



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİYOMEDİKAL SESLERİN ANALİZİ VE
SINIFLANDIRILMASI

Fatma Zehra GÖĞÜŞ

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Şubat-2015
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Fatma Zehra GÖĞÜŞ tarafından hazırlanan “Biyomedikal Seslerin Analizi ve Sınıflandırılması” adlı tez çalışması 06/02/2015 tarihinde aşağıdaki jüri tarafından oy birliği ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan-Danışman

Prof. Dr. Bekir KARLIK


Üye

Prof. Dr. Yüksel ÖZBAY

Üye

Yrd. Doç. Dr. Gülay TEZEL

İmza



Yukarıdaki sonucu onaylarım.

Prof. Dr. Aşır GENÇ
FBE Müdürü


Bu tez çalışması Öğretim Üyesi Yetiştirme Programı Koordinatörlüğü tarafından 2014-ÖYP-064 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



Fatma Zehra GÖĞÜŞ

ÖZET

YÜKSEK LİSANS TEZİ

BİYOMEDİKAL SESLERİN ANALİZİ VE SINIFLANDIRILMASI

Fatma Zehra GÖĞÜŞ

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Bekir KARLIK

2015, 122 Sayfa

Jüri

Prof. Dr. Bekir KARLIK

Prof. Dr. Yüksel ÖZBAY

Yrd. Doç. Dr. Gülay TEZEL

Biyomedikal sesler vücudun üretmiş olduğu seslerdir. Kalp sesi, solunum sesi gibi vücudun bir alanından ya da organlardan gelen sesler stetoskop aracılığı ile dinlenilebilmektedir. Seslerin varlığı, yokluğu veya normalden farklı olması herhangi bir hastalığın belirtisi olabilmektedir. Bu nedenle vücuttan stetoskop ile dinlenen biyomedikal sesler uzmanlar tarafından yorumlanarak hastalık teşhisinde kullanılmaktadır. Ancak bu şekilde yapılan teşhisler bir takım kısıtlamalara ve dezavantajlara sahiptir. Son zamanlarda, mühendislik, bilgisayar ve elektronik alanlarında meydana gelen gelişmeler, bu kısıtlamaların üstesinden gelerek, seslerin sayısal ortamlarda daha güvenilir ve daha kaliteli bir şekilde dinlenilmesini ve analizini mümkün kılmıştır. Bilgisayar destekli işaret işleme ve makine öğrenmesi algoritmaları sayesinde, vücut seslerinin sayısal ortamlarda analizi ile çeşitli hastalıkların teşhisi yapılabilmektedir.

Bu tez kapsamında akciğer, kalp ve konuşma biyomedikal ses işaretlerinin analizi ve sınıflandırılması işlemleri gerçekleştirilmektedir. Analiz amacıyla hızlı Fourier dönüşümü (HFD), otoregresif (AR) ve otoregresif hareketli ortalama (ARMA) metotları, ayrık ve paket dalgacık dönüşüm yöntemleri kullanılmaktadır. Tez çalışmasında, yapay sinir ağları (YSA), k-en yakın komşuluk (K-NN), destek vektör makineleri (DVM), Naive Bayes ve bulanık K-NN makine öğrenmesi yöntemleri kullanılarak ses işaretlerinin sınıflandırılması sağlanmıştır. Bu sayede, seslerin üretildiği organ ya da sisteme ait çeşitli hastalıkların teşhisinin sayısal ortamda yapılabilmesi amaçlanmıştır.

Anahtar Kelimeler: Biyomedikal Sesler, İşaret İşleme, Makine Öğrenmesi, Özellik Çıkarma, Sınıflandırma

ABSTRACT**MS THESIS****Analysis and Classification of Biomedical Sounds****Fatma Zehra GÖĞÜŞ****THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SELÇUK UNIVERSITY****Advisor: Prof. Dr. Bekir KARLIK****2015, 122 Pages****Jury****Prof. Dr. Bekir KARLIK****Prof. Dr. Yüksel ÖZBAY****Asst. Prof. Dr. Gülay TEZEL**

Biomedical sounds are the sounds which are produced by the body. Sounds from organs or area of the body such as heart sounds, lung sounds can be heard via stethoscope. The presence and absence of these sounds, or being different from usual may be indicative of variety problems related to the organs or systems. Therefore biomedical sounds which are heard with the stethoscope from body are used in the diagnosis of disease by interpreting listened sounds by experts. However, diagnosis which is made in this way has a number of limitations and disadvantages. Lately developments occurring in the computer and electronics technology overcome these constraints and make it possible to listen to and analysis of biomedical sounds more reliable and more quality in the digital environment. Due to computer-aided signal processing and machine learning algorithms, analysis of body sounds can be carried out. In this way, diagnosing of various diseases can be performed.

In this thesis, analysis and classification of lung, heart and speech biomedical sounds are carried out. Fast Fourier transform (FFT), autoregressive (AR) and autoregressive moving average (ARMA) methods, discrete wavelet and wavelet package transforms are used to analyze. In this thesis, classification of sounds are provided through artificial neural networks (ANN), k-nearest neighbor (K-NN), support vector machines (SVM), Naive Bayes and fuzzy K-NN machine learning methods. And whereby, it is intended through that diagnosing of various diseases belong to organ or systems in the digital environment.

Keywords: Biomedical Sounds, Signal Processing, Machine Learning, Feature Extraction, Classification

ÖNSÖZ

Bu çalışmamda bana yol gösteren danışman hocam Prof. Dr. Bekir KARLIK'a, Selçuk Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü Öğretim Elemanları'na, Yalova Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünde görevli olan Arş. Gör. Güneş Harman'a ve Celal Bayar Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümünde görevli olan Yrd. Doç. Dr. Yücel Koçyiğit'e teşekkürlerimi sunarım.

Ayrıca, maddi ve manevi yönden her zaman beni destekleyen, üzerimde büyük hakları olan aileme teşekkürü bir borç bilirim.

Fatma Zehra GÖĞÜŞ
KONYA-2015

İÇİNDEKİLER

ÖZET	1
ABSTRACT.....	2
ÖNSÖZ	3
İÇİNDEKİLER	4
SİMGELER VE KISALTMALAR	6
1. GİRİŞ	10
1.1. Tezin Organizasyonu	13
2. LİTERATÜR TARAMASI	15
2.1. Filtreleme İşlemi	16
2.1.1. Akciğer ses işaretleri.....	16
2.1.2. Kalp ses işaretleri.....	17
2.2. İşaret İşleme	18
2.2.1. Akciğer ses işaretleri.....	18
2.2.2. Kalp ses işaretleri.....	21
2.2.3. Parkinson hastalığında konuşma ses işaretleri.....	24
2.3. Sınıflandırma	24
2.3.1. Akciğer ses işaretleri.....	25
2.3.2. Kalp ses işaretleri.....	26
2.3.3. Parkinson Hastalığında Konuşma ses işaretleri	28
3. BİYOMEDİKAL SESLER	29
3.1. Akciğerlerin Yapısı ve Çalışması	29
3.2. Akciğer Sesleri.....	31
3.2.1. Normal akciğer sesleri	32
3.2.2. Anormal akciğer sesleri	33
3.3. Akciğer Hastalıkları	34
3.4. Kalbin Yapısı ve Çalışması.....	36
3.5. Kalp Sesleri.....	39
3.5.1. Normal kalp sesleri	41
3.5.2. Anormal (Patolojik/Ek) kalp sesleri	41
3.6. Konuşma Sesleri ve Parkinson Hastalığı	44
4. MATERYAL VE YÖNTEMLER	47
4.1. Biyomedikal Ses Verileri.....	47
4.2. Ön İşlemler	48
4.3. Sayısal İşaret İşleme Yöntemleri	49
4.3.1. Parametrik olmayan yöntem: Fourier dönüşümü.....	49
4.3.1.1. Hızlı Fourier dönüşümü ile güç spektrum kestirimi	52

4.3.2. Parametrik Yöntemler	53
4.3.2.1. AR (otoregresif / özbağlanım) yöntemi	54
4.3.2.2. MA (hareketli ortalamalar) yöntemi	55
4.3.2.3. ARMA (özbağlanım hareketli ortalamalar) yöntemi	56
4.3.3. Dalgacık dönüşümleri	57
4.3.3.1. Ayırık dalgacık dönüşümü (ADD).....	57
4.3.3.2. Dalgacık paket dönüşümü (DPD)	58
4.4. Boyut Azaltma Yöntemleri	59
4.4.1. Temel bileşenler analizi (TBA)	59
4.4.2. Lineer diskriminant analizi (LDA)	61
4.4.3. Bulanık c ortalama (BCO)	61
4.5. Sınıflandırma Yöntemleri	63
4.5.1. Yapay sinir ağları (YSA)	63
4.5.2. K-en yakın komşuluk (K-NN)	67
4.5.3. Destek vektör makineleri (DVM)	68
4.5.3.1. Doğrusal ayrılabilen veriler için DVM	69
4.5.3.2. Doğrusal ayrılamayan veriler için DVM	71
4.5.4. Naive Bayes	72
4.5.5. Bulanık k en yakın komşuluk	74
5. BİYOMEDİKAL SESLERDEN ÖZELLİK ÇIKARIMI	75
5.1. Akciğer Ses Verilerinin Özellik Çıkarımı	75
5.1.1. Welch, AR ve ARMA yöntemleri ile özellik çıkarımı	75
5.1.2. ADD ve DPD ile özellik çıkarımı.....	83
5.2. Kalp Ses Verilerinin Özellik Çıkarımı.....	84
5.2.1. Fourier dönüşümü, AR ve ARMA metotları ile özellik çıkarımı	84
5.2.2. ADD ve DPD ile özellik çıkarımı.....	86
5.3. Konuşma Ses Verilerinin Özellik Çıkarımı	87
5.3.1. Özellik seçimi	88
6. SINIFLANDIRMA SONUÇLARI	90
6.1. Akciğer Ses Verilerinin Sınıflandırılması.....	90
6.1.1. Welch, Burg, ARMA yöntemleri - istatistiksel özellikler	91
6.1.2. Welch, Burg, ARMA yöntemleri –BCO- istatistiksel özellikler	94
6.1.3. ADD, DPD - istatistiksel özellikler	96
6.2. Kalp Ses Verilerinin Sınıflandırılması.....	97
6.3. Konuşma Ses Verilerinin Sınıflandırılması	99
7. SONUÇ ve ÖNERİLER	100
KAYNAKLAR	106

SİMGELER VE KISALTMALAR

Simgeler

$a(k)$	: AR Metot Katsayıları (Parametreleri)
C	: Kovaryans Matrisi
d	: Mesafe Ölçütü
$e(t)$	: Hata Terimi (Beyaz Gürültü)
e_p	: Toplam en az karesel hata
f	: Frekans uzayı
g	: Alçak geçiren filtre
$H(x_j)$	: Aday Öznitelik Entropisi
h	: Yüksek geçiren filtre
H_1	: Yüksek (detay) Frekans Bileşenleri
H_i^q	: q 'uncu katmandaki i biriminin girdisi
I	: Ortak Bilgi
L_1	: Düşük (yaklaşım) Frekans Bileşenleri
$p(x,y)$	: X ve Y 'nin birleşik dağılım fonksiyonu
$P(X C)$	: C Verildiğinde X 'in Koşullu Olasılığı
p	: AR Metot Derecesi
P	: Periodogram
$p_1(x)$	: X Raslantı Değişkeni Marjinal Olasılık Dağılım Fonksiyonu
$p_2(y)$	: Y Raslantı Değişkeni Marjinal Olasılık Dağılım Fonksiyonu
P_{AR}	: AR Metot Güç spektrum Yoğunluğu
P_{ARMA}	: ARMA Metot Güç spektrum Yoğunluğu
P_{Burg}	: Burg Metodu Güç spektrum Yoğunluğu
P_{MA}	: MA Metot Güç spektrum Yoğunluğu
q	: MA Metot Derecesi
T	: Hedef Değişkeni
t	: Zaman uzayı
U'	: Pencereleme Fonksiyonu İçerisindeki Güç
U	: Üyelik matrisi
$W(n)$	: Pencereleme fonksiyonu
w	: Ağırlık Vektörü
w_{ij}^q	: $(q-1)$ 'inci katmandaki i birimini, q 'ncu katmandaki j birimine bağlayan ağırlık
y_i^q	: q 'uncu katmandaki i biriminin çıktısı
$\delta(\text{Delta})$	: Çıkış veya Gizli Katman Birimleri İçin Hata Terimleri
ε	: Epsilon

$\theta(k)$	:	MA Metot Katsayıları (Parametreleri)
θ	:	Teta
Λ_x	:	Öz Değerler
Π	:	Pi
$\sigma(\text{Sigma})$	:	Varyans
τ	:	Tau
$\Psi(\text{Psi})$	:	Temel Dalgacık
Φ_x	:	Öz Vektörler

Kısaltmalar

AC	: Otokorelasyon
ADD	: Ayrık Dalgacık Dönüşümü
AFD	: Ayrık Fourier Dönüşümü
APQ3	: 3 noktalı genlik değişim katsayısı
APQ5	: 5 noktalı genlik değişim katsayısı
APQ11	: 11 noktalı genlik değişim katsayısı
AR	: Otoregresif (Autoregressive) Metot
ARMA	: Otoregresif Hareketli Ortalama (Autoregressive Moving Average) Metot
ASD	: Atrial septal Defekt
BCO	: Bulanık C Ortalama
BFGS	: Broyden-Fletcher-Goldfarb-Shannon
DDP	: Bağlı Mutlak Ortalama
DPD	: Dalgacık Paket Dönüşümü
DVM	: Destek Vektör Makineleri
FIR	: Sonlu Darbe Cevaplı (Finite Impulse Response)
HFD	: Hızlı Fourier Dönüşümü
HTN	: Harmonik Gürültü Oranı
Hz	: Hertz
IIR	: Sonsuz Darbe Cevaplı (Infinite Impulse Response)
K-NN	: K En Yakın Komşuluk
KOAH	: Kronik Obstrüktif Akciğer Hastalığı
KZDF	: Kısa Zamanlı Fourier Dönüşümü
LDA	: Lineer Diskriminant Ayırışım
MA	: Hareketli Ortalama (Moving Average) Model
MFCC	: Mel Frekans Cepstral Katsayıları
MID	: Mutual information Difference
MIQ	: Mutual Information Quotient
MRMR	: Minimum Redundancy Maximum Relevance
NTH	: Gürültü Harmonik Oranı
PDA	: Patent Ductus Arteriosus
PH	: Parkinson Hastalığı
PPQ	: Periyot Değişim Katsayısı
RAP	: Bağlı Ortalama Değişimi
S1	: 1. Kalp Sesi
S2	: 2. Kalp Sesi
S3	: 3. Kalp Sesi

S4	: 4. Kalp Sesi
TBA	: Temel Bileşenler Analizi
VSD	: Ventriküler Septal Defekt
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Çeşitli tıbbi durumların klinik değerlendirmesinde x-ray, bilgisayarlı tomografi (Computerized Tomography, CT), röntgen, MR, ultrason, laboratuvar tanı testleri, steteskop ile muayene (oskültasyon) vb. bir çok temel tanı aracı kullanılmaktadır. X-ray, CT, röntgen ve ultrason gibi tanı araçları, hastalık ve hastalığın meydana geldiği bölgeler hakkında hekimlere net bir görüntü sağlar. Ancak bu araçlar ile gerçekleştirilen tanı pahalıdır ve x ışınları ile hasta zarara yol açabilecek dozlarda radyasyona maruz kalmaktadır. Laboratuvar tanı testleri ise hastanın işbirliğini gerektirir ve belirli yaş altı hastalara örneğin bebeklere tatbik edilemez. Ayrıca, testler ancak bir hastalıktan şüphelenildiği takdirde teşhise yardımcı olarak kullanılmaktadır. Bu araçlar arasında dinleme (oskültasyon) diğer araçlara göre daha ucuz ve halen tanı için kullanılan en yaygın tekniktir. Bazı durumlarda, uzak bölgelerde ya da gelişmekte olan ülkelerde özellikle oskültasyon mevcut olan tek tanı aracı olabilmektedir (Güler ve ark., 2005).

Oskültasyon vücut organlarının üretmiş olduğu sesleri dinlemenin tıbbi adıdır ve steteskop aracılığı ile gerçekleştirilir. Kalp, akciğer, bağırsak gibi organların faaliyetleri sırasında ürettikleri seslerin varlığı, yokluğu veya normalden farklı olması, sesin üretildiği organa veya sisteme ait bir takım hastalıkların göstergesi olabilir. Bu nedenle vücut içerisinde oluşan sesler, çeşitli tıbbi hastalıkların teşhis ve tedavisi amacıyla kullanılır ve biyomedikal sesler olarak adlandırılır. Hekimler tarafından steteskop aracılığı ile dinlenen biyomedikal sesler yine hekimler tarafından yorumlanarak hastalık teşhisinde kullanılırlar. Dinleme işlemi, kalp, karın, akciğerler, kan damarları gibi vücut yapılarını örten deri üzerine steteskop yerleştirilerek gerçekleştirilir ve bu işlem doktorların, insan kulağının işittiği frekans aralıklarındaki vücut seslerini duyabilmelerine olanak sağlar.

Vücudun bazı kısımlarından dinlenen biyomedikal sesler ve hastalıklar arasındaki ilişkiler;

- **Boyun Bölgesinden Dinlenen Biyomedikal Sesler:** Deri yüzeylerine yakın kan damarları çevreye bir takım sesler yayarlar. Bu sesler, kan damarları daraldığında veya genişlediğinde aynı zamanda kalp kapakları daraldığında veya hasara uğradığında duyulabilir. Örnek olarak boyun damarları dinlenilmesi ile üfürüm sesi duyulabilir bu da şah damarlarında bir problem olduğu anlamına gelebilir.

- Göğüs Bölgesinden Dinlenen Biyomedikal Sesler: Göğüs bölgesinde bulunan akciğerler ve kalp bir takım sesler üretirler. Bu seslerde meydana gelen anormallikler astım, koah, kalp yetmezliği, kalp kapak hastalığı gibi hastalıkların belirtisi olabilmektedir. Kalp ve akciğer sesleri çok karmaşık seslerdir. Bu nedenle hastalık teşhisi için bu seslerin doğru ve güvenilir bir şekilde yorumlanması gerekir.
- Karın Bölgesinden Dinlenen Biyomedikal Sesler: Karın bölgesindeki mide ve bağırsak gibi organlarda meydana gelen seslerdir. Barsakta hava ve sıvı hareketi nedeni ile olan gürültülü guruldama sesleri örnek olarak verilebilir. Bu seslerden mide ve bağırsak gibi organların durumları tespit edilebilir. Herhangi bir hastalık yoksa bile karın iç organlarının çıkardıkları seslerden, organların fonksiyonları öğrenilebilir.

Oskültasyon ucuz, etkili, uygulaması kolay, hasta için zararsız bir tanı aracı ve dünya üzerinde kullanılan en yaygın teşhis metodudur. Oskültasyon hem dinlenen organın fonksiyonu ve durumu ile ilgili hekimlere faydalı bilgiler verir hem de hasta ile hekim arasındaki tanıya yönelik etkileşimi artırır (Spieth ve ark., 2011). Oskültasyonun bu avantajlarına rağmen, bu işlem birçok kısıtlamalara ve dezavantajlara da sahiptir. Oskültasyon sonucu elde edilen bulguları tanımlama ve yorumlama hekimin uzmanlığına bağlıdır. Hekimin işitme gücü, yaşı, tecrübesi, eğitimi, sesler arasındaki farklılıkları ayırt edebilme yeteneği, çevresel etmenler, yorgunluk, uykusuzluk gibi birçok faktör bulguların yorumlanması ve tanı konulmasını etkileyebilmektedir (Kandaswamy ve ark., 2004). İnsan kulağının belirli frekans altındaki seslere karşı çok hassas olmaması da oskültasyonun dezavantajları arasında sayılmaktadır (Sovijarvi ve ark., 2000). Ayrıca steteskop ambulans, acil yardım odası gibi ortamlarda çok güvenilir bir araç olmayabilir.

Bilgisayar, elektronik ve mühendislik alanlarındaki teknolojik gelişmeler, biyomedikal ses işaretlerinin sayısal ortamlarda güvenilir bir şekilde kaydedilmesini ve analizini mümkün kılmıştır. (Güler ve ark., 2005; Dokur ve Ölmez, 2008). Buna bağlı olarak, sayısal işaret işleme ve makine öğrenmesi algoritmalarıyla vücut seslerinin bilgisayar ortamında analizi, hastalık teşhisine yardımcı olabilmektedir. Ayrıca bilgisayar destekli yöntemler sayesinde hekimler aynı ortamda çalışmasalar bile internet veya intranet aracılığıyla meslektaşları ve uzmanlar ile teşhis ve tanı için etkileşime geçebilmektedirler. Bilgisayar ortamında sayısal olarak kaydedilen biyomedikal sesler

uzun süre saklanabilmekte ve hastanın patolojik deęişiklikleri için kullanılabilir. Kaydedilen seslerden oluşturulan veri tabanı ile dięer bireylerin hastalık teşhisi ve genç hekimlerin eğitimi yapılabilir (Yiğiner, 1999).

Gelişen teknoloji ile birlikte bilgisayar tabanlı ses işaret analizi; bir elektronik cihaz yardımıyla bireyin vücut seslerinin kaydedilmesini, bunu takiben işaretin özelliklerine dayanarak işaret işleme ve sınıflandırma teknikleri ile seslerin analizini içermektedir (Grung ve Ark., 2011).

Vücut organlarının faaliyetleri sırasında üretilen biyomedikal ses işaretleri, üretildikleri organın fonksiyonuna ve tıbbi durumuna ilişkin bilgi taşıdıkları için önemlidirler. Önemli tanısal bilgi ses işaretlerinin başta frekans dağılımı olmak üzere şiddet (yoğunluk, büyüklük), süre ve kalite gibi karakteristik özellikleri analiz edilerek elde edilebilir (Kumar, 2007).

Sesin frekansı birim zamandaki titreşim sayısının, saniye başına döngü sayısının ölçüsüdür ve hertz (Hz) ile ifade edilir. 1 Hertz saniyede bir titreşim demektir. Birim zamandaki düşük veya yüksek titreşim sayısı sesin meydana geldiği bölgedeki bir problemin göstergesi olabilir (Howell, 2006). Kalp seslerinde saniyede ortalama olarak 150'nin üzerinde titreşimin meydana gelmesi, aort ve pulmonalis yetmezliğinin belirtisidir. Bu durumda üfürüm sesi duyulur.

Sesin kulak tarafından duyulan yüksekliğine sesin şiddeti (yoğunluğu) denir. Sesin şiddeti, titreşimlerin genliğine ve enerjisine bağlıdır (Howell, 2006).

Sesin süresi, sesi oluşturan titreşimlerin zaman içindeki devamlılığıdır. Ses süresinin uzunluğu ya da kısalığı hastalık hakkında bilgi verebilir (Howell, 2006). Örneğin Kronik obstrüktif akciğer hastalığı (KOAH) olan bir hastada, uzun hırıltılı bir nefes verme sesi hastalığa işaret edebilir.

Tını olarak adlandırılan ses kalitesi, belirli bir sesi oluşturan frekanslara bağlıdır. Tını sayesinde muayene eden kişi farklı sesleri algılayabilir ve hastalık teşhisinde bulunabilir. Ses, kendine özgü olan bu özelliği, taşıyıcı bir titreşimin (asıl dalganın) üzerine oranlı olarak, yan titreşimlerin binmesiyle oluşan karmaşık titreşimlerin sonucu sonucunda kazanır (Howell, 2006).

Bu karakteristik özelliklerin belirlenmesi seslerin sınıflandırılması içinde önemli bir adımdır. Seçilen analiz yöntemleri ile çıkarılan ses özelliklerine bağlı olarak seslerin sınıflandırılma doğrulukları değişebilmektedir. Bu nedenle doğru bir sınıflandırma için ses işaretlerinin analizi ve işaretlerden özellik çıkarımı aşaması çok önemli bir adım olmaktadır.

Yapılan tez çalışması kapsamında akciğer, kalp ve konuşma biyomedikal ses işaretlerinin bilgisayar destekli analizi ve sınıflandırılması gerçekleştirilecektir.

Seslerin analizi ve seslerden özellik çıkarılması aşamasında hızlı fourier dönüşümü (HFD), otoregresif (AR) ve otoregresif hareketli ortalama (ARMA) yöntemleri, ayırık ve paket dalgacık dönüşümleri kullanılacak ve karşılaştırılmaları yapılacaktır.

Temel bileşenler analizi (TBA), lineear diskriminant analizi (LDA), bulanık c ortalama (BCO) algoritması ve istatistiksel özellikler, boyut azaltmak amacıyla, elde edilen özellik vektörleri üzerinde uygulanacaktır.

Biyomedikal seslerin sınıflandırılması aşamasında yapay sinir ağları (YSA), k en yakın komşuluk (K-NN), destek vektör makineleri (DVM), Naive Bayes, bulanık K en yakın komşuluk (bulanık K-NN) sınıflandırıcı algoritmaları kullanılarak en yüksek doğruluk oranını veren sınıflandırıcı veya sınıflandırıcılar tespit edilecektir.

Yapılacak çalışma sonucunda kullanılan biyomedikal sesler için en iyi analiz ve sınıflandırıcı yöntemleri belirlenerek hastalık tanısının ne kadar başarılı bir şekilde yapıldığı konusunda çıkarım yapılacaktır.

1.1. Tezin Organizasyonu

Bu tez çalışması çeşitli makine öğrenmesi ve işaret işleme algoritmaları ile biyomedikal seslerin analizini ve sınıflandırılmasını konu edinmektedir.

Tez çalışması 7 temel bölümden oluşmaktadır.

Bölüm 1, tezin temel amacı, yapısı ve bu tezin katkıları hakkında kısa bir giriş bilgisi vermektedir.

Bölüm 2, literatür araştırmalarını içermektedir.

Bölüm 3, biyomedikal sesler hakkında kısa bilgiler sunmaktadır. Bölüm akciğerler, akciğerlerin çalışması, akciğer seslerinin üretilmesi, normal ve anormal akciğer sesleri ve akciğer hastalıkları hakkında kısa bilgiler ile başlamaktadır. Bölüm daha sonra kalp ve dolaşım sistemi, kalp seslerinin üretimi, normal ve anormal kalp sesleri hakkında bilgiler ile devam etmektedir. 3. bölüm konuşma sesleri ve parkinson hastalığı hakkında bilgiler sunarak son bulmaktadır.

Bölüm 4, tez çalışmasında kullanılan veriler, materyal ve yöntemler hakkındaki teorik bilgileri içermektedir.

Bölüm 5, tezin en önemli kısımlardan biri olan seslerin analizinin ve seslerden özellik çıkarımının anlatıldığı bölümdür. Farklı işaret işleme yöntemleri ile akciğer seslerinin, kalp seslerinin ve konuşma seslerinin analizleri bu bölümde detaylı bir şekilde anlatılmaktadır.


Bölüm 6, analizleri yapılarak özellikleri çıkarılmış biyomedikal ses verilerinin çeşitli makine öğrenmesi yöntemleri ile sınıflandırılmasını konu edinmektedir. Sınıflandırma sonuçları bu bölümde gösterilmektedir.

Bölüm 7, tez çalışmasının sonuç kısmıdır. Tez çalışmasının kısa bir açıklamasının ve sınıflandırma sonuçlarının yorumlanmasının yapıldığı bölümdür.

2. LİTERATÜR TARAMASI

Biyomedikal sesler (akciğer, kalp sesleri ...) durağan ve lineer olmayan yani frekansı ve spektral içeriği zaman içerisinde değişebilen, stokastik işaretlerdir (Marshall ve Boussakta, 2007). Stokastik işaret, işareti kararlı hale getiren etmenlerin bilinmemesi durumunda bu ismi alan, içerisinde rassal süreçler barındıran işaretlerdir. Şekil 2.1 'de rastgele bir işaret yapısı gösterilmektedir.

Biyomedikal sesler ayrıca genel olarak periyodik olmayan işaretlerdir. Kalp sesleri diğer ses işaretlerine göre periyodik olmaya biraz daha yakın olsa da bireylerin kalp seslerindeki periyodikliklerde de önemli değişiklikler olmaktadır. Bu özellikleri biyomedikal seslerin analizini zor bir görev haline getirmektedir. (Marshall ve Boussakta 2007) (Kandaswamy ve ark., 2004)



Şekil 2.1. Rastgele işaret yapısı

Teknolojik ilerlemeler ile birlikte kalp sesleri, akciğer sesleri gibi vücut içi seslerin araştırılması yıllarca heyecan verici bir çalışma alanı olmuştur. Bu alanda yapılmış birçok araştırma ve çalışma mevcuttur. Bu çalışmalar genellikle üç temel grup altında incelenmiştir. Birincisi, ses işaretlerini kaydetmek ve veri tabanı oluşturmak için yapılan donanım ağırlıklı çalışmalardır (Yi ve Caiming, 2006). İkincisi, sesleri çeşitli gürültülerden ayırmak için yapılan filtreleme çalışmalarıdır (Mastorocostas ve ark., 2004) ve son grup ise bu çalışmaların çok büyük bir kısmını ve tez çalışmamızı oluşturacak olan ses işaretlerinin analizi, işlenmesi ve sınıflandırılması (Li ve Du, 2005) için yapılan çalışmalardır (İcer ve Gengeç, 2014). Özellikle kalp sesleri ve akciğer sesleri, kalp ve akciğerin mekanik aktiviteleri ile ilgili değerli bilgiler sağladıkları için çok sayıda araştırmanın odak noktası olmuştur (Reyes ve ark., 2014).

2.1. Filtreleme İşlemi

2.1.1. Akciğer ses işaretleri

Akciğer ses işaretleri sınırlı frekans bant genişlikleri olan gürültülü işaretlerdir. Kalp, kas ve vücudun bazı bölgelerinden gelen sesler, ortam gürültüleri, ses kaydı için kullanılan cihazların vermiş olduğu gürültüler vs. akciğer seslerine karışarak ses işaretinin ayırt edilebilirliğini azaltmaktadır. Bu nedenle akciğer ses işaretleri gereksiz ve istenmeyen frekans bileşenlerinden ve gürültülerden temizlenmek amacıyla filtrelerden geçirilirler.

Ses işaretlerinin analizi için, birçok çalışmada farklı örnekleme oranlarında (4000-12.000 Hz) ve çözünürlüklerde (12-16 bit) farklı filtreler(50-2240 Hz), ses işaretleri üzerinde uygulanmıştır.

Göğüsten kaydedilen ses (akciğer sesleri) kayıtları için en yaygın kullanılan bant genişliği 60-100 Hz ve 2 kHz arasındır. Sesler trekeadan kaydedildiği zaman ise en yaygın olarak kullanılan bant genişliği 60-100 Hz ve 4 kHz aralığıdır (Güçlü, 2010).

Yapılan çalışmaların ve araştırmaların çoğunda yüksek geçiren, alçak geçiren ve bant geçiren filtreler akciğer ses işaretlerinin filtrelenmesi amacıyla kullanılmıştır.

Yüksek geçiren filtreler, kalp sesleri gibi düşük frekanslı bileşenleri azaltmak ve yok etmek için kullanılmıştır. Jarad ve ark. (1994) 3dB noktalı yüksek geçiren filtreyi özellikle kalp sesleri olmak üzere düşük frekanslı bileşenleri en aza indirmek amacıyla kullanmışlardır. Serbes ve ark. (2013) akciğer sesleri üzerinde 6. dereceden bessel yüksek geçiren filtre kullanarak 80 Hz aşağısında bulunan frekans bileşenlerini (kalp sesleri) minimize etmişlerdir.

Alçak geçiren filtreler, kesme frekansı örnekleme oranına bağlı olacak şekilde bir düzgünleştirme fonksiyonu sağlamak için kullanılmışlardır. Ortam gürültüleri, sürtünme gürültüleri gibi yüksek frekanslı bileşenleri en aza indirmek için akciğer ses işaretleri üzerinde uygulanmışlardır. Aljarad ve ark. (1994) 3 dB noktalı alçak geçiren filtreyi maksimum frekansı 2.5 kHz'e sabitlemek amacıyla kullanmışlardır. Serbes ve ark. (2013) akciğer sesleri üzerinde 8. dereceden butterworth alçak geçiren filtre kullanarak 4 kHz üzerindeki frekans bileşenlerini yok etmişlerdir. Fenton ve ark. (1985) 2560 Hz örnekleme oranlı ve 1000 Hz kesme frekanslı 5. Dereceden eliptik alçak geçiren, Anderson ve ark. (1990) 9600 Hz örnekleme oranlı ve 3 kHz kesme frekanslı Chebychev alçak geçiren filtreleri akciğer ses işaretleri üzerinde uygulamışlardır.

Bazı uygulamalarda ise hem alçak geçiren filtre hem yüksek geçiren filtre görevini üstlenebilen bant geçiren filtreler kullanılmıştır. İçer ve ark. (2014) kalp ve kas parazit seslerini azaltmak amacıyla 150 ile 1800 Hz frekans aralığını muhafaza eden IIR Butterworth bant geçiren filtre kullanmışlardır. Rietveld ve ark. (1999) akciğer sesleri üzerinde 100-1500 Hz bant geçişi ile dördüncü dereceden Butterworth analog filtre uygulamışlardır. Sello ve ark. (2008) akciğer seslerinin frekans aralıklarını 148-2000 Hz olarak değerlendirmişler ve 149 lineer katsayılı FIR bant geçiren filtreyi istenilen frekans aralıklarını elde etmek için kullanmışlardır. Broersen ve de Waele (2000) 5000 Hz örnekleme oranlı 4. dereceden bessel bant geçiren filtreyi 100-1500 Hz aralığı dışındaki frekans bileşenlerini minimize etmek amacıyla akciğer ses işaretleri üzerinde uygulamışlardır.

Dalgacık dönüşümlerinin geliştirilmesi ile birlikte birçok uygulamada dalgacık dönüşümü tabanlı teknikler akciğer seslerinin istenmeyen frekans bileşenlerinden temizlenmesi amacıyla kullanılmıştır (Kandaswamy ve ark., 2004; Hadjileontiadis ve Panas, 1998).

