

T.C.

TRAKYA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK SESİN MÜZİKAL
ÖZNİTELİKLERİ İLE PARKİNSON HASTALIĞININ TESPİTİ**

İLKE KURT

YÜKSEK LİSANS TEZİ

HESAPLAMALI BİLİMLER ANABİLİM DALI

Tez Danışmanı: Doç. Dr. OĞUZHAN ERDEM

İkinci Tez Danışmanı: Dr. Öğr. Üyesi SEZER ULUKAYA

EDİRNE-2018

İlke KURT' un hazırladığı "Makine Öğrenmesi Yöntemleri Kullanılarak Sesin Müzikal Özellikleri İle Parkinson Hastalığının Tespiti" başlıklı bu tez, tarafımızca okunmuş, kapsam ve niteliği açısından Hesaplamalı Bilimler Anabilim Dalında bir Yüksek lisans tezi olarak kabul edilmiştir.

Jüri Üyeleri:

Doç. Dr. Oğuzhan ERDEM

Doç. Dr. Yılmaz KALKAN

Dr. Öğr. Üyesi Aydın CARUS

İmza



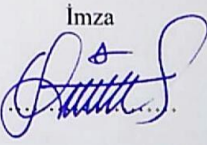

Tez Savunma Tarihi: 13/12/2018

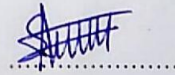
Bu tezin Yüksek Lisans tezi olarak gerekli şartları sağladığını onaylarım.

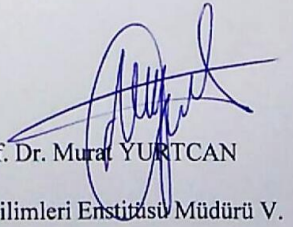
Doç. Dr. Oğuzhan ERDEM
Tez Danışmanı

Dr. Öğr. Üyesi Sezer ULUKAYA
İkinci Tez Danışmanı

Trakya Üniversitesi Fen Bilimleri Enstitüsü onayı

İmza





Prof. Dr. Murat YURTCAN
Fen Bilimleri Enstitüsü Müdürü V.

T.Ü.FEN BİLİMLERİ ENSTİTÜSÜ

**HESAPLAMALI BİLİMLER ANABİLİM DALI YÜKSEK LİSANS
PROGRAMI**

DOĞRULUK BEYANI

Trakya Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada, tüm verilerin bilimsel ve akademik kurallar çerçevesinde elde edildiğini, kullanılan verilerde tahrifat yapılmadığını, tezin akademik ve etik kurallara uygun olarak yazıldığını, kullanılan tüm literatür bilgilerinin bilimsel normlara uygun bir şekilde kaynak gösterilerek ilgili tezde yer aldığını ve bu tezin tamamı ya da herhangi bir bölümünün daha önceden Trakya Üniversitesi ya da farklı bir üniversitede tez çalışması olarak sunulmadığını beyan ederim.

13 /12 / 2018

İlke KURT



Yüksek Lisans Tezi

Makine Öğrenmesi Yöntemleri Kullanılarak Sesin Müzikal Öznitelikleri İle Parkinson Hastalığının Tespiti

T.Ü. Fen Bilimleri Enstitüsü

Hesaplamalı Bilimler Anabilim Dalı

ÖZET

Parkinson hastalığı ülkemizde ve dünyada Alzheimer hastalığından sonra en yaygın görülen, sinir sistemini etkileyen motor becerileri (yazma, denge, yutkunma, vb.), konuşma zorluğu, ses kısıklığı, düşünme ve davranış fonksiyonların kısmen veya tamamen kaybolmasına neden olan ve gündelik yaşantıyı olumsuz yönde etkileyen nörodejeneratif (sinir sisteminde geri dönüşü olmayan) hastalıklardan biridir. Hastalığın kesin bir tedavisi olmamakla birlikte hastaların gündelik yaşantılarını etkileyen semptomları azaltmayı sağlayan ilaç tedavisi uygulanmaktadır.

Konuşma ve ses bozuklukları, Parkinson hastalığı sürecinin erken teşhisinde başvurulan en belirleyici semptomlardır. Bu amaçla bu çalışmada sesin müzikal özelliklerinin Parkinson hastalığının teşhisindeki etkisi incelenmiştir. Bu doğrultuda, Parkinson hastası ve sağlıklı bireylerden alınan ham ses kayıtlarından sesin ritim, ton, tını, perde ve dinamiklik gibi özellikleri çıkartılarak yapay öğrenme algoritmaları ile hangi özelliklerin hastalığı teşhis etmede daha başarılı olduğu araştırılmıştır.

Bu tez çalışması, sesin müzikal özelliklerinin, Parkinson hastalığının teşhisinde kullanıldığı literatürdeki ilk örnek çalışma olacaktır.

Yıl : 2018

Sayfa Sayısı : 96

Anahtar Kelimeler : Parkinson Hastalığı, Disfoni, Müzikal özellik, Makine Öğrenimi, Ses analizi, Öznitelik çıkarımı ve seçimi, Sınıflandırma

Master's Degree Thesis

Detection of Parkinson's Disease with Musical Features Using Machine Learning
Methods

Trakya University Institute of Natural Sciences

Computational Science Department

ABSTRACT

Parkinson's disease becomes a prevalent neurodegenerative disorder comes after Alzheimer's diseases in our country as well as all around the world. It affects the nervous system motor skills (writing, balance, swallowing, etc.), speech and voice production difficulties, mental and behavioral functions partially or completely. While not being a definitive treatment of this disease, drug therapy is being applied to reduce the symptoms affecting the daily lives of patients.

Speech and voice disorders are one of the most significant symptoms of early diagnosis of the Parkinson's disease process. For this purpose, in this study, the effect of musical features on the diagnosis of Parkinson's disease was investigated. The rhythm, tone, timbre, pitch and dynamics features of the voice were extracted from the raw voice recordings of patients with Parkinson's disease and healthy individuals and the machine learning algorithms were used to determine which feature is more successful in diagnosing the disease.

This thesis study will be the first case study in the literature in which the musical properties of sound are used in the diagnosis of Parkinson's disease.

Year : 2018

Number of Pages : 96

Keywords : Parkinson's Disease, Dysphonia, Musical Feature, Machine Learning, Voice Analysis, Feature Extraction and Selection, Classification

ÖNSÖZ

Bu çalışma, Trakya Üniversitesi Fen Bilimleri Enstitüsü Hesaplamalı Bilimler Anabilim Dalı'nda yapılan "Makine Öğrenmesi Yöntemleri Kullanılarak Müzikal Öznitelikler İle Parkinson Hastalığının Tespiti" isimli yüksek lisans tez çalışmasını içermektedir.

Yüksek lisans öğrenimim sırasında, kendi çalıştığı alandan farklı bir alanda da olsa çalışmak istediğim konu üzerinde akademik eksiklerimi gidermek için her türlü destek ve yardımlarını benden esirgemeyen değerli danışman hocam, Sayın Doç. Dr. Oğuzhan ERDEM' e,

Bu çalışmanın yürütülmesi boyunca sabrının sınırlarını benim için zorlayan, bilgilerini tereddütsüz paylaşan ve her zaman yol gösteren değerli ikinci danışman hocam Sayın Dr. Öğr. Üyesi Sezer ULUKAYA' ya,

Akademik olarak kendisinden aldığım derslerle bana yeni bir ufuk kazandıran ve desteğini hiçbir zaman esirgemeyen kıymetli hocam Sayın Dr. Öğr. Üyesi Aydın CARUS' a teşekkürlerimi sunarım.

Adım attığım bu yolda bana her zaman güvenen, koşulsuz her daim beni destekleyen, tökezlediğim çıkmaza girdiğim anlarda elimden tutan sevgili babam, annem, ablam ve canımdan çok sevdiğim biricik yeğenime teşekkür ve sevgilerimi sunarım.

Ve son olarak bu tez çalışmamı, her ne kadar yokluğunu hep hissetsem ve onu çok özlesem de varlığını hep yanımda hissettiğim, benim bu konuda çalışmamda öncü olan bir tanecik anneanneme ithaf ediyorum.

İÇİNDEKİLER

DOĞRULUK BEYANI	ii
ÖZET.....	iii
ABSTRACT.....	v
ÖNSÖZ	vii
İÇİNDEKİLER	viii
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR.....	xiv
BÖLÜM 1: GİRİŞ.....	1
BÖLÜM 2: PARKİNSON HASTALIĞI ve SES	5
2.1. Parkinson Hastalığı	5
2.1.1. Hastalığa Neden Olan Etmenler.....	6
2.1.2. Hastalığın Belirtileri.....	7
2.1.2.1. Titreme	7
2.1.2.2. Katılık.....	8
2.1.2.3. Duruş ve Yürüyüş Bozuklukları.....	8
2.1.2.4. Hareketlerde Yavaşlama	8
2.1.2.5. Mikografi	8
2.1.2.6. Maske Yüz	8
2.1.2.7. Zihinsel ve Ruhsal Bozukluklar	9
2.1.2.8. Uyku Bozuklukları	9
2.1.2.9. Konuşma ve Ses Bozuklukları	9
2.1.2.10. Diğer Belirtiler	9
2.2. Konuşma ve Ses	9
2.2.1.Sesin Anatomisi ve Oluşumu	10
2.3. Ses/ Konuşma Bozukluğu ve Parkinson Hastalığı	11
2.4. Parkinson Hastalığının Ses Çıkarımı ile Teşhisine Yönelik Yapılan Çalışmalar	12
BÖLÜM 3: MAKİNE ÖĞRENİMİ ve ÖZİNİTELİK ÇIKARIM YÖNTEMLERİ	15
3.1. Makine Öğrenimi	15

3.2. Veri Kümelerinin Elde Edilmesi.....	16
3.3. Öznitelik Çıkarımı.....	17
3.3.1. Müzikal Bilgi Çıkarım Aracı (MIR-Toolbox)	17
3.3.2. Dinamik Grubu Özellikleri	20
3.3.2.1. Karesel ortalamanın karekökü (RMS)	20
3.3.2.2. Düşük Enerji (Low Energy)	21
3.3.3. Perde Grubu Özellikleri	21
3.3.4. Ritim Grubu Özellikleri	21
3.3.4.1. Dalgalanma Kuvveti (Fluctuation Strength)	22
3.3.4.2. Atım Spektrumu (Beat Spectrum).....	23
3.3.4.3. Başlama Noktası (Event, Onset)	23
3.3.4.4. Spektral Akı (Spectral Flux)	24
3.3.4.5. Nokta Çıkarımı (Emerge event)	25
3.3.4.6. Başlangıç Yoğunluğu (Event Density)	26
3.3.5. Tını Grubu Özellikleri.....	26
3.3.5.1. Sıfır-Geçiş (Zero-Cross).....	26
3.3.5.2. Roll-off 85	27
3.3.5.3. Roll-off 95	28
3.3.5.4. Parlaklık (Brightness)	28
3.3.5.5. Geometrik Merkez (Centroid).....	29
3.3.5.6. Yayılım (Spread).....	29
3.3.5.7. Çarpıklık (Skewness)	29
3.3.5.8. Basıklık (Kurtosis)	30
3.3.5.9. Düzgünlük (Flatness)	30
3.3.5.10. Entropi.....	31
3.3.5.11. Mel-Frekansı-Keprum- Katsayıları (MFCC)	31
3.3.5.12. Pürüzlülük (Roughness).....	33
3.3.5.13. Düzensizlik (Irregularity).....	33
3.3.6. Ton Grubu Özellikleri	34
3.3.6.1. Spektral/ Örtülü Spektral Kromagram	34
3.3.6.2. Anahtar Kuvveti (Keystrength).....	35
3.3.6.3. Anahtar (Key).....	35
3.3.6.4. Mod	36

3.3.6.5. Tonal Ağırlık Merkezi.....	36
3.4. Normalizasyon Yöntemleri	37
3.4.1. Min-Maks Normalleştirme.....	37
3.4.2. Sıfır-Ortalama Normalleştirme	38
3.5. Öznitelik Seçim Yöntemleri.....	38
3.5.1. En Küçük Mutlak Daralma ve Seçme Operatörü (LASSO)	39
3.5.2. RELIEF	40
3.5.3. Minimum Artıklık Maksimum Bağlantı (mRmR).....	41
3.5.4. Ardışık İleri Yönde Seçim (Sequential Forward Feature Selection (SFS)).....	42
3.5.5. Ardışık Geri Yönde Seçim (Sequential Backward Feature Selection (SBS)).....	42
3.5.6. Rastgele Orman (RF)	43
3.6. Sınıflandırma Yöntemleri.....	44
3.6.1. Destek Vektör Makinaları (DVM).....	44
3.6.2 k-En Yakın Komşu Algoritması (k-EYK)	45
3.7. Çapraz Doğrulama Yöntemleri	46
3.7.1. Birini Dışarda Bırakma Çapraz Doğrulama (BDB).....	47
3.7.2. Bir Bireyi Dışarda Bırakma Çapraz Doğrulama (BBDB).....	48
3.8. Değerlendirme Ölçütleri.....	49
3.8.1. Doğruluk	50
3.8.2. Duyarlılık	50
3.8.3. Kesinlik	50
3.8.4. F-ölçütü	51
3.8.5. Matthews Korelasyon Katsayısı (MKK).....	51
BÖLÜM 4: DENEYSEL SONUÇLAR.....	52
4.1. Normalizasyon Yöntemlerinin Etkisi.....	52
4.2. Çapraz Doğrulama Yöntemlerinin Kıyaslanması	53
4.3. Sınıflandırma Yöntemlerinin Kıyaslanması.....	56
4.4. Öznitelik Seçme Algoritmalarının Uygulanması.....	58
4.4.1. En Küçük Mutlak Daralma ve Seçme Operatörü ile Öznitelik Seçimi.....	59
4.4.2. RELIEF ile Öznitelik Seçimi	60
4.5.3. Minimum Artıklık Maksimum Bağlantı ile Öznitelik Seçimi	62
4.5.4. Ardışık İleri ve Geri Yönde Seçim ile Öznitelik Seçimi	62
4.5.5. Rastgele Orman ile Öznitelik Seçimi.....	62

