdır.

(ii) Algılama - Tahmin: Belirli hastalıklarla ilişkili olan anormal sesleri (ral veya wheeze gibi ek sesleri) ve bunların arka plandaki akciğer seslerinden ayrıştırılmasını veya akciğer seslerinden solunum döngüsünün kestirilmesidir.

(iii) Sınıflandırma: Akciğer seslerinin sağlıklı/patolojik olarak veya ek ses türlerinin sınıflandırılmasını içerir.

(iv) Haritalama: Akciğer ses verilerinden elde edilen akustik bilgileri kullanarak akciğer ses bilgisinin akciğerlere göre görsel temsillerinin oluşturulmasıdır.



Şekil 4.Çok kanallı kayıt yöntemleri

Bu bilimsel çalışma, otomatik solunum döngüsü algılama ve sınıflandırma çalışmaları nedeniyle, yukarıda özetlen kategorilerden algılama ve sınıflandırma hedefleri kategorileri altında yer almaktadır. Algılama kategorisi ile ilgili olarak solunum döngülerinin algılanması üzerine yapılmış olan çalışmalar yukarıda tartışılmıştı. Akciğer seslerinin tanınması/sınıflandırılması üzerine yapılan çalışmalar incelendiğinde, bu

çalışmaların kayıt yöntemleri açısından çok kanallı ve tek kanallı kayıt yöntemleri olarak iki ana kategoride incelenmesinin daha uygun olduğu anlaşılmaktadır. Çok kanallı kayıt yöntemleri iki ya da daha fazla sinyal kaydının yapıldığı kayıt yöntemleridir. Şekil-4'te literatürde sunulmuş birkaç çok kanallı kayıt yönteminin örnekleri sunulmaktadır. Çok kanallı kayıtlarda akciğer seslerinin dışında da sinyaller kullanıldığı biraz önce solunum döngülerinin otomatik belirlenmesi üzerine yapılan çalışmalar özetlenirken de tartışılmıştı.



Şekil 5. Tek kanallı kayıt yöntemleri

Akciğer seslerinin tanınması üzerine yapılmış çalışmalarda kullanılan tek kanallı kayıt yöntemlerinin birkaç örneği ise Şekil-5'de gösterilmiştir. Tek kanallı kayıtları kullanan önceki çalışmalarda solunum döngüleri manuel olarak ayrıştırılmış ve çalışmalarda kullanılan veri setleri bu şekilde oluşturulmuştur. Otomatik akciğer ses analiz cihazları, kullanımı kolay, taşınabilir olmalı ve mümkün olduğu kadar az sayıda sensör gerektirmelidir [27].

Tek kanallı akciğer ses kayıtlarını kayıtları kullanan önceki çalışmalar incelendiğinde araştırmacıların çoğunun wheeze sesine yoğunlaştığı görülmektedir. Wheeze sesi, neredeyse normal sesler kadar sık karşılaşılan bir ek ses türüdür. Ancak wheeze sesinin bir diğer özelliği de bu sesi duymak için stetoskopa gerek duyulmamasıdır. Yüksek perdeden bir ses duyulduğundan hasta bireyin yakınından rahatlıkla duyulabilir. Bu yüzden wheeze sesi genellikle oskulte edilmez. Wheeze sesine yoğunlaşan ve tek kanallı kayıt kullanan çalışmalardan;

Bokov ve ark. [32] wheeze sesini saptamak için DVM sınıflandırmasının kullanıldığı bir algoritma geliştirmişlerdir. Ağız kenarından fiziksel temas olmadan, akıllı bir telefonla kaydettikleri tek kanallı akciğer sesleri üzerinden, geliştirdikleri yöntemi test etmişlerdir. Toplam 186 kayıt alsalar da, tüm kayıtları çocuk acil servisinde aldıklarından seçtikleri hasta grubu ortalama 20 aylık olan bebeklerdir. Dolayısıyla çalışma yetişkin hasta grubunda test edilmemiştir. Alınan kayıtlar bölümlere ayrılmış ve özellikle akustik tanımlamaya dayalı wheeze sesi ile uyumlu öznitelikleri bu bölümlerin her çerçevesinden çıkarmışlardır. Lojistik regresyon modeli sınıflandırıcısı kullansalar da en iyi sonuç yöntemde DVM kullanılması durumunda % 71.40 duyarlılık ve % 88.90 özgüllük ile elde edilmiştir.

Akciğer ses verilerini boyun, ön ve arka göğüs üzerindeki farklı noktalardan bir elektronik stetoskop ve cep telefonu yardımıyla kaydeden Chamberlain [33] ve ark., 171 normal, 33'ü wheeze, 19'u ral, 4'ü de wheeze ve ral içeren toplamda 227 kayıt kullandılar. Anlamli özniteliklerin çıkartılmasından önce kayıtların sadece küçük bir bölümünün (% 5) elle etiketlenmesini gerektiren yarı denetlenmiş derin öğrenme yöntemini kullanan bir yöntem önerdiler. Elde edilen performans, wheeze sesi için % 64 özgüllük ile % 90 duyarlılığa ulaşırken, bu oranlar ral sesi için % 44 özgüllük ile % 90 duyarlılık olarak elde edilmiştir.

Li ve ark. [34] 70 wheeze ve 42 normal akciğer sesinden oluşan iki farklı veri grubuyla çalıştılar. Wheeze veri setini, Amerikan Toraks Derneği (ATD), KOAH web

sitesi ve diğer bazı akciğer sesi içeren web sitelerinden aldılar. Normal akciğer sesleri ise sağlıklı kişilerden tek kanallı bir elektronik stetoskop ile alınmıştır. Önerdikleri yöntem, Kısa Zamanlı Fourier Dönüşümü (KZFD) ile genlik spektrumunun geniş sinyallerinin saptanması, büyük sinyallerin gruplandırılması, gruplanmış sinyaller sürelerinin belirlenmesi ve wheeze sesi süresinden daha kısa olan grupların çıkarılması, özellik çıkarılması gibi adımları içeren geliştirilmiş bir wheeze algılama yönteminden oluşur. Önerdikleri yöntem sonucunda doğruluk % 90.17, duyarlılık % 90.00, özgüllük ise % 90.48 olarak elde edilmiştir.

Lin ve ark. [35], Mel frekansı keppstrum katsayılarının (MFKK) Gauss karışım modeli (GKM) içine entegre edildiği wheezing saptamaya alternatif bir yaklaşım önerdiler. MFKK'larının kısa süreli spektral bilgileri birkaç katsayıya indirgendikten sonra GKM ile solunum sesleri tanınmaktadır. Çalışmada, eğitim ve test için 18 gönüllüden (9 astımlı ve 9 normal erişkin) oluşan solunum sesleri kaydedilmiştir. Kayıtlar bir elektronik kondansatör mikrofonu ve yüksek frekanslı stetoskop diyaframı kullanılarak tek kanallı olarak alınmıştır. Wheeze algılama algoritmasının nitel analizinin sonuçları 0.881 sensitivite ve 0.995 özgüllük olarak elde edilmiştir.

Mendes ve ark. [36] wheeze sesini sinyalin çerçeve boyutundan algılayacak bir yöntem önerdiler. Akciğer seslerinin durağan olmaması nedeniyle dalgacık tabanlı, teager enerji temelli ve entropi temelli bir özniteliklerin de yer aldığı geniş çaplı bir şekilde özniteliklerin sıralı kombinasyonlarını denediler. En iyi sonuçları 128ms'lik çerçeve kullanılması durumunda elde ettiler. Pozitif prediktif değeri 0.77 ± 0.22 ve duyarlılık ise 0.76 ± 0.23 olarak elde edilmiştir.

Sağlıklı, wheeze veya ral seslerine sahip 38 kişiden özel bir stetoskop ve bir akıllı telefon yardımıyla akciğer ses kayıtları alan Chamberlain ve ark., [37], zaman-frekansı analizi ve KZFD'ne dayanan otomatik wheeze algılama algoritması önerdiler. Kullanılan algılama şeması, enerji eşiğini kullanarak potansiyel wheeze seslerini seçmek için akciğer ses kayıtlarının spektrogramını işler. Elde edilen performans, % 86 doğruluğa sahiptir.

Lin ve ark. [38] elektret kondens mikrofon yardımıyla 58 bireyden (32'si astım 26'sı sağlıklı) kayıt aldılar. Akciğer seslerinden elde edilen spreogramın yatay kenarlarının araştırılmasını kolaylaştıran wheezing özelliklerini görselleştirmeyi mümkün kılan geri yayımlı sinir ağına dayanan bir yöntem geliştirmişlerdir. Çalışmanın iddia ettiği performans, wheeze kayıtlarının sınıflandırması için % 100 özgüllük ve % 94.60'lık duyarlılıktır.

Matsuke ve ark. [39] bir elektronik stetoskop yardımıyla 66 anormal, 64 sağlıklı akciğer sesine sahip bireylerden kayıt aldılar. Normal solunum ile anormal solunum arasında ayırım yapmak için normal solunum olasılığını ve anormal solunum olasılığını karşılaştırmaya dayanan bir yöntem önerdiler. Olasılık, Saklı Markov Modelleri kullanılarak maksimum olasılık yaklaşımına göre hesaplanmıştır. Sonuçlar wheeze algılamada 0.946' duyarlılık ve 1.00 gibi yüksek bir özgüllük göstermiştir.

Mazić ve ark. [40] MFKK, kurtosis ve entropiyi öznitelik olarak kullanan bir wheeze algılama yöntemi geliştirmişlerdir. Analiz için 45 kayıt bir akselerometre (BU-3173) kullanılarak elde edilmiştir. Sınıflandırıcı olarak iki paralel Destek Vektör Makineleri (DVM) kullanılmış ve her ikisinin çıktılarının çarpımı kullanılarak son karar verilmiştir. Bildirilen performans güvenilirlik oranı % 97.68 idi.

Mendes ve ark. [41] wheeze sesini algılamak için Rastgele Orman Algoritmasını kullandılar. Çalışmadaki veri seti tek kanallı bir elektronik stetoskop yardımıyla bireylerin göğüs ve arkasındaki birden fazla pozisyondan elde edilmiştir. 12 bireyden toplamda 24 kayıt alınmıştır. Algılama için kullanılan özellikler müzikal özellikler ve pik seçimini içeren wheeze sesslerinin spektrogramıydı. Potansiyel hırıltılar, 10 katlı çapraz doğrulama tekniği ile bir Rasgele Orman Algoritması kullanılarak sınıflandırıldı. Çalışmada % 90.9 \pm % 2 duyarlılık ve % 99.4 \pm % 1 özgüllük performansı elde edilmiştir.

Bir başka wheeze algılama üzerine çalışan grup da Yu ve ark. [42]'dir. Bireylerin boyun bölgesinden bir elektronik stetoskop yardımıyla kayıt almışlardır. Almış oldukları 59 kayıt 25 wheeze ve 34 normal akciğer seslerinden oluşuyordu. Sınıflandırıcı olarak ampirik olarak belirlenmiş bir eşik, öznitelik olarak da korelasyon katsayısını kullandılar. Sonuç olarak % 88 özgüllük ve % 88 duyarlılık değerlerini elde ettiler.

Jin ve ark. [43] mikrofona kaydedilen 100 normal ve 86 wheeze sesi kayıtlarıyla yaptıkları çalışmada dar bant filtrelenmiş solunum seslerinin örnek entropi histogramlarını kullanarak otomatik wheeze algılama yöntemi önerdiler. Yöntem, solunum döngüsünün nefes alış kısmı için 85.30, veriş kısmı için ise 97,90 doğruluk değeri vermiştir.

Wheeze ve normal seslerin sınıflandırılması için Gauss Karma Modeli ile birleştirilmiş MFKK katsayıları Chien ve ark. [44] tarafından kullanılmıştır. Çalışmada, segment seviyesi tespitinde % 94.90'lık bir doğruluk bildirilmiştir.

Akciğer ses kayıtlarının spektrogramı üzerinde görüntü işleme tekniği kullanılarak bir wheeze saptama tekniği Hsueh ve ark. [45] tarafından önerilmiştir. Çalışmadaki

kayıtlar, boyun üzerine yerleştirilen bir mikrofon kullanarak 16 gönüllüden alınmıştır. Çalışmada % 89'un üzerinde duyarlılık ve özgüllük değerleri edilmiştir.

Homs ve ark. [46] 16 astımlı ve 15 sağlıklı bireyden boyuna yerleştirilen bir piezoelektrik mikrofon kullanarak aldıkları kayıtlardan wheeze tespiti için yöntem önermişlerdir. Vaka seviyesinde yüksek hava akışı için % 100 duyarlılık ve özgüllük sağlayan bir eşik enerjisi kullanılmıştır.

Wheeze sesinden sonra en sık duyulan anormal sesler rallerdir. Literatürde wheeze sesinin dışında gerçekleştirilmiş tek kanallı çalışmalarda Aykanat ve ark. [47] geliştirdikleri bir elektronik stetoskop yardımıyla 1630 denekten veri kaydettiler. Destek vektör makinesinde MFKK özellikleri ve konvolusyonel sinir ağında spektrogram görüntüleri olmak üzere iki tip öğrenme algoritması kullandılar. Çalışmada, solunum seslerini sınıflandırmak için dört veri seti oluşturulmuştur. Sağlıklı ve patolojik sınıflandırmada konvolusyonel sinir ağı % 86 ve DVM % 86, ral, rhonchus ve normal ses sınıflandırmasında konvolusyonel sinir ağı % 76 ve DVM% 75, tekil solunum sesi tipi sınıflandırmada konvolusyonel sinir ağı % 80 ve DVM% 80 ve tüm ses türleri ile ses türü sınıflandırmasında ise konvolusyonel sinir ağı % 62 ve DVM% 62 oranında başarı elde edildiği bildirilmiştir.

Pinho ve ark. [48] ral seslerini algılamak için tek kanallı elektronik stetoskoplardan alınan kayıtlarla oluşturulmuş hazır iki veri seti kullanmıştır. Pnömoni veya kistik fibroz hastalığına sahip bireylerden alınan 24 kaydın kullanıldığı çalışmada, ral seslerini tanımak için fraktal boyutta eşikleme yanında, literatürde önceden tanımlanmış olan bazı ral kriterleri de kullanılmıştır. Çalışmada bildirilen performans, % 89 ± 10 'luk bir ortalama duyarlılık ve % 95 ± 11 'lik pozitif öngörü değeri idi.

Zhang ve ark. [49] 50 ral ve 50 sağlıklı solunum sesinden oluşan kayıtları bir elektronik stetoskop yardımıyla aldılar. Ral seslerinin sınıflandırma yöntemiyle tanınması spektrogramdaki bir ral sesinin matematiksel morfolojisine dayanıyordu. Çalışmada sonuç olarak % 86 sensitivite ile % 92 özgüllük elde edilmiştir.

İçer ve ark. [50] ral ve ronküsü sınıflandırmak için bir çalışma sundular. Çalışmada analiz için bir elektronik stetoskop yardımıyla 60 kayıt alınmıştır. Öznitelik olarak frekans oranı, anlık frekansın ortalaması, değişim zamanı ve özdeğerleri kullanılmıştır. 5 kat çapraz doğruluğunun ve DVM nin kullanıldığı çalışmadaki doğruluk % 80'in üzerindedir.

Trakea üzerine yerleştirilen bir mikrofon yardımıyla kaydedilen wheeze, stridor ve ronküs seslerinin sınıflandırılması için Jin ve ark. [51] bir çalışma yaptılar. Veri setini hazır

veri setinden ve bazı gönüllülerden alınan akciğer ses kayıtları üzerinden oluşturdular. 339 solunum kaydının alındığı çalışmadaki öznitelikler; kurtozis, ayırt edici fonksiyonlar ve örnek entropisi temeline dayanıyordu. İleri öznitelik seçim algoritması ile birlikte DVM sınıflandırıcısının verdiği sonuç ortalama % 98 civarındaydı.

Mondal ve ark. [52] wheeze, ral ve squawktan ve sağlıklı akciğer seslerinden oluşan verilerle normal ve anormal olarak sınıflandırmaya çalıştılar. Kayıtlar trakea üzerine yerleştirilen bir mikrofon yardımıyla alınmıştır. Beş kat çapraz doğrulama tekniği sınıflandırma aşamasında aşırı öğrenme makinesi ile birlikte kullanılmıştır. Çalışma sonucunda % 86.30 duyarlılık, % 86.90 özgüllük değeri elde edilmiştir.

Emmanouilidou ve ark. [53] 10 normal, 10 wheeze ve 8 ral sesinden oluşan toplam 28 kayıtlık veri setini bir elektronik stetoskop yardımıyla aldılar. Kayıtlardan öznitelik olarak kortikal bir model çıkarılmış ve sınıflandırma aşamasında DVM kullanılmıştır. Sonuç olarak duyarlılık için % 89.44, özgüllük için ise % 80.50 başarı elde edilmiştir.

Normal-anormal solunum seslerinin sınıflandırılması üzerine bir başka çalışma da Himeshima ve ark. [54] tarafından yapılmıştır. Akciğer ses kayıtları için piezoelektrik mikrofon içeren bir elektronik stetoskop kullanılmıştır. Amfizemi olan 63 birey ve 63 sağlıklı bireyden akciğer sesleri alınmıştır. Çalışmada, gürültünün ve anormal solunum seslerinin süre dağılımı, gürültünün neden olduğu yanlış alarmları azaltmak için kullanılmıştır. Birini dışarıda bırak çapraz doğrulama yöntemi kullanılarak elde edilen performans, anormal ve normal akciğer seslerinin sınıflandırılması için % 88.7 duyarlılık ve % 91.5 özgüllük olarak elde edilmiştir.

Xie ve ark. [55] Ampirik Sınıflandırma olarak adlandırılan k-en yakın komşuluk (k-EYK) yöntemine benzer yeni bir sınıflandırma yaklaşımı kullandı. Yöntem k-EYK'ya benzese de, lokal uzaklık yerine varyans farkına dayalı global benzerlik kontrol edildi. Çalışmada öznitelik olarak çok ölçekli bir Temel Bileşenler Analizi kullanılmıştır. Çalışmada, boyuna yerleştirilen bir mikrofon yardımı ile kaydedilen verilerin yanında bazı kitapların ekinde yer alan hazır ses verileri kullanılmıştır. Normal ve anormal seslerin sınıflandırılması için % 98.34' doğruluk elde etmişlerdir.

Ek seslerin sınıflandırılması üzerine Jin ve ark. tarafından [56] k-EYK sınıflandırıcısının kullanıldığı bir çalışma yapıldı. Sınıflandırmada normal 264'ü normal, 132 polifonik wheeze, 93 monofonik wheeze ve 96 stridor olmak üzere toplam 585 kayıt bir mikrofon yardımıyla alınarak değerlendirildi. Zamansal spektral dominantlık spektrogramına dayalı olarak çıkarılmış öznitelikler ile birlikte kullanılan k-EYK

sınıflandırıcısının yanında birini dışarıda bırak çapraz doğrulama yöntemi de kullanılmıştır. Elde edilen genel doğruluk performansı $\% 92.40 \pm 2.9$ 'dır.

Dokur [57], dokuz farklı solunum sesini sınıflandırmak için nöral ağların performanslarını karşılaştırmalı olarak inceledi. Bir elektronik stetoskop yardımıyla 36 hastadan alınan 10'ar solunum döngüsü içeren akciğer seslerini kullandı. Böylece 360 akciğer sesinden oluşan veri seti oluşturdu. Öznitelik olarak ortalama güç tayfını kullandı. Veri setini ikiye bölerek elde ettiği 180 veriden oluşturduğu test setinde artımlı denetimli sinir ağı sınıflandırıcı için $\% 98$ en iyi doğruluk elde etmiştir.

Matsunaga ve ark. [58] SMM'ni kullanarak Maksimum Olabilirlik yaklaşımına dayalı normal ve anormal solunum seslerini ayırmak için bir sınıflandırma prosedürü önerdiler. Bir mikrofon yardımıyla 162 bireyden alınan kayıtların 109'u amfizemli bireylerden alınmıştır. Birini dışarıda bırak çapraz doğrulama yöntemi ile çalışmada $\% 64.80$ özgüllük ve $\% 93.20$ duyarlılık elde edilmiştir.

Alsmadi ve ark. [59] elektronik bir stetoskop kullanarak 65 bireyden kayıt aldılar. Önitelik olarak özbağlanımlı katsayılar kullanılmıştır. Birini dışarıda bırak çapraz doğrulama yöntemi ile birlikte k-EYK sınıflandırıcısı birlikte kullanılmış ve test setinde $\% 92$ 'lik bir hassaslık ve $\% 100$ 'lük bir özgüllük elde edilmiştir.

Kahya ve ark. [60] ral sesini sınıflandırmaya çalışan ilk araştırmacılardandır. Ral seslerini tespit etmek ve izole etmek için enerji zarfı üzerindeki bir eşik kullanıldı. Ral sesleri, süre ve frekans pikleri gibi özellikler kullanılarak ince ve kaba ral olarak sınıflandırılmıştır. Dokuz hastadan alınan kayıtların ince ve kaba ral sınıflandırılması sonucunda $\% 100$ doğruluk elde edildiği bildirilmiştir.

Çok kanallı kayıtlar ile akciğer seslerinin tanınması üzerine yapılan önceki çalışmalar incelendiğinde;

Taplidou ve ark. da [61]. wheeze algılama çalışması üzerine yoğunlaştılar. 13 kişiden toplamda 422 wheeze sesi kaydettiler. Ses sinyalleri boyun, ön ve arka göğüste yerleştirilen beş mikrofon ile çok kanallı olarak kaydedilmiştir. Çalışmada 13 bireyin 10'undan alınan veriler, 337 adet wheeze sesi içeren bir test seti olarak kullanılmıştır. Algılama, belirlenmiş kurallara göre seçilen piklere dayanarak yapılmıştır. Test sonucunda duyarlılık $\% 95.50 \pm 4.80$, özgüllük ise $\% 93.70 \pm 9.30$ elde edilmiştir.

Lozano ve ark.'nın [62] yaptığı bir araştırmada sürekli akciğer seslerinin sınıflandırılması için 30 gönüllüden, beş mikrofon yardımıyla kayıtlar alınmıştır. Bir sensör boynuna konurken dört sensör sırtın üzerine yerleştirilmiştir. Toplamda sürekli

akciğer sesi içeren 485 örnekten 870 inspiratuar döngü kaydedildi. 870 döngüden, 639'unda sürekli akciğer sesi içeren 1494 segment elde edildi. Anlık frekansa dayalı bir özellik kümesi çıkarıldı ve bir DVM sınıflandırıcısı kullanıldı. En uygun DVM parametrelerini elde etmek 10 kat çapraz doğrulama kullanıldı. Elde edilen en iyi performans, döngü düzeyinde % 94.2'lik duyarlılık ve % 96.1'lik özgüllük sonucunu vermiştir.

Şen ve ark.'nın yaptığı bir çalışmada [63], normal ve anormal akciğer ses kayıtlarının sınıflandırılması için bir GKM ve DVM'nin performansını karşılaştırmıştır. Birini dışarıda bırak çapraz doğrulama kullanan bir özellik kümesi olarak bir özbağlanımlı model kullanıldı. Kullanılan veriler, arka göğüste yerleştirilen on dört adet mikrofon ile elde edilen 40 kayıttır. Bir Gauss karışım modeli kullanılarak ulaşılan en iyi doğruluk değeri % 90 olarak elde edilmiştir.

Ulukaya ve ark. [64] monofonik ve polifonik wheeze seslerini ayırt etmek için bir çalışma yaptı.. Wheeze seslerinin kaydı, göğüs üzerinde birden fazla yerde konumlandırılmış on dört mikrofon kullanılarak gerçekleştirilmiştir. Analiz için 121 monofonik ve 110 polifonik wheeze içeren toplam 7 kayıt yapılmıştır. Çeyrek frekans oranı ve ortalama çaprazlama düzensizliği öznelikleriyle birlikte sınıflandırıcı olarak DVM kullanılmıştır. Bildirilen DVM performansı % 69.29 doğruluk oranıdır. k-EYK ve Naive Bayes (NB) sınıflandırıcılarının da kullanıldığı çalışmada, bildirilen en iyi genel doğruluğa % 75.78 ile k-EYK sınıflandırıcısı ulaşmıştır.

Tüberkülozlu hastalardan alınan kayıtlar üzerinden wheeze ve ral ses analizi çalışması Becker ve ark. [65] tarafından yapılmıştır. Analiz kayıtları boyun, göğüs ve sırt üstünden 7 mikrofon kullanılarak yapılmıştır. Çalışmada 60 gönüllüden alınan ses sinyalleri kullanılmıştır. Yapay Sinir Ağı (YSA), modelin eğitimi için verilerin % 75'inde, modelin testi için % 25'inde kullanıldı. Yapılan sınıflandırma, bir kaydın tüberkülozlu bir hastadan mı, yoksa normal bir kayıttan mı kaynaklandığını kontrol etmektir. Bir wheezin varlığı, spektrogramı değerlendirerek bulgulanırken, raller YSA için dalgacık tabanlı özellikler kullanılarak tanımlanmıştır. Elde edilen performans tüberküloz tespitinde % 80 özgüllük ile % 80 duyarlılıktır.

Serbes ve ark. [66] raller ve normal sesler arasında bir sınıflandırma yapmak için DVM sınıflandırıcısı kullanılmıştır. Sinyaller, göğüs üzerine yerleştirilmiş on dört adet mikrofon kullanılarak elde edilmiştir. Çalışmada 26 farklı kayıt kullanılmıştır. Veriler, DVM modelinin eğitilmesi, test edilmesi ve doğrulanması için eşit olarak bölünmüştür.

Sınıflandırma için Çok Katlı Algılayıcı ve k-EYK yöntemleri de kullanılmıştır. Çalışma sonucunda, DVM'nin k-EYK ve çok katlı algılayıcıya göre daha yüksek bir başarıya sahip olduğu bildirilmiştir. Buna göre DVM ile elde edilen doğruluk değeri % 97.50, hassaslık değeri ise % 97.30 olarak elde edilmiştir.

Fischer Ayrımcılık Analizi, wheeze ve normal ses sınıflandırıcısı olarak Aydore ve ark. [67] tarafından kullanılmıştır. Kayıtlar 7 gönüllüden, on dört adet mikrofon kullanılarak kaydedilmiştir. Sınıflandırma için kullanılan veriler kayıtlardan 246 wheeze ve 246 normal segment şeklinde çıkarılmıştır. Özellik kümesi kurtozis, Renyi Entropi, frekans güç oranı ve ortalama çaprazlama düzensizliği olarak çıkarılmıştır. Çalışmadaki performans % 93.5 doğruluk olarak bildirilmiştir.

Güler ve ark. [68] solunum sesinin kalıplarını sınıflandırmak için sinir ağlarının işbirliğine dayanan bir hiyerarşik karar verme planı önerdiler. Bu amaçla, her solunum döngüsü fazlara bölünür ve her biri için faz uzmanı olarak adlandırılan ayrı bir çok katlı algılayıcı sınıflandırıcısı kullandılar. Faz kararları daha sonra bir karar kombinasyon fonksiyonu ile birleştirilmiştir. Çalışmada 57 solunum ses sinyali için sınıflandırma sonuçları sunulmuştur. Kayıtlar, hava kuplajlı iki adet elektret mikrofon yardımıyla, 18 KOAH, 19 restriktif akciğer hastalığı ve 20 sağlıklı bireyden alınmıştır. Kayıtlar eğitim ve test seti olarak ikiye ayrıldıktan sonra, özbağlanımlı parametreler ve kepsral katsayılar kullanıldı. Çalışmada cepstral katsayı öznitelik seti için test setinde ortalama % 10-20 civarında hatalı sınıflandırma oluşmuştur.

Martinez ve ark. [69] ral olan ve ral olmayan bölümlerin sınıflandırılmasını yapmak için geri yayımlı sinir ağını kullandı. Veriler, 10 sağlıklı gönüllü ve 19 hastanın göğüsüne yerleştirilen 25 mikrofon kullanılarak kaydedildi geri yayımlı sinir ağını eğitmek için 456 normal ve 456 anormal olan 912 segment kullanıldı. 114 segment doğrulama için kullanılırken, bir başka 114 segment ise test seti olarak kullanılmıştır. Çok değişkenli bir özbağlanımlı model, geçerlilik kümesindeki segment düzeyinde % 80.70 duyarlılık ve % 84.21 özgüllük elde etmek için bir öznitelik olarak kullanılmıştır.

Bir başka geri yayımlı sinir ağı çalışması da Waitmann ve ark.[70] tarafından anormal ve normal solunum seslerinin sınıflandırılmasını gerçekleştirmek kullanılmıştır. Veriler, ön göğüse yerleştirilen iki adet mikrofon kullanılarak kaydedilmiştir. Bunun dışında farklı kaynaklardan ek veriler de kullanılmıştır. Öznitelik olarak ortalama güç tayfı kullanılmış ve elde edilen en iyi performans, kayıtlı sesler için % 59'luk bir duyarlılık ve %

81'lik özgüllük, anormal solunum sesi sınıflamasında CD ek verileri için % 87'lik bir duyarlılık ve % 95 özgüllük değeridir.

Temel patolojiye dayalı kayıtların sınıflandırılması Kahya ve ark. [71] tarafından yapılmıştır. Kayıtlar 69 gönüllünün göğsünden birden fazla pozisyondan iki mikrofon kullanılarak kaydedilmiştir. Gönüllülerden 28'inin obstrüktif hava yolu hastalığı olduğu, 23'ünde hava yolu kısıtlılığı olduğu bildirilmiştir. Segment seviyesinde, özbağlanımlı modeli olan bir k-EYK sınıflandırıcıyı kullanarak birini dışarıda bırak çapraz doğrulama gerçekleştirilmiştir. Karşılık gelen solunum olaylarının patolojisini belirlemek için her segmentin sonucunda çok terimli bir sınıflandırıcı kullanılmıştır. Son kayıt sınıflandırması o zamanki vakaların oylama sonuçlarından elde edilmiştir. Araştırma, hastalığa dayalı kayıtların sınıflandırılmasında % 71,07'lik genel bir doğruluğa ulaşmıştır.

1.7. Tezin Kapsamı

Bu tez çalışmasında, tek kanallı akciğer seslerinden solunum döngülerinin otomatik olarak algılanması ve sınıflandırılması için başarı oranı yüksek otomatik bir elektronik oskültasyon yaklaşımı önerilmiştir. Çalışmada kullanılan akciğer ses kayıtları, Karadeniz Teknik Üniversitesi Göğüs Hastalıkları Ana Bilim Dalına başvuran yetişkin bireylerden (18 yaş üstü) kaydedilmiştir. Tez çalışmasında öncelikle akciğer seslerinden solunum döngülerinin otomatik olarak algılanabilmesi için akciğer seslerinin enerjisi ve spektrogram özelliklerinden faydalanan bir yöntem geliştirilmiştir. Bu yaklaşım, “2.2.1.3. Akciğer seslerinden solunum döngülerinin ayrıştırılması” başlığı altında açıklanmıştır. Geliştirilen yöntem sayesinde akciğer seslerinden solunum döngüleri otomatik olarak algılanmış ve çalışmadaki veri setleri bu solunum döngülerinden oluşturulmuştur. Oluşturulan veri setleri ile ilgili ayrıntılı açıklama bölüm “2.2.1.4. Solunum Döngülerinden Veri setinin Oluşturulması” başlığı altında ayrıntılı olarak verilmektedir. Veri setleri üzerinde geniş kapsamlı bir öznitelik (zaman bölgesi (ZBP) ve frekans bölgesi parametreleri (FBP), MFKK, doğrusal öngörü katsayıları (DÖK) ve istatistiksel parametreler) ve etkin bir sınıflandırma yöntemi (doğrusal ayırma ayırıcı (DAA), DVM, NB ve k-EYK) araştırma çalışmaları yürütülmüştür. Önerilen otomatik elektronik oskültasyon yönteminin doğruluğunu test etmek amacıyla sağlıklı/patolojik akciğer seslerinin yanı sıra, yaygın akciğer seslerinin (normal, ince ral, kaba ral, ronküs) sınıflandırılması çalışmaları yapılmıştır. Çalışmanın sonunda elde edilen yüksek başarılı

sonulara ek olarak ardışıl ileri yönlü öznitelik seçme yöntemi uygulanmış ve başarıml daha da artırılmıştır. Tüm sınıflandırma doğrulukları bölüm 3.'te bulgular başlığı altında verilmiştir. Sonuçlar kısmında ise elde edilen bulgular yorumlanarak literatürdeki mevcut çalışmaların sonuçları ile detaylı bir şekilde karşılaştırılmıştır. Çalışmanın öneriler ve tartışma başlığı altında ise tez kapsamında elde edilen sonuçlar tartışılmış ve ileride yapılacak çalışmalar için önerilerde bulunulmuştur.