2.1.2. Kalp ses işaretleri

Kalp sesleri genellikle çevresel gürültü, güç parazitleri, nefes sesi, akciğer sesi, kas hareketleri vb. tarafından kaynaklanan büyük hacimde istenmeyen bileşenlere sahiptir. Kalp ses işaretlerinin son derece durağan olmayan, kompleks doğası ve frekans karakteristiklerinden dolayı, etkin bir kalp ses tanımlaması yapılmadan önce gürültünün minimuma indirgenmesi için uygun filtreleme işlemlerinin gerçekleştirilmesi gerekmektedir (Choi ve Jiang, 2010).

Kalp ses işaretlerinin filtrelenmesi için yıllardır yapılan çalışmalarda genellikle bant geçiren, alçak ve yüksek geçiren filtreler ve dalgacık tabanlı filtreler kullanılmıştır.

Amiri ve Armano (2013) birinci (S1) ve ikinci (S2) kalp seslerinin temel frekans spektrumlarının 200 Hz civarında bulunduğunu tespit etmişler ve 3. dereceden butterworth bant geçiren filtreyi kalp sesleri üzerinde uygulayarak 50 Hz-2000 Hz frekans aralığını elde etmişlerdir. Amit ve ark. (2009) 20-250 Hz frekans aralıklı sayısal bir bant geçiren filtre kullanarak sürekli kalp seslerinin analizden önce gereksiz bileşenlerden arındırılmasını sağlamışlardır. Segaiar ve ark. (2005) ses işaretlerini 40-1100 Hz frekans kesmeli bant geçiren filtreden geçirmişlerdir.

Gupta ve ark. (2005) normal ve anormal kalp seslerinin 50-700 Hz frekans aralıklarında bir dağılıma sahip olduklarını, daha yüksek frekansların tanı ve analiz için klinik bir önemlerinin olmadığını belirtmişlerdir. Bu nedenle alçak geçiren Chebyshev türü filtre tasarımı yaparak 750 Hz üzerindeki frekans bileşenlerini en aza indirmişlerdir. Wang ve ark. (2014) kalp seslerine karışan çevresel gürültülerin kompleks ve tahmin edilemeyen yüksek frekans bileşenlerinden oluştuğunu ifade etmişlerdir. Bu araştırmacılar kalp seslerinin genellikle 0-300 Hz aralığında bulunduğunu belirterek, sesleri yüksek frekanslı gereksiz bileşenlerden arındırmak amacıyla alçak geçiren filtreden geçirmişlerdir. Bazı durumlarda alçak geçiren filtrenin gürültü azaltmak için çokta etkili olmayacağını savunarak, bir sonraki adımda kalp seslerinin filtrelenmesi için, seslere dalgacık yumuşak eşikleme uygulamışlardır.

Hartimo ve ark.(1998) 40 Hz kesmeli yüksek geçiren filtre kullanarak kalp ses kayıtlarını kas titreşimleri ve düşük frekanslı diğer gürültülerden filtrelemişlerdir.

Choi ve Jiang (2010) dalgacık dönüşümünü kardiyak seslerinin tanımlanması için önişlem olarak kullanmışlardır. Dokur ve ölmez (2009) kalp seslerini gürültülerden arındırmak amacıyla dalgacık dönüşümünü kullanmışlardır.

2.2. İşaret İşleme

2.2.1. Akciğer ses işaretleri

Akciğer ses işaretlerinin araştırılması yıllardır heyecan verici bir çalışma alanı olmuştur. Literatürde akciğer ses işaretleri üzerinde yapılmış çok sayıda ve çeşitli çalışmalar bulunmaktadır (İçer ve ark., 2014). Özellikle farklı hastalık durumlarına göre akciğer seslerinden ayırt edici özelliklerin çıkarılması ve analiz edilmesi literatür çalışmalarının büyük bir kısmını oluşturmaktadır.

Özellik çıkarımı aşaması bir işaretin ayırt edici özelliklerinin belirlenmesi sürecidir (Bobrowski ve Lukaszuk, 2009) ve etkili bir sınıflandırma için etkin rol oynar. Akciğer seslerinin özellik çıkarımı ve analizi için kullanılan en yaygın yöntemler Fourier dönüşümleri (Gavriely ve ark., 1981; Banham ve ark. 1984; Forkheim ve ark. 1995; Rietveld ve ark. 1999; Waitman ve ark. 2000; Ono ve ark. 2009; Riella ve ark. 2009), AR, ARMA gibi parametrik yöntemler (Gavriely ve Herzberg, 1992; Vanderschoot ve Schreur 1994; Sankur ve ark. 1994), mel-frekans cepstral katsayıları (MFCC)(Bahoura ve ark., 2003; Bahoura ve ark., 2004; Bahoura ve ark., 2004; Wang

ve ark., 2011), enerji ve entropi hesaplama yöntemleri ve dalgacık dönüşümleridir (Pesu ve ark., 1998; Kandaswamy ve ark., 2004; Dokur ve ark., 2003).

Akciğer ses işaretlerinin analizi genellikle güç spektral yoğunluğu, spektral enerji dağılımının tahmini, seslerdeki ısığın, hırıltının, çırtının, öksürüğün ve horlamanın tespiti, normal ve anormal akciğer seslerinin ayrılması gibi terimleri içermektedir (Güçlü, 2010).

Baughman and Loudon (1984;1985) hırıltı tarafından işgal edilen solunum döngüsü oranını değerlendirmek için bir algoritma geliştirmişlerdir. Hırıltı tespiti için 150 Hz ve 1000 Hz aralığında güç spektrumunda keskin tepelerin varlığını kriter olarak kullanmışlardır. Fenton ve ark. (1985) astım hastalığına sahip ve sağlıklı çocuklardan kaydettikleri solunum seslerini hırıltı tespiti için analiz etmişlerdir. Hırıltının göstergeleri olarak yüksek genlikli ve yüksek frekanslı zirveler için seslerin güç spektrumları analiz edilmiştir. Hırıltılar 200 Hz üzerindeki güç spektrumundaki zirvelerin varlığı tarafından karakterize edilmişler ve genliklerinin ortalama spektrum genliğinden 15 kat daha büyük olduğu ifade edilmiştir. Taplidou ve Hadjileontiadis (2007) nefes darlığı olan akciğer hastalarında bulunan hırıltı gibi anormal sesleri gözlemlemişlerdir. Otomatik zaman frekans hırıltı tespit edici (TF-WD) oluşturarak hırıltıları otomatik olarak tespit etmeyi amaçlamışlardır. TF-WD akciğer ses işaretinin kayıt edilmesi sırasında zaman frekans analizine bağlı olarak hırıltılı bölgeleri tanımlar. Araştırmacılar seslerin zaman frekans analizini ise kısa zamanlı Fourier dönüşümü kullanarak gerçekleştirmişlerdir. Hırıltılı bölgeler farklı genliklerde olduğu ve solunum döngüsünün farklı zamanlarında ortaya çıktığı için akciğer seslerinin zaman frekans analizi yapılmıştır. Forkheim ve ark. (1995) hırıltılı ve normal solunum (akciğer) seslerini Fourier dönüşümü ile analiz ederek elde ettikleri özellikleri sınıflandırma işlemine tabi tutmuşlardır. Bu süreçlerin sonucunda akciğer seslerini normal ve hırıltılı olarak ayırma işlemini gerçekleştirmişlerdir. Bahoura ve Pelletier (2003) cepstral katsayıları kullanarak seslerin hırıltı içerip içermediğini belirlemişlerdir. Antonia ve ark. (2004) hırıltıları tespit ve analiz etmek için 2 teknik sunmuşlardır; zaman – frekans algoritması ve gruplama algoritması. Zaman frekans algoritmasının akciğer seslerinin zaman içerisindeki genlik zirvelerinin ve frekanslarının analizini gerçekleştirerek hırıltılı bölgelerin tespitini yaptığını belirtmişlerdir. Gruplama algoritmasının ise hırıltılı bölgelerin sürekliliğini değerlendirdiğini ifade etmişlerdir. Taplideu ve ark. (2003) nefes alma ve nefes verme solunum seslerinden hesaplanan spectrogram zirvelerine belirli eşik değerleri uygulayarak hırıltı tanımlaması yapmışlardır. Aydöre (2009) tarafından

yapılan çalışmada hırıltılı ve hırıltısız normal akciğer seslerinin analizi Renyi entropi ve ortalama-geçiş özellikleri kullanılarak gerçekleştirilmiştir. Hırıltı ve hırıltısız sesler Fisher diskriminant analizi kullanılarak başarılı bir şekilde iki sınıfa ayrılmıştır.

Güler ve ark. (2005) farklı solunum yolu hastalıklarına sahip bireylerden ve sağlıklı bireylerden kaydettikleri akciğer ses işaretlerini 15-20 sn süreli aralıklara örneklemiştir. Tesadüfî, beklenmedik seslerin (hırıltı ve çıtırtı) varlığını veya yokluğunu tahmin etmek için her bir aralıktan 1 solunum döngüsü seçerek döngülerin Fourier dönüşümü ile güç spektrum yoğunluklarını hesaplamışlar ve sınıflandırma işlemine tabi tutmuşlardır. İçer ve ark. (2014) normal akciğer seslerinden patolojik akciğer seslerinin çıtırtılarını ve ronküslerini ayırmak için çeşitli özellik çıkarma yöntemleri önermişlerdir. Bu yöntemler; 1) Welch metodu ile hesaplanan güç spektrum yoğunluklarının minimum ve maksimum frekans oranları. 2) Hilbert Huang Dönüşümü (HHT) tarafından hesaplanan ortalama anlık frekans ve anlık frekansın değişim zamanı. 3) Tekil spektrum analizi ile elde edilen öz değerler.

Serbes ve ark. (2013) çalışmalarında çıtırtıları tespit etmek için bir yöntem önermişlerdir. Bu yöntemde akciğer seslerinden zaman frekans ve zaman ölçek analiz yöntemlerini kullanarak çeşitli özellik setleri çıkarmışlardır. Farklı pencere ve dalgacık türlerinin kullanmanın çıtırtı tespitine etkilerini anlayabilmek için zaman frekans analizi için Gaussian, Blackman, Hanning, Hamming, Bartlett, Üçgen (Triangular) and Dikdörtgen (Rectangular) pencerelerini ve zaman ölçek analizi için Morlet, Mexican Hat and Paul dalgacık türlerini test etmişlerdir. Zaman frekans analizini pencerelenmiş Fourier dönüşümü ile gerçekleştirmişlerdir. Zaman ölçek analizini ise dalgacık dönüşümü kullanarak gerçekleştirmişlerdir. Munakata ve ark. (1992) solunum seslerinin HFD analizini ve zaman genişletilmiş dalga formu analizini gerçekleştirmişlerdir. Çalışmada ince ve kaba çıtırtılar incelenmiş ve ince çıtırtıların zirvelerinin ve maksimum frekanslarının kaba çıtırtılarınkinden daha yüksek olduğunu belirtilmiştir. Kandaswamy ve ark. (2004) kaydettikleri akciğer seslerinden hırıltı, çıtırtı, ısıklık (stridor), squawk, rhonchus anormal seslerini ayırmak için dalgacık dönüşümünü kullanılmışlardır. İlk olarak akciğer seslerini ayırık dalgacık dönüşümü ile frekans alt bantlarına ayırmışlardır. Daha sonra seçilen frekans alt bantlarından ses işaretlerini temsil edecek istatistiksel özellikler çıkararak sınıflandırma işlemine tabi tutmuşlardır.

Hernandez ve ark. (2005) çok kanallı olarak kaydettikleri normal ve anormal akciğer seslerinden özellik çıkarma amacıyla analizi için çok değişkenli AR model kullanmışlardır. Elde ettikleri özellik vektörlerinin boyutunun tekil değer ayrışımı ve

TBA kullanarak azaltmışlardır. Yi ve Caiming (2006) astım, pnömoni, bronşit hastalıklarına sahip ve sağlıklı bireylerin içerisinde bulunduğu 100 kişiye ait akciğer seslerinin analizi için seslere dalgacık dönüşümü uygulamışlardır. Villalabos ve ark. (2007) tarafından 4 sağlıklı ve 4 akciğer hastalığı bulunan 8 bayana ait akciğer seslerinin incelenmesi amacıyla Hilbert dönüşümü kullanılmıştır. Aka'nın (2006) yapmış olduğu çalışmada HFD ve kısa zamanlı Fourier dönüşümü teknikleri ile pnömoni ve hırıltılı akciğer seslerinin karakteristiklerinin elde edilmesi amaçlanmıştır. Pnömoni hastalığına sahip bireyin akciğer seslerinde anormal ses frekans aralığının 300 ve 600 Hz arasında olduğu saptanmıştır. Sankur ve ark. (1994) patolojik ve normal deneklerin solunum seslerinin analizini farklı derecelerde AR temelli yöntemler kullanarak gerçekleştirmişlerdir.

2.2.2. Kalp ses işaretleri

Kalp sesleri spektral analiz, parametrik ve parametrik olmayan zaman-frekans ayrışması ve akustik modelleme dâhil olmak üzere çeşitli sayısal işaret işleme teknikleri kullanılarak birçok çalışmada incelenmiştir.

Kalp seslerinin frekans bileşenleri, çeşitli kalp, kalp kapağı ve dolaşım sistemi hastalıklarının olası bir göstergesi olarak değerlendirilmektedir. Özellikle Fourier dönüşümüne dayalı ve parametrik modeller ile seslerin frekans bilgilerine dayanarak normal-anormal kalp seslerinin ayırt edilebilmesi ve bu sayede çeşitli kalp hastalıklarının teşhisi bilgisayar tabanlı ortamlarda rahatlıkla yapılabilmektedir. Spektral analiz, güç spektrum yoğunluğu, frekans dağılımı gibi terimler kalp seslerinin analizinde sıklıkla karşılaşılmaktadır. Arnot ve ark. (1984) 74 normal ve 7 hipertansiyonlu bireylerden kaydettikleri birinci (S1) ve ikinci (S2) kalp seslerinin analizini HFD kullanarak gerçekleştirmişlerdir. Araştırmacılar daha sonra cinsiyet, kan basıncı ve vücut yüzey alanı gibi istatistiksel özellikleri, kalp seslerinin frekans bileşenleri ile ilişkilendirmek ve bu sayede normal ve hipertansiyonlu bireylere ait kalp seslerini ayırt etmek için kullanmışlardır. Vücut yüzey alanı, cinsiyet, kan basıncı ve kalp sesleri frekans içeriği arasında gözlenen ilişkiler göstermiştir ki kalp boyutu arttıkça, 150 Hz üzerindeki frekans katsayıları genliği azalmaktadır. Çalışmada bu gözlemlerin S1 spektrumlarında S2 spektrumlarına göre daha belirgin olduğu belirtilmiştir. Ancak hipertansiyon hastalarında olduğu gibi kalp boyutunda önemli bir değişiklik olduğu zaman, eğilimlerin S2 spektrumlarında da olabileceği belirtilmiştir.

Elgendi ve ark. (2014) pulmoner arter hipertansiyona sahip çocuklar ile sağlıklı çocukları ayırt etmek için, ortalama yaş grubu 7 olan 27 erkek bireye ait kalp seslerinin spektral analizini gerçekleştirmişlerdir. Spektral analiz için HFD kullanmışlardır. Xin ve Zhong (1987) ARMA yöntemini normal ve 3 farklı kalp rahatsızlığı; mitral darlığı, mitral yetersizliği ve mitral darlığa ek üremisi olan bireylerin kalp seslerinin karakteristiklerini analiz etmek için kullanmışlardır. ARMA yöntemine ait belirli parametreler belirlemişlerdir. ARMA metodunun farklı kalp seslerini (S1, S2, S3, S4) ayırmada gayet başarılı olduğu çalışmada belirtilmiştir. Ergen (2010) kalp seslerinden kesin özellikleri elde edebilmek için doğrusallık incelenmesi gerçekleştirmiştir. Yapılan çalışmada, Fourier (ikiz spektrum) ve parametrik tabanlı (AR ve AR-HOS), güç ve yüksek dereceden elde edilen spektrumların karşılaştırmaları yapılarak doğrusallık analizi yapılmıştır. Sonuçlar kalp seslerinin doğrusal olmayan yapı sergilediğini göstermiştir. Debbal ve Requig (2006) kalp seslerinin spektral analizinin kardiyak hastalıklarının tanısı için yeterli olacak özellikler sağladığını belirtmişler ve HFD metodunu seslerin frekans içeriği hakkına bilgi elde etmek için kullanmışlardır. Amiri ve Armano (2013) yeni doğanlarda patolojik üfürümlü kalp seslerinden normal kalp seslerini ayırt etmek amacıyla Kepstrum Bispectrum ve Wigner Bispectrum tekniklerini kullanmışlar ve kullanılan teknikleri karşılaştırmışlardır. Araştırmacılar karşılaştırma sonucunda yüksek dereceli spektrum analiz yöntemlerinden olan Bispectrum ve Wigner Bispectrum yöntemlerinin daha iyi sonuçlar verdiğini belirtmişlerdir.

Kalp sesleri düşük frekanslı, durağan olmayan, çok bileşenli işaretlerdir ve zaman-frekans alanlarında eş zamanlı değişkenlik gösterirler. Bu nedenle ortak zaman frekans analiz teknikleri kalp seslerinin temsil edilmesinde yıllardır en çok kullanılan ve uygun teknikler haline gelmiştir (Amit ve ark., 2009). Kısa zamanlı Fourier dönüşümü, wigner – ville dağılımı, dalgacık dönüşümleri (sürekli, ayrık, ...) bu teknikler arasındadır. Amit ve ark. (2009) kalp seslerine segmentasyon işlemi uygulayarak S1 kalp seslerini elde etmişlerdir. Elde ettikleri S1 kalp seslerini zaman boyutunda, frekans boyutunda ve hem zaman hem de frekans boyutunda olmak üzere 3 şekilde karakterize etmişlerdir. İlk olarak sesleri zaman serileri olarak doğrudan karakterize etmişlerdir. İkinci olarak HFD uygulayarak seslerin spektral analiz ile frekans karakterlerini elde etmişlerdir. Son olarak kısa zamanlı Fourier dönüşümü, s dönüşümü, Wigner-Ville dağılımı, Choi Williams dağılımı ile seslerin zaman frekans ortak karakterizasyonu gerçekleştirilmiştir. Obaited (1993) kalp seslerinin analizi için kısa zamanlı Fourier dönüşümü, Wigner-Wile Dönüşümü ve dalgacık dönüşümünü kullanmıştır. Çalışmada

kısa zamanlı Fourier dönüşümünün birinci kalp sesinin 4 bileşenini hiç tespit edemediği ve ikinci kalp sesinin 2 bileşenini de tam olarak tespit edemediği belirtilmiştir. Araştırmacı, Wigner dağılımının kalp seslerine ait zaman-frekans bileşenlerini sağladığını ancak yeterli teşhis bilgisi vermediğini belirtmiştir. Ayrıca wigner dağılımı ile birinci kalp sesine ait 4 bileşenin tam olarak tespit edilemediğini, ikinci kalp sesine ait 2 bileşenin ise tek bir bileşen olarak görüldüğünü vurgulamıştır. Dalgacık dönüşümünün ise bütün bileşenleri tespit edebildiği ve diğer yöntemlerle kıyaslandığında kalp seslerine ait daha fazla özellik tanımladığı çalışmada sonuç olarak verilmiştir. Debbal ve Requig (2006) HFD metodunun yanı sıra kısa zamanlı Fourier dönüşümü, wigner dağılımı ve dalgacık dönüşümü kullanarak kalp seslerinin analizini gerçekleştirmişlerdir. Kao ve ark. (2009) kalp seslerini tek bir döngü içerecek şekilde döngüler haline ayırdıktan sonra kısa zamanlı Fourier dönüşümü ve otokorelasyon yöntemleri ile ses döngülerini analiz etmişlerdir. Debbal ve Requig (2004) 2. Kardiyak seslerine hızlı fourier ve sürekli dalgacık dönüşümlerini uygulamışlardır. Kamarulafizam ve ark. (2006) 100 normal bireyden ve 100 mitral yetersizliği, darlık gibi rahatsızlıkların da dahil olduğu çeşitli kalp rahatsızlıkları bulunan bireylerden kaydedilen kalp seslerinin hem zaman-frekans dağılım analizini hem de Mel Frekans Cepstrum Katsayısı frekans analizini gerçekleştirmişlerdir. Tekil değer ayrışımı ve TBA teknikleri ile seslere ait önemli özellikleri elde etmişlerdir. Rakovic ve ark. (2006) kısa zamanlı Fourier dönüşümü ile elde edilen spektrogram, Wigner dağılımı ve S metodunun içerisinde bulunduğu zaman frekans tekniklerinin kalp seslerinden hastalık teşhisi amacıyla kullanmışlardır. Çalışmanın sonucunda S metodunun kalp seslerinin analizinde ve mevcut tanı tekniklerinin geliştirilmesinde kullanılabileceği vurgulanmıştır. Dokur ve Ölmez (2008) ayrık dalgacık dönüşümünü pencerelenmiş tek döngü içeren kalp seslerine uygulamışlardır. Dalgacık dönüşümü hem S1-S2 kalp seslerinin segmentasyonunda hem de kalp seslerine ait özellikler çıkarmada kullanılmıştır. Dalgacık seviyesi 5 olarak belirlenmiştir. Araştırmacılar 5 frekans alt bantlarına ait detay katsayılarının güçleri özellik çıkarımı için kullanmışlardır. Sanei ve ark. (2011) tekil spektrum analizi ile tek kanallı kalp ses işaretlerinden üfürümleri ayırmışlardır. Wang ve ark. (2014) Optimum çok ölçekli paket dalgacık dönüşümü (OMS-WPD) ile 5 tür anormal ve normal kalp seslerini alt bantlara ayırarak analiz etmişlerdir. Daha sonra dalgacık zaman entropisi özellik çıkarma amacıyla alt bantlara uygulanmıştır.

2.2.3. Parkinson hastalığında konuşma ses işaretleri

Little ve ark. (2009) Parkinson hastalığı tarafından sebep olunan disfoni (ses bozukluğu) ölçerek hastalığın hangi aşamada olduğunu analiz etmeyi amaçlamışlardır. Çalışmalarında 23'ü Parkinson hastası olan 31 kişiden sürekli ünlü olan a sesini kaydetmişlerdir. Daha sonra hastalığın derecesini belirleyebilmek için kaydettikleri seslerden özellikler çıkararak disfoni ölçmüşlerdir.

Tsanas ve ark. (2010) Parkinson hastalığının ilerleme eğilimini tahmin etmek için konuşma verilerini kullanmışlardır. İşaret işleme algoritmalarını kullanarak seslere ait özellikler çıkarmışlar ve faydalı özellikleri tanımlamışlardır.

Khan ve ark. (2014) parkinson hastalarının klinik değerlendirilmesi için konuşma anlaşılabilirliğini bozan solunum, fonasyon, eklem gibi bütün konuşma bileşenlerini incelemişlerdir. Mel frekansları, cepstral katsayıları gibi ayırt edici özellikleri içeren 13 özellik seti her bir konuşma bileşeni için hesaplanmıştır.

Guerra ve Lovey (2003) dizartriya olarak bilinen nörolojik hastalıkları değerlendirmek için bu hastalığın 8 farklı türünü gösteren hastalardan kaydedilen konuşma seslerini hem sayısal işaret işleme yöntemleri ile hem de medikal kayıtlar ve klinisyenlerden alınan bilgiler ile değerlendirmişlerdir. Ses frekansı, konuşma üretimi sırasında seste ani ve kontrol edilemeyen varyasyonlar, seste titreme, aşırı gürültü (yüksek ses) varyasyonu, sert ses, nefes sesi, ses durması (stopaj) gibi nesnel özellikler ile klinisyenlerden edinilen özellikler sesleri değerlendirmek için kullanılmıştır.

Bocklet ve ark. (2011) seslerin ve konuşmaların parkinson hastalığından etkilenip etkilenmediğini tespit etmek amacıyla, sürekli fonasyonlar, hece tekrarları, metin okuma gibi farklı konuşma testleri üzerinde akustik özellikleri, aruz özellikleri ve vokal kıvrımların iki kitle modelinden türetilen özellikleri uygulamışlardır. Çalışmada en önemli özellikleri belirlemek amacıyla ilişki tabanlı özellik seçim metodu kullanılmıştır.

2.3. Sınıflandırma

Bilgisayar tabanlı ses analizinde YSA, K-NN, gizli markov modeli, gauss karışım modeli, genetik algoritmalar ve bulanık sınıflandırıcılar gibi makine öğrenmesi yöntemleri sıklıkla kullanılmaktadır (Palaniappan ve ark., 2013).

2.3.1. Akciğer ses işaretleri

Sankur ve ark. (1994) sağlıklı ve patolojik bireylere ait akciğer seslerinin analizini gerçekleştirdikten sonra sınıflandırıcı olarak K-NN ve quadratic algoritmalarını kullanmışlardır. K-NN ve quadratic sınıflandırıcılar ile %93.75 ve %87.50 sınıflandırma doğruluk oranları, %100 ve % 71,4 duyarlılık ve özgüllük oranları elde etmişlerdir. Forkheim ve ark. (1995) hırıltılı akciğer seslerini tespit etmek amacıyla sınıflandırıcı olarak radyal tabanlı sinir ağlarını kullanmışlardır. Sınıflandırma doğrulukları 1. ve 2. Eğitim setleri için %93 ve %96 olarak elde edilmiştir. Kahya ve ark. (1997) K-NN sınıflandırıcı kullanarak patolojik ve normal akciğer seslerini ayırt etmişlerdir. Çalışmada sınıflandırma doğruluğu %69.59 olarak bildirilmiştir. Alsmadi ve ark.(2008) K-NN ve minimum mesafe sınıflandırıcı algoritmalarını kullanarak normal ve anormal ses işaretlerini ayırt etmişlerdir. Çalışmada sınıflandırma işlemi sonrasında %96 sınıflandırma doğruluğu, %92 ve %100 duyarlılık ve özgüllük oranları elde edilmiştir.

Rietveld ve ark. (1999) normal, hırıltılı ve çıtırtılı akciğer ses işaretlerini YSA ile sınıflandırma işlemine tabi tutmuşlardır. Çalışmada sınıflandırma doğruluğu %95 olarak görülmüştür. Waitman ve ark. (2000) normal ve patolojik akciğer seslerinin sınıflandırılmasını YSA ile gerçekleştirmişlerdir. Eğitim seti için sınıflandırılma doğruluğu %91 test seti için ise %73 olarak belirtilmiştir. Çalışmada ki duyarlılık ve özgüllük oranları %87 ve %95 'tir. Kandaswamy ve ark. (2014) normal, hırıltı, çıtırtı, ısıklık (stridor) şeklindeki, squawk, rhonchus anormal seslerini ayırt etmek amacıyla YSA kullanmışlar ve eğitim seti için %100, test seti için %94.02 doğruluk oranları elde etmişlerdir. Güler ve ark. (2005) YSA ve genetik algoritma tabanlı yapay sinir ağları (GA-YSA) kullanarak normal, hırıltılı ve çıtırtılı akciğer ses işaretlerini sınıflandırmışlardır. Sınıflandırma doğrulukları YSA ve GA-YSA için sırasıyla %81-91 ve %83-93 olarak elde edilmiştir.

Bahoura ve Pelletier (2003) vektör kuantalama algoritmasını sınıflandırıcı olarak kullanarak hırıltılı ve hırıltılı olmayan akciğer seslerini birbirlerinden ayırt etmişlerdir. Hırıltılı ve hırıltılı olmayan akciğer ses işaretlerinin sınıflandırılma doğrulukları sırasıyla %75.80 ve %77.50 olarak belirtilmiştir.

Bahoura ve Pelletier (2004) normal ve hırıltılı akciğer seslerini gauss karışım modelleri kullanarak sınıflandırmışlardır. Gauss karışım modeli sınıflandırma algoritmasını vektör kuantalama ve çok katmanlı sinir ağları ile karşılaştırmışlar ve bu

sınıflandırıcının daha yüksek doğruluk oranları sağladığını ifade etmişlerdir. Lu ve Bahoura (2008) ince ve kaba çitirtılı akciğer ses işaretlerini gauss karışım modeli algoritmasını kullanarak sınıflandırma işlemine tabi tutmuşlardır. Araştırmacılar sınıflandırma doğruluğunu %95,1, duyarlılık ve özgüllük oranlarını ise %95,6 ve %63,3 olarak belirtmişlerdir.

Matsunaga ve ark. (2009) normal ve anormal akciğer seslerini sınıflandırmak amacıyla gizli markov modeli algoritmasını kullanmışlardır.

Zolnoori ve ark. (2010) bulanık sınıflandırıcıyı akciğer seslerine uygulayarak astım derecesini belirlemişlerdir.

Azarbarzin ve ark. (2010) akciğer seslerinin sınıflandırılması için k-ortalama kümeleme algoritmasını kullanmışlardır. Sınıflandırma işlemi sonucunda başarılı sonuçlar elde etmişlerdir.

Serbes ve ark. (2011) çitirtılı akciğer seslerini DVM sınıflandırıcı algoritması ile sınıflandırma işlemine tabi tutmuşlardır. Sonuç olarak %97.20 sınıflandırma doğruluğu elde etmişlerdir. Flietstra ve ark. (2011) Pnömoni ve Konjestif Kalp Yetmezliği bulunan bireylere ait akciğer seslerini analiz ettikten sonra DVM ile sınıflandırmışlardır. Pnömoni için %86, kalp yetmezliği için % 82 sınıflandırma doğrulukları elde etmişlerdir.

2.3.2. Kalp ses işaretleri

Güraksın ve Uğuz (2011) 3 tip kalp ses işaretlerinin analizi için ayrık dalgacık dönüşümü ve shannon entropi algoritmalarını kullandıktan sonra elde ettikleri özellik vektörlerini sınıflandırmak amacıyla en küçük kareler DVM algoritmasını kullanmışlardır. DVM ile %96 sınıflandırma performansı elde etmişlerdir. Alajarín ve ark. (2007) normal, holosistolik üfürümlü ve midsystolic üfürümlü 3 türdeki kardiyak seslerini Levenberg-Marquardt eğitim algoritması ile eğitilmiş çok katmanlı YSA ile sınıflandırmışlardır. Jia ve ark. (2012) temel olarak S1 ve S2 kalp seslerine odaklanarak normal ve anormal kalp seslerinin zaman domaininde analizini ve sınıflandırılması işlemlerini gerçekleştirmişlerdir. Sınıflandırma işlemi için yapısal öğrenme algoritması ile bulanık sinir ağını kullanmışlardır. Araştırmacılar sonuç olarak tüm test verilerinin doğru bir şekilde sınıflandırıldığını ifade etmişlerdir.

Hadi ve ark. (2010) 250 kardiyak peryodunu s dönüşümü ile analiz ettikten sonra çok katmanlı sinir ağı ile sınıflandırmışlardır. %98 üzerinde sınıflandırma doğruluğu

elde edilmiştir. Wang ve ark. (2014) normal ve anormal kalp seslerinden işaret işleme yöntemleri ile ses işaretlerine ait karakteristik özellikler elde etmişlerdir. Elde ettikleri özellikleri sınıflandırmak amacıyla DVM kullanmışlardır. Chebil ve Nabulsi (2007) ayrık dalgacık dönüşümünden sistolik kalp üfürümlerini, diyastolik kalp üfürümlerini ve normal kalp seslerini sınıflandırmak amacıyla faydalanmışlardır. Reed ve ark. (2004) önemli kalp hastalıklarına işaret eden semptomlarını kalp seslerinden belirlemek amacıyla 3 katmanlı sinir ağlarını sınıflandırıcı olarak kullanmışlardır. Ölmez ve Dokur (2003) kalp seslerine ait özellik vektörlerini sınıflandırmak amacıyla büyü ve öğren (GAL) sinir ağı ve lineer vektör quantalama (LVQ) sinir ağı algoritmalarını kullanmışlardır. Araştırmacılar sonuç olarak GAL ağının LVQ ağından daha başarılı sonuçlar verdiğini belirtmişlerdir. Vepa (2009) üfürümleri tespit etmek amacıyla kalp seslerinden elde ettiği özellikleri sınıflandırmak amacıyla 3 tür algoritma kullanmışlardır. Bu algoritmalar; K-NN, çok katmanlı sinir ağları ve DVM'dir. Çalışmada en iyi sınıflandırıcının %95 doğruluk oranı ile DVM olduğu vurgulanmıştır. Zawbaa ve ark. (2012) sağlıklı ve 4 farklı kalp rahatsızlığı (aort darlığı, aort yetmezliği, mitral darlık ve mitral yetersizlik) olan bireylere ait kalp seslerinden ikili parçacık sürü algoritması ile en önemli özellikleri çıkarmışlardır. Bu işlemi takiben ilk olarak DVM ile sesleri normal ve anormal olarak sınıflandırmışlardır. Daha sonra anormal sesleri yine DVM kullanarak aort darlığı, aort yetmezliği, mitral darlık ve mitral yetersizlik olarak 4 sınıfa ayırmışlardır.

Safara ve ark. (2013) online kaynaklardan ve eğitim CD'lerinden topladıkları normal ve 4 farklı anormal kalp seslerine paket dalgacık dönüşümü uygulamışlardır. Ardından, özellik vektörleri türetmek için trapezoidal fonksiyon hesaplanmıştır. Çalışmada özellik vektörlerini sınıflandırmak için çok katmanlı YSA, K-NN ve DVM algoritmalarının bulunduğu karma bir sınıflandırıcı oluşturulmuştur. Abbas ve ark. (2008) Debauchies ve Meyer dalgacık dönüşümleri ve ardından istatistiksel işlemler ile kalp seslerinden tanımlayıcı özellikler elde etmişlerdir. Elde edilen özellikleri sınıflandırmak amacıyla bulanık sınıflandırıcı kullanmışlardır. Leung ve ark.(2000) patolojik ve patolojik olmayan kalp seslerinden çıkardıkları özellikleri sınıflandırmak amacıyla olasılıklı sinir ağı kullanmışlardır. Gupta ve ark. (2005) kalp seslerine ayrık dalgacık dönüşümü ve ardından TBA algoritmalarını uygulayarak seslere ait tanımlayıcı özellikler çıkarmışlardır. Elde edilen özellikleri ve çok katmanlı geri yayımlı YSA kullanarak kalp seslerini normal, sistolik üfürüm ve diyastolik üfürüm olmak üzere 3 ayrı kategoriye sınıflandırmışlardır. %94.5 doğru sınıflandırma oranı elde etmişlerdir.