4.6. Öznitelik Seçme Algoritmalarının Kıyaslanması	64
4.7. Ton Farkının Sınıflandırma Performansına Etkisi	68
BÖLÜM 5: SONUÇ ve TARTIŞMA	70
KAYNAKÇA	74
EKLER	79
ÖZGEÇMİŞ	81

ŞEKİLLER DİZİNİ

Şekil 2.1: Dopamin ve hücreler arası sinir iletim mekanizması	6
Şekil 2.2: Parkinson hastalarının genel görünümü	7
Şekil 2.3: Ses ve konuşma oluşumu	11
Şekil 3.1: Sistemin genel işlem basamakları	16
Şekil 3.2: (a) Sağlıklı ve (b) hasta bireylere ait RMS enerji grafikleri	20
Şekil 3.3: (a) Sağlıklı ve (b) hasta bireylere ait dalgalanma kuvvetlerinin spektrum olarak gösterimi	22
Şekil 3.4: (a) Sağlıklı ve (b) hasta bireylere ait başlangıç noktası grafikleri	24
Şekil 3.5: (a) Sağlıklı ve (b) hasta bireylere ait spektral akı grafikleri	25
Şekil 3.6: (a) Sağlıklı ve (b) hasta bireylere ait nokta çıkarım grafikleri	25
Şekil 3.7: MIR-toolbox kullanım kılavuzunda yer alan örnek sıfır geçiş grafiği	27
Şekil 3.8: MIR-toolbox kullanım kılavuzunda yer alan örnek Roll-off 85 grafiği	27
Şekil 3.9: (a) Sağlıklı ve (b) hasta bireylere ait MFCC değer grafikleri.....	32
Şekil 3.10: (a) Sağlıklı ve (b) hasta bireylere ait pürüzlülük grafikleri	33
Şekil 3.11: (a) Sağlıklı ve (b) hasta bireylere ait örtülü spektral kromagram grafikleri .	34
Şekil 3.12: (a) Sağlıklı ve (b) hasta bireylere ait anahtar kuvveti grafikleri	35
Şekil 3.13: (a) Sağlıklı ve (b) hasta bireylere ait merkezi tonal ortalama grafikleri	37
Şekil 3.14: DVM algoritmasının şekilsel gösterimi.....	45
Şekil 3.15: k-EYK ile sınıfı bilinmeyen verinin sınıflandırılması.....	46
Şekil 3.16: Birini dışarda bırakma (BDB) çapraz doğrulama yöntemi.....	47
Şekil 3.17: Bir bireyi dışarda bırakma (BBDB) çapraz doğrulama yöntemi	49
Şekil 4.1: Çapraz doğrulamalı LASSO ile MSE değerleri.....	60
Şekil 4.2. Özniteliklerin RELIEF ile elde edilen ağırlık değerleri.....	61
Şekil 4.3. RF yöntemiyle belirlenen en iyi özniteliklerin histogram gösterimi	63
Şekil 4.4: Seçilen özniteliklerin DVM sınıflandırıcıda doğruluk performansı	65
Şekil 4.5: Seçilen özniteliklerin k-EYK sınıflandırıcıda doğruluk performansı.....	67

ÇİZELGELER DİZİNİ

Çizelge 3.1: Veri kümelerinin kısa özeti.....	17
Çizelge 3.2: Ses örneklerinden çıkartılan müzikal bazlı öznitelikler	18
Çizelge 3.3: Çıkartılan öznitelikler ve dahil olduğu temel müzikal öznitelik grupları ...	19
Çizelge 3.4. Sınıflandırıcı tahminine göre karmaşıklık matrisi	49
Çizelge 4.1 Çeşitli normalleştirme uygulamalarının farklı sınıflandırıcılardaki doğruluk performansı	53
Çizelge 4.2: k-EYK sınıflandırıcı için BDB ve BBDB çapraz doğrulama yöntemlerinin doğruluk sonuçları	55
Çizelge 4.3: DVM sınıflandırıcı için BDB ve BBDB çapraz doğrulama yöntemlerinin doğruluk sonuçları	55
Çizelge 4.4: BDB çapraz doğrulama yöntemlerinin farklı sınıflandırma uygulamalarında doğruluk, f ölçütü ve MKK sonuçları	57
Çizelge 4.5: BBDB çapraz doğrulama yöntemlerinin farklı sınıflandırma uygulamalarında doğruluk, f ölçütü ve MKK sonuçları	57
Çizelge 4.6: Farklı öznitelik seçim algoritmaları ile belirlenen ilk 20 öznitelik	59
Çizelge 4.7: Farklı ses tonlarının öznitelik seçimi öncesi doğruluk değerleri	68
Çizelge 4.8: Farklı ses tonlarının öznitelik seçimi sonrası doğruluk değerleri	69

SİMGELER ve KISALTMALAR

Simgeler

C	: Maliyet parametresi
f_0	: Temel frekans
g	: Çekirdek genişliği

Açıklamalar

Kısaltmalar

BBDB	: Bir-bireyi-dışarda-bırak (Leave-one-subject-out, LOSO)
BDB	: Birini-dışarda-bırak (Leave-one-out, LOO)
BPHDÖ	: Birleşik Parkinson Hastalığı Değerlendirme Ölçeği
dB	: Desibel
DCT	: Ayrık Kosinüs Dönüşümü (Discrete Cosine Transform)
DVM	: Destek Vektör Makinaları (Support Vector Machines)
FFT	: Hızlı Fourier Dönüşümü (Fast Fourier Transform)
GN	: Gerçek negatif
GP	: Gerçek pozitif
HH	: Huntington hastalığı
Hz	: Hertz
inBag	: Torba içi
k-EYK	: k-En Yakın Komşu (k-Nearest Neighbor)
LASSO	: En küçük mutlak daralma ve seçme operatörü (Least Absolute Shrinkage and Selection Operator)
LibSVM	: Destek vektör makinaları için kütüphane (Library for Support Vector Machines)
MDVP	: Çok boyutlu ses programı (Multi-Dimensional Voice Program)
MFCC	: Mel-Frekansı Cepstrum Katsayıları (Mel-Frequency Cepstrum Coefficient)
MIR-toolbox	: Müzik Bilgisi Alma aracı (Music Information Retrieval Toolbox)

MKK	: Matthews korelasyon katsayısı
mRmR	: Minimum artıklık maksimum bağlantı (Minimum Redundancy Maximum Relevance)
mRmR _{MI}	: Ortak bilgiye dayalı minimum artıklık maksimum bağlantı
mRmR _{PR}	: Pearson korelasyon katsayılı minimum artıklık maksimum bağlantı
mRmR _{SP}	: Spearman korelasyon katsayılı minimum artıklık maksimum bağlantı
ms	: Milisaniye
MSA	: Çoklu sistem atrofisi (Multiple system atrophy)
MSE	: Ortalama kare hata (Mean Square Error)
OOB	: Torba dışı (Out-Of-Bag)
PSP	: Progresif supranükleer felç (Progressive Supranuclear Palsy)
RF	: Rastgele Orman (Random Forest)
RMS	: Karekök ortalama (Root Mean Square)
s	: Saniye
SBS	: Ardışık Geri Yönde Seçim (Sequential Backward Feature Selection)
SFS	: Ardışık İleri Yönde Seçim (Sequential Forward Feature Selection)
SVD	: Saarbrücken Ses Veri Tabanı (Saarbrücken Voice Database)
UCI	: Kaliforniya Üniversitesi, Irvine (University of California, Irvine)
YN	: Yanlış negatif
YP	: Yanlış pozitif

BÖLÜM 1

GİRİŞ

Parkinson hastalığı dünya çapında 10 milyondan fazla insanı etkileyen evrensel bir nörolojik hastalıktır (Tysnes & Storstein, 2017). Çoklu sistem atrofisi (MSA), Huntington hastalığı (HH) ve progresif supranükleer felç (PSP) gibi diğer merkezi sinir sistemi hastalıkları ile karşılaştırıldığında, Parkinson hastalığı sıklığı yaşlanma ile birlikte artmaktadır (Yacoubian, 2017). Her yıl, 60 yaş üstü ortalama her 100 bireyden birisine Parkinson hastalığı teşhisi konulmaktadır.

Genel olarak, nörodejeneratif hastalıklar¹ öğrenilen motor yetilerinin kontrol mekanizmasını etkiler. Dopamin, vücut hareketlerini yönetmek için sinir hücreleri arasındaki mesajların iletilmesinden sorumludur (Ramezani, Khaki, Erzin, & Akan, 2017). Parkinson teşhisi konan hastalarda dopamin düzeyi azaldıkça, kasların kontrol mekanizmasında oluşan hasar sonucu genellikle ellerde, kollarda titreme, kaslarda ve eklemlerde katılık, hareket etmede zorluklar görülmeye başlar (Jankovic, 2008). Hastalığın prognozu (seyri) ilk yıllarda hafif olduğundan hastalar önemli motor bozukluklarla karşılaşmayabilirler. Parkinson hastalığının kesin bir tedavisi olmamakla birlikte, hastaların günlük yaşamlarını etkileyen semptomları azaltmak için genellikle ilaç tedavisi uygulanmaktadır (Jankovic, 2008; Wirdefeldt, Adami, Cole, Trichopoulos, & Mandel, 2011). İlerleyici bir hastalık olduğu için önemli sağlık sorunlarına yol açmakta ve bireylerin beslenme, giyinme, yürüyüş gibi günlük aktivitelerindeki performansını etkilemektedir.

¹ Nörodejeneratif hastalıklar, sinir hücrelerinde meydana gelen hasar sonucu geri dönüşü ve tedavisi mümkün olmayan, kalıcı ve ilerleyici hastalıklardır.

Parkinson için bilinen belirli bir teşhis yöntemi yoktur. Nörologlar, hastaların fiziksel muayene ve tıbbi öykülerine ek olarak kan testleri, nörogörüntüleme teknikleri gibi diğer tanı prosedürleri ile hastalığı teşhis ederler (Poewe & Scherfler, 2003). Ne yazık ki, hastalığın ilk evrelerinde MSA ve PSP gibi diğer nörolojik bozukluklarla benzer semptomları gösterebilmesi nedeniyle, bulgular yanıltıcı olup yanlış tanı görülebilir. Bu nedenlerden dolayı, hastalığın erken teşhisi, tedavinin etkinliğini arttırmak için önemli bir rol oynamaktadır (Perju-Dumbrava vd., 2012).

Ses, bir bireyin çevresindeki diğer kişilerle iletişiminde duyularını, hislerini ve karakteristik özelliklerini aktarmasını sağlayan temel öğelerin başında gelir (Poewe & Scherfler, 2003). Fonasyon (ses üretimi) ise, solunum sırasında akciğerlerden gelen havanın vücuttan dışarı çıktığı sırada meydana gelen dinamik bir süreçtir. Parkinson hastalarında ses oluşumu ve konuşma sisteminde kullanılan yüz, ağız ve boğazdaki kasların kontrol mekanizması dopamin eksikliğinden etkilenir. Ses oluşumundaki bozuklukları niteleyen disfoni, hastalığın ikincil semptomlarından biri olmakla birlikte hasta bireyleri sağlıklı bireylerden ayırabilmeyi sağlayan önemli bir parametredir. Ses yüksekliğinde azalma, pürüzlülük, monoton ses, solunum güçlüğü, konuşmada zorluk, stres veya ritim bozukluğu, kekemelik ve yavaş veya hızlı konuşma Parkinson hastalarının yaklaşık %90'ını etkileyen yaygın problemlerdir (Ramezani vd., 2017; Rueda & Krishnan, 2017).

Akıcı konuşma testi günlük kullanımda daha gerçekçi sonuçlar verse bile, uzatılmış sesli harflerin daha istikrarlı vokal performans sergilediği ve kolayca analiz edilebildiği için araştırmacılar tarafından sıkça tercih edilen bir yöntemdir (Rueda & Krishnan, 2017). Holmes ve ekibinin yapmış oldukları çalışmada Parkinson hastası ve sağlıklı bireylerin ayırımında uzatılmış ses örnekleri kullanılmış ve bu analiz bu alandaki diğer araştırmacılar için bir ışık olmuştur (J Holmes, M Oates, J Phylard, & J Hughes, 2000)

Konuşma; cinsiyet, yaş, anatomik ve fizyolojik farklılıklar nedeniyle kişiden kişiye değişiklik gösteren bir olgudur. Çok Boyutlu Ses Programı (MDVP) (Elemetrics, 1993), PRAAT (Paul Boersma, 2013) gibi birçok farklı ses analiz yazılım araçları ve algoritmalar, ses kayıtlarından Parkinson tanısının doğruluğunu geliştirmek için

kullanılmıştır. Bu alanda yapılan daha önceki çalışmalarda deneklerden alınan ses sinyallerinin temel frekansına dayalı hızlı dalgalanma, titreşim ve harmoniklik gibi öznitelikler sınıflandırma kriteri olarak kullanılmıştır (Alhussein, 2017; Benba, Jilbab, Hammouch, & Sandabad, 2015; Das, 2010; Little, McSharry, Hunter, Spielman, & Ramig, 2009; Momo & Uddin, 2017; Rueda & Krishnan, 2017; B. E. Sakar vd., 2013). Ancak, ses müzikal ve ritmik özelliklere sahiptir. Bildiğimiz kadarıyla literatürde, ses kısıklığı sorunu yaşayan Parkinson hastalarının ses verileri ile sesin müzikal karakteristiklerini oluşturan ton, tını, ritim ve perde gibi özellikleri kullanarak ayırımı gerçekleştiren herhangi bir çalışma bulunmamaktadır. Bu alanda yapılan önceki çalışmaların aksine, bu araştırmanın temel amacı hasta ve sağlıklı seslerin müzikal karakterinden yararlanılarak hangi özneliğin hastalığın ayırımında daha ayırt edici olduğunu araştırmaktır. Bu amaçla, müzik bilgilerinin Parkinson hastalığının ses ve konuşma bozukluğu belirtilerini tespit etmede ne kadar etkili ve yararlı olduğunu göstermek için, Müzik Bilgisi Alma (MIR-toolbox) araç kutusu (Olivier Lartillot & Toivainen, 2007) öznitelik çıkarım aracı olarak kullanılmıştır.