2. YAPILAN ÇALIŞMALAR

2.1. Materyal

2.1.1. Kullanılan Kayıt Cihazı

Tek kanallı akciğer ses kayıt yöntemlerinin oskültasyon prosedürüne daha uygun olduğu, avantaj ve dezavantajları ile bölüm 1.6.'da Literatür Araştırması başlığı altında tartışılmıştı. Bu çalışmada verilerin tek kanallı olarak kaydedilmesi için oskültasyon prosedürüne uygun olan Thinklabs-ds32a+ elektronik stetoskobu kullanılmıştır. Bu stetoskobun avantajı, oskültasyon esnasında hekime ek bir yük getirmeden, aynı anda stetoskobun tek kanal analog çıkışına bağlı bir dijital ses kayıt cihazı (Şekil-6) ile seslerin kayıt altına alınabilmesidir. Böylece hekimlerin oskültasyon esnasında duymuş oldukları anlık sesler birebir kayıt edilmiş olmaktadır. Oskültasyonda dinlenen akciğer seslerinin bant genişliği yaklaşık 80-2000Hz arasındadır [72]. Kullandığımız elektronik stetoskobun akciğer sesleri için uygun diyafram modu (20-2000Hz) ise bu frekans bandı aralığını kapsamaktadır.



Şekil 6. Kayıt alınırken kullanılan elektronik stetoskop ve ses kayıt cihazı

2.2. Yöntem

2.2.1. Otomatik Akciğer Oskültasyon Yöntemi

Akciğer oskültasyonunda, oskültasyon prosedürüne uygun olarak akciğer sesleri tek kanallı olarak dinlenir ve bu sesler oskültasyonun gerçekleştiren kişinin duyma yeteneği, bilgisi ve tecrübesine bağlı olan yoruma dayanarak etiketlenir. Tek kanallı otomatik akciğer oskültasyon yönteminin farkı ise dinlenen seslerin cihaz tarafından yorumlanıp etiketlenmesidir. Otomatik akciğer oskültasyon yöntemi aşağıdaki bileşenlerden oluşmaktadır. Yöntem bileşenleri ise sırasıyla bölümün devamında ayrıntılı bir biçimde sunulmaktadır.


- Akciğer ses sinyallerinin kaydedilmesi
- Önişleme
- Akciğer seslerinden solunum döngülerinin ayrıştırılması
- Solunum Döngülerinden Veri setinin Oluşturulması
- Öznitelik çıkarma
- Sınıflandırma

2.2.1.1. Akciğer Ses Sinyallerinin Kaydedilmesi

Akciğer ses kayıtlarının alınması için TÜBİTAK 116E003 numaralı proje kapsamında, Karadeniz Teknik Üniversitesi Göğüs Hastalıkları Ana Bilim Dalı tarafından konusunda uzman iki akademisyen görevlendirilmiştir. Ayrıca tüm kayıt alım süreci, Trabzon Klinik Araştırmalar Etik Kurul Başkanlığı'nın 30.04.2015 tarih ve 24237859-293 sayılı numaralı izni ile yürütülmüş ve kayıtlar yetişkin (18 yaş üstü) bireylerden alınmıştır. Kayıt alımlarına başlamadan önce görevlilere cihazların kullanımı ve kayıtların ham veriler şeklinde alınabilmesi için bilgilendirme yapılmıştır. Cihazın ortam gürültüsü azaltma, ses yükseltme seçenekleri v.b. gibi özellikleri devre dışı bırakılarak sadece akciğer ses bandına (80-2000Hz) uygun olan diyafram modunda (20-2000Hz) kayıt alınması sağlanmıştır. Tüm kayıtlar, bölüm 1.3.'te Akciğer Oskültasyonu başlığı altında açıklanan oskültasyon prosedürüne uygun olarak alınmıştır.

Oskültasyonda akciğer seslerinin net bir şekilde duyulabilmesi için aşağıdaki prosedürleri uygulamak gerekir [73];

Sessiz bir odada, tercihen oturma pozisyonunda dinleme yapılmalıdır. Hasta oturma pozisyonu alamazsa, dinleme yapabilmek için yatay pozisyondaki hasta bir yandan diğer yana döndürülmelidir.



Şekil 7. Akciğer oskültasyonunda izlenen sıra [74]; A, Akciğerlerin arkadan görünümü. B, Akciğerlerin önden görünümü. C, Akciğerlerin yandan görünümü.

Stetoskobu hastanın vücuduna temas ettirmeden önce, stetoskobun ucu el yardımıyla ısıtılmalıdır. Giysi üzerinden oskültasyon yapılmamalı, stetoskobun ucu direk olarak hastanın vücuduna temas ettirilmelidir.

- Hastanın ağız açık vaziyette yavaş ve derin nefes alması istenmelidir.
- Stetoskop, her iki akciğerin simetrik noktaları karşılaştırmalı olarak dinlenecek biçimde Şakil-7’de gösterildiği gibi ileri geri hareket ettirilmelidir.
- Her bölgede en az bir tam solunum döngüsü duyulmalıdır.

- Nefes seslerinin kalitesi, nefes seslerinin yoğunluğunu ve ek seslerin var olup olmadığı dikkatlice dinlenmelidir.

Oskültasyonda dinleme yapılan noktalar için izlenen sıra Şekil-7’de gösterilmektedir. Buradan da anlaşıldığı üzere oskültasyonda trakea sesleri genellikle dinlenilmez. Yukarıda belirtilen oskültasyon prosedürünü ek olarak, göğüs kılları üzerinden de dinleme yapmaktan kaçınılmalıdır. Çünkü solunum sırasında diyaframa sürtünen kıllar rallere benzeyen sesler oluşmasına neden olabilir. Bu sorun kılların ıslatılmasıyla çözülebilir. Bunun dışında stetoskoptan duyulması muhtemel parmak eklem sesleri, kumaşa veya başka bir eşyaya sürtünme seslerinden kaçınılmalıdır.

Solunum döngüleri, kaydedilen akciğer seslerinden bu doktora tezinde geliştirilen yöntem sayesinde otomatik olarak ayrıştırılmıştır. Ayrıştırılan solunum döngüsü türleri, sayıları ve oluşturulan veri setleri, ileride bölüm 2.2.1.4.’te Solunum Döngülerinden Veri Setlerinin Oluşturulması başlığı altında sunulmaktadır.

2.2.1.2. Ön işleme

Ön işlemede akciğer ses sinyali öncelikle birbiriyle %99 örtüşen çerçevelere bölünür. $x[n]$, N uzunluğundaki bir çerçeve, $w[n]$ ise aynı uzunlukta bir pencere fonksiyonu (Hamming penceresi, denklem-2) olarak kabul edilirse, pencere fonksiyonu uygulanmış sinyal $x_p[n] = x[n].w[n]$ olarak elde edilir. Daha sonra spektrogramı elde etmek için N -noktalı ayrık Fourier Dönüşümü denklem-1’deki gibi uygulanır.

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

burada $k = 0, 1, 2, \dots, N-1$ ’dir. Hamming pencere fonksiyonu $w[n]$, denklem-2’de verilmiştir.

$$w[n] = \begin{cases} 0.54 - 0.46 \cos\left(\frac{2\pi n}{N_w}\right), & 0 \leq n \leq N_w - 1 \\ 0, & N_w - 1 < n < 0 \end{cases} \quad (2)$$

Hamming penceresinin sadece N_w kadar uzunlukta bir aralıkta sıfır olmadığı varsayılır. Spektrogram hesaplandıktan bir sonraki adım f_L (80 Hz) ve f_H (1000 Hz) arasındaki $X[k]$ üzerinden enerjinin (denklem-3) hesaplanmasıdır.


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

Akciğer ses sinyalleri her ne kadar gürültüsüz bir ortamda kaydedilmeye çalışılsa da klinik ortamda tamamen gürültüsüz bir kayıt ortamı sağlamak oldukça zordur. Bu yüzden geliştirilecek yöntemin gürültülü kayıtlarda da başarılı olması beklenir. Örneğin, Şekil-8'deki $p[n]$ sinyalinde iki solunum döngüsü arasında bir gürültü etkisi vardır (Şekil-8'de sarı çerçeve ile özetlenmiştir). Bu tip bozulmayı önlemek ve daha yumuşak bir enerji dağılım grafiğine sahip olmak için $p[n]$ 'e medyan filtre uygulanır. Daha sonra ise hareketli (kayan) ortalama filtre ile daha düzgün bir hale getirilir (Bu iki filtreleme işlemi denklem-4'te *smooth* olarak adlandırılmıştır).

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

Düzeltilmiş enerji sinyali, şekil-8'de de görüldüğü üzere solunum döngülerinin sınır noktalarını temsil edilebilen yerel minimum noktaları içerir. Yerel minimum noktalar, ikinci türevin pozitif olduğu $X_s[n]$ nin birinci türevinin köklerinden denklem-5'teki gibi hesaplanır. Burada $minInd$, $X_s[n]$ 'nin minimum noktalarının indekslerini içeren vektördür.

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




Şekil 8. Frotman sesi için önışleme süreci örneği

2.2.1.3. Akciğer Seslerinden Solunum Döngülerinin Ayırıştırılması

Önişleme aşamasına örnek olması amacıyla Şekil-8'de frotman sesinin ön işleme süreci gösterilmektedir. Şekilde üstten alta doğru: frotman dalga formu, spektrogramı, spektrografi ve bant geçiren filtrelenmiş ortalama enerjinin yumuşatılmış hali görülmektedir. Ön işlemeden sonra elde edilen $X_s[n]$ sinyali incelendiğinde, daha pürüzsüz bir hale gelen solunum döngülerinin her biri ikişer pik değerine sahip olmak üzere, tekrar eden paternler olarak ortaya çıktığı görülmektedir. Solunum döngülerinin sınır noktalarının, bu paternlerin bazı minimum noktalarına karşılık geldiği anlaşılmaktadır. Dolayısıyla geliştirilen yöntem, solunum döngülerinin sınır noktalarını belirlemek için $X_s[n]$ sinyalinin minimum noktalarından ve solunum döngülerinin benzerliğinden faydalanmaktadır. Buradaki temel mantık, $X_s[n]$ sinyalinin başından itibaren iki solunum döngüsünün bulunması muhtemel bir uzunluğu belirlemek ve bu aralıkta yer alan minimum noktalar arasından solunum döngüsünü temsil eden muhtemel bir paterni model olarak seçmektir. Böylece bu model diğer minimum noktalar arasında yer alan test paternleri ile karşılaştırılabilir. Birbirlerine en çok benzeyen paternlerin sınırları solunum döngüsünün sınırları olarak belirlenmiş olur.

İlk adım, solunum döngülerini ayrı ayrı temsil eden model ($M_i[n]$) ve test kalıplarının ($T_{i,p}[n]$) belirlenmesidir. Solunum döngüsü sınırlarını elde etme sürecinin bir örneği olan Şekil-9, modelin belirleme aşamasını, test modellerini ve ilgili indisleri göstermektedir.



Şekil 9. Model ve test paternlerinin belirlenmesi

Olası tüm model ve test kalıplarının sınırları, denklem-5'de elde edilen minimum değerden seçilir. i .nci modelin alt ve üst sınırları sırasıyla bM_L^i ve bM_U^i olarak ifade

edilirse, modelin üst ve alt sınırları $1 \leq bM_L^i \leq bM_U^i \leq 2L_{max}$ aralığında seçilebilir. İki minimum nokta arasında yer alan ve bir solunum döngüsünü temsil edecek patern mutlaka bu aralıkta bulunacaktır. Dolayısıyla benzer paternleri karşılaştırmak amacıyla model paterni bu aralıkta seçilebilir. Ancak bir çok minimum nokta olması muhtemel olduğundan minimum noktaların bu aralıktaki sayısına bağlı olarak birçok model belirlenebilir. Bu çalışmada veri setindeki veriler üzerinden elde edilen tecrübeye dayanarak $L_{max} = 5.5$ saniye seçilmiştir. Seçilen model paterninin uzunluğu $L_{min} \leq bM_U^i - bM_L^i \leq L_{max}$ aralığında olmalıdır. Bu kısıtlama, model paterninin olası uzunluklarını kontrol ederek sürecin karmaşıklığını azaltmak için gereklidir. Seçilen L_{min} değeri, mümkün olan en kısa solunum döngüsünden daha kısa olmalıdır, veri setimizden elde edilen tecrübeye dayanarak bu çalışmada $L_{min} = 1.25$ saniye olarak belirlenmiştir. Bu koşulların hepsini göz önüne alarak, i . Model için, alt sınır indeksi olan bM_L^i , aşağıdaki fonksiyondan hesaplanır:

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

Modelin üst sınırı olan bM_U^i , bM_L^i değerine bağlı olarak yukarıdaki sınırlar içerisinde belirlenir. Böylece, model paterni $bM_L^i \leq n \leq bM_U^i$ aralığında $X_s[n]$ sinyalinin örneklerinden seçilir. Bununla birlikte, seçilen aralıktaki örnek sayısı fazla olacağı için, Dinamik Zaman Bükme (DZB) algoritmasında benzerlikleri karşılaştırma süreci de karmaşık ve uzun süreli olacaktır. Sürecin karmaşıklığını azaltmak için modelden eşit aralığa sahip N_s kadar örnek alınır. Burada, N_s sayısı örnekleme teorisine göre $X_s[n]$ sinyalinin maksimum frekansının en az iki katı olacak şekilde seçilir. Kayıtlarda aynı kişiye ait solunum sinyallerine ait genliklerin, nefesin güçlü bir şekilde alınıp verilmesine bağlı olarak değişkenlik gösterdiği anlaşılmaktadır. Benzer olması beklenen patern genliklerinin farklılıkları nedeniyle DZB algoritmasının hatalı sonuçlar üretmesini önlemek için model paterni kendi içinde normalize edilir. Modelin alt sınırı, bM_L^i , ve üst sınır bM_U^i belirlendiğinde, i . modeli temsil eden katsayılar $n = 0, \dots, N_s - 1$ olan aşağıdaki denklemden hesaplanır;

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

Burada, X_{sm}^i , X_s 'nin bM_U^i ve bM_L^i indisleri arasındaki genlik değerlerinin maksimumudur. Bir sonraki adım $M_i[n]$ ile karşılaştırılacak test örneği örneklerini belirtmektir. Her test paterni ($T_{i,p}[n]$), aynı alt sınıra sahip olan alt test modellerinden ($t_{p,r}[n]$) seçilir. Model örüntüsünden sonra belirlenecek olan ilk test modelinin alt sınırı ($bt_L^{p,r}$), o modelin üst sınırına (bM_U^i) eşit olacaktır. $bt_L^{p,r}$ sabit tutularak $L_{min} \leq bt_U^{p,r} - bt_L^{p,r} \leq L_{max}$ durumuna uyan alt test kalıplarının r -sayısı belirlenir. Genlik normalizasyonu, her alt test paterni için de uygulanarak eşit aralıklı N_s adet örnek, model paterninden seçilen örneklerle karşılaştırılmak amacıyla seçilir. Daha sonra, bu örnekler DZB algoritmasında $M_i[n]$ ile karşılaştırılır. Model paterni ile karşılaştırma sonucunda en küçük DZB değerinin elde edildiği test paterni, modelden sonraki ilk test paterni $T_{i,p}[n]$ olarak belirlenir. Bir sonraki adım, belirlenmiş test paterninden sonraki yeni bir test paterninin tanımlanmasıdır. Bunu yapmak için, belirlenen son test modelinin üst sınırı, yeni test modelinin alt sınırının indeksi olarak kabul edilir. Aynı işlem $X_s[n]$ sinyalinin sonuna kadar devam eder daha önceden belirtilen tüm koşullar yerine getirilir. i 'inci modelin p 'inci test modelini ($T_{i,p}[n]$) belirlemek üzere seçilen alt test modellerinin ($t_{p,r}[n]$) alt limit endeksleri, aşağıdaki şekilde hesaplanır:

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

burada r , alt test paternlerinin sayısıdır. r 'inci test paterninin üst sınır indeksi $L_{min} \leq bt_U^{p,r} - bt_L^{p,r} \leq L_{max}$ koşuluna göre belirlendikten sonra p 'inci test patern adayını belirlemek için oluşturulacak r 'inci test paterni aşağıdaki denklemden hesaplanır:

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

burada X_{st}^i, X_s 'nin bt_U^i ve bt_L^i indisleri arasındaki maksimum genlik değeridir. Belirlenen r -adet alt test paternleri, DZB algoritması kullanılarak $M_i[n]$ ile karşılaştırılır. Sonrasında,

minimum karşılaştırma sonuçlarına sahip olan alt test paterninin ($T_{i,p}[n]$)sınırları, üst ve alt sınırları ($bt_L^{i,p}, bt_U^{i,p}$) olarak belirlenir.

Sonuç olarak, model olarak belirlenen paternler ile bu modellere benzer olarak belirlenen test paternlerinin DZB algoritmasında karşılaştırılmasından sonra en küçük DZB değerine sahip olan model ve ona ait patern grubu, solunum döngülerini temsil eden paternler olarak belirlenir. Bu paternlerin sınır noktaları da orijinal akciğer sesindeki solunum döngülerinin başlangıç ve bitiş noktalarını temsil eder. Böylece orijinal sinyal içinden solunum döngüleri ayrıştırılabilir.

Dinamik Zaman Bükme Algoritması (DZB), iki vektörün birbirine yakın olan elemanlarını birbirine eşler ve benzer elemanlar arasındaki uzaklıkları hesaplayarak kümülatif olarak bir benzerlik değeri elde eder. En küçük DZB değeri, birbirine en çok benzeyen iki vektörü belirtir. Eğer DZB değeri sıfıra eşit ise karşılaştırılan iki vektörün tüm elemanları birbirine eşittir. Eğer model olarak belirlenen paternden karşılaştırma için seçilen veriler (m_1, m_2, \dots, m_M), test olarak belirlenen paternden alınan verileri ise (t_1, t_2, \dots, t_N) ile ifade edilirse, DZB algoritması ile bu iki vektör $D(M \times N)$ arasındaki mesafe aşağıdaki gibi hesaplanır [75]:

$$D(i, j) = \min \left\{ \begin{array}{l} D(i, j - 1) \\ D(i - 1, j) \\ D(i - 1, j - 1) \end{array} \right\} + d(m_i + t_j) \quad (10)$$

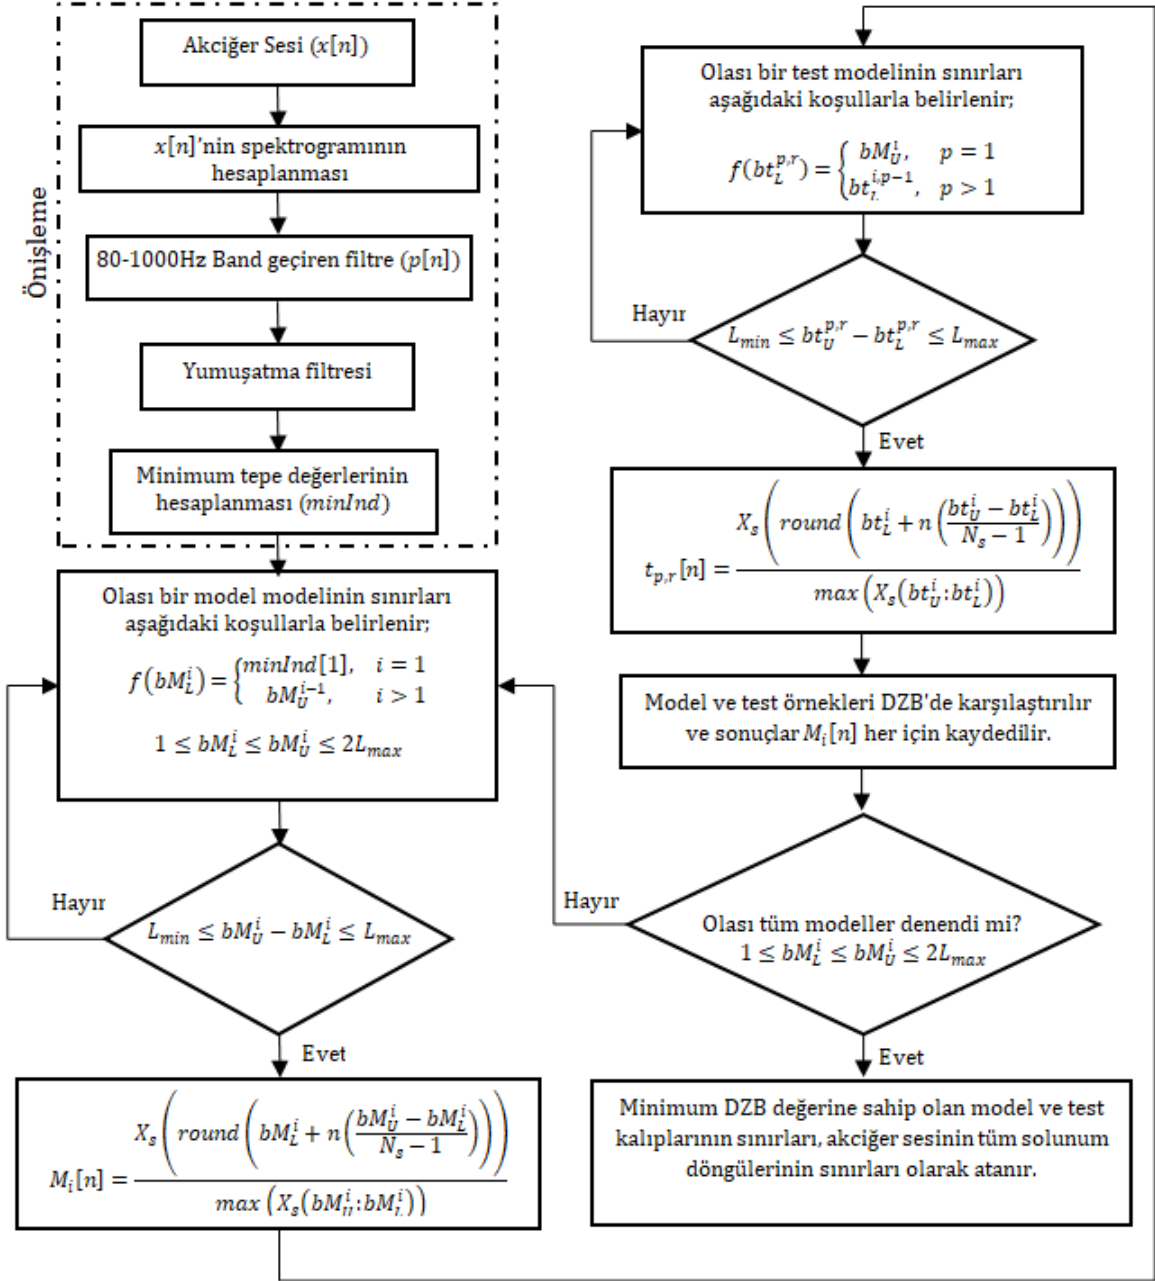
Bu tez çalışmasında $M = N = N_s$ olarak alınmıştır. Çünkü paternlerden eşit sayıda alınan örnekler karşılaştırılmaktadır. Yukarıdaki denklemde $d(m, t)$ yerel uzaklık fonksiyonudur. $i = 1, \dots, M$ ve $j = 1, \dots, N$ olmak üzere $d(m, t)$ denklem-11'deki gibi hesaplanır.

$$d(m, t) = \sqrt{\sum_i (m_i + t_i)^2} \quad (11)$$

İki vektörün karşılaştırılmasından elde edilen D değeri küçük ise bu iki vektör benzer, büyük ise benzerliğin az olduğunu belirtir. Sıfıra eşit ise iki vektör elemanları eşittir.

Solunum döngülerinin otomatik algılanması için önerilen yöntemin bileşenleri buraya kadar ayrıntılı olarak anlatılsa da yöntemin içeriğinin bütünüyle gözlemlenmesi

açısından akış diyagramı olarak özetlenmesi, konunun daha net anlaşılması açısından gereklidir. Bu amaçla oluşturulan akış diyagramı Şekil-10'da verilmektedir.



Şekil 10. Solunum döngülerinin otomatik algılanması için önerilen yöntemin akış diyagramı

2.2.1.4. Solunum Döngülerinden Veri Setlerinin Oluşturulması

Tablo 1. Sağlıklı/patolojik akciğer sesleri için tam solunum döngülerinden oluşturulan veri seti-2'nin içerdiği sesler

Veri seti-2 (Sağlıklı / patolojik akciğer sesleri) (toplam 1002 adet tam solunum döngüsü)			
<i>Sınıf-1</i>	<i>Sınıf-2</i>		
288 Solunum sesi	734 Solunum sesi		
Normal	İnce Ral	Kaba Ral	Ronküs
44 birey	33 birey	21 birey	35 birey
288 Solunum sesi	268 Solunum sesi	172 Solunum sesi	274 Solunum sesi

Geliştirdiğimiz yöntem ile solunum döngüleri otomatik olarak ayrıştırıldıktan sonra çalışmamız için üç farklı veri seti belirlenmiştir. İlk veri seti (veri seti-1), solunum döngülerinin otomatik ayrıştırılması amacıyla geliştirdiğimiz yöntemin başarısını test etmek amacıyla; normal, ince ral, kaba ral, ronküs, frotman ve tuber Sufl seslerine sahip üçer bireyden alınan toplam 21 kayıttan oluşturulmuştur. Bu ses kayıtlarının her biri minimum üç solunum döngüsüne sahiptir. Sağlıklı/patolojik ses ayrımı için oluşturulan veri seti-2'nin ayrıntıları Tablo-1'de, yaygın akciğer sesleri için oluşturulan veri seti-3'ün ayrıntıları ise Tablo-2'deki gibi oluşturulmuştur. Veri seti-2 ve veri seti-3'den de görüldüğü üzere toplamda 1002 solunum sesinden oluşmaktadır.

Tablo 2. Yaygın akciğer sesleri için tam solunum döngülerinden oluşturulan veri seti-3'ün içerdiği sesler

Veri seti-3 (Yaygın akciğer sesleri) (Toplam 1002 adet tam solunum döngüsü)			
<i>Sınıf-1</i>	<i>Sınıf-2</i>	<i>Sınıf-3</i>	<i>Sınıf-4</i>
Normal	İnce Ral	Kaba Ral	Ronküs
44 birey	33 birey	21 birey	35 birey
288 Solunum sesi	268 Solunum sesi	172 Solunum sesi	274 Solunum sesi

Yaygın akciğer sesleri Amerikan Toraks Derneğinin tanımına göre normal, ince al, kaba ral, ronküs ve wheezeden oluşmaktadır. Ancak, wheeze sesi stetoskoba gerek duyulmadan dışarıdan rahatlıkla duyulabildiğinden genellikle oskülte edilmezler. Bu yüzden yaygın akciğer seslerine wheeze sesi dâhil edilmemiştir.

Veri seti-2 ve veri seti-3, otomatik olarak algılanmış olan tam solunum döngülerinden oluşmaktadır. Otomatik olarak algılanmış solunum döngüleri daha sonra inspirasyon ve ekspirasyon fazlarına manuel olarak ayrıştırılmıştır. Sağlıklı/patolojik akciğer ses ayrımı için solunum döngülerinin inspirasyon fazlarından veri seti-4 oluşturulmuştur. Veri seti-4'ün içerdiği sesler Tablo-3'te gösterilmiştir.

Tablo 3. Sağlıklı/patolojik akciğer sesleri için inspirasyon seslerinden oluşturulan veri seti-4'ün içerdiği sesler

Veri seti-4 (Sağlıklı / patolojik akciğer sesleri) (toplam 1002 adet inspirasyon sesi)			
<i>Sınıf-1</i>	<i>Sınıf-2</i>		
288 inspirasyon sesi	734 inspirasyon sesi		
Normal	İnce Ral	Kaba Ral	Ronküs
44 birey	33 birey	21 birey	35 birey
288 inspirasyon sesi	268 inspirasyon sesi	172 inspirasyon sesi	274 inspirasyon sesi

Yaygın akciğer ses ayrımı için solunum döngülerinin inspirasyon fazlarından oluşturulan veri seti, veri seti-5 olarak adlandırılmış ve Tablo-4'te gösterilmiştir.

Tablo 4. Yaygın akciğer sesleri için inspirasyon seslerinden oluşturulan veri seti-5'in içerdiği sesler

Veri seti-5 (Yaygın akciğer sesleri) (Toplam 1002 inspirasyon sesi)			
<i>Sınıf-1</i>	<i>Sınıf-2</i>	<i>Sınıf-3</i>	<i>Sınıf-4</i>
Normal	İnce Ral	Kaba Ral	Ronküs
44 birey	33 birey	21 birey	35 birey
288 inspirasyon sesi	268 inspirasyon sesi	172 inspirasyon sesi	274 inspirasyon sesi

Ekspirasyon fazlarının sağlıklı/patolojik ayrımı için solunum döngülerinin inspirasyon fazlarından veri seti-6 oluşturulmuştur. Veri seti-6'nın içerdiği sesler Tablo-5'te gösterilmiştir.

Tablo 5. Sağlıklı/patolojik akciğer sesleri için ekspirasyon seslerinden oluşturulan veri seti-6'nın içerdiği sesler

Veri seti-6 (Sağlıklı / patolojik akciğer sesleri) (toplam 1002 adet ekspirasyon sesi)			
<i>Sınıf-1</i> 288 ekspirasyon sesi	<i>Sınıf-2</i> 734 ekspirasyon sesi		
Normal	İnce Ral	Kaba Ral	Ronküs
44 birey	33 birey	21 birey	35 birey
288 ekspirasyon sesi	268 ekspirasyon sesi	172 ekspirasyon sesi	274 ekspirasyon sesi

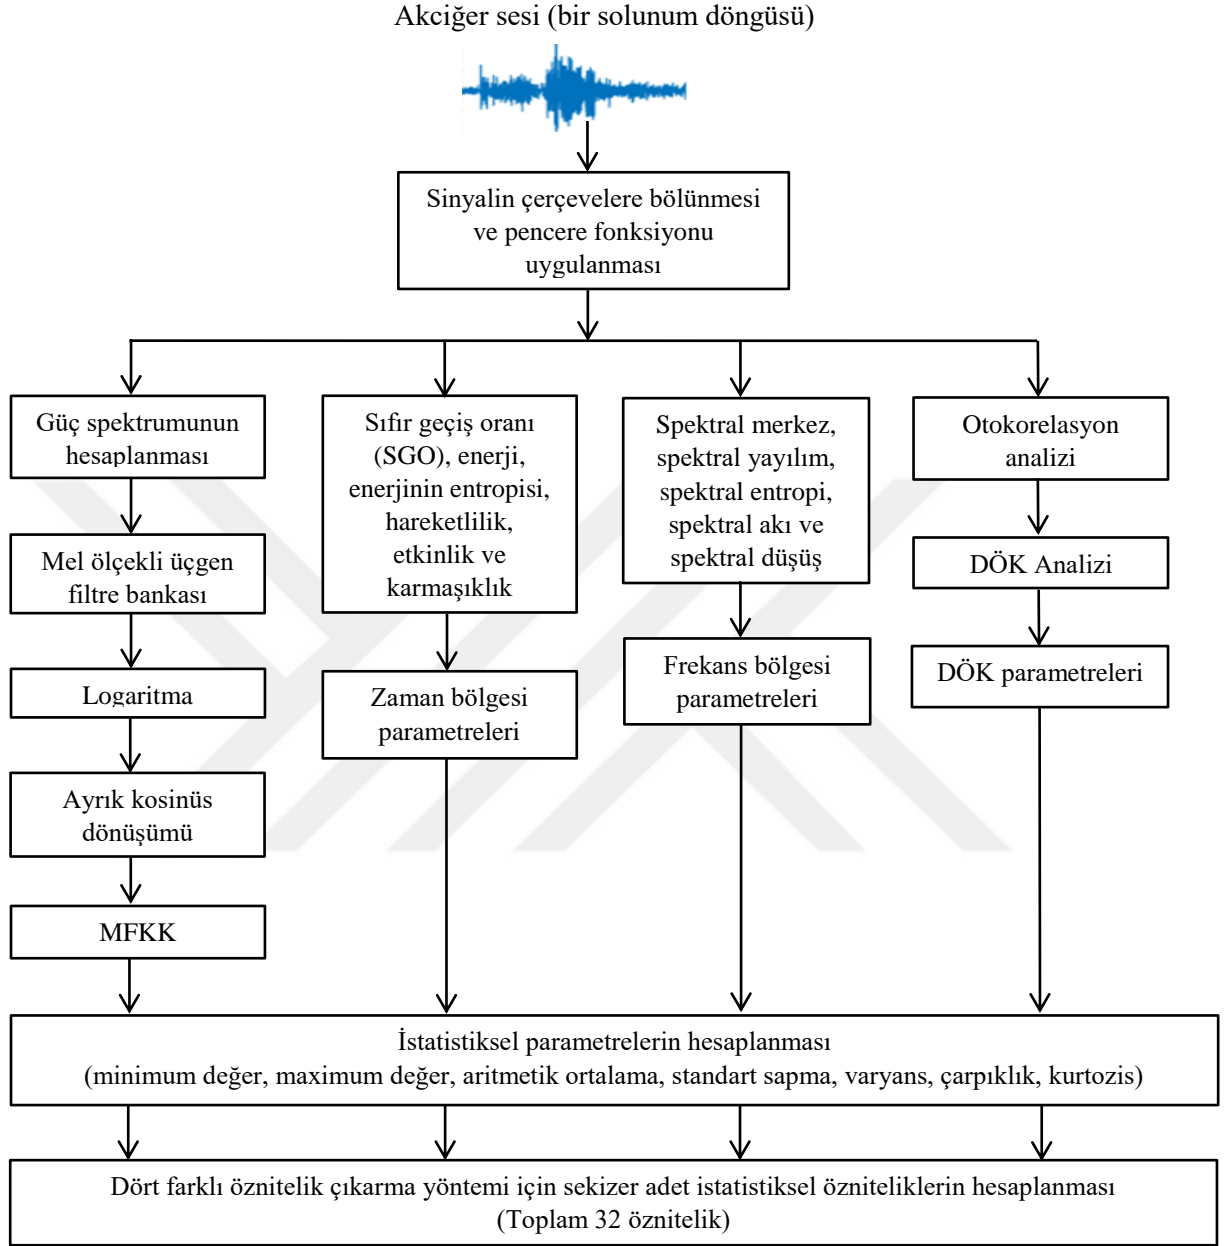
Yaygın akciğer ses ayrımı için solunum döngülerinin ekspirasyon fazlarından oluşturulan veri seti, veri seti-7 olarak adlandırılmış ve Tablo-6'da gösterilmiştir.