2.3.3. Parkinson Hastalığında Konuşma ses işaretleri

Parkinson hastalarına ait seslerin sınıflandırılması için yapılan birçok çalışmada DVM kullanılmıştır (Little ve ark., 2009; Sakar ve Kursun, 2010; Kursun ve ark., 2012).

Little ve ark. (2009) normal ve parkinson hastalığı olan bireylerden kaydettikleri sürekli ünlü olan a seslerinden çıkarttıkları özellikleri DVM kullanarak sınıflandırma işlemine tabi tutmuşlardır. %91.4 doğruluk oranı ile parkinson hastalığının derecesini belirlemişlerdir.

Khan ve ark. (2014) 60 parkinson hastası bireyden 20 sağlıklı bireyden kaydettikleri seslerden çıkardıkları özellikleri sınıflandırmak amacıyla DVM kullanmışlardır. Konuşma örnekleri birleşik parkinson hastalığı derecelendirme ölçeği (UPDRS Unified Parkinson's Disease Rating Scale) kullanılarak değerlendirilmiştir. DVM sınıflandırma algoritması ile UPDRS'nin 3. derecesi için %85, 2. derecesi için %92 doğruluk oranı elde edilmiştir.


Guerra ve Lovey (2003) lineer ayırt edilebilirlik analizi ve lineer olmayan yöntemler ile iki farklı sınıflandırmayı konuşmaya etki eden dizartriya hastalığının değerlendirilmesi için kullanmışlardır. Çalışmaya göre lineer olmayan sınıflandırıcı daha yüksek sınıflandırma doğruluk oranı üretmiş ve hastalıkla ilgili özelliklere ait daha doğru bilgiler vermiştir.

Bocklet ve ark. (2011) normal ve parkinson hastalarından kaydettikleri seslerden elde ettikleri özellikleri sınıflandırma amacıyla DVM'den faydalanmışlardır. 3 ayrı kategoride (aruz modelleme, akustik modelleme, vokal modelleme) seslerden özellikler çıkarmışlar ve hepsine ayrı ayrı sınıflandırma işlemi uygulamışlardır. Aruz modelleme ile Parkinson hastalığının erken dönemlerindeki kişiler ile normal kişileri % 91 oranında konuşmalarından tanıma sonuçlarını, akustik modelleme ile % 88 oranında tanıma sonuçlarını ve vokal modelleme % 79 oranında tanıma sonuçlarını elde ettiklerini ifade etmişlerdir.

3. BİYOMEDİKAL SESLER

3.1. Akciğerlerin Yapısı ve Çalışması


Akciğerler solunum sisteminin en önemli organlarından biridir. Göğüs boşluğu içerisinde sağda ve solda olmak üzere 2 adet akciğer bulunur. Akciğerler kalp ile birlikte göğüs boşluğunu doldurmaktadırlar (Koyuncu, 2014). Sağdaki akciğer birbirlerinden zarla ayrılmış 3 loba, soldaki akciğer ise 2 adet loba sahiptir. Soldaki akciğerde 2 lob bulunmasının nedeni göğüs boşluğunda bulunan kalbin sol akciğerin 3. lobunun yerini almış olmasındandır (Özdoğan, 2014). Bundan dolayı sağ akciğerin büyüklüğü sol akciğerden yaklaşık olarak %10 daha fazladır. Sağ ve sol akciğerler ve sahip oldukları loblar Şekil 3.1’de gösterilmektedir.



Şekil 3.1. Sağ ve sol akciğerler (Anonim, 2014)

Akciğerlerin içi bir ağaç yapısına benzer. Üst göğüs boşluğundan gelen soluk borusu (trakea) her iki akciğere doğru olmak üzere bronşlar adı verilen 2 ana hava kanalına ayrılır (Ateş, 2009). Akciğerlerin içinde bronş adı verilen kanallar yeniden birkaç kez dallanarak daha ince yapıdaki kanallara ayrışır (Ateş, 2009). Bu ince yapıdaki kanallar bronşçuk olarak adlandırılır. Bronşçuklar etrafı kan hücreleri ile ağ gibi çevrili üzüm salkımına benzer şekilde kümelenmiş olan küçük hava keseciklerinde son bulur (Ateş, 2009). Alveol olarak bilinen bu hava keseciklerinden her akciğerde yaklaşık 300 milyon tane vardır (Temel Britannica, cilt:1 1992). Akciğerlerde bulunan

milyonlarca alveol, solunum yüzeyini artırarak yaklaşık 70-100m²lik bir alan oluşmasını sağlar (Akkaya ve ark., 2013). Bu geniş yüzey sayesinde akciğerler oksijeni emip karbon dioksiti atma işlevini yerine getirebilirler (Temel Britannica, cilt:1 1992). Şekil 3.2 akciğerlerin genel yapısını göstermektedir (Sayn, 2014).



Şekil 3.2. Akciğerlerin yapısı (Sayn, 2014)


Akciğerler solunum sistemi içerisinde temel olan iki görevi yerine getirirler. Bu görevlerden ilki dışarıdaki havayı soluk alma yoluyla vücuda almasıdır. Akciğerlerin ikinci görevi ise hava içindeki oksijenin alveollerin etrafındaki kılcal kan damarlarına geçmesini ve organlardan venöz kanla gelen karbondioksitin alveollere alınıp soluk verme yoluyla dışarı atılmasını sağlamasıdır (Yıldız, 2012).

Burun ve ağız yoluyla vücuda alınan hava, nefes borusu adı verilen esnek bir borudan geçerek akciğerlere ulaşır. Nefes borusu, akciğerlerde bronşlara ve daha küçük olan bronşiyollere ayrılır ve alveol denilen hava keselerinde sonlanır. Alveoller etrafını saran kan damarları tarafından bol kanla beslenir. Alveol çeperlerinden oksijen ve karbondioksit serbestçe geçer (Arslan, 2013).

Soluk alma (inspirasyon) ve verme (ekspirasyon) iki şekilde gerçekleşir. Göğüs kafesi, kaburgalara ve omurgaya bağlı kaslarla birlikte genişler; genişlemeye bağlı olarak akciğerlerin içindeki basınç azalır ve hava akımı başlar, hava içeri girer

(inspirasyon). Kaslar gevşeyince göğüs kafesi daralır, akciğerlerde bulunan hava dışarı atılmaya zorlanır (ekspirasyon) (Arslan, 2013).

Şekil 3.3'te açıklandığı gibi solunum sürekli bir döngü içerisinde gerçekleşir (Güçlü, 2010).



Şekil 3.3. Solunum döngüsü (Güçlü, 2010)

3.2. Akciğer Sesleri

Solunum veya nefes sesleri olarak da bilinen akciğer sesleri havanın bronşiyal ağaç üzerindeki hareketi ile oluşan seslerdir. Türbülans tarafından oluşturulan hava akımındaki dalgalanmalar, girdaplar ve doku yapılarının salınımları akciğerler içerisindeki hava akışını duyabilmemize olanak sağlarlar. Hava akışı kritik bir hıza ulaştığı zaman türbülans meydana gelir ve akış içerisindeki parçacıkların sıralı düzeni bozulur. Bu parçacıkların rastgele hareketi çarpışan moleküller arasında enerji transferi ve geçici basınç dalgaları ile sonuçlanır. Hava basıncındaki değişiklikler, her biri kendilerine özgü genlik ve frekanslara sahip sesler oluşturur (Güler ve ark., 2005).

Akciğer sesleri stetoskop ile vücudun belirli bölgelerinden dinlenebilirler. Bu işlem oskültasyon olarak adlandırılır.

Genel olarak oskültasyon ile dinlenen akciğer sesleri normal ve anormal akciğer sesleri olmak üzere 2 gruba ayrılır.


3.2.1. Normal akciğer sesleri

Sağlıklı akciğer dokuları tarafından, nefes alma ve nefes verme sırasında üretilen seslerdir (Bahoura, 2009). Normal solunum sesinde nefes alma (inspirasyon) sesi, nefes verme (ekspirasyon) sesine oranla daha şiddetli, daha tiz ve daha uzun sürelidir (Güler ve ark. 2005). Normal solunum sesleri duyulma yerlerine bağlı olarak veziküler, trekeal, bronşial ve bronkoveziküler sesler olmak üzere ayrıştırılabilir (Bahoura, 2009).

Sağlıklı kişilerde akciğer parankimi üzeri dinlendiğinde yumuşak, boğuk ses duyulur. Bu sesler “veziküler solunum sesleri” olarak bilinir, bronşial solunum sesine göre frekansı ve yoğunluğu düşüktür, çok kısa ekspirasyon komponenti ile inspirasyon sırasında duyulur (Yıldırım, 2011).

Sağlıklı kişilerde trakea üzerinde duyulan tübüler kalitedeki ve kaba sesler “bronşial ya da trakeal solunum sesleri” olarak bilinir. Bronşial solunum sesinin ekspirasyon komponenti, inspirasyon komponentine eşit ya da daha uzun, yüksek frekanslı ve şiddetli bir sestir (Yıldırım, 2011).

Sırtta skapulalar arasında ve önde sternum üst yarısı civarında (1 ve 2. kot aralıklarında) duyulan ses “bronkoveziküler solunum sesi”dir. Bu sesler bronşial solunum sesleri kadar güçlü değildir, frekansı daha düşüktür, inspirasyon ve ekspirasyon komponentleri eşittir. Bu sesin çıkış yeri ana bronşlar ve karinaya yakın kısımlarıdır (Yıldırım, 2011). Oskültasyonla dinlenen normal sesler ve dinlenilme bölgeleri Şekil 3.4’te gösterilmektedir (Noall, 2011).



Şekil 3.4. Oskültasyonda duyulan normal sesler ve dinlenilme bölgeleri (Noall, 2011)

3.2.2. Anormal akciğer sesleri

Akciğerlerdeki havanın hareketine bağlı olarak çıkan anormal solunum seslerine “ek solunum sesleri” denir. Çoğunlukla ek solunum sesleri hırıltılar (wheeze) ve ronküsler gibi kesintisiz ya da ince ve kaba çıtırtılar gibi kesintili sesler olarak sınıflandırılır (İçer ve Gengeç, 2014). Kesintisiz akciğer sesleri 25 milisaniyeden daha uzun süren seslerdir. Kesintili akciğer seslerinin özelliği ise aralıklı, kısa süren çıtırtı şeklinde seslerdir ve süresi genellikle 20 milisaniyeden daha kısadır (Yıldırım, 2011).

Sibilan ronküsler: Sibilan ral, wheezing, sibilan ronküs ya da hırıltılı solunum olarak adlandırılırlar. Havanın iyice daralmış soluk yollarından geçerken oluşturduğu yüksek frekanslı seslerdir. 100 ms’den daha uzundur (Bahoura, 2009), 100-2500 Hz frekans aralığında bulunurlar ve baskın frekansları 100 Hz-1000 Hz aralığındadır (Grung ve ark., 2011). Bu tür anormal seslerin varlığı akciğerlerde kısmi veya şiddetli hava yolu tıkanıklığı ile ilişkilidir (Riella ve ark., 2009). Soluk alma ve soluk verme aşamalarının ikisinde de meydana gelir. Bu yüksek frekanslı ses, astım krizi, anaflaktik şok vb gibi bronkospazma neden olan durumlarda oluşur.

Ronküsler: Gürültülü, kaba, düşük frekanslı, horlama sesine benzeyen, hem soluk alma hem de soluk verme sırasında duyulan kesintisiz seslerdir Baskın frekansları 200 Hz ve altında olan 100 ms’den daha uzun süreli olan sestir (Korono ve ark., 1998; Xavier ve ark. 2014). Büyük çaplı bronşların akut veya kronik iltihaplanması, tümör, düz kas spazmı ya da mukus birikimi sebebiyle tıkanmış bronşlardan soluk alıp verirken çıkan ek solunum sesidir.


Çıtırtılı sesler/Raller (Crackles): Sınırlı ve süreksiz seslerdir. Genellikle nefes alırken veya bazı durumlarda nefes verirken duyulan seslerdir ve genellikle 10ms’den kısadırlar. 200 Hz ve 2000 Hz arasında bulunurlar. Farklı rahatsızlıklar için çıtırtıların karakteristikleri, sayıları ve zamanları farklılıklar gösterebilmektedir. İnce, Orta ve kaba çıtırtılar olmak üzere 3 grupta incelenebilirler. İnce çıtırtılar nefes almanın sonunda duyulan kısa süreli yüksek volumlü seslerdir. Orta çıtırtılar ince çıtırtılarla birlikte bulunurlar, nefes almanın ortasında bulunan daha düşük frekanslı seslerdir Kaba çıtırtılar ise nefes almanın başında duyulur. Kaba çıtırtılar ince çıtırtılara göre daha seslidir ve daha uzun sürelidir, büyük hava yollarındaki sekresyonlara bağlıdır (Korono ve ark., 1998). Bronşit, pnömoni ve pulmoner fibrozis gibi akciğer patolojilerinde duyulabilir (İçer ve Gengeç, 2014).

Stridor: Islığa benzer, kaba, yüksek frekanslı ek solunum sesleridir. Trekea veya gırtlığın yarı tıkanıklığından dolayı oluşan türbülans hava akımı stridor ek sesini meydana getirir. Çoğunlukla nefes alma esnasında duyulur. 1000 Hz civarındaki önemli zirvelerle temsil edilirler (Kandaswamy ve ark., 2004).

Plevral sürtünme (Frotman): Plevranın inflamasyonu sonucu plevral sıvının azalması ya da kaybolması sonucu yaprakların birbiri üzerinde sürtünmesinden çıkan sestir (Güven, 2011). Frotman sesi pnömönide duyulabilir.

3.3. Akciğer Hastalıkları


Astım: Havayollarının yani bronşların daralması ile kendini gösteren akciğer hastalığıdır (Kala, 2013). Çeşitli alerjik reaksiyona neden olan maddeler, sigara dumanı, egzersiz, soğuk havaya maruz kalma, duygusal faktörler gibi etkenler astım hastalığının oluşması için tetikleyici bir görev üstlenirler. Astım hastalığına sahip kişilerde nefes darlığı, öksürük, hışıltılı (hırıltılı) solunum veya bazen de daha müzikal karakterde ısıklık ya da düdük sesine benzer bir sesin duyulur. Hastalığın ayrıca güçlükle balgam çıkarma, göğüste sıkışıklık hissi gibi belirtileri de vardır ve bu belirtilerin şiddeti hastadan hastaya büyük oranda değişiklik gösterebilir (Çağlayan, 2014). Normal ve astımlı akciğer yapısı Şekil 3.5’de gösterilmektedir.



Şekil 3.5. Normal ve astımlı akciğer yapısı (Anonim, 2011)

Kronik Obsr ktif Akci er Hastalığı (KOA ): KOA  zararlı gaz ve partik llerin, aşırsı sigara kullanımının ve kirli havanın neden olduėu tıkalıcı ve ilerleyici akci er hastalığıdır. Nefes verme sırasında havayollarında meydana gelen   kme ve aşırsı bronşial ifrazat havayollarında daralmaya neden olarak hava akımını kısıtlamakta ve bu olay s rekli olarak şiddetini arttırarak hastanın yaşıam kalitesinde bozulmaya yol a maktadır. KOA 'ta havayollarında meydana gelen deėişikler s rekli ilerleyici karakterdedir ve geri d n ş ms zdir. Bu hastalık başladı mı geriye d n ş  yoktur. Mutlaka ilerleme g sterir.  l mle sonu lanabilir. American Thoracic Society'nin tanımına g re KOA , kronik bronşit ve amfizeme baėlı hava akımı kısıtlaması ile karakterize edilir. Bu 2 hastalığın akci erde yerleştii alan ve yapmış oldukları kalıcı deėişiklikler farklı tipte olmakla beraber KOA , genellikle kronik bronşit ve amfizemin deėişik oranlarda birlikteliėi ile karakterizedir. Hastalığın erken d nemlerde fark edilmemesi durumunda hastalık ilerler ve  ks r k, balgam, hırıltılı solunum, nefes darlığı gibi şikayetler ortaya  ıkar ( aėlayan, 2014).

Amfizem: American Thoracic Society'nin tanımlamasına g re amfizem akci erin en u  noktalarında yer alan ve atmosfer havasından Oksijenin alınıp kandaki Karbon dioksitin havaya verilmesini saėlayan alveollerin anormal şekilde olan kalıcı genişılemesidir (Şekil 3.6) ( aėlayan, 2014).



Şekil 3.6. Amfizem ( aėlayan, 2014)

Bronşit: Bronşların  eşitli fakt rlere ve nedenlere baėlı olarak iltihaplanmasına bronşit denir. Akut bronşit ve kronik bronşit olmak  zere ikiye ayrılır (Engin, 2011).

- I. *Akut Bronşit*: Genellikle solunum yollarında virüs veya enfeksiyondan meydana gelen bir hastalıktır. Genellikle bronşlarda şişme ve balgam artışı şeklinde görülen belirtileri vardır (Engin, 2011).
- II. *Kronik Bronşit*: Akciğerleri soluk borusuna bağlayan bronşların iltihaplanmasıdır (Anonim, 2005). Bronşların iltihaplanması sonucu, akciğerlere giren ve çıkan hava akışı azalır ve akciğerler mukus veya salya üretmeye başlar. Ardışık iki yıl içerisinde üç aya kadar çıkan bir süre zarfında günlerin çoğunluğunda öksürük oluşturan mukus üretimi söz konusu ise bu durum kronik bronşit olarak değerlendirilir. Bu çeşit bronşitte, havayollarını yağlama görevini yerine getiren bezler büyümüş ve iç yüzlerinde bulunan tüyler görevini yapamaz olmuştur. Hastalığın en sık görülen ve en önemli belirtisi uzun süren öksürük ve balgam çıkarmadır. Bronşlarda daralma mevcuttur. Nefes almada güçlük çekilir. Nefes alıp verirken, kişinin solunumunda hırıltı duyulur (Anonim, 2010).

Pnömoni (Zatürre): Genellikle zatürre olarak bilinen, tıbbi adı pnömoni olan hastalık bakteri, virüs ve nadiren de olsa parazitlerin neden olduğu akciğer enfeksiyonu olarak tanımlanır. Akciğerde meydana gelen bu enfeksiyon, alveol adı verilen küçük hava keseciklerine iltihap birikmesine ve yine bu alana kan damarlarından gelen serumun dolmasına neden olur. İçleri serum sıvısı ve iltihap hücreleri ile dolan alveoller solunum işlevlerini yerine getiremez hale gelirler. Eğer pnömoni yaygın ise hastada solunum yetersizliği görülebilir. Pnömonide genellikle yüksek ateş, boğaz ağrısı, titreme, hızlı ve hırıltılı soluk alıp verme, halsizlik, öksürük, balgam çıkarma, nefes almakla batıcı tarzda göğüs ağrısı ve hastalığın ciddiyeti ile ilişkili olarak nefes darlığı, siyanoz gibi belirtiler ortaya çıkar (Çağlayan, 2014).

3.4. Kalbin Yapısı ve Çalışması

Kalp, göğüs kafesinin iki akciğeri birbirinden ayıran orta boşluğunda ve sol tarafta bulunan, kaslardan oluşan dolaşım sisteminin en önemli organıdır. Kalbin yapısını da (Şahin, 2014);

- ✓ Kaslar
- ✓ Sinirler
- ✓ Kapakçıklar

- ✓ Kan Damarları
- ✓ Koruyucu Zar
- ✓ Kaygan sıvı

bulunur. Kalp birbirinin benzeri ve sıkıca birbirine kaynaşmış dört bölümden oluşur. Üst kısımda olup toplardamarların açıldığı boşluklara atrium (kulakçık), alt kısımda olup kanı vücudumuza pompalayan boşluklara ise ventrikül (karıncık) adı verilir (Dursun, 2014).


Kalp de yer alan karıncıkların oldukça sağlam kalın çeperleri mevcuttur ve bunlar uçları aşağıya doğru bakan koniler şeklindedir (Güler, 2013). Kulakçıklar ise ince çeperli ve küp biçimindedirler (Güler, 2013). Karıncıklara atardamarlar, kulakçıklara ise toplardamarlar bağlıdır. Kulakçıklar emici bir yapı gibi çalışırlar. Akciğer ve diğer organlardan kalbe kan alır ve karıncıklara iletirler. Karıncıklar ise pompa gibi çalışırlar. Kalpteki kanı akciğerlere ve diğer organlara gönderirler. (Şahin, 2014)

Kalpte iki adet atrioventriküler kapak, iki adet de büyük damar kapakları (semilunar kapak) olmak üzere 4 kapakçık bulunmaktadır. Kulakçıklar ile karıncıklar arasında ve karıncıklar ile buradan çıkan damarlar arasında kapaklar bulunur. Kapakçıkların amacı kanakışının tek yönlü ilerlemesini sağlamak ve kanın geriye dönüşünü engellemektir (Kaptanoğlu, 2014).

Kalp kapakçıkları (Kaptanoğlu, 2014);


- ✓ *Triküspid kapakçık*: Sağ kulakçık ile sağ karıncık arasında bulunur.
- ✓ *Pulmoner kapakçık*: Sağ karıncık ile pulmoner arter (akciğer arteri) arasında bulunan kalp kapakçığıdır. Bu kapakçık sağ karıncıktan pompalanan kanın geri dönüşünü engeller ve üç adet yarım ay şeklindedir.
- ✓ *Mitral kapakçık*: Sol karıncık ve sol kulakçık arasında bulunur.
- ✓ *Aort kapakçığı*: Sol karıncık ile aort arasında bulunur. Bu kapaklar sol karıncıktan pompalanan kanın geri dönüşünü engeller.

Şekil 3.7’de kalbin anatomik yapısı gösterilmektedir (Kazaz, 2014).



Şekil 3.7. Kalbin anatomik yapısı (Kazaz, 2014)

Her iki kulakçık (atrium) çıkarıldıktan sonra kalp kapaklarının üstten görünüşü Şekil 3.8’de görülmektedir (Alpman, 2012).



Şekil 3.8. Kalp kapaklarının üstten görünüşü (Alpman, 2012)

Şekil 3.8’de sol tarafta mitral ve triküspit kapaklar açık, aort ve pulmoner kapaklar ise kapalı halde, sağda ise mitral ve triküspit kapaklar kapalı, aort ve pulmoner kapaklar ise açık halde görülmektedir (Alpman, 2012).

Herhangi bir kalp kasının (karıncıkların ya da kulakçıkların) kasılması aşaması sistol, gevşeme aşaması ise diyastol olarak adlandırılır.

Vücutta kalbin temel eleman olarak görev aldığı iki çeşit dolaşımdan bahsedilir (Açıkel, 2013).

Küçük dolaşım, kanın akciğerler vasıtasıyla oksijenlenmesini sağlar. Organlar tarafından oksijeni kullanılan kan, vena cava inferior ve vena cava superior adı verilen büyük toplardamarlar ile sağ atriüme gelir. Sağ atrium dolduğunda, kasılarak (sistol) kanın triküspid kapakçıktan sağ ventriküle geçmesini sağlar, sağ ventrikülün de kasılmasıyla pulmoner kapakçıktan geçen kan pulmoner artere (akciğer atardamarı) pompalanır. Akciğerlere gelen pulmoner arter, arteriol adı verilen küçük kılcal damarlara ayrılarak kanın temizlenme işleminin gerçekleşeceği alveol denilen hava keseciklerine ulaşır. Kan burada oksijen bakımından zenginleştirilir (Açıkel, 2013).

Büyük dolaşım, akciğerde oksijen yönünden zengin hale gelen kanı organların kullanması için vücuda gönderilmesini sağlar. O₂ taşıyan kan, kılcal damarların birleşerek oluşturduğu pulmoner venler aracılığıyla kalbin sol atrium bölümüne ulaşır. Sol atriumun kasılmasıyla mitral kapakçıktan geçerek, sol ventriküle dolan kan, mitral kapağın kapanması ve aort kapakçığının açılarak kanın aorta pompalanmasıyla vücuda gönderilir. Aynı anda kalbin diğer yarısında pulmoner kapakçık da açılarak, sağ ventriküldeki venöz kan pulmoner atardamara pompalanır (Açıkel, 2013).

Kalbin her vuruşunda iki kulakçık birden kasılarak karıncıklara kan pompalar. Bunu, karıncıkların birlikte kasılması izler. Bu kasılmalar dizisini çok karmaşık bir elektriksel zamanlama sistemi düzenler. Kalbin çalışmasını denetleyen asıl nokta, sağ kulakçığın üstünde yer alan ve “sino-atrial düğüm” adı verilen odaktır. Buradan yayılan elektriksel uyarı kulakçıklara ulaştığında onların kasılmasına neden olur. Kulakçıklarla karıncıkların birleştiği noktada ise atrioventriküler düğüm bulur. Kasılma uyarısı burada hafif bir gecikmeye uğradıktan sonra “his demeti” adı verilen iletken lif demeti boyunca önce karıncıklar arası bölmeye, sonra da karıncıklara yayılıp, kasılmalarını sağlar (Güler, 2013).


3.5. Kalp Sesleri

Kalbin çalışması sırasında kalp kapakçıklarının açılıp kapanması (mekanik hareketler) ve kanın akciğerler ve bedene pompalanması esnasında meydana gelen seslerdir. Kalp sesleri stetoskop yardımıyla göğüs duvarından dinlenebilirler.

Kalp seslerinin dinleme odakları (Soner, 1979; Binak ve ark., 1991; Bates, 1979);

- ✓ *Mitral (apikal) odak*: Mid-klavikular vertikal (klavikulanın orta hat) çizgisinin sol 5. interkostal aralığı (kaburgalar arası) kestiği bölge mitral (apikal) odaktır. Mitral kapağa ait üfürümler, hasta hafif sola dönük ve nefes alma esnasında dinlenirse daha rahat duyulur (Soner, 1979; Binak ve ark., 1991; Bates, 1979).
- ✓ *Triküspid odak*: 5. interkostal aralığın, göğüs kemiğinin (sternumun) sol kenarıyla birleştiği bölgedir. Triküspid odağı nefes alma esnasında dinlenirse sesler daha rahat duyulur (Soner, 1979; Binak ve ark., 1991; Bates, 1979).
- ✓ *Aort odağı*: Sağ ikinci interkostal aralığın, göğüs kemiğinin sağ kenarıyla birleştiği bölgedir. Aortla ilgili üfürümler en iyi bu bölgede duyuluyorsa da, bazen apekten, sternumun sol kenarından hatta karotid arterlerin bulunduğu bölgeden de güçlü duyulabilir. Hasta biraz öne eğik ve soluk verirken en iyi dinleme sağlanır (Soner, 1979; Binak ve ark., 1991; Bates, 1979).
- ✓ *Pulmoner odak*: Sol 2. interkostal aralığın, göğüs kemiğinin sol kısmı ile birleştiği bölgedir. Üfürümler en güçlü nefes alma esnasında duyulur (Soner, 1979; Binak ve ark., 1991; Bates, 1979).
- ✓ *Erb's point (mezokardiyak odak) :* Göğüs kemiğinin solunda 3. interkostal aralıktadır. Aort ve pulmonalis yetmezliğinin en iyi duyulduğu yerdir (Soner, 1979; Binak ve ark., 1991; Bates, 1979).


Bu odaklar kalp kapaklarının anatomik olarak bulundukları bölgeler değildir. Odaklar kapaklardan geçen kanın akışı yönündedir. Kalp sesleri dinleme odakları Şekil 3.9'daki gibidir.



Şekil 3.9. Kalp sesleri dinleme odakları (Soner, 1979; Binak ve ark., 1991; Bates, 1979)

3.5.1. Normal kalp sesleri

Normal bir kalbin her bir atımı sırasında, kalp kapakçıklarından kanın geçmesiyle temel olarak iki ses üretilir. Bu sesler “lub-dub” şeklinde duyulur. "lub" duyulan ilk sestir ve yaygın olarak S1 olarak kullanılır ve sistol başlangıcında mitral ve trikuspit kapakların kapanmasının neden olduğu titreşimlerden kaynaklanır. İkinci kalp sesi "dub" olarak duyulur ve S2 olarak adlandırılır. S2, sistol sonunda aortik ve pulmonik kapakların kapanmasından kaynaklanır (Phua ve ark., 2008). Bu nedenle birinci kalp sesi ile ikinci ses arasındaki geçen süre sistolu (ventriküler ejeksiyon) ve ikinci ses ile ardından gelen birinci ses arasında geçen süre diyastolu (ventriküler dolmayı) belirler (Amiri ve Armano, 2013). Şekil 3.10’da S1 ve S2 kalp sesleri gösterilmektedir. Normal kalp sesleri genellikle 20-200Hz frekans aralığında bulunurlar (Choi ve Jiang, 2010). S1 ve S2 kalp sesleri 2 temel bileşenden oluşurlar. Mitral ve trikuspit kapakların kapanmasından dolayı S1’in bileşenleri M1 ve T1’dir. S2’nin bileşenleri aort ve pulmoner kapakların kapanmasından dolayı A2 ve P2’dir (Debbal ve Reguig, 2007).



Şekil 3.10. S1 ve S2 normal kalp sesleri (Phua ve ark., 2008)

3.5.2. Anormal (Patolojik/Ek) kalp sesleri


S1 ve S2'ye ek olarak üçüncü (S3) ve dördüncü kalp sesi (S4) belirlenir. S3 ve S4 normal kişilerde görülebilir veya patolojik süreçlerle ilişkilendirilebilir. Ritmik sıra veya ritmik zamanlamadan dolayı S3 ve S4'e gallop adı verilir. Galloplar S1 ve S2'den daha düşük olan, düşük frekanslı seslerdir. Galloplar en iyi, steteskopun çanı hafifçe cildin üzerindeyken dinlenir. Çanı sert bastırmak genellikle gallopların iletiminin, işitme eşiğinin altına inmesine neden olur (Murphy ve ark., 2002).

S3 kalp sesi hasta sol yan yattığında steteskobun çan kısmı ile mitral odaktan dinlenir. S2 den sonra sol ventriküler yetmezlikte duyulan bu sese ventriküler gallop da denir. Atriumlardan kan ventriküle hızla atılırken içerde kalan volüme çarpar ve dolgun bir ses oluşur (Soner, 1979; Binak ve ark., 1991; Bates, 1979).

Erken diyastolik dolma ile ilişkilendirilen gallop S3 gallopudur. S3, S2'den 0.13 ile 0.18 saniye sonra görülür (Murphy ve ark., 2002).

S4 atriyal kasılma ile ilişkilendirilen bir geç diyastolik sestir. En iyi mitral odaktan ve S1 den hemen önce duyulur. Karıncıklar dolu iken basınç kulakçıklara yayılır. Bu basınç kulakçıklardaki kanı dalgalandırır, duyulan bu dalgalanma sesi S4'tür. Bu sese atrial gallop da denir (Murphy ve ark., 2002). Akut myokard infarktüsüne bağlı gelişir (Soner, 1979; Binak ve ark., 1991; Bates, 1979). S4 koroner arterlerdeki bir hastalık, atrioventriküler yetmezlik, kontrolsüz hipertansiyon, aort ve pulmoner darlık gibi patolojik durumlarla ilişkilendirilebilir.

S3 ve S4 kalp seslerine örnekler Şekil 3.11'de görülmektedir.



Şekil 3.11. S3 ve S4 normal kalp sesleri (Murphy ve ark., 2002).

Açılma Sesi (Opening Snap): Mitral ve triküspid kapakların açılması sırasında duyulan, S2'den kısa bir süre sonra ortaya çıkan klik sesidir (Reed ve ark., 2004). Bu ses sağlıklı bireylerde duyulmaz.

Ejeksiyon sesi (Ej): Kanın karıncıklardan aorta veya pulmoner artere ejeksiyonu sonucu oluşur. S1'den hemen sonra duyulan, S2'den önce sonlanan yüksek perdeden bir sestir. Aort ve pulmoner darlıkla, aort koartasyonu ve atrial septal defekt ile ilgilidir (Erbaş, 2014).

Midsistolik klik: Mitral kapak prolapsusunu gösterir (Gülgün ve arkd., 2013). Sistol evresinin geç bölümlerinde görülebileceği gibi, birden fazla sayıda da olabilir.

Üfürümler: Kalp üfürümleri kan akış türbülansından ve anormal girdaplardan kaynaklanır (Soner, 1979; Binak ve ark., 1991; Bates, 1979). Kan, dar ya da düzensiz kapaktan geçerken girdap oluşur.

- 1- Kanın akış yönündeki lezyondan dolayı, kan akışının bozulması
 - 2- Kanın akışı yönünde etraftaki yapıların ve fiziksel değişikliklerin neden olduğu titreşimler
 - 3- Kanın dar bir aralıktan geçmesi
 - 4- Kanın dar olmayan fakat pürüzlü bir kapak sistemi içinden geçmesi
 - 5- Normal bir kapak sistemi içinden geçen kan akımının hızlanması
 - 6- Dar bir yerden geniş bir sisteme geçmesi
- girdaba yol açar ve üfürümler duyulur (Soner, 1979; Binak ve ark., 1991; Bates, 1979).

Üfürümler iki kalp atışı arasında duyulan yüksek frekanslı, gürültü benzeri seslerdir. Bir kalp üfürümünün patolojik bir önemi olmayabilir veya kalpte yapısal anormallikler bulunduğu dair önemli bir ipucu olabilir. Kalp üfürüm değerlendirmesi kalp çevrimindeki zamanlama, şekil, konum, yayılma, ton, yoğunluk ve süreye bağlıdır. (Sanei ve ark., 2011)

Üfürümler bir periyod içerisinde sistol veya diyastol evrelerinde erken, orta, geç ya da holosistolik olarak bulunabilirler.