UCI makine öğrenimi veri tabanından alınan hasta ve Saarbrücken ses veri tabanından (SVD) alınan sağlıklı bireylerin ham ses kayıtlarından ritim, perde, tını, ton ve enerji olmak üzere beş ana gruptan toplam 111 müzikal öznitelik çıkartılmış ve bu özniteliklerin k-En Yakın Komşu Algoritması (k-EYK) ve Destek Vektör Makinaları (DVM) gibi sıklıkla tercih edilen makine öğrenimi sınıflandırıcıları kullanılarak hasta ve sağlıklı birey ayırımındaki başarı performansı incelenmiştir. Elde edilen özniteliklerin sınıflandırma performansındaki etkisini test etmek için Birini-Dışarda-Bırak (BDB), Bir-Bireyi-Dışarda-Bırak (BBDB) çapraz doğrulama yöntemleri kullanılmıştır. Çok öznitelik içeren veri kümelerinde bazı öznitelikler sınıflandırma performansını olumsuz etkileyebilmektedir. Daha değerli bilgi taşıyan özniteliklerin tespiti için farklı öznitelik seçme algoritmaları uygulanmış ve belirlenen özniteliklerin sınıflandırma performansları karşılaştırılmıştır.

Bu tez çalışmasında Bölüm 2, tez çalışmasının ana konusu olan Parkinson hastalığı, ses ve konuşma hakkında genel bilgileri ve birbirleri ile olan bağlantıyı içerirken Bölüm 3'te makine öğrenimi ve öznitelik çıkarımında kullanılan yöntemler hakkında bilgi sunulmaktadır. Yapılan deneyler ve elde edilen sonuçlar Bölüm 4'te

belirtilmiştir. Sonuçların detaylı yorumlanması ve ileri çalışmalara Bölüm 5’te yer verilmiştir.

BÖLÜM 2

PARKİNSON HASTALIĞI VE SES

2.1. Parkinson Hastalığı


Parkinson hastalığı 1817’de Doktor James Parkinson tarafından titrek felç olarak tanımlanmış ve adlandırılmıştır (Little vd., 2009). Doktor James, daha önce birçok felç hastası görmesine rağmen titreme ve hareket kaybı gibi belirtiler gösteren bir felç rahatsızlığına rastlamamıştı. Doktor James Parkinson Uluslararası Nörologlar toplantısında bir sunumu esnasında henüz tanımlanmamış bu hastalığı anlatmış ve hastalığa kendi adını vermiştir. Sonrasında birçok nörolog hastalık hakkında bilgi toplamak adına James Parkinson'un hastaları üzerinde çeşitli testler yapmışlar ve tedavi yöntemlerini araştırmaya girişmişlerdir.

Parkinson hastalığı Alzheimer hastalığından sonra en sık görülen beyin kaynaklı motor refleks, konuşma, davranış, zihinsel süreç ve diğer hayati fonksiyonların kısmen ya da tamamen kaybolmasına sebep olan merkezi sinir sistemine ait nörodejeneratif bir hastalıktır (Kurt, Ulukaya, & Erdem, 2018). Genelde orta yaşlı ve üzeri bireylerde ortaya çıkar ve hastaların %90’ında konuşma ve motor yeteneklerinde (yazma, denge gibi) kayba neden olur (B. E. Sakar vd., 2013).

Parkinson hastalığında yaş ve cinsiyet, hastalığın gelişmesi ve ilerlemesinde önemli birer risk faktörüdür. Özellikle 65 yaş üzeri her 100 kişiden birinde Parkinson hastalığı görülmektedir (Jankovic, 2008). Giderek yaşlanan toplumlarda Parkinson hastalığı teşhisi konan bireylerin oranı ise gün geçtikçe çoğalmakta, Türkiye’de 120.000 civarında olduğu tahmin edilmektedir (Akbayır vd., 2017). Ayrıca, 50 yaş ve üzeri erkek bireylerde kadınlara nazaran hastalığın görülme olasılığı yüksektir.

2.1.1.Hastalığa Neden Olan Etmenler

Parkinson şikâyeti olan bireylerin beyinde sinir hücreleri arasında iletişimi sağlayan, dopamin adı verilen nörotransmitter maddeyi üreten sinir hücreleri hasara uğrar (dejenerasyon) ve yıllar içinde sayıları giderek azalır (Özekmekçi, Apaydın, Oğuz, & Zileli, 2013). Dopamin aynı zamanda vücut hareketlerini kontrol ve koordine etmekten de sorumludur. Dopamin üretim sisteminin zarar görmesiyle, beynin kontrol mekanizması olumsuz yönde etkilenerek hareketlerde yavaşlamalara neden olmaktadır. Sinir hücrelerinin kaybı yavaş ilerleyen bir süreçtir. Bu hücreler %60- %80 oranında azaldığında hastalığın hareketleri kısıtlayıcı belirtileri ortaya çıkar (TPHD, 2017). Parkinson hastalığı belirtilerinden uzuvlarda titreme, kas sertliği, hareket yavaşlığı ve duruş bozukluğu yeterli miktarda dopamin üretilmediği için ortaya çıkar (Cakmur, 2011).



Şekil 2.1. Dopamin ve hücreler arası sinir iletim mekanizması (<https://www.ilacrehberi.com>; <https://www.inploid.com>) esinlenilerek oluşturulmuştur.

Genetik olarak Parkinson rahatsızlığı olmayan kişilerde de yaşam şekillerine göre hastalığın belirtilerinin görülebildiği ortaya konulmuştur (Akbayır vd., 2017). Örneğin kırsal kesimde yaşayıp ve tarım işleriyle uğraşan bireylerde tarım ilaçlarında bulunan bazı kimyasallara maruz kalmalarından, şehirde yaşayan bireylerde ise yedikleri besinlerden, soludukları havadan, içtikleri sudan kaynaklı erken yaşta

Parkinson hastalığı görülebilmektedir. Kesin bir şekilde sebebi bilinmeyen bu hastalığın oluşumuna katkı sağlayan çok sayıda faktör, insanların günlük yaşantısı içerisinde mevcuttur. Parkinson hastalığının görülme riskini artıran bir diğer faktör ise demir, kurşun ve manganez gibi ağır metallerdir. Bu tarz ağır metaller beyinde dopamin üretim bölgesinde birikerek dopamin üretim mekanizmasını olumsuz etkilemekte ve hastalığın oluşumuna zemin hazırlamaktadır (Akbayır vd., 2017; Aygün, Türkel, & Onar, 2009).

2.1.2. Hastalığın Belirtileri

Parkinson hastalığı, her hastada farklı belirtilerle ortaya çıkabilmektedir ve bu sebeple semptomların ilerleyişi de farklılık gösterebilmektedir.



Şekil 2.2. Parkinson hastalarının genel görünümü (<http://fizyosaglik.com>)

2.1.2.1. Titreme

Tremor olarak da ifade edilen titreme parmaklarda, ellerde, kollarda, bacaklarda, çenede, dilde, dudaklarda, göz kapaklarında ve kafada görülür. Fakat genellikle eller ve parmaklardaki titremeler baskındır. Uyku halinde titreme durur fakat uyanmayla birlikte geri döner.

2.1.2.2. Katılık

İskelet kasları hastalığına bağlı olarak istemsiz olarak kasıldığından kaslarda sertleşme oluşur. Katılaştıran bölgelerde ağrı olabilir.

2.1.2.3. Duruş ve Yürüyüş Bozuklukları

Parkinson hastaları, oturdukları yerden birden kalkmakta, yürümeyi başlatmakta zorluk yaşarlar. Gövdesi öne doğru eğik, küçük adımlarla ve yavaş bir şekilde yürürler. Otururken veya ayakta dururken yaşadıkları denge kayıpları ile yürüyüş sırasında ayaklarını yere sürüyerek adım atmalarından dolayı karşılaştıkları tökezlemeler sonucunda öne, yana veya arkaya doğru düşme eğilimindedirler (Özekmekçi vd., 2013; TPHD, 2017).

2.1.2.4. Hareketlerde Yavaşlama

Yürüme ve elle yapılan işler gibi günlük aktivitelerde genel bir yavaşlama söz konusudur. Hareketi planlama, başlatma ve sürdürme süreçlerindeki bu gecikmeden dolayı hareketlerde yavaşlama ortaya çıkar. İlk başlarda vücudun tek tarafında başlayan belirtiler, yavaş bir şekilde ilerleyerek vücudun diğer tarafına yayılır. Bu semptomlar her Parkinson hastasında aynı şiddette görülmebilir (Özekmekçi vd., 2013).

2.1.2.5. Mikrografi

Hastaların yazı yazma becerilerinin değişmesi, düğme ilikleme ve açma gibi ince işlerde ve gece yatakta dönmekte zorluk çekmek gibi günlük işlevlerin yerine getirilmesinde yaşanan sıkıntılar.

2.1.2.6. Maske yüz

Hastaların baş ve boynunda bulunan kasları istediği gibi kontrol edememesi sebebiyle yüz hareketlerinde de ciddi bir yavaşlama ve donukluk oluşur. Bu da duygusal ifadelerin azalmasıyla sonuçlanır.

2.1.2.7. Zihinsel ve Ruhsal Bozukluklar

Hastalığın teşhisinde ilk olarak hareketle ilgili belirtilerin daha ön plana çıkmasıyla zihinsel ve ruhsal belirtiler hasta yakınlarının gözünden kaçabilir. Demans (unutkanlık), kişinin sosyal ve iş yaşamından soyutlanmasına, bir durum hakkında sorumluluk ve karar alma gibi konuları başkalarına bırakmasına neden olmaktadır. Ayrıca hastalar aşırı yeme, kumar oynama, riske girme gibi davranışlara eğilim göstermektedirler. Hayal görme ve depresyon hastalık ilerledikçe belirginleşen ruhsal belirtilerdir. (Pekel, Yıldız, Sığırlı, Güneş, & Seferoğlu, 2017).

2.1.2.8. Uyku Bozuklukları

Uyku sırasında rüyaların görüldüğü dönemde hastalar hareketlenirler, gördükleri rüyanın etkisinde kalarak saldırgan davranışlarda bulunabilirler. Yatakta bacağını, kolunu sallar, yumruk atabilir, ya da korkuyla kalkıp bilinçsiz hareketler yapabilirler (Özekmekçi vd., 2013). Ayrıca hastalarda, gün içinde aşırı uyuma veya uykusuzluk gibi uyku bozuklukları da gözlenmektedir (Aygün vd., 2009).

2.1.2.9. Konuşma ve Ses Bozuklukları

İlerleyen safhalarda ses zayıf çıkmakta ve konuşmaların anlaşılması güçleşmektedir. Hastaların %90'ında görülen en yaygın belirtidir (Kurt vd., 2018).

2.1.2.10. Diğer Belirtiler

Parkinson hastalığında hareket sistemin dışında da değişiklikler görülür. Hastalıkta ilk olarak sindirim sistemi ve koku yolları etkilenmektedir. Kabızlık, barsak hareketlerinde düzensizlikler, idrar kaçırma, tansiyon düşmesi, gözlerde kuruma, ciltte aşırı yağlanma bu belirtilerden bazılarıdır (Aygün vd., 2009; Özekmekçi vd., 2013).

2.2. Konuşma ve Ses

Ses, cisimlerin titreşiminden meydana gelen dinamik bir yapıdır. Ses; sözlü iletişimdeki öneminin yanı sıra, bireyden bireye farklılık gösteren bedenimizin türlü

perdelerde çeşitli renklerdeki tınlarıyla, kendine has olması ile kişinin karakteristik özelliklerini yansıtan ayna gibidir (Gerçeker, Yorulmaz, & Ural, 2000).

Konuşma; insana ait bir eylemdir. Oldukça karmaşık bir fonksiyon olan konuşma düşünce ve fikirleri söz, şekil, mimik ve hareketlerle anlatılabilme yeteneğidir.

Sözlü iletişim, aşağıda belirtilen üç temel sürecin bir düzen ve uyum içinde gerçekleşmesi ile mümkündür (Orozco-Arroyave vd., 2016):

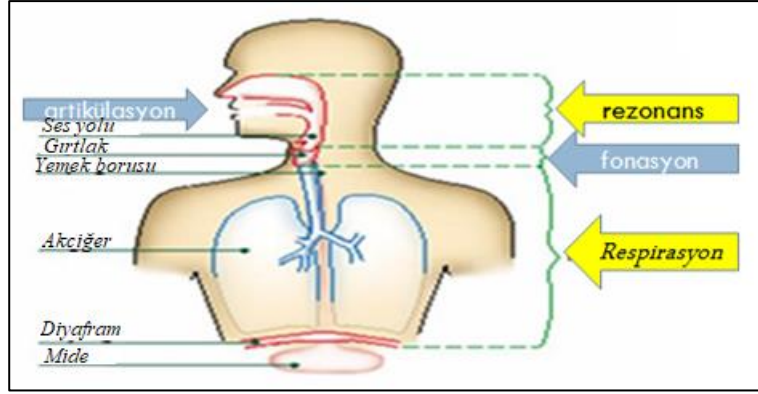
- Kavramların sembolik ifadeleri ve anlatının düzeni,
- Konuşma seslerinin üretilmesi (fonasyon) ve bunların söz dizileri halindeki uyumluluğu,
- Düşüncelerin, solunum (respirasyon), seslerin üretilmesi, seslerin düzgün çıkartımı (artikülasyon) ve prozodiyi (vurgu, ritm, ahenk) sağlayacak uygun motor becerileri ile birlikte konuşma biçiminde ifade edilebilmesi

2.2.1. Sesin Anatomisi ve Oluşumu

Ses sistemimiz, sırası ile aşağıdan yukarıya doğru akciğerler, soluk borusu, gırtlak, burun ve ağız boşluğundan kısacası solunum yollarını oluşturan organlardan meydana gelmektedir (Torun, 1991). İnsan sesinin üretilmesi üç aşamadan oluşmaktadır (Şekil 2.3). Bunların birincisi solunum aşamasıdır. Solunum, dış ortamdan alınan oksijen ile içerdeki karbondioksitin karşılıklı olarak yer değiştirmesidir. Tüm canlılar, yaşamlarını sürdürebilmek için solunuma gereksinim duyar ki bu solunuma yaşamsal solunum adı verilir. Ancak, bizler yaşamsal işlevinin yanında konuşma eylemini gerçekleştirirken de solunuma gereksinim duyarız ki bu solunuma da biyososyal solunum adı verilir (Titze & Martin, 1998).