Tablo 6. Yaygın akciğer sesleri için ekspirasyon seslerinden oluşturulan veri seti-7'nin içerdiği sesler

Veri seti-7 (Yaygın akciğer sesleri) (Toplam 1002 ekspirasyon sesi)			
<i>Sınıf-1</i>	<i>Sınıf-2</i>	<i>Sınıf-3</i>	<i>Sınıf-4</i>
Normal	İnce Ral	Kaba Ral	Ronküs
44 birey	33 birey	21 birey	35 birey
288 ekspirasyon sesi	268 ekspirasyon sesi	172 ekspirasyon sesi	274 ekspirasyon sesi

Böylece toplamda yedi farklı veri seti oluşturulmuştur. Bunlardan veri seti-1, otomatik olarak algılanan solunum döngülerinin doğru belirlenip belirlenmediğini araştırmak amacıyla kullanılmıştır. Geriye kalan diğer altı veri seti ise sınıflandırma başarımını ölçmek amacıyla kullanılmıştır.

2.2.1.4.1. Kullanılan Öznitelik Çıkarma Yöntemleri



Şekil 11. Kullanılan özniteliklerin elde edilme süreci

Akciğer ses sinyalindeki örneklerin tamamını kullanmak yerine onları temsil edebilecek en önemli özelliklerin çıkarılarak daha küçük boyutta öznitelik vektörünün çıkarılması sınıflandırmanın önemli bir aşamasıdır. Çıkarılan öznitelikler sınıflandırmanın başarısını direk olarak etkileyen faktörlerden biridir. Bu proje çalışmasında kullanılan öznitelikler ve özniteliklerin elde edilme süreci şekil-11’de gösterilmektedir.

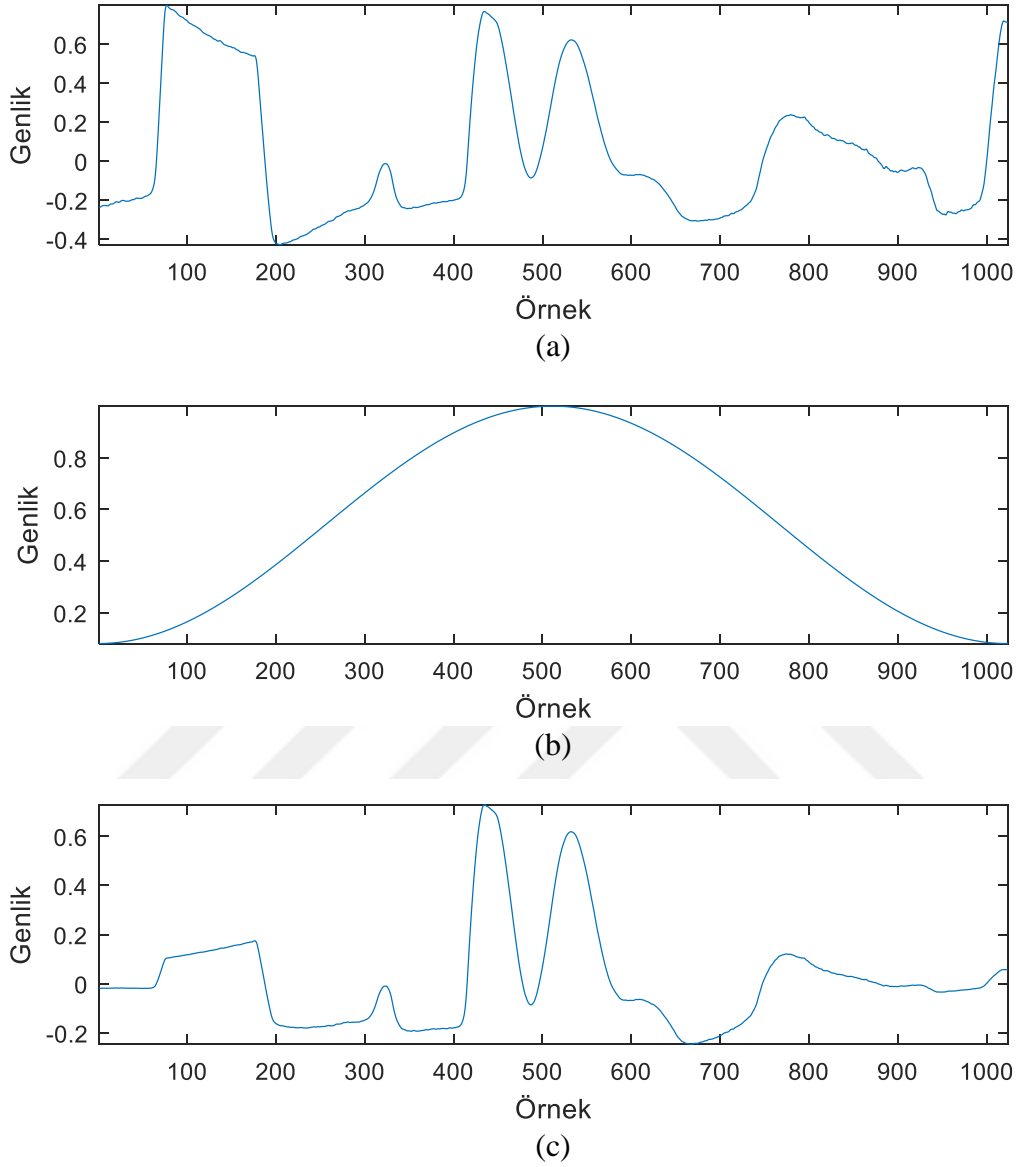
Kişinin nefes alış verişine bağlı olarak, havanın akciğerlerdeki hava kanallarında yer değiştirmesinden dolayı akciğer ses işareti sürekli olarak değişir. Bu nedenle akciğer ses sinyali, sesin durağan kabul edildiği N örnek uzunluğundaki kısa süreli çerçevelere bölünür. İlk çerçeve hariç, tüm çerçevelere kendisinden önceki çerçeve ile $N - M$ kadar ($M < N$ sağlayacak şekilde) örtüşme uygulanır [75]. Örtüşme uygulanmasının sebebi kaydırmada bilgi kaybını önlemektir. Böylece sinyalin çerçeve sonundaki bileşenlerinin önemini kaybetmemesi sağlanır. Bu tez çalışmasında çerçeve uzunluğu 32ms ve $M = N/2$ olarak (% 50 örtüşme) alınmıştır.

Sinyalin çerçevelere bölünmesinden sonraki işlem her bir çerçeveye pencere fonksiyonu uygulanmasıdır. Pencere fonksiyonu yardımıyla sinyalin başı ve sonundaki kesmelerden kaynaklanan süresiz kısımlar azaltılır. Böylece bilgi içermeyen kısımlar bastırılarak spektral bozulmanın önüne geçilmiş olur. Pencere fonksiyonu $w(n)$ olarak kabul edilirse, giriş işareti $x(n)$ ile çıkış işareti $y(n)$ arasındaki eşitlik;

$$y(n) = x(n)w(n) \quad (12)$$

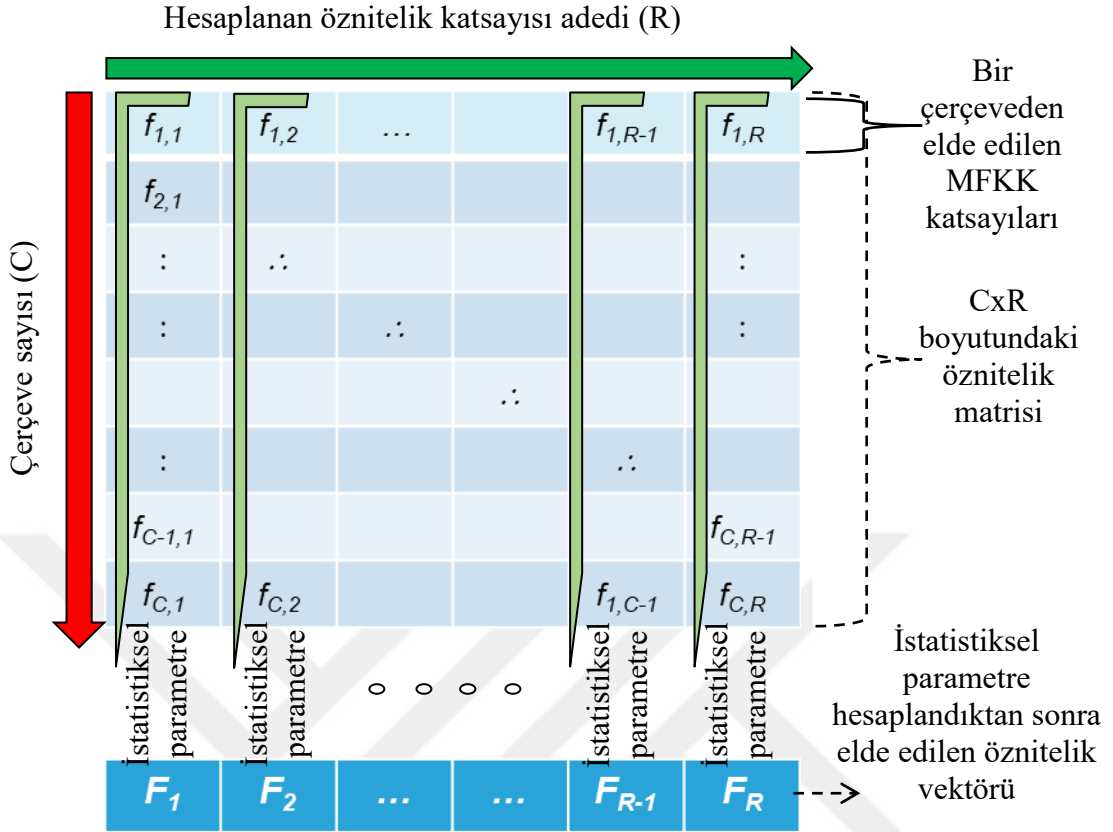
olarak ifade edilir. Bu çalışmada pencere fonksiyonu olarak daha önce denklem-2 'de ifadesi verilen Hamming penceresi kullanılmıştır. Bir akciğer ses sinyal çerçevesi için Hamming penceresinin uygulama aşaması Şekil-12 'de gösterilmektedir. Daha önce şekil 11'de de bahsedildiği üzere çerçevelere pencere fonksiyonu uygulandıktan sonraki adım özniteliklerin hesaplanmasıdır. Herhangi bir çerçeveden hesaplanan bir öznitelik vektörü, akciğer ses sinyaline ait öznitelik matrisinin bir satırını oluşturur. Bu satırlar çerçeveler hesaplandıkça alta alta sıralanır. Sonuç olarak satır sayısı çerçeve sayısına, sütun sayısı ise hesaplanan öznitelik katsayı adedine bağlı olarak değişen bir öznitelik matrisi elde edilir.

Solunum döngülerinin süreleri hem kişisel özelliklere, hem de hastalık türüne bağlı olarak (hızlı ya da yavaş nefes alma durumuna göre) değişkenlik göstermektedir. Sinyallerden elde edilen çerçevelerin boyutu sabit tutulsa da, solunum döngüsünün uzunluğuna bağlı olarak elde edilen toplam çerçeve sayısı değişebilmektedir. Dolayısıyla, öznitelik matrisinin satır sayısı da değişkenlik göstermektedir. Bu durum ise sınıflandırma algoritmalarında farklı boyutlardaki verileri karşılaştırmamızı gerektirdiğinden sorun olarak karşımıza çıkmaktadır. Bu sorunun üstesinden gelmek için bu tez çalışmasında, özellik matrisinin her bir sütunundan ayrı ayrı istatistiksel parametrelerin hesaplanmasını öngören bir yöntem önerilmiştir.



Şekil 12. (a) 32ms uzunluklu akciğer ses çerçevesi, (b) 32ms uzunluğunda Hamming penceresi, (c) Akciğer ses işaretinin pencere fonksiyonu uygulanmış hali

Bir kayıttan elde edilen öznelik matrisine örnek olarak bir model Şekil-13'te gösterilmiştir. Şekil-13'te her satır bir çerçeveden elde edilen öznelik vektörünü ifade etmektedir. Hesaplanan özneliğin sayısı ise sütun sayısıdır. Böylece hesaplanan istatistiksel parametrenin türüne bağlı olarak özellik matrisinden bir adet öznelik vektörü elde edilmiş olur. Öznelik vektörünün boyutu ise öznelik matrisinin sütun sayısı kadardır. Bu sayede sınıflandırma aşamasında yaşanacak zorlukların önüne geçilmiş olur.



Şekil 13. Bir öznelik matrisinden istatistiksel parametrelerin hesaplanması

Öznelik olarak zaman bölgesi parametreleri, frekans bölgesi parametreleri, MFKK ve DÖK katsayılarından oluşan geniş bir öznelik araştırılması yapılmıştır. Daha sonra bu özneliklerden elde edilen özellik matrislerinden istatistiksel parametreler yardımıyla öznelik vektörleri hesaplanmıştır. Devam eden kısımlarda bu çalışmada kullanılan öznelik çıkarma yöntemlerinden bahsedilmektedir.

2.2.1.4.2. Zaman Bölgesi Parametreleri

Zaman bölgesinden elde edilen özneliklerin en önemli avantajı, herhangi bir matematiksel dönüşüm gerektirmeden hızlı bir şekilde hesaplanabilmesidir. Fakat bu öznelikler, sinyalin genliği kullanılarak hesaplandığından gürültüye ve diğer rahatsız edici etkilere duyarlı olabilirler. Bu tez çalışmasında, zaman bölgesi öznelikleri olarak sıfır geçiş oranı (SGO), enerji, enerjinin entropisi, hareketlilik, etkinlik ve karmaşıklık parametreleri hesaplanmıştır. SGO, sinyalin pozitiften negatife veya negatiften pozitifte değişme oranıdır ve denklem-13'deki gibi hesaplanır.

$$\frac{1}{2N} \sum_{n=1}^N |sgn[x_i(n)] - sgn[x_i(n-1)]| \quad (13)$$

Burada $x_i(n)$ terimi, ses sinyalinin i . çerçevesinin örneklerini temsil eder. Ayrıca, N çerçevenin uzunluğudur. Signum fonksiyonu (sgn) ise denklem 14'deki gibi tanımlanır.

$$sgn[x_i(n)] = \begin{cases} 1, & x_i(n) > 0 \\ 0, & x_i(n) = 0 \\ -1, & x_i(n) < 0 \end{cases} \quad (14)$$

Ses sinyallerinin işlenmesindeki temel parametrelerden biri olan kısa zaman enerjisi, ses sinyalinin i . çerçevesi için denklem-15'deki gibi hesaplanır.

$$E(i) = \sum_{n=1}^N [x_i(n)]^2 \quad (15)$$

Bir diğer zaman bölgesi parametrelerinden olan enerjinin entropisi, bir sinyalin zaman-enerji içeriğinin düzensizliğini belirler. Enerjinin entropisini hesaplamak için, seçilen x_i çerçevesi, eşit uzunluktaki M alt-çerçevelerine bölünür. Ardından, her alt çerçevenin enerjisi, denklem-15 kullanılarak hesaplandıktan sonra, çerçevenin toplam enerjisine bölünür. Eğer alt çerçevelerin enerjisi $e_j, j = 1, \dots, M$ ise, enerjinin entropisi (H_i) denklem-16'daki gibi hesaplanır.

$$H_i = -\sum_{j=1}^M e_j \cdot \log_2(e_j) \quad (16)$$

Zaman bölgesinden hesaplanan son üç parametre ise Hjorth parametreleridir. Bu parametreler esas olarak Hjorth tarafından bir elektroensefalogram (EEG) sinyalinin nicelendirilmesi için geliştirilmiştir [76]. Hjorth parametreleri, etkinlik (H_E), hareketlilik (H_H) ve karmaşıklıktan (H_K) oluşur. Ayrık zamanlı $x[n]$ 'nin (analiz edilecek akciğer ses sinyalinin segmentinin) Hjorth parametrelerinin hesaplanması, $x[n]$ 'nin varyansını (σ_0^2) ve aynı zamanda $x[n]$ 'nin birinci ve ikinci türevlerinin standart sapmalarını (σ_1 ve σ_2) kapsar. Varyans, bir serideki değerlerin aritmetik ortalamadan sapmalarının karelerinin ortalamasıdır. Aritmetik ortalama aşağıdaki eşitlikten hesaplanır.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (17)$$

x , N uzunlukta bir seri, \bar{x} 'de bu serinin ortalamasını, σ standart sapmasını ve σ^2 de varyansını temsil etmek üzere, σ^2 aşağıdaki eşitlikten hesaplanır.

$$\sigma^2 = \frac{1}{N} \sum_{n=1}^N (x(n) - \bar{x})^2 \quad (18)$$

Etkinlik parametresi (H_E) sinyalin genişliğini temsil eder ve denklem 19'da da gösterildiği gibi sinyalin varyansına eşittir.

$$H_E = \sigma_0^2 \quad (19)$$

Hareketlilik, sinyalin birinci türevinin etkinlik parametresi ile orijinal sinyalin etkinlik parametresi arasındaki oranın karekökü olarak denklem 20'deki gibi hesaplanır.

$$H_H = \frac{\sigma_1}{\sigma_0} \quad (20)$$

Bant genişliğinin kestirimi olarak da bilinen karmaşıklık parametresi, sinyalin birinci türevinin hareketliliği ile sinyalin hareketliliği arasındaki oran olarak denklem 21'deki gibi hesaplanır.

$$H_K = \sqrt{\left(\frac{\sigma_2}{\sigma_1}\right)^2 - \left(\frac{\sigma_1}{\sigma_0}\right)^2} \quad (21)$$

2.2.1.4.3. Frekans Bölgesi Parametreleri

Frekans bölgesinde öznitelik elde etmek amacıyla kullanılan parametreler spektral merkez, spektral yayılım, spektral entropi, spektral akı ve spektral düşüşten oluşmaktadır. Bu beş parametreden biri olan spektral merkez, denklem-22 ile gerçekleştirilen Ayrık Fourier Dönüşümü (AFD) sonrasında elde edilen spektrumun ağırlık merkezi belirlenerek elde edilir.

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-\frac{j2\pi kn}{N}} \quad (k = 0, 1, \dots, N - 1) \quad (22)$$

Spektral özelliklerin hesaplanması için frekans spektrumunun ilk yarısı ile çalışmak yeterlidir. Bu nedenle spektral merkez (C_i), i . çerçeve için denklem-23'deki gibi hesaplanır.

$$C_i = \frac{\sum_{k=1}^{N/2} kX_i(k)}{\sum_{k=1}^{N/2} X_i(k)} \quad (23)$$

Spektral yayılım (S_i), spektrumun merkez çevresinde dağılımı hakkında bilgi verir ve denklem-24'den hesaplanır.

$$S_i = \sqrt{\frac{\sum_{k=1}^{N/2} (k-C_i)^2 X_i(k)}{\sum_{k=1}^{N/2} X_i(k)}} \quad (24)$$

Spektral entropinin hesaplanacağı çerçeve öncelikle L adet altbanda bölünür. Daha sonra, her f 'inci altbandın enerjisi, çerçevenin toplam band enerjisine bölünerek n_f ($f = 0, 1, \dots, L - 1$) elde edilir. Spektral entropi ise denklem-25 kullanılarak hesaplanır.

$$H = -\sum_{f=0}^{L-1} n_f \cdot \log_2(n_f) \quad (25)$$

İki ardışık çerçeve arasındaki spektral değişim olan spektral akıyı hesaplamak için denklem-26 kullanılır.

$$SF_{(i,i-1)} = \sum_{k=1}^{N/2} (X_i(k) - X_{i-1}(k))^2 \quad (26)$$

Burada $X_i(k)$, i . çerçeve içinde ayrık fourier dönüşümü (AFD) 'nün normalleştirilmiş katsayısı olarak ifade edilir.


Frekans spektrumundaki büyüklüklerin toplamının önceden belirlenmiş bir yüzde değerine karşılık gelen frekans değerine spektral düşüş denir. Bu çalışmada yüzde değeri %85 olarak seçilmiştir. m 'inci DFT katsayısının, i 'inci karenin spektral bozunumuna karşılık geldiğini düşünürsek, spektral düşüş, denklem-27 kullanılarak hesaplanabilir.

$$\sum_{k=1}^m X_i(k) = 0.85 \sum_{k=1}^{N/2} X_i(k) \quad (27)$$

2.2.1.4.4. Mel Frekansı Kepstrum Katsayıları

Mel Frekansı Kepstrum Katsayıları ses tanıma çalışmalarında en sık kullanılan öznel çıkarma yöntemlerinden biridir. Melodinin kısaltması olarak kullanılan Mel kavramı ilk olarak Stevens ve ark. [77] tarafından kullanılmıştır. Ayrıca, deneklerin psikofizik ayarlamaları deneylerinde verdikleri cevaplara dayanarak perdelerin psikolojik algılanması cetvelini (mel ölçeğini) ortaya çıkarmışlardır. Bu ölçeğe göre, insanların duydukları perde aralıklarının frekans aralıklarıyla tamamen düz orantılı olmadığını, logaritmik bir şekilde de bağlantılı olduğunu göstermişlerdir. Deneklerden elde edilen veriler insan kulağının 1kHz'in altındaki frekansları doğrusal ölçekli, 1kHz'in üstündeki frekansları ise logaritmik ölçekli olarak duyduğunu ortaya koymuştur. Dolayısıyla işitsel dönüşüm, insanoğlunun psikoakustik sisteminden kaynaklanmaktadır. Psikoakustik kulak tepkisine göre Hertz'i Mel ölçeğine çevirmek için yaygın olarak kabul gören ve kullanılan O'shaughnessy'nin matematiksel modeli [78] denklem-29'da verilmektedir.

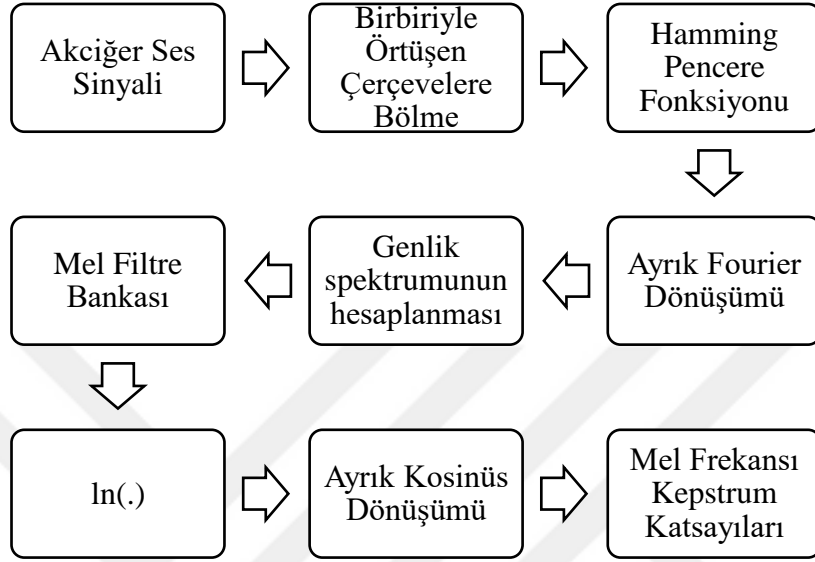
$$f_{mel} = 2595 \log_{10} \left(\frac{f}{700} + 1 \right) \quad (28)$$



Şekil 14. Frekans ve Mel skalası arasındaki ilişki

Frekans ve mel ölçekleri arasındaki ilişki şekil-14'de görselleştirilmiştir. Mel frekansı kepstrum katsayılarının elde ediliş sürecinin genel akış şeması ise şekil-15'de gösterilmiştir. Bu şemaya göre akciğer seslerine yapılacak olan işlem öncelikle ses sinyalinin birbiriyle örtüşen çerçevelere bölmektir.

Daha önce bölüm 2.2.1.4.1.'de “Kullanılan öznelik çıkarma yöntemleri” başlığı altında akciğer ses sinyalinin çerçevelere bölünmesi ve çerçevelere Hamming pencere fonksiyonu uygulanması kısımlarından bahsedilmişti.



Şekil 15. MFKK hesaplama süreci akış diyagramı

Pencere fonksiyonu uygulandıktan sonraki adım, her çerçevenin genlik spektrumunu hesaplamaktır. İnsanlar sesleri dinlerken seslerin frekansına bağlı olarak iç kulağın işitsel kısmı olan kokleada titreşimler oluşur. Kokleadın titreştiği bölgesine bağlı olarak farklı görevlere sahip sinirler beyne belirli frekansların bulunduğunu bildirir. Genlik spektrumu, akciğer seslerinde hangi frekansların bulunduğunu belirleyerek bizim için benzer bir iş gerçekleştirir. Genlik spektrumu (G) denklem-29'dan hesaplanır.

$$G_i(k) = |X_i(k)| \quad (29)$$

Böylece genlik spektrumu hem frekans hem de büyüklük açısından ölçeklendirilerek elde edilmiş olur. Bundan sonra frekans eksenini, Mel filtre bankası ($H(k, m)$) kullanılarak logaritmik olarak ölçeklendirilir. Bu durum, i . çerçeve için denklem-30'da ifade edilmektedir.

$$X'_i(m) = \ln\left(\sum_{k=0}^{N-1} G_i(k)H(k, m)\right) \quad (30)$$

Burada M , $m = 1, 2, \dots, M$ ($M \ll N$) için filtre bankasındaki filtre sayısıdır. Mel filtre bankası, merkez frekansları ($f_c(m)$) tarafından tanımlanan üçgen filtrelerden oluşur ve dekleme-31'deki gibi ifade edilir;

$$f(x) = \begin{cases} 0, & f(k) < f_c(m-1) \\ \frac{f(k)-f_c(m-1)}{f_c(m)-f_c(m-1)}, & f_c(m-1) \leq f(k) < f_c(m) \\ \frac{f(k)-f_c(m+1)}{f_c(m)-f_c(m+1)}, & f_c(m) \leq f(k) < f_c(m+1) \\ 0, & f(k) \geq f_c(m+1) \end{cases} \quad (31)$$

Mel filtre bankasındaki merkez frekanslar denklem-28 yardımıyla hesaplanır. Daha sonra, denklem-32 ile Mel ölçeğinde sabit bir frekans çözünürlüğü olan $\Delta\phi$ hesaplanır. Mel ölçeğindeki üçgen filtrelerin merkezi frekansları $\Delta\phi$ kadar aralıklarla yerleştirilir.

$$\Delta\phi = (\phi_{max} - \phi_{min}) / (M + 1) \quad (32)$$

Burada ϕ_{max} , frekans ölçeğindeki en büyük frekans değeri olan (örnekleme frekansının yarısı) eşit olan f_{max} 'ın denklem-28 yardımıyla elde edilen mel frekans ölçeğindeki karşılığıdır. ϕ_{min} ise frekans ölçeğindeki minimum frekans olan f_{min} değerinin mel ölçeğindeki karşılığıdır. Bu tez çalışmasında $f_{min} = 0$, $f_{max} = 16000 \text{ Hz}$ ve $M = 30$ olarak alınmıştır. Bu durumda mel ölçeğindeki merkez frekansları

$$\phi_c(m) = m \cdot \Delta\phi \quad (33)$$

eşitliği ile verilir. Burada $m = 1, 2, \dots, M$ 'dir. Mel ölçeğinde eşit aralıklarla yerleştirilen merkez frekansları denklem-28'un tersi olan denklem-34 sayesinde yeniden frekans ölçeğine dönüştürülür.

$$f_{Hz} = 700(10^{f_{mel}/2595} - 1) \quad (34)$$

Sonuç olarak MFKK, $X'_i(m)$ 'nin denklem-35'de verilen ayırık kosinüs dönüşümünün hesaplanması ile elde edilmiş olur.

$$c(l) = \sum_{m=1}^M X'_i(m) \cos\left(l \frac{\pi}{M} \left(M - \frac{1}{2}\right)\right) \quad (35)$$

Burada $l = 1, 2, \dots, M$ olmak üzere, $c(l)$, l 'inci MFKK'dır.

2.2.1.4.5. Doğrusal Öngörülü Kodlama

Ses sinyali işlemede sıklıkla kullanılan yöntemlerden biri olan DÖK, ses sinyalinin sıkıştırılmış bir biçimini temsil eder. Ses sinyalinin bir örneğinin kendinden önceki ses örneklerinin doğrusal bir birleşimi olarak ifade edilmesi prensibine dayanır [79]. Akciğer ses sinyalleri zamanla değiştiği için, bu işlem ses sinyalinin durağan olarak kabul edildiği çerçeveler üzerinde yapılır.