Sistolik Üfürümler: Erken sistolik üfürüm, S1 ile veya S1'den hemen sonra başlar ve sistolün ortasında (midsistolde) sonlanır (Erbaş, 2014). Küçük ventrikül septum defektinde erken sistolik üfürüm işitilir (Erbaş, 2014). Midsistolik üfürüm, S1'den daha sonra başlar ve S2'den önce sonlanır. Geç sistolik üfürüm, midsistolde başlar, S2'ye kadar devam eder ve aort koarktasyonunda geç sistolik üfürüm işitilir (Erbaş, 2014). Holosistolik üfürüm, tüm sistol boyunca yer alır ve S1 ve S2'nin zayıflamasına neden olur.

Diyastolik Üfürümler: Erken diyastolik üfürüm, S2 ile başlar. Bu ses yüksek frekanslıdır, aort ve pulmoner kapak yetersizliklerinde duyulur (Erbaş, 2014). Middiyastolik üfürüm, S2'den sonra başlar ve S1'den önce son bulur. S2 ile bu üfürüm arasında kısa bir zaman aralığı vardır (Erbaş, 2014). Alçak frekanslı, kalın, kaba üfürümlerdir, mitral ve triküspid kapak darlıklarında işitilir (Erbaş, 2014). Geç diyastolik üfürüm, S1'den hemen önce biter. Kısa süreli ve gürültülü bir üfürümdür. Daha sık mitral darlıkta duyulur (Erbaş, 2014).

Mitral Stenozu (Mitral Darlığı): Kanın sol kulakçıktan sağ kuakçığa geçmesini sağlayan ve geri dönmesini önleyen mitral kapakçığın daralması sonucunda oluşur (Alpman, 2012). Diyastolde açılma sesinin yanısıra middiyastolik ve presistolik olmak üzere iki çeşit üfürüm bulunmaktadır.

Aort Stenozu (Aort Darlığı): Aort darlığı, normalde tamamen açılarak kanın ileri doğru gitmesine izin veren aort kapağının, çeşitli nedenlerle daralarak kanı ileri doğru geçişine engel oluşturmaktadır (Alpman, 2012). Aort kapak alan 1 cm^2 'nin altına indiği zaman kanın sol karıncıktan aorta geçişinde önemli güçlük ortaya çıkar (Alpman, 2012). Sistolde, aortik ejeksiyon ve orta dereceden elmas şeklinde bir ses, diyastolde ise S4 ek sesi bulunmaktadır.

Atrial Septal Defekt (ASD): Atrial septal defekt (ASD), sağ ve sol atriumlar arasındaki septumun tam olarak kapanmaması ile karakterize, sık görülen bir doğumsal kalp hastalığıdır. Pulmoner odakta sistolik üfürüm ve ikinci kalp sesinde sabit çiftleşme duyulur (Canbaz, 2006).

Ventricular Septal Defekt (VSD): Kalbin sağ ve sol karıncıkları arasındaki duvarda bir açıklık (delik) olmasıdır (Reed ve ark., 2004). Bu açıklık vasıtasıyla oksijen bakımından zengin kan ile venöz birbrine karışır (Reed ve ark., 2004). Ventricular septal defect üfürümünde, mitral yetmezliğin üfürümüne benzer şekilde holosistolik bir üfürüm ve yüksek sesli pansistolik üfürüm duyulur. Ayrıca S3 ve middiyastolik bir üfürümde duyulabilir (Reed ve ark., 2004).

Patent Ductus Ateriosus (PDA): Aort ve sol pulmoner arter arasındaki fetal dönemde açık olması normal olan kanalın, kalıcı olarak açık kalması nedeniyle oluşur. Sistolde ve diyastolde üfürüm bulunmaktadır (Semizel, 2011).


3.6. Konuşma Sesleri ve Parkinson Hastalığı

Konuşma, çeşitli organlarımızın ortaklaşa işleyerek ürettikleri seslerden ya da sesbirimlerinden oluşan hecelerle ve bunlardan oluşan sözcüklerle sağlanır. Bu organlar gırtlak, boğaz, ağız, geniz ve burun boşluklarıdır. Soluk borusunun üst bölümünde yer alan ve solunum aygıtının bir parçası olan ses aygıtı solukla çalışır. Ses aygıtımızda içten dışa doğru ses telleri, gırtlak kapağı, küçükdil, dil ve dudaklar yer alır. Akciğerlerden başlayıp dudaklarda son bulan bu organların tümüne "ses yolu" denir (Temel Britannica, cilt:10 1992).

Sesin oluşması için, havaya ve titreşime gereksinim vardır. İnsan sesinin oluşumunu, akciğerlerden gelen havanın ses yolunda herhangi bir engelle karşılaşmadan akışı ve ses tellerinin titreşimi sağlamaktadır (Vardar ve ark., 1980). Akciğerler solunum havasını gırtlığa doğru iterler. Gırtlaktaki ses tellerinin arasından geçen hava ses oluşturur. Oluşan ses ağız boşluğu, dil, dişler, burun boşluğu ve sinüsler aracılığı ile konuşma halini alır (Temel Britannica, cilt:10 1992).

Şekil 3.12’de konuşma organları gösterilmektedir (Altun, 2014).

Konuşmanın gerçekleşebilmesi için gerekli olan solunum, ses üretimi ve ses iletim (artikülasyon) sistemlerinin hepsi kaslar tarafından çalışmaktadır. Bu görevi yerine getiren kaslar da beyni tarafından kontrol edilmektedir (Ertan, 2001).



Şekil 3.12. Konuşma organları (Altun, 2014)

Parkinson hastalığı (PH) merkezi sinir sisteminin nörodejeneratif bozukluğudur (Jankovic, 2007;Sakar ve ark., 2013). Parkinson hastalığında uzuvlarda görülen titreme, azalmış hareket, kaslarda sertlik gibi değişiklikler aynı zamanda konuşma, ses ve yutma sistemlerinde de ortaya çıkabilir. Hastalığın erken belirtilerinden biri olan ses ve konuşmadaki değişiklikler, sıklıkla iletişim problemlerine neden olmaktadır (Ertan, 2001).

Beyindeki hasara bağlı olarak kas kontrolü ve konuşma mekanizmasındaki yetersizliklerle karakterize konuşma bozukluklarına "dysarthrias" (dizarthri) denir (Ertan, 2001).

Dizartri, solunumu, ses üretimini ve dudaklar, dil, çene, yumuşak damak gibi ses iletimini sağlayan yapıları etkiler. Sekiz çeşit dizartri vardır ve bunlardan bir tanesi Parkinson hastalığının sebep olduğu "hypokinetik dysarthrias" (hareket başlangıcında sorunlar ve/veya anormal yavaş hareket ile karakterize dizartri)' dir (Ertan, 2001).

Parkinson hastalığı olan bireylerde konuşurken;

- Karşısındakine sesi duyuramama ya da kalabalık ortamlarda konuşmada zorluk
- Seste normalde var olması gereken iniş çıkışların kaybolması
- Hep aynı şiddette konuşma, seste şiddet değişiminin olmaması, şiddette azalma
- Uzun yersiz sessizlikler
- Yavaş hızla birlikte zorlamalı konuşma
- Mimiklerin kaybolması
- Konuşmanın anlaşılabilirliğinde azalma, artikülasyonda sorun

görülebilir (Ertan, 2001).

4. MATERYAL VE YÖNTEMLER

4.1. Biyomedikal Ses Verileri

Tez çalışmasında kullanılan akciğer ses verileri, Yalova Üniversitesi, Mühendislik Fakültesi Bilgisayar Müh. Bölümünde görevli Arş. Gör. Güneş Harman'dan temin edilmiştir.


Akciğer ses verileri sağlıklı ve çeşitli patolojik akciğer hastalıklarına sahip 15 bireye ait verilerdir. Sağlıklı olmayan bireyler kronik obstrüktif akciğer hastalığı (KOAH), farklı düzeylerde astım (başlangıç seviyesinde, orta seviyede ve ileri seviyede), ve pnömoni rahatsızlıklarına sahiptirler.

Göğsün sağ ve sol bölgelerinden dinlenmelerine göre her bir bireye ait 2 adet akciğer ses işareti bulunmaktadır. 8 kHz, 16 bit örnekleme oranlı seslerin süreleri 10-14 saniye arasında değişmektedir ve sesler birden fazla solunum döngüsüne sahiptir.

Tez çalışmasında kullanılan kalp ses verileri, Celal Bayar Üniversitesi, Mühendislik Fakültesi Elektrik Elektronik Müh. Bölümünde görevli olan Yrd. Doç. Dr. Yücel Koçyiğit 'ten temin edilmiştir.

44100 Hz örnekleme frekanslı ve 14-15 sn. süreli 9 farklı türde kalp sesi tez çalışmasında kullanılacaktır. Kullanılacak kalp sesleri; Normal kalp sesleri (birinci S1 ve ikinci S2), üçüncü kalp sesi(S3), dördüncü kalp sesi(S4), açılma sesi, midsistolik klik + geç sistolik üfürüm, aort stenozu, atriyal septal defekt, ventriküler septal defekt, patent duktus arteriyozus. Şekil 4.1 'de tez çalışmasında kullanılacak kalp sesleri gösterilmektedir (Kocyiğit, 2014).

Tez çalışmasında kullanılan özellikleri çıkarılmış Parkinson konuşma ses verileri, UCI Makine Öğrenme ve Akıllı Sistemler Araştırma Merkezi ücretsiz veri tabanından temin edilmiştir.



Şekil 4.1. Dokuz farklı kalp sesinin bir periyodu (Kocayigit, 2014)


4.2. Ön İşlemler

Akciğer seslerinin kendisine karışmış olan kalp, kas ve diğer (istenilmeyen) seslerden dolayı analizi ve sınıflandırılması kaliteli ve nesnel sonuçlar üretemeyecektir. Ayrıca literatür çalışmaları incelendiğinde akciğer ses işaretlerinin 100-2000Hz frekans aralığında olduğu görülmüştür. Bu frekans aralıkları dışında kalan alçak ve yüksek frekans bileşenleri analiz ve sınıflandırma işlemi için faydalı bilgiler sağlamamaktadır. Bu nedenle akciğer seslerinin istenmeyen gürültülerden ve gereksiz frekans bileşenlerden arındırılması gerekmektedir. Bu amaçla genellikle yüksek, alçak ve bant geçiren filtreler kullanılmaktadır.

Tez çalışmasında analizi ve sınıflandırılması yapılan akciğer seslerine 100 Hz ve altındaki sesleri süzmek için yüksek geçiren, 2000 Hz üstündeki sesleri süzmek için ise alçak geçiren filtre uygulanmıştır. Analog olarak süzülen sesler 200. mertebeden bant geçiren FIR filtresinden geçirilmiş ve sayısallaştırılmıştır. Filtreleme işleminin ardından, ses işaretleri solunum döngüsünün nefes alma ve verme aşamalarının başlangıç ve bitiş zamanlarına göre nefes alma ve nefes verme olarak ayrıştırılmıştır ve gruplandırılmıştır.

Akciğer seslerinin analiz aşamasına geçilmeden önce her bir ses işareti solunum döngüsünün yalnızca 1 nefes alma veya 1 nefes verme aşamasını içerecek şekilde segmentlere ayrılmıştır. Analiz ve sınıflandırılma aşamalarında her bir ses segmenti ayrı bir örüntü olarak değerlendirilmiştir.

Kalp ses işaretleri genellikle 20-600 Hz frekans bant aralıklarında bulunmaktadır. Şekil 4.2, kardiyovasküler seslerin frekans karakteristiklerini göstermektedir (Choi ve Jiang, 2010). Normal kalp sesleri 20-200 Hz frekans aralığında bulunurken, kalp üfürümleri genellikle 30-600/700 Hz frekans aralığı boyunca dağılmış durumdadırlar (Choi ve Jiang, 2005; Bhatikar ve ark. 2005; Jiang ve Choi 2006; Choi ve Jiang 2008). Tez çalışmasında kullanılan kalp seslerine 20-600 Hz arasındaki frekans bileşenlerini süzen 3. dereceden butterworth bant geçiren filtre uygulanmıştır. Filtreleme işleminden sonra, 9 farklı kalp sesi, kalp atışının tam bir döngüsünü içerecek şekilde daha küçük süreli segmentlere ayrılmıştır.



Şekil 4.2. Kardiyovasküler ses frekansları (Choi ve Jiang, 2010)

4.3. Sayısal İşaret İşleme Yöntemleri

4.3.1. Parametrik olmayan yöntem: Fourier dönüşümü

Fourier dönüşümü ses işaretlerinin frekans bileşenleri hakkında bilgi sağlamak için uzun zamanlardır yoğunlukla kullanılan spektral analiz metodudur (Grung ve ark., 2011).

1882’de Joseph Fourier tarafından bulunan bu dönüşüm ile her işaret, farklı genlik, frekans ve faz değerlerine sahip kosinüs ve sinüs işaretlerinin bileşimi şeklinde ifade edilebilir. Böylece k uzayında tanımlı bir işaret, Fourier Dönüşümü alınarak, içerdiği frekans bileşenleri ve ağırlıkları cinsinden tanımlanma imkânına sahip olur. (Abacı, 2012).

Fourier dönüşümü ile hem işlem kolaylığı hem de k uzayında tanımlı bir işaretin farklı bir uzayda tanımlı hale getirilmesi ile direk olarak görmemizin mümkün olmadığı bileşenlerin dönüşümü alınarak görülebilmesi sağlanır. İşlem kolaylığına, zaman domeninde konvolüsyon işleminin Fourier dönüşümü ile cebirsel çarpma işlemine dönüşmesi örnek olarak verilebilir.

Fourier dönüşümü sürekli Fourier dönüşümü, ayrık Fourier (AFD) dönüşümü, hızlı Fourier dönüşümü (HFD), kısa zamanlı Fourier dönüşümü gibi alt (KZFD) başlıklar altında incelenmektedir. Ancak Fourier dönüşümü genellikle hızlı Fourier dönüşümü olarak kullanılır ve yorumlanır (Debbal, 2008).

Fourier dönüşümü matematiksel olarak denklem 4.1’deki gibi ifade edilir (Abacı, 2012).

$$\begin{aligned} X(f) &= \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \\ x(t) &= \int_{-\infty}^{\infty} X(f)e^{-j2\pi ft} df \end{aligned} \quad (4.1)$$

Denklemden $x(t)$ Fourier dönüşümü alınacak işaret, $X(f)$ ise Fourier dönüşümü alınmış işarettir (Abacı, 2012). t ve f sırasıyla zaman ve frekans uzaylarıdır. Fourier dönüşümü ile zaman (t) uzayındaki bir nesne frekans (f) uzayında tanımlanmıştır. Bu dönüşüm sayesinde t uzayındaki diferansiyel denklemler f uzayında lineer denklemler olarak ifade edilirler. f uzayında bu denklemin çözümü bulunduktan sonra ters dönüşümle t uzayındaki karşılığı elde edilir. Denklemden de görüldüğü üzere işlemlerde bir süreklilik söz konusudur ve bu Fourier dönüşümü sürekli Fourier dönüşümü olarak isimlendirilir.

Sürekli bir dönüşüm ve sonsuz uzunluklu bir integrali bilgisayar programına dönüştürmek imkânsızdır. Bunun için sürekli Fourier dönüşümü ayrıklaştırılarak ayrık Fourier dönüşümü (DFT: Discrete Fourier Transform) geliştirilmiştir.

AFD metodunda, sürekli Fourier dönüşüm metodundan farklı olarak integral yerine toplam sembolü kullanılmış ve sonsuz uzunluklu dönüşüm, işaretin uzunluğu ile sınırlandırılmıştır (Abacı, 2012). AFD'nin matematiksel formülü denklem 4.2'deki gibidir.

$$X(k) = \sum_{n=1}^{N-1} x(n) e^{-j2\pi nk/N} \quad (4.2)$$

$$W = e^{-2j\pi/N} \quad (4.3)$$

Denklem 4.2, denklem 4.4'teki gibi yeniden yazılabilir.

$$X(k) = \sum_{n=1}^N x(n) W^{-nk} \quad (4.4)$$

$X(k)$ ayrık Fourier katsayıları, N elde edilen verinin uzunluğu ve $x(n)$ zaman alanındaki giriş işaretidir (Bayrakçı ve ark., 2008).

AFD hesaplamasında her bir $X(k)$ değeri için N adet karmaşık çarpma (dört gerçel çarpma ve iki gerçel toplama işlemi) ve $N-1$ adet karmaşık toplama (iki gerçel toplama) işlemi yapılmaktadır. Bundan dolayı N adet AFD değeri bulunurken, N^2 adet çarpma ve $N(N-1)$ adet toplama işlemi gereklidir. Sonuç olarak, veri (işaret/sinyal) uzunluğu olan N 'nin büyük olması durumunda AFD'nin doğrudan bulunması çok fazla miktarda işlem yapılmasını gerektirir. N sayısı ne kadar artarsa yapılan işlem sayısı da o hızla artmakta ve işlem sayısı kabul edilemez bir seviyeye doğru gitmektedir (Baykut, 2011; Cooley ve Tukey, 1965). 1965 yılında Cooley ve Tukey AFD işlemi üzerinde çeşitli matematiksel kısaltmalar ve dönüşümler uygulayarak hızlı Fourier dönüşüm (HFD) algoritmasını üretmişlerdir.

Sürekli, ayrık gibi Fourier dönüşümleri ile işaretin yalnızca frekans uzayındaki bileşenleri hakkında bilgiler edinilebilir. İşaretin zaman uzayındaki durumu hakkında bir bilgi edinilemez. Bu nedenle Kısa Zamanlı Fourier Dönüşümü (KZFD) geliştirilmiştir. Kısa Zamanlı Fourier Dönüşümü zamanda kayan bir pencere yardımıyla bölütlenen işaretin Fourier dönüşümü alınarak elde edilmektedir (Polat ve ark., 2003). KZFD de ise işaretin zaman ve frekans uzayında yorumu sağlanır. KZFD'nin matematiksel temsili (Debbal, 2008);

$$X(t, f) = \int_{-\infty}^{\infty} x(\tau) w(\tau - t) e^{-j2\pi n k / N} d\tau \quad (4.5)$$

$w(\tau - t)$, $x(\tau)$ işaretine uygulanan kayan pencereyi, f frekansı, t zamanı temsil etmektedir (Debbal, 2008).

Ses işaretlerinin frekans özelliklerini temsil etmek için genellikle Fourier dönüşümleri ile seslerin güç spektrumları bulunmaktadır (Qiu, 2003). Güç spektrumlarından çıkarılan frekans ve genlik bilgileri ses işaretlerine ait öznelilikler olarak kabul edilmekte ve sınıflandırıcılara girdi olarak verilmektedirler. Bunun yanı sıra, frekansların medyanı (Anderson ve ark., 1990; Spence ve ark. 1992; Malmberg ve ark. 1994; 1995; Sovijarvi ve ark. 1996; Fiz ve ark. 1999), maksimumu, (Lenclud ve ark., 1996; Gross ve ark., 2000), spektrum regresyon çizgilerinin eğimleri (Gavriely ve ark., 1984; Gavriely ve ark., 1995) gibi sesleri karakterize eden özellikler spektrumlardan çıkarılarak analiz için kullanılmaktadırlar (Qiu, 2003).

4.3.1.1. Hızlı Fourier dönüşümü ile güç spektrum kestirimi

Güç spektrum kestirimi, işaret frekansının üzerinden güç tespiti ve spektrum bilgisi edinmedir (Seçen, 2013). Güç spektrum yoğunluğu, işaretin frekans bandı üzerindeki güç dağılımı olarak düşünülebilir.

Welch metodu en sık kullanılan klasik spektral analiz yöntemlerinden olup, hızlı Fourier dönüşümü temelli, iyileştirilmiş periodogramların ortalamasının alınmasına dayanır. (Güler ve ark., 2005; Alkan, 2006).

Periodogramın iyileştirilmiş yapısı Welch tarafından önerilmiş olup, bu yöntem işareti üst üste çakışabilecek bölümlere ayırır. Daha sonra da her bölümün iyileştirilmiş periodogramı alınıp, elde edilen bu bölümlere ait periodogramların ortalaması alınır (Alkan, 2006). Welch metodunda işaret $x(n)$, D nokta üst üste binecek şekilde M uzunluktaki K bölüme ayrılır (Vaseghi, 2000).

i. bölüm;

$$x_i(n) = x(n + iD), n = 0, \dots, M - 1, i = 0, \dots, K - 1 \quad (4.6)$$

ile ifade edilir (Vaseghi, 2000).

i. iyileştirilmiş periodogram denklem 4.7'deki gibi elde edilir (Vaseghi, 2000).

$$P(w, i) = \frac{1}{MU} \left| x_i(n)w(n)e^{-2jfn} \right|^2 \quad (4.7)$$

$W(n)$ pencereleme fonksiyonu, U ise pencereleme fonksiyonu içerisindeki güçtür. U ;

$$U = \frac{1}{M} \left[\sum_{n=1}^{L-1} w^2(n) \right] \quad (4.8)$$

şeklinde temsil edilir (Vaseghi, 2000).

Sonuç olarak denklem 4.9'da görüldüğü gibi Welch metodu ile güç spektrum kestirimi pencerelenmiş bölümlerin iyileştirilmiş periodogramların ortalaması alınarak elde edilir (Vaseghi, 2000).

$$PSX(w) = \frac{1}{K} \sum_{i=1}^K P(w, i) \quad (4.9)$$

4.3.2. Parametrik Yöntemler

Fourier dönüşümü tabanlı yöntemler yaygın olarak kullanılmasına rağmen performans yönünden bazı kısıtlamalara sahiptir. Bu matotların varyansları yüksektir ve ayrıca Fourier dönüşümünü frekans çözünürlüğü işaretin karakteristiğinden bağımsız olarak elde edilen işaretin uzunluğu ile sınırlıdır. Bu olumsuzluklarla birlikte, pencerelenmeden kaynaklanan bozulmuş spektrum kestirimi elde edilir. Fourier Dönüşümü yapısı gereği 10ms üzerindeki işaretlerde iyi bir spektral çözünürlük yakalayamaz. Bu nedenle bu süreyi aşan işaretlerde iyi bir çözünürlük yakalayabilmek için işaretin durağan (stabil) hale getirilmesi gerekir ki bu da aynı zamanda işaretin parametrik hale gelmesi demektir. Fourier dönüşüm matotlarının bu dezavantajları nedeniyle özbağlanım (autoregressive, AR), hareketli ortalama (moving average, MA), özbağlanımlı hareketli ortalama (autoregressive moving average, ARMA) gibi parametrik spektral analiz yöntemleri işaret analizinde önemli bir yer edinirler. (Ubeyli ve ark., 2003; Rao ve ark., 1988)

4.3.2.1. AR (otoregresif / özbağlanım) yöntemi

AR yöntemi bir zaman serisinin herhangi bir dönemindeki gözlem değerlerini, aynı serinin ondan önceki belirli sayıda dönemin gözlem değerlerine ve hata terimine bağlı olarak açıklayan modeldir. Örneğin özbağlanım (AR) metodunda işarete ait belli bir andaki genliği elde etmek için, o ana kadar örneklenmiş bölümlerin genlikleri farklı oranlarda toplanır ve bu toplama bir tahmin hatası eklenir. Bu işlem denklem 4.10'daki gibi formülize edilir.

AR yönteminde işaret, tüm-kutup veya IIR (Sonsuz Darbe Cevaplı), girişi beyaz gürültü olan ayırık filtrenin çıkışı olarak modellenir (Acharya ve ark., 2008).

AR yöntemi içerdiği geçmiş dönem gözlem değeri sayısına göre isimlendirilir. Mesela AR(4) 4 tane geçmiş dönem gözlem değeri içerir ve 4. dereceden otoregresif modeli olarak isimlendirilir. Bu yöntem denklem 4.10'daki gibi temsil edilir (Acharya ve ark., 2008).

$$x(n) = -\sum_{k=1}^p a(k)x(n-k) + e(n) \quad (4.10)$$

$a(k)$ AR metot katsayılarını (parametreler) temsil ederken, $e(n)$ hata terimini (beyaz gürültü) temsil eder.

AR parametreleri Burg, Yule Walker vb. gibi farklı tahmin teknikleri ile tahmin edilebilmektedir (Kay ve Marple, 1981; Waitkus ve ark., 1988; Übeyli ve Güler, 2004).

AR yöntemi ile güç spektrum yoğunluğu matematiksel olarak denklem 4.11'de görüldüğü gibi ifade edilir (Acharya ve ark., 2008).

$$P_{AR}(f) = \frac{\sigma^2}{|A(f)|^2} \quad (4.11)$$

$$A(f) = 1 + a_1 e^{-j2\pi f} + \dots + a_p e^{-j2\pi fp}$$

Denklem 4.11 yeniden formülize edilirse güç spektrum yoğunluğu;

$$P_{AR}(f) = \frac{\sigma^2}{\left| 1 + \sum_{k=1}^p a(k) e^{-j2\pi fk} \right|^2} \quad (4.12)$$

olarak ifade edilir (Acharya ve ark., 2008).

Burg tekniği sık kullanılan ve etkili sonuçlar üreten AR yöntemlerinden biridir (Ubeyli ve Güler, 2003). Bu yöntem temel olarak ileri ve geri tahmin hatalarının minimize edilmesi prensibine dayanır. Burg yöntemi ile AR güç spektrum yoğunluğu denklem 4.13 deki gibi hesaplanır (Acharya ve ark., 2008).

$$P_{BURG}(f) = \frac{e_p}{\left| 1 + \sum_{k=1}^p a(k) e^{-j2\pi f k} \right|^2} \quad (4.13)$$

e_p toplam en az karesel hatayı gösterir. Toplam en az karesel hata, ileri ve geri tahmin hatalarının toplamıdır.

4.3.2.2. MA (hareketli ortalamalar) yöntemi

Bir zaman serisinin (işaretin) herhangi bir dönemindeki gözlem değerlerini aynı dönemdeki hata terimine ve ondan önceki belirli sayıda dönemin hata terimine bağlı olarak açıklayan yöntemdir. Denklem 4.14'deki gibi formülize edilir.

MA metodunda işaret, girişi beyaz gürültü olan tüm-sıfır ayırık filtrenin çıkışı olarak modellenir (Ubeyli ve Güler, 2003; Acharya ve ark., 2008) .

$$x(n) = e(t) \sum_{k=1}^q \theta(k) + e(t-k) \quad (4.14)$$

$\theta(k)$ MA yöntemine ait parametreleri, e ise hata terimini temsil etmektedir. MA yöntemi ile güç spektrum yoğunluğu;

$$P_{MA} = \sum_{k=-q}^q \theta(k) e^{-j2\pi f k} \quad (4.15)$$

olarak ifade edilir (Acharya ve ark., 2008).

4.3.2.3. ARMA (özbağlanım hareketli ortalamalar) yöntemi

Özbağlanım (AR) ve hareketli ortalamalar (MA) yöntemlerinin kombinasyonudur. Bu yöntemde bir zaman serisinin herhangi bir dönemine ait gözlem değeri, ondan önceki belirli sayıdaki gözlem değerinin ve hata teriminin doğrusal bir birleşimi olarak ifade edilir. ARMA yöntemi ile işaret girişi beyaz Gauss gürültü olan nedensel, kutup-sıfır, ayrık filtrenin çıkışı olarak modellenir (Übeyli ve Güler, 2004).

p. dereceden AR ve q. Dereceden MA modelinin birleşimi sonucu ARMA yöntemi, ARMA (p,q) şeklinde ifade edilir. (p,q)'uncu dereceden ARMA yönteminin denklemi şu şekilde ifade edilir:

$$x(n) = -\sum_{k=1}^p a(k)x(n-k) + \sum_{k=0}^q \theta(k)e(n-k) \quad (4.16)$$

ARMA yöntemi ile güç spektrum kestirimi denklem 4.17 'deki gibi ifade edilir.

$$P_{ARMA} = \frac{P_{MA}(f)}{P_{AR}(f)} \quad (4.17)$$

Denklem açık şekliyle yeniden ifade edilecek olursa denklem 4.18 elde edilir (Acharya ve ark., 2008).

$$P_{ARMA} = \frac{\sum_{k=-q}^p \theta(k)e^{-2jfk}}{\left| 1 + \sum_{k=1}^p a(k)e^{-j2pfk} \right|^2} \quad (4.18)$$

Frekans spektrumunda ani, keskin tepeler olan işaretler için AR yönteminin, keskin tepeleri bulunmayan işaretler için ise MA yönteminin kullanılması uygundur. ARMA yöntemi ise her iki tip işaret için de kullanılabilir. Ses işaretleri ani tepeleri olan işaretler olduğundan AR yönteminin veya ARMA yönteminin ses işaretlerinin analizinde kullanımı daha uygundur ve yaygındır. AR yöntemi işlem yükü açısından, ARMA'ya nazaran daha avantajlıdır.

Parametrik yöntemler kullanılırken ses işaretleri, güç spektrumu, işaretin tepe frekansı, band genişliği veya güç içeriği gibi bir dizi parametre ile özetlenebilir.

4.3.3. Dalgacık dönüşümleri

Biyomedikal ses işaretlerinin durağan, lineer ve periyodik olmayan doğası nedeniyle, sesler Fourier dönüşümü ve AR gibi parametrik yöntemlerle analize çok da uygun değildirler. Dalgacık dönüşümlerinin geliştirilmesiyle birlikte ses işaretleri gibi durağan olmayan işaretlerin kısmi spektral ve zamansal bilgileri elde edilmektedir (Sello ve ark., 2008; Marshall ve Boussakta, 2007). Dalgacık dönüşümleri ses işaretlerini hem zaman hem de frekans boyutunda tanımlar ve seslerin zaman-frekans dağılımları hakkında bilgiler sağlar (Marshall ve Boussakta, 2007). Bu nedenle yıllardır biyomedikal seslerin analizinde sürekli dalgacık, ayrık dalgacık, paket dalgacık gibi dönüşüm yöntemleri kullanılmaktadır.

1909 yılında Alfred Haar dalgacık ifadesini ilk defa gündeme getirmiştir (Kakilli ve ark., 2005). Zaman içerisinde Jean Marlet ile Y. Meyer ve arkadaşları yöntemi geliştirmişler ve 1988 yılında Stephane Mallat önemli katkılar sağlamıştır. Daha ilerleyen zamanlarda Ingrid Daubechies, Ronald Coifman gibi uluslararası araştırmacılar bu yöntemi daha da geliştirerek bugünkü şekline getirmişlerdir (Erdoğan ve Pekçakar, 2009).

Dalgacık dönüşümü işareti (işaret, görüntü vb.) temel yapı taşlarına ayırarak işareti hem zaman hem de frekans alanında ifade eder (Li ve ark., 1995).

Sürekli dalgacık dönüşümü Fourier dönüşümünün genelleştirilmiş halidir. Sürekli dalgacık dönüşümünde, işaret ile ilgili birçok detay verildiğinden ve hesaplamada bütün ölçekler kullanıldığından bu dönüşümün hesaplama yükü, karmaşıklığı ve zamanı fazladır (Bayhan ve Yılmaz, 2009).

Sürekli dalgacık dönüşümünün hesap yükünü azaltmak için Ayrık Dalgacık Dönüşümü geliştirilmiştir.

4.3.3.1. Ayrık dalgacık dönüşümü (ADD)

ADD yönteminin temelini oluşturan esas, ana işaretin yüksek ve alçak geçiren filtrelerden geçirilerek alt bileşenlere ayrılma işlemidir (Tawade ve ark. 2011). İlk seviyenin ardından elde edilen düşük frekanslı işaret tekrar dalgacık dönüşümüne tabi

tutularak kendi alt bileşenlerine ayrılır ve işlem bu şekilde beklenen ya da istenen işaretlerin elde edilmesine kadar devam eder (Coşkun ve İstanbullu, 2012). ADD yöntemine ait akış diyagramı Şekil 4.3'te gösterilmektedir (Bayhan ve Yılmaz, 2009). ADD denklem 4.19, 4.20 ve 4.21 ile ifade edilmektedir (Karlík ve ark., 2009).


$$W(j,k) = \sum_j \sum_k x(k) 2^{-j/2} \psi(2^{-j}n - k) \quad (4.19)$$

Denklem 4.19'da x işareti, ψ ise ana dalgacığı temsil etmektedir (Karlík ve ark., 2009).

$$L1 = \sum_k x(k)g[2n - k] \quad (4.20)$$

$$H1 = \sum_k x(k)h[2n - k] \quad (4.21)$$

g alçak geçiren filtreyi, h yüksek geçiren filtreyi ifade etmektedir. $L1$ ve $H1$ ise düşük (yaklaşım) ve yüksek (detay) frekans bileşenlerini belirtmektedir.




Şekil 4.3. ADD akış diyagramı (Bayhan ve Yılmaz, 2009)

4.3.3.2. Dalgacık paket dönüşümü (DPD)

Dalgacık paket dönüşümünde, ADD'den farklı olarak düşük frekanslı işaretin (yaklaşım katsayılarının) yanı sıra yüksek frekanslı işaret (detay katsayıları) de tekrar

dalgacık dönüşümüne tabi tutulur (Tepe ve Sezgin, 2009). DPD yöntemine ait akış diyagramı Şekil 4.4'te gösterilmektedir (Tepe ve Sezgin, 2009).



Şekil 4.4. DPD akış diyagramı (Tepe ve Sezgin, 2009)

Ses işaretleri dalgacık dönüşümleri ile alt bantlara ayrıştırılır. İstenilen alt bantlardaki dalgacık katsayıları doğrudan analiz için kullanıldığı gibi, bu alt bantlardan çıkarılan bir takım istatistiksel özelliklerde (dalgacık katsayılarının ortalaması, standart sapması, maksimumu, minimumu, ortalama gücü, mutlak değerlerinin ortalaması...) bu işaretlerin analizi için kullanılırlar.

4.4. Boyut Azaltma Yöntemleri

4.4.1. Temel bileşenler analizi (TBA)

Temel bileşenler analizi, orijinal p sayıda değişkenin varyans yapısını daha az sayıda ve bu değişkenlerin doğrusal bileşenleri olan yeni değişkenlerle ifade etmektedir. Aralarında ilişki, bağımlılık bulunan p sayıda değişkenin açıkladığı yapıyı, aralarında bağımlılık bulunmayan ve sayıca orijinal değişken sayısından daha az sayıda ($p > k$) orijinal değişkenlerin doğrusal bileşenleri olan değişkenlerle ifade etme yöntemine TBA denir (Kocabaş, 2008) . Dönüşüm sonrasında temel bileşenler olarak adlandırılan değerler elde edilir. İlk temel bileşenin varyans değeri en büyüktür ve diğer temel bileşenler varyans değerleri azalacak şekilde sıralanırlar (Yazar ve ark., 2009).