Konuşmanın ikinci aşaması ses tellerinin titreşimiyle gerçekleşen ses üretimi aşamasıdır. Bu aşamada; solunum sırasında akciğerlerimizden gelen hava soluk borumuz aracılığı ile gırtlığa ulaşır. Gırtlak; kıkırdak, kas ve bağlardan oluşan karmaşık bir solunum yolu bölümüdür ve üzerinde ses tellerini barındırır. Konuşma sırasında akciğerlerden gelen havanın, gırtlak üzerindeki ses tellerini titreştirmesi ile ham ses meydana gelmektedir. Ses tellerinin bir saniyedeki açılıp kapanma olayı sesin temel

frekansını (f_0) oluşturur. Temel frekans sesin tizliğini ve pesliğini belirlemektedir. Ham ses gırtlaktaki ses tellerinin hava ile teması sırasında titreşir ve burada meydana gelen titreşim yutak, burun ve ağız boşlukların hacimlerine göre şekillenerek kişinin ses tonunu oluşturur. Ki bu aşamaya da rezonans aşaması denmektedir (Gerçeker vd., 2000; Torun, 1991).



Şekil 2.3. Ses ve konuşma oluşumu (<http://www.odyolojivedilkonusma.com>)

En son aşama ise dil, diş, dudak, damak, yutak gibi yardımcı konuşma organlarımızın sistematik düzene uyarak gerçekleştirdiği hareketler aracılığı ile konuşma sesleri (ses birimleri) üretilerek konuşmanın gerçekleşmiş olduğu artikülasyon aşamasıdır.

2.3. Ses/Konuşma Bozukluğu ve Parkinson Hastalığı

Gırtlak hastalıklarının en önemli semptomlarından olan ses kısılması olarak tanımlanan ancak ses çıkarımını etkileyen tüm bozuklukları ifade eden disfoni; ses tellerinin vibrasyon özelliklerinde işlev kaybı veya tellerin üzerinde meydana gelen salgısal düzensizlikten oluşur (Bakır, 2015).

Konuşmanın bozulmasına neden olan semptom dizartri olarak tanımlanır. Bu belirtiyeye neden olan ise, konuşurken kullanılan kasların zayıflaması veya bu kasların birlikte uyum içinde çalışmasında güçlük yaşanmasıdır. Konuşma bozukluğu, konuşma mekanizmasını oluşturan solunum, ses tellerinin titreşimi ve seslerin düzgün telaffuz edilmesi bileşenlerinden herhangi birinde yaşanan yetersizlikler ile ayırt edilmektedir.

Parkinson hastalarında görülen ses üretim ve konuşma bozuklukları, dopamin eksikliğinin yüz, ağız gırtlak ve yutak kaslarının hareket mekanizmasını olumsuz yönde etkilemesi ve hareket kabiliyetinin azalmasından dolayı ortaya çıkar (Torun, 1991).

Ses tonundaki tekdüzelik, vurgulamalarda azalma, ses seviyesinin düzensizliği, sözcüklerin ağızda gevelenmesi, kısa cümle kuruluşları, sesin çatallı nitelikte olması, ses perdesinde incelmeye ve konuşmada bazen sözcükleri anlayamayacak kadar hızlı veya yavaş telaffuz etme Parkinson hastalarında görülen ses ve konuşma bozukluklarının önemli belirtileri arasındadır (Uğurel, Eranıl, Berrin, & Doğan, 2012).

Konuşma bozukluğu kliniksel olarak; monoton ve karakteristik olarak zayıf bir sesle konuşmadan, anlaşılması zorlaşan, ya da imkansızlaşan bir konuşma şekline doğru ilerleyiş göstermektedir. Parkinson hastalığındaki hareket zayıflığı Parkinson hastalarında bir bölümünde gözlemlenen yavaşlama veya yürüyüşün istemsiz hızlanması fenomeni durumu sadece hareketlerde değil zamanla sözcüklerin birbirine girdiği konuşma hızında gözlenmektedir. Aynı zamanda Parkinson hastalarında konuşma motor becerilerinde gırtlak kaslarındaki katılma çabuk yorulmalara neden olmakta ve bunun sonucunda yaşanan zamansız duraklamalar hasta bireylerin iletişim kurmasını zorlaştırmaktadır. Bu nedenle konuşmanın başlaması ile sonlandırılması arasındaki harcanan süre uzamaktadır.

2.4. Parkinson Hastalığının Ses Çıkarımı ile Teşhisine Yönelik Yapılan Çalışmalar

Teknolojinin gelişmesiyle hastalığın tanı ve teşhisinde hekimlere yardımcı olabilmek için birçok yöntem geliştirilmiştir. Ses ve konuşma bozuklukları kolay veri elde edilmesi ve uygulanabilirlik açısından birçok araştırmacının ilgisini çekmiştir.

Little ve arkadaşları Parkinson hastalığının bulgularından ses kısıklığını ölçerek hastalığın şiddetini derecelendirmeyi baz aldıkları çalışmalarında (Little vd., 2009) 23 tanesi Parkinson hastası olmak üzere 31 denek kullanmışlardır. Parkinson hastalığının teşhisi ve hangi aşamada olduğunun tespitinde kullanılacak sesteki hızlı dalgalanma, titreşim, ses düzeyi ve harmoniklik gibi özelliklerin çıkartılması için konuşma testleri uygulanmış ve %91,4'e yakın bir başarı elde edilmiştir.

Tsanas ve arkadaşları yaptıkları çalışmalarında (Tsanas, Little, McSharry, & Ramig, 2010a), 42 Parkinson hastasından temin edilen yaklaşık 6000 ses kaydı ile konuşmadaki ses özelliklerini sinyal işleme algoritmalarıyla birleştirerek uygulanabilir özellikleri karakterize ederek hastalığı ilerleme ya da gerileme değişim oranı tahmin etmeyi hedeflemişlerdir.

Revelt ve arkadaşları (Revelt, Gorunescu, & Salem, 2009), Little ve arkadaşlarının verilerini kaba küme yaklaşımı kullanarak analiz etmişlerdir. Elde ettikleri bu verileri öncelikle filtreleme algoritmalarıyla kendi içinde elemiş ve çıkan neticeler sınıflandırma algoritmasına verilerek %90 başarı sağlanmıştır.

Tsanas ve arkadaşları yaptıkları başka bir çalışmada (Tsanas, Little, McSharry, & Ramig, 2010b) ses sinyallerini logaritmik olarak dönüştürmeyle ilgilenmişlerdir. Hastanın evinde kendi kendine gerçekleştirmiş olduğu bu test çalışması ile elde edilen sonuçlar, uzmanlar tarafından hastalığın teşhis ve derecesini belirlemek için kullandıkları Birleşik Parkinson Hastalığı Değerlendirme Ölçeğiyle (BPHDÖ) eşleştirmişlerdir. Görülmüştür ki; logaritmik olarak dönüştürülmüş ses sinyallerinin ham ses sinyallerine göre çok daha iyi klinik bilgiler sağlamaktadır.

Das yapmış olduğu benzer bir çalışmada UCI veri tabanından elde ettiği 23'ü hasta 31 bireye ait veriler için yapay sinir ağları, karar ağaçları ve regresyon metodlarını içeren farklı sınıflandırma yöntemlerini kullanmıştır. %92,9 doğru sınıflandırma sonucunu sinir ağları uygulaması ile elde etmiştir (Das, 2010).

Şakar ve Kurşun, öznelikler ve BPHDÖ puanı arasındaki ilişkiyi belirlemek için ortak bilgi tabanlı bir öznelik seçimi uygulaması ve seçilen öznelikleri DVM sınıflandırıcısına vererek bir sınıflandırma modeli oluşturmuşlardır. Ayrıca bir bireyi dışarıda bırakma (BBDB) çapraz doğrulama yöntemini kullanarak sistemin tarafsızlığını arttırmaya çalışmışlardır. Sistemlerin başarı performansını ROC eğrisi (alıcı işletim eğrisi), gerçek pozitif ve yanlış negatif oranları ile ölçülmüştür (C. O. Sakar & Kursun, 2010).

Bayestehtashk vd, yaptıkları çalışmalarında 168 Parkinson hastasından aldıkları çeşitli verilerden OPENSIMILE (Eyben, Wöllmer, & Schuller, 2010) aracı kullanarak 1582 öznelik çıkarmış, birini dışarıda bırak çapraz doğrulama yöntemi kullanmış ve

farklı regresyon yöntemlerinin sınıflandırmadaki başarısını incelemiştir. Sonuç olarak ridge regresyon analizinin, lasso ve destek vektör regresyonuna göre daha iyi performans sergilediği görülmüştür (Bayestehtashk, Asgari, Shafran, & McNames, 2015).

Şakar ve arkadaşları (B. E. Sakar vd., 2013), 20 sağlıklı 20 hasta toplam 40 bireyden, gündelik cümleler, sayılar, basit kelimeler ve uzatılmış seslilerden oluşan 26şar ses kaydından PRAAT akustik analiz yazılımı ile sesin temel frekansına dayalı 26 öznitelik elde etmiş ve sınıflandırma işleminde k-EYK ve LibSVM sınıflandırma algoritmalarının performanslarını incelemiştir. Ayrıca merkezi yayılım ve dağılım ölçütlerini baz alarak geliştirdikleri özetlenmiş birini dışarda bırakma yöntemi (ö- BDB) ile bir bireyi dışarda bırakma (BBDB) çapraz doğrulama yöntemlerinin sınıflandırma başarısına olan etkisini araştırmış ve ö- BDB ile %85 oranında bir başarı elde etmişleridir.

Cantürk ve Karabiber (Cantürk & Karabiber, 2016) yaptıkları çalışmada Şakar vd., oluşturmuş oldukları veri kümesi üzerinde dört farklı öznitelik seçim ve altı farklı sınıflandırma algoritmaları uygulamışlar modelin doğruluğu için k-katlı ve bir bireyi dışarda bırakma çapraz doğrulama yöntemlerinin karşılaştırmasını yapmışlardır. Sonuç olarak LASSO ile seçilen özniteliklerin DVM sınıflandırıcıda 10-katlı çapraz doğrulama yöntemiyle daha iyi başarı gösterdikleri görülmüştür.

BÖLÜM 3

MAKİNE ÖĞRENİMİ VE ÖZİNİTELİK ÇIKARMA YÖNTEMLERİ

3.1. Makine Öğrenimi

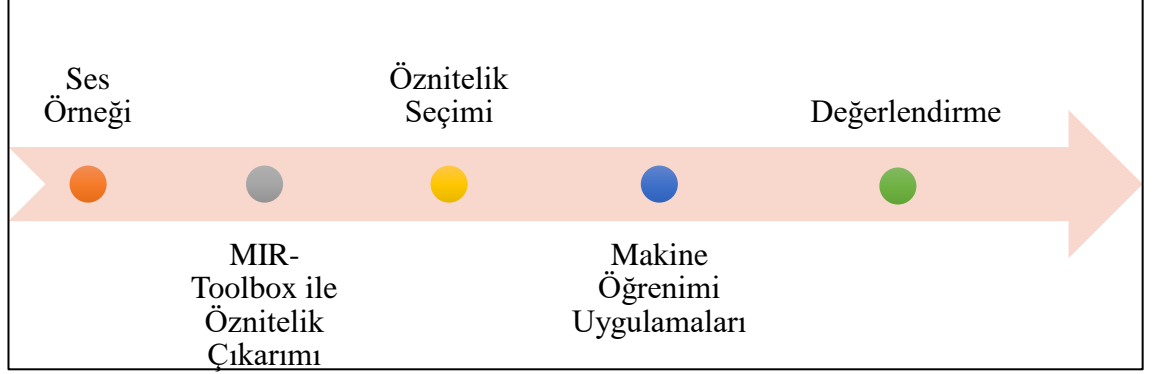
Makine öğrenimi, bir konu veya bir problemi, problemle ilgili mevcut bilgilere göre modelleyip sonuçlandıran yöntemlerin genel adıdır (Silahtaroglu, 2008). Bu modellemeler yapılırken çeşitli algoritmalarından yararlanır.

Makine öğrenimi algoritmaları, metin, görüntü, sayısal ölçüm gibi çeşitli verileri kullanarak bu veri kümelerinden çeşitli bilgiler çıkarır. Çıkarım yapılan bilgilerle probleme uygun bir çıkarım modeli oluşturulur. Çıkarım modelleri veri türüne göre değişiklik gösterebilmektedir. Örneğin belirli bir hastalığın belirtilerini kullanarak hasta ve sağlıklı bireylerin ayrılmasında sınıflandırma yöntemleri kullanılabilir. Daha büyük ölçekli verilerle işlem yapılan alanlarda, veriler içerisinde benzer yapıya sahip olanları ayırıp kategorize ederek sonuca ulaşan kümeleme yöntemleri kullanılabilir.

Bu modellerin uygulanabilmesi için öncelikle verilerin hazırlanması gerekmektedir. Elde edilen sonuçlara göre veriler, doğrudan kullanılabilmenin yanında uygun olmayan verilerin veri kümesinden çıkartılması, eksik verilerin tamamlanması ve farklı ölçekteki verilerin standart bir değer aralığına dönüştürülmesi gibi bazı ön işlemlere de tâbi tutulabilir. Makine öğreniminde analiz edilen veriler toplanan örneklerden çıkartılır. Problemle ilgili çıkarım yapmak amacıyla toplanan her örneğe ait kullanılabilir her türlü bilgiye *öznitelik (feature)* adı verilir (Özkan, 2008). Özniteliğin yanında çıkarım için her örneğin kategorisel yada bulunduğu sınıfa ait bilgiler gereklidir. Makine öğreniminde kullanılan modelin oluşturulması için gerekli veri

kümesine *eğitim kümesi*, karşılaştırılacak olan veriye ise *test verisi* adı verilir (Alpaydın, 2009).

Bu tez çalışmasında izlenen makine öğrenimi aşamaları Şekil 3.1’de özetlenmiştir.