DÖK yöntemi, durağan kabul edilen ses çerçevesinin n 'inci örneğinin kendinden önceki geçmiş p adet ses örneklerinin doğrusal bir birleşimi olarak denlem-36'daki gibi a_k katsayılarına bağlı olarak yazılabileceği varsayımıyla hareket eder.

$$\hat{s}(n) \approx a_1 s(n-1) + a_2 s(n-2) + \dots + a_p s(n-p) = \sum_{k=1}^p a_k s(n-k) \quad (36)$$

Burada incelenen ses sinyali çerçevesinin durağan olduğu kabul edildiğinden a_k katsayılarının da sabit olduğu kabul edilirse sinyal, özbağlanımlı bir süreç olarak modellenebilir. Öyleyse yukarıdaki denklemler, bir uyarma terimi olan $Gu(n)$ dahil edilerek şu şekilde dönüştürülebilir:

$$s(n) = \sum_{i=1}^p a_i s(n-i) + Gu(n) \quad (37)$$

Burada $Gu(n)$ (G kazanç, $u(n)$ uyarım işareti) uyarım terimidir. Denklem-37 z-bölgesine dönüştürüldüğünde;

$$S(z) = \sum_{i=1}^p a_i z^{-i} S(z) + GU(z) \quad (38)$$

ve sonuç olarak, transfer fonksiyonu $H(z)$, aşağıdaki gibi elde edilir.

$$H(z) = \frac{S(z)}{GU(z)} = \frac{1}{1 - \sum_{i=1}^p a_i z^{-i}} = \frac{1}{A(z)} \quad (39)$$

$\hat{s}(n)$ 'yi n . Örnekten önceki p kadar geçmiş örneğin doğrusal kombinasyonu olarak tanımlayıp, aynı sistemi doğrusal öngörü mantığı ile incelersek;

$$\hat{s}(n) = \sum_{k=1}^p a_k s(n-k) \quad (40)$$

Bu durumda tahmin (öngörü) hatası $e(n)$ şu şekilde tanımlanır:

$$e(n) = s(n) - \hat{s}(n) = s(n) - \sum_{k=1}^p a_k s(n-k) \quad (41)$$

Deklem-41, z -bölgesine dönüştürülürse;

$$E(z) = S(z) \left[1 - \sum_{k=1}^p a_k z^{-k} \right] = S(z) A(z) \quad (42)$$

Bu ifadeyi $s(n)$ 'i çıkış olarak görebileceğimiz bir transfer fonksiyonuna dönüştürürsek;

$$H(z) = \frac{S(z)}{E(z)} = \frac{1}{1 - \sum_{k=1}^p a_k z^{-k}} = \frac{1}{A(z)} \quad (43)$$

olarak elde edilir. Böylece girişi öngörü hatası $u(n)$, transfer fonksiyonu $H(z)$ ve çıkışı $s(n)$ olan bir özbağlanımlı model oluşturulmuş olur.

Sistemin çıktısı olan $A(z)$ ise aşağıdaki gibi ifade edilir;

$$A(z) = 1 - \sum_{k=1}^p a_k z^{-k} \quad (44)$$

Eğer $\hat{a}_k = a_k$ alınırsa, aşağıdaki eşitliğe sahip oluruz.

$$H(z) = \frac{G}{A(z)} \quad (45)$$

Temel amaç, bir çerçevedeki tahmin hatasının karesini en aza indirgeyen a_k katsayılar kümesini elde etmektir. Hatayı minimize etmek, $\hat{s}(n)$ 'yi olabildiğince $s(n)$ 'ye yaklaştırmakla mümkündür. Fakat a_k katsayılarının olasılık dağılım bilgisi bulunmadığından, ortalama karesel hatayı minimuma indirecek a_k katsayıları tespit edilir.

Akciğer sesleri öznelik elde edilme sürecinin başında çerçeveler halinde bölündüğünden, doğrusal öngörü katsayıları da her çerçeveden ayrı ayrı hesaplanacaktır. n anında başlayan bir çerçevenin m 'inci örneği $s_n(m)$ ile ifade edildiğinde aşağıdaki tanımlamalar yapılabilir.

$$s_n(m) = s(m + n) \quad (46)$$

$$e_n(m) = e(m + n) \quad (47)$$

Bu tanımlara bağlı olarak, çerçeve başına ortalama karesel hata denklem-48'deki gibi tanımlanır.

$$E_n = \sum_m e_n^2(m) = \sum_m [s_n(m) - \sum_{k=1}^p a_k s_n(m - k)]^2 \quad (48)$$

E_n hata değerini en aza indirgeyen a_k katsayıların değerleri denklem-49 yardımıyla elde edilebilir. E_n 'nin

$$\frac{dE_n}{da_k} = 0, \quad k = 1, 2, \dots, p \quad (49)$$

Yukarıdaki çözüm, denklem-50 ile ifade edilir.

$$\sum_m s_n(m - i) s_n(m) = \sum_{k=1}^p \hat{a}_k \sum_m s_n(m - i) s_n(m - k) \quad (50)$$

Buradaki $\sum_m s_n(m - i) s_n(m - k)$ kovaryans bağıntısı olarak tanımlanır;

$$\phi_n(i, k) = \sum_m s_n(m - i) s_n(m - k) \quad (51)$$

Bu tanıma göre denklem-50'yi yeniden yazarsak;

$$\phi_n(i, 0) = \sum_{k=1}^p \hat{a}_k \hat{\phi}_n(i, k) \quad (52)$$

elde edilir. Denklem-52, Yule-Walker eşitliği olarak bilinir ve p bilinmeyenli p adet eşitliği ifade eder. Bu durumda, hatayı minimize eden eşitlik denklem-53'deki gibi elde edilir.

$$E_n = \sum s_n^2(m) - \sum_{k=1}^p a_k \sum_m s_n(m) s_n(m-k) \quad (53)$$

veya sıkıştırılmış formda denklem-54'deki gibi gösterilebilir.

$$E_n = \phi_n(0,0) - \sum_{k=1}^p a_k \phi_n(0,k) \quad (54)$$

En optimum a_k katsayılarını belirleyerek denklem-52'yi çözmek için, $\phi_n(i,k)$ değerleri $1 \leq i \leq p$ ve $0 \leq k \leq p$ için hesaplanmalıdır. Daha sonra eşzamanlı p denklem takımı çözülür.

Denklem-48'de karesel öngörü hata ifadesindeki incelenen çerçeve ($0 \leq m \leq N - 1$) işaretin sıfır olduğu kabulü yapılmıştı. $w(m)$ de, sonlu uzunluklu ve $0 \leq m \leq N - 1$ dışında sıfır olan bir çerçeve fonksiyonu olarak kabul edilirse $s_n(m)$ işareti denklem-55'deki gibi tanımlanabilir;

$$s_n(m) = s(m+n).w(m) \quad (55)$$

Gerçek değer ile tahmin değeri arasındaki öngörü hata ifadesi yeniden yazılırsa;

$$e_n(m) = s_n(m) - \hat{s}_n(m) = s_n(m) - \sum_{k=1}^p a_k s_n(m-k) \quad (56)$$

elde edilir. Denklem-56 incelendiğinde ve $0 \leq m \leq N - 1 + p$ aralığında öngörü hatasının sıfırdan farklı değerler alabildiği görülmektedir. Öyleyse, öngörü hatası denklem-57'de olduğu gibi yeniden ifade edilebilir.

$$E_n = \sum_{m=0}^{N+p-1} e_n^2(m) \quad (57)$$

Bu durumda $\phi_n(i,k)$;

$$\phi_n(i, k) = \sum_{m=0}^{N+p-1} s_n(m-i)s_n(m-k), \quad \begin{array}{l} 1 \leq i \leq p \\ 0 \leq k \leq p \end{array} \quad (58)$$

ya da

$$\phi_n(i, k) = \sum_{m=0}^{N-1-(i-k)} s_n(m)s_n(m+i-k), \quad \begin{array}{l} 1 \leq i \leq p \\ 0 \leq k \leq p \end{array} \quad (59)$$

olarak ifade edilebilir. Denklem-59, $(i-k)$ 'nın bir fonksiyonu olduğundan, kovaryans fonksiyonu $\phi_n(i, k)$, basit otokorelasyon fonksiyonuna indirgenir. Diğer bir deyişle;

$$\phi_n(i, k) = r_n(i-k) = \sum_{m=0}^{N-1-(i-k)} s_n(m)s_n(m+i-k) \quad (60)$$

olarak ifade edilir. Özilinti fonksiyonu simetrik olduğundan ($r_n(k) = r_n(-k)$) doğrusal öngörü katsayıları aşağıdaki gibi tanımlanır.

$$\sum_{k=1}^p r_n(|i-k|)\hat{\alpha}_k r_n(i), \quad 1 \leq i \leq p \quad (61)$$

Bu ifade, denklem-62'deki gibi matris formunda da yazılabilir.

$$\begin{bmatrix} r_n(0) & r_n(1) & r_n(2) & \cdots & r_n(p-1) \\ r_n(1) & r_n(0) & r_n(1) & \cdots & r_n(p-2) \\ r_n(2) & r_n(1) & r_n(0) & \cdots & r_n(p-3) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_n(p-1) & r_n(p-2) & r_n(p-3) & \cdots & r_n(0) \end{bmatrix} \begin{bmatrix} \hat{\alpha}_1 \\ \hat{\alpha}_2 \\ \hat{\alpha}_3 \\ \vdots \\ \hat{\alpha}_p \end{bmatrix} = \begin{bmatrix} r_n(1) \\ r_n(2) \\ r_n(3) \\ \vdots \\ r_n(p) \end{bmatrix} \quad (62)$$

Özilişki değerlerinden oluşan denklem-62'deki pxp boyutundaki matrisin tüm diyagonal elemanları simetrik ve eşit olduğundan bu Toeplitz matrisidir. Dolayısıyla Levinson-Durbin yöntemi kullanılarak, katsayılar kolaylıkla elde edilebilir.

2.2.1.4.6. İstatistiksel Öznitelikler

Daha önce bölüm 2.2.1.4.1.'de Kullanılan öznitelik çıkarma yöntemlerinde de anlatıldığı üzere, bir nefes döngüsünden elde edilen öznitelik matrisinin satır sayısı bir

nefes döngüsünden bölünerek elde edilen çerçeve sayısına, sütun sayısı ise hesaplanan öznitelik adedine bağlıdır. Nefes döngülerinin uzunlukları değişkenlik gösterdiğinden hesaplanan çerçeve sayıları değişmekte, dolayısıyla da öznitelik matrisinin satır sayısı da değişmektedir. Fakat sınıflandırma aşamasında öznitelik matrislerinin kullanılabilmesi için boyutlarının eşit olması gerekir. Bunu sağlamak amacıyla, bu tez çalışmasında öznitelik matrisine ait her sütunun ayrı ayrı istatistiksel parametrelerinin hesaplanarak, tek satır uzunluğunda bir öznitelik vektörü elde edilmesi yaklaşımı önerilmiştir. Minimum değer, maksimum değer, aritmetik ortalama, standart sapma, varyans, çarpıklık, basıklık ve ortanca değerden oluşan sekiz farklı istatistiksel parametre kullanılmıştır.

İstatistiksel parametreler öznitelik matrisinin her bir sütunu için ayrı ayrı elde edilir. Sütun içindeki en küçük değer minimum değer olarak, en büyük değer ise maksimum değer olarak belirlenir.

Ortalama daha değer denklem-17'de, standart sapma ve varyans terimleri ise denklem-18'de açıklanmıştır. Çarpıklık, serideki örneklerin nasıl dağılık olduğunu ve simetrik olarak ne derece uzakta olduklarını gösteren bir parametredir. Denklem-63'deki gibi hesaplanır.

$$S = \frac{1}{N} \sum_{i=1}^N \left[\frac{x_i - \bar{x}}{\sigma} \right]^3 \quad (63)$$

Basıklık örnek dağılımın tepe noktasını veya düzlüğünü gösterir; diğer bir deyişle, serinin yüksekliğinin normal serinin yüksekliğinden ne kadar uzakta olduğunu gösterir ve denklem-65'deki gibi hesaplanır.

$$K = \frac{1}{N} \sum_{i=1}^N \left[\frac{x_i - \bar{x}}{\sigma} \right]^4 \quad (64)$$

Ortanca değer (medyan), veri değerlerini küçükten büyüğe doğru sıralandıktan sonra, ortadaki sayı bu dizinin ortanca değeridir. Veri sayısı çift ise ortadaki iki değer aritmetik ortalaması ortanca değeri verir.

2.2.1.4.7. Temel Bileşen Analizi

TBA, bir veri kümesindeki bilgi değişimini mümkün olduğunca koruyarak o veri kümesi boyutlarının daha küçük boyutlara indirgenmesini sağlayan bir dönüşüm tekniğidir [80]. Bu dönüşümün başarılı olabilmesi için verilerin en fazla değiştiği yönün bulunması gerekir. TBA uygulaması sonucunda ilk değişkenlerin temel bileşenleri elde edilmiş olur. Birbirlerine dik olarak elde edilen temel bileşenler daha sonra varyans değerlerine göre büyükten küçüğe doğru sıralanır. Eğitim kümesi veri matrisini X olarak tanımlar ve her biri N uzunlukta olan gözlem vektörlerinden de M adet bulunduğunu varsayarsak eğitim kümesi matrisi denklem-65'deki gibi gösterilir;

$$X = [x^1 | x^2 | \dots | x^M]_{(NxM)} = \begin{bmatrix} x_1^1 & x_1^2 & \dots & x_1^M \\ x_2^1 & x_2^2 & \dots & x_2^M \\ \vdots & \vdots & \ddots & \vdots \\ x_N^1 & x_N^2 & \dots & x_N^M \end{bmatrix} \quad (65)$$

Veri kümesine TBA uygulayabilmek için öncelikle veri kümesinin ortalaması (m) denklem-66 ile hesaplanır.

$$m = \frac{1}{M} \sum_{i=1}^M x^i = \begin{bmatrix} m_1 \\ m_2 \\ \vdots \\ m_N \end{bmatrix} \quad (66)$$

Sonraki adım, X veri kümesi ile ortalama değeri arasındaki fark kümesini denklem-67'deki gibi hesaplamaktır.

$$x^{-i} = x^i - m \quad (67)$$

Böylece değişken değerleri merkezleştirilmiş (sıfır ortalamalı) olur. Sıfır ortalamalı gözlem matrisi ise denklem-68'deki gibi ifade edilir.

$$\tilde{X} = [\tilde{x}^1 | \tilde{x}^2 | \dots | \tilde{x}^M]_{(NxM)} = \begin{bmatrix} x_1^1 - m_1 & x_1^2 - m_1 & \dots & x_1^M - m_1 \\ x_2^1 - m_2 & x_2^2 - m_2 & \dots & x_2^M - m_2 \\ \vdots & \vdots & \ddots & \vdots \\ x_N^1 - m_N & x_N^2 - m_N & \dots & x_N^M - m_N \end{bmatrix} \quad (68)$$

Denklem-68'de elde edilen matrizen faydalanarak kovaryans matrisi hesaplanır;

$$C = \tilde{X}\tilde{X}^T = \begin{bmatrix} (x_1^1 - m_1)^2 & (x_1^2 - m_1)(x_2^1 - m_2) & \dots & x_1^{M1} - m_1 \\ (x_2^1 - m_2)(x_1^2 - m_1) & (x_2^2 - m_2)^2 & \dots & x_2^M - m_2 \\ \vdots & \vdots & \ddots & \vdots \\ (x_N^1 - m_N)(x_1^M - m_1) & (x_N^2 - m_N)(x_2^M - m_2) & \dots & (x_N^M - m_N)^2 \end{bmatrix} \quad (69)$$

Özdeğer ve özvektörleri hesaplamak için C kovaryans matrisi, λ bir skaler ve v bir vektör olmak üzere denklem-70'den faydalanılır.

$$Cv = \lambda v \quad (70)$$

W izdüşüm matrisi, büyükten küçüğe doğru sıralanan özdeğerlere karşılık gelen özvektörlerden seçilen p adedi ile denklem-71'deki gibi elde edilir.

$$W = [w_1 \ w_2 \ \dots \ w_p] \quad (71)$$

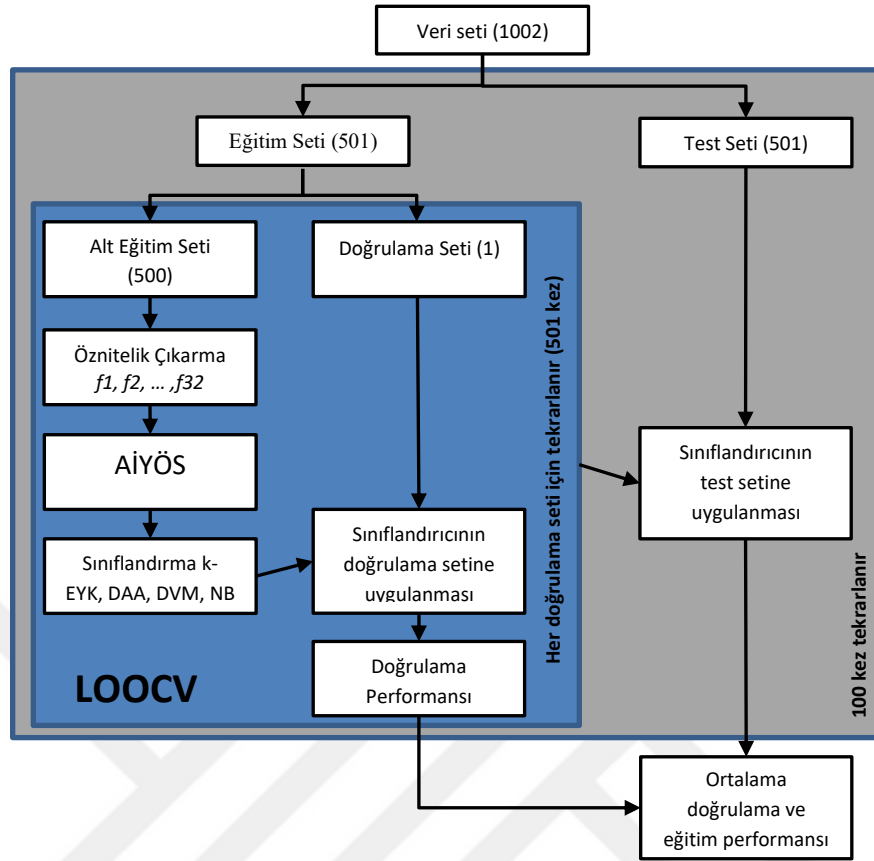
Veri örneklerinin öznitelikleri de özvektörlerin belirlediği uzay üzerine izdüşüm alınarak denklem-72'de verildiği gibi hesaplanır.

$$y^i = W^T x^i, \quad i = 1, 2, \dots, M \quad (72)$$

Daha düşük boyutlu öznitelikler belirlenerek eğitim aşaması tamamlanmış olur.

2.2.1.5. Sınıflandırma

Toplam 1002 adet etiketlenmiş solunum döngüsü, rasgele olarak yarısı eğitim, kalan yarısı test kümesi olmak üzere iki eşit parçaya ayrılmıştır. Eğitim setine birini dışarıda bırak çapraz doğrulama yöntemi ile tüm sınıflandırıcı parametreleri belirlendikten sonra eğitilmiş sınıflandırıcı test veri setine uygulanmıştır. Böylece, test veri doğruluğu elde edilmiştir. Bu prosedür Şekil-16'da gösterilmektedir. Önerilen yöntemin kararlılığını test etmek için yukarıda açıklanan döngü, eğitim ve test kümelerinin rasgele ayrılmasından başlayarak 100 kez koşulmuş ve ortalama test doğruluğu ile bunlara ait standart sapma sonucu elde edilmiştir.



Şekil 16. Sınıflandırma sürecinin akış şeması

Sınıflandırma performansını elde etmek için, iyi bilinen ve yaygın olarak kullanılan DVM, k-EYK, DAA ve NB algoritmaları kullanılmıştır. Sonuçlar üzerinden sınıflandırmanın performansını artırabilmek için ayrıca AİYÖS metodu kullanılmıştır. Bu metod sınıflandırma algoritmalarını müteakiben bir sonraki bölümde açıklanmaktadır.

2.2.1.5.1. Doğrusal Ayırma Ayırıcı

Doğrusal ayırma ayırıcı (linear discriminant analysis), yaygın olarak kullanılan istatistiksel sınıflandırma yöntemlerinden biridir. DAA yöntemi, özniteliklerden oluşan örnek uzayında sınıfları en iyi şekilde ayıracak vektörleri bulur. Başka bir deyişle amaç, farklı sınıf verilerine ait izdüşümleri ayıracak bir doğru bulmaktır. Bunu sağlamak için ortalama değerleri farklı olan sınıfların sınıflar arası dağılımını artırmaya, sınıf içi dağılımını ise azaltmaya çalışılır.

DAA yaklaşımında, sınıflara ait öznitelikleri birbirinden en iyi biçimde ayıracak bir düzleme iz düşürmeye çalışılır. V izdüşüm matrisini, V^T ise izdüşüm matrisinin

transpozunu temsil etmek üzere her x noktası $y_i = V^T x$ sağlayacak şekilde değiştirilmiştir. Veri grubundaki i . sınıfa ait özniteliklerin sayısı n_i olmak üzere, i . sınıfa (c_i) ait özniteliklerin ortalaması olan μ_i aşağıdaki gibi hesaplanır.

$$\mu_i = \frac{1}{n_i} \sum_{x \in c_i} x \quad (73)$$

Tüm sınıflara ait özniteliklerin ortalaması ise μ ile ifade edilirse, T_r eğitim kümesini göstermek üzere denklem-74'deki gibi hesaplanır.

$$\mu = \frac{1}{n} \sum_{x \in T_r} x_i \quad (74)$$

Bu tanımlara bağlı olarak ve g sınıf parametresini göstermek üzere sınıf içi dağılım (kovaryans) matrisi S_W , denklem-75'deki gibi ifade edilir.

$$S_W = \sum_{i=1}^g \sum_{x \in c_i} (x_k - \mu_i)(x_k - \mu_i)^T \quad (75)$$

Daha önce de belirtildiği gibi i . sınıfa ait özniteliklerin sayısı n_i olmak üzere, sınıflar arası dağılım (kovaryans) matrisi S_B denklem-76'deki gibi ifade edilir.

$$S_B = \sum_{i=1}^g (\mu_i - \mu)(\mu_i - \mu)^T \quad (76)$$

Ayrırma kriterini sağlayacak değerlerden oluşan V matrisi (projeksiyon matrisi) denklem-77'den hesaplanır.

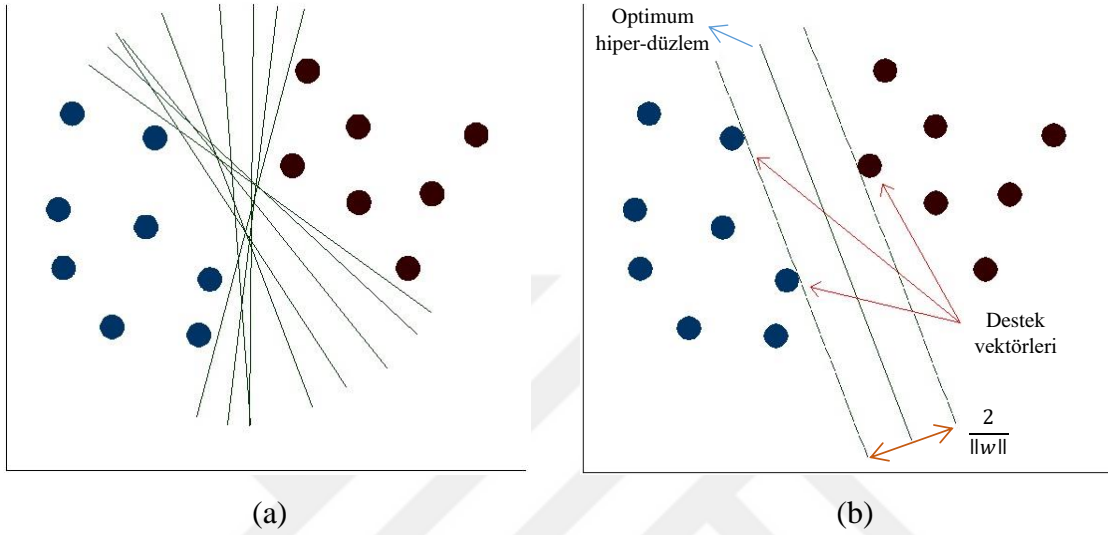
$$S_B V = \lambda S_W V \rightarrow (S_W^{-1} S_B - \lambda I) V = 0 \quad (77)$$

Burada genel bir özdeğer özvektör bulma problemi görülmektedir. Dolayısıyla $S_W^{-1} S_B$ 'nin öz vektörleri hesaplanıp V elde edilir. Daha sonra sınıflandırma işlemi doğrudan uzaklık hesaplanarak bulunabilir. Bu aşamada denklem-78'de gösterilen Öklid uzaklık bağıntısı kullanılmıştır. Öklid uzaklığı i ve j noktaları için aşağıdaki gibi elde edilir.

$$d_W = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \quad (78)$$

Daha sonra test verisini uygun gruba sınıflandırmak için bu uzaklıktan faydalanılır.

2.2.1.5.2. Destek Vektör Makineleri



Şekil 17. (a) İki sınıflı bir problem için hiper-düzlemler, (b) Optimum hiper-düzlem ve destek vektörleri.

Regresyon ve sınıflandırma problemlerine çözüm olarak için Vapnik [81] tarafından geliştirilen Destek Vektör Makineleri (DVM), istatistiksel öğrenme teorisine dayanan denetimli bir sınıflandırma tekniğidir. Eğitim kümesi ile bir model oluşturup, test örneklerinin hangi sınıfta olacağını belirlemeye çalışır. Bunun için, sınıfları birbirinden ayıracak en uygun karar sınırını arar.

Bu tez çalışmasında kullanılan veri seti-2 gibi iki gruplu (sağlıklı/patolojik) sınıflandırma probleminde DVM, aynı düzlemde bulunan iki sınıfı ayırmak için optimal bir sınır çizer. Şekil-17 (a)'dan de görülebileceği gibi iki grup arasında sonsuz sayıda doğru çizilebilir. Ancak, çizilecek sınırın iki grubun özneliklerine de olabilecek en uzak mesafede (marjinde) olması gerekmektedir. Bu sayede şekil-17 (b)'de görüldüğü gibi optimum hiper-düzlem belirlenmiş olur. DVM'nin parametreleri öznelik vektörlerinin doğrusal olarak ayrılabilir veya ayrılamaz yapıda olmasına göre değerlendirilir.

DVM'de iki sınıflı etiketler genellikle $\{-1,+1\}$ olarak gösterilir. Eğitim verisinden elde edilen karar fonksiyonu yardımıyla sınıflar birbirinden ayrıştırılmaya çalışılır. Doğrusal ayrılabilen veriler için DVM ile çözülecek iki sınıflı bir problemde ikinci

dereceden denklem çözümü gerekir. Eğitim verisinin k adet örnekten oluştuğunu ($i = 1, 2, \dots, k$) varsayalım. DVM'nin eğitimi için optimum hiper-düzlem eşitsizlikleri aşağıdaki gibi olur:

$$wx_i + b \geq 1 \quad y_i = +1 \quad (79)$$

$$wx_i + b \leq -1 \quad y_i = -1 \quad (80)$$

Burada $x_i \in R^N$ (N-boyutlu bir uzayda) destek vektörlerini, $y_i \in \{-1, +1\}$ sınıf etiketlerini, w ağırlık vektörünü, b ise eğilim değerini göstermektedir [82]. İki sınıfı birbirinden optimum şekilde ayıracak hiper-düzlemin sınırlarının belirlenmesi için öncelikle paralel olarak belirlenecek iki hiper-düzlemin denklemi aşağıdaki gibi ifade edilir;

$$wx_i + b = \pm 1 \quad (81)$$

Bu durumda, $\|w\|$ değeri minimum olduğunda optimum hiper-düzlem sınırı maksimum olabilecektir. Öyleyse en iyi hiper-düzlem;

$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (82)$$

ile oluşturulabilir. Eşitlikler birleştirilirse $\forall i$ için;

$$y_i(wx_i + b) \geq 1 \quad (83)$$


elde edilir. Yukarıdaki denklem-83, Lagrange denkleminden faydalanılarak çözülebilir.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha_i y_i (wx_i + b) + \sum_{i=1}^k \alpha_i \quad (84)$$

Burada α_i , Lagrange çarpanlarını ifade etmektedir. En iyi hiper-düzleminin bulunacağı karar fonksiyonu ise denklem-85'deki gibi ifade edilir.

$$f(x_i) = \text{sign}(wx_i + b) = \begin{cases} 1, & y_i = 1 \\ -1, & y_i = -1 \end{cases} \quad (85)$$

Örnek olarak şekil-18'de de gösterildiği gibi, benzer birçok problemde verilerin doğrusal olarak ayrılması mümkün değildir. Bu durumda doğrusal olmayan bir hiper-düzlem elde edilmeye çalışılır. Bunun için doğrusal olmayan çekirdek fonksiyonları kullanılarak daha yüksek boyutlu bir uzayda çalışılır. Böylece doğrusal olmayan dönüşümler yapılmış olur [83].



Şekil 18. Doğrusal olarak ayrılamayan iki sınıflı problem örneği

Optimum hiper-düzlem belirlenmiş olsa da, eğitim verilerinin bir kısmı hiper düzlemin istenmeyen tarafında (diğer tarafta) kalabilir. Bu problemi çözmek için pozitif bir yapay değişken (ξ) tanımlanır. Bu tanımlamaya göre optimizasyon problemi;

$$\min \left[\frac{1}{2} \|w\|^2 \right] + C \sum_{i=1}^r \xi_i \quad (86)$$

olarak ifade edilir. Buna bağlı olarak $\forall i$ için sınırlamalar $\xi \geq 0$ ve $i = 1, 2, \dots, N$ olmak üzere aşağıdaki gibi ifade edilir.

$$y_i(wy_i + b) \geq 1 - \xi_i \quad (87)$$

Doğrusal olarak ayrılamayan sınıflandırma problemleri için DVM, denklem-88'de ifade edilen bir Kernel fonksiyonu yardımıyla çok boyutlu uzayda doğrusal ayırım yapılabilmektedir.

$$\varphi(x_i)\varphi(x_j) = K(x_i, x_j) \quad (88)$$

Buradaki K , çekirdek fonksiyonudur. En çok kullanılan Kernel fonksiyonları şunlardır;

$$K_{(RBF)} = e^{-\left(\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)} \quad (89)$$

$$K_{(linear)}(x_i, x_j) = x_i^T x_j + C \quad (90)$$

$$K_{(polinomal)} = (\gamma x_i^T x_j + C)^d \quad (91)$$

$$K_{(sigmoid)} = \tanh(\gamma x_i^T x_j + C) \quad (92)$$

RBF (Radyal Bazlı Fonksiyon) çoğu çalışmada iyi sonuçlar verdiği için tercih edilen bir Kernel çekirdek fonksiyonudur [84]. Bu tez çalışmasında da DVM'ye ait sonuçlar RBF Kernel fonksiyonu kullanılarak elde edilmiştir.

K Kernel çekirdek fonksiyonu ve $z = \varphi(x)$ dönüşüm parametresi olarak alınırsa, doğrusal ayırım yapabilen (çok boyutlu uzayda) karar fonksiyonu aşağıdaki gibi ifade edilir.

$$f(x_i) = \text{sign}(wz + b) = \text{sign}\left[\frac{1}{2}\sum_{i=1}^{N_s} y_i \alpha_i K(x_i, x) + b\right] \quad (93)$$

2.2.1.5.3. Naive Bayes

Naive Bayes sınıflandırıcısı, basit varsayımlar üzerine kurulmuş, kolaylıkla uygulanabilen etkili bir olasılık tabanlı yöntemdir. Naive Bayes, belirli bir sınıfa bir öznelik değerinin diğer öznelik değerlerinden bağımsız olduğunu varsayar [85]. Bu varsayım, hesaplamayı kolaylaştırmak için yapılır ve bu anlamda "Naive" (saf) olarak kabul edilir.

Veri setinde bulunan m adet sınıfı C_1, C_2, \dots, C_m ile temsil edelim. Hangi sınıfa ait olduğu bilinmeyen X 'in sınıfını Naive Bayes sınıflandırıcısı ile belirlediğimizi varsayalım.

Naive Bayes sınıflandırıcıda amaç, X 'in bilinen sınıflara ait olma olasılığını hesaplayarak, X 'i en yüksek değere sahip C_i sınıfına atamaktır. X , n boyutlu öznitelik vektörleri ile $X = (X_1, X_2, \dots, X_n)$ olarak gösterilmiş olsun. Bu durumda X 'in C_i sınıfına ait olma olasılığı Bayes Teoremine göre denklem-95'deki gibi elde edilir.