TBA yönteminin amacı doğrusal ilişkiler içeren çok sayıda veriden, birbirinden bağımsız az sayıda veri elde etmektir. Buradaki önemli olan kısım, veri boyutunun düşürülebilmesi için doğrusal olarak ilişkili verilerin ayıklanmaya çalışılmasıdır. Bu şekilde boyut düşürülürken, verilerin tanımlayıcı olma özelliği de kaybedilmemektedir.

Yöntem, bu yönüyle bir veri sıkıştırma algoritması olarak da kullanılmaktadır (Atasoy, 2012).

TBA şu şekilde ifade edilebilir;

$X=[x_1, x_2, \dots, x_n]$ n adet d boyutlu, x verisi içeren bir matris olsun (Baştürk ve ark., 2006).

İlk olarak n adet verinin ortalama değeri (m) bulunur. Ortalama değerle her bir x_i verisinin farkı alınarak $\bar{X}=[x_1-m, x_2-m, \dots, x_n-m]$ fark matrisi elde edilir (Baştürk ve ark., 2006).

Kovaryans matrisi elde edilen fark denklemi kullanılarak elde edilir. Kovaryans matrisi denklem 4.22'de görüldüğü gibi hesaplanır (Baştürk ve ark., 2006).

$$C = \frac{1}{n} \bar{X} \bar{X}^T \quad (4.22)$$

C kovaryans matrislerinin Φ_x öz vektörleri ve Λ_x öz değerleri bulunur (denklem 4.23) (Baştürk ve ark., 2006).

$$C\Phi_x = \Phi_x \Lambda_x \quad (4.23)$$

Bu aşamayla elde edilen d adet d boyutlu öz vektör ve köşegen matris biçiminde d adet öz değer aşağıdaki gibi olur (Baştürk ve ark., 2006).

$$\Lambda_x = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \dots & 0 & \lambda_d \end{bmatrix} \quad \Phi_x = [\phi_1, \phi_2, \dots, \phi_d]$$


y adet, yüksek öz değere karşılık gelen öz vektörler seçilerek dxy boyutlu iz düşüm matrisi x_i' denklem 4.24'deki eşitsizlik ile elde edilir (Baştürk ve ark., 2006).

$$x_i' = W^T (x_n - m) \quad (4.24)$$

Denklem 4.24'deki ifade ile d boyutlu x_i verisiyle daha düşük boyutlu x_i' verisi elde edilmiş olur.

4.4.2. Lineer diskriminant analizi (LDA)

Fisher'in ayırım analizi olarak da bilinen lineer diskriminant analizi (LDA), çok değişkenli veriler üzerinde işlem yapan danışmanlı doğrusal boyut azaltma yöntemidir. Bu yöntem, veri içerisinde bulunan farklı sınıflara ait grupların doğrusal ayrılabilirliğini maksimize ederek boyut azaltması yapar (Orhan, 2012). Her grup içerisindeki varyansın minimum olmasını sağlar ve grupların ortalamalarını birbirlerinden maksimum düzeyde uzak tutar. LDA ile gerçekleştirilen ayırmada sınıf içi farklılıklar en az; sınıflar arası farklılıklar en fazla olmalıdır. LDA mantığı Şekil 4.5'te gösterilmektedir.



Şekil 4.5. Lineer diskriminant analizi (Orhan, 2012)

$$\max \frac{\mu_1' - \mu_2'}{\sigma_1'^2 - \sigma_2'^2} \quad (4.25)$$

LDA, nesneleri ya da olayları birden fazla sınıfa en iyi şekilde ayıran veya nesneleri en iyi şekilde karakterize eden özelliklerin lineer kombinasyonunu bulmaya çalışır (Kurt ve ark., 2007). Sonuç kombinasyonu bazen sınıflandırma amacıyla kullanılabilir ama çoğu kez boyut azaltma için kullanılır.

4.4.3. Bulanık c ortalama (BCO)

Bulanık c-ortalama algoritması, Dunn tarafından 1973 yılında ortaya atılmış ve Bezdek tarafından 1981' de geliştirilmiştir. Bu algoritma kümeleme teknikleri

arasında en iyi bilinen ve sıklıkla kullanılan kümeleme algoritmalarından biridir. Aynı zamanda veri azaltmada amacıyla da kullanılabilir (Işık ve ark., 2007).

Bulanık c-ortalamlar algoritması, verilerin iki veya daha fazla kümeye ait olabilmesine izin verir. Bulanık kümeleme yönteminde üyelik olasılıklarının toplamı daima 1 olmak üzere, bir verinin bir kümede olma olasılığı tüm olası kümeler arasında 0 ile 1 arasında değişen bir üyelik değeri ile belirlenir (Doring ve ark., 2006). Bu durum, veri noktalarının aynı anda birden fazla kümeye ait olabileceğini göstermektedir. Kümeye üyelikler bulanık olduğu için veri noktasının hangi kümeye ait olduğunu gösteren tek bir değer yoktur, onun yerine bir değerler kümesi vardır (Tatlıdil, 1992; Yılcı 2010). Birim bir bölümüyle bir kümeye ait iken, bir bölümüyle kümenin dışındadır ve en yüksek olasılığa sahip olduğu kümeye atanır (Torra, 2005; Yılcı, 2010). Dolayısıyla klasik katı kümeleme yöntemlerini, bulanık kümelemenin bir alt durumu olarak ele almak mümkündür. Bulanık c-ortalamlar algoritması amaç fonksiyonu temelli bir metottur. Algoritma, en küçük kareler yönteminin genellemesi olan denklem 4.26'daki amaç fonksiyonunu öteleyerek minimize etmek için çalışır (Höppner ve ark., 2000; Işık ve ark., 2007).

$$Jm = \sum_{i=1}^N \sum_{j=1}^c u_{ij}^m \|x_i - c_j\|^2, 1 \leq m < \infty \quad (4.26)$$

Algoritma U üyelik matrisinin rastgele atanmasıyla başlatılır. İkinci adımda ise merkez vektörleri hesaplanır. Merkezler denklem 4.27'de görülen formülle hesaplanır (Höppner ve ark., 2000; Işık ve ark., 2007).

$$c_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m} \quad (4.27)$$

Hesaplanan küme merkezlerine göre U matrisi denklem 4.28'deki eşitsizlik kullanılarak yeniden hesaplanır. Eski U matrisi ile yeni U matrisi karşılaştırılır ve fark ε 'dan küçük olana kadar işlemler devam eder (Moertini, 2002; Işık ve ark., 2007)

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{\|x_i - c_i\|}{\|x_i - c_k\|} \right)^{2/(m-1)}} \quad (4.28)$$

Kümeleme işlemi sonucunda oluşan, bulanık değerler içeren U üyelik matrisi kümelemenin sonucunu yansıtır. Berraklaştırma yapılarak bu değerler yuvarlanıp 0 ve 1'lere dönüştürülebilir (Işık ve ark., 2007).

4.5. Sınıflandırma Yöntemleri


Analiz edilen biyomedikal ses işaretlerinin sınıflandırılması için birçok sınıflandırıcı kullanılmaktadır. Bu sınıflandırıcılara örnekler;

- ✓ Yapay Sinir Ağları
- ✓ K-En Yakın Komşuluk
- ✓ Destek Vektör Makineleri
- ✓ Naive Bayes
- ✓ Bulanık K en Yakın Komşuluk

4.5.1. Yapay sinir ağları (YSA)


YSA insan beynindeki biyolojik nöronların yapısından ve çalışmasında esinlenerek geliştirilmiş (Dallali ve ark., 2011), çoğunlukla örüntü sınıflandırma, kestirim ve optimizasyon işlemlerinin karmaşık sorunlarını çözmek için kullanılan bir algoritmadır. YSA, sinir sistemindeki biyolojik nöronların simüle edilmiş hali olan nöron yada düğüm olarak da bilinen birçok işlem elemanından oluşur. Bu işlem elemanları ağırlıklı bağlantılar vasıtasıyla birbirleriyle haberleşirler. Her bir işlem elemanı kendi hafızasına sahiptir (Akkoç ve Elitaş, 2010). Şekil 4.6'da YSA'daki bir işlem elemanı gösterilmektedir (Juneed, 2011) .

Her işlem elemanı istenildiği sayıda giriş bağlantısı ve tek bir çıkı bağlantısı alabilir. Giriş işaretleri YSA'na bilgi taşır. Sonuç ise çıkış işaretlerinden alınabilir (Juneed, 2011).



Şekil 4.6. İşlem elemanı (Düğüm) (Juneed, 2011)

İnsanların zaman içerisinde yaptıkları, yaşadıkları ve tecrübeleri ile gerçekleşen öğrenme, YSA da nöronlar arasındaki sinaptik bağlantıların ayarlanması ile olur (Erdoğan ve Pekaçar, 2009). Öğrenme, eğitime yoluyla örnekler kullanarak olur; yani, girdi/çıkı verilerinin yapay sinir hücresindeki eğitime algoritması tarafından kullanarak bağlantı ağırlıklarının bir yakınsama sağlanana kadar, tekrar tekrar ayarlanmasıyla gerçekleşir. Yapay sinir hücre yapısı Şekil 4.7’de görülmektedir (Demirhan ve ark., 2009).




Şekil 4.7. Yapay sinir hücre yapısı (Demirhan ve ark., 2009)

Şekil 4.7’de görünen yapay sinir hücresinin girdileri x_n ve her bir girdiye ait bağlantı ağırlık katsayısı (önemlilik derecesi) w_n ile belirtilmiştir. Girişler ($x_1, x_2, \dots, x_n$) çevreden veya kendinden önceki sinirlerden aldığı bilgiyi diğer sinirlere getirir. Bir

sinir birden çok giriş alabilir. Sinirler ise tüm girdi işaretlerinin ağırlıklı toplamalarını elde etmekte ve daha sonra bu toplamı bir transfer fonksiyonundan geçirmektedir. Transfer fonksiyonu, nöronun çıkış değerini istenilen değerler arasında sınırlar. Doğrusal, basamak, sigmoid ve hiperbolik tanjant fonksiyonları yaygın olarak kullanılan transfer fonksiyonlarıdır. Bir nöronun çıkışı $y_i = f(x)$ transfer fonksiyonu sonucunun dış ortama veya diğer sinirlere gönderildiği yerdir. Bir sinirin tek bir çıkışı olabileceği gibi birden fazla çıkışı da olabilir. Elde edilen çıkış değeri ile istenen çıkış değeri arasındaki fark belli bir değerin üzerindeyse hata geriye doğru bir önceki katmana yayılarak ağ hatasının karesini minimize etmek için ağırlıkların değerleri güncellenir. Hata değeri belli bir değerin altına düşüncüye kadar iterasyon işlemine devam edilir ve böylece ağı öğrenme aşaması tamamlanmış olur (Fausett L., 1994; Demirhan ve ark., 2009).

YSA giriş katmanı, ara katman (birden fazla olabilir) ve çıktı katmanı olmak üzere 3 katmandan meydana gelmektedir. İlk katman olan giriş katmanı, girişlerin YSA'na sunulduğu ve söz konusu değişkenlerin ara katmana aktarıldığı katmandır. Ara katmanda ise girdi katmanından sağlanan bilgiler işlenerek çıktı katmanına gönderilir. Çıktı katmanında ise ağı üretmiş olduğu çıktı değeri dış dünyaya iletilir (Akkoç ve Elitaş, 2010).

Şekil 4.8'de bir gizli katmana sahip YSA gösterilmektedir (Akkoç ve Elitaş, 2010).



Şekil 4.8. 1 gizli katmanlı yapay sinir ağı (Akkoç ve Elitaş, 2010)

YSA'nın eğitimi için birçok öğrenme algoritması geliştirilmiştir. Bu algoritmalar (Etike, 2009);

- ✓ Geri Yayılım Algoritması
- ✓ Esnek Yayılım Algoritması
- ✓ Delta Bar Delta Algoritması
- ✓ Geliştirilmiş Delta Bar Delta Algoritması
- ✓ Hızlı Yayılım Algoritması
- ✓ Levenberg-Marquardt Geri Yayılım Metodu
- ✓ Eşleştirmeli Eğitim Algoritmaları
- ✓ Genetik Algoritma
- ✓ BFGS Quasi-Newton Geri yayılım algoritması

Bu algoritmalar arasından geri yayılma algoritması (backpropagation), basitliği ve uygulamadaki görüş açısı gibi başarılarından dolayı ağ eğitimi için kullanılan en popüler algoritmadır (Aktaş ve Okumuş, 2003). Bu algoritma; hataları geriye doğru çıkıştan girişe azaltmaya çalışmaktadır (Keleşoğlu ve Fırat, 2006).

Q katmanlı ileri beslemeli bir ağ için geri yayılım algoritması; aşağıdaki basamaklardan oluşur (Keleşoğlu ve Fırat, 2006).

$q = 1, 2, 3, \dots, Q$ katman numarası,

H_i^q : q 'uncu katmandaki i biriminin girdisi,

y_i^q : q 'uncu katmandaki i biriminin çıktısı,

w_{ij}^q : $(q-1)$ 'inci katmandaki i birimini, q 'ncu katmandaki j birimine bağlayan ağırlık olmak üzere (Keleşoğlu ve Fırat, 2006);

1.Adım: w 'ye reel değerli küçük rastgele sayılar olacak şekilde başlangıç değerleri atanır.

2.Adım: Eğitim kümesinden bir (giriş-hedef) çalışma modeli seçilir ve q katmanındaki her bir j birimi için ileri yönde 'çıkış' değerleri denklem 4.29'daki gibi hesaplanır.

$$y_i^q = f\left(\sum_i y_i^{q-1} w_{ij}^q\right) \quad (4.29)$$

3.Adım: Denklem 4.30'da görülen eşitsizlik ile çıkış birimleri için hata hesaplanır.

$$\delta_i^q = (y_i^q - y_i^q) f'(H_i^q) \quad (4.30)$$

4.Adım: $q = Q, Q-1, \dots, 2$ katmanlarındaki tüm i birimleri için geriye yayılım yoluyla deltalar yani gizli katman birimleri için hata terimleri hesaplanır.

$$\delta_i^{q-1} = f'(H_i^{q-1}) \sum_j \delta_j^q w_{ij}^q \quad (4.31)$$

5.Adım: Bütün ağırlıklar w_{ij} 'ler kullanılarak güncellenir.

$$w_{ij}^{yeni} = w_{ij}^{eski} + \Delta w_{ij}^q \quad (4.32)$$

$$\Delta w_{ij}^q = \eta \delta_i^q y_i^{q-1} \quad (4.33)$$

6.Adım: 2. adıma dönülüp, toplam hata kabul edilebilir bir düzeye gelene kadar her bir p modeli için işlemler tekrarlanır.

YSA biyomedikal alanında modelleme, veri analizi ve tanı için sınıflandırma amacıyla sıklıkla kullanılmaktadır (Kandaswamy ve ark., 2004).

4.5.2. K-en yakın komşuluk (K-NN)

K-NN algoritması, sınıflandırma amacıyla sıklıkla kullanılan danışmanlı ve parametrik olmayan algoritmalarından biridir. KNN'de hiçbir eğitim süreci olmadığı için, diğer sınıflandırma teknikleri ile karşılaştırıldığında bu teknik düşük bir hesaplama maliyeti olan basit bir sınıflandırma tekniğidir. Özellikle veri setindeki verilerin dağılımı ile ilgili önceden bir bilgiye sahip olunmadığı durumlarda kullanılır (Babaoğlu ve ark., 2013).

Sınıflandırma için kullanılan temel yaklaşım; sınıflandırılmak istenen yeni örneğin daha önceden hangi sınıfa ait olduğu bilinen örneklerden k tanesine yakınlığına bakılır. K sayısının değeri sınıflandırma açısından önemlidir. K değeri çok küçük olursa model çok etkilenir. Çok büyük olursa da tek bir sınıf gibi olur. Yani k sayısının sınıflandırmaya etkisi vardır (Yorgancılar, 2013).

Algoritma adımları:

- ✓ K sayısı belirlenir.
- ✓ Çeşitli uzaklık fonksiyonları kullanılarak yeni gelen örneğin veri setindeki sınıfları bilen tüm örneklerle uzaklıkları hesaplanır.
- ✓ En yakın k adet örnek seçilir.
- ✓ Seçilen örneklerin büyük bir kısmının ait olduğu sınıf belirlenir.
- ✓ Yeni gelen örnek belirlenen sınıfa atanır.

K-En yakın komşuluk algoritması mesafe ölçümlerine dayanır ve bu nedenle mesafe ölçütlerine gerek duyar (Amit, 2004). Bu sınıflandırma algoritmasında mesafe ölçütünün seçimi önemli bir konudur. Manhattan, hamming, öklid gibi birçok mesafe hesaplama fonksiyonu vardır. Öklid bu fonksiyonlar arasında en sık kullanılan mesafe ölçüt fonksiyonudur. Öklid uzaklığı denklem 4.34'deki matematiksel formülle hesaplanır.

$$d = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.34)$$

4.5.3. Destek vektör makineleri (DVM)


DVM, temeli istatistiksel öğrenme kuramına dayandırılarak Vapnik tarafından geliştirilen sınıflandırma, regresyon, tanıma ve aykırı değerler belirleme işlemleri için kullanılan danışmanlı öğrenme yöntemidir (Cortes ve Vapnik, 1995). DVM ilk olarak iki sınıflı doğrusal verilerin sınıflandırılabilmesi için geliştirilmiş ancak daha sonra çok sınıflı ve doğrusal olmayan verilerinde sınıflandırılabilmesi için genelleştirilmiştir (Kavzoğlu ve Çölkesen, 2010).

DVM yöntemi, verileri birbirinden ayırmak için en uygun fonksiyonun tahmin edilmesi esasına dayanır. Bir DVM, verileri optimal olarak farklı kategorilere ayıran n boyutlu bir hiperdüzlem oluşturmaktadır (Yakut ve ark., 2014).


DVM'de iki durum söz konusudur. İlk durum verilerin doğrusal olarak ayrılacakları bir yapıda olmasıdır. İkinci durum ise verilerin doğrusal olarak ayrılamayan yapıda olmasıdır.

4.5.3.1. Doğrusal ayrılabilen veriler için DVM

Her biri $y_i = \{-1, 1\}$ ile gösterilen sınıflardan birine ait olan, doğrusal bir şekilde ayrılabilir x_i örnekler kümesi verilmiştir. $i=1, \dots, N$. Amaç, veri kümesini verilen etiketlere göre bir hiper düzlem yardımıyla ayırıp, aynı sınıfa ait bütün verileri hiper düzlemin aynı tarafında bırakmaktır (Yakut ve ark., 2014; Kavzoğlu ve Çölkesen, 2010). Şekil 4.9'da görüldüğü gibi doğrusal olarak ayrılabilen verileri ayırabilen birçok hiper düzlem çizilebilir. Ancak DVM'nin amacı kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkaran hiper-düzlemi bulabilmektir. Şekil 4.10'da görüldüğü üzere bu amaç için H1 ve H2 düzlemleri seçilmiştir.



Şekil 4.9. İki sınıflı bir problem için çizilen hiperdüzlemler (Kavzoğlu ve Çölkesen, 2010)



Şekil 4.10. Optimum hiper düzlem ve destek vektör makineleri (Kavzoğlu ve Çölkesen, 2010)

Sınırı maksimuma çıkararak iki sınıf veriyi birbirinden en iyi şekilde ayıran hiper-düzleme optimum hiper-düzlem denilmektedir. Sınır genişliğini sınırlandıran noktalar ise destek vektörleri olarak adlandırılmaktadır (Kavzoğlu ve Çölkesen, 2010).

Optimum hiper düzlemin üzerinde kalan veriler denklem 4.35'deki eşitsizliğe, alt kısmında kalan veriler ise denklem 4.36'daki eşitsizliğe uymaktadırlar (Alıç, 2011).

$$w \cdot x_i + b \geq +1 \quad (4.35)$$

$$w \cdot x_i + b \leq -1 \quad (4.36)$$

w ağırlık vektörünü (hiper-düzlemin normali) ve b eğilim değerini göstermektedir (Osuna ve ark., 1997). Destek vektörler ile optimum hiper düzlem arasındaki mesafe $d = \frac{1}{\|w\|}$ olarak hesaplanır ve m denklem 4.37'deki eşitsizlikten hesaplanır (Alıç, 2011).

$$m = 2d = \frac{2}{\|w\|} \quad (4.37)$$

DWM'nin amacı H1 ve H2 hiper düzlemleri arasındaki mesafeyi (m) maksimize etmek olduğuna göre, $\|w\|$ ifadesinin minimizasyonu m 'yi maksimize edecektir. Buna bağlı sınırlamalar;

$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad (4.38)$$

şeklinde belirtilir (Vapnik, 1995; Kavzoğlu ve Çölkesen, 2010).

Lagrange denklemleri kullanılarak bu sınıflandırma problemi çözülebilir. Sonuç olarak doğrusal olarak ayrılabilen 2 sınıflı bir problem için karar fonksiyonu denklem 4.39'da görüldüğü gibi yazılabilir (Osuna ve ark., 1997; Alıç, 2011).

$$f(x) = \text{sign} \left(\sum_{i \in SV} a_i y_i (x_i^T x) + b^* \right) \quad (4.39)$$


Bunun yerine sadece destek vektörler göz önüne alınacak olursa,

$$f(x) = \text{sign}(wx + b^*) \quad (4.40)$$

bağıntısı da kurulabilir (Alıç, 2011).

4.5.3.2. Doğrusal ayrılamayan veriler için DVM

Şekil 4.11’de görüldüğü gibi problemlerin birçoğunda veriler doğrusal olarak ayrılamayabilir. Bu problem pozitif bir yapay ξ_i değişkeni ve C düzenleme parametresi tanımlanması ile çözülür (Cortes ve ark., 1995).



Şekil 4.11. Doğrusal olarak ayrılamayan veriler için hiper düzlemin belirlenmesi (Kavzoğlu ve Çölkesen, 2010)

Düzenleme parametresi ve yapay değişken kullanılarak doğrusal olarak ayırım yapılamayan veriler için sınıflandırma problemi denklem 4.41’deki matematiksel hali alır (Kavzoğlu ve Çölkesen, 2010).

$$\min \left[\frac{\|w\|^2}{2} + C \sum_{i=1}^r \xi_i \right] \quad (4.41)$$

Buna bağılı sınırlamalar ise denklem 4.42 ve denklem 4.43'deki gibi ifade edilir (Alıç, 2011).

$$w \cdot x_j + b \geq +1 - \xi_j, y = +1 \quad (4.42)$$

$$w \cdot x_j + b \leq -1 + \xi_j, y = -1 \quad (4.43)$$

Doğrusal olmayan ayrılabilirlik durumunda, veriler orijinal giriş uzayında doğrusal olarak ayrılamazlar. Bu tip durumlarda, girdi uzayında doğrusal olarak ayrılamayan orijinal veri, doğrusal olarak kolayca sınıflandırılabilceği yüksek boyutlu nitelik uzayında görüntülenir. DVM, çekirdek fonksiyonları kullanarak doğrusal olmayan dönüşümler yapabilmekte ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayırımına imkân sağlamaktadır. Çekirdek fonksiyonları ile bütün değerlerin tekrar tekrar çarpım değerlerinin hesaplanarak bulunması yerine doğrudan çekirdek fonksiyonunda değerin yerine koyularak nitelik uzayındaki değerin bulunması sağlanır. (Kavzoğlu ve Çölkesen, 2010; Yakut ve ark., 2014)

DVM yaygın olarak kullanılan dört çekirdek fonksiyonu vardır. Bu fonksiyonlar (Yakut ve ark., 2014):

1. Doğrusal Fonksiyon,
2. Polinomial Fonksiyon
3. Sigmoid Fonksiyon,
4. Radyal Tabanlı Fonksiyon

4.5.4. Naive Bayes

Adını Matematikçi Thomas Bayes'den alan, Bayes karar teorisine dayanan basit bir olasılıksal sınıflandırıcıdır (Sezgin ve ark., 2013).

Naive Bayes sınıflandırmasında sisteme hangi sınıflara ait oldukları bilinen belirli bir oranda öğretilmiş veri sunulur. Öğretilmiş veriler üzerinde yapılan olasılık hesapları ile sisteme sunulan yeni test verileri, daha önce elde edilmiş olasılık değerlerine göre işletilir ve verilen test verisinin hangi sınıfa ne kadar olasılıkla ait olduğu tespit edilmeye çalışılır (Usta, 2014)

Naive Bayes algoritmasının uygulanmasında bir takım kabuller yapılır. Niteliklerin birbirinden bağımsız olduğu kabulü bunlardan en önemlisidir. Eğer nitelikler birbirini etkiliyorsa olasılık hesaplamak zordur. Niteliklerin hepsinin aynı derecede önemli olduğu da diğer kabul edilmesi gereken kurallardan biridir.(Siyah, 2012)

Naive Bayes Sınıflandırıcısı için;

X giriş örneği, n adet özellikten oluşmakta ve $X=\{x_1, x_2, \dots, x_n\}$ şeklinde ifade edilmektedir. N sınıf olduğu düşünüldüğünde $C_1, C_2, \dots, C_N$ sınıf değerlerini ifade etmektedir. Sınıfı belirlenecek olan örneğe ilişkin olarak,

$$P(C_i | X) = \frac{P(X | C_i)P(C_i)}{P(X)} \quad (4.44)$$

ile olasılıklar hesaplanır.

$P(X|C_i)$ olasılığı örneğe ait x_i değerlerinin birbirinden bağımsız olduğu kabul edilir. Birçok özelliğin kesişimi görünümündeki bu veri örneği için hedef sınıf tahmininde tüm nitelikler için koşullu olasılıkların çarpımı denlem 4. 45'deki eşitsizlik ile elde edilir (Orhan ve Adem, 2012).

$$P(x_1, x_2, \dots, x_m | C_i) = \prod_{k=1}^n P(x_k | C_i) \quad (4.45)$$

Bilinmeyen örnek X'i sınıflandırmak için $P(C_i|X)$ içinde yer alan payda kısımları tüm hedef durumların olasılık hesaplarında ortak olduğundan hesaplamada kullanılmaz. Sadece pay kısmında bulunan değerlerin karşılaştırılması yeterlidir. Bu durumda çok niteliğe sahip girişlerde Naive Bayes formülü denklem 4.46'daki gibi olmaktadır.

$$C' = \underset{C_i}{\operatorname{argmax}} \prod_{k=1}^n P(x_k | C_i) \quad (4.46)$$

4.5.5. Bulanık k en yakın komşuluk

Keller ve ark. (1985) tarafından geliştirilen bulanık k en yakın komşuluk algoritması özellikle biyolojik ve tıbbi veri sınıflandırma problemlerinde performansı artırabilir.

K-NN algoritmasında sınıflandırılacak örneklerin sınıfları k en yakın komşuları arasında en yaygın bulunan sınıfa göre belirlenir. Bulanık K-NN algoritmasında ise tek bir sınıfa göre değerlendirmeden ziyade, örneklerin farklı sınıflara göre bulanık üyelikleri belirlenir. Üyelikler denklem 4.47’de görülen eşitsizlikten hesaplanır (Chen ve ark., 2011)

$$u_i(x) = \frac{\sum_{j=1}^k u_{ij}(1 / \|x - x_j\|^{2/(m-1)})}{\sum_{j=1}^k (1 / \|x - x_j\|^{2/(m-1)})} \quad (4.47)$$

Eşitsizlikte $i=1,2,\dots,c$ ve $j=1,2,\dots,k$. c sınıf sayını, k ise en yakın komşu örneklerin sayısını temsil etmektedir. m, 0 ve 1 arasında değişen bulanık güç parametresidir. Bu parametre her bir komşunun üyelik değerine katkısı hesaplanırken hangisinin ağırlıklı olarak etki ettiğini belirlemek için kullanılır. $u_i(x)$ i. Sınıfa ait x örneğinin üyelik değerini belirtir (Chen ve ark., 2011).

Yeni bir örneğin sınıfı, üyelik değeri en büyük olan sınıf olarak belirlenir.

5. BİYOMEDİKAL SESLERDEN ÖZELLİK ÇIKARIMI

İşaretlere ait karakteristik özelliklerin belirlenmesi seslerin sınıflandırılması için önemli bir rol teşkil etmektedir. Seçilen analiz yöntemlerine bağlı olarak çıkarılan ses özelliklerine göre seslerin sınıflandırılma doğrulukları değişebilmektedir. Bu nedenle doğru bir sınıflandırma için, ses işaretlerinin analizi ve işaretlerden özellik çıkarma aşaması çok önemli bir adım olmaktadır.

Çeşitli hastalıklar için önemli tanısal bilgi, biyomedikal seslerin frekans dağılımından elde edilebilmektedir (Kandaswamy ve ark., 2004). Ayrıca frekans dağılımı, seslerin sınıflandırılmasında kullanılan önemli özelliklerden biridir. Bu nedenle tez çalışmasında seslerin karakteristik özelliklerinden olan frekans bileşenlerinden yararlanılmıştır.

Dijital işaret işleme yöntemlerinden olan spektral analiz yöntemleri, işaretin frekans bileşenleri hakkında bilgi edinebilmek amacıyla son yıllarda sıkça kullanılmaktadır. Hızlı Fourier dönüşümü temelli Welch metodu, AR metotlardan biri olan Burg tekniği ve ARMA metodu en yaygın kullanılan spektral analiz yöntemlerinden olup tez çalışmasında da kullanılmıştır. Ayrıca zaman- frekans çözünürlüğü sağlayan ADD ve DPD yöntemleri de ses işaretlerinden karakteristik özellikler çıkarılabilmesi amacıyla tez çalışmasında kullanılan diğer yöntemlerdir.

5.1. Akciğer Ses Verilerinin Özellik Çıkarımı

5.1.1. Welch, AR ve ARMA yöntemleri ile özellik çıkarımı

Welch, Burg ve ARMA spektral analiz yöntemleri ile normal ve 5 farklı patolojik akciğer hastalığına sahip akciğer ses işaretlerinin güç spektrum yoğunlukları bulunarak seslere ait frekans bilgileri elde edilmiştir.

Çalışmamızda kullanılan;

Welch parametreleri

- ✓ Hamming pencere fonsiyonu
- ✓ 1024 pencere boyutu
- ✓ 1023 üst örtüşen nokta sayısı
- ✓ 1024 Ayrık Fourier Dönüşümü nokta sayısı (nfft)
- ✓ 8000 Hz akciğer ses işaretleri örnekleme frekansı

Burg parametreleri

- ✓ p AR-Burg metot derecesi;
 - Sağ Bazal Nefes Alma Sesleri için: 9
 - Sağ Bazal Nefes Verme Sesleri için: 14
 - Sol Bazal Nefes Alma Sesleri için: 22
 - Sol Bazal Nefes Verme Sesleri için: 16
- ✓ 1024 nokta sayısı (nfft)
- ✓ 8000 Hz akciğer ses işaretleri örnekleme frekansı

ARMA parametreleri


- ✓ p,q ARMA metot dereceleri;
 - Sağ Bazal Nefes Alma Sesleri için: 21,20
 - Sağ Bazal Nefes Verme Sesleri için: 14,13
 - Sol Bazal Nefes Alma Sesleri için: 25, 24
 - Sol Bazal Nefes Verme Sesleri için: 27, 26
- ✓ 1024 nokta sayısı (nfft)
- ✓ 8000 Hz akciğer ses işaretleri örnekleme frekansı

olarak belirlenmiştir.


Sağ ve sol bazaldan dinlenen nefes alma ve nefes verme seslerinin karakteristikleri birbirlerinden farklıdır. Bu nedenle her bir ses kategorisi için en iyi sınıflandırma doğruluğunu veren farklı AR derecesi (p değeri) ve ARMA dereceleri (p ve q değerleri) seçilmiştir.

Astım hastalığına sahip bir bireyin sağ bazal nefes alma ve nefes verme seslerine ait; Welch yöntemi ile hesaplanan güç spektrum yoğunlukları Şekil 5.1’de, Burg yöntemi ile hesaplanan güç spektrum yoğunlukları Şekil 5.2’de ve ARMA yöntemi ile hesaplanan güç spektrum yoğunlukları Şekil 5.3’te görülmektedir.


Normal (sağlıklı) bir bireyin sağ bazal nefes alma ve nefes verme seslerinin güç spektrum yoğunlukları, Welch ile hesaplandığında Şekil 5.4’te, Burg ile hesaplandığında Şekil 5.5’te ve ARMA ile hesaplandığında Şekil 5.6’da gösterildiği gibi olmaktadır.




Şekil 5.1. Welch metodu ile astımlı akciğer sesleri güç spektrum yoğunluğu




Şekil 5.2. AR-Burg metodu ile astımlı akciğer sesleri güç spektrum yoğunluğu




Şekil 5.3. ARMA metodu ile astımlı akciğer sesleri güç spektrum yoğunluğu



Şekil 5.4. Welch metodu ile normal akciğer sesleri güç spektrum yoğunluğu



Şekil 5.5. AR-Burg metodu ile normal akciğer sesleri güç spektrum yoğunluğu




Şekil 5.6. ARMA metodu ile normal akciğer sesleri güç spektrum yoğunluğu


Şekillerden güç yoğunluklarının genellikle 100–600 Hz aralığında birikmiş olduğu görülmektedir.

KOAH hastalığına sahip bir bireye ait nefes alma ve nefes verme seslerinin Welch yöntemi ile hesaplanılan güç spektrum yoğunlukları Şekil 5.7’de


gösterilmektedir. Aynı hastaya ait solunun seslerinin Burg yöntemi ile hesaplanan güç spektrum yoğunlukları Şekil 5.8’de, ARMA yöntemi ile hesaplanılan güç spektrum yoğunlukları ise Şekil 5.9’da görülmektedir.