Şekil 3.1: Sistemin genel işlem basamakları

3.2. Veri Kümelerinin Elde Edilmesi

Yapılan deneysel çalışmalarda, çok dilli ve dengeli bir model oluşturmak için iki farklı veri kümesi kullanılmıştır. Parkinson hastalarına ait veri kümesi UCI makine öğrenme havuzundan elde edilirken (Asuncion & Newman, 2007), sağlıklı bireylere ait veriler deneklerin sayısını dengelemek için Saarbrücken Ses Veri Tabanından – SVD temin edilmiştir (Barry & Pützer, 2007). Müzikal özelliklerin etkilerini incelemek için deneylerde ham ses kayıtları kullanılmıştır.

Bu çalışmada kullanılan hasta bireylere ait veri kümesi, 28 Parkinson hastasına ait uzatılmış /a/ ve /o/ seslerinin üçer tekrarını içermektedir. (B. E. Sakar vd., 2013).

Şakar vd.’nin UCI veri tabanında bulunan sağlıklı iki bireye ait ham ses dosyalarının deneylerde kontrol grubu olarak kullanılması sayı bakımından yeterli değildir. Bu sebeple, sağlıklı bireylere ait ham ses dosyaları SVD veri tabanından temin edilmiştir. 62 sağlıklı bireyden elde edilen sürdürülmüş /a/ ve /o/ sesleri UCI veri tabanından temin edilen hasta veri kümesi dikkate alınarak aynı yaş aralığındaki bireylerden seçilmiştir. Bu veri tabanından ayrıca üç farklı tonda (yüksek, normal ve

düşük) ses kaydı ton farkının sınıflandırmaya olan etkisini incelenmek için kullanılmıştır (Çizelge 3.1).

Çizelge 3.1. Veri kümelerinin kısa özeti

	Hasta Veri Kümesi	Sağlıklı Veri Kümesi
Katılımcı kişi sayısı	28	62
Erkek katılımcı	19	35
Kadın katılımcı	9	27
Hastalık geçmişi (yıl)	0-13	-
Yaş aralığı	39-79	39-79
Yaş ortalaması	62.67	50.75
Yaşın standart sapma	10.96	9.61
Veri kümesi örnek sayısı	28*6 =168	62*2 = 124

3.3. Öznitelik Çıkarımı

Ses üretiminde görevli gırtlak kaslarının Parkinson hastalığı ile etkilenmesi sonucu ortaya çıkan ses bozuklukları, hastalarda konuşma sırasında seste titremeye, düşük tonda ve tekdüze ses çıkartılmasına, ritimsel bozukluklara sebep olmaktadır. Hasta ve sağlıklı bireylerden elde edilen ses örneklerinin müzikal özniteliklerini belirlemek amacıyla Music Information Retrieval (MIR) Toolbox aracı kullanılmıştır (Olivier Lartillot & Toiviainen, 2007). Hasta ve sağlıklı bireylerden elde edilen müzikal özniteliklerin çıktıları, ilgili özniteliliğin altında şekilsel olarak gösterilmiştir.

3.3.1 Müzikal Bilgi Çıkarım Aracı (MIR-Toolbox)

Müzik bilgi çıkarım aracı (Music information retrieval- MIR-toolbox), GNU genel kamu lisansı ile indirilebilen ücretsiz bir yazılımdır. Olivier Lartillot ve Petri Toiviainen tarafından geliştirilen bu araç müzik analizi ve özellikle müzikal özellik çıkarma için bilgisayar tabanlı araştırmalara genel bir bakış sunar (Olivier Lartillot, Toiviainen, & Eerola, 2008).

MIR-toolbox, Matlab' da yazılan, ton, ritim, tını, perde, dinamiklik gibi müziksel özelliklerin ses kayıtlarından çıkarılmasını sağlayan bir araç kutusudur.

Yaklaşık 50 ses ve müzikal öznitelik çıkarıcı ve istatistiksel tanımlayıcı içeren geniş bir yelpazeye sahip olan MIR-toolbox istatistiksel analiz uygulanabilecek ses dosyalarından çıkartılabilecek öznitelik hesaplanmasını sağlamak amacıyla tasarlanmıştır (Olivier Lartillot & Toivainen, 2007). MIR-toolbox, kurulumunda Matlab'ın 7. sürüm ve sonrası sürümleri gerekmektedir. Ayrıca yine Matlab platformunun sinyal işleme araç kutusunun kurulu olması gerekmektedir.

Özniteliği çıkarılmak istenilen ses kaydı örneği ses dosyası (wav- waveform audio file) formatına dönüştürülerek ve gürültüden ayrıştırılarak işlem yapılmalıdır. 111 adet sesin müzikal özelliklerine dayanan öznitelik MATLAB sinyal işleme ve yazılım platformunda çıkartılmıştır. Çizelge 3.2'de gösterilen öznitelikler MIR-toolbox ile uyumluluğu bakımından orijinal dilinde verilmiştir. Özniteliklerin Türkçe karşılıklarını içeren çizelge ise *Ek 1*'de gösterilmiştir.

Çizelge 3.2: Ses örneklerinden çıkartılan müzikal bazlı öznitelikler

No	Öznitelik	No	Öznitelik
1	RMS	17	Emerge event (std)
2	Low energy	18	Emerge event (median)
3	Best pitch	19	Emerge event (max)
4	Fluctuation (mean)	20	Emerge event (min)
5	Fluctuation (std)	21	Spectral Flux (mean)
6	Fluctuation (median)	22	Spectral Flux (std)
7	Fluctuation (max)	23	Spectral Flux (median)
8	Fluctuation (min)	24	Spectral Flux (max)
9	Beatspectrum (max)	25	Spectral Flux (min)
10	Beatspectrum (min)	26	Event (max)
11	Beatspectrum (range)	27	Event (min)
12	Beatspectrum (mean)	28	Event (range)
13	Beatspectrum (var)	29	Event (mean)
14	Beatspectrum (kurt)	30	Event (var)
15	Beatspectrum (skew)	31	Event (kurt)
16	Emerge event (mean)	32	Event (skew)

Çizelge 3.2: Ses örneklerinden çıkartılan müzikal bazlı öznitelikler (devam)

33	Event Density	65	Chromagram (max)
34	Zero-cross	66	Chromagram (min)
35	Roll-of 85	67	Chromagram (range)
36	Roll-off 95	68	Chromagram (mean)
37	Brightness	69	Chromagram (var)
38	Centroid	70	Chromagram (kurt)
39	Spread	71	Chromagram (skew)
40	Skewness	72	Wrapped Chromagram (max)
41	Kurtosis	73	Wrapped Chromagram (min)
42	Flatness	74	Wrapped Chromagram (range)
43	Entropy	75	Wrapped Chromagram (mean)
44-56	MFCC 1-13	76	Wrapped Chromagram (var)
57	Roughness (max)	77	Wrapped Chromagram (kurt)
58	Roughness (min)	78	Wrapped Chromagram (skew)
59	Roughness (range)	79-102	Key strength 1-24
60	Roughness (mean)	103	Key
61	Roughness (var)	104	Mode (best)
62	Roughness (kurt)	105	Mode (sum)
63	Roughness (skew)	106-111	Tonal centroid 1-6
64	Irregularity		

Çizelge 3.3, yukarıda verilen 111 özniteliğin dinamik, tını, ritim, perde ve ton gruplarından hangisine dahil olduğunu göstermektedir.

Çizelge 3.3. Çıkartılan öznitelikler ve dahil olduğu temel müzikal öznitelik grupları

Öznitelik Grupları	Öznitelik Numara Aralığı
Dinamik	1-2
Perde	3
Ritim	4-33
Tını	34-64
Ton	65-111

3.3.2. Dinamik Grubu Özellikler


Dinamik grubu özellikleri, ses sinyallerinin enerjisi hakkında bilgileri kapsamaktadır. Bir ses dalgasının genliği ne kadar fazla ise şiddeti ve enerjisi o kadar fazladır. Ses dalgalarının genliği azaldıkça sesin enerjisi ve şiddeti azalır. Genliği az olan ses dalgalarının oluşturduğu sese *zayıf ses* denir. Parkinson hastalarında konuşma sırasında ses gücünün giderek azalması ve şiddetini kaybetmesi beklenir.

3.3.2.1 Karesel ortalamanın karekökü (RMS)

Karesel ortalamanın karekökü (RMS), bir sinyalin büyüklüğünün ölçülmesi için kullanılır. Herhangi bir sinüsoidal dalganın karekök ortalama değeri hesaplanırken, sinyal boyunca kaydedilen genlik değerlerinin karelerinin ortalaması bulunur. Elde edilen ortalama değerinin karekökü alınır (Denklem 3.1).

$$x_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} = \sqrt{\frac{x_1^2 + x_2^2 + \dots + x_n^2}{n}} \quad (3.1)$$

Şekil 3.2, sağlıklı ve hasta bireylerden alınan ses sinyallerinin 50 milisaniyelik bölümlerinin karekök ortalama değerlerinin birleşimiyle oluşan enerji grafiklerini göstermektedir.



Şekil 3.2: (a) Sağlıklı ve (b) hasta bireylere ait RMS enerji grafikleri

Şekil 3.2'te görüldüğü üzere Parkinson hastası bir birey ile sağlıklı bir bireyin ses sinyallerinin enerjisi farklılık göstermektedir. Parkinson hastalığında ses çıkarımı ve konuşma kaslarının kontrolünde yaşanan kayıp sonucu hasta bireylerin ses sinyal

enerjileri düşüktür. MIR-toolbox aracına entegre olan “*mirrms*” komutu ile ses sinyallerinin karekök ortalama enerji değerleri öznitelik olarak çıkartılmıştır.

3.3.2.2 Düşük Enerji (Low Energy)

Enerji eğrisi, sinyale ait enerjinin sinyal boyunca zamansal dağılımını değerlendirmek için kullanılır. Düşük enerji oranı, ortalama enerjiden daha az olan sinyal parçalarının yüzdesi hesaplanarak bulunur (Tzanetakis & Cook, 2002).

MIR-toolbox bünyesindeki “*mirlowenergy*” komutu ile hasta ve sağlıklı bireylerden oluşturulan veri kümesindeki ses dosyalarından sesin dinamikliğine ait öznitelik değerleri çıkartılmıştır.

3.3.3. Perde Grubu Özellikler

Perde, bir ses sinyalini oluşturan ses dalgalarının titreşim frekansına bağlıdır. İnsanlarda, akciğerden gelen havanın ses tellerini titretmesi sonucu oluşan titreşim frekansı sesin perdesini belirler. Kadın ve çocukların ses telleri kısa ve ince yapıda oldukları için yetişkin erkek bireylere göre daha yüksek perdeye sahiptirler.

Bu tez çalışmasında kullanılan Parkinson hastası ve sağlıklı bireylerin ses dosyalarından MIR-toolbox içerisinde oluşturulmuş “*mirpitch*” komutu ile çıkartılan öznitelikler belirli bir frekans değerindeki en iyi perde genliğini ifade etmektedir.

3.3.4. Ritim Grubu Özellikler

Ritim, Latince'de akış demektir. Türk Dil Kurumuna göre ise ritim “*Bir dizede, bir notada vurgu, uzunluk veya ses özelliklerinin, durakların düzenli bir biçimde tekrarlanmasından doğan ses uygunluğu, tartım, dizem.*” ifadeleri ile tanımlanır (TDK). Bir başka deyişle, ses sinyalindeki iniş ve çıkışların belirli bir harmonide tekrarlanması, sesin ritmik karakteristiğini verir. Sesin ritmi kişiye özgüdür.


Ritim, zamanlama ve hız akıcı konuşmada büyük önem taşımaktadır. Akıcı konuşmada sözcükler, sözcük grupları arasında vurgulama ve doğru yerde duraklama açısından farklılıklar olsa da kendiliğinden akar. Akıcı konuşma esnasında ortaya çıkan

bozukluklar, uygun olmayan duraklamalar, tekrar edilen sözcük ve sözcük grupları ve benzer problemler konuşmanın doğal akışını etkilemektedir. Parkinson hastalığında da konuşma sırasında kelimeler arasında alışılmış duraklamaların olmaması, hastanın günlük yaşantısında kendini ifade etme sırasında cümlelerin iç içe girmişçesine anlaşılabilir hale gelmesine neden olabilmektedir. Yüz ifadelerini veren ve ses çıkarımında görevli olan kasların etkilenmesi sonucu hasta bireylerde ifade ritminde sorunlar gözlenmektedir.

3.3.4.1 Dalgalanma Kuvveti (Fluctuation Strength)

Ritmi tahmin etmenin bir yolu, işitsel modelleme ile dönüştürülen spektrogram hesaplamasına dayanır (Pampalk, Rauber, & Merkl, 2002). Ritim düzeni, ilgili frekans bantlarında güçlü ve hızlı vuruşların nasıl yapılacağı hakkında bilgi içerir. Ses şiddetinin genlik değişimleri, geçiş frekansına bağlı olarak işitme duyumuzda farklı etkilere sahiptir (Fastl, 1982). Dalgalanma kuvveti, bir sesin 20 Hertze kadar olan daha düşük genlikteki geçişlerini ölçmek için kullanılır.

“*mirfluctuation*” komutu ile 0.5 saniyelik çerçevelere ayrılan ses örnekleri 10 Hertzlik frekans değerine ayarlanarak dalgalanma kuvvetleri hesaplanmıştır.



Şekil 3.3: (a) Sağlıklı ve (b) hasta bireylere ait dalgalanma kuvvetlerinin spektrum olarak gösterimi

Parkinson hastalığında vokal kordların titreşim fonksiyonu bozulmaktadır. Ayrıca hastalar seslerini kontrol etmekte zorluk yaşamaktadır. Bu sebeple Şekil 3.3'te de görüldüğü üzere eşit bant genişliklerinde Parkinson hastası bireylerin seslerinde sağlıklı bireylere göre daha fazla dalgalanma gözlenmektedir.

3.3.4.2 Atım Spektrumu (Beat spectum)

Atım spektrumu, müzik ve sesin ritim ve temposunu otomatik olarak karakterize eden bir özneliktir. Bu özellik zaman gecikmesinin bir fonksiyonu olarak akustik öz benzerliğinin bir ölçüsüdür (Foote & Uchihashi, 2001).