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)} \quad (94)$$

Burada, $P(C_i|X)$ 'i maksimize eden sınıf araştırılır. $P(X)$ tüm sınıflar için aynı olduğundan yalnızca payın değer artışı ile ilgilenilir. Birçok özniteliğe sahip veri kümeleri göz önüne alındığında, $P(C_i|X)$ hesaplamak zaman alıcı ve yorucu olurdu. $P(X|C_i)P(C_i)$ değerinin hesaplanmasındaki zorluğu azaltmak için sınıf koşullu bağımsızlık varsayımı yapılır. Yani, örneklerin sınıf etiketiyle birlikte, öznitelik değerlerinin koşullu olarak birbirinden bağımsız olduğunu varsayılır. Bu durum, denklem-95'deki gibi ifade edilir;

$$P(X|C_i) = \prod_{k=1}^n P(x_k|C_i) \quad (95)$$

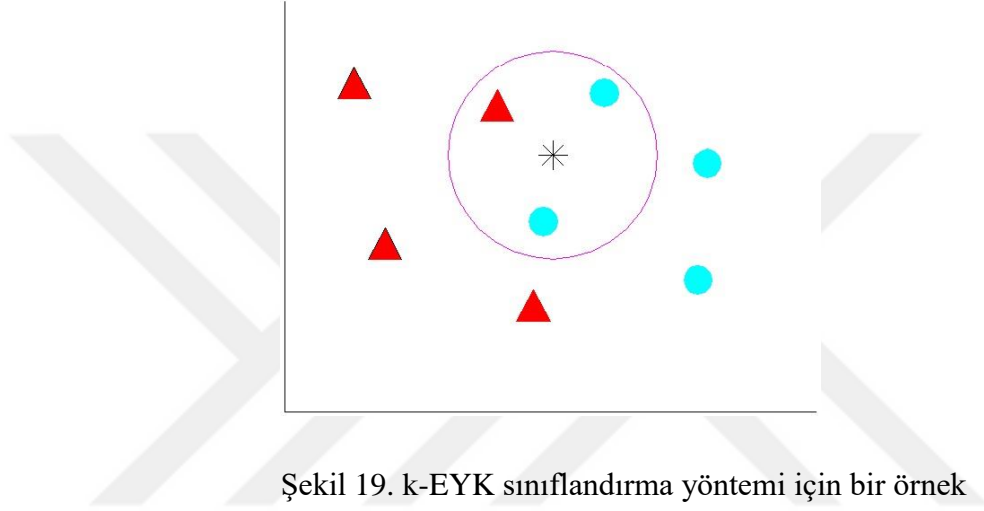
$P(x_1|C_i), P(x_2|C_i), \dots, P(x_n|C_i)$ olasılıkları, eğitim setinden kolayca elde edilebilir. Burada $P(X|C_i)$ 'nin hesaplaması niteliğin kategorik ya da nümerik olma durumuna göre değişmektedir. Ancak, Bu çalışmadaki öznitelikler nümerik sayılardan oluştuğu için (normal dağılım varsayımı ile) niteliğin Gauss gösterdiği varsayılır. Buna göre μ ortalama ve σ standart sapma olarak ifade edildiğinde;

$$P(x_k|C_i) = g(x_k, \mu_{C_i}, \sigma_{C_i}) = \frac{1}{\sigma_{C_i}\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_k - \mu_{C_i}}{\sigma_{C_i}}\right)^2} \quad (96)$$

olarak elde edilir. X 'in sınıf etiketini tahmin etmek için $P(X|C_i)P(C_i)$ değeri, her sınıf C_i için değerlendirilir. Sınıflandırıcı, X 'in sınıf etiketinin, yalnızca ve $P(X|C_i)P(C_i)$ 'yi maksimize eden sınıf olması durumunda, C_i olduğu öngörüsünde bulunur.

2.2.1.5.4. k-En Yakın Komşuluk Yöntemi

Klasik örüntü tanıma metotlarından biri olan k-EYK, sınıfların olasılık dağılımına gerek duymayan denetlemeli bir öğrenme algoritmasıdır. Bir test verisinin sınıfını belirlemek için, test verisinin, mevcut öğrenme verisinin üzerindeki en yakın k-adet komşusu bulunur. Bu komşuların en fazla yoğunlaştığı sınıf, tanıma sonucu olarak test verisine atanır [86]. Şekil-19'da k-EYK'nın nasıl çalıştığını anlatan basit bir örnek verilmiştir.



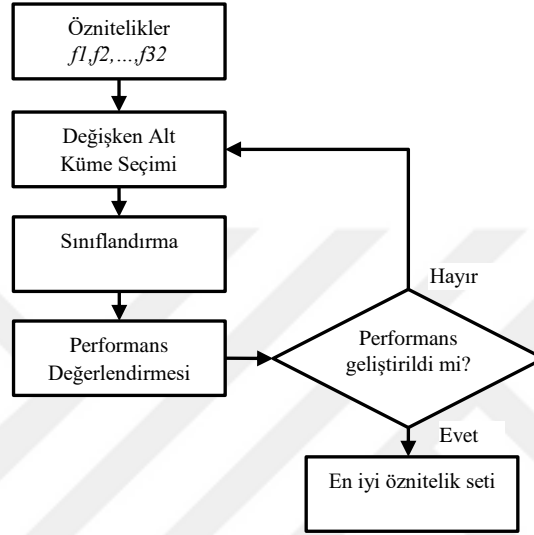
Şekil 19. k-EYK sınıflandırma yöntemi için bir örnek

Kırmızı ve mavi olmak üzere iki sınıflı verilerden oluşan eğitim sınıfı için yıldız şeklinde sınıfı belli olmayan bir test verisinin sınıfı araştırılmaktadır. Eğitim verisinden, test edilen veriye en yakın üç ($k = 3$ seçilmiştir) adet verinin uzaklığı hesaplanır. Şekilde test verisine en yakın eğitim verileri daire içinde gösterilmiştir. İki veri mavi, bir veri ise kırmızı sınıfı işaret etmektedir. Ancak test verisi, çoğunluğun verisi olan mavi sınıf ile etiketlenir. Bu çalışmada en yakın komşuları bulmak amacıyla Öklid uzaklığı kullanılmıştır. Örnekten de anlaşılacağı üzere, k parametresinin değeri k-EYK'nın başarısını önemli ölçüde etkilemektedir. Bu nedenle bu tez çalışmasında kullanılan veri setlerinden oluşturulan eğitim kümeleri için k -katsayıları geniş bir aralıkta hesaplanarak uygun k değerleri belirlenmiştir.

2.2.1.6. Ardışıl İleri Yönlü Öznitelik Seçme yöntemi

Ardışıl ileri yönlü öznitelik seçme (AİYÖS) işlemi için basit ancak etkili bir metottur. Bu metotta, belirli bir öznitelik kümesi oluşturulur ve her bir adımda seçilen

yönteme göre öznelik alt kümesinden bir öznelik ekleme işlemini gerçekleştirilir. Burada seçim ölçütü ise sınıflandırıcı algoritmasının başarı oranıdır. Belirlenen sınıflandırıcı algoritmasının başarı durumuna göre her bir adımda ayırım gücü yüksek olan öznelikler tespit edilir. Şekil-20, AIYÖS yönteminin akış diyagramını göstermektedir.



Şekil 20. Ardışıl ileri yönlü öznelik seçme (AIYÖS) yönteminin akış şeması


3. BULGULAR

3.1. Akciğer Seslerinden Solunum Döngülerinin Ayrıştırılması Bulguları

Bu tez kapsamında tek kanallı akciğer seslerinden solunum döngülerinin sınırlarını belirlemek için geliştirilen yöntemin değerlendirilmesi için veri set-1 kullanılmıştır. Yedi farklı akciğer sesinin birer örneğini içeren veri set-1 için elde edilen sonuçlar Şekil-21’de verilmiştir.

Şekil-21’deki kırmızı noktalar, önerilen yöntemle elde edilen solunum döngülerinin alt ve üst sınır noktalarını temsil etmektedir. Magenta dikey çizgiler, hekimler tarafından seslerin dinlenerek belirlenen solunum döngülerinin sınırlarını temsil eder. Sonuçlar irdelendiğinde, önerilen yöntem ile belirlenen sınırların hekimler tarafından belirlenen sınırlara çok yakın olduğu, neredeyse örtüştüğü görülmektedir. Ayrıca bu sonuçlara ek olarak hekimler, yöntemimizle otomatik olarak belirlenen sınır noktalarının uygunluğunu belirlenen solunum döngülerini tekrar dinleyerek onaylamışlardır. Başka bir bakış açısı için önerilen yöntemin ve hekimlerin belirlediği sınırların sonuçları Tablo-7’de de istatistiksel olarak karşılaştırılmıştır.

Şekil-21 ayrıca, önışleme sonucunda ortaya çıkan tekrarlayan paternlerin genlik farklılıklarını da ortaya koymaktadır. Örneğin, akciğer sesi kaydedilen bireylerin genellikle güçlü-güçsüz ya da güçsüz-güçlü nefes alış verişleri, paternler arası genlik farklılıklarına neden olmaktadır. Bahsedilen genlik farklılıklarının azaltılması ve paternlerin benzerliğinin daha net karşılaştırılabilmesi amacıyla, paternlerin genlikleri normalize edilmiş ve bu normalize genliklerden eşit sayıda numune alınarak Dinamik Zaman Bükme (DZB) algoritmasında karşılaştırılmıştır. Uygun bir örnek, Şekil-21’deki ronküsün altıncı solunum paterninde görülmektedir. Diğer solunum döngülerine ait patern genliklerinden farklı olarak altıncı paternde çift maksimum pik noktası bulunmaktadır. Fakat buna rağmen geliştirilen yöntem sınır noktalarını başarıyla belirlemiştir. Ayrıca, yöntemimiz tarafından belirlenen solunum sıklığının hekimler tarafından kabul edilmesi, önerilen yöntemin başarısını destekleyen diğer bir faktördür.



Şekil 21. Yedi farklı akciğer ses örneğinden otomatik olarak algılanan solunum döngüleri

Geliştirilen yöntemin istatistiksel sonuçları Tablo-7'de verilmiştir ve yöntemin başarısını başka bir perspektiften değerlendirmek için önemlidir. Tabloyu oluşturmak için gerçek sınır değerlerinin doktorların belirlediği noktalar olduğu kabul edilmiştir.

Tablo 7. Otomatik solunum döngüsü belirleme algoritmasının istatistiksel sonuçları

Akciğer Ses Türü	Solunum döngü sürelerinin ortalamaları (ms)	Solunum döngü sürelerinin standart sapmaları (ms)	Mutlak hata ortalamaları (ms)	Mutlak hata standart sapmaları (ms)
Frotman	2355.79	100.14	105.06	55.43
İnce Ral	2738.73	75.85	88.32	65.70
Kaba Ral	2245.58	184.39	125.43	62.06
Ronküs	3437.23	304.32	130.86	81.20
Tubersufl	2033.97	143.11	72.43	25.22
Wheeze	3510.82	289.96	180.60	58.39
Normal	2419.90	358.76	128.29	47.54
Ortalama:	2677.43	208.08	118.71	56.51

Bir solunum döngüsünün süresi bireyin hastalığının türüne de bağlıdır. Dolayısıyla bu durum, solunum döngülerinin ortalama süresine yansır. Örneğin wheeze, ciğerlerdeki küçük hava yollarının daralmasının neden olduğu kısıtlı hava hareketinin bir sonucu olarak akciğerlerde ortaya çıkan bir sestir. Dolayısıyla havanın akciğerlere dolması veya boşalması biraz daha uzun sürer. Bu nedenle, wheeze sesine ait solunum döngülerinin ortalaması 3510.82ms ile diğerlerinden yüksektir. Tubersufl sesi, akciğerlerdeki sıvı birikimi nedeniyle duyulan sestir. Biriken sıvı nedeniyle solunum kalitesi düştükçe hasta daha sık nefes almak zorundadır. Bundan dolayı, frotman solunum sesi 2033.97ms ile ortalama solunum döngü sürelerinin en kısa süresine sahiptir.

Tüm sonuçların ortalamalarını incelediğimizde, solunum döngülerinin ortalama süresinin 2677.43ms, sürelerin mutlak hata ortalamalarının ise yaklaşık 120ms olduğu görülmektedir. Bu iki değer karşılaştırıldığında, sürelerin mutlak hata ortalamaları solunum döngülerinin ortalama süresinin yaklaşık %4.4'ü olarak ortaya çıkmaktadır. Geliştirilen yöntemimizin başarısını ölçmede bu değer çok önemli bir faktördür, çünkü veri kaybı tüm solunum döngüsü ile karşılaştırıldığında oldukça düşüktür. Buna ek olarak, ortalama mutlak hata oranları %3.2 ile %5.6 arasında değişmektedir. Düşük değerlerdeki ortalama mutlak hata sürelerinin elde edilmiş olması, önerilen yöntemin başarısını gösteren diğer bir faktördür. Doktorlar tarafından manuel solunum döngüsü sınırının belirlenmesinde

oluşabilecek ölçüm hataları da dikkate alındığında, bu hata oranlarının otomatik solunum döngüsü algılama uygulamaları için kabul edilebilir sınırlar dahilinde olduğunu söylemek mümkündür.

Mutlak hata oranlarının standart sapması, ortalama değerler için beklenenden daha yüksek görünebilir. Bununla birlikte, standart sapmaların beklenenden daha yüksek olacağı anlaşılabilir bir durumdur. Çünkü yöntemimizin sonuçları hekimler tarafından belirlenen sınırlara göre değerlendirilmiştir. Bireylere göre solunum döngüleri arasındaki bekleme süresi değişkendir. Diğerlerine göre daha uzun bekleme süreleri üzerinden doktorların manuel belirlediği sınır noktalarındaki küçük kaymaların, standart sapmada bir artış ile sonuçlandığı değerlendirilmektedir.

3.2. Öznitelik Parametreleri

Detayları daha önce “Kullanılan öznitelik çıkarma yöntemleri” başlığı altında verilmiş olan öznitelik çıkarma yöntemlerinden elde edilen parametrelerin kısa adları ve açıklamaları tablo-8’de verilmiştir. Bulgular kısmındaki gösterimlerde kolaylık sağlaması amacıyla bundan sonra bu kısa adlandırmalar kullanılacaktır.

Tablo 8. Türetilen öznitelikler ve kısa adları

	Zaman Bölgesinden Türetilen Öznitelikler	Frekans Bölgesinden Türetilen Öznitelikler	MFKK’dan Türetilen Öznitelikler	DÖK’ten Türetilen Öznitelikler
Minimum Değer	$f1$	$f9$	$f17$	$f25$
Maksimum Değer	$f2$	$f10$	$f18$	$f26$
Aritmetik Ortalama	$f3$	$f11$	$f19$	$f27$
Standart Sapma	$f4$	$f12$	$f20$	$f28$
Varyans	$f5$	$f13$	$f21$	$f29$
Çarpıklık	$f6$	$f14$	$f22$	$f30$
Basıklık	$f7$	$f15$	$f23$	$f31$
Ortanca Değer	$f8$	$f16$	$f24$	$f32$

3.3. Tam Solunum Döngüsü Seslerinin Sağlıklı/Patolojik Akciğer Sesleri İçin Sınıflandırma Bulguları

Tam solunum döngülerinden eğitim kümeleri için elde edilen sağlıklı/patolojik akciğer ses sınıflandırma sonuçlarının ortalamaları Tablo-9'da gösterilmektedir. TBA uygulanmadan önceki ilk sınıflandırma sonuçları değerlendirildiğinde f19 özniteliğinin 95,85 ortalama ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre F19 sabit tutularak 2.adımda diğer öznitelikler ile f19'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarısı araştırılmıştır. Bu kombinasyonlar elde edilen başarıya düşene kadar veya özniteliklerin tamamı kullanılına kadar devam eder. Tam solunum sesleri için f19+f20+f32 öznitelik kombinasyonunun %97,34 ile en iyi ortalama sonuca ulaştığı görülür. Bir sonraki adımda ise başarıya düşmüş ve AİYÖS yöntemine göre sınıflandırma süreci tamamlanmıştır. TBA uygulandığında ise en iyi kombinasyon %95,60 ile f19+f3 özniteliklerinden oluşmuştur. Bu iki sonuç değerlendirildiğinde en iyi başarıya, TBA uygulanmadığı durumda f19+f20+f32 öznitelik kombinasyonunun %97,34 ortalama değeri ile elde edilmiştir.

Tablo 9. Tam solunum döngülerinden elde edilen sağlıklı/patolojik akciğer ses sınıflandırma bulguları (%)

	AİYÖS Yöntemi Sonuçları				TBA+ AİYÖS Yöntemi Sonuçları		
	1.Adım	2.Adım	3.Adım	4.Adım	1.Adım	2.Adım	3.Adım
f1	86,50 DAA	96,36 k-EYK k=1	93,77 k-EYK k=1	94,14 k-EYK k=1	87,50 k-EYK k=5	92,30 k-EYK k=1	93,60 k-EYK k=1
f2	82,22 k-EYK k=5	90,64 k-EYK k=5	91,53 k-EYK k=5	91,16 k-EYK k=5	85,20 DAA	93,60 k-EYK k=7	93,30 k-EYK k=3
f3	88,44 DVM	94,30 k-EYK k=1	95,14 k-EYK k=1	95,17 k-EYK k=1	92,90 k-EYK k=5	95,60 k-EYK k=1	<i>f3 sabit</i>
f4	79,86 k-EYK k=5	93,32 k-EYK k=1	94,57 k-EYK k=1	94,62 k-EYK k=1	84,50 k-EYK k=5	94,90 k-EYK k=7	94,30 k-EYK k=3
f5	79,36 k-EYK k=5	89,23 DAA	91,03 DAA	90,81 DAA	81,80 k-EYK k=5	93,60 k-EYK k=9	81,10 k-EYK k=11
f6	82,08 k-EYK k=5	91,25 k-EYK k=1	92,18 k-EYK k=1	92,37 k-EYK k=1	84,80 k-EYK k=7	92,90 k-EYK k=3	92,30 k-EYK k=1
f7	82,16 DAA	89,58 DAA	90,74 DAA	90,95 DAA	83,50 k-EYK k=7	92,90 k-EYK k=3	91,90 k-EYK k=3
f8	86,91 DAA	93,03 k-EYK k=1	94,14 k-EYK k=1	93,96 k-EYK k=1	89,60 k-EYK k=9	95,30 k-EYK k=3	94,60 k-EYK k=1
f9	82,32 DVM	95,72 k-EYK k=1	94,84 k-EYK k=1	94,32 k-EYK k=1	84,50 k-EYK k=9	91,60 k-EYK k=1	92,90 k-EYK k=1
f10	80,04 k-EYK k=5	95,80 k-EYK k=1	96,68 k-EYK k=1	96,90 k-EYK k=1	85,20 DVM	92,60 k-EYK k=5	93,60 k-EYK k=3
f11	87,19 k-EYK k=5	95,85 k-EYK k=1	97,12 k-EYK k=1	97,00 k-EYK k=1	90,60 k-EYK k=7	94,60 k-EYK k=1	93,90 k-EYK k=1
f12	87,67 k-EYK k=5	95,93 k-EYK k=1	96,81 k-EYK k=1	96,58 k-EYK k=1	89,60 k-EYK k=11	93,60 k-EYK k=5	94,60 k-EYK k=5
f13	86,53 DVM	95,98 k-EYK k=1	96,82 k-EYK k=1	97,09 k-EYK k=1	88,90 DVM	93,30 k-EYK k=5	95,30 k-EYK k=1
f14	75,97 k-EYK k=5	91,04 k-EYK k=5	92,26 DAA	91,96 DAA	77,80 k-EYK k=7	93,60 k-EYK k=5	93,90 k-EYK k=5
f15	72,49 k-EYK k=5	89,42 DAA	90,98 DAA	91,05 DAA	75,80 k-EYK k=15	94,30 k-EYK k=5	95,10 k-EYK k=3
f16	85,84 k-EYK k=5	95,29 k-EYK k=3	96,87 k-EYK k=1	96,81 k-EYK k=1	84,80 k-EYK k=7	92,30 k-EYK k=5	93,60 k-EYK k=3

Tablo 9. (Devamı) Tam solunum döngülerinden elde edilen sağlıklı/patolojik akciğer ses sınıflandırma bulguları (%)

	AİYÖS Yöntemi Sonuçları				TBA+ AİYÖS Yöntemi Sonuçları		
	1.Adım	2.Adım	3.Adım	4.Adım	1.Adım	2.Adım	3.Adım 3
f17	90,29 k-EYK k=3	93,11 k-EYK k=3	93,20 k-EYK k=5	92,99 k-EYK k=3	87,90 DAA	91,90 DAA	91,90 k-EYK k=1
f18	88,94 k-EYK k=5	91,74 k-EYK k=3	92,01 k-EYK k=5	92,07 k-EYK k=3	90,20 k-EYK k=7	90,90 DVM	91,60 k-EYK k=3
f19	95,85 k-EYK k=1	<u>f19 sabit</u>	<u>f19 sabit</u>	<u>f19 sabit</u>	93,30 k-EYK k=5	<u>f19 sabit</u>	<u>f19 sabit</u>
f20	91,58 k-EYK k=5	96,91 k-EYK k=5	<u>f20 sabit</u>	<u>f20 sabit</u>	91,90 k-EYK k=7	92,30 DVM	93,60 k-EYK k=1
f21	89,53 k-EYK k=5	94,34 k-EYK k=1	94,81 k-EYK k=1	94,07 k-EYK k=1	91,60 DAA	92,90 k-EYK k=1	94,60 k-EYK k=1
f22	86,22 k-EYK k=3	94,37 k-EYK k=1	94,64 k-EYK k=1	95,04 k-EYK k=1	87,90 k-EYK k=9	92,90 k-EYK k=5	94,30 k-EYK k=1
f23	81,78 k-EYK k=7	90,08 k-EYK k=3	90,67 DAA	90,85 DAA	81,50 DAA	91,90 k-EYK k=5	91,60 k-EYK k=1
f24	94,99 k-EYK k=1	95,72 k-EYK k=1	96,48 k-EYK k=1	96,35 k-EYK k=1	91,90 DVM	90,90 k-EYK k=5	92,60 DVM
f25	83,21 k-EYK k=9	94,50 k-EYK k=1	95,77 k-EYK k=1	92,24 k-EYK k=1	83,20 DVM	90,90 DVM	91,90 DVM
f26	81,54 DAA	94,49 k-EYK k=1	95,01 k-EYK k=1	95,23 k-EYK k=1	86,90 DAA	90,20 k-EYK k=3	92,30 DVM
f27	88,77 k-EYK k=7	95,68 k-EYK k=1	96,68 k-EYK k=1	96,89 k-EYK k=1	87,50 DVM	90,60 DAA	93,60 k-EYK k=1
f28	84,88 k-EYK k=5	95,95 k-EYK k=1	97,09 k-EYK k=1	96,62 k-EYK k=1	85,50 k-EYK k=9	90,20 k-EYK k=3	91,90 DVM
f29	83,56 k-EYK k=9	96,12 k-EYK k=1	96,89 k-EYK k=1	97,01 k-EYK k=1	85,50 k-EYK k=7	91,20 k-EYK k=1	90,90 k-EYK k=1
f30	78,47 DAA	88,49 DAA	90,90 DAA	90,70 DAA	84,20 k-EYK k=9	91,60 DVM	92,90 k-EYK k=5
f31	75,55 k-EYK k=5	89,00 DAA	90,72 DAA	90,21 DAA	79,80 k-EYK k=13	91,20 DAA	91,90 DAA
f32	90,02 k-EYK k=3	95,79 k-EYK k=1	97,34 k-EYK k=1	<u>f32 sabit</u>	87,50 DVM	91,20 k-EYK k=3	93,30 k-EYK k=1

3.4. Tam Solunum Döngüsü Seslerinin Yaygın Akciğer Sesleri İçin Sınıflandırma Bulguları

Tam solunum döngülerinden eğitim kümeleri için elde edilen yaygın akciğer ses sınıflandırma sonuçlarının ortalamaları Tablo-10'da gösterilmektedir. TBA uygulanmadan önceki ilk sınıflandırma sonuçları değerlendirildiğinde f19 özniteliğinin 85,80 ortalama ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. İkinci adımda ise f19+f24 öznitelik kombinasyonunun %87,04 ortalama değeri ile %1,24'lük bir başarı artışı elde edilmiştir. Dördüncü adımdaki başarı ise AİYÖS yöntemi sayesinde %1,50'lik bir ek artışla %87,30'a kadar yükselmiştir. Başarım yükseldiğinden 5.adımdaki öznitelik kombinasyonlarının başarıları da incelenmiştir. Ancak bu adımdaki kombinasyonların başarıları düşüşünden AİYÖS yöntemi gereği sınıflandırma sonlandırılmıştır.

TBA uygulandığında diğer sonuçlarda olduğu gibi burada da f19 özniteliği AİYÖS yönteminin 1.adımında en başarılı öznitelik olarak %82,20 ortalama değer ile ortaya çıkmaktadır. TBA uygulanmadan önceki f19 özniteliği başarıyı %85,50 iken, TBA uygulandığında bu başarımın %82,20'ye düştüğü gözlemlenmiştir. 2.adımdaki ikili öznitelik kombinasyonları değerlendirildiğinde, en yüksek başarımın %2'lik bir artışla %84,20 ortalama değer ile f19+f8 öznitelik kombinasyonuna ait olduğu görülmektedir. Başarımda artış olduğundan daha sonra üçlü öznitelik kombinasyonlarına geçilse de bu kombinasyonlarda elde edilen en iyi başarım ortalama %81,80'de kalmıştır. Dolayısıyla üçlü kombinasyonların başarıyı ikili kombinasyonlara göre düşüş gösterdiğinden sınıflandırma burada sonlandırılmıştır.

Tablo 10. Tam solunum döngülerinden elde edilen yaygın akciğer ses sınıflandırma bulguları (%)

	AİYÖS Yöntemi Sonuçları					TBA+ AİYÖS Yöntemi Sonuçları		
	1.Adım	2.Adım	3.Adım	4.Adım	5.Adım	1.Adım	2.Adım	3.Adım
<i>f1</i>	53,40 DAA	85,79 k-EYK k=1	80,74 k-EYK k=1	81,99 k-EYK k=1	81,92 k-EYK k=1	55,60 DVM	75,80 k-EYK k=5	78,10 k-EYK k=1
<i>f2</i>	49,83 DAA	67,14 DAA	84,52 k-EYK k=1	70,41 DAA	71,57 DAA	53,50 DVM	76,10 k-EYK k=1	76,80 k-EYK k=1
<i>f3</i>	61,85 DVM	82,89 k-EYK k=1	84,90 k-EYK k=1	85,78 k-EYK k=1	85,67 k-EYK k=1	68,00 k-EYK k=5	82,20 k-EYK k=1	81,10 k-EYK k=1
<i>f4</i>	53,10 DAA	82,44 k-EYK k=1	84,33 k-EYK k=1	85,90 k-EYK k=1	85,52 k-EYK k=1	60,60 k-EYK k=3	81,80 k-EYK k=1	81,50 k-EYK k=1
<i>f5</i>	52,21 DAA	68,65 DAA	68,64 k-EYK k=1	71,32 DAA	72,13 DAA	57,60 k-EYK k=1	79,10 k-EYK k=1	80,80 k-EYK k=1
<i>f6</i>	54,76 k-EYK k=1	74,16 k-EYK k=1	77,76 k-EYK k=1	78,98 k-EYK k=1	79,47 k-EYK k=1	58,20 DVM	79,10 k-EYK k=1	78,10 k-EYK k=1
<i>f7</i>	50,73 k-EYK k=5	68,04 DAA	66,96 DAA	70,28 DAA	72,28 DAA	48,10 DVM	76,40 k-EYK k=1	77,80 k-EYK k=1
<i>f8</i>	61,17 DVM	79,94 k-EYK k=1	82,91 k-EYK k=1	84,02 k-EYK k=1	83,73 k-EYK k=1	63,30 k-EYK k=13	84,20 k-EYK k=1	<i>f8</i> sabit
<i>f9</i>	41,55 DAA	86,20 k-EYK k=1	86,03 k-EYK k=1	86,82 k-EYK k=1	86,79 k-EYK k=1	47,10 k-EYK k=9	78,50 k-EYK k=1	81,80 k-EYK k=1
<i>f10</i>	48,91 DAA	85,13 k-EYK k=1	85,49 k-EYK k=1	87,28 k-EYK k=1	87,16 k-EYK k=1	50,80 DVM	76,80 k-EYK k=1	78,10 k-EYK k=1
<i>f11</i>	64,80 k-EYK k=3	85,41 k-EYK k=1	85,42 k-EYK k=1	86,93 k-EYK k=1	86,86 k-EYK k=1	71,40 k-EYK k=3	80,80 k-EYK k=1	81,80 k-EYK k=1
<i>f12</i>	60,42 DAA	85,99 k-EYK k=1	85,48 k-EYK k=1	87,29 k-EYK k=1	87,06 k-EYK k=1	63,60 k-EYK k=1	76,40 k-EYK k=1	77,40 k-EYK k=1
<i>f13</i>	56,31 DVM	85,80 k-EYK k=1	85,34 k-EYK k=1	87,06 k-EYK k=1	87,06 k-EYK k=1	63,00 k-EYK k=3	76,40 k-EYK k=1	77,10 k-EYK k=1
<i>f14</i>	47,15 DAA	69,32 DAA	71,39 k-EYK k=1	73,50 k-EYK k=1	73,52 k-EYK k=1	49,20 DVM	74,10 k-EYK k=1	58,90 k-EYK k=19
<i>f15</i>	46,09 DAA	67,99 DAA	67,37 DAA	70,73 DAA	71,74 DAA	41,80 DVM	73,10 k-EYK k=1	74,40 k-EYK k=1
<i>f16</i>	61,39 DAA	85,41 k-EYK k=1	85,37 k-EYK k=1	87,30 k-EYK k=1	<i>f16</i> sabit	62,60 DVM	78,80 k-EYK k=1	81,10 k-EYK k=1

Tablo 10'un devamı

	AİYÖS Yöntemi Sonuçları					TBA+ AİYÖS Yöntemi Sonuçları		
	1.Adım	2.Adım	3.Adım	4.Adım	5.Adım	1.Adım	2.Adım	3.Adım
<i>f17</i>	59,32 k-EYK k=1	74,37 k-EYK k=1	74,52 k-EYK k=1	79,92 k-EYK k=1	78,22 k-EYK k=1	56,90 k-EYK k=5	68,70 DAA	69,40 k-EYK k=1
<i>f18</i>	61,91 k-EYK k=7	73,27 k-EYK k=3	76,29 k-EYK k=3	77,39 k-EYK k=1	77,23 k-EYK k=1	62,00 k-EYK k=15	67,30 DAA	64,60 DAA
<i>f19</i>	85,80 k-EYK k=1	<i>f19</i> sabit	<i>f19</i> sabit	<i>f19</i> sabit	<i>f19</i> sabit	82,20 k-EYK k=1	<i>f19</i> sabit	<i>f19</i> sabit
<i>f20</i>	67,20 k-EYK k=1	87,00 k-EYK k=1	87,09 k-EYK k=1	<i>f20</i> sabit	<i>f20</i> sabit	58,20 k-EYK k=5	73,40 k-EYK k=3	74,40 k-EYK k=1
<i>f21</i>	60,82 DAA	80,94 k-EYK k=1	82,18 k-EYK k=1	82,97 k-EYK k=1	82,09 k-EYK k=1	59,60 DVM	75,10 k-EYK k=1	74,70 k-EYK k=1
<i>f22</i>	61,23 k-EYK k=5	78,38 k-EYK k=1	80,42 k-EYK k=1	82,03 k-EYK k=1	81,99 k-EYK k=1	56,20 DVM	69,70 k-EYK k=1	72,70 k-EYK k=1
<i>f23</i>	51,05 k-EYK k=9	66,40 DAA	67,57 k-EYK k=3	70,90 DAA	72,13 k-EYK k=1	48,10 DVM	65,00 k-EYK k=1	69,70 k-EYK k=1
<i>f24</i>	83,69 k-EYK k=1	87,04 k-EYK k=1	<i>f24</i> sabit	<i>f24</i> sabit	<i>f24</i> sabit	73,40 k-EYK k=1	69,70 DAA	68,00 DAA
<i>f25</i>	47,07 DAA	81,72 k-EYK k=1	82,94 k-EYK k=1	84,95 k-EYK k=1	83,39 k-EYK k=1	46,50 DVM	67,70 k-EYK k=1	73,10 k-EYK k=1
<i>f26</i>	48,65 DAA	80,44 k-EYK k=1	81,82 k-EYK k=1	83,97 k-EYK k=1	83,56 k-EYK k=1	52,90 DVM	68,40 k-EYK k=3	71,00 k-EYK k=1
<i>f27</i>	65,20 DAA	85,69 k-EYK k=1	85,74 k-EYK k=1	87,06 k-EYK k=1	87,06 k-EYK k=1	63,60 DAA	74,40 k-EYK k=1	76,80 k-EYK k=1
<i>f28</i>	53,63 DAA	85,82 k-EYK k=1	85,35 k-EYK k=1	87,14 k-EYK k=1	87,14 k-EYK k=1	54,20 DAA	72,40 k-EYK k=1	75,80 k-EYK k=1
<i>f29</i>	53,15 DAA	85,08 k-EYK k=1	85,70 k-EYK k=1	87,06 k-EYK k=1	87,08 k-EYK k=1	54,20 DVM	75,80 k-EYK k=1	77,10 k-EYK k=1
<i>f30</i>	49,59 DAA	66,67 DAA	66,07 DAA	69,92 DAA	70,71 DAA	50,20 DAA	66,70 k-EYK k=1	69,40 k-EYK k=1
<i>f31</i>	44,53 k-EYK k=9	66,87 DAA	65,58 DAA	69,85 DAA	70,89 DAA	44,40 k-EYK k=11	65,00 DAA	68,70 k-EYK k=1
<i>f32</i>	65,86 k-EYK k=1	66,30 DAA	85,29 k-EYK k=1	87,06 k-EYK k=1	87,06 k-EYK k=1	59,90 DVM	75,80 k-EYK k=1	80,50 k-EYK k=1

3.5. İspirasyon Seslerinin Sağlıklı/Patolojik Akciğer Sesleri İçin Sınıflandırma Bulguları

İspirasyon seslerinin eğitim kümelerinden elde edilen sağlıklı/patolojik akciğer ses sınıflandırma sonuçlarının ortalamaları Tablo-11’de gösterilmektedir. TBA uygulanmadan önceki ilk sınıflandırma sonuçları değerlendirildiğinde yine f19 özniteliğinin %95,30’luk yüksek bir ortalama değer ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yönteminin ikinci adımına geçildiğinde ise f19+f29 öznitelik kombinasyonunun yine f19 özniteliğinde olduğu gibi %95,30 ortalama değerini verdiği görülmektedir. Fakat AİYÖS yöntemine göre, başarımda düşüş olmadığından öznitelik kombinasyonlarının araştırmasına devam edilmektedir. Bu nedenle üçlü öznitelik kombinasyonlarının da başarısı irdelenmiştir. Fakat üçlü kombinasyonlarda ortalama başarımda %94,90’a düştüğünden sınıflandırma AİYÖS yöntemi gereği durdurulmuştur. Dolayısıyla TBA uygulanmadığı durumdaki en iyi başarımda f19 özniteliği kullanıldığında veya f19+f29 öznitelikleri birlikte kullanıldığında elde edilebilmiştir.