Şekil 5.7. Welch metodu ile KOAH akciğer sesleri güç spektrum yoğunluğu



Şekil 5.8. AR-BURG metodu ile KOAH akciğer sesleri güç spektrum yoğunluğu



Şekil 5.9. ARMA metodu ile KOAH akciğer sesleri güç spektrum yoğunluğu

Koah hastalığı bulunan bireylerin akciğer seslerine ait güç yoğunluklarının ise 1000 Hz'e kadar yayılmış durumda olduğu şekillerden anlaşılmaktadır.

Tez çalışmasında Welch, Burg ve ARMA metotları ile bulunan güç spektrum yoğunlukları seslere ait karakteristik özellik vektörleri olarak değerlendirilmektedir. Bu durumda özellik vektörlerinin boyutu (güç spektrum yoğunluk boyutu) 513 olmaktadır. Ancak sınıflandırma işleminin kısa sürede ve başarılı bir şekilde gerçekleşmesi için bu boyut çok büyüktür ve indirgenmelidir.

Klasik boyut azaltma yöntemleri (TBA, LDA vb.) kullanılarak boyut azaltma işlemi gerçekleştirildiğinde doğru ve tutarlı sonuçlar elde edilememiştir. Bu nedenle boyut azaltma 2 farklı şekilde gerçekleştirilmiş ve bu amaçla istatistiksel özelliklerden faydalanılmıştır.

Boyut Azaltma: 1.Yöntem

Her bir ses işaretine ait güç spektrum yoğunlukları frekans alt bantlarına ayrıştırılmıştır. Ayrıştırılan frekans alt bantları;

1. Frekans Alt Bandı: 1000-2000
2. Frekans Alt Bandı: 500-1000
3. Frekans Alt Bandı: 250-500
4. Frekans Alt Bandı: 125-250

5. Frekans Alt Bandı: 62,5-125
6. Frekans Alt Bandı: 31.25-62,5
7. Frekans Alt Bandı: 0-31.25

Akciğer ses frekansları genellikle 100-2000 Hz frekans aralıklarına dağılmış durumda bulunurlar. Bu nedenle ilk beş frekans alt bandı ,seslere ait özellik vektörleri oluşturmak için seçilmiştir. Seçilen her bir frekans alt bandından aşağıdaki istatistiksel özellikler çıkarılarak özellik vektörleri oluşturulmuştur.

- ✓ Güç spektrum yoğunluk değerlerinin mutlak ortalaması
- ✓ Güç spektrum yoğunluk değerlerinin maksimumu
- ✓ Güç spektrum yoğunluk değerlerinin standart sapması
- ✓ Komşu frekans alt bantlarının mutlak ortalamalarının oranları

İlk 2 istatistiksel özellik işaretin frekans dağılımını, 3. ve 4. özellikler ise frekans dağılımındaki değişiklikleri temsil etmektedir.

Welch, AR-Burg, ARMA metotları ile güç spektrum yoğunlukları bulunan akciğer seslerinin özellik vektörleri 3 aşamada oluşturulmuştur.

1. Seslere ait güç spektrum yoğunluklarının hesaplanması
2. Güç spektrumlarının frekans alt bantlarına ayrıştırılması ve gerekli frekans alt bantlarının belirlenmesi
3. Belirlenen frekans alt bantlarından istatistiksel özelliklerin çıkarılması

Gerçekleştirilen işlemler sonucunda özellik vektörlerinin boyutu 513'ten 19'a indirgenmiştir. Böylelikle 19 özellik boyutlu özellik vektörleri elde edilmiştir.

Boyut Azaltma: 2.Yöntem

Bulanık C Ortalama (BCO) algoritması da tez çalışmasında boyut azaltma amacıyla kullanılan diğer bir algoritmadır. Welch, Burg ve ARMA metotları ile bulunan güç spektrum yoğunlukları BCO algoritması ile 6 farklı gruba kümelendirilmiştir. Her bir kümede bulunan elemanların maksimumu, mutlak değerlerinin ortalaması, standart sapması ve komşu kümelerin mutlak ortalamalarının oranları bulunarak akciğer seslerine ait 23 boyutlu özellik vektörleri elde edilmiştir.


BCO algoritmasının çalışma prensibinde ilk merkez değerleri rastgele atanmaktadır. Rasgelelik algoritmanın her çalışmasında farklı sonuçlar üretmesine yani seslere ait farklı özellik vektörleri oluşturmaya neden olmaktadır. Bu nedenle tez çalışmamızda algoritma 10 kez çalıştırıldı ve en iyi sınıflandırma sonucu veren özellik vektörleri sesleri temsil etmesi amacıyla seçildi.

5.1.2. ADD ve DPD ile özellik çıkarımı


Spektral analiz yöntemlerinin yanısıra ADD ve DPD yöntemleri de akciğer seslerinin analizi için tez çalışmasında kullanılmıştır.

ADD yöntemi ile her bir ses işareti düşük ve yüksek frekanslı alt bantlara ayrıştırılmıştır. Ayrıştırma seviyesi 7, dalgacık türü ise 5. dereceden Daubechies (db5) olarak belirlenmiştir. Böylelikle ADD için D1-D7 detay (yüksek frekanslı bileşenler) katsayıları ve A7(düşük frekanslı bileşenler) yaklaşım katsayıları elde edilmiştir (Şekil 5.10). Soslere ait özellik vektörlerini elde etmek için D2-D6 detay katsayıları kullanılmıştır. D1 Akciğer seslerinin bulunmadığı çok yüksek frekans bileşenlerini, D7 ve A7'de çok düşük frekans bileşenlerini bulundurmaktadır. D1, D7 ve A7 katsayıları akciğer seslerinin analizi için faydalı bilgiler vermediği için çalışmamızda kullanılmamıştır. Ayrıca akciğer sesleri yüksek frekanslı sesler olduğu için yaklaşım katsayıları değil detay katsayıları kullanılmıştır.

DPD yöntemi akciğer ses işaretlerine uygulanarak, seslere ait frekans alt bantları elde edilmiştir. Ayrışma katsayısı ve dalgacık türü ADD'de olduğu gibi 7 ve 5. dereceden Daubechies (db5) olarak belirlenmiştir. Ayrıştırma işleminin ardından sesleri temsil edecek frekans alt bantları belirlenmiştir. Akciğer seslerinin DPD ile ayrışımı ve sesleri temsil etmesi için seçilen alt bantlar altı çizili olarak Şekil 5.11'de gösterilmiştir.



Şekil 5.10. Akciğer seslerinin ADD ile ayrışımı



Şekil 5.11. Akciğer seslerinin DPD ile ayrışımı

ADD’de ve DPD’de seçilen her bir frekans alt bandından aşağıdaki istatistiksel özellikler çıkarılarak özellik vektörleri oluşturulmuştur.

- ✓ Her bir frekans alt bandındaki dalgacık katsayılarının mutlak ortalaması
- ✓ Her bir frekans alt bandındaki dalgacık katsayılarının maksimumu
- ✓ Her bir frekans alt bandındaki dalgacık katsayılarının standart sapması
- ✓ Her bir frekans alt bandındaki dalgacık katsayılarının ortalama gücü
- ✓ Komşu frekans alt bantlarının dalgacık katsayılarının mutlak ortalamalarının oranları
- ✓ Her bir alt banttaki sıfır geçiş sayısı

1. , 2. ve 3. Özellikler işaretin frekans dağılımını, 4. , 5. ve 6. özellikler de frekans dağılımındaki değişiklikleri temsil etmektedir.

5.2. Kalp Ses Verilerinin Özellik Çıkarımı

5.2.1. Fourier dönüşümü, AR ve ARMA metotları ile özellik çıkarımı

9 farklı türdeki kalp seslerinin frekans bileşenleri hakkında bilgi edinebilmek amacıyla Welch, Burg ve ARMA yöntemleri kullanılmış ve seslere ait güç yoğunluk spektrumları bulunmuştur.

Çalışmamızda kullanılan;

Welch parametreleri

- ✓ Hamming pencere fonsiyonu
- ✓ 1024 pencere boyutu
- ✓ 1023 üst örtüşen nokta sayısı
- ✓ 1024 Ayrık Fourier Dönüşümü nokta sayısı (nfft)
- ✓ 44100 Hz kalp ses işaretleri örnekleme frekansı

Burg parametreleri

- ✓ p AR-Burg metot derecesi: 16
- ✓ 1024 nokta sayısı (nfft)
- ✓ 44100 Hz kalp ses işaretleri örnekleme frekansı

olarak belirlenmiştir.

ARMA parametreleri, ARMASA matlab aracı (Broersen, 2002) tarafından ses işaretlerinin karakteristiklerine göre otomatik olarak ayarlanmıştır. ARMASA sadece istatistiksel olarak anlamlı detaylarla güç spektral yoğunluğu tahmin eden otomatik bir programdır.

Farklı tiplerdeki kalp seslerinin sınıflandırılması aşamasında en iyi sınıflandırma doğruluğu üreten AR derecesi (p değeri) ve ARMA dereceleri (p ve q değerleri) seçilmiştir.

Welch, Burg ve ARMA yöntemleriyle bulunan güç spektrum yoğunlukları kalp seslerine ait karakteristik özellik vektörleri olarak değerlendirilmektedir. Ancak elde edilen özellik vektörlerinin boyutu (güç spektrum yoğunluk boyutu: 513), sınıflandırma işleminin kısa sürede ve başarılı bir şekilde gerçekleşmesi için çok büyüktür ve indirgenmelidir.

Klasik boyut azaltma yöntemlerinden olan TBA ve LDA kullanılarak boyut azaltma işlemleri gerçekleştirilmiş ve sınıflandırmada kullanılacak özellik vektörleri oluşturulmuştur.

Welch yöntemi ile elde edilen 513 boyutlu özellik vektörlerinin boyutu TBA ile 10'a, LDA ile 8'e indirgenmiştir.

AR yöntemi kullanımı elde edilen güç spektrum yoğunluklarından oluşan 513 boyutlu özellik vektörlerine TBA ve LDA algoritmalarının uygulanması sonucunda 8'er boyutlu özellik vektörleri elde edilmiştir.

ARMA yönteminin kalp seslerine uygulanması sonucunda elde edilen güç spektrum yoğunluklarından oluşan 513 boyutlu özellik vektörlerinin boyutu TBA algoritması ile 9'a, LDA algoritması ile de 8'e indirgenmiştir.

5.2.2. ADD ve DPD ile özellik çıkarımı


Kalp seslerinden özellikler çıkarabilmek için tez çalışmasında kullanılan diğer yöntemler; ADD ve DPD yöntemleridir.

ADD ile her bir ses işareti düşük ve yüksek frekanslı alt bantlara ayrıştırılmıştır. Ayrıştırma seviyesi 10, dalgacık türü ise 6. dereceden Daubechies (db6) olarak belirlenmiştir. Böylelikle ADD için D1-D10 detay (yüksek frekanslı bileşenler) katsayıları ve A10(düşük frekanslı bileşenler) yaklaşım katsayıları elde edilmiştir (Şekil 5.12). D6 ve D10 frekans alt bantları kalp seslerinin dağılmış olduğu 20-600 Hz aralığındaki frekans bileşenlerini içerdiği için, seslere ait özellik vektörleri D6-D10 detay katsayılarından elde edilmiştir.

DPD kalp ses işaretlerine uygulanarak, seslere ait frekans alt bantları elde edilmiştir. Ayrışma katsayısı 11 kabul edilmiş, dalgacık türü 6. dereceden Daubechies (db6) olarak belirlenmiştir. Kalp seslerini temsil edecek 7 adet alt bant, DPD ağacından seçilmiştir.

Akciğer seslerinin analizinde olduğu gibi kalp seslerinin analizinde de, ADD ve DPD ile sesleri temsil eden frekans alt bantları belirlenmiştir. Belirlenen frekans alt bantlarının herbirinden aşağıdaki istatistiksel özellikler çıkarılarak özellik vektörleri oluşturulmuştur.

- ✓ Her bir frekans alt bandındaki dalgacık katsayılarının mutlak ortalaması
- ✓ Her bir frekans alt bandındaki dalgacık katsayılarının maksimumu
- ✓ Her bir frekans alt bandındaki dalgacık katsayılarının standart sapması
- ✓ Her bir frekans alt bandındaki dalgacık katsayılarının ortalama gücü
- ✓ Komşu frekans alt bantlarının dalgacık katsayılarının mutlak ortalamalarının oranları
- ✓ Her bir alt banttaki sıfır geçiş sayısı



Şekil 5.12. Kalp seslerinin ADD ile ayrışımı

5.3. Konuşma Ses Verilerinin Özellik Çıkarımı

Betül Erdoğan Sakar, M. Erdem Isenkul, C. Okan Sakar, Ahmet Sertbaş, Fikret Gürgen, Şakir Delil, Hülya Apaydin ve Olcay Kurşun tarafından oluşturulmuş parkinson konuşma ses kayıtları tez çalışmasında kullanılmıştır. Ses kayıtları UCI Makine Öğrenme ve Akıllı Sistemler Araştırma Merkezi veri tabanında ücretsiz olarak bulunmaktadır. Veri seti eğitim ve test verilerini içermektedir. Eğitim verileri 20 parkinson hastası (6 kadın, 14 erkek) ve 20 sağlıklı bireye (10 kadın, 10 erkek) aittir. Sakar ve ark. (2013) eğitim verileri için her bir bireyden sürekli sesleri, sayıları kelimeleri ve kısa cümleleri içeren 26 ses örneği kaydetmişlerdir.

Test verileri ise 28 parkinson hastasına aittir. Sakar ve ark. (2013) test verileri için her bir bireyden sürekli seslerden olan ‘a’ ve ‘o’ seslerini üçer kez söylemelerini rica etmiş ve toplam 168 ses kaydı elde etmişlerdir.

Hem eğitim verilerinden hem de test verilerinden 26’şar özellik Sakar ve ark. (2013) tarafından çıkarılmış ve 2014 yılında özellikleri çıkarılmış veriler UCI veri tabanına kaydedilmiştir. Seslere ait özellikler;

Özellik 1-5: Temel frekanstaki düzensizlik ölçümleri (Jitter(bölgesel), Jitter (yerel, mutlak), Jitter (RAP), Jitter (PPQ) ve Jitter (DDP))

Özellik 6-11: Genlik düzensizlik ölçümleri (Shimmer (bölgesel), Shimmer (bölgesel, dB), Shimmer (APQ3) , Shimmer (APQ5), Shimmer (APQ11), Shimmer (DDA))

Özellik 12-14: Otokorelasyon(AC), Gürültü-Harmonik Oranı (NTH), Harmonik-Gürültü Oranı (HTN)

Özellik 15-19: Ortanca (Medyan) pitch, Ortalama pitch, Standart Sapma, Minimum pitch, Maksimum pitch

Özellik 20-23: Darbelerin, Periyotların sayısı, Ortalama periyot, Periyotların standart sapması

Özellik 24-26: Bölgesel sessiz pencerelerin oranı, Ses kesintisi sayısı, Ses kesintisi derecesi

5.3.1. Özellik seçimi

Özellik seçme yöntemleri ile sınıflandırmaya etkisi en az olan özellik verileri elenmesi ile özellik vektörlerinin boyutları azaltılır.

Yapılan tez çalışmasında MRMR (Minimum Redundancy Maximum Relevance) algoritması konuşma seslerinden etkin özniteliklerin seçilebilmesi amacıyla kullanılmıştır.

MRMR yöntemi sınıf bilgileriyle veri kümelerindeki özniteliklerden en ilişkilerini seçerken, diğer bir yandan bu öznitelikler arasındaki artıklığı minimuma indirmeye çalışmaktadır (Ding ve Peng, 2003; İsenkul, 2011).

Algoritma tüm özellikler bağımsız birer raslantı değişkeni olarak görür ve iki rastgelen seçilmiş özellik, X ve Y, arasındaki benzerlik ilişkisini bulmak için denklem 5.1'i kullanır.

$$I(X, Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p_1(x)p_2(y)} \right) \quad (5.1)$$

Denklem 5.1'deki $p(x, y)$ X ve Y'nin birleşik dağılım fonksiyonunu, $p_1(x)$ ve $p_2(y)$ ise X ve Y rastlantı değişkenlerinin diğer bir deyişle özniteliklerinin marjinal olasılık dağılım fonksiyonlarını göstermektedir (Rosenbaum, 2006).

MRMR yaklaşımına göre, en iyi n-1 adet özniteliği barındıran S kümesine eklenecek n. öznitelik, denklem 5.2 deki kriteri sağlamalıdır:

$$\max_{x_j \in X-S_{n-1}} \left[I(x_j, T) - \frac{1}{n-1} \sum_{x_i \in S_{n-1}} I(x_j; x_i) \right] \quad (5.2)$$

Denklem 5.2’de verilen X tüm öznitelik kümesini; T hedef değişkenini; x_i i. özniteliğini; I ise ortak bilgiyi simgelemektedir. Diğer bir ifadeyle, bu kriteri en büyük kılacak yeni x_j özniteliğinin T hedef değişkeniyle olan korelasyonunun yüksek, S kümesindeki mevcut özniteliklerle olan ikili korelasyonlarının ortalamasının da düşük olması gerekmektedir (Sakar ve Kurşun, 2010; İsenkul, 2011).

Yeni eklenecek x_j özniteliğinin entropisine bağlı olarak 5.2, denklem 5.3 de görüldüğü gibi tekrar yazılabilir.

$$\max_{x_j \in X-S_{n-1}} \left[H(x_j) \left(\frac{I(x_j, T)}{H(x_j)} - \frac{1}{n-1} \sum_{x_i \in S_{n-1}} \frac{I(x_j; x_i)}{H(x_j)} \right) \right] \quad (5.3)$$

Denklem 5.3’de $H(x_j)$ aday özniteliğin entropisini simgelemektedir. Buna göre S kümesiyle ve hedeflenen değişkenle (T) olan benzerlikleri arasındaki fark en büyük olan yani T değişkenin tahmini için mevcut özniteliklere en çok desteği sağlayan yeni öznitelik, S alt kümesine eklenecek bir sonraki eleman olarak seçilir (Sakar ve Kurşun, 2010; İsenkul, 2011).

MRMR özellik seçme algoritması için MID (Mutual information Difference) ve MIQ(Mutual Information Quotient) kriterleri kullanılmıştır. Algoritma ile 26 özellikli vektörlerden sırasıyla 5, 6, 7, 8, 9, 10 adet özellik seçilerek sınıflandırılma doğrulukları sınıflandırılmaktadır.

6. SINIFLANDIRMA SONUÇLARI

YSA, K-NN, DVM, Naive Bayes ve bulanık K-NN algoritmaları biyomedikal seslerin sınıflandırılması amacıyla bu çalışmada kullanılmıştır.

Çalışmada geriye yayılım temelli, 3 katmanlı sinir ağı yapısı kullanılmıştır. Sinir ağının eğitilmesinde Broyden-Fletcher-Goldfarb-Shanno (BFGS) öğrenme algoritması tercih edilmiştir.

K-NN algoritmalarında mesafe ölçütü Öklid, k değeri 3 olarak belirlenmiştir.

DVM için çekirdek fonksiyonu olarak lineer fonksiyonu seçilmiştir.

Sınıflandırma işlemleri 1000 iterasyon ve 15 çapraz doğrulama ile gerçekleştirilmiştir.

Tez çalışmasında, performans değerlendirme kriteri olarak sınıflandırma doğruluğu kullanılmıştır. Her bir sınıflandırma algoritması için sınıflandırma doğruluğu, doğru sınıflanmış örnek sayısının toplam örnek sayısına oranından elde edilmiştir.

Sınıflandırma işlemi 15 çapraz doğrulama ile gerçekleştirildiğinden dolayı, her bir doğrulama için sınıflandırma doğruluğu hesaplanmıştır. Sonuç sınıflandırma doğruluğu, 15 doğrulamada elde edilen doğruluk oranlarının ortalaması alınarak oluşturulmuştur.

6.1. Akciğer Ses Verilerinin Sınıflandırılması

Sağlıklı ve çeşitli akciğer hastalıklarına sahip 15 bireye ait akciğer seslerinin segmentasyonu sonucunda elde edilen; 67 sağ bazal nefes alma, 67 sağ bazal nefes verme, 70 sol bazal nefes alma, 70 sol bazal nefes verme akciğer ses işaretleri 5 farklı sınıflandırıcı ile sınıflandırılmıştır. Akciğer seslerinin hastalıklara göre dağılımı aşağıda görüldüğü şekildedir.

- 67 sağ bazal nefes alma akciğer sesleri;
 - ✓ 24 normal
 - ✓ 4 hafif derecede (şiddette) astım
 - ✓ 29 orta derecede astım
 - ✓ 2 ileri derecede astım
 - ✓ 3 KOAH (Kronik Obstrüktif Akciğer Hastalığı)
 - ✓ 5 Pnömosi
- 67 sağ bazal nefes verme akciğer sesleri;

- ✓ 23 normal
- ✓ 3 hafif derecede (şiddette) astım
- ✓ 32 orta derecede astım
- ✓ 2 ileri derecede astım
- ✓ 3 KOAH (Kronik Obstrüktif Akciğer Hastalığı)
- ✓ 4 Pnömosi
- 70 sol bazal nefes alma akciğer sesleri;
 - ✓ 25 normal
 - ✓ 4 hafif derecede (şiddette) astım
 - ✓ 27 orta derecede astım
 - ✓ 4 ileri derecede astım
 - ✓ 4 KOAH (Kronik Obstrüktif Akciğer Hastalığı)
 - ✓ 6 Pnömosi
- 73 sol bazal nefes verme akciğer sesleri;
 - ✓ 24 normal
 - ✓ 4 hafif derecede (şiddette) astım
 - ✓ 29 orta derecede astım
 - ✓ 4 ileri derecede astım
 - ✓ 5 KOAH (Kronik Obstrüktif Akciğer Hastalığı)
 - ✓ 7 Pnömosi

6.1.1. Welch, Burg, ARMA yöntemleri - istatistiksel özellikler

Analiz ve özellik çıkarma aşamasında Welch, Burg ve ARMA spektral analiz metotlarının akciğer seslerine uygulanması sonucu elde edilen güç spektrumları, 7 frekans alt bandına ayrıştırılmıştır. Ayrıştırma işleminin ardından seslerin frekans aralıklarını barından 5 frekans alt bantı seçilerek her birinden 4'er istatistiksel özellik çıkarılmıştır. Böylelikle sesleri temsil eden, her biri 19 özellik verisi içeren özellik vektörleri elde edilmiştir.

Akciğer seslerine ait özellik vektörleri YSA, K-NN, DVM, Naive Bayes ve bulanık K-NN algoritmaları ile sınıflandırılmışlardır.

Çalışmada kullanılan YSA'nın giriş katmanı 19 nörona sahiptir. Gizli katmanı sağ bazal için 18, sol bazal için 20 nörona, çıkış katmanı ise 6 nörona sahiptir.

Welch, Burg, ARMA metotları ve istatistiksel işlemler ile elde edilmiş, sağ bazal nefes alma akciğer ses işaretlerine ait özellik vektörlerinin 5 farklı algoritmayla sınıflandırılması sonucu oluşan sınıflandırma doğrulukları çizelge 6.1’de gösterilmektedir.

Çizelge 6.1. Sağ bazal nefes alma ses işaretlerinin farklı spektral analiz ve sınıflandırma yöntemleri için sınıflandırılma doğrulukları

Yöntem	YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (SD%)
Welch	80.33	74.00	66.33	65.00	82.44
Burg	85.67	81.33	76.00	64.67	85.11
ARMA	86.00	73.00	80.00	81.33	80.66

SD%: Yüzdelik olarak sınıflandırılma doğruluğu

3 farklı analiz yöntemi ve 5 farklı sınıflandırıcı kullanıldığında, sağ bazal nefes verme ses işaretlerinin sınıflandırma doğrulukları çizelge 6.2’de gösterilmektedir.

Çizelge 6.2. Sağ bazal nefes verme ses işaretlerinin farklı spektral analiz ve sınıflandırma yöntemleri için sınıflandırılma doğrulukları

Yöntem	YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (SD%)
Welch	72.33	59.00	63.33	60.33	80.57
Burg	78.33	73.33	60.67	57.67	81.33
ARMA	84.67	83.00	71.67	73.33	83.07

SD%: Yüzdelik olarak sınıflandırılma doğruluğu

Sağ bazal akciğer sesleri için;

ARMA yönteminin, özellikle YSA olmak üzere kullanılan bütün sınıflandırıcılarla kombinasyonu sonucu ürettiği sınıflandırma doğruluklarının oldukça yüksek olduğu ve Burg metodunun Welch yöntemi ile karşılaştırıldığında kısmen daha iyi sonuçlar verdiği çizelge 6.1 ve çizelge 6.2’ya bakılarak söylenebilmektedir.

Çizelge 6.3 ve Çizelge 6.4’de sol bazal nefes alma ve nefes verme akciğer ses işaretlerine ait özellik vektörlerinin 5 farklı algoritmayla sınıflandırılması sonucu oluşan sınıflandırma doğrulukları görülmektedir.

Çizelge 6.3. Sol bazal nefes alma ses işaretlerinin farklı spektral analiz ve sınıflandırma yöntemleri için sınıflandırılma doğrulukları

Yöntem	YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (SD%)
Welch	89.00	83.67	70.00	78.33	91.05
Burg	93.00	83.33	74.00	74.00	88.22
ARMA	86.67	80.67	78.33	74.00	86.04

SD%: Yüzdelik olarak sınıflandırılma doğruluğu

Çizelge 6.4. Sol bazal nefes verme ses işaretlerinin farklı spektral analiz ve sınıflandırma yöntemleri için sınıflandırılma doğrulukları

Yöntem	YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (%SD)
Welch	75.67	70.33	56.33	64.33	76.74
Burg	81.33	68.67	59.00	60.33	82.58
ARMA	80.33	74.67	53.00	68.00	80.44

SD%: Yüzdelik olarak sınıflandırılma doğruluğu

Sol bazal nefes alma sesleri için;

- ✓ AR metodunun YSA ile kullanıldığında, Fourier ve ARMA yöntemlerine göre
- ✓ Hızlı Fourier dönüşümünün K-NN, Naive Bayes ve Bulanık K-NN sınıflandırıcıları ile kullanıldığında, AR ve ARMA yöntemlerine göre
- ✓ ARMA metodunun ise DVM sınıflandırıcı ile kullanıldığında, Fourier dönüşümü ve AR yöntemlerine göre

Sol bazal nefes verme sesleri için;

- ✓ AR metodunun YSA, DVM ve bulanık K-NN sınıflandırma algoritmaları ile kullanıldığında, Fourier ve ARMA yöntemlerine göre
- ✓ ARMA metodunun ise KNN ve DVM sınıflandırıcıları ile kullanıldığında, Fourier dönüşümü ve AR yöntemlerine göre

daha yüksek sınıflandırma doğruluk oranları verdiği çizelge 6.3 ve 6.4'den anlaşılmaktadır.

Yapılan 5 sınıflandırma işleminde YSA ve bulanık K-NN algoritmalarının diğer sınıflandırıcı algoritmalarına göre daha yüksek sınıflandırma doğrulukları ürettiği açıkça görülmektedir.

6.1.2. Welch, Burg, ARMA yöntemleri –BCO- istatistiksel özellikler

Akciğer seslerine ait Welch, Burg ve ARMA yöntemleri ile bulunan güç spektrum yoğunluklarının boyutlarının indirgenmesi amacıyla kullanılan algoritmalarından biri de bulanık C ortalamadır. Bulanık C ortalama algoritması (BCO) ile her bir spektrum 6 farklı gruba kümelenmiş ve her bir kümeden aşağıdaki istatistiksel özellikler çıkarılarak özellik vektörleri oluşturulmuştur.

- ✓ Kümelerde bulunan elemanların maksimumu
- ✓ Kümelerde bulunan elemanların mutlak değerlerinin ortalaması
- ✓ Kümelerde bulunan elemanların standart sapması
- ✓ Komşu kümelerin mutlak ortalamalarının oranları

BCO algoritması rasgelelik barındıran bir algoritmadır. Bu nedenle her bir spektrum üzerinde bu algoritma 10 kez çalıştırılmış dolayısıyla her bir sese ait 10 farklı özellik vektörü elde edilmiştir.

Elde edilen 10 ayrı özellik vektörü 5 farklı sınıflandırma algoritması ile sınıflandırılmıştır. En yüksek doğruluk ve ortalama doğruluk değerleri hesaplanmıştır.

Sağ bazal nefes alma seslerinin spektral analiz, bulanık c ortalama ve istatistiksel işlemler ile elde edilen sınıflandırılma doğrulukları çizelge 6.5’de, aynı bazala ait nefes verme sesleri sınıflandırılma doğrulukları ise çizelge 6.6’da gösterilmektedir.

Çizelge 6.5. Sağ bazal nefes alma ses işaretlerinin spektral analiz, BCO ve farklı sınıflandırıcılar için sınıflandırılma doğrulukları

Özellik Çıkarma Yöntemleri	Sonuçlar	Sınıflandırma Yöntemleri				
		YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (SD%)
Welch-BCO	Ortalama	80.36	72.46	69.76	74.26	80.27
	En Yüksek	85.67	82.33	75.67	78.33	84.58
Burg-BCO	Ortalama	85.56	83.43	70.68	75.46	88.26
	En Yüksek	90.00	90.00	79.33	81.67	90.98
ARMA- BCO	Ortalama	83.06	74.49	71.96	58.16	77.01
	En Yüksek	85.67	80.33	77.67	61.00	80.39

SD%: Yüzdelik olarak sınıflandırılma doğruluğu

Çizelge 6.5’den görüldüğü üzere en iyi ortalama doğruluk %88.26 ve en yüksek doğruluk %90.98 olarak Burg yöntemi, BCO algoritması ve bulanık k-nn sınıflandırıcısı birlikte kullanıldığında elde edilmiştir.

İkinci en yüksek doğruluk oranı da Burg, BCO ve YSA veya K-NN algoritmaları birlikte kullanıldığında %90 olarak elde edilmiştir.

ARMA ve Welch yöntemlerinin analiz için birbirine yakın sınıflandırma doğrulukları ürettiği çizelge 6.5’den görülmektedir.

Sağ bazal nefes verme sesleri için ARMA metodunun analiz yöntemi olarak seçilmesinin daha iyi sonuçlar üretebileceği çizelge 6.6’dan anlaşılmaktadır.

Çizelge 6.6. Sağ bazal nefes verme ses işaretlerinin spektral analiz, BCO ve farklı sınıflandırıcılar için sınıflandırılma doğrulukları

Özellik Çıkarma Yöntemleri	Sonuçlar	Sınıflandırma Yöntemleri				
		YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (SD%)
Welch-BCO	Ortalama	68.56	57.96	58.36	54.33	70.20
	En Yüksek	72.67	69.67	65.67	60.67	76.33
Burg-BCO	Ortalama	72.67	64.00	64.79	57.76	71.03
	En Yüksek	78.33	67.33	70.33	62.00	76.55
ARMA- BCO	Ortalama	81.06	66.29	61.83	64.80	75.35
	En Yüksek	85.67	70.00	65.00	70.00	79.66

SD%: Yüzdelik olarak sınıflandırılma doğruluğu

Çizelge 6,7’de sol bazal nefes alma seslerine ait sınıflandırma doğrulukları, çizelge 6,8’de ise aynı bazala ait nefes verme doğrulukları gösterilmektedir.

Çizelge 6.7. Sol bazal nefes alma ses işaretlerinin spektral analiz, BCO ve farklı sınıflandırıcılar için sınıflandırılma doğrulukları

Özellik Çıkarma Yöntemleri	Sonuçlar	Sınıflandırma Yöntemleri				
		YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (SD%)
Welch-BCO	Ortalama	80.13	72.20	64.26	63.53	75.73
	En Yüksek	84.33	79.67	69.00	75.67	80.44
Burg-BCO	Ortalama	85.23	79.00	70.33	64.23	84.86
	En Yüksek	88.67	84.00	74.00	69.33	89.49
ARMA- BCO	Ortalama	80.20	69.96	69.73	74.10	79.11
	En Yüksek	83.33	71.67	73.00	77.67	83.25

SD%: Yüzdelik olarak sınıflandırılma doğruluğu

Çizelge 6.8. Sol bazal nefes verme ses işaretlerinin spektral analiz, BCO ve farklı sınıflandırıcılar için sınıflandırılma doğrulukları

Özellik Çıkarma Yöntemleri	Sonuçlar	Sınıflandırma Yöntemleri				
		YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (SD%)
Welch-BCO	Ortalama	63.96	59.23	55.40	55.20	66.86
	En Yüksek	70.33	68.33	61.33	56.67	69.47
Burg-BCO	Ortalama	63.90	54.56	49.30	51.20	67.21
	En Yüksek	71.00	63.00	55.67	55.00	72.77
ARMA- BCO	Ortalama	64.20	60.36	45.60	46.16	59.50
	En Yüksek	67.00	65.33	49.67	49.33	69.92

SD%: Yüzdelik olarak sınıflandırılma doğruluğu

Sol bazal ses işaretleri için;

10 kez BCO algoritmasının çalıştırılması sonucunda en yüksek sınıflandırma doğruluğu nefes alma için %89.49 ve nefes verme için % 72.77 olarak Burg yöntemi ve bulanık K-NN algoritması birlikte kullanıldığında elde edilmiştir. En iyi ortalama doğruluk ise nefes alma için %85.23, nefes verme için %67.21 olarak Burg yöntemi, YSA ve Bulanık K-NN sınıflandırıcı algoritmaları kullanılarak elde edilmiştir.

6.1.3. ADD, DPD - istatistiksel özellikler

Analiz ve özellik çıkarma aşamalarında akciğer ses işaretlerinden özellik vektörleri elde etmek amacıyla sırasıyla aşağıdaki adımlar gerçekleştirilmiştir.

- Sesler ADD ve DPD ile frekans alt bantlarına (detay ve yaklaşım dalgacık katsayılarına) ayrıştırılmıştır.
- Sesleri temsil edecek frekans alt bantları belirlenmiştir.
- Belirlenen her bir frekans alt bandındaki dalgacık katsayılarının mutlak değerlerinin ortalaması, maksimumu, standart sapması, güçlerinin ortalaması, sıfır geçiş sayısı ve komşu alt bantların dalgacık katsayılarının mutlak ortalamalarının oranları bulunarak özellik vektörleri oluşturulmuştur.