Tempo, bir ses sinyalinin veya konuşmanın hızını ifade eder. Atım spektrumu ile ses sinyallerine tempo analizi yapılabilmektedir. Atım spektrumundaki tepe noktaları, kaynak sesin ana ritmik bileşenlerine karşılık gelen değerleri ifade eder. Her bileşenin tekrarlanma zamanı ilgili tepe noktasının gecikme süresi ile belirlenebilir. Bu durum ise aynı tempodaki farklı ritim çeşitlerinin ayırt edilebilmesine imkan sağlar.

Atım spektrumu, ses sinyallerinden üç temel adımda hesaplanır (Foote & Uchihashi, 2001):

- İlk olarak, ses kaydı spektral veya diğer gösterim yolları kullanılarak parametreler çıkartılarak öznelik vektörleri oluşturulur.
- İkinci adımda ise öznelik vektörlerinin tüm çift yönlü kombinasyonları arasındaki benzerliği hesaplamak için bir mesafe ölçümü kullanılır. Bu ölçüm değerleri ile benzerlik matrisi adı verilen iki-boyutlu bir gösterge oluşturulur.
- Son adımda ise, diyagonal toplam veya otokorelasyon kullanılarak benzerlik matrisindeki periodiklik hesaplanır.

Parkinson hastası ve sağlıklı bireylerin ses kayıtlarından “*mirbeatspectrum*” komutu kullanılarak atım spektrumu değerleri çıkartılmıştır.


3.3.4.3 Başlama noktası (Event, Onset)

Müzikal bir eserin oluşumunda her notanın bir çıkış noktası vardır. Bir notadan diğerine geçişlerde çok kısa süreli de olsa bir bekleme anı vardır. Oluşan bu beklemenin ardından diğer notaya geçiş anı başlangıç noktası (onset) olarak ifade edilir. Başlangıç noktası, sinyallerde ardışık iki nokta arasındaki ardışık enerji değerine tekabül eden noktaları temsil eder (Dixon, 2006).

Müzik eserlerindeki bu geçiş durumları konuşmada da geçerlidir. Ses üretiminde ses sinyalinin başlangıç ve bitiş noktaları arasında yaşanan iniş ve çıkışlar sırasında

gerçekleşen ancak dışarıdan algılanmayan bu kısa süreli duraksamalar sinyali analizi ile belirlenebilmektedir.

Tez çalışmasında kullanılan veri kümesindeki farklı sınıflardaki bireylerin ses kayıtlarından MIR-toolbox’da mevcut olan “*mirevents* (eski sürümlerde “*mironsets*”)” fonksiyonu ile çıkartılan grafiklerden de (Şekil.3.4) görülebileceği üzere Parkinson hastalarında fonasyon sırasında meydana gelen değişimler hem daha fazla miktarda olmaktadır hem de sağlıklı bireylere göre daha düşük enerjiye sahiptirler.




Şekil 3.4: (a) Sağlıklı ve (b) hasta bireylere ait başlangıç noktası grafikleri

3.3.4.4 Spektral Akı (Spectral Flux)

Spektral akı, bölümlere ayrılmış bir sinyalin belli bir çerçevedeki güç spektrumunun kendinden önce gelen çerçevedeki güç spektrumu ile arasındaki Öklid mesafe ölçütüyle hesaplanan değerlerdir ve sinyalin güç spektrumlarının ne kadar hızla değiştiğinin bir göstergesidir.

“*mirflux*” fonksiyonu ile belirlenebilen spektral akı değerleri elde edilebilirken, sinyalde gözlenen başlangıç noktalarını görmek için “*mirevents* (*dosya_adi*, ‘*SpectralFlux*’)” fonksiyon komutu kullanılabilir (Şekil 3.5).




Şekil 3.5: (a) Sağlıklı ve (b) hasta bireylere ait spektral akı grafikleri

3.3.4.5. Nokta Çıkarımı (Emerge event)

Nokta Çıkarımı özneteliği, spektral akı özneteliğinin geliştirilmiş bir sürümüdür. Spektral akıya göre aynı anda daha fazla nota ve sinyal başlama noktası algılayabilen bu öznetelik fazla titreşimden kaynaklanan spektral varyasyonu göz ardı eder (Olivier Lartillot vd., 2013).

Tez çalışması için oluşturulan hasta ve sağlıklı sınıfa ait verilerden “*mirevents (dosya_adi, 'Emerge')*” komutu kullanılarak elde edilen grafikler Şekil 3.6’da gösterilmiştir.



Şekil 3.6: (a) Sağlıklı ve (b) hasta bireylere ait nokta çıkarım grafikleri

3.3.4.6 Başlangıç Yoğunluğu (Event Density)

Ortalama başlangıç frekansını, yani saniyede tespit edilen sinyal başlangıç noktalarının sayısını ifade eder.

MIR-toolbox'a entegre edilmiş fonksiyonlarından birisi olan "mireventdensity" komutu ile çıkartılan değerler öznitelik olarak kullanılmıştır. Komutun Matlab komut ekranındaki örnek çıktısı aşağıdaki gibidir.

- Sağlıklı kontrol grubu bireylerden çıkartılan örnek sonuç:

"The Event density related to file control_set_subject_1a1.wav is 1.81 per second"

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:


"The Event density related to file test_set_subject_2a1.wav is 0.082645per second"

3.3.5. Tını Grubu Özellikler

Sesin önemli karakteristik özelliklerinden birisi olan tını sesin rengini ifade etmektedir. Aynı oktavda, aynı gürlük ve aynı uzunluktaki sesleri ayırt etmemizi sağlayan bir niteliktir. Örneğin, bir besteyi keman ve piyano aletlerinden aynı notaları çalmalarına rağmen farklı seslerde algılarız. Çünkü bu durum keman ve piyanonun tınılarının farklı olmasından kaynaklıdır. Sesteki bu farkı meydana getiren unsur da overtone yada armoni denilen esas frekans ile aynı anda duyulan alt ya da üst frekanslardır.

3.3.5.1 Sıfır Geçiş (Zero-cross)

Bir ses sinyalinde örneklerin negatif yönden pozitif yöne veya tam tersi yöndeki geçiş işlemleri sıfır geçiş olarak isimlendirilir (Şekil 3.7). Konuşma sırasında bu geçişlerin sayısı fazladır. Olası konuşmada, ses şiddetinin ani artması ve düşmesi ile tespit edildikten sonra sesin tam olarak nerede başlayıp hangi noktada sona ermesinin kontrolü için bu geçişlerin sayısına bakılır.



Şekil 3.7: MIR-toolbox kullanım kılavuzunda yer alan örnek sıfır geçiş grafiği (O Lartillot, 2012)

MIR-toolbox'ın tını özellikleri grubunda yer alan “*mirzerocross*” fonksiyonu ile Parkinson hastası ve sağlıklı gruplardan alınan örnek sinyallerin Matlab komut ekranındaki değerleri aşağıda verilmiştir.

- Sağlıklı kontrol grubu bireylerden çıkartılan örnek sonuç:


“*The Zero-crossing rate related to file control_set_subject_1a1.wav is 526.4245*”

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“*The Zero-crossing rate related to file test_set_subject_2a1.wav is 652.6406*”

3.3.5.2 Roll-off 85

Roll-off kullanarak ses sinyalinin toplam enerji miktarının belirli bir eşik frekansı altında kalan bölümünün frekans miktarı bulunur (Şekil 3.8). Roll-off 85, genlik dağılımının % 85'inin altındaki kalan frekans miktarını temsil eder (Tzanetakis & Cook, 2002).



Şekil 3.8: MIR-toolbox kullanım kılavuzunda yer alan örnek Roll-off 85 grafiği (O Lartillot, 2012)

MIR-toolbox'ın tını özellikleri grubunda yer alan “*mirrolloff (dosya_adi, 'Threshold', 85)*” fonksiyonu ile Parkinson hastası ve sağlıklı gruplardan alınan örnek sinyallerin Matlab komut ekranındaki değerleri aşağıda verilmiştir.

- Sağlıklı kontrol grubu bireylerden çıkartılan örnek sonuç:

“*The Rolloff related to file control_set_subject_1a1.wav is 3438.0787 Hz.*”

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“*The Rolloff related to file test_set_subject_2a1.wav is 2513.3286 Hz*”

3.3.5.3 Roll-off 95

Roll-off 95, genlik dağılımının % 95'inin altındaki kalan frekans miktarını temsil eder (Pohle, Pampalk, & Widmer, 2005). MIR-toolbox'ın tını özellikleri grubunda yer alan “*mirrolloff (dosya_adi, 'Threshold', 95)*” fonksiyonu ile Parkinson hastası ve sağlıklı gruplardan alınan örnek sinyallerin Matlab komut ekranındaki değerleri aşağıda verilmiştir.

- Sağlıklı kontrol grubu bireylerden çıkartılan örnek sonuç:

“*The Rolloff related to file control_set_subject_1a1.wav is 6475.6062 Hz*”

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“*The Rolloff related to file test_set_subject_2a1.wav is 4910.3694 Hz.*”

3.3.5.4 Parlaklık (Brightness)

Parlaklık, aynı zamanda yüksek frekanslı enerji olarak da adlandırılır ve Roll-off özelliği ile benzerlik gösterir. Aralarındaki fark ise, Brightness özelliğinde belirli bir kesme frekansı eşik değerinden daha yüksek frekansa denk gelen spektral enerji miktarını hesaplanır. Bu değerler 0 ile 1 arasındadır (Juslin, 2000). Kesme frekansı 500 Hz ile 3000 Hz arasında değişmektedir. Varsayılan değer olarak ise 1500 Hz seçilmektedir. “*mirbrightness (dosya_adi, 'Cutoff', 1500)*” ifadesi ile istenilen kesme frekansı ayarlanarak çıkartılan değerler brightness özneliği olarak kullanılmaktadır.

- Sağlıklı kontrol grubu bireylerden çıkartılan örnek sonuç:

“The Brightness related to file control_set_subject_2a1.wav is 0.25918”

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“The Brightness related to file test_set_subject_2a1.wav is 0.2089”

3.3.5.5. Geometrik merkez (Centroid)

Spektral dağılımın istatistiksel verilerinden olan ortalama, dağılımın geometrik merkezini (centroid) ifade eder ve dağılımdaki rasgele değişkenler için merkezi eğilimin bir ölçüsüdür. *“mircentroid”* ifadesi ile Parkinson hastası ve sağlıklı bireylerin ses dosyalarından elde edilen merkezi ortalama tını grubu öznelikleri arasındadır.

- Sağlıklı kontrol grubu bireylerden çıkartılan örnek sonuç:

“The Spectral centroid related to file control_set_subject_1a1.wav is 1830.5339”

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“The Spectral centroid related to file test_set_subject_2a1.wav is 1326.3183”

3.3.5.6. Yayılım (Spread)

İstatistiksel olarak varyans değerlerini kullanan yayılım, elde edilen verilerin ortalama değerinden sapmalarının karelerinin toplamıdır. MIR-toolbox yardımıyla varyans değeri *“mirspread”* komutu kullanılarak elde edilir.

- Sağlıklı kontrol grubu bireylerden çıkartılan örnek sonuç:

“The Spectral spread related to file control_set_subject_1a1.wav is 3081.7943”

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“The Spectral spread related to file test_set_subject_2a1.wav is 1932.0044”

3.3.5.7. Çarpıklık (Skewness)

Normal dağılımın test ölçütlerinden birisi olan çarpıklık spektral dağılımın simetrisi hakkında bilgi verir. *“mirskewness”* komutu çarpıklık ölçütünün katsayı değerlerini baz alır. Çarpıklık katsayısının kullanılması, doğal sistemlerden elde edilen

veriler için genellikle -3.0 ile +3.0 arasında deęişir. Simetrik normal daęılımlarda ise arpıklık katsayısının 0 olması gereklidir.

- Saęlıklı kontrol grubu bireylerden ıkartılan rnek sonu:

“The Spectral skewness related to file control_set_subject_1a1.wav is 4.1611”

- Parkinson hastası grubunda bulunan bireylerden ıkartılan rnek sonu:

“The Spectral skewness related to file test_set_subject_2a1.wav is 5.4007”

3.3.5.8. Basıklık (Kurtosis)

Daęılım eęrisinin basıklığı hakkında bilgi verir. Basıklık normal daęılımın istatistiksel parametrelerinden birisidir. Basıklık katsayısının normal daęılımda 0 olması gerekmektedir. Verilerle elde edilen daęılımın, normal daęılımdan farklı olmaması iin verilerin -1,+1 deęerleri arasında olması gerekmektedir. Daęılım grafiklerinde sivrilme pozitif basıklık katsayıları ile,basık bir grafik ise negatif basıklık katsayı deęerleri ile gzlenir.

MIR-toolbox aracında *“mirkurtosis”* ifadesi kullanılarak daęılımın basıklık katsayı deęerleri elde edilir.

- Saęlıklı kontrol grubu bireylerden ıkartılan rnek sonu:

“The Spectral kurtosis related to file control_set_subject_1a1.wav is 23.1405”

- Parkinson hastası grubunda bulunan bireylerden ıkartılan rnek sonu:

“The Spectral kurtosis related to file test_set_subject_2a1.wav is 45.8481”

3.3.5.9. Düzgünlük (Flatness)

Düzgünlük, daęılımın düz mü yoksa sivri tepeli mi olduğunu ifade eder. Geometrik ortalama ile aritmetik ortalama arasındaki basit oranla hesaplanır. MIR-toolbox aracında *“mirflatness”* ifadesiyle daęılımın düzgünlüğü hakkında bilgiler ıkartılabilmektedir.