TBA uygulandığında f19 özniteliği AİYÖS yönteminin 1.adımında en başarılı öznitelik olarak %91,60 ortalama değer ile öne çıkmaktadır. F19 özniteliği sabit tutulup, ikili öznitelik kombinasyonları araştırıldığındaki başarımda f19+f3 kombinasyonunda %1,30’luk bir artışla %92,30’a kadar yükselmiştir. Başarımda artış nedeniyle daha sonra üçlü kombinasyonların sonuçları irdelenmiştir. Üçlü kombinasyonlarda en iyi sonucu f19+f3+f8 öznitelik kombinasyonu % 93,30’luk bir ortalama değere taşımıştır. Bu durumda AİYÖS yöntemi sayesinde 1.adıma göre %1,7’lik bir artış elde edilmiştir. Başarımda artış devam ettiğinden dördü öznitelik kombinasyonlarının başarımları da araştırılmıştır. Fakat dördü kombinasyonlardan elde edilen en yüksek ortalama başarımda %1 gerileyerek en fazla %92,30’da kalmıştır. Dördü kombinasyonların başarımlarında yaşanan düşüş nedeniyle AİYÖS yöntemine göre beşli kombinasyonların sınıflandırma sonuçları hesaplanmadan sınıflandırma aşaması son bulmuştur.

Tablo 11. İspirasyon seslerinden elde edilen sağlıklı/patolojik akciğer ses sınıflandırma bulguları (%)

	AİYÖS Yöntemi Sonuçları			TBA+ AİYÖS Yöntemi Sonuçları			
	1.Adım	2.Adım	3.Adım	1.Adım	2.Adım	3.Adım	3.Adım
<i>f1</i>	88,20 k-EYK k=9	93,60 k-EYK k=3	92,90 k-EYK k=3	87,20 k-EYK k=9	91,60 DAA	92,30 DAA	92,30 DVM
<i>f2</i>	84,50 DVM	93,90 k-EYK k=3	94,60 k-EYK k=3	84,20 DAA	91,90 k-EYK k=7	91,60 k-EYK k=5	91,60 k-EYK k=7
<i>f3</i>	91,20 k-EYK k=9	94,60 k-EYK k=5	94,30 k-EYK k=1	91,30 k-EYK k=7	92,90 DVM	<i>f3</i> sabit	<i>f3</i> sabit
<i>f4</i>	86,90 k-EYK k=7	93,60 k-EYK k=3	93,60 k-EYK k=3	87,20 k-EYK k=5	92,60 k-EYK k=5	93,10 k-EYK k=3	91,60 DVM
<i>f5</i>	84,50 k-EYK k=5	92,90 k-EYK k=5	92,90 k-EYK k=3	82,80 k-EYK k=5	91,90 k-EYK k=5	93,10 k-EYK k=7	91,20 k-EYK k=5
<i>f6</i>	82,80 k-EYK k=21	92,90 k-EYK k=1	92,30 k-EYK k=5	82,80 k-EYK k=7	92,30 DAA	91,90 DVM	91,90 DVM
<i>f7</i>	81,10 k-EYK k=3	92,60 k-EYK k=5	93,30 k-EYK k=1	80,80 k-EYK k=9	91,20 k-EYK k=5	92,60 DAA	92,30 DVM
<i>f8</i>	88,20 k-EYK k=5	94,30 k-EYK k=5	93,60 k-EYK k=3	88,20 k-EYK k=7	92,60 k-EYK k=3	93,30 DVM	<i>f8</i> sabit
<i>f9</i>	82,80 k-EYK k=7	93,60 k-EYK k=1	94,30 k-EYK k=1	82,80 DAA	91,20 DAA	91,90 k-EYK k=7	91,60 k-EYK k=3
<i>f10</i>	85,50 DVM	92,30 k-EYK k=3	93,30 k-EYK k=3	83,20 DVM	91,60 DAA	92,90 k-EYK k=5	92,30 k-EYK k=5
<i>f11</i>	86,50 k-EYK k=5	94,30 k-EYK k=3	94,90 k-EYK k=3	89,20 k-EYK k=7	91,20 DAA	92,90 k-EYK k=5	92,30 k-EYK k=7
<i>f12</i>	88,20 DVM	93,90 k-EYK k=1	94,60 k-EYK k=3	90,20 DVM	92,30 k-EYK k=3	92,60 k-EYK k=3	91,60 DVM
<i>f13</i>	87,90 DVM	93,90 k-EYK k=1	93,90 k-EYK k=3	88,90 DVM	92,60 k-EYK k=5	92,60 k-EYK k=7	92,30 DVM
<i>f14</i>	74,70 DVM	92,30 k-EYK k=5	91,90 k-EYK k=7	75,10 DAA	92,30 DAA	92,30 k-EYK k=3	91,90 DVM
<i>f15</i>	74,70 DVM	92,30 k-EYK k=5	91,90 k-EYK k=3	78,80 k-EYK k=9	92,30 k-EYK k=5	91,90 k-EYK k=3	92,30 DVM
<i>f16</i>	81,80 k-EYK k=7	94,30 k-EYK k=3	94,30 k-EYK k=3	83,50 k-EYK k=11	91,20 k-EYK k=7	91,90 k-EYK k=7	92,30 k-EYK k=3

Tablo 11'in devamı

	AİYÖS Yöntemi Sonuçları			TBA+ AİYÖS Yöntemi Sonuçları			
	1.Adım	2.Adım	3.Adım	1.Adım	2.Adım	3.Adım	3.Adım
<i>f17</i>	88,90 k-EYK k=7	92,90 k-EYK k=3	92,60 k-EYK k=5	86,20 DAA	90,90 DVM	92,30 DVM	92,30 DVM
<i>f18</i>	90,90 k-EYK k=11	92,30 k-EYK k=3	91,90 k-EYK k=11	89,60 DVM	91,90 DAA	91,20 DVM	90,20 DAA
<i>f19</i>	95,30 k-EYK k=3	<i>f19</i> sabit	<i>f19</i> sabit	91,60 k-EYK k=5	<i>f19</i> sabit	<i>f19</i> sabit	<i>f19</i> sabit
<i>f20</i>	89,20 DVM	93,60 k-EYK k=3	93,30 k-EYK k=5	90,90 DAA	92,30 DAA	92,30 k-EYK k=3	91,60 DVM
<i>f21</i>	87,50 DVM	93,60 k-EYK k=5	93,90 k-EYK k=1	88,60 DAA	92,30 DVM	92,60 k-EYK k=5	92,30 k-EYK k=3
<i>f22</i>	85,90 k-EYK k=7	92,60 k-EYK k=3	92,60 k-EYK k=3	84,50 k-EYK k=3	92,30 DAA	91,90 DVM	91,60 k-EYK k=5
<i>f23</i>	80,50 k-EYK k=5	92,90 k-EYK k=3	91,90 k-EYK k=1	80,10 DAA	90,90 DVM	91,20 k-EYK k=5	90,90 k-EYK k=5
<i>f24</i>	92,30 k-EYK k=3	92,60 k-EYK k=3	92,90 k-EYK k=5	90,60 DVM	91,60 DAA	92,30 k-EYK k=3	91,60 k-EYK k=3
<i>f25</i>	85,20 DVM	92,90 k-EYK k=3	91,60 k-EYK k=3	82,50 DVM	90,60 DAA	91,20 DVM	90,60 DVM
<i>f26</i>	84,80 DVM	91,90 DVM	91,60 DVM	84,80 DVM	91,20 DAA	90,20 DVM	90,90 DVM
<i>f27</i>	88,20 k-EYK k=11	94,90 k-EYK k=3	94,60 k-EYK k=3	87,90 DVM	91,20 DAA	92,60 DVM	92,30 DVM
<i>f28</i>	84,80 DVM	93,90 k-EYK k=3	93,30 k-EYK k=3	85,20 DVM	90,20 k-EYK k=1	90,90 DVM	92,30 DVM
<i>f29</i>	86,20 k-EYK k=7	95,30 k-EYK k=3	<i>f29</i> sabit	82,20 DVM	90,20 DAA	90,90 DVM	89,60 DVM
<i>f30</i>	82,50 DVM	90,60 k-EYK k=11	90,60 DVM	82,20 k-EYK k=13	91,20 k-EYK k=7	92,30 DVM	91,20 DVM
<i>f31</i>	77,80 DVM	91,20 DVM	90,60 k-EYK k=9	79,50 DAA	90,60 DVM	91,60 DVM	91,60 DVM
<i>f32</i>	88,90 k-EYK k=5	93,60 k-EYK k=3	94,30 k-EYK k=3	85,50 DVM	90,90 DAA	90,90 DVM	91,20 DVM

3.6. İspirasyon Seslerinin Yaygın Akciğer Sesleri İçin Sınıflandırma Bulguları

İspirasyon seslerinin eğitim kümelerinden elde edilen yaygın akciğer ses sınıflandırma sonuçlarının ortalamaları Tablo-12’de gösterilmektedir. TBA uygulanmadan önceki ilk sınıflandırma sonuçları değerlendirildiğinde yine f19 özniteliğinin %95,30’luk yüksek bir ortalama değer ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yönteminin ikinci adımına geçildiğinde ise f19+f29 öznitelik kombinasyonunun yine f19 özniteliğinde olduğu gibi %95,30 ortalama değerini verdiği görülmektedir. Fakat AİYÖS yöntemine göre, başarımda düşüş olmadığından öznitelik kombinasyonlarının araştırmasına devam edilmektedir. Bu nedenle üçlü öznitelik kombinasyonlarının da başarısı irdelenmiştir. Fakat üçlü kombinasyonlarda ortalama başarımlar %94,90’a düştüğünden sınıflandırma AİYÖS yöntemi gereği durdurulmuştur. Dolayısıyla TBA uygulanmadığı durumdaki en iyi başarımlar f19 özniteliği kullanıldığında veya f19+f29 öznitelikleri birlikte kullanıldığında elde edilebilmiştir.

TBA uygulandığında f19 özniteliği AİYÖS yönteminin 1.adımında en başarılı öznitelik olarak %91,60 ortalama değer ile öne çıkmaktadır. F19 özniteliği sabit tutulup, ikili öznitelik kombinasyonları araştırıldığındaki başarımlar f19+f3 kombinasyonunda %1,30’luk bir artışla %92,30’a kadar yükselmiştir. Başarımların artışı nedeniyle daha sonra üçlü kombinasyonların sonuçları irdelenmiştir. Üçlü kombinasyonlarda en iyi sonucu f19+f3+f8 öznitelik kombinasyonu % 93,30’luk bir ortalama değere taşımıştır. Bu durumda AİYÖS yöntemi sayesinde 1.adıma göre %1,7’lik bir artış elde edilmiştir. Başarımların artışı devam ettiğinden dördümlü öznitelik kombinasyonlarının başarımları da araştırılmıştır. Fakat dördümlü kombinasyonlardan elde edilen en yüksek ortalama başarımlar %1 gerileyerek en fazla %92,30’da kalmıştır. Dördümlü kombinasyonların başarımlarında yaşanan düşüş nedeniyle AİYÖS yöntemine göre beşli kombinasyonların sınıflandırma sonuçları hesaplanmadan sınıflandırma aşaması son bulmuştur.

Tablo 12. İspirasyon seslerinden elde edilen yaygın akciğer ses sınıflandırma bulguları (%)

	AİYÖS Yöntemi Sonuçları			TBA+ AİYÖS Yöntemi Sonuçları		
	1.Adım	2.Adım	3.Adım	1.Adım	2.Adım	3.Adım
<i>f1</i>	52,20 k-EYK k=5	79,10 k-EYK k=1	78,80 k-EYK k=1	54,20 DVM	73,40 k-EYK k=1	<i>f1</i> sabit
<i>f2</i>	52,90 k-EYK k=9	81,10 k-EYK k=1	79,80 k-EYK k=1	51,20 k-EYK k=1	70,00 k-EYK k=1	71,70 k-EYK k=5
<i>f3</i>	64,00 k-EYK k=3	83,20 k-EYK k=1	<i>f3</i> sabit	64,60 k-EYK k=1	72,40 k-EYK k=9	72,70 k-EYK k=1
<i>f4</i>	56,60 k-EYK k=3	77,40 k-EYK k=3	76,80 k-EYK k=1	56,20 k-EYK k=1	72,70 k-EYK k=3	72,10 k-EYK k=1
<i>f5</i>	53,20 k-EYK k=5	76,10 k-EYK k=3	79,80 k-EYK k=1	51,90 DVM	72,40 k-EYK k=3	72,10 k-EYK k=1
<i>f6</i>	52,50 k-EYK k=15	78,50 k-EYK k=1	77,80 k-EYK k=1	50,80 DVM	67,00 k-EYK k=1	69,70 k-EYK k=1
<i>f7</i>	44,80 DVM	74,70 k-EYK k=1	75,80 k-EYK k=1	46,50 DVM	69,00 k-EYK k=5	70,40 k-EYK k=1
<i>f8</i>	60,90 k-EYK k=7	81,10 k-EYK k=1	80,50 k-EYK k=1	61,30 DVM	72,70 k-EYK k=7	73,40 k-EYK k=1
<i>f9</i>	51,90 k-EYK k=17	83,10 k-EYK k=1	82,20 k-EYK k=1	48,50 DAA	69,40 k-EYK k=1	70,00 k-EYK k=1
<i>f10</i>	49,80 k-EYK k=15	76,80 k-EYK k=1	78,50 k-EYK k=1	49,20 DVM	68,00 k-EYK k=1	69,00 k-EYK k=1
<i>f11</i>	55,90 k-EYK k=17	80,80 k-EYK k=1	80,80 k-EYK k=1	66,30 k-EYK k=1	72,70 k-EYK k=1	72,40 k-EYK k=1
<i>f12</i>	58,20 k-EYK k=11	78,10 k-EYK k=1	79,10 k-EYK k=1	60,90 k-EYK k=5	73,10 k-EYK k=1	71,70 k-EYK k=1
<i>f13</i>	53,20 k-EYK k=19	77,40 k-EYK k=1	78,80 k-EYK k=1	59,60 k-EYK k=5	72,10 k-EYK k=7	72,10 k-EYK k=1
<i>f14</i>	42,11 k-EYK k=15	72,40 k-EYK k=9	76,10 k-EYK k=1	43,40 DVM	71,00 k-EYK k=1	70,70 k-EYK k=5
<i>f15</i>	39,40 k-EYK k=1	71,70 k-EYK k=5	73,10 k-EYK k=1	40,10 k-EYK k=5	68,40 k-EYK k=9	67,30 k-EYK k=5
<i>f16</i>	55,20 DVM	79,10 k-EYK k=1	79,80 k-EYK k=1	60,90 DVM	72,10 k-EYK k=1	69,40 k-EYK k=1

Tablo 12'nin devamı

	AİYÖS Yöntemi Sonuçları			TBA+ AİYÖS Yöntemi Sonuçları		
	1.Adım	2.Adım	3.Adım	1.Adım	2.Adım	3.Adım
<i>f17</i>	55,60 k-EYK k=1	71,70 k-EYK k=1	75,10 k-EYK k=1	56,90 k-EYK k=13	66,00 DAA	67,70 DAA
<i>f18</i>	61,30 k-EYK k=9	70,00 k-EYK k=1	73,40 k-EYK k=1	57,60 DVM	67,70 DVM	66,30 DVM
<i>f19</i>	82,20 k-EYK k=1	<i>f19</i> sabit	<i>f19</i> sabit	71,00 k-EYK k=1	<i>f19</i> sabit	<i>f19</i> sabit
<i>f20</i>	54,20 k-EYK k=1	78,80 k-EYK k=1	79,80 k-EYK k=1	59,90 DVM	71,40 DAA	71,00 DAA
<i>f21</i>	54,20 k-EYK k=1	78,80 k-EYK k=1	79,10 k-EYK k=1	58,60 DVM	69,40 DVM	69,00 DAA
<i>f22</i>	53,20 k-EYK k=1	73,10 k-EYK k=1	71,40 k-EYK k=1	46,80 k-EYK k=1	57,20 k-EYK k=13	66,00 DAA
<i>f23</i>	40,10 k-EYK k=5	72,10 k-EYK k=5	71,40 k-EYK k=1	41,10 DAA	64,30 DVM	65,30 k-EYK k=1
<i>f24</i>	77,80 k-EYK k=1	78,10 k-EYK k=1	80,10 k-EYK k=1	65,00 DVM	65,30 DVM	67,00 DVM
<i>f25</i>	46,10 k-EYK k=11	73,10 k-EYK k=5	73,40 k-EYK k=1	48,10 DVM	64,30 DAA	65,70 DAA
<i>f26</i>	49,20 k-EYK k=9	72,70 k-EYK k=3	77,80 k-EYK k=1	47,50 DVM	64,30 k-EYK k=1	66,00 k-EYK k=7
<i>f27</i>	62,60 k-EYK k=7	79,50 k-EYK k=1	81,50 k-EYK k=1	62,30 DVM	67,00 DAA	69,40 k-EYK k=1
<i>f28</i>	53,50 DVM	76,40 k-EYK k=1	78,10 k-EYK k=1	53,90 DVM	66,00 DVM	66,30 k-EYK k=1
<i>f29</i>	50,50 DVM	80,10 k-EYK k=1	79,80 k-EYK k=1	52,50 DVM	67,30 k-EYK k=5	67,70 k-EYK k=1
<i>f30</i>	50,20 DVM	68,70 k-EYK k=5	73,10 k-EYK k=1	50,80 k-EYK k=15	65,00 k-EYK k=5	67,00 k-EYK k=1
<i>f31</i>	44,80 DVM	69,00 k-EYK k=5	69,40 k-EYK k=5	47,10 DAA	64,60 DVM	65,00 k-EYK k=1
<i>f32</i>	63,30 k-EYK k=1	79,50 k-EYK k=1	81,50 k-EYK k=1	58,60 DVM	71,70 k-EYK k=1	71,40 k-EYK k=1

3.7. Ekspirasyon Seslerinin Sağlıklı/Patolojik Akciğer Sesleri İçin Sınıflandırma Bulguları

Ekspirasyon seslerinin eğitim kümelerinden elde edilen sağlıklı/patolojik akciğer ses sınıflandırma sonuçlarının ortalamaları Tablo-13’de gösterilmektedir. TBA uygulanmadan önceki ilk sınıflandırma sonuçları değerlendirildiğinde f19 özniteliğinin %94,60’luk yüksek bir ortalama değer ile diğer öznitelik gruplarına göre en yüksek sınıflandırma sonucunu verdiği ve öne çıktığı görülmektedir. AİYÖS yöntemine göre ikinci adımda ikili öznitelik kombinasyonlarının başarımları incelendiğinde f19 ve f21’den oluşan ikili öznitelik kombinasyonunun 1.adıma göre %1,7’lik bir artışla %96,30’luk bir ortalama değere ulaştığı görülmektedir. Bu sonuç artış gösterdiğinden AİYÖS yöntemine göre üçlü kombinasyon başarımları da incelenmiştir. Tablo-13 değerlendirildiğinde, f19+f21+f24 kombinasyonu %97,00’lik bir başarıma ulaşmıştır. Dörtlü öznitelik kombinasyonları değerlendirildiğinde de f19+f21+f24+f1 kombinasyonu sayesinde başarımlar %97,30’a ulaşmıştır. Başarımların artışı f19+f21+f24+f1+f12’den oluşan beşli öznitelik kombinasyonlarında da devam ederek %97,60’a kadar artmıştır. Ancak 6.adımda %0,30 luk bir azalışla %97,30 ortalama değeri elde edildiğinden AİYÖS yöntemi gereği sınıflandırma sonlandırılmıştır. Böylece ekspirasyon seslerinin sağlıklı/patolojik sınıflandırma sonucu %97,60 olarak elde edilmiştir.

AİYÖS yöntemi TBA birlikte uygulandığında f19 özniteliği 1.adımda %90,60 ortalama değeri ile en başarılı sonucu vermiştir. F19 özniteliği ikili kombinasyonlarda sabit tutulup, diğer öznitelikler ile kombinasyonları araştırıldığındaki başarımlar f19+f20 kombinasyonunda 1.adımdaki başarımlara göre %2,70’lik bir artışla %93,30’a kadar yükselmiştir. Başarımların artışı nedeniyle daha sonra üçlü kombinasyonların sonuçları irdelenmiştir. Üçlü kombinasyonlarda en iyi sonucu f19+f20 +f8 öznitelik kombinasyonu % 93,90’lık bir ortalama değere taşımıştır. Bu durumda AİYÖS yöntemi sayesinde 1.adıma göre %3,30’luk bir artış elde edilmiştir. Başarımların artışı devam ettiğinden dörtlü öznitelik kombinasyonlarının başarımları da araştırılmıştır. Fakat dörtlü kombinasyonlardan elde edilen en yüksek ortalama başarımlar %0,3 gerileyerek en fazla %93,60’da kalmıştır. Dörtlü kombinasyonların başarımlarında yaşanan düşüş nedeniyle AİYÖS yöntemine göre beşli kombinasyonların sınıflandırma sonuçları hesaplanmadan sınıflandırma aşaması son bulmuştur.

Tablo 13. Ekspirasyon seslerinden elde edilen sağlıklı/patolojik akciğer ses sınıflandırma bulguları (%)

	AİYÖS Yöntemi Sonuçları						TBA+ AİYÖS Yöntemi Sonuçları			
	1.Adım	2.Adım	3.Adım	4.Adım	5.Adım	6.Adım	1.Adım	2.Adım	3.Adım	4.Adım
<i>f1</i>	86,50 k-EYK k=3	94,30 k-EYK k=3	96,00 k-EYK k=1	97,30 k-EYK k=1	<i>f1</i> sabit	<i>f1</i> sabit	85,20 DVM	90,20 k-EYK k=5	90,90 k-EYK k=1	91,20 DAA
<i>f2</i>	84,80 k-EYK k=7	93,60 k-EYK k=1	94,60 k-EYK k=1	94,90 k-EYK k=1	96,00 k-EYK k=1	95,60 k-EYK k=1	83,50 DAA	92,30 k-EYK k=5	91,20 DAA	91,60 k-EYK k=3
<i>f3</i>	88,90 k-EYK k=3	95,30 k-EYK k=1	96,60 k-EYK k=1	96,60 k-EYK k=1	96,60 k-EYK k=1	96,60 k-EYK k=1	87,90 k-EYK k=1	92,60 k-EYK k=5	92,30 k-EYK k=5	91,90 k-EYK k=3
<i>f4</i>	85,20 k-EYK k=5	93,90 k-EYK k=3	96,00 k-EYK k=1	95,60 k-EYK k=1	96,30 k-EYK k=1	97,00 k-EYK k=1	83,80 k-EYK k=17	92,30 k-EYK k=5	92,30 k-EYK k=5	93,30 k-EYK k=3
<i>f5</i>	83,50 k-EYK k=11	94,60 k-EYK k=3	96,30 k-EYK k=1	95,30 k-EYK k=1	96,00 k-EYK k=1	96,60 k-EYK k=1	80,50 k-EYK k=5	92,60 k-EYK k=5	91,20 k-EYK k=3	92,30 k-EYK k=3
<i>f6</i>	80,80 k-EYK k=11	92,90 k-EYK k=1	94,30 k-EYK k=1	94,90 k-EYK k=1	96,00 k-EYK k=1	95,30 k-EYK k=1	78,80 DAA	89,90 DAA	91,90 k-EYK k=3	91,60 k-EYK k=3
<i>f7</i>	79,80 k-EYK k=9	91,60 k-EYK k=1	93,30 k-EYK k=1	93,60 k-EYK k=1	94,30 k-EYK k=1	94,30 k-EYK k=1	80,80 DAA	90,20 DAA	91,20 k-EYK k=3	93,60 k-EYK k=3
<i>f8</i>	87,50 k-EYK k=7	95,60 k-EYK k=1	96,30 k-EYK k=1	96,60 k-EYK k=1	96,60 k-EYK k=1	97,00 k-EYK k=1	85,90 k-EYK k=7	91,60 k-EYK k=7	93,90 k-EYK k=3	<i>f8</i> sabit
<i>f9</i>	85,50 k-EYK k=13	92,30 k-EYK k=1	94,60 k-EYK k=1	94,90 k-EYK k=1	94,90 k-EYK k=1	95,60 k-EYK k=1	86,50 k-EYK k=9	89,90 DVM	90,90 DVM	90,60 DVM
<i>f10</i>	84,80 k-EYK k=9	94,60 k-EYK k=1	95,60 k-EYK k=1	96,60 k-EYK k=1	96,60 k-EYK k=1	96,00 k-EYK k=1	80,50 k-EYK k=17	91,60 DAA	91,90 DAA	91,90 k-EYK k=3
<i>f11</i>	85,50 k-EYK k=15	94,30 k-EYK k=1	95,30 k-EYK k=3	96,00 k-EYK k=3	96,00 k-EYK k=1	97,00 k-EYK k=1	87,90 k-EYK k=7	91,20 DVM	91,60 DVM	92,60 k-EYK k=3
<i>f12</i>	87,20 k-EYK k=3	95,60 k-EYK k=1	96,30 k-EYK k=1	96,30 k-EYK k=1	97,60 k-EYK k=1	<i>f12</i> sabit	87,50 k-EYK k=13	91,20 k-EYK k=5	91,60 k-EYK k=7	92,90 k-EYK k=3
<i>f13</i>	84,80 DVM	94,90 k-EYK k=1	95,30 k-EYK k=3	96,30 k-EYK k=1	96,60 k-EYK k=1	95,60 k-EYK k=1	86,90 k-EYK k=5	91,90 k-EYK k=5	91,60 DVM	91,90 k-EYK k=3
<i>f14</i>	80,10 k-EYK k=17	92,60 k-EYK k=3	94,90 k-EYK k=3	95,30 k-EYK k=3	95,30 k-EYK k=1 3	96,00 k-EYK k=1	77,80 k-EYK k=13	90,90 k-EYK k=5	91,20 DAA	91,20 k-EYK k=3
<i>f15</i>	80,10 k-EYK k=9	92,90 k-EYK k=1	94,30 k-EYK k=1	95,60 k-EYK k=1	95,60 k-EYK k=1	96,00 k-EYK k=1	79,50 k-EYK k=13	90,60 DVM	91,20 DVM	93,30 k-EYK k=3
<i>f16</i>	83,50 k-EYK k=13	92,90 k-EYK k=3	96,30 k-EYK k=1	96,30 k-EYK k=1	96,00 k-EYK k=1	96,00 k-EYK k=1	78,50 k-EYK k=3	91,20 k-EYK k=5	92,90 k-EYK k=3	93,30 k-EYK k=3

Tablo 13'ün devamı

	AİYÖS Yöntemi Sonuçları						TBA+ AİYÖS Yöntemi Sonuçları			
	1.Adım	2.Adım	3.Adım	4.Adım	5.Adım	6.Adım	1.Adım	2.Adım	3.Adım	4.Adım
<i>f17</i>	90,60 DVM	92,30 k-EYK k=5	94,90 k-EYK k=1	94,60 k-EYK k=1	95,30 k-EYK k=1	94,30 k-EYK k=1	88,20 k-EYK k=7	90,20 DVM	91,60 DVM	91,60 DVM
<i>f18</i>	90,20 k-EYK k=5	91,60 k-EYK k=5	94,90 k-EYK k=1	95,30 k-EYK k=3	94,90 k-EYK k=1	94,30	88,60 DAA	89,20 DVM	91,20 DVM	91,20 DVM
<i>f19</i>	94,60 k-EYK k=3	<i>f19</i> sabit	<i>f19</i> sabit	<i>f19</i> sabit	<i>f19</i> sabit	<i>f19</i> sabit	90,60 k-EYK k=3	<i>f19</i> sabit	<i>f19</i> sabit	<i>f19</i> sabit
<i>f20</i>	90,20 k-EYK k=3	96,00 k-EYK k=1	96,00 k-EYK k=1	96,00 k-EYK k=3	96,30 k-EYK k=1	96,30 k-EYK k=1	90,30 k-EYK k=9	93,30 k-EYK k=3	<i>f20</i> sabit	<i>f20</i> sabit
<i>f21</i>	89,60 k-EYK k=1	96,30 k-EYK k=3	<i>f21</i> sabit	<i>f21</i> sabit	<i>f21</i> sabit	<i>f21</i> sabit	88,90 k-EYK k=7	91,90 k-EYK k=3	90,90 k-EYK k=3	91,60 k-EYK k=3
<i>f22</i>	84,20 k-EYK k=17	90,60 k-EYK k=7	91,90 k-EYK k=3	92,30 k-EYK k=3	93,30 k-EYK k=1	93,30 k-EYK k=1	84,50 k-EYK k=21	90,90 DVM	91,20 DVM	91,60 k-EYK k=3
<i>f23</i>	76,10 k-EYK k=23	90,60 k-EYK k=3	91,60 k-EYK k=3	92,60 k-EYK k=5	92,90 k-EYK k=1	92,60 k-EYK k=1	76,10 DVM	89,90 DAA	91,60 DVM	91,20 DVM
<i>f24</i>	93,60 k-EYK k=3	94,90 k-EYK k=3	97,00 k-EYK k=1	<i>f24</i> sabit	<i>f24</i> sabit	<i>f24</i> sabit	89,60 k-EYK k=3	90,60 DVM	91,20 DVM	91,20 DVM
<i>f25</i>	82,50 k-EYK k=15	91,90 k-EYK k=1	94,90 k-EYK k=1	94,30 k-EYK k=1	94,60 k-EYK k=1	94,90 k-EYK k=1	82,20 DVM	90,60 DVM	90,20 DAA	90,20 DVM
<i>f26</i>	84,50 DVM	92,90 k-EYK k=3	95,30 k-EYK k=1	95,30 k-EYK k=1	95,60 k-EYK k=1	94,90 k-EYK k=1	82,50 DVM	89,02 DVM	91,20 DVM	90,20 DVM
<i>f27</i>	87,50 k-EYK k=3	95,30 k-EYK k=1	95,30 k-EYK k=3	95,60 k-EYK k=1	97,30 k-EYK k=1	97,30 k-EYK k=1	86,50 DVM	89,90 DVM	90,20 k-EYK k=1	90,20 DAA
<i>f28</i>	85,20 DVM	94,30 k-EYK k=1	95,30 k-EYK k=1	95,60 k-EYK k=1	96,30 k-EYK k=1	96,00 k-EYK k=1	82,80 DAA	91,90 DVM	91,20 DVM	91,20 DVM
<i>f29</i>	82,80 k-EYK k=9	92,60 k-EYK k=1	94,90 k-EYK k=1	96,00 k-EYK k=1	97,00 k-EYK k=1	96,60 k-EYK k=1	82,80 DVM	89,20 DAA	89,90 DAA	89,60 DVM
<i>f30</i>	82,80 k-EYK k=13	89,90 k-EYK k=1	92,30 k-EYK k=1	93,60 k-EYK k=1	93,60 k-EYK k=1	93,60 k-EYK k=3	82,50 DAA	89,60 DVM	91,60 DVM	91,20 k-EYK k=7
<i>f31</i>	76,40 k-EYK k=9	90,60 k-EYK k=1	93,30 k-EYK k=1	93,30 k-EYK k=1	94,30 k-EYK k=1	93,30 k-EYK k=1	78,50 k-EYK k=5	89,20 k-EYK k=3	90,90 DVM	91,20 k-EYK k=3
<i>f32</i>	86,90 DVM	93,30 k-EYK k=1	96,60 k-EYK k=1	96,60 k-EYK k=1	96,60 k-EYK k=1	97,00 k-EYK k=1	83,50 DVM	88,60 DVM	89,20 k-EYK k=3	89,20 DVM

3.8. Ekspirasyon Seslerinin Yaygın Akciğer Sesleri İçin Sınıflandırma Bulguları

Ekspirasyon seslerinin eğitim kümelerinden elde edilen yaygın akciğer ses sınıflandırma sonuçlarının ortalamaları Tablo-14'de gösterilmektedir. TBA uygulanmadığı durumdan önceki ilk sınıflandırma sonuçları değerlendirildiğinde f19 özniteliğinin %78,80'lik yüksek bir ortalama değer ile diğer öznitelik gruplarına göre en yüksek sınıflandırma sonucunu verdiği ve öne çıktığı görülmektedir. AİYÖS yöntemine göre ikinci adımda ikili öznitelik kombinasyonlarının başarımları incelendiğinde f19 ve f3'den oluşan ikili öznitelik kombinasyonunun 1.adıma göre %3,4'lük bir artışla %82,20'luk bir ortalama değere ulaştığı görülmektedir. Gözlemlenen bu artış nedeniyle AİYÖS yöntemine göre üçlü özniteliklerinin kombinasyon başarımları da incelenmiştir. Tablo-14 değerlendirildiğinde üçlü öznitelik kombinasyonlarındaki en yüksek skor %80,50 ile f19+f3+f8'in kombinasyonundan oluşmuştur. Fakat bu başarımların ikili öznitelik kombinasyonlarına göre %1,7'lik bir düşüş gösterdiğinden AİYÖS yöntemi gereği sınıflandırma sonlandırılmıştır. Böylece ekspirasyon seslerinin yaygın akciğer seslerine göre en iyi sınıflandırma sonucu %82,20 olarak elde edilmiştir.