ADD ve DPD ile elde edilen özellik vektörlerini sınıflandırmada kullanılan YSA'nın giriş katmanları sırasıyla 29 ve 47 nörondan oluşmaktadır. Gizli katman her iki yöntem içinde 23 nöron, çıkış katmanı ise 6 nörondan oluşmaktadır.

Çizelge 6.9 ve Çizelge 6.10’da ADD ve DPD ile elde edilen akciğer ses işaretlerine ait özellik vektörlerinin 5 farklı algoritmayla sınıflandırılması sonucu oluşan sınıflandırma doğrulukları görülmektedir.

Çizelge 6.9. ADD ile analiz edilen akciğer ses işaretlerinin sınıflandırılma doğrulukları

Akciğer Sesleri		YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (%SD)
Sağ Bazal	NA	87.00	77.33	77.67	69.33	83.19
	NV	71.00	76.33	72.33	61.00	82.33
Sol Bazal	NA	93.00	85.33	78.33	66.00	92.11
	NV	80.33	66.67	71.00	63.00	75.33

SD%: Yüzdelik olarak sınıflandırılma doğruluğu
NA: Nefes Alma, NV: Nefes Verme.

Çizelge 6.10. DPD ile analiz edilen akciğer ses işaretlerinin sınıflandırılma doğrulukları

Akciğer Sesleri		YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (SD%)
Sağ Bazal	NA	88.33	79.00	76.00	68.00	79.66
	NV	78.67	70.00	69.67	61.33	85.52
Sol Bazal	NA	90.00	85.67	80.67	67.33	92.11
	NV	76.33	65.33	68.33	64.33	73,03

SD%: Yüzdelik olarak sınıflandırılma doğruluğu
NA: Nefes Alma
NV: Nefes Verme

Çizelge 6.9 ve 6.10’da görüldüğü gibi her iki dalgacık dönüşümünden elde edilen özellik vektörlerinin sınıflandırılma doğrulukları birbirlerine oldukça yakınlık göstermektedir. Bulanık K-NN ve YSA algoritmalarının en yüksek sınıflandırma doğruluğu veren sınıflandırıcılar olduğu da sonuçlardan görülmektedir.

6.2. Kalp Ses Verilerinin Sınıflandırılması

Her biri 17 vuruşmdan oluşan 9 farklı türdeki kalp sesleri özellik çıkarma aşamasından önce segmentasyon işlemine tabi tutulmuştur. Kalp seslerinin her biri, bir vuruş içerecek şekilde 17 segmente ayrılmıştır. Böylelikle analiz ve sınıflandırma için 9x17 adet kalp ses segmenti elde edilmiştir.

Kalp seslerinin analizi ve özellik çıkarımı için Welch, Burg, ARMA, ADD, DPD yöntemleri kullanılmıştır.

Kalp seslerinin Welch, Burg ve ARMA yöntemleri ile güç spektrum yoğunlukları bulunduğundan sonra TBA ve LDA boyut azaltma yöntemleri ile spektrumların boyutları indirgenmiş ve özellik vektörleri elde edilmiştir.

Kalp seslerinden özellik çıkarma amacıyla kullanılan diğer yöntemler ADD ve DPD'dir. Kalp sesleri dalgacık dönüşümleri ile frekans alt bantlarına (detay ve yaklaşım dalgacık katsayılarına) ayrıştırılmış ve seçilen alt bantlardan istatistiksel özellikler çıkarılarak özellik vektörleri elde edilmiştir.

Bütün özellik çıkarma yöntemleri ile elde edilen özellik vektörleri 5 farklı sınıflandırma algoritmasıyla sınıflandırılmıştır. Çizelge 6.11'de kalp seslerine ait sınıflandırılma doğrulukları gösterilmektedir.

Çizelge 6.11. Kalp ses işaretlerinin sınıflandırılma doğrulukları

Özellik Çıkarma Yöntemleri	Sınıflandırma Yöntemleri				
	YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (SD%)
Welch-TBA(10)	98.73	98.00	98.67	98.00	91.36
Welch-LDA(8)	99.33	99.33	99.33	99.33	98.78
Burg-TBA(8)	99.33	98.67	99.33	98.06	100
Burg-LDA(8)	99.33	100	100	99.33	99.52
ARMA- TBA(9)	94.00	88.06	93.39	85.45	91.11
ARMA- LDA(8)	95.33	92.06	95.39	89.52	94.94
ADD-İst. Özellik (29)	99.39	100	100	100	99.04
DPD-İst. Özellik (41)	100	97.39	100	100	98.08

SD%: Yüzdelik olarak sınıflandırılma doğruluğu

Çizelge 6.11'deki sonuçlardan;

Burg metodu, LDA boyut azaltma yöntemi, K-NN ve DVM sınıflandırıcılar kalp seslerinin analizi ve sınıflandırılması amacıyla birlikte kullanıldığı zaman %100 olarak en yüksek doğruluk oranını üretmiştir.

Ayrıca ADD, istatistiksel işlemler, K-NN, DVM ve Naive Bayes algortimaları birlikte kullanıldığında ve DPD, istatistiksel işlemler, YSA, DVM ve Naive Bayes algortimaları birlikte kullanıldığında en yüksek doğruluk oranı olan %100 sonucunu üretmişlerdir.

Kalp sesleri için LDA algoritmasının boyut azaltma işleminde TBA algoritmasından daha iyi olduğu da sonuçlardan gözlenmektedir.

Spektral analiz ve TBA yöntemleri, YSA sınıflandırıcı algoritması ile kullanıldığında diğer sınıflandırıcılara oranla kısmen daha yüksek sonuçlar üretmiştir.

6.3. Konuşma Ses Verilerinin Sınıflandırılması

Özellikleri çıkarılmış konuşma ses verilerinden MRMR algoritması ile sırasıyla 5, 6, 7, 8, 9, 10 adet özellik MID ve MIQ kriterlerine göre seçilmiştir. Seçilen özneliklerden oluşan özellik vektörleri YSA, K-NN, DVM, Naive Bayes ve Bulanık K-NN algoritmaları ile sınıflandırılmıştır.

26 özellikli orijinal konuşma sesleri YSA ile sınıflandırıldığında %72,59, K-NN ile sınıflandırıldığında % 68,04, DVM ile sınıflandırıldığında % 66,90, Naive Bayes ile sınıflandırıldığında % 66,90 ve Bulanık K-NN ile sınıflandırıldığında %70,76 sınıflandırılma doğrulukları elde edilmiştir.

Çizelge 6.12’de seçilmiş özneliklerin farklı sınıflandırıcılarla sınıflandırılması sonucu oluşan sınıflandırma doğrulukları gösterilmektedir.

Çizelge 6.12. Konuşma ses işaretlerinin sınıflandırılma doğrulukları

MRMR Kriterleri	Seçilen Özellik Sayısı	Sınıflandırma Yöntemleri				
		YSA (SD%)	K-NN (SD%)	DVM (SD%)	N.Bayes (SD%)	Bulanık K-NN (SD%)
MID	5	71,53	66,80	63,01	64,25	60,51
MIQ	5	68,22	65,73	61,43	63,67	65,48
MID	6	71,78	68,29	65,25	63,35	60,09
MIQ	6	68,05	66,14	61,68	63,17	64,46
MID	7	73,28	65,48	65,99	63,92	63,00
MIQ	7	69,71	65,73	63,80	65,41	64,33
MID	8	70,62	63,82	65,49	64,41	61,50
MIQ	8	72,44	67,63	63,17	66,23	66,13
MID	9	71,61	64,06	65,49	66,15	62,17
MIQ	9	72,77	67,80	66,91	66,57	67,88
MID	10	70,53	63,33	65,57	66,24	63,41
MIQ	10	71,77	68,71	67,32	67,65	67,80

SD%: Yüzdelik olarak sınıflandırılma doğruluğu

7. SONUÇ ve ÖNERİLER

Bu çalışmada biyomedikal seslerden olan akciğer sesleri, kalp sesleri ve konuşma sesleri analiz edilmiş ve sınıflandırılmıştır.

Çalışmada sesler ilk olarak ön işlemlerden geçirilmiştir. Her bir ses işareti alçak, yüksek veya bant geçiren filtrelerden geçirilerek gürültülerden ve istenmeyen (gereksiz) frekans bileşenlerinden arındırılmıştır. Filtreleme işlemlerinin ardından sesler segmente edilerek daha düşük süreli ses segmentleri elde edilmiştir.

Seslerin analizi için hızlı Fourier dönüşümü temelli Welch yöntemi, öz bağlanım (AR) metotlarından olan Burg yöntemi, ARMA metodu, ayrık ve paket dalgacık dönüşümleri kullanılmıştır. Welch, Burg ve ARMA yöntemleri ile seslerin güç spektrum yoğunlukları bulunarak seslere ait frekans bilgileri elde edilmiştir. LDA, TBA, bulanık c ortalama algoritması ve istatistiksel işlemler özellik vektörlerinin boyutlarının azaltılması amacıyla çalışmada kullanılmıştır.

Ses işaretlerine ait özellik vektörlerinin sınıflandırılması amacıyla tez çalışmasında kullanılan makine öğrenmesi yöntemleri;

- ✓ Yapay Sinir Ağları (YSA)
- ✓ K En Yakın Komşuluk Algortiması (K-NN)
- ✓ Destek Vektör Makineleri (DVM)
- ✓ Naive Bayes Algoritması
- ✓ Bulanık K-En Yakın Komşuluk Algortiması

Akciğer sesleri sağ bazal ve sol bazal için nefes alma ve nefes verme aşamaları ayrı düşünülerek analiz ve sınıflandırma işlemlerine tabi tutulmuştur. Ses işaretleri 6 farklı sınıfa sınıflandırılmıştır.

Bu sınıflar;

- ✓ Normal (Sağlıklı)
- ✓ Hafif Derecede Astım
- ✓ Orta Derecede Astım
- ✓ Ağır Derecede Astım
- ✓ Kronik Obstrüktif Akciğer Hastalığı (KOAİ)
- ✓ Hipersensitive Pnömosi

Tez çalışmasında akciğer sesleri 3 farklı şekilde analiz edilmiş ve sınıflandırılmıştır.

Akciğer sesleri ile yapılan ilk sınıflandırmada, analiz yöntemleri olarak hızlı Welch, Burg ve ARMA spektral analiz yöntemleri kullanılmıştır. Boyut azaltma amacıyla, spektral analiz yöntemleri ile bulunan spektrumlar frekans alt bantlarına ayrıştırılmış ve seçilen alt bantlardan istatistiksel özellikler çıkarılmıştır. Böylelikle çıkarılan istatistiksel özellikleri içeren özellik vektörleri elde edilmiştir. Elde edilen özellik vektörleri YSA, K-NN, DVM, Naive Bayes ve bulanık K-NN makine öğrenmesi yöntemleri ile sınıflandırılmıştır.

Gerçekleştirilen işlemler sonucunda elde edilen en iyi sınıflandırılma doğrulukları, bu doğrulukların hangi analiz ve sınıflandırıcı yöntemleri ile elde edildiği aşağıda belirtilmiştir.

Sağ bazal nefes alma ve nefes verme ses işaretlerinin ARMA yöntemi ile analiz ve YSA ile sınıflandırılma işlemleri gerçekleştirildiğinde, sırasıyla %86 ve %84.64 sınıflandırma doğrulukları elde edilmiştir.

Sol bazal nefes alma ses işaretlerinin Burg yöntemi ile analizi, YSA ile sınıflandırılma işlemi gerçekleştirildiğinde %93, nefes verme ses işaretlerinin Burg yöntemi ile analizi ve bulanık K-NN ile sınıflandırılması gerçekleştirildiğinde %82,58 sınıflandırma doğruluk oranları elde edilmiştir.

Akciğer sesleri ile yapılan ikinci sınıflandırmada, seslerin analizi için aynı spektral analiz yöntemleri kullanılmıştır. Ancak boyut azaltma işlemi bulanık c ortalama kümeleme algoritması kullanılarak gerçekleştirilmiştir. Bu işlemler sonucunda;

Sağ bazal nefes alma ses işaretlerinin Burg yöntemi ile analizi ve bulanık k en yakın komşuluk algoritması ile sınıflandırılma işlemi gerçekleştirildiğinde en yüksek doğruluk oranı %90.98 ve ortalama doğruluk oranı %88.26 olarak elde edilmiştir.

Sağ bazal nefes verme ses işaretlerinin analizi için ARMA, sınıflandırılması için YSA yöntemleri kullanıldığında, en yüksek doğruluk oranı %85.67 ve ortalama doğruluk oranı %81.06 olarak elde edilmiştir.

Sol bazal nefes alma ses işaretlerinin analizi Burg yöntemi, sınıflandırılması sırasıyla bulanık K-NN ve YSA algoritmaları ile gerçekleştirildiğinde en yüksek sınıflandırılma doğruluğu %89,49, ortalama sınıflandırılma doğruluğu %85.23 olarak elde edilmiştir.

Sol bazal nefes verme ses işaretlerinin analizi için Burg, sınıflandırılması için bulanık K-NN algoritması kullanıldığında en yüksek sınıflandırılma doğruluğu %72,77, ortalama sınıflandırılma doğruluğu ise %67,21 olarak elde edilmiştir.

Akciğer sesleri ile yapılan son sınıflandırma da ise analiz yöntemleri olarak ADD ve DPD yöntemleri kullanılmıştır. Boyut azaltma işlemi için istatistiksel özelliklerden faydalanılmıştır. Gerçekleştirilen işlemler sonucunda;

Sağ bazal nefes alma ve nefes verme ses işaretlerinin analizi için DPD, sınıflandırılması amacıyla ise nefes alma için YSA, nefes verme için bulanık K-NN komşuluk algoritması kullanıldığında aşağıdaki sınıflandırılma doğrulukları elde edilmiştir.

Sağ bazal nefes alma: %88.33

Sağ bazal nefes verme:%85.67

Sol bazal nefes alma ve nefes verme ses işaretlerinde ise analiz için ADD, sınıflandırma için YSA kullanıldığında daha iyi sonuçlar elde edilmiştir. Elde edilen sınıflandırma doğrulukları:

Sol bazal nefes alma: %93.00

Sol bazal nefes verme:%80.33

AR, ARMA spektral analiz yöntemlerinin ve dalgacık dönüşümlerinin akciğer seslerinin analizi için YSA sınıflandırılma algoritması ile kullanıldığında yüksek sayılabilecek sınıflandırma doğrulukları ürettiği elde edilen sonuçlardan gözlemlenmiştir.

Kalp ses işaretleri 9 farklı türe sınıflandırılmıştır.

Sınıflar;

- ✓ Normal kalp sesleri (birinci S1 ve ikinci S2)
- ✓ Üçüncü kalp sesi(S3)
- ✓ Dördüncü kalp sesi(S4)
- ✓ Açılma sesi
- ✓ Midsistolik klik + geç sistolik üfürüm
- ✓ Aort stenozu
- ✓ Atriyal septal defekt
- ✓ Aentrikuler septal defekt

✓ Patent duktus arteriyozus

Kalp seslerine ait özellik vektörlerinin çıkarılması için, ilk olarak Welch, Burg ve ARMA spektral analiz yöntemleri kullanılmıştır. Spektral analiz yöntemleri ile seslere ait güç spektrum yoğunlukları hesaplanarak seslere ait özellik vektörleri elde edilmiştir. TBA ve LDA özellik vektörlerinin boyutunun azaltılması amacıyla kullanılmıştır.

Kalp seslerinin analizi için Burg yöntemi, LDA boyut azaltma yöntemi ve 5 farklı makine öğrenmesi yöntemi ile kullanıldığında yüksek sınıflandırma doğrulukları elde edilmiştir.

Elde edilen sınıflandırma doğrulukları;

Kalp sesleri + AR-Burg + LDA+ YSA: %99.33

Kalp sesleri + AR-Burg + LDA+ K-NN: %100

Kalp sesleri + AR-Burg + LDA+ DVM: %100

Kalp sesleri + AR-Burg + LDA+ Naive Bayes: %99.33

Kalp sesleri + AR-Burg + LDA+ Bulanık K-NN: %99.52

Kalp seslerine ait özellik vektörlerinin çıkarılması için, ADD ve DPD de kullanılan diğer yöntemlerdir. Bu yöntemler sonucu elde edilen özellik vektörlerinin boyutlarının azaltılması için istatistiksel özelliklerden faydalanılmıştır.

ADD yöntemi K-NN, DVM ve Naive Bayes sınıflandırma algoritmaları ile birlikte kullanıldığında, kalp sesleri için %100 sınıflandırılma doğrulukları elde edilmiştir.

DPD yöntemi YSA, DVM ve Naive Bayes sınıflandırma algoritmalar ile kullanıldığında, kalp sesleri için yine %100 sınıflandırılma doğrulukları elde edilmiştir.

Özellik çıkarma başarılı bir sınıflandırma için en önemli aşamadır. Kalp seslerinin özellik çıkarımında kullanılan Ar-Burg ve dalgacık dönüşüm yöntemlerinin kalp seslerin sınıflandırılma sonuçlarına önemli etkisi olmuştur.

Parkinson hastalığına sahip bireylerden ve sağlıklı bireylerden kaydedilmiş, sonrasında da özellikleri çıkarılmış seslere ait özellik vektörlerine MRMR algoritması özellik seçme amacıyla uygulanmıştır. Seçilen özellikleri barındıran özellik vektörleri sınıflandırma algoritmaları ile normal ve parkinson hastası olarak sınıflandırılmışlardır.

MRMR algoritması ile MID kriterine göre 7 özellik seçildiğinde ve seçilen özellikler YSA ile sınıflandırıldığında en yüksek sınıflandırılma doğruluğu % 73,28 olarak elde edilmiştir. Bu oran 26 özellikli orijinal konuşma seslerinin YSA ile sınıflandırılma doğruluğundan daha yüksektir.

MRMR algoritması ile MIQ kriterine göre 10 özellik seçip K-NN, DVM, N.Bayes ve Bulanık K-NN algoritmaları ile sınıflandırma işlemleri gerçekleştirildiğinde ise sırasıyla % 68,71, %67,32, % 67,65 ve %67,80 sınıflandırma doğrulukları elde edilmiştir. Elde edilen sınıflandırma doğrulukları, 26 özellikli orijinal konuşma seslerinin K-NN, DVM ve Naive Bayes algoritmaları ile sınıflandırılmaları sonucu üretilen doğruluktan daha yüksektir.

Yapılan analiz ve sınıflandırılma sonuçlarından, her bir biyomedikal ses verisinin farklı karakteristik özellik gösterdiği görülmektedir. Bu nedenle tez çalışmasında kullanılan bütün biyomedikal seslerin analizini en iyi şekilde gerçekleştirebilecek bir yöntem belirlenememiştir. Ancak elde edilen sınıflandırma sonuçlarına göre, Burg ve dalgacık dönüşüm yöntemlerinin seslerin analizi için kullanımının uygun olduğu çıkarımı yapılabilmektedir.

Bulanık K-NN ve YSA algoritmalarının akciğer ses işaretlerinin sınıflandırılmasında yüksek sınıflandırma doğruluklarını ürettiği sonuçlardan görülmektedir.

YSA, kullanılan diğer tüm biyomedikal seslerin sınıflandırılmasında da en yüksek sınıflandırma doğruluklarını üretmiştir. Sonuçların genelinde K-NN algoritması YSA'dan sonra en iyi sonuç üreten sınıflandırıcı olarak görülmektedir. DVM ve Naive Bayes sınıflandırıcılar ise birbirlerine oldukça yakın sınıflandırma doğrulukları üretmişlerdir.

Biyomedikal sesler organ ve sistemlerin mekanik aktivitelerini temsil etmektedirler. Bu sesler sayısal ortamlarda otomatik şekilde analiz edilebilir bu sayede hastalıkların teşhisinde kullanılabilirler.

Bu çalışmada, bilgisayar tabanlı makine öğrenmesi ve işaret işleme algoritmaları ile tıbbi teşhise yardımcı olunmaya çalışılmıştır. Bu sayede teşhis, tanı süresi de azaltılabilmektedir. Birden fazla hastalığın olduğu karmaşık vakaların teşhisinde bilgisayar tabanlı yöntemler kullanılarak hekimlerin daha doğru teşhis yapmaları sağlanabilir.

Her ne kadar son yıllarda biyomedikal seslerin sayısal ortamlarda kaydedilmesi, işlenmesi, analizi ve sınıflandırılması konuları üzerine birçok çalışma gerçekleştirilmiş

olsa da bilgisayar tabanlı biyomedikal ses analizi henüz klinik ortamlarda kullanılabilen bir seviyeye ulaşmamıştır. Gerçek zamanlı bilgisayar tabanlı ses analiz sistemlerinin geliştirilebilmesi ve ticarileştirilebilmesi konuları ileriye yönelik, araştırmacılar için önemli çalışma alanlarından bir olacaktır.

KAYNAKLAR

- Abacı, B., 2012, Fourier Dönüşümü [online], <http://www.cescript.com/2012/05/fourier-donusumu-jean-baptiste-joseph.html>, [Ziyaret Tarihi: 2 Aralık 2015].
- Abbas, A. K., Bassam, R., Kasim, R. M., 2008, Mitral regurgitation PCG-signal classification based on adaptive Db-wavelet, *4th Kuala Lumpur International Conference on Biomedical Engineering IFMBE Proceedings*, 21, 212-216.
- Acharya U. R., Sankaranarayanan, M., Nayak, J., Xiang, C. and Tamurad, T., 2008, Automatic identification of cardiac health using modeling techniques: A comparative study, *Information Sciences*, 178, 4571-4582.
- Açıkel, Ü., 2013, Kalbin Genel Anatomisi [online], <http://www.unalacikel.com.tr/kalp-damar-cerrahi.asp?alt=1> [Ziyaret Tarihi: 17 Kasım 2014].
- Aka, L., 2006, Diagnosis using pulmonary sounds and design of an electronic auscultation device, *University of Gaziantep at the Graduate School of Natural Applied Science*.
- Akkaya, E., Ayık, Ş. ve İlhan, F., 2013, Ortaöğretim biyoloji 12, Milli Eğitim Bakanlığı Yayınları Ders Kitapları Dizisi, 47.
- Akkoç, S. ve Elitaş, C., 2010, Yapay sinir ağları ve doğrusal ayırma analizi ile kredi derecelendirme, *14. Ulusal Finans Sempozyumu*, Selçuk Üniversitesi İktisadi ve İdari Bilimler Fakültesi 3 – 6 Kasım 2010.
- Aktaş, M. ve Okumuş, H. İ., 2003, Doğrudan moment kontrollü asenkron motorun stator direncinin yapay sinir ağı ile kestirimi, *International XII. Turkish Symposium on Artificial Intelligence and Neural Networks*, TAİNN-03, 189–191.
- Alajarin, J. M., Candel, J. L. and Merino, R. R., 2007, Classification and diagnosis of heart sounds and murmurs using artificial neural networks, *Part I: Bio-inspired Modeling of Cognitive Tasks, WINAC '07 Proceedings of the 2nd international work- conference on The Interplay Between Natural and Artificial Computation*, 303-312,
- Aljarad, N., Davies, S. W., Logan-Sinclair, R. and Rudd, R. M., 1994, Lung crackle characteristics in patients with asbestosis, asbestos-related pleural disease and left ventricular failure using a time-expanded waveform analysis - a comparative study, *Respiratory Medicine*, 88, 37-46.
- Alkan, 2006, EEG işaretlerinin ayrıştırılmasında, altuzay yöntemlerinin kullanılması, *Journal of Yaşar University*, 1(3), 211-219.
- Alpman, A., 2012, Kalp kapak hastalıkları [online], <http://www.ahmetalpman.com/defkonuoku.asp?id=2650> [ziyaret Tarihi: 17-20 Kasım 2014]

- Alsmadi, S. and Kahya, Y.P., 2008, Design of a DSP-based instrument for real-time classification of pulmonary sounds, *Comput Biol Med* , 38,53–61.
- Altun, M., 2014, Ses bilgisi [online], <http://www.dilbilimi.net/sesbilgisi.htm>, [Ziyaret Tarihi: 24 Kasım 2014].
- Amiri, A. M. and Armano, G., 2013, Heart sound analysis for diagnosis of heart diseases in newborns, *APCBEE Procedia* 7, 109-116.
- Amit, G., 2004, Heart Sound Analysis: Theory, techniques and applications, *Advanced Research Seminar*, May 2004.
- Amit, G., Gavriely, N. and Intrator, N., 2009, Cluster analysis and classification of heart sounds, *Biomedical Signal Processing and Control*, 4, 26-36.
- Anderson, K., Aitken, S., Carter, R., MacLeod, J. E., and Moran, F., (1990), Variation of' breath sound and airway caliber induced by histamine challenge, *Am Rev Respir Dis*, 141(5), 1147-1150.
- Anonim, 2005, Soluk alıp verme problemleri [online], <http://www.labs.com.tr/meraket6.htm> [Ziyaret Tarihi: 10 Kasım 2014].
- Anonim, 2010, Solunum yetmezliği [online], http://www.respitek.com.tr/kronik_bronsit.asp [Ziyaret Tarihi: 10 Kasım 2014].
- Anonim 2011, Alerjik astım tanısı deri testleri [online], <http://hastanebolumleri.blogspot.com.tr/2011/02/alerjik-astm-tans-deri-testleri.html> [Ziyaret Tarihi: 10 Kasım 2014].
- Anonim 2014, Sağ ve sol akciğerlerin yapıları [online], <http://www.erguven.net/anasayfa/yazigoster/Sag-ve-Sol-Akcigerlerin-Yapilari-6-Sinif-Fen497> [Ziyaret Tarihi: 4 Kasım 2014].
- Arnott, P. J., Pfeiffer, G. W., and Tavei, M. E., 1984, Spectral analysis of heart sounds: relationships between some physical characteristics and frequency spectra of first and second heart sounds in normals and hypertensives, *J Biomed Eng*, 6(2), 121-128.
- Arslan, N., 2013, Akciğerler nasıl çalışır [online], <http://hastaneciyiz.blogspot.com.tr/2013/01/akcigerler-nasil-calisir.html> [Ziyaret Tarihi: 4 Kasım 2015].
- Atasoy, H., 2012, Kaynak: <http://www.atasoyweb.net/Temel-Bilesen-Analizi-Ile-Yuz-Tanima>, [Ziyaret Tarihi:21 Aralık 2014]
- Ateş 2009, Vücudumuz ve sistemler, <http://atespervane.blogcu.com/vucudumuz-ve-sistemler/4363365> [Ziyaret Tarihi: 4 Kasım 2014]

- Aydöre, S., 2009, Wheeze detection in respiratory sounds via statistical signal modeling, University of Bogaziçi at the Graduate Program in Electrical and Electronics Engineering.
- Azarbarzin, A. and Moussavi, Z., 2010, Unsupervised classification of respiratory sound signal into snore/no-snore classes, *Engineering in Medicine and Biology Society (EMBC)*, 3666–3669, Annual International Conference of the IEEE .
- Babaoğlu, İ., Kıran, M. S., Ülker, E. and Gündüz, M., 2013, Diagnosis of coronary artery disease using artificial bee colony and K-Nearest Neighbor Algorithms, *International Journal of Computer and Communication Engineering*, 2 (1), 56-59.
- Bahoura, M. and Pelletier, C., 2003, New parameters for respiratory sound classification, in: Electrical and Computer Engineering, *Canadian Conference on IEEE CCECE*, 3, Montreal, Canada, May 4–7, 2003, 1457–1460.
- Bahoura, M. and Pelletier, C., 2004, Respiratory sounds classification using Gaussian mixture models, in: Electrical and Computer Engineering, *Canadian Conference on IEEE CCECE 2004*, 3, Niagara Falls, Canada, May 2–5, 1309–1312.
- Bahoura, M. and Pelletier, C., 2004, Respiratory sounds classification using cepstral analysis and Gaussian mixture models, in: *26th Annual Conference of the IEEE EMBS*, San Francisco, CA, September 1–5, 9–12.
- Bahoura, M., 2009, Pattern recognition methods applied to respiratory sounds classification into normal and wheeze classes, *Comput. Biol. Med.*, 39, 824–843.
- Banham, S. W., Urquhart, R. B., MacLeod, J. E., and Moran, F., 1984, Alteration in the low frequency lung sounds in respiratory disorders associated with crackles, *Eur J Respir Dis*, 65 (1), 58-63.
- Basturk, A., Yugnak, Z., Ketencioglu, H. ve Yuksel, M. E., 2006, Gabor Dalgacıkları ve Temel Bileşen Analizi Kullanarak Tekstil Kumaşlarında Hata Denetimi, *Elektrik, Elektronik ve Bilgisayar Mühendisliği Sempozyumu ve Fuarı, ELECO-2006*, Bursa, 222-226..
- Bates, B., A Guide to Physical Examination, 2nd Ed., Lippincott Company, 1979, USA.
- Baughman R. P. and Loudon R. G., 1985, Lung sound analysis for continuous evaluation of airflow obstruction in asthma. *Chest*, 88(3), 364-368, Epub 1985/09/01.
- Baughman, R. P. and Loudon, R. G., 1984, Quantization of Wheezing in Acute Asthma. *Chest*, 5, 718-722.
- Bayhan S. ve Yılmaz D., (2009). Güç sistemlerinde meydana gelen dalga şekli bozukluklarının dalgacık dönüşümü yardımıyla tespiti, *e-Journal of New World Sciences Academy -Technological Applied Sciences*, 2, 151-162.

- Baykut, S., 2011, Ayırık Fourier dönüşümü (DFT) & hızlı Fourier dönüşümü (FFT) [online], http://web.itu.edu.tr/~baykut/lab/pdf/Deney_3.pdf [Ziyaret Tarihi: 2 Aralık 2014].
- Bayrakçı, N. ve Barışçı, N., 2008, Mitral kapak doppler işaretlerinin bulanık kümeleme ile sınıflandırılması, *Bursa ELECO*, 181-191.
- Bhatikar, S. R., DeGroff, C. and Mahajan, R. L., 2005, A classifier based on the artificial neural network approach for cardiologic auscultation in pediatrics, *Artificial Intelligence in Medicine*, 33 (3), 251–260.
- Binak, K., Sırmacı, N. ve Başarı, I., Pratik Kardiyoloji, 1991, Sandoz Ürünleri A. Ş. İlaç Bölümü, İstanbul, Sayfa: 19-23.
- Bobrowski, L. and Łukaszuk, T., 2009 Feature selection based on relaxed linear separability, *Biocybern Biomed Eng.*, 29, 43–59.
- Bocklet, T., Nöth, E., Stemmer, G., Ruzickova, H. and Rusz, J., 2011, Detection of persons with Parkinson's disease by acoustic, vocal, and prosodic analysis, *ASRU*, 478–483.
- Broersen, P. M. T. and de Waele, S., 2000, Detection of methacholine with time series models of lung sounds, *IEEE T instrum Meas*, 49(3), 517-523.
- Broersen, P. M. T., 2002, Automatic spectral analysis with time series models, *IEEE Transactions on Instrumentation and Measurement*, 51 (2), 211-216.
- Çağlayan, B., 2014, Astım [online], <http://www.akcigerim.com/?sayfa=astim> [Ziyaret Tarihi: 10 Kasım 2014]
- Çağlayan, B., 2014, Kronik obstrüktif akciğer hastalığı (KOAH) [online], <http://www.akcigerim.com/?sayfa=koah> [Ziyaret Tarihi: 10 Kasım 2014]
- Çağlayan, B., 2014, Pnömoni (Zatürre) [online], <http://www.akcigerim.com/?sayfa=pnomoni> [Ziyaret Tarihi: 10 Kasım 2014]
- Canbaz, S., 2006, Atrial Septal Defekt ve Cerrahi Tedavisi, *Türkiye Klinikleri J Pediatr*, 2(12), 28-35.
- Chebil, J., and Al-Nabulsi, J., 2007, Classification of heart sound signals using discrete wavelet analysis, *International J. of Soft Computing*, 2 (1), 37-47.
- Chen, H. L., Liu, D. Y., Yang, B., Liu, J., Wang, G., Wang, S. J., 2011, An adaptive fuzzy k-nearest neighbor method based on parallel particle swarm optimization for bankruptcy prediction advances in knowledge discovery and data mining, *Lecture Notes in Computer Science*, 6634, 249-264.
- Choi, S. and Zhongwei, J., (2010), Cardiac sound murmurs classification with autoregressive spectral analysis and multi-support vector machine technique, *Computers in Biology and Medicine*, 40, 8-20.

- Choi, S. and Jiang, Z., 2005, Development of wireless heart sound acquisition system for screening heart valvular disorder, in: *Proceedings of the SICE Annual Conference*, 3771–3776.
- Choi, S. and Jiang, Z., 2008, Comparison of envelope extraction algorithms for cardiac sound signal segmentation, *Expert Systems with Applications*, 34 (2), 1056–1069.
- Choi, S. and Jiang, Z., 2010, Cardiac sound murmurs classification with autoregressive spectral analysis and multi-support vector machine technique, *Computers in Biology and Medicine*, 40, 8-20.
- Cooley, J. W. and Tukey, J. W., 1965, An Algorithm for the Machine Computation of Complex Fourier Series, *Mathematics of Computation*, 19, 297-301.
- Cortes, C. and Vapnik, V., 1995, Support vector networks, *Machine Learning*, 20,1-25.
- Coşkun, M. ve İstanbullu, A., 2012, EEG İşaretlerinin FFT ve dalgacık dönüşümü ile analizi, *Akademik Bilişim '12 - XIV. Akademik Bilişim Konferansı*, 323-328.
- Dallali, A., Kachouri, A., and Samet, M., 2011, Fuzzy c means clustering, neural network, WT, and HRV for classification of cardiac arrhythmia, *ARPJ Journal of Engineering and Applied Sciences*, 6 (10), 112-118.
- Debbal, S. and Bereksi-Reguig, F., 2006, Spectral analysis of the PCG signals, *The Internet Journal of Medical Technology*, 2006, 4 (1).
- Debbal, S. M. and Bereksi-Reguig, F., 2007, Time-frequency analysis of the first and the second heartbeat sounds, *Applied Mathematics and Computation*, 184, 1041-1052.
- Debbal, S. M., 2008, Computerized heart sounds analysis, *Comput Biol Med*, 38(2),263-280.
- Debbal, S. and Bereksi-Reguig, F., 2004, Analysis of the second heart sound using continuous wavelet transforms, *J. Med. Eng. Technol*, 28, 151–156.
- Demirhan, A., Kılıç, Y. A. ve Güler, İ., 2009, Tıpta yapay zeka uygulamaları, 5. *Cerrahi Araştırma Kongresi*, Ankara, 2009 Aralık.
- Ding, C. and Peng, H.C., 2003, Minimum redundancy feature selection from microarray gene expression data, Proc., *Second IEEE Computational Systems Bioinformatics Conf.*, Aug. 2003, 523-528.
- Dokur, Z. and Olmez, T., 2003, Classification of respiratory sounds by using an artificial neural network, *International Journal of Pattern Recognition and Artificial Intelligence*, 17 (4), 567–580.
- Dokur, Z., and Ölmez, T., 2008, Heart sound classification using wavelet transform and incremental self-organizing map, *Digital Signal Processing*, 18, 951-959.