- Saęlıklı kontrol grubu bireylerden ıkartılan rnek sonu:

“The Spectral flatness related to file control_set_subject_1a1.wav is 0.084098”

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“The Spectral flatness related to file test_set_subject_2a1.wav is 0.034244”

3.3.5.10. Entropi

Belirsizlik değeri olan entropi genel olarak bir sistemin düzensizliği ve rastgeleliği hakkında sayısal bilgi veren bir terimdir. Claude E. Shannon tarafından formülize edilen bu ölçüt (Shannon, 1948) veri madenciliği alanında bilgi kazancını hesaplamak için sıklıkla kullanılır. Bir veri kümesinde çeşitlilik, belirsizlik ne kadar fazla ise o veri kümesinden çıkartılacak bilgi kazanımı o kadar fazladır. Elde edilen eğri düzleşme oranı arttıkça belirsizlik durumu da artar. Entropinin minimum olduğu durumlarda ise, eğri keskin ve sivri bir tepeden oluşur.

MIR-toolbox aracında “mirentropy” komutu kullanılarak veri dağılımının entropisi hakkında bilgi elde edebilir.

- Sağlıklı kontrol grubu bireylerden çıkartılan örnek sonuç:

“The Entropy of Spectrum related to file control_set_subject_1a1.wav is 0.7634”

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“The Entropy of Spectrum related to file test_set_subject_2a1.wav is 0.80744”

3.3.5.11. Mel-Frekansı Kepstrum Katsayıları (MFCC)


Mel-Frekansı Kepstrum Katsayıları (MFCC), sesin spektral şeklinin bir ifadesini sunar. Ses tanıma, analiz ve sistemlerinde sıklıkla kullanılan bir yöntemdir. Bunun nedeni, MFCC insan kulağının frekans seçiciliğine yakın bir analiz yaparak konuşmacıları daha iyi şekilde ayırt edici değerler sunar. MFCC katsayıları, ses dalga yapısından ve değişimlerden çok daha az etkilenir (Eskidere & Ertaş, 2009).

MFCC katsayılarını elde ederken sinyallere bazı işlemler uygulamak gereklidir.

- **Çerçeveleme:** Konuşma süresince farklı ses üretimi gerçekleştiği için sinyaller de sürekli bir değişim halindedir. Sinyallerin daha sabit hale getirilip, değişimlerin en az olmasını sağlamak için sinyallere çerçeveleme işlemi uygulanır. Çerçeveleme işleminde sinyaller örneğin 15-30 ms süreli bölümlere ayrılır.

- **Pencereleme:** Çerçeveleme işlemi sonrasında oluşan spektral etkileri azaltmak amacıyla uygulanan bir işlem sürecidir. Çerçevelere ayrılan sinyallerin orta kısımları güçlendirilirken uç kısımları zayıflatılır. Bu süreçte Hamming, Hanning, Blackman gibi matematiksel fonksiyonlardan yararlanır.
- **Hızlı Fourier Dönüşüm (FFT):** Sinyallerin genlik spektrumlarını hesaplamak amacıyla kullanılan, sinyalin hangi frekansta ne şiddette bir titreşime sahip olduğunun bilgisini veren bir sinyal dönüşüm modelidir.
- **Ön vurgulama:** Ses yolunun yüksek frekansları zayıflatmasını önlemek amacıyla kullanılan bir adımdır. Ünlü seslerin oluşum ve konuşmaya dönüş süreci sırasında -6dB/oktav'lık bir zayıflama meydana gelmektedir. Ünsüz seslerde böyle bir durum olmadığı için ön vurgulama adımına ihtiyaç yoktur.
- **Mel-ölçek süzgeç dizini:** Sinyallerin genlik spektrumlarının, belirli bir merkez frekansı ve bu merkez frekansına bağlı olarak belirlenen alt üst sinyalleri geçiren üçgen süzgeçlerden geçirildiği bir adımdır. Buradaki amaç ses yolunun etkisini kaynaktan ayırmaktır.
- **Ayrık Kosinüs Dönüşümü (DCT):** Kepstrum sayıları hesaplanırken normal spektral analizde kullanılan Ayrık Fourier Dönüşümü (DFT) yerine kullanılır. Daha güçlü enerji sıkıştırma özelliği gösteren bir dönüşüm olduğu için Kepstral sayılar yüksek derecede istatistiksel bağımsızlık göstererek, normal spektral analize göre yüksek tanıma oranı verirler.

MIR-toolbox aracında MFCC katsayılarını elde edebilmek için “*mirmfcc*” komutunu kullanarak 13 adet katsayı değeri edilebilmektedir (Şekil 3.9).




Şekil 3.9: (a) Sağlıklı ve (b) hasta bireylere ait MFCC değer grafikleri

3.3.5.12 Pürüzlülük (Roughness)

Pürüzlülük, aynı sestem gelen birbirine yakın frekans pikleri arasındaki farklı atımlar nedeniyle oluşan duyuşsal uyumsuzluğun ölçümüdür. Örtüşen iki ses dalgası arasındaki genlik dalgalanmasının oranı, iki dalga arasındaki farkın Hertz cinsinden gösterimidir. Bu fark 20 Hz sınırının üzerinde olması durumunda pürüzlülük oluşur (Plomp & Levelt, 1965).

MIR-toolbox aracılığıyla “*mirroughness*” komutu ile Parkinson hastası ve sağıklı bireylere ait ses örneklerinden pürüzlülük özneliğı hesaplanabilmektedir (Şekil 3.10).



Şekil 3.10: (a) Sağıklı ve (b) hasta bireylere ait pürüzlülük grafikleri

3.3.5.13 Düzensizlik (Irregularity)

Bir spektrumun düzensizliğı, ardışık tepe noktaları arasındaki değışim derecesi ile ifade edilir.

“*mirregularity*” komutuyla elde edilen sesin düzensizlik deęerleri sesin tımsal özelliğı olarak seslerin ayrımı konusunda bilgi vermektedir.

- Sağıklı kontrol grubu bireylerden çıkartılan örnek sonuç:

“*The Spectral irregularity related to file control_set_subject_1a1.wav is 1.4407*”

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“*The Spectral irregularity related to file test_set_subject_2a1.wav is 1.1241*”

3.3.6.Ton Grubu Özellikler

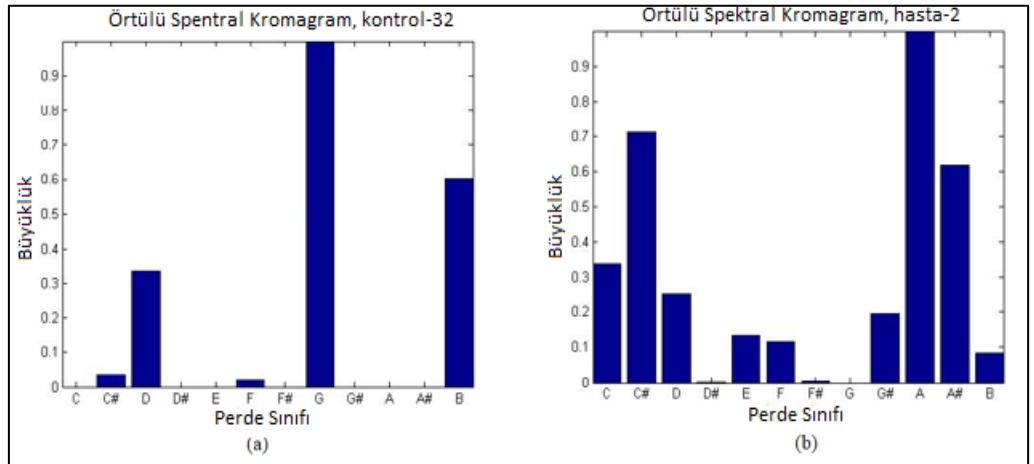
Ses tonu, gırtlakta bulunan havanın ses tellerini titretip ağız boşluğunda yankılanması sonucu oluşan parmak izi gibi kişiye özgü bir özelliktir. Konuşma sırasında sesin yükselip alçalması, azalıp çoğalması sırasındaki vurgulandırma ses tonu ile ilişkilidir. Ayrıca kişinin sosyal hayatında iletişimini etkileyen en önemli unsurlardan bir tanesidir. Kalın ses tonları majör ton olarak adlandırılırken ince ses tonları minör ton olarak tanımlanır.

3.3.6.1 Spektral / Örtülü Spektral Kromagram

Harmonik perde sınıfı profili olarak da adlandırılan kromagram, spektrum enerjisinin farklı perdeler boyunca yeniden dağıtılması yani spektral renk doygunluğu hakkında bilgi verir.

Örtülü spektral kromagram ise spektral enerjinin 12 perde sınıfına ayrılması ve her bir sınıftaki dağılımı hakkında bilgi vermektedir.


MIR-toolbox aracının ton öznitelikleri içinde bulunan “*mirchromagram*” komutu ile spektral kromagram hesaplanırken, “*mirchromagram* (*'dosya_adi'*, *'Wrap'*, *'yes'*)” ifadesi ile örtülü spektral kromagram hakkında bilgiler elde edilebilmektedir (Şekil 3.11).



Şekil 3.11: (a) Sağlıklı ve (b) hasta bireylere ait örtülü spektral kromagram grafikleri

3.3.6.2. Anahtar Kuvveti (Keystrength)

Anahtar kuvveti, benzer özellik gösteren olası adayların "mirchromagram" ile elde edilen örtünmüş ve normalleştirilmiş kromagram değerlerinin çapraz korelasyonu yoluyla belirlendiği -1 ve +1 arasında değişen değer ölçütüdür.



Şekil 3.12: (a) Sağlıklı ve (b) hasta bireylere ait anahtar kuvveti grafikleri

“*mirkeystrength*” ile elde edilen grafiklerdeki değerler bireylerin ses örneklerindeki tüm farklı tondaki adayların çapraz korelasyon skorunu göstermektedir (Şekil 3.12).

3.3.6.3. Anahtar (Key)

Müzikte notaların hangi tonda çalınacağı bilgisini veren kılavuzlara anahtar adı verilmektedir. Konuşmada ise seslerin doğru ve düzgün çıkartılmasına, sözlerin anlaşılır olmasına öncülük eden tonal merkez noktalarıdır.

“*mirkey*” fonksiyonu ile ses örneklerinden sesin anahtar özelliği temin edilebilmektedir.

- Sağlıklı kontrol grubu bireylerden çıkartılan örnek sonuç:

“*The Key related to file control_set_subject_1a1.wav is G maj*”

- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“*The Key related to file test_set_subject_2a1 is A maj*”

3.3.6.4. Mod

Bir grup sesin belirli oranlarla bir araya gelmesiyle oluşan, bazı seslerin etkisizleşip bazılarının ise anlam kazanmasıyla ortaya çıkan oluşum sesin modunu ifade etmektedir. Modal seslerde majör ve minör mod baz alınır. Sesin modları duyumsal olarak makamı andırır. “*mirmode*” ile elde edilen değerler -1 ile +1 arasındadır. Ses örneklerinden çıkarılan sonuçlar +1’e yakın değerler majör tonları,-1’e yakın değerler ise minör tonlardan oluşan sesi ifade eder.

“*mirmode* (*'dosya_adi'*, *'Best'*)” komutu ile elde edilen değerler hesaplanırken en iyi majör anahtar (en yüksek anahtar kuvveti değeri) ile en iyi minör anahtar (en düşük anahtar kuvveti değeri) arasındaki fark hesaplanır.

“*mirmode* (*'dosya_adi'*, *'Best'*)” komutu ile elde edilen değerler ise tüm majör anahtarlar ile onlara karşılık gelen tüm minör anahtarlar arasındaki farkların toplamını ifade eder.

- Sağlıklı kontrol grubu bireylerden çıkartılan örnek sonuç:

“*The Mode related to file control_set_subject_1a1.wav is 0.17659*”


- Parkinson hastası grubunda bulunan bireylerden çıkartılan örnek sonuç:

“*The Mode related to file test_set_subject_2a1 is 2.2959*”

3.3.6.5.Tonal Ağırlık Merkezi

Spectral kromagramdan 6 boyutlu tonal ağırlık merkezi vektörünü çıkartır (Harte, Sandler, & Gasser, 2006). Ses tonunun ayarı anlamına gelen akorların sinyaldeki yansıma değerlerini ifade eder.

“*mirtonalcentroid*” komutu ile ifade edilen Şekil 3.13’te gösterilen grafiklerde her sütun 6 boyutlu tonal ağırlık merkezi vektörünün her bir boyutundaki değerlerini göstermektedir.



Şekil 3.13: (a) Sağlıklı ve (b) hasta bireylere ait merkezi tonal ortalama grafikleri

3.4. Normalizasyon Yöntemleri

Veri kümesi oluşturma aşamasında veri tekrarını, veri kaybını veya veri yetersizliğini önlemek için verilerin düzenlenmesi gerekmektedir. Buradaki amaç, gereksiz veri tekrarının önlenerek verilerin bozulmasını önlemek, uygulanacak yöntem değişse bile oluşturulan veri kümesinin tutarlı bir şekilde çalışmasını sağlamak ve sistemin çalışma performansını arttırmaktır.

Bir başka deyişle, veriler arasında farklılığın çok fazla olduğu durumlarda verileri tek bir düzen içerisinde ele almaktır. Ayrıca farklı ölçekleme sisteminde bulunan verilerin birbiri ile karşılaştırılabilmesine olanak sağlar.

3.4.1. Min-Maks Normalleştirme

Min-maks yöntemi verileri doğrusal olarak normalize eder. Min değeri bir verinin alabileceği en düşük değeri, maks ise verinin alabileceği en yüksek değeri ifade eder. Bir veri kümesini genellikle 0-1 aralığına indirmek için kullanılan yöntemlerden birisidir.

$$yeni_{değer} = \frac{değer - min_{değer}}{maks_{değer} - min_{değer}} \quad (3.2)$$

Öznitelik çıkarımından sonra ilgili öznitelige ait deęerler 0-1 aralıęına çekilse de bazı durumlarda bu aralık deęerlerinin kullanılması yeterli olmayabilmektedir. Bu durumda ise aralık deęerleri formül revize edilerek istenilen sınırlarda kullanılabilir (Silahtaroglu, 2008).

$$yeni_deęer = \frac{deęer - min_deęer}{maks_deęer - min_deęer} (yeni_maks_deęer - yeni_min_deęer) + yeni_min_deęer \quad (3.3)$$

Yapılan deneysel çalışmalarda, öznitelik çıkarımı sonrası elde edilen deęerler göz önünde tutularak min-maks normalizasyon yönteminde [-1,+1] deęer aralıęı kullanılmıştır.