AİYÖS yöntemi TBA birlikte uygulandığında f19 özniteliği 1.adımda %72,10 ortalama değeri ile en başarılı sonucu vermiştir. Daha sonra f19 özniteliği sabit tutularak ikili öznitelik kombinasyonların başarımları incelenmiştir. Tablo-14 incelendiğinde f19+f4 özniteliklerinden oluşan ikili kombinasyonun 1.adıma göre %2,60'lık bir artışla %74,70 ortalama değerine ulaştığı görülmektedir. Başarımların artışı nedeniyle daha sonra üçlü kombinasyonların sonuçları irdelenmiştir. Üçlü kombinasyonlarda en iyi sonucu f19+f4+f8 öznitelik kombinasyonu % 81,50'lik bir ortalama değere taşımıştır. Bu durumda AİYÖS yöntemi sayesinde 1.adıma göre %9,4'lük bir artış elde edilmiştir. Başarımların artışı devam ettiğinden dördümlü öznitelik kombinasyonlarının başarımları da araştırılmıştır. Fakat dördümlü öznitelik kombinasyonlarından elde edilen başarımlarda düşüş gözlemlendiğinden AİYÖS yöntemine göre beşli kombinasyonların sınıflandırma sonuçları hesaplanmadan sınıflandırma aşaması son bulmuştur.

Tablo 14. Ekspirasyon seslerinden elde edilen yaygın akciğer ses sınıflandırma bulguları (%)

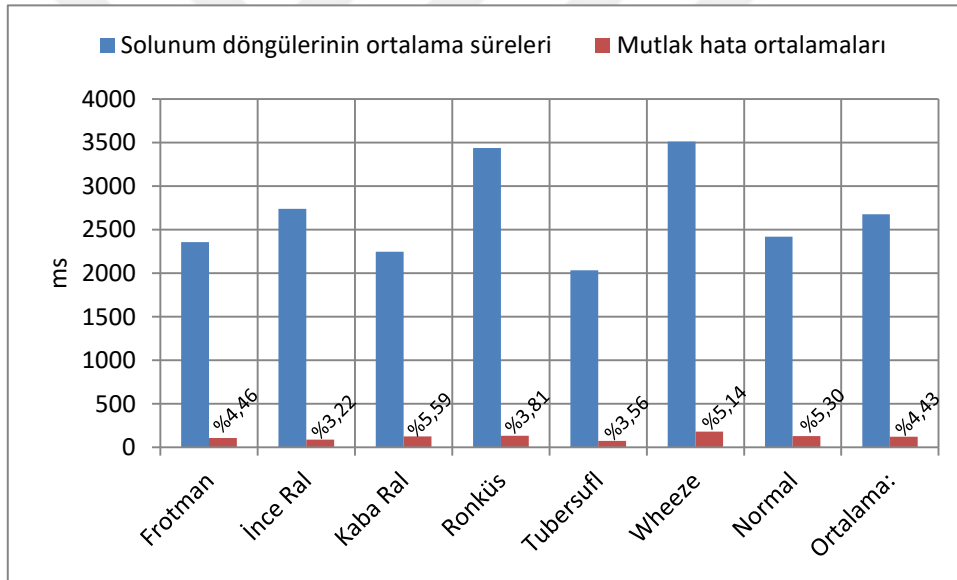
	AİYÖS Yöntemi Sonuçları			TBA+ AİYÖS Yöntemi Sonuçları			
	1.Adım	2.Adım	3.Adım	1.Adım	2.Adım	3.Adım	4.Adım
<i>f1</i>	50,20 k-EYK k=5	75,10 k-EYK k=1	74,40 k-EYK k=1	53,20 DVM	66,30 k-EYK k=1	68,70 k-EYK k=1	71,00 k-EYK k=1
<i>f2</i>	54,20 k-EYK k=11	78,80 k-EYK k=1	79,50 k-EYK k=3	49,50 DVM	67,00 DVM	67,30 k-EYK k=1	68,00 k-EYK k=1
<i>f3</i>	65,70 k-EYK k=5	82,20 k-EYK k=1	<i>f3</i> sabit	62,30 k-EYK k=5	70,40 k-EYK k=1	73,10 k-EYK k=1	66,70 k-EYK k=1
<i>f4</i>	54,20 k-EYK k=3	78,50 k-EYK k=1	78,80 k-EYK k=1	56,20 k-EYK k=5	74,70 k-EYK k=1	<i>f4</i> sabit	<i>f4</i> sabit
<i>f5</i>	52,90 k-EYK k=5	78,80 k-EYK k=1	78,80 k-EYK k=1	51,20 DAA	71,70 k-EYK k=1	72,10 k-EYK k=1	71,70 k-EYK k=1
<i>f6</i>	49,80 DVM	76,10 k-EYK k=1	78,10 k-EYK k=1	50,20 DVM	66,00 k-EYK k=1	70,40 k-EYK k=1	69,40 k-EYK k=1
<i>f7</i>	45,80 k-EYK k=13	74,10 k-EYK k=1	76,80 k-EYK k=1	43,80 DVM	65,00 DVM	66,30 k-EYK k=1	70,00 k-EYK k=1
<i>f8</i>	60,60 k-EYK k=7	80,50 k-EYK k=1	80,50 k-EYK k=1	58,60 k-EYK k=5	70,00 k-EYK k=1	81,50 k-EYK k=1	<i>f8</i> sabit
<i>f9</i>	52,20 k-EYK k=9	76,10 k-EYK k=1	78,80 k-EYK k=1	51,90 DVM	66,00 DVM	71,40 k-EYK k=1	72,70 k-EYK k=1
<i>f10</i>	49,50 DVM	76,40 k-EYK k=1	78,80 k-EYK k=1	47,10 DAA	68,00 k-EYK k=1	68,40 k-EYK k=1	69,70 k-EYK k=1
<i>f11</i>	61,30 DVM	77,40 k-EYK k=1	79,10 k-EYK k=1	64,00 k-EYK k=5	70,40 k-EYK k=1	71,70 k-EYK k=1	70,40 k-EYK k=1
<i>f12</i>	59,60 DVM	74,40 k-EYK k=3	78,10 k-EYK k=1	57,90 k-EYK k=21	68,70 k-EYK k=1	72,70 k-EYK k=1	69,70 k-EYK k=1
<i>f13</i>	57,90 DVM	74,40 k-EYK k=3	76,80 k-EYK k=1	54,50 k-EYK k=9	66,70 k-EYK k=1	69,70 k-EYK k=1	68,00 k-EYK k=1
<i>f14</i>	42,10 k-EYK k=9	70,70 k-EYK k=9	73,10 k-EYK k=1	51,20 DAA	69,00 k-EYK k=3	69,40 k-EYK k=1	74,70 k-EYK k=1
<i>f15</i>	46,10 k-EYK k=7	71,40 k-EYK k=1	73,40 k-EYK k=1	46,50 DVM	67,70 k-EYK k=3	69,00 k-EYK k=1	70,40 k-EYK k=1
<i>f16</i>	60,30 k-EYK k=13	75,10 k-EYK k=1	77,80 k-EYK k=1	60,60 DAA	64,30 DAA	71,00 k-EYK k=1	71,40 k-EYK k=1

Tablo 14'ün devamı

	AİYÖS Yöntemi Sonuçları			TBA+ AİYÖS Yöntemi Sonuçları			
	1.Adım	2.Adım	3.Adım	1.Adım	2.Adım	3.Adım	4.Adım
<i>f17</i>	63,00 k-EYK k=13	73,40 k-EYK k=5	74,40 k-EYK k=5	56,20 k-EYK k=9	62,30 DAA	65,00 DAA	67,00 k-EYK k=1
<i>f18</i>	61,60 k-EYK k=5	71,70 k-EYK k=1	72,40 k-EYK k=3	58,60 DVM	63,30 DVM	64,30 DVM	64,30 k-EYK k=1
<i>f19</i>	78,80 k-EYK k=1	<i>f19 sabit</i>	<i>f19 sabit</i>	72,10 k-EYK k=1	<i>f19 sabit</i>	<i>f19 sabit</i>	<i>f19 sabit</i>
<i>f20</i>	56,90 DVM	75,40 k-EYK k=1	77,10 k-EYK k=1	56,90 k-EYK k=3	67,30 k-EYK k=1	70,40 k-EYK k=1	66,70 k-EYK k=1
<i>f21</i>	57,90 DVM	76,10 k-EYK k=1	77,40 k-EYK k=1	55,90 DVM	66,70 k-EYK k=1	67,70 k-EYK k=1	65,70 k-EYK k=1
<i>f22</i>	49,80 k-EYK k=3	68,70 k-EYK k=1	71,40 k-EYK k=1	51,90 DAA	63,30 DVM	63,30 DVM	65,00 DVM
<i>f23</i>	35,40 DVM	64,00 k-EYK k=11	66,30 k-EYK k=1	46,50 DVM	61,60 DVM	63,30 k-EYK k=1	64,30 k-EYK k=1
<i>f24</i>	74,70 k-EYK k=1	77,80 k-EYK k=1	80,10 k-EYK k=1	64,00 DVM	64,30 DVM	64,00 DAA	64,00 k-EYK k=1
<i>f25</i>	49,80 DVM	70,10 k-EYK k=1	73,40 k-EYK k=1	43,40 DAA	64,00 DVM	63,00 DAA	66,70 k-EYK k=1
<i>f26</i>	49,20 DVM	72,70 k-EYK k=3	75,10 k-EYK k=1	48,80 DAA	61,30 DAA	64,00 k-EYK k=1	67,00 k-EYK k=1
<i>f27</i>	64,60 k-EYK k=9	79,80 k-EYK k=1	80,50 k-EYK k=1	61,60 k-EYK k=1	65,70 k-EYK k=5	68,70 k-EYK k=1	68,40 k-EYK k=1
<i>f28</i>	49,50 k-EYK k=7	73,40 k-EYK k=1	76,80 k-EYK k=1	53,90 DVM	62,60 k-EYK k=1	63,60 DVM	65,70 k-EYK k=1
<i>f29</i>	52,20 DVM	76,10 k-EYK k=1	79,10 k-EYK k=1	48,50 DVM	64,00 k-EYK k=1	66,00 k-EYK k=1	64,60 k-EYK k=1
<i>f30</i>	47,50 DVM	68,40 k-EYK k=1	70,40 k-EYK k=1	46,50 DVM	61,30 k-EYK k=1	66,00 k-EYK k=1	66,00 k-EYK k=1
<i>f31</i>	46,10 k-EYK k=1	70,40 k-EYK k=1	75,10 k-EYK k=1	40,10 k-EYK k=9	60,60 DVM	63,00 k-EYK k=1	63,60 k-EYK k=1
<i>f32</i>	61,30 k-EYK k=11	76,40 k-EYK k=1	80,50 k-EYK k=1	57,60 DVM	63,30 k-EYK k=1	68,70 k-EYK k=1	67,00 k-EYK k=1

4. SONUÇLAR

Akciğer seslerinin otomatik olarak sınıflandırılabilmesi için öncelikle solunum döngülerinin akciğer seslerinden otomatik olarak algılanması gereklidir. Böylece akciğer sesleri birer solunum döngüsüne indirgenerek sınıflandırma aşamasında eşit koşullarda karşılaştırılmış olur. Bu çalışmada, tek kanallı akciğer seslerinden otomatik solunum döngüsü algılamak için geliştirilen yöntemin genel bir değerlendirmesi için hazırlanan grafik şekil-22’de sunulmuştur. Grafikte solunum döngülerinin ortalama süreleri ile mutlak hata sürelerinin ortalamaları karşılaştırılmıştır. Ayrıca mutlak hata sürelerinin, solunum döngülerinin ortalama sürelerine göre yüzdelik oranları da şekil-22 üzerinde belirtilmiştir.



Şekil 22. Otomatik solunum döngüsü algılama yöntemi sonuçlarının istatistiksel özeti

Sonuçlar değerlendirildiğinde solunum döngülerine ait süre ortalamalarının yaklaşık 2000ms ile 3500ms arasında değiştiği gözlemlenmektedir. Ortalama solunum döngü süresi ise 2500ms'nin üzerindedir. Mutlak hata ortalama süreleri, solunum döngü sürelerine göre yaklaşık %3,2 ile % 5,5 arasında değişmektedir. Ortalama mutlak hata süresi ise %4,43 olarak ölçülmüştür. Mutlak hata süre yüzdelilerinin düşük olması, otomatik olarak belirlenmiş solunum döngülerinin konusunda uzman iki doktor tarafından dinlenerek onaylanmış olması ve sonuçların geniş bir akciğer ses yelpazesinde test edilmiş olması gibi

önemli sonuçlar, bu tez çalışmasında geliştirilen otomatik solunum algılama yönteminin başarısının doğrulanması ve onaylanması açısından oldukça önemli faktörlerdir.

Sağlıklı/patolojik akciğer ses sınıflandırma işlemleri; tam solunum seslerinden oluşan veri seti-2, inspirasyon seslerinden oluşan veri seti-4 ve ekspirasyon seslerinden oluşan veri seti-6'dan elde edilmiştir. Sağlıklı/patolojik akciğer ses sınıflandırma sonuçları tüm sonuçlar için derlenerek başarımların sıralarına göre Tablo-15'de sunulmuştur.

Tablo 15. Sağlıklı/Patolojik akciğer seslerinin sınıflandırma sonuçları

Sıralama	Kullanılan Veri	Öznitelikler	Başarım (%)
1	Ekspirasyon	$f_{19}+f_{21}+f_{24}+f_{1+12}$	97,60 (k-EYK k=1)
2	Tam solunum döngüsü	$f_{19}+f_{20}+f_{32}$	97,34
3	İnspirasyon	$f_{19}+f_{29}$	95,30 (k-EYK k=3)
4	İnspirasyon	$f_{19}+f_3+f_8$ (TBA)	93,30 (DVM)
5	Ekspirasyon	$f_{19}+f_{20}+f_8$ (TBA)	93,90 (k-EYK k=3)
6	Tam solunum döngüsü	$f_{19}+f_3$ (TBA)	95,60 (k-EYK k=1)
7	Tam solunum döngüsü	Tüm özniteliklerin birleştirilmesi $(f_1+f_2+\dots+f_{32})$	92,60 (k-EYK k=3)
8	İnspirasyon	Tüm özniteliklerin birleştirilmesi $(f_1+f_2+\dots+f_{32})$	91,90 (DVM)
9	Tam solunum döngüsü	Tüm özniteliklerin birleştirilmesi $(f_1+f_2+\dots+f_{32})$ (TBA)	90,90 (DAA)
10	Ekspirasyon	Tüm özniteliklerin birleştirilmesi $(f_1+f_2+\dots+f_{32})$	88,20 (k-EYK k=5)
11	İnspirasyon	Tüm özniteliklerin birleştirilmesi $(f_1+f_2+\dots+f_{32})$ (TBA)	87,50 (k-EYK k=11)
12	Ekspirasyon	Tüm özniteliklerin birleştirilmesi $(f_1+f_2+\dots+f_{32})$ (TBA)	86,20 (k-EYK k=7)

Tablo-15'deki sonuçlar incelendiğinde, başarımların oldukça yüksek olarak elde edilmiş olduğu görülmektedir. Ekspirasyon seslerinin ortalama %97,60'lık bir başarıma ulaşması geliştirilen yöntemin başarısını açıkça ortaya koymaktadır. Bunun dışında genel olarak AIYÖS yöntemi ile başarımların artırıldığı görülürken, TBA yönteminin başarıyı artıramadığı ve düşürdüğü yönündedir. TBA yöntemindeki başarımların azalışının nedeni, veri kümesi büyük olsa da öznel vektör boyutlarının küçük olması nedeni olabilir. Çünkü 32 farklı öznel vektör uzunlukları 5, 6, 12 ve 18 örnek arasında değişmektedir. Bu uzunlukların çoklu kombinasyonlarda TBA'nın başarısı için yeterli olmayabileceği düşüncesiyle, tüm öznel vektörler birleştirilerek başarımların incelenmiştir. Fakat genel olarak değerlendirildiğinde TBA yönteminin bu tez çalışmasında kullanılan akciğer ses verilerinde başarılı olamadığı değerlendirilmiştir.

Ekspirasyon seslerinin ardından tam solunum döngülerinden elde edilen başarımların da oldukça önemli bir sonuçtur. Çünkü, tam solunum seslerinin veri kümeleri tamamen otomatik olarak oluşturulmuş ve sınıflandırma süreci de aynı şekilde sonlandırılmıştır. Bu sonuçlar, akciğer seslerinin otomatik sınıflandırılması için bu tez kapsamında geliştirilen yöntemin gerçek zamanlı olarak uygulanmasının mümkün olabileceğini işaret etmektedir.

Sağlıklı/patolojik akciğer ses ayrımı için yapılan tüm değerlendirmeler sonucunda $f19+f21+f24+f1+f12$ 'den oluşan beşli kombinasyonun rasgele oluşturulan eğitim kümelerinden elde edilen $97,60 \pm 0,87$ başarımla en yüksek değere ulaştığı anlaşılmıştır. Bu en iyi üçlü kombinasyonun test kümelerindeki başarısı ise $97,68 \pm 0,75$ olmuştur. Dolayısıyla, tek kanallı akciğer seslerinden solunum döngülerinin otomatik olarak algılanması ve sınıflandırılması için geliştirilen yöntemin sağlıklı/patolojik seslerin sınıflandırılmasındaki başarımlarını $97,68 \pm 0,75$ gibi yüksek bir değere ulaştırmıştır.

Yaygın akciğer sesleri için oluşturulan ve tam solunum seslerinden oluşturulan veri seti-3, inspirasyon seslerinden oluşturulan veri seti-5 ve ekspirasyon seslerinden oluşturulan veri seti-7 kullanılarak elde edilen sonuçlar derlenmiş ve başarımlarına göre Tablo-16'da sunulmuştur. Tablo-15'de olduğu gibi yaygın akciğer sesleri için de tüm öznel vektörler birleştirilerek TBA için ayrı bir veri elde edilmiştir.

Tablo-16 incelendiğinde sağlıklı/patolojik ses sınıflandırma sonuçlarındaki ekspirasyon seslerinin yerine yaygın akciğer ses sınıflandırmasında tam solunum döngülerinin $87,30$ ile en iyi sonucu elde ettiği görülmektedir. AIYÖS yönteminin başarımlarını artırdığı görülürken, yaygın akciğer seslerinden elde edilen öznel vektörlerde de TBA yönteminin başarımlarını artıramadığı görülmektedir.

Tablo 16. Yaygın akciğer seslerinin sınıflandırma sonuçları

Sıralama	Kullanılan Veri	Öznitelikler	Başarım (%)
1	Tam solunum döngüsü	$f_{19}+f_{24}+f_{20}+f_{16}$	87,30 (k-EYK k=19)
2	İnspirasyon	Tüm özniteliklerin birleştirilmesi ($f_1+f_2+\dots+f_{32}$)	86,80 (k-EYK k=5)
3	Tam solunum döngüsü	$f_{19}+f_8$ (TBA)	84,20 (k-EYK k=1)
4	İnspirasyon	$f_{19}+f_3$	83,20 (k-EYK k=1)
5	Ekspirasyon	$f_{19}+f_3$	82,20 (k-EYK k=1)
6	Ekspirasyon	$f_{19}+f_4+f_8$ (TBA)	81,50 (k-EYK k=1)
7	Tam solunum döngüsü	Tüm özniteliklerin birleştirilmesi ($f_1+f_2+\dots+f_{32}$)	76,10 (k-EYK k=1)
8	İnspirasyon	$f_{19}+f_1$ (TBA)	73,40 (k-EYK k=1)
9	Tam solunum döngüsü	Tüm özniteliklerin birleştirilmesi $f_1+f_2+\dots+f_{32}$ (TBA)	65,10 (DAA)
10	Ekspirasyon	Tüm özniteliklerin birleştirilmesi $f_1+f_2+\dots+f_{32}$ (TBA)	64,20 (DAA)
11	Ekspirasyon	Tüm özniteliklerin birleştirilmesi ($f_1+f_2+\dots+f_{32}$)	63,20 (DVM)
12	İnspirasyon	Tüm özniteliklerin birleştirilmesi $f_1+f_2+\dots+f_{32}$ (TBA)	62,30 (k-EYK k=1)

Yaygın akciğer seslerinin sınıflandırılması için yapılan tüm değerlendirmeler sonucunda tam solunum döngülerinden elde edilen ve f_{19} , f_{24} , f_{20} ve f_{16} 'dan oluşan dördümlü öznitelik kombinasyonunda bu tez çalışmasında yaygın akciğer seslerinin en yüksek sınıflandırma sonucu olan $\%87,30 \pm 1,69$ 'a ulaştığı görülmektedir. Bu en iyi dördümlü kombinasyonun test kümelerindeki başarısı ise $\%87,61 \pm \%1,67$ olarak elde edilmiştir. Yaygın akciğer seslerinden, yani dört sınıflı bir problemde elde edilen bu sonucun, yeterli tecrübeye sahip olmayan doktorlara fikir verebilecek başarımda olduğu düşünülmektedir. Bu başarımın, ileride yapılacak farklı çalışmalarla daha da artırılması gerçek zamanlı bir

uygulamanın ortaya konulabilmesi açısından oldukça önemlidir. Çünkü yaygın akciğer seslerindeki en iyi sonuç, tamamen otomatik bir sınıflandırma sürecine tabi olan tam solunum döngülerinden elde edilmiştir.

Bu tez çalışmasında, tek kanallı akciğer sesleri için solunum döngülerini otomatik olarak algılayan bir yöntem literatürde ilk kez geliştirilmiştir. Ayrıca, tek kanallı akciğer seslerinden otomatik olarak algılanan solunum döngüleri ile oluşturulan veri setleri üzerinden bir sınıflandırma çalışması da yine literatüre ilk kez gerçekleştirilmiştir.

Sonuçların özeti olarak, bu tez kapsamında 1000'in üzerindeki sayıda tek kanallı akciğer seslerinden solunum döngüleri otomatik olarak algılanmış ve başarılı bir şekilde sınıflandırılmıştır. Geliştirilen yöntemin elde ettiği sınıflandırma sonuçları kısaca tablo-17'de özetlenmiştir.

Tablo 17. Akciğer seslerinden nefes döngülerinin otomatik olarak algılanması ve sınıflandırılması yönteminin kısa sonuç özeti

Sağlıklı/Patolojik Akciğer Sesleri (Ekspirasyon veri seti-6 için)		Yaygın Akciğer Sesleri (Tam solunum döngüsü veri seti-3 için)	
<p><u>Kullanılan öznelik kombinasyonu;</u> <i>f19</i> (MFKK'nın aritmetik ortalaması)+ <i>f21</i> (MFKK'nın varyansı)+ <i>f24</i> (MFKK'nın ortanca değeri)+ <i>f1</i>(ZBP'nin minimum değeri)+ <i>f12</i> (FBP'nin standart sapması)</p>		<p><u>Kullanılan öznelik kombinasyonu;</u> <i>f19</i> (MFKK'nın aritmetik ortalaması) + <i>f24</i> (MFKK'nın ortanca değeri) + <i>f20</i> (MFKK'nın standart sapması) + <i>f16</i> (FBP'nin ortanca değeri)</p>	
Eğitim	Test	Eğitim	Test
%97,60±0,87	%97,68±0,75	%87,30 ± %1,69	%87,61 ± %1,67

5. ÖNERİLER VE TARTIŞMA

Geliştirilen yöntemin sonuçları, özellikle gerçek zamanlı sağlıklı/patolojik akciğer ses sınıflandırma çalışmalarının gerçek zamanlı uygulamalarının gerçekleştirilebilmesi için oldukça teşvik edicidir. Yaygın akciğer sesleri üzerinden elde edilen sınıflandırma sonuçları her ne kadar literatürde yapılmış otomatik olmayan diğer çalışmalara göre başarılı olsa da, gerçek zamanlı uygulamalar için bu konuda daha ayrıntılı ve kapsamlı çalışmalar yapılması ve başarımların daha da artırılması uygun olacaktır.

Bu tez çalışmasında, tek kanallı akciğer seslerinden solunum döngülerinin belirlenmesi için gereken manuel yardım ihtiyacını ortadan kaldıracak şekilde solunum döngülerinin sınırlarını otomatik olarak belirleyen bir yöntem geliştirilerek literatüre açıkça önemli bir katkıda bulunulmuştur. Ayrıca, otomatik olarak algılanan solunum döngüleri sayesinde veri setlerinin de otomatik olarak oluşturma imkanının sunulması, bu tez çalışmasını öne çıkaran ayrı bir unsurdur.

Çalışmanın bir diğer önemli katkısı da, tek kanallı akciğer sesleri için gerçek zamanlı otomatik bir sınıflandırmaya imkân tanınmasıdır. Makine öğrenme temelli bir sınıflandırma yöntemini gerçek zamanlı olarak gerçekleyebilmek için öncelikle sistemin önceki kayıtlar ile eğitilmesi gerekir. Bu çalışmada geliştirdiğimiz yöntem, hem kayıtlardan solunum döngülerini ayırıp sistemi eğitebilecek hem de gerçek zamanlı olarak alınan bir akciğer sesinden solunum döngüsünü algılayarak sınıflandırmaya dâhil edebilecek yetenektedir.

Geliştirilen yöntemin tek kanallı olması, daha önce literatürde sıkça kullanılan çok kanallı kayıt yöntemlere göre daha pratik bir kullanım sunar. Bir diğer önemli husus da kullanılan kayıt yönteminin oskültasyon prosedürüne uygun olmasıdır. Çünkü çok kanallı kayıtların kullanılması sırasında şişman veya kıllı cilt yapısına sahip bireylerde mikrofonların tutturulmasında sıkıntılar yaşanabilmektedir. Ancak bu durum, özünde basit bir işlem olan oskültasyon prosedürünün dışına çıkılmasına neden olmaktadır.

Akciğer seslerinin tanınması üzerine yapılan çalışmalardaki en büyük eksiklik, çalışmaların belirli bir standart altında yapılmadığından karşılaştırılamamasıdır. Gurung ve arkadaşları [87] 2011'de yaptıkları çalışmada, önceki çalışmalardaki standardizasyon eksikliklerine vurgu yaparak, literatürdeki çalışmaların bu nedenle karşılaştırılamadığını, bu yüzden akciğer seslerini gerçek zamanlı olarak tanıyan ticari bir ürünün geliştirilemediğini açıkça ortaya koymuştur. 2017'de Pramono ve arkadaşlarının [88]

yaptığı benzer bir tarama çalışmasında da, geçen zaman içinde de bu durumun değişmediği, akciğer sesleri üzerine standartlaştırılmış bir yaklaşımın ve karşılaştırma imkânının henüz tam olarak kurulamadığı bildirilmiştir.

Günümüze kadar yapılan çalışmalar farklı standartlara sahip olsa da, gerçekleştirilen bu tez çalışmasının literatürdeki yerini özetlemek amacıyla bugüne kadar yapılan ve öne çıkan çalışmaların birçok kategori açısından özeti Tablo-13’de sunulmuştur. Bu tez çalışmasını diğerlerinden ayıran en önemli özellik, veri setindeki solunum döngülerinin otomatik olarak algılanması ve bazı veri setlerinin de otomatik olarak oluşturulmuş olmasıdır. Ayrıca, oluşturulan veri setlerinin diğer çalışmalara göre oldukça geniş kapsamlı olduğu da görülmektedir. Dolayısıyla, 1002 solunum döngüsü verisinden sağlıklı/patolojik sınıflandırma için elde edilen $97,68 \pm 0,75$ ’lik sınıflandırma doğruluğu diğer sonuçlara göre oldukça belirgindir. Bunun dışında dört sınıftan oluşan yaygın akciğer sesleri ile oluşturulan veri seti üzerinden elde edilen $87,61 \pm 1,67$ ’lik başarımlar da oldukça değerlidir. Çünkü solunum döngülerinin otomatik algılanmasıyla oluşturulan veri setleri üzerinden elde edilen bu sonuçlar, bu tez çalışmasında geliştirilen yöntemin gerçek zamanlı akciğer ses tanıma çalışmalarının alt yapısını oluşturabileceğini göstermektedir.

Gerçekleştirilen bu doktora tezinin genel bir değerlendirmesini yapacak olursak, başlangıçta belirlenen amaçlara ulaşıldığı ve solunum döngülerinin otomatik olarak algılanması sayesinde hedeflerin üzerine çıkıldığı belirtilebilir. Bundan sonra benzer bir konuda çalışacak akademisyenlere tavsiye olarak; kayıt aşamasının çalışmanın temelini oluşturduğu, alınacak kayıt sayısının birlikte çalışılacak hekim sayısına ve onlara başvuracak kişilerin patolojik bulgularına bağlı olacağı unutulmamalıdır. Eğer gerçek zamanlı bir akciğer ses sınıflandırma çalışması yapılacak istenirse, en önemli unsurlardan biri de kayıt cihazı olacaktır. Kayıt cihazı akciğer seslerine uygun bir frekans aralığında kayıt yapmalıdır. Eğitim kümeleri cihazdan alınacak kayıtlarla oluşturulacağından, gerçek zamanlı uygulamada kullanılması planlanan cihazlarla kayıtların alınması gerekecektir. Çünkü, aynı cihazla alınan kayıtlarda bile gerçek zamanlı çalışmalarda farklı türde gürültüler akciğer seslerine karışabilmektedir. Fakat bu gürültülerin cihaz farklılığından kaynaklanması elde edilmiş olan eğitim kümesinin işlevini yitirmesine neden olabilir. Ayrıca, yaygın akciğer sesleri dışındaki akciğer sesleri üzerine de çalışılmak istenildiğinde birlikte çalışılacak doktor sayısının artırılması daha az bulunan veriye ulaşma ihtimalini artıracaktır. Bu durum özellikle süreli çalışmalarda önem arz edebilir.