- Doring, C., Lesot, M. J. and Kruse, R., 2006, Data analysis with fuzzy clustering methods, *Computational Statistics & Data Analysis*, 194.
- Dursun, H., 2014, Kardiyovasküler hastalıklar [online], <https://prezi.com/aaxzgoebumuw/untitled-prezi/> [Ziyaret Tarihi: 17 Kasım 2014].
- Elgendi, M., Bobhate, P., Jain, S., Guo, L., Rutledge, J., Coe, Y., Zempc, R., Schuurmans, D. and Adatia I., 2014, Spectral analysis of the heart sounds in children with and without pulmonary artery hypertension, *International Journal of Cardiology*, 173, 92–99.
- Engin, B., 2011, Bronşit: Akut ve kronik bronşitin nedenleri, belirtileri, tanısı ve tedavisi [online], <http://www.saglik.net/bronsit.html> [Ziyaret Tarihi: 10 Kasım 2014].
- Erbaş, O., 2014, Kardiyoloji [online], <http://www.oytunerbas.com.tr/kardiyoloji> [Ziyaret Tarihi: 18 Kasım 2014].
- Erdoğan ve Pekçakar, 2009 Dalgacık dönüşümü ile EKG sinyallerinin özellik çıkarımı ve yapay sinir ağları ile sınıflandırılması, *5. Uluslararası İleri Teknolojiler Sempozyumu (IATS'09)*, 13-15 Mayıs 2009, Karabük, Türkiye.
- Ergen, B., 2011, Kalp seslerinin güç ve yüksek derece spektrum kestirim teknikleri ile doğrusallık analizi, *Fırat Univ. Journal of Engineering*, 23(1), 53-60.
- Ertan, E., 2001, Parkinson hastalığında ses ve konuşma gücü [online], http://www.novartis.com.tr/Default.aspx?sayfa=parkinson_hastaliginda_ses [Ziyaret Tarihi: 24 Kasım 2014].
- Etike, E., 2009, Yapay sinir ağı temelli model esaslı kontrol algoritmasının bir polimer reaktörüne uygulanması, Yüksek Lisans Tezi, *Ankara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 10-22.
- Fausett, L., 1994, Fundamentals of neural networks: architectures, algorithms and applications, USA, Prentice Hall.
- Fenton, T., Pasterkamp, H., Tal, A. and Chernick, V., 1985, Automated spectral characteristics of wheezing in asthmatic children, *IEEE Trans Biomed Eng*, 32, 50-55.
- Fiz, J. A., Jane, R., Salvatella, D., Izquierdo, J., Lores, L., Caminal, P. and Morera, J., 1999, Analysis of tracheal sounds during forced exhalation in asthma patients and normal subjects: bronchodilator response effect, *Chest*, 116 (3), 633-638.
- Flietstra, B., Markuzon, N., Vyshedskiy, A. and Murphy, R., 2011, Automated analysis of crackles in patients with interstitial pulmonary fibrosis, *Pulmonary Medicine*.

- Forkheim, K. E., Scuse, D. and Pasterkamp, H., 1995, A comparison of neural network models for wheeze detection, *in: IEEE WESCANEX 95 Proceedings*, 1, New York, USA , 214–219.
- Gavriely, N., Palti, Y. and Alroy, G., 1981, Spectral characteristics of normal breath sounds, *J. uppl. Physiol.*, 50, 307-314.
- Gavriely, N., Palti, Y., Alroy, G. and Grotberg, J. B., 1984, Measurement and theory of wheezing breath sounds, *JAppl Physiol*, 57 (2), 481-492.
- Gavriely, N. and Herzberg, M., 1992, Parametric representation of normal breath sounds, *J Appl Physiol*, 73(5), 1776-1784.
- Gavriely, N., Nissan, M., Rubin, A. H. and Cugell, D. W., 1995, Spectral characteristics of chest wall breath sounds in normal subjects, *Thorax*, 50 (12), 1292-1300.
- Gross, V., Dittmar, A., Penzel, T., Schuttier, F. and von Wichert, P., 2000, The relationship between normal lung sounds, age, and gender, *Ain J Respir Crit Care Med*, 162 (3), 905-909.
- Grung, A., Scrafford, C. G., Tielsch, J. M., Levine, O. S. and Checkley W., 2011, Computerized lung sound analysis as diagnostic aid for the detection of abnormal lung sounds: a systematic review and meta-analysis, *Respir. Med.*, 105 (9), 1396-1403.
- Guerra, E. C. and Lovely, D. F., 2003, A modern approach to dysarthria classification, *Proceedings of the IEEE Conference on Engineering in Medicine and Biology Society (EMBS)*, 2257–2260.
- Güler, S., 2013, Kalbin Yapısı İşleyişi ve Görevi Hakkında Bilgiler [online], <http://www.bilgihanemiz.com/2013/04/kalbin-yaps-isleyisi-ve-gorevi-hakknda.html> [Ziyaret Tarihi: 17 Kasım 2014].
- Güler, İ., Polat, H. and Ergun, U., 2005, Combining neural network and genetic algorithm for prediction of lung sounds, *Journal of Medical Systems*, 29, 217-231.
- Gupta, C. N., Palaniappan, R., Rajan, S., Swaminathan, S., Krishnan, S. M., Segmentation and classification of heart sounds, *Electrical and Computer Engineering, Canadian Conference on*, 1674-1677.
- Gupta, C. N., Palaniappan, R., Swaminathan, S. and Krishnan, S. M., 2007, Neural network classification of homomorphic segmented heart sounds, *Appl. Soft Comput*, 7, 286-297.
- Güçlü, G., 2010, Comparison of different feature extraction methods to analysis lung sound signals, Yüksek Lisans Tezi, *Fatih Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.

- Gülgün, M., Fidancı, K. ve Demirbaş, S., 2013, Aile Hekimliğinde sağlam çocuk izlemi, Derman Tıbbi Yayıncılık, Ankara, 82-87.
- Güraksın, G. E, and Uğuz, H., 2011, Classification of heart sounds based on the least squares support vector machine, *International Journal of Innovative Computing, Information and Control*, 7 (12) , 7131–7144.
- Güven, Y., 2011, Hasta tanılamada fiziksel değerlendirme [online], www.acibademhemsirelik.com/e-dergi/yeni_tasarim/files/yasemin.pdf [Ziyaret Tarihi: 6 Kasım 2014]
- Hadi, H. M., Mashor, M. Y., Suboh, M. Z. and Mohamed, M. S., 2010, Classification of heart sound based on s-transform and neural network, *Information Sciences Signal Processing and their Applications (ISSPA), 10th International Conference on*, 189-192.
- Hadjileontiadis, L. J. and Panas, S. M., 1998, A wavelet-based reduction of heart sound noise from lung sounds, *Int. J. Med. Inform.*, 52, 183-190.
- Hernandez, G. M., Corrales, T. A., Camarena, R. G., Villalobos, S. C. and Lem G. C., 2005, Computerized classification of normal and abnormal lung sounds by multivariate linear autoregressive model, in: *Proc. IEEE EMBS 2005*, 5999–6002.
- Homs-Corbera, A., Fiz, J. A., Morera, J. and Jané, R., 2004, Time-Frequency detection and analysis of wheezes during forced exhalation, *IEEE Transactions on Biomedical Engineering*, 51(1).
- Howel, D. C. J., 2006, Signs of respiratory disease: lung sounds, *Oxford: Academic Press*, 35-41.
- Höppner, F., Klawonn, F., Kruse, R., and Runkler, T., 1999, Fuzzy cluster analysis, Wiley, Chichester .
- Işık, M. ve Çamurcu, A. Y., 2007, K-Means, K-Medoids ve bulanık C-Means algoritmalarının uygulamalı olarak performanslarının tespiti, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 31-45.
- İçer, S., and Gengeç, Ş., 2014, Classification and analysis of non-stationary characteristics of crackle and rhonchus lung adventitious sounds, *Digital Signal Processing*, 28, 18-27.
- İsenkul, M. E., 2011, Parkinson hastalığının teşhisi için veri toplama ve örüntü tanıma sistemi, Yüksek Lisans Tezi, *İstanbul Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Jankovic, J., 2007, Parkinson's disease: Clinical features and diagnosis, *J.Neurol. Neurosurgery Psychiatry*, 79 (4),368–376.

- Jiang, Z. and Choi, S., 2006, A cardiac sound characteristic waveform method for in-home heart disorder monitoring with electric stethoscope, *Expert Systems with Applications*, 31 (2), 286–298.
- Juneed, S. A., 2011, Bulanık mantık yöntemleri kullanılarak gazlı içeceklerde karbondioksit kontrolü, Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 25-37.
- Kahya, Y. P., Guler, E.C. and Sahin, S., 1997, Respiratory disease diagnosis using lung sounds, , *Proc. 19th Conf. IEEE-EMBS*, Chicago, 2051–2053.
- Kakilli, A., Akıncı, T. Ç., Yılmaz, Ö., 2005, Dalgacık analizinin EKG sinyallerine uygulanması ve sinyal sıkıştırma, *Bilimde Modern Yöntemler Sempozyumu BBMYS'2005*, 16-18 Kasım, 2005, Grand Yükseliş Kocaeli, 700-707.
- Kala, S., 2013, Astım [online], <http://www.medi-tech.com.tr/tani-ve-tedavi-unitesi-12-gogus-hastaliklari.html> [Ziyaret Tarihi: 6 Kasım 2014]
- Kamarulafizam, I., Salleh, S. H., Najeb, J. M., Ariff, A. K. and Chowdhury, A., 2007, Heart sound analysis using MFCC and time frequency distribution, *IFMBE Proceedings Volume, World Congress on Medical Physics and Biomedical Engineering*, 14, 946-949.
- Kandaswamy, A., Kumar, C. S., Ramanathan, R. P., Jayaraman, S. and Malmurugan, N., 2004, Neural classification of lung sounds using wavelet coefficients, *Comput Biol Med*, 34, 523-537.
- Kao, W.C., Wei, C.C., Liu, J.J. and Hsiao, P. Y., 2009, Automatic heart sound analysis with short-time Fourier transform and support vector machines, *Circuits and Systems*, 4 (1), *MWSCAS '09. 52nd IEEE International Midwest Symposium on*, 188-191.
- Kaptanoğlu, A., Y., 2014, Trakya sağlık yönetimi 1. sınıf dolaşım sistemi notları [online], <http://aysegulyildirimkaptanoglu.com/hizmet-trakya-saglik-yonetimi-1.-sinif-dolasim...-39-2-1.html> [Ziyaret Tarihi: 17 Kasım 2014].
- Kazaz, H., 2014, Kalbin Anatomisi [online], <http://www.hakkikazaz.info/2014/08/26/kalbin-anatomisi> [Ziyaret Tarihi: 17 Kasım 2014].
- Karlık, B., Koçyiğit, Y. and Korürek, M., 2009, Differentiating types of muscle movements using a wavelet based fuzzy clustering neural network, *Expert Systems*, 26(1), 49-59.
- Kavzoğlu, T. ve Çölkesen, İ., 2010, Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi, *Harita Dergisi*, 144(7), 73-82,.
- Kay, S. M. and Marple, S. L., 1981, Spectrum analysis—a modern perspective, *Proc. IEEE*, 69 (11), 1380–1419.

- Keleşoğlu, Ö. ve Fırat, A., 2006, Tuğla duvardaki ve tesisattaki ısı kaybının yapay sinir ağları ile belirlenmesi, *Fırat Üniv. Fen ve Müh. Bil. Der.*, 18 (1), 133-141.
- Keller, J. M., Gray, M. R. and Givens, 1985, J.A., A fuzzy k-nearest neighbor algorithm, *IEEE Transactions on Systems, Man and Cybernetics*, 15, 580-585.
- Kocabaş , K., 2008, Temel Bileşenler Analizi: Gelişmekte Olan Ülkeler [online], <http://www.misjournal.com/?p=3759> [Ziyaret Tarihi:10 Aralık 2014]
- Kocyigit, Y., 2014, A Novel Feature Extraction Method for Heart Sounds Classification, *Proceedings IWBBIO 2014, Granada*, 34-41.
- Korona, Z. and Kokar, M. M., 1998, Lung sound recognition using model-theory based feature selection and fusion, *Appl Sign Proc*, 5, 152–169.
- Koyuncu, E. 2014, Akciğer [online], <http://www.mediankahastanesi.com.tr/content-641-akciger.html> [Ziyaret tarihi: 4 Kasım 2014]
- Kumar, B. H., 2007, A fuzzy expert system design for analysis of body sounds and design of an unique electronic stethoscope (development of HILSA kit), *Biosensors and Bioelectronics*, 27, 1121-1125.
- Kursun, O., Gumus, E., Sertbas, A. and Favorov, O., Selection of vocal features for Parkinson's disease diagnosis, *Int. J. Data Mining Bioinf.*, 6 (2), 144–161.
- Kurt, Z., Türkmen, H. İ. ve Karslıgil, M. E., 2007, DAA yöntemi ile osmanlıca karakter tanıma, *SİU 2007*, Eskişehir, Türkiye.
- Lenclud, C., Cuttitta, G., Van Gansbeke, D., Visconti, A., Van Muylem, A., Bellia, V., and Yernault, J. C., 1996, Evaluation of nocturnal bronchoconstriction by all night tracheal sound monitoring, *Iliorax*, 51(7), 694-698.
- Leung, T. S., White, P. R., Collis, W. B., Brown, E., Salmon, A. P., 2000. Classification of heart sounds using time– frequency method and artificial neural networks, *In: Proceedings of the 22nd Annual International Conference of the IEEE-EMBS*, Chicago, 988–991.
- Li, C., Zheng, C. and Tai, C., 1995, Detection of ECG characteristic points using wavelet transforms, *IEEE Trans. Biomed. Eng.*, 42 (1), 21-28.
- Li, Z., and Du, M., 2005, HHT based lung sound crackle detection and classificatio, *in: Proc. IEEE International Symposium on Intelligent Signal Processing and Communication Systems*, 385-388.
- Liang, H. and Hartimo, I., 1998, A heart sound feature extraction algorithm based on wavelet decomposition and reconstruction, *in: Proceedings of the 20th Annual International Conference of the IEEE EMBS*, 3, 1539-1542.

- Little, M. A., McSharry, P. E., Hunter, E. J., Spielman, J. and Ramig, L. O., 2009, Suitability of dysphoniamasurements for telemonitoring of Parkinson's disease, *IEEE Trans. Biomed. Eng.*, 56(4), 1010–1022.
- Lu, X., and Bahoura, M., 2008, An integrated automated system for crackles extraction and classification, *Biomedical Signal Processing and Control* , 3 (3), 244–254.
- Malmberg, L. P., Sovijarvi, A. R., Paaanen, E., Piirila, P., Haahtela, T. and Katila, T., 1994, Changes in frequency spectra of breath sounds during histamine challenge test in adult asthmatics and healthy control subjects, *Chest*, 105 (1), 122-131.
- Malmherg, L. P., Pesu, L. and Sovijarvi, A. R., 1995, Significant differences in flow standardised breath sound spectra in patients with chronic obstructive pulmonary disease, stable asthma, and healthy lungs, *Thorax*, 50 (12), 1285-1291.
- Marshall, A., and Boussakta, S., 2007, Signal analysis of medical acoustic sounds with applications to chest medicine, *Journal of the Franklin Institute*, 344, 230-242.
- Mastorocostas, P. A. and Constantinos, S. H., 2004, A dynamic Fuzzy-Neural Filter for the analysis of lung sounds, in: *Proc. IEEE International Conference on Systems Man and Cybernetics*, 2231-2236.
- Matsunaga, S., Yamauchi, K., Yamashita, M. and Miyahara, S., 2009, Classification between normal and abnormal respiratory sounds based on maximum likelihood approach, *Acoustics, Speech and Signal Processing*, 517-520, ICASSP 2009. IEEE International Conference on.
- Moertini, V. S., 2002, Introduction to five clustering algorithms, *Integral*, 7 (2).
- Munakata ,M., Ukita,H., Doi, I., Ohtsuka, Y., Masaki, Y., Homma, Y. and Kawakami, Y., 1992, Spectral and wave-form characteristics of fine and coarse crackles, *Thorax* 46 ,651–657.
- Murphy, R. L. H., Murphy, M. A. and Brockington, G., A.Vyshedskiy, Introduction to heart sofunda [online], <http://www.stethographics.com/heart/main/intro.htm> [Ziyaret Tarihi: 18 Kasım 2014].
- Noall, K., 2011, Pulmonary [online] , <http://quizlet.com/5357789/pulmonary-flash-cards> [Ziyaret Tarihi: 6 Kasım 2014]
- Obaidat, M. S., 1993, Phonocardiogram signal analysis : techniques and performance comparison, *J. Med. Eng. technol*, 17 (6), 221–227.
- Ono, H., Taniguchi, Y., Shinoda, K., Sakamoto, T., Kudoh, S. and Gemma, A., 2009, Evaluation of the usefulness of spectral analysis of inspiratory lung sounds recorded with phonopneumography in patients with interstitial pneumonia, *J Nippon Med Sch*, 76, 67-75.

- Orhan, 2012, Makine öğrenmesi [online], <http://bmb.cu.edu.tr/uorhan/DersNotu/Ders11.pdf> [Ziyaret Tarihi:10 Aralık 2014].
- Orhan, U. ve Adem, K., 2012, Naive bayes yönteminde olasılık çarpanlarının etkileri, *ELECO 2012*, Poster Sunum, Bursa.
- Osuna, E. E., Freund, R. and Girosi, F., 1997, Support Vector Machines: training and applications, *Massachusetts Institute of Technology and Artificial Intelligence*, 1602, 144.
- Ölmez, T., and Dokur, Z., 2003, Classification of heart sounds using an artificial neural network, *Pattern Recognition Letters.*, 24(6), 617-629.
- Özdoğan, M., 2014, Akciğer kanseri [online], <http://www.drozdogan.com/akciger-kanseri/akciger-kanseri.html> [Ziyaret Tarihi: 4 Kasım 2014].
- Palaniappan, R., Sundaraj, K. and Ahamed, N. U., 2013, Machine learning in lung sound analysis: A systematic review, *Biocybernetics and biomedical engineering*, 33,129–135.
- Pesu, L., Helistö, P., Ademovic, E., Pesquet, J. C., Saarinen, A. and Sovijarvi, A. R. A., 1998, Classification of respiratory sounds based on wavelet packet decomposition and learning vector quantization, *Tech- nol. Health Care*, 6, 65–74.
- Phua, K., Chen, J., Dat, T. H. and Shue, L., 2008, Heart sound as a biometric, *Pattern Recognition*, 41, 906-919.
- Polat, H., and Darılmaz, M. , 2003, Elektronik steteskopun akciğer oskültasyon yeteneğinin incelenmesi ve akciğer seslerinin spektral analizi, *Politeknik Dergisi*, 613-618.
- Qiu, Y., 2003, Measurement and analysis of breath sounds, PhD thesis, *University of Glasgow*,Glasgow, Scoland, 19-23.
- Rakovic, P., Sejdic, E., Stanković, L. J. and Jiang, J., 2006, Time-frequency signal processing approaches with applications to heart sound analysis, *Computers in Cardiology*, 197-200.
- Rao, A. R. and Durgunoglu, A., 1988, Ar and ARMA spectral estimation, *Stochastik Hydrol. Hydraul*, 35–50.
- Reed, T. R., Reed, N. E. and Fritzson, P., 2004, Heart sound analysis for symptom detection and computer- aided diagnosis, *Simulation Modelling Practive and Theory*, 12, 129-146.
- Reyes, B. A., Charleston-Villalobos, S. and González-Camarena, R., 2014, Assessment of time–frequency representation techniques for thoracic sounds analysis, *Computer Methods and Programs in Biomedicine*, 114, 276-290.

- Riella, R. J., Nohama, P. and Maia, J. M., 2009, Method for automatic detection of wheezing in lung sounds, *Braz J Med Biol Res*, 42, 674-684.
- Rietveld, S., Oud, M. and Dooijes, E. H., 1999, Classification of asthmatic breath sounds: preliminary results of the classifying capacity of human examiners versus artificial neural networks, *Comp. and Biomed. Research*, 32, 440-448.
- Rietveld, S., Oud, M. and Dooijes, E. H., 1999, Classification of asthmatic breath sounds: preliminary results of the classifying capacity of human examiners versus artificial neural networks, *Computers and Biomedical Research*, 32, 440-448.
- Rosenbaum, R. B., 2006, Understanding parkinson's disease: a personal and professional view, *Greenwood Publishing Group*, Greenwood Publishing Group, 1 Oca 2006.
- Safara, F., Doraisamy, S., Azman, A., Jantan, A., and Ranga, S., 2013, Diagnosis of heart valve disorders through trapezoidal features and hybrid classifier, *International Journal of Bioscience, Biochemistry and Bioinformatics*, 3 (6), 662-665.
- Sakar, B. E., Isenkul, M. E., Sakar, C. O., Sertbas, A., Gorgen, F., Delil, S., Apaydin, H. and Kursun, O., Collection and analysis of a parkinson speech dataset with multiple types of sound recordings, *IEEE Journal of biomedical and health informatics*, 17(4), 828-834.
- Sakar, C. O., and Kursun, O., 2010, Telediagnosis of parkinson's disease using measurements of dysphonia, *J. Med. Syst.*, 34(4), 591-599.
- Sakar, C.O. and Kursun, O., 2010, Telediagnosis of parkinson's disease using measurements of dysphonia, *Journal of Medical Systems*, 34(4), 591-599.
- Sanei, S., Ghodsi, M., and Hassani, H., 2011, An adaptive singular spectrum analysis approach to murmur detection from heart sounds, *Medical Engineering & Physics*, 33, 362-367.
- Sankur, B., Kahya, Y. P., Guler, E. C. and Engin, T., 1994, Comparison of AR based algorithms for respiratory sound classification, *Comput. Biol. Med.*, 01.21 (4), 67-76.
- Sayn, S., 2014, İnsanda solunum sistemi [online], <http://biyolojin.com/?p=366> [Ziyaret Tarihi: 4 Kasım 2014].
- Seçen, İ., 2013, Sinyal işleme alanları ve çeşitleri [online], <http://www.elektrikport.com/teknik-kutuphane/sinyal-isleme-nedir/10222#ad-image-0> [Ziyaret Tarihi: 4 Aralık 2014].
- Sello, S., Strambi, S., Michele, G. D. and Ambrosino, N., 2008, Respiratory sound analysis in healthy and pathological subjects: A wavelet approach, *Biomedical Signal Processing and Control*, 181-191.

- Semizel, E., 2011, Patent Duktus Arteriyozus (PDA) [online], <http://evrensemizel.com/patent-duktus-arteriyozus-pda.htm> [Ziyaret Tarihi: 20 Kasım 2014].
- Serbes, G., Sakar, C. O., Kahya, Y. P. and Aydın, N., 2013, Pulmonary crackle detection using time–frequency and time–scale analysis, *Digital Signal Processing*, 23, 1012-1021.
- Serbes, G., Sakar, C. O., Kahya, Y.P. and Aydın, N., 2011, Feature extraction using time–frequency/scale analysis and ensemble of feature sets for crackle detection, *Conf Proc IEEE Eng Med Biol Soc.*, 3314–3317.
- Sezgin, E. ve Çelik, Y., 2013, Veri Madenciliğinde Kayıp Veriler İçin Kullanılan Yöntemlerin Karşılaştırılması, *Akademik Bilişim 2013 Konferansı*, Akdeniz Üniv., Antalya, 194-198.
- Siyah, B., 2012, Naive Bayes ile spor metinleri sınıflandırma, www.bulentsiyah.com/naive-bayes-ile-spor-metinleri-siniflandirma [Ziyaret Tarihi: 26 Aralık 2014].
- Soner, A., Kardiyoloji, 2. Baskı, 1979, Türk Tarih kurumu Basımevi, Ankara, Sayfa: 62-93.
- Sovijarvi, A. R., Malmberg, L. P., Paaanen, E., Piirila, P., Kallio, K. and Katila, T., 1996, Averaged and time-gated spectral analysis of respiratory sounds. Repeatability of spectral parameters in healthy men and in patients with fibrosing alveolitis, *Chest*, 109 (5), 1283-1290.
- Sovijarvi, A. R. A., Vanderschoot, J. and Earis, J. E., 2000, Standardization of computerised respiratory sound analysis, *Eur. Respir. Rev.*, 10 (77), 585.
- Spence, D. P., Bentley, S., Evans, D. H., and Morgan, M. D., 1992, Effect of methacholine induced bronchoconstriction on the spectral characteristics of breath sounds in asthma, *Thorax*, 47 (9), 680-683.
- Spieth, P. M., and Zhang, H., 2011, Analyzing lung crackle sounds: stethoscopes and beyond, *Intensive Care Med*, 37, 1238-1239.
- Şahin, S., 2014, Kalbin Yapısı ve Görevleri [online], <http://www.fenbilimleri.org/soru-bankasi/item/265-kalbin-yapisi-ve-gorevleri.html> [Ziyaret Tarihi: 17 Kasım 2014]
- Taplidou S. A. and Hadjileontiadis L. J., 2007, Wheeze detection based on time-frequency analysis of breath sounds, *Comput Biol Med*, 37(8), 1073-1083.
- Taplidou, S. A., Hadjileontiadis, L. J., Penze1, T., Gross, V., and Panas, S. M. , 2003, WED: An efficient wheezing-episode detector based on breath sounds spectrogram analysis, *Proceedings of the 25th Annual International Conference*.
- Tatlıdil, H., 1996, Uygulamalı çok değişkenli istatistiksel analiz, *Akademi Matbaası*, 140.

- Tawade L. and Warpe H., Detection of epilepsy disorder using discrete wavelet transforms using MATLABs, *International Journal of Advanced Science and Technology*, 28, March, 2011, 17-20.
- Temel Britannica, 1992, Ana Yayıncılık, cilt 1, 107-108.
- Temel Britannica, 1992, Ana Yayıncılık, cilt 10
- Tepe, C. ve Sezgin, H., 2009, EKG sinyalinde gürültü gidermede ayrık dalgacık ve paket dalgacık yöntemlerinin karşılaştırılması, *Elektrik – Elektronik – Bilgisayar ve Biyomedikal Müh. 13. Ulusal Kongresi*, 23-26 Aralık 2009, Ankara
- Torra, V., 2005, Fuzzy c means for fuzzy hierarchical clustering, *FUZZ-IEEE 2005*, Reno, Nevada, 22-25 Mayıs, 646-651.
- Tsanas, A., Little, M. A., Mcsharry, P. E. and Ramig, L. O., 2010, Enhanced classical dysphonia measures and sparse regression for telemonitoring of parkinson's disease progression, *IEEE International Conference on Acoustics Speech and Signal*, 594-597.
- Ubeyli, E. D. and Guler, I., 2003, Spectral analysis of internal carotid arterial doppler signals using FFT, AR, MA, and ARMA methods, *Computers in Biology and Medicine*, 34 (4), 1–35.
- Ubeyli, E. D. and Guler, I., 2003, Spectral analysis of internal carotid arterial doppler signals using FFT, AR, MA, and ARMA methods, *Computers in Biology and Medicine*, 34 (4), 1–13.
- Usta, R., 2014, Naive Bayes Sınıflandırma Algoritması, <http://kodcu.com/2014/05/naive-bayes-siniflandirma-algoritmasi> [Ziyaret Tarihi: 26 Aralık 2014].
- Übeyli ve Güler 2004 AR ve ARMA metotlarının kullanımı ile teşhis sistemleri için öznetelik çıkarma: oftalmik atardamar doppler işaretlerinin durum analizi, *Gazi Üniv. Müh. Mim. Fak. Der.*, 19(4), 405-413.
- Vaitkus, P. J., Cobbold, R. S. C. and Johnston, K.W., 1988, A comparative study and assessment of Doppler ultrasound spectral estimation techniques part II: methods and results, *Ultrasound Med. Biol.*, 14 (8), 673–688.
- Vanderschoot, J. and Schreur, H. J., 1994, AR (q, v) modeling of normal lung sounds, *Methods inf Med*, 33 (1), 24-27.
- Vardar, B., Güz, N., Öztokat, E., Rifat, M., Senemoğlu, O. ve Sözer, E. (1980), *Dilbilgisi ve Dilbilim Terimleri Sözlüğü*, Türk Dil Kurumu Yayınları, Ankara.
- Vaseghi, S. V., 2000, Power spectrum and correlation, *Advanced Digital Signal Processing and Noise Reduction*, 263-296.

- Vepa, J., 2009, Classification of heart murmurs using cepstral features and support vector machines, *Conf Proc IEEE Eng Med Biol Soc.*, 2539-2542.
- Villalobos, S. C., Camarena, R. G., Lem, G. C. and Corrales, T. A., 2007, Acoustic thoracic images for transmitted glottal sounds, *in: Proc. IEEE EMBS 2007*, 3481–3484.
- Waitman, L. R., Clarkson, K. P., Barwise, J. A. and King, P. H., 2000, Representation and classification of breath sounds recorded in an intensive care setting using neural networks, *Journal of Clinical Monitoring and Computing*, 16, 95–105.
- Wang, X., Zhang, J. and Yan, Y., 2011, Discrimination between pathological and normal voices using GMM-SVM approach, *J. Voice*, 25 (1), 38–43.
- Wang, Y., Wenzao, L., Zhou, J., Li, X. and Pu, Y., 2014, Identification of the normal and abnormal heart sounds using wavelet-time entropy features based on OMS-WPD, *Future Generation Computer Systems*, 37, 488–495.
- Xavier, G. N., Duarte, A. C. M., Melo-Silva, C. A., Dos-Santos, C. E. V. G. And Amado, V. M., 2014, Accuracy of pulmonary auscultation to detect abnormal respiratory mechanics: A cross-sectional diagnostic study, *Medical Hypotheses*, 2014.
- Xin, T. and Zhong, T., 1987, Analysis and decision of heart sounds via ARMA models, *Measurement*, 5(3), 102-106.
- Yakut, E., Elmas, B. ve Yavuz, S., 2014, Yapar Sinir Ağları ve Destek Vektör Makineleri yöntemleriyle borsa endeksi tahmini, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19(1), 139-157.
- Yazar, I., Yavuz, H., S. ve Çay, M., A., 2009, Temel bileşen analizi yönteminin ve bazı klasik ve robust uyarlamalarının yüz tanıma uygulamaları, *Eskişehir Osmangazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 22(1), 49-63.
- Yılcı, V., 2010, Bulanık kümeleme analizi ile Türkiye’deki illerim sosyoekonomik açıdan sınıflandırılması, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15 (3), 453-470.
- Yıldırım 2011 Tıbbi beceri uygulamaları, İ.Ü. Cerrahpaşa Tıp Fakültesi, Tıp Eğitimi anabilim Dalı, Multidisiplinler Tıbbi Beceri Uygulamaları Koordinatörlüğü, İstanbul.
- Yıldız, A., 2012, Solunum sistemi organları ve önemli hastalıkları [online], <http://draliyyildiz.blogspot.com.tr/2012/10/solunum-sistemi-organlari-ve-onemli.html> [Ziyaret Tarihi: 4 Kasım 2014]
- Yi, L., and Caiming, Z., 2006, A new feature extraction method based on feature integration, *in: Proc. IEEE ICICIC’06*, 3, 170-173.

- Yiğiner, M., 1999, Classification of lung sounds using wavelet-based neural network, Yüksek Lisans Tezi, *Boğaziçi Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Yorgancılar, S., 2013, En yakın komşu bulma algoritması [online], <http://www.herturbilgi.com/2013/01/en-yakin-komsu-bulma-algoritmasi-knn> [Ziyaret Tarihi: 12 Aralık 2014].
- Zawbaa, H. M., Ghali, N. and Hassanien, A. E., 2012, Detection of heart disease using binary particle swarm optimization, *Proceedings of the Federated Conference on Computer Science and Information Systems*, 177-182.
- Zolnoori, M., Zarandi, M., Moin, M. and Teimorian, S., 2010, Fuzzy rule- based expert system for assessment severity of asthma, *J Med Syst*, 1–11.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Fatma Zehra GÖĞÜŞ
Uyruğu :
Doğum Yeri ve Tarihi : Selçuklu / Konya 01.09.1990
Telefon : 0332 223 21 50
Faks :
e-mail : fzehra@selcuk.edu.tr

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Özel Lale Lisesi Meram/Konya	2007
Üniversite	: Selçuk Üniversitesi Selçuklu/Konya	2012
Yüksek Lisans	: Selçuk Üniversitesi Selçuklu/Konya	
Doktora	:	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2012-2013	Nevşehir Üniversitesi	Arş. Gör.
2013-Halen	Selçuk Üniversitesi	Arş. Gör.

UZMANLIK ALANI

YABANCI DİLLER: İngilizce (Orta derecede)

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR

Fatma Z. Göğüş, Bekir Karlık, and Güneş Harman, "Classification of Asthmatic Breath Sounds by Using Wavelet Transforms and Neural Networks", International Journal of Signal Processing Systems, Vol. 3, No. 2, pp. 106-111, December 2015. doi: 10.12720/ijsp.3.2.106-111

Identification of Respiratory Disorders by Using Different Spectral Analysis Methods isimli makele submit edilmiştir.