3.4.2. Sıfır Ortalama Normalleştirme

Sıkça kullanılan istatistiksel dönüşüm yöntemlerinden birisidir. Bu yöntemde veri ortalama deęeri ve standart sapma deęerleri göz önüne alarak yeni deęerlere dönüştüren bir normalleştirme yöntemidir (Özkan, 2008).

$$yeni_deęer = \frac{deęer - ortalama}{standart\ sapma} \quad (3.4)$$

Parkinson hastası ve sağlıklı bireylerden elde edilen ve müzikal öznitelikleri çıkartılan veri kümesine hangi normalizasyon yönteminin daha uygun olduęu sonuçlar ve bulgular kısmında tartışılmıştır.

3.5. Öznitelik Seçim Yöntemleri

Veri kümesinden çıkartılan özellik sayısı kimi durumlarda birkaç tane olabilirken, kimi durumlarda ise kullanılan verilerden bile daha fazla olabilmektedir. Kullanılan öznitelik sayısı işlem süresini ve sınıflandırma performansını etkileyen önemli unsurlardan birisidir. Öznitelik seçimi, bir problemin çözüm başarısını arttırabilmek için kullanılacak en az sayıdaki en belirleyici özniteliklerin seçim işlemidir. Tüm öznitelikleri kullanmak yerine sadece bazı yüksek seviyeli özniteliklerin kullanılması oluşturulan modelin daha kolay yorumlanmasına yardımcı olur. Gereksiz olan ve herhangi bir bilgi kazandırmayan özniteliklerin kaldırılmasıyla hem boyut hem

de yapılan işlem sayısı azalır. Böylece sınıflandırmayı olumsuz etkileyen özniteliklerden arınılır ve performansta artış sağlanabilir.

Literatürde öznitelik seçimi için uygulanan bir çok yöntem vardır. Filtre yöntemleri, özniteliklerin oluşturulan model için ne kadar yararlı olduklarına Ki-kare, Pearson korelasyonu, Spearman korelasyonu, ortak bilgi çıkarımı gibi öznitelikler arasındaki istatistiksel metod ve korelasyon sonuçlarının kullanılmasına göre sıralama yaparak öznitelik seçimi yapar (Budak, 2018). İkinci olarak, Sarıcı yöntemler, farklı öznitelik alt kümeleri üretir ve her bir alt küme daha sonra bir model oluşturmak ve algoritmayı eğitmek için kullanılır. Bu şekilde sınıflandırma algoritmasının tahmin oranını yükselten öznitelikler tutulurken diğerleri çıkartılır. Bu ekleme çıkartma bir arama algoritmasıyla birlikte gerçekleştirilir. En iyi öznitelik alt kümesi, algoritmayı test ederek seçilir. Alt kümelerin özelliklerini seçmek için İleri ve Geri seçim gibi farklı kriterler kullanılır. Son olarak Gömülü yöntemler, model oluşturulurken modelin doğruluğuna en iyi katkıda bulunacak özellikleri öğrenir. Gömülü özellik seçim yöntemlerinin en yaygın türü, düzenleme (regularizasyon) yöntemleridir. Düzenleme yöntemleri ayrıca, modeli daha az karmaşıklığa (daha az katsayı) doğru yönlendiren bir tahmin algoritmasının (bir regresyon algoritması gibi) optimizasyonuna ek kısıtlamalar getiren cezalandırma yöntemleri olarak adlandırılmaktadır.

3.5.1. En Küçük Mutlak Daralma ve Seçme Operatörü (LASSO)

Değişken seçimi regresyon analizindeki diğer önemli bir konudur. Gereksiz açıklayıcı değişkenlerin içerilmesi sonuç tahmin edicilerinin etkisini azaltabilir. Diğer taraftan bilgi kazancı yüksek, açıklayıcı bir değişkeninin çıkarılması yanlış parametre tahminlerini ve tahmin sonuçlarını olumsuz bir şekilde etkileyebilir.

Genel olarak doğrusal regresyon birden çok değişken içeren veri kümelerine uygulanır ancak bazı olumsuz durumlar gerçekleşebilir. Değişken sayısı arttıkça, modelin aşırı öğrenme (overfit) olasılığı artmaktadır. Ayrıca, elimizdeki sıfırdan farklı katsayı arttıkça, bunları açıklamak zorlaşmaktadır.

En Küçük Mutlak Daralma ve Seçme Operatörü (Least Absolute Shrinkage and Selection Operator - LASSO) regresyonu, ürettiği istatistiksel modelin tahmin

doğruluğunu ve yorumlanabilirliğini arttırmak için hem değişken seçimi hem de regülasyonu gerçekleştiren bir regresyon analiz yöntemidir. LASSO orijinal olarak en küçük kareler modelleri için formüle edilmiştir. LASSO regresyonu aynı zamanda standart doğrusal regresyon gibi katsayı kestirimlerinin eşdoğrusal olması durumunda, benzersiz olması gerekmediğini de ortaya koyar.

LASSO regresyonunun önemli bir karakteristiği, bilgi kazancı en az olan özniteliklerin ağırlıklarına sıfır atayarak onları öznitelik veri kümesinden elemektedir (Fonti & Belitser, 2017).

3.5.2. RELIEF

Kira ve arkadaşları tarafından geliştirilen RELIEF algoritması öznitelikleri aralarındaki ilişkiye göre ağırlıklandırılan bir öznitelik seçim yöntemidir (Kira & Rendell, 1992). Bu yöntem ikili sınıflandırma yapan veri setlerinde başarılı sonuçlar gösterir. Bu yöntemin ilk aşamasında tüm özniteliklerin ağırlıkları 0 olarak belirlenir. Daha sonra her bir adımda veri setinden rastgele bir veri seçilir ve bu veri ile aynı sınıfa sahip en yakın örnekteki ilgili öznitelik değeri ve farklı sınıfa sahip en yakın örnekteki ilgili öznitelik değeri belirlenir (Kaynar, Arslan, Görmez, & Işık, 2018).

RELIEF algoritmasının ana fikri, k en yakın komşu algoritmasının temel kuralına benzemektedir. Yani verilen bir mesafeye daha yakın uzaklıkların aynı sınıfa ait olmaları, çok daha olasıdır. İlgili öznitelik ve komşuları arasında uzaklık değerleri hesaplanarak özniteliklerin ağırlıkları belirlenir. Bahsedilen bu ağırlıklar Denklem 3.5'in n kez tekrarlanması yoluyla hesaplanır. Son aşamada belirlenen koşulu sağlamayan özellikler veri setinden atılarak yeni veri seti oluşturulur (Budak, 2018).

$$W_i = W_{i-1} - (x_i - nearHit_i)^2 + (x_i - nearMiss_i)^2 \quad (3.5)$$

Formüldeki W_i i özniteliğinin ağırlık derecesini, $nearHit_i$ aynı sınıfa ait en yakın örneğin öznitelik değerini ifade ederken $nearMiss_i$ ise farklı sınıfa ait en yakın örneğin öznitelik değerinin göstermektedir.

3.5.3. Minimum Artıklık Maksimum Bağlantı (mRmR)

Minimum artıklık maksimum bağlantı (Minimum Redundancy Maximum Relevance - mRmR) algoritması, bir yandan sınıf bilgileri ile ilgili en bağlantılı öznitelikleri seçerken bir yandan da öznitelikler arasındaki artıklığı minimize etmeye çalışan filtre yöntemlerinden birisidir (Ding & Peng, 2005). Ortak bilgi çıkarımı veya korelasyon tabanlı birçok istatistiksel yöntem algoritmaya uyarlanarak filtreleme kriteri olarak kullanılmaktadır. Algoritmada her öznitelik ayrık bir rastlantı değişkeni olarak kullanılır ve iki öznitelik (X ve Y) arasındaki benzerlik seviyesini ölçmek için aralarındaki ortak bilgiyi, $I(X, Y)$, Denklem 3.6 ile hesaplanır.

$$I(X, Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log\left(\frac{p(x, y)}{p_1(x)p_2(y)}\right) \quad (3.6)$$

Denklem 3.6'da $p(x, y)$; X ve Y özniteliklerinin birleşik olasılık dağılımı, X ve Y özniteliklerinin marjinal olasılık değerleri ise sırasıyla $p(x)$ ve $p(y)$ olarak gösterilmiştir (Gülgezen, Çataltepe, & Yu).

Ortak bilgi kavramı, sadece iki öznitelik arasındaki benzerlik düzeyini ölçmek için kullanılmaz. Aynı zamanda herhangi bir öznitelik ile sınıf bilgileri arasındaki benzerlik de hesaplanabilir .

mRmR algoritmasında belirlenecek olan öznitelik kümesinin en iyi küme olabilmesi için iki koşulu sağlaması gerekmektedir. Bunlardan birisi minimum artıklık diğeri ise maksimum bağlantı koşuludur. Algoritmanın ilk aşamasında maksimum bağlantıya göre ilk öznitelik belirlenir. Ardından her basamakta ortak bilgi farkını sağlayan öznitelik seçilir.

$$mRmR_{MI} = \max\left[I(X, H) - \frac{1}{|N|} \sum_{Y \in N} I(X, Y)\right] \quad (3.7)$$

Denklem 3.7'de $I(X, H)$, X özniteliğinin ilgili sınıf bilgisi ile olan bağlantısını, $|N|$ öznitelik kümesi eleman sayısını ifade eder.

Ortak bilgi temelli mRmR öznitelik seçim yöntemi daha çok geniş dağılımlı veri kümelerinde uygulanırken, korelasyon bazlı filtre seçenekleri doğrusal bağlılığı/ ilişkiyi ölçmek için daha uygundur (Ramezani vd., 2017).

$$mRmR_{corr} = |corr(X, H)| - \frac{1}{|N|} \sum_{Y \in N} |corr(X, Y)| \quad (3.8)$$

Korelasyon parametreleri olarak Pearson korelasyon katsayısının (Ramezani vd., 2017) veya Spearman korelasyon katsayısının (Tsanas, Little, McSharry, Spielman, & Ramig, 2012) kullanıldığı çalışmalar bulunmaktadır.

3.5.4. Ardışık İleri Yönde Seçim (Sequential Forward Feature Selection-SFS)

Ardışık ileri yönde seçim (SFS) yöntemi, eğitim için en uygun öznitelik setini bulmayı hedefleyen bir Whitney tarafından önerilen basit ve etkili bir öznitelik seçim yöntemidir (Whitney, 1971). Öznitelik seçme işlemi azdan çoğa doğru yapıldığı için ileriye doğru olarak adlandırılmıştır.

SFS algoritmasında ilk olarak boş bir öznitelik kümesi ile başlanır. İlk adımda tüm öznitelikler taranarak özniteliklere uygun bir başarı değeri bulunur. Her tekrarda daha önce eklenmemiş en iyi değere sahip bir öznitelik daha önce belirlenen öznitelikle birlikte bir alt küme oluşturur. Her bir özelliğin alt kümeye dahil edilip edilmemesinde sınıflandırma başarısına olan katkısı dikkate alınır. Bu işlem sınıflandırma oranında artış olmayana kadar devam eder.

3.5.5. Ardışık Geri Yönde Seçim (Sequential Backward Feature Selection-SBS)

Ardışık geri yönde öznitelik seçimi (SBS); SFS ile aynı amaç doğrultusunda kullanılan bir yöntemdir. SFS'den farklı olarak öznitelik eleme işlemi geriye doğru yani çoktan aza olacak şekilde yapılmaktadır. Yöntem ilk olarak Marill ve Green (Marill & Green, 1963) tarafından önerilmiştir.

SBS algoritmasında ilk olarak tüm özniteliklerin olduğu veri kümesi ile başlanır. Mevcut tüm özellikler içerisinde özellik sayısını azaltarak, sınıflandırma başarısını maksimize edecek şekilde en iyi özelliklere sahip alt kümeyi bulmayı amaçlamaktadır. Her adımda sınıflandırma başarısında artış olmayana dek katkısı olmayan bir tane öznitelik kümeden çıkartarak devam etmektedir.

3.5.6. Rastgele Orman (RF)

Rastgele orman (RF) birçok karar ağacından oluşan bir topluluk öğrenme algoritmasıdır. Bireysel olarak oluşturulan ağaçlar arasında oylama sonucuna göre kazanan sınıfı çıktı olarak veren bir makine öğrenmesi yöntemidir. Rastgele Orman, Leo Breiman ve Adele Cutler tarafından geliştirilmiştir (Breiman, 2001).

RF, birden fazla karar ağacı oluşturur ve daha doğru ve istikrarlı bir tahmin elde etmek için ağaçları birleştirir. En büyük avantajlarından birisi hem sınıflandırma hem de regresyon problemleri için kullanılabilmesidir.

RF yönteminde karar ağaçlarında da görülen dallanma kriterinin belirlenmesi ve budama işleminin yapılması için, sınıf özniteliklerinin zayıflık derecesini ölçmek amacıyla Gini indeksi yöntemi kullanılmaktadır. Algoritmada öncelikle ağaç yapısının oluşturulması için her düğümde kullanılacak veri sayısı ve oluşturulacak ağaç sayısının belirlenmesi gerekmektedir. K adet karar ağacından oluştuğu düşünülen karar ormanında veri kümesi bu K adet karar ağacından geçirilir ve K adet ağaçtan elde edilen K adet oy içerisinde en fazla oya sahip sınıfta karar verilir.

RF yönteminde, sınıf dağılımı göz önünde bulundurularak oluşturulan modeli test etmek için, orijinal veri setinin $2/3$ 'ü eğitim kümesi (inBag), $1/3$ 'ü ise test kümesi (Out-Of-Bag (OOB)) olarak ayrılır.

Karar ormanında, oluşturulacak karar ağacı sayısı kadar sayıda bootstrap tekniği ile örneklem oluşturulur. Her örneklem sayısı kadar inBag ve OOB verisi ayrılır. Kurulan her karar ağacı için ayrılan OOB verisi ile test yapılarak hata oranı tahmini yapılır ve bütün karar ağaçları için yapılan OOB hata oranlarının ortalaması alınarak, karar ormanının OOB hata oranı hesaplanır. Hata oranı sınıflandırma doğruluğunun anlaşılmasına yardımcı olur.

Karar ağacının oluşturulmasının