Tablo 18. Önerilen yöntem ile literatürdeki çalışmaların (özet) karşılaştırılması

Akciğer Ses Sınıfları	Kayıt Türü	Kayıt Yöntemi	Veri seti oluşumu	Veri türü	Kullanılan Öznitelik	Sınıflandırma Yöntemi	Performans	Ref.
S/P ve Yaygın akciğer esleri 133 kişi, 1002 Solunum döngüsü	Elektronik stetoskop	Tek kanallı	Otomatik	Solunum döngüsü	ZBP, FBP, MFKK, DÖK ve istatistiksel öznitelikler	DAA, NB, k-EYK, DVM	Sağ./Pat %97,04 ± %0,97, Yaygın akc. %87,61 ± %1,67	Ben
Normal / sürekli ek sesler 30 kişi	Pnömo-takograf, Piezo-elektrik mik.	Çok kanallı	Manuel	Bir nefes alış	Grup Ampirik Mod Ayr. ve Anlık Frekans	DVM	Duyarlılık %94,2, Özgüllük %96,1	[89]
Sağlıklı/patolojik 40 kişi (20 sağlıklı, 20 patolojik)	14 hava kuplajlı elektret mikrofon pnömo-takograf	Çok kanallı	Manuel	Bir segment	Autoregressive model	DVM, GMM	%90 doğruluk	[90]
S/P 26 kişi (13 sağlıklı, 13 patolojik)	hava kup.elektret mikrofonlar ve akış ölçer (flowmeter)	Çok kanallı	Manuel	Bir segment	FBP (Spektrogram), ZBP (Dalgacık dönüşümü)	DVM, k-NN	% 97,5 doğruluk	[66]
Normal/Anormal 126 kişi (63 normal/63 anormal)	Piezo-elektrik mikrofon	Tek kanallı	Manuel	Solunum döngüsü	Spektral olasılık	SMM	Genel doğruluk oranı %90	[54]
585 segment (normal, polf. ve mon. wheeze, stridor)	Elektret kapasitif mikrofon	Tek kanallı	Manuel	Bir segment	Zamansal-spektral baskınlık spektrogramı	k-EYK	Genel doğruluk oranı %92,4 ± 2,9%	[56]
12 Normal/12 wheeze (dört kitap CD'si ve internet)	Belirsiz	Belirsiz	Manuel	Bir segment	Fourier Dönüşümü, DÖK, Dalgacık Dnş, MFKK	Vektör nicemleme, GKM, YSA	Duyarlılık %94,6, Özgüllük %91,9	[91]
S/P (20 sağlıklı, 20 patolojik)	İki adet hava kuplajlı elektret mikrofon	Çok kanallı	Manuel	50-60ms'lik segment	Autoregressive model katsayıları	k-EYK, ANN	Sınıf doğruluğu %92,5, özg: %90, duy: %95	[92]
Normal/Anormal (60 Normal/40 Anormal)	40 piezo-elektrik sensör	Çok kanallı	Manuel	12 sn (3-4 sol. döngüsü)	Fourier Transform, Titreşim Tepki Görüntüleme (VRI)	Görsel sınıflandırma (hekimlere göre)	duyarlılık %82,5 ve özgüllük %80	[93]
Pnömoni/Normal (100 pnömoni, 100 normal)	16 mikrofon	Çok kanallı	Manuel	20 sn'lik ses kaydı	Zaman Genişletilmiş Dalgaformu Analizi, Akustik Güç Analizi	YSA	%87 sınıflandırma, duyarlılık %90, özgüllük %88	[94]
Sağ./pat. (17 kişi)	2 mikrofon	Çok kanallı	Manuel	Bir segment	Ortalama güç spektral yoğunluğu	YSA, İleri beslemeli ağ	%73 sınıf doğruluğu, duy: %87 ve özg: %95.	[70]
Normal, wheeze ve ral (60 kişi)	Elektret mikrofon (Trakea)	Tek kanallı	Manuel	Solunum döngüsü	Fourier güç spektrumu özellikleri	YSA, İleri beslemeli ağ	Sınıflandırma doğruluğu %95	[95]

Bundan sonraki çalışmalarda, çeşitli öznitelik ve sınıflandırma yöntemlerini araştırmaya devam ederek sınıflandırma başarısının daha yükseğe çekilmesi ve bu alt yapıyı kullanarak akciğer seslerini gerçek zamanlı olarak tanıyacak bir çalışmanın yapılması planlanmaktadır. Daha iyi bir performans elde etmek için elbette veri sayısının da artırılması gerekecektir.



6. KAYNAKLAR

1. Mondal, A., Bhattacharya, P. ve Saha, G., Detection of Lungs' Status using Morphological Complexities of Respiratory Sounds. The Scientific World Journal, (2014) 1829–38.
2. Mangione, S. ve Nieman, L. Z., Pulmonary Auscultatory Skills During Training in Internal Medicine and Family Practice, American Journal of Respiratory and Critical Care Medicine, 159,4 (1999) 1119-1124.
3. Kaur, J., Chugh, K., Sachdeva, A. ve Satyanarayana, L., Under Diagnosis of Asthma in School Children and its Related Factors, Indian Pediatrics, 44,6 (2007) 425-428.
4. Mandke, A. ve Mandke, K., Under Diagnosis of COPD in Primary Care Setting in Surat, India, European Respiratory Journal, 46, (2015) PA1809.
5. Lehrer, S. ve Nowey Donald, W., Akciğer sesleri kılavuzu, Çev:Topalcan, A., ve Öztürk, C., Ankara, 2007.
6. <https://cdn.thinglink.me/api/image/854600112649797633/1240/10/scaletowidth> İnsanda Solunum Sistemi, 6 Kasım 2017.
7. Polat, H. ve Darılmaz, M., Elektronik Stetoskopun Akciğer Oskültasyon Yeteneğinin İncelenmesi ve Akciğer Seslerinin Spektral Analizi, Politeknik Dergisi, 6,4 (2003).
8. Bohadana, A., Izbicki, G. ve Kraman, S. S., Fundamentals of Lung Auscultation, New England Journal of Medicine, 370,8 (2014) 744-751.
9. Sarkar, M., Madabhavi, I., Niranjana, N. ve Dogra, M., Auscultation of The Respiratory System, Annals of thoracic medicine, 10,3 (2015) 158.
10. Vannuccini, L., Earis, J. E., Helisto, P., Cheetham, B. M. G., Rossi, M., Sovijarvi, A. R. A. ve Vanderschoot, J., Capturing and Preprocessing of Respiratory Sounds, European Respiratory Review, 10,77 (2000) 616-620.
11. Huq, S. ve Moussavi, Z., Acoustic Breath-Phase Detection using Tracheal Breath Sounds, Medical & biological engineering & computing, 50,3 (2012) 297-308.
12. Tabata, H., Hirayama, M., Enseki, M., Nukaga, M., Hirai, K., Furuya, H. ve Mochizuki, H., A Novel Method for Detecting Airway Narrowing using Breath Sound Spectrum Analysis in Children, Respiratory Investigation, 54,1 (2016) 20-28.

13. Yahya, O. ve Faezipour, M., Automatic Detection and Classification of Acoustic Breathing Cycles, American Society for Engineering Education (ASEE Zone 1), Nisan 2014, Bridgeport, Connecticut, U.S.A., 1-5.
14. Dabiri, S. ve Shirazi, M. A. M., Estimation of Respiratory Rate from Photoplethysmogram Signal of Sleep Apnea Patients: A Comparative Study of Different Methods, Telecommunications and Signal Processing (TSP), Temmuz 2015, Prag, Çek Cumhuriyeti , 440-443.
15. Anusha, A. R., Soodi, A. L. ve Kumar, S. P. Design of Low-Cost Hardware for Lung Sound Acquisition and Determination of Inspiratory-Expiratory Phase using Respiratory Waveform, Computing Communication & Networking Technologies (ICCCNT), Temmuz 2012, Coimbatore, Tamilnadu, India, 1-5.
16. Moussavi, Z. K., Leopando, M. T., Pasterkamp, H. ve Rempel, G., Computerised Acoustical Respiratory Phase Detection Without Airflow Measurement, Medical and Biological Engineering and Computing, 38,2 (2000) 198-203.
17. Reyes, B. A., Reljin, N., Kong, Y., Nam, Y., Ha, S. ve Chon, K. H., Towards The Development of A Mobile Phonopneumogram: Automatic Breath-Phase Classification using Smartphones, Annals of Biomedical Engineering, 44,9 (2016) 2746-2759.
18. Palaniappan, R., Sundaraj, K., Sundaraj, S., Hularaj, N. ve Revadi, S. S., A Novel Approach to Detect Respiratory Phases from Pulmonary Acoustic Signals using Normalised Power Spectral Density and Fuzzy Inference System, The clinical respiratory journal, 10,4 (2016). 486-494.
19. Alsmadi, S. ve Kahya, Y. P., Design of A DSP-Based Instrument for Real-Time Classification of Pulmonary Sounds, Computers in Biology and Medicine, 38(1) (2008) 53-61.
20. Mondal, A., Bhattacharya, P. ve Saha, G., Detection of Lungs Status using Morphological Complexities of Respiratory Sounds, The Scientific World Journal, 38, (2014) 1829
21. Le Cam, S., Collet, C. ve Salzenstein, F., Acoustical Respiratory Signal Analysis and Phase Detection, International Conference on Acoustics, Speech and Signal Processing (ICASSP), Mart 2008, Las Vegas, NV, U.S.A., 3629-3632.
22. İpek Şen, Multivariate Modeling And Diagnostic Classification Of Pulmonary Sounds, Doktora Tezi, Boğaziçi Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2013.
23. Charleston-Villalobos, S., Martinez-Hernandez, G., Gonzalez-Camarena, R., Chillem, G., Carrillo, J. G. ve Aljama-Corrales, T. Assessment of Multichannel Lung Sounds Parameterization for Two-Class Classification in Interstitial Lung Disease Patients, Computers in Biology and Medicine, 41,7 (2011) 473-482.

24. <http://projekter.aau.dk/projekter/files/16322765/article.pdf> System for Locating A 3-D Position of A Generated Sound In The Human Bowel, Using Time-Delay of Arrival, 6 Kasım 2017.
25. Bergstresser, T., Ofengeim, D., Vyshedskiy, A., Shane, J. ve Murphy, R., Sound Transmission in The Lung as a Function of Lung Volume, Journal of Applied Physiology, 93,2 (2002) 667-674.
26. Mehta, A. C., Gat, M., Mann, S. ve Madison, J. M., Accuracy of Gray-Scale Coding in Lung Sound Mapping, Computerized Medical Imaging and Graphics, 34,5 (2010) 362-369.
27. Fleming, S., Plüddemann, A., Wolstenholme, J., P. Price, C., Heneghan, C. ve Thompson, M., Diagnostic Technology: Automated Lung Sound Analysis for Asthma, Horizon Scan Report 0016, the Primary Care Diagnostic Horizon Scanning Centre Oxford, 11 Temmuz 2011.
28. Tasaka, S., Saraya, T., Kuraishi, H., Sim-bara, H., Oda, K. ve Takizawa, H., Consistency of Interpretation of Lung Sounds between Experienced Physicians and Automatic Analysis Using a Newly Developed Algorithm Based on the Acoustic Characteristics, Pulmonary Research and Respiratory Medicine (2016) 9-11.
29. Khan, S. I., Jawarkar, N. P. ve Ahmed, V., Cell Phone Based Remote Early Detection of Respiratory Disorders for Rural Children Using Modified Stethoscope, Communication Systems and Network Technologies (CSNT), Mayıs 2012, Rajkot, Gujarat, India, 936-940.
30. Ward, J. J. ve Wattier, B. A. Technology for enhancing chest auscultation in clinical simulation, Respiratory Care, 56,6 (2011) 834-845.
31. Nowak, K. M. ve Nowak, L. J. Experimental Validation of the Tuneable Diaphragm Effect in Modern Acoustic Stethoscopes, Postgraduate Medical Journal, (2017)
32. Bokov, P., Mahut, B., Flaud, P., ve Delclaux, C. Wheezing Recognition Algorithm Using Recordings of Respiratory Sounds at the Mouth in A Pediatric Population, Computers in Biology and Medicine, 70, (2016) 40-50.
33. Chamberlain, D., Kodgule, R., Ganelin, D., Miglani, V. ve Fletcher, R. R., Application of Semi-Supervised Deep Learning to Lung Sound Analysis, Engineering in Medicine and Biology Society (EMBC), Ağustos 2016, Florida, U.S.A., 804-807.
34. Li, J. ve Hong, Y., Wheeze Detection Algorithm Based on Spectrogram Analysis, Computational Intelligence and Design (ISCID), Aralık 2015, Hangzhou, China, 1,318-322.
35. Lin, B. S. ve Lin, B. S., Automatic Wheezing Detection Using Speech Recognition Technique. Journal of Medical and Biological Engineering, 36,4 (2016) 545-554.

36. Mendes, L., Vogiatzis, I. M., Perantoni, E., Kaimakamis, E., Chouvarda, I., Maglaveras, N., ... ve Paiva, R. P., Detection of Crackle Events Using A Multi-Feature Approach, Engineering in Medicine and Biology Society (EMBC), Ağustos 2016, Florida, U.S.A., 3679-3683.
37. Chamberlain, D., Mofor, J., Fletcher, R. ve Kodgule, R. Mobile Stethoscope and Signal Processing Algorithms for Pulmonary Screening and Diagnostics, Global Humanitarian Technology Conference (GHTC), Ekim 2015, Seattle, U.S.A., 385-392.
38. Lin, B. S., Wu, H. D. ve Chen, S. J., Automatic Wheezing Detection Based on Signal Processing of Spectrogram and Back-Propagation Neural Network, Journal of Healthcare Engineering, 6,4 (2015) 649-672.
39. Matsutake, S., Yamashita, M. ve Matsunaga, S., Abnormal-Respiration Detection by Considering Correlation of Observation of Adventitious Sounds, Signal Processing Conference (EUSIPCO), Ağustos 2015, Nice, France, 634-638.
40. Mazić, I., Bonković, M. ve Džaja, B., Two-Level Coarse-to-Fine Classification Algorithm for Asthma Wheezing Recognition in Children's Respiratory Sounds, Biomedical Signal Processing and Control, 21, (2015) 105-118.
41. Mendes, L., Vogiatzis, I. M., Perantoni, E., Kaimakamis, E., Chouvarda, I., Maglaveras, N., ... ve Paiva, R. P., Detection of Wheezes Using Their Signature in the Spectrogram Space and Musical Features, Engineering in Medicine and Biology Society (EMBC), Ağustos 2016, Florida, U.S.A., 5581-5584.
42. Yu, C., Tsai, T. H., Huang, S. I. ve Lin, C. W., Soft Stethoscope for Detecting Asthma Wheeze in Young Children, Sensors, 13,6 (2013) 7399-7413.
43. Jin, F., Sattar, F. ve Goh, D. Y., Automatic Wheeze Detection Using Histograms of Sample Entropy, Engineering in Medicine and Biology Society (EMBS), Ağustos 2008, Vancouver, Canada, 1890-1893.
44. Chien, J. C., Wu, H. D., Chong, F. C. ve Li, C. I., Wheeze Detection Using Cepstral Analysis in Gaussian Mixture Models, Engineering in Medicine and Biology Society (EMBS), Ağustos 2007, Lyon, France, 3168-3171.
45. Hsueh, M. L., Chien, J. C., Chang, F. C., Wu, H. D. ve Chong, F. C., Respiratory Wheeze Detection System, Engineering in Medicine and Biology Society (EMBS) Ocak 2005, Shanghai, China, 7553-7559.
46. Homs-Corbera, A., Fiz, J. A., Morera, J. ve Jané, R., Time-Frequency Detection And Analysis of Wheezes During Forced Exhalation, IEEE Transactions on Biomedical Engineering, 51,1 (2004) 182-186.

47. Aykanat, M., Kılıç, Ö., Kurt, B. ve Saryal, S., Classification of Lung Sounds Using Convolutional Neural Networks, EURASIP Journal on Image and Video Processing, 1, (2017) 65.
48. Pinho, C., Oliveira, A., Jácome, C., Rodrigues, J. ve Marques, A., Automatic Crackle Detection Algorithm Based on Fractal Dimension and Box Filtering, Procedia Computer Science, 64, (2015) 705-712.
49. Zhang, K., Wang, X., Han, F. ve Zhao, H., The Detection of Crackles Based on Mathematical Morphology in Spectrogram Analysis, Technology and Health Care, 23,s2, (2015) S489-S494.
50. İçer, S. ve Gengeç, Ş., Classification and Analysis of Non-Stationary Characteristics of Crackle and Rhonchus Lung Adventitious Sounds, Digital Signal Processing, 28, (2014) 18-27.
51. Jin, F., Sattar, F. ve Goh, D. Y., New Approaches for Spectro-Temporal Feature Extraction with Applications to Respiratory Sound Classification, Neurocomputing, 123, (2014) 362-371.
52. Mondal, A., Bhattacharya, P. ve Saha, G., Detection of Lungs Status Using Morphological Complexities of Respiratory Sounds, The Scientific World Journal, (2014).
53. Emmanouilidou, D., Patil, K., West, J. ve Elhilali, M., A Multiresolution Analysis for Detection of Abnormal Lung Sounds, Engineering in Medicine and Biology Society (EMBC), Ağustos 2012, San Diego, California, U.S.A., 3139-3142.
54. Himeshima, M., Yamashita, M., Matsunaga, S. ve Miyahara, S., Detection of Abnormal Lung Sounds Taking into Account Duration Distribution for Adventitious Sounds, Signal Processing Conference (EUSIPCO), Ağustos 2012, Bucharest, Romania, 1821-1825.
55. Xie, S., Jin, F., Krishnan, S. ve Sattar, F., Signal Feature Extraction by Multi-Scale PCA and its Application to Respiratory Sound Classification, Medical & biological engineering & computing, 50,7 (2012) 759-768.
56. Jin, F., Krishnan, S. ve Sattar, F., Adventitious Sounds Identification and Extraction Using Temporal-Spectral Dominance-Based Features. IEEE Transactions on Biomedical Engineering, 58,11 (2011) 3078-3087.
57. Dokur, Z., Respiratory Sound Classification by Using an Incremental Supervised Neural Network, Pattern Analysis and Applications, 12,4 (2009) 309.
58. Matsunaga, S., Yamauchi, K., Yamashita, M. ve Miyahara, S., Classification Between Normal and Abnormal Respiratory Sounds Based on Maximum Likelihood Approach, Acoustics, Speech and Signal Processing (ICASSP), Nisan 2009. Taipei, Taiwan, 517-520.

59. Alsmadi, S. ve Kahya, Y. P., Design of a DSP-Based Instrument for Real-Time Classification of Pulmonary Sounds, Computers in Biology and Medicine, 38,1 (2008) 53-61.
60. Kahya, Y. P., Güler, E. Ç., Sankur, B. ve Engin, T., Detection and Clustering Analysis of Crackles in Respiratory Sounds, Engineering in Medicine and Biology Society, Ekim 1992, São Paulo, Brazil, 6, 2527-2528.
61. Taplidou, S. A. ve Hadjileontiadis, L. J., Wheeze Detection Based on Time-Frequency Analysis of Breath Sounds, Computers in Biology and Medicine, 37,8 (2007) 1073-1083.
62. Lozano, M., Fiz, J. A. ve Jané, R., Automatic Differentiation of Normal and Continuous Adventitious Respiratory Sounds Using Ensemble Empirical Mode Decomposition and Instantaneous Frequency, IEEE Journal of Biomedical and Health Informatics, 20,2 (2016) 486-497.
63. Şen, I., Saraclar, M. ve Kahya, Y. P., A Comparison of DVM and GMM-Based Classifier Configurations for Diagnostic Classification of Pulmonary Sounds, IEEE Transactions on Biomedical Engineering, 62,7 (2015) 1768-1776.
64. Ulukaya, S., Sen, I. ve Kahya, Y. P., Feature Extraction Using Time-Frequency Analysis for Monophonic-Polyphonic Wheeze Discrimination, Engineering in Medicine and Biology Society (EMBC), Ağustos 2015, Milano, Italy, 5412-5415. IEEE.
65. Becker, K. W., Scheffer, C., Blanckenberg, M. M. ve Diacon, A. H., Analysis of Adventitious Lung Sounds Originating from Pulmonary Tuberculosis, Engineering in Medicine and Biology Society (EMBC), Temmuz 2013, Osaka, Japan, 4334-4337. IEEE.
66. Serbes, G., Sakar, C. O., Kahya, Y. P. ve Aydin, N., Pulmonary Crackle Detection Using Time-Frequency and Time-Scale Analysis, Digital Signal Processing, 23,3 (2013) 1012-1021.
67. Aydore, S., Sen, I., Kahya, Y. P. ve Mihcak, M. K., Classification of Respiratory Signals by Linear Analysis, Engineering in Medicine and Biology Society (EMBC), Eylül 2009, Minneapolis, U.S.A., 2617-2620.
68. Güler, E. Ç., Sankur, B., Kahya, Y. P. ve Raudys, S., Two-Stage Classification of Respiratory Sound Patterns, Computers in Biology and Medicine, 35,1 (2005) 67-83.
69. Martinez-Hernandez, H. G., Aljama-Corrales, C. T., Gonzalez-Camarena, R., Charleston-Villalobos, V. S. ve Chi-Lem, G., Computerized Classification of Normal and Abnormal Lung Sounds by Multivariate Linear Autoregressive Model, Engineering in Medicine and Biology Society (EMBS), Eylül 2005, Shanghai, China, 5999-6002.

70. Waitman, L. R., Clarkson, K. P., Barwise, J. A. ve King, P. H., Representation and Classification of Breath Sounds Recorded in An Intensive Care Setting Using Neural Networks, Journal of Clinical Monitoring and Computing, 16,2 (2000) 95-105.
71. Kahya, Y. P., Guler, E. C. ve Sahin, S., Respiratory Disease Diagnosis Using Lung Sounds, Engineering in Medicine and Biology Society, Kasım 1997, Chicago, U.S.A., 5, 2051-2053.
72. Vannuccini, L., Earis, J. E., Helisto, P., Cheetham, B. M. G., Rossi, M., Sovijarvi, A. R. A. ve Vanderschoot, J., Capturing and Preprocessing of Respiratory Sounds, European Respiratory Review, 10,77 (2000) 616-620.
73. Sarkar, M., Madabhavi, I., Niranjana, N. ve Dogra, M., Auscultation of the Respiratory System, Annals of Thoracic Medicine, 10,3 (2015) 158.
74. https://evolve.elsevier.com/objects/apply/RN/Mobility/RN_26-17.html Landmarks for Chest Percussion and Auscultation, 10 Aralık 2017.
75. Rabiner, L. R. ve Juang, B. H. Fundamentals of speech recognition, Oppenheim, A. V., PTR Prentice-Hall, New Jersey, 1993
76. Charakopoulos, A. K., Karakasidis, T. E., Papanicolaou, P. N. ve Liakopoulos, A., Nonlinear Time Series Analysis and Clustering for Jet Axis Identification in Vertical Turbulent Heated Jets, Physical Review E, 89,3 (2014) 032913.
77. Stevens, S. S., Volkman, J. ve Newman, E. B., A Scale for The Measurement of The Psychological Magnitude Pitch, The Journal of the Acoustical Society of America, 8,3 (1937) 185-190.
78. O'shaughnessy, D., Speech Communication: Human and Machine, Universities Press, 1987.
79. Žak, A., Usefulness of Linear Predictive Coding in Hydroacoustics Signatures' Features Extraction, Hydroacoustics, 17, 2014.
80. Kurt Zühal, Temel Bileşen Analiziyle Öznitelik Seçimi ve Görsel Nesne Sınıflandırma, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir, 2013.
81. Vapnik, V., The Nature of Statistical Learning Theory, Springer, 1995.
82. Osuna, E., Freund, R., ve Girosi, F. Support Vector Machines: Training and Applications, Massachusetts Institute of Technology and Artificial Intelligence Laboratory, Massachusetts, (1997), A.I. Memo No. 1602, C.B.C.L. Paper No. 144.
83. Ayhan, S., ve Erdoğan, Ş., Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 9,1 (2014) 175-198.

84. Xu, Q., Zhou, H., Wang, Y. ve Huang, J., Fuzzy Support Vector Machine for Classification of EEG Signals Using Wavelet-Based Features, Medical Engineering & Physics, 31,7 (2009) 858-865.
85. Solmaz, R., Günay, M. ve Alkan, A., Fonksiyonel Tiroit Hastalığı Tanısında Naive Bayes Sınıflandırıcının Kullanılması, KSÜ, Kahramanmaraş, Türkiye.
86. Aydemir, Ö. ve Kayıkçıoğlu, T., EEG Tabanlı Beyin Bilgisayar Arayüzleri, Akademik Bilişim'09-XI. Akademik Bilişim Konferansı Bildirileri, 11-13 Şubat 2009, Harran Üniversitesi.
87. Gurung, A., Scrafford, C. G., Tielsch, J. M., Levine, O. S. ve Checkley, W., Computerized Lung Sound Analysis As Diagnostic Aid for The Detection of Abnormal Lung Sounds: A Systematic Review and Meta-Analysis, Respiratory medicine, 105,9 (2011) 1396-1403
88. Pramono, R. X. A., Bowyer, S. ve Rodriguez-Villegas, E., Automatic Adventitious Respiratory Sound Analysis: A Systematic Review. PloS One, 12,5 (2017) e0177926.
89. Lozano, M., Fiz, J. A. ve Jané, R., Automatic Differentiation of Normal and Continuous Adventitious Respiratory Sounds Using Ensemble Empirical Mode Decomposition and Instantaneous Frequency, IEEE Journal of Biomedical and Health Informatics, 20,2 (2016) 486-497.
90. Şen, I., Saraclar, M. ve Kahya, Y. P., A Comparison of DVM and GMM-Based Classifier Configurations for Diagnostic Classification of Pulmonary Sounds, IEEE Transactions on Biomedical Engineering, 62,7 (2015) 1768-1776.
91. Bahoura, M., Pattern Recognition Methods Applied to Respiratory Sounds Classification into Normal and Wheeze Classes, Computers in Biology and Medicine, 39,9 (2009) 824-843.
92. Kahya, Y. P., Yeginer, M. ve Bilgic, B., Classifying Respiratory Sounds with Different Feature Sets, Engineering in Medicine and Biology Society (EMBS), Ağustos 2006, New York City, U.S.A., 2856-2859.
93. Mor, R., Kushnir, I., Meyer, J. J., Ekstein, J. ve Ben-Dov, I., Breath Sound Distribution Images of Patients with Pneumonia and Pleural Effusion, Respiratory Care, 52,12 (2007) 1753-1760.
94. Murphy, R. L., Vyshedskiy, A., Power-Charnitsky, V. A., Bana, D. S., Marinelli, P. M., Wong-Tse, A. ve Paciej, R., Automated Lung Sound Analysis in Patients With Pneumonia, Respiratory Care, 49,12 (2004) 1490-1497.

95. Rietveld, S., Oud, M. ve Dooijes, E. H., Classification of Asthmatic Breath Sounds: Preliminary Results of The Classifying Capacity of Human Examiners Versus Artificial Neural Networks, Computers and Biomedical Research, 32,5 (1999) 440-448.



ÖZGEÇMİŞ

1978 Fatsa doğumludur. Samsun Namık Kemal Lisesinden mezun olduktan sonra, Ondokuz Mayıs Üniversitesi (OMÜ) Elektrik - Elektronik Mühendisliği Bölümünde lisans öğretimine başlamış ve 2002 yılında 'Elektrik ve Elektronik Mühendisi' unvanı ile mezun olmuştur. Daha önce 2003-2004 yılları arasında Albaraka Türk K.B., 2004-2010 yılları arasında ise Milli Savunma Bakanlığı Erzurum İnşaat Emlak ve NATO Enf. Bölge Başkanlığı'nda çalışmıştır. 2009'da Atatürk Üniversitesi Fen Bilimleri Enstitüsü Anabilim Dalında yüksek lisans eğitimini tamamlamıştır. Elektrik-Elektronik Mühendisliği 2010 yılından bu yana Karadeniz Teknik Üniversitesi (KTÜ) Elektrik ve Elektronik Mühendisliğinde teknik personel olarak görev yapmaktadır. Evli ve iki çocuk babasıdır.

Uluslararası hakemli dergilerde yayınlanan makaleler (SCI/SCI-E)

1. Aras, S., Öztürk M. ve Gangal A., Automatic detection of the respiratory cycle from recorded, single-channel sounds from lungs, Turkish Journal Of Electrical Engineering & Computer Sciences, 26, (2018), 11-22.

Uluslararası bilimsel toplantılarda sunulan ve bildiri kitabında basılan bildiriler

1. Aras S. ve Gangal A., Comparison of Different Features Derived from Mel Frequency Cepstrum Coefficients for Classification of Single Channel Lung Sounds, 40th International Conference on Telecommunications and Signal Processing (TSP), Temmuz 2017, Barselona, İspanya, 346-349.
2. Aras, S., Cinel M., ve Gangal A., Classification of Commonly Heard Lung Sounds Recorded in Single Channel, 5th International Conference on Advanced Technology & Sciences (ICAT 17), Mayıs 2017, İstanbul, Türkiye.
3. Aras, S., ve Gangal A., Recognition of Common Lung Sounds using PCA and Support Vector Machines, 2016 3rd International Conference on Advanced Technology & Sciences (ICAT16), Eylül, 2016, Konya, Türkiye.

4. Aras S., Öztürk M. ve Gangal A., Endpoint Detection of Lung Sounds for Electronic Auscultation, 2016 39th International Conference on Telecommunications and Signal Processing (TSP), Haziran 2016, Viyana, Avusturya, 405-408.

Ulusal bilimsel toplantılarda sunulan bildiri kitabında basılan bildiriler

1. Aras, S., Cinel M., ve Gangal A., Tek Kanallı Akciğer Seslerine Dayalı Uygun Öznitelik Çıkarma Yöntemlerinin Araştırılması, IEEE 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU), Mayıs 2017, Antalya, Türkiye.
2. Aras, S., Gangal, A., ve Bülbül, Y., Elektronik Oskültasyon ile Kayıt Edilen Sağlıklı ve Patolojik Akciğer Seslerinin Sınıflandırılması, IEEE 23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU), Mayıs 2015, Malatya, Türkiye.
3. Aras, S., Gangal, A., ve Bülbül, Y., Genlikleri Normalize Edilmiş Sağlıklı ve Patolojik Akciğer Seslerinin Sınıflandırılması, IEEE 23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU), Mayıs 2015, Malatya, Türkiye.
4. Aras, S., Öztürk M., ve Gangal A., Gerçek Zamanlı Sesli Yön Komutlarının Tanınması, IEEE 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU), Nisan 2014, Trabzon, Türkiye.
5. Aras, S. ve Gangal A., Görüntü Renklendirme Teknikleri ve Uygulamaları Üzerine Bir Araştırma, Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu (ASYU), Temmuz 2012, Trabzon, Türkiye.

Görev aldığı projeler

1. Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK)

Projedeki Görevi : Doktora Öğrencisi (Bursiyer)

Proje Kodu/No : TÜBİTAK 3001 - 116E003

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

Proje Yürütücüsü : Prof. Dr. Ali GANGAL

2. Karadeniz Teknik Üniversitesi Bilimsel Araştırma Projeleri Birimi (KTÜ-BAP) tarafından desteklenen:

Projedeki Görevi : Araştırmacı

Proje Kodu/No : KTÜ BAP- 9747

Projenin Adı : Solunum Sistemlerinin Sınıflandırılması

Proje Yürütücüsü : Prof. Dr. Ali GANGAL

SERTİFİKA, KURS ve EĞİTİMLER

ERASMUS Personel Değişim Programı (Eğitim Alma Hareketliliği), Brno Teknik Üniversitesi, Çek Cumhuriyeti, 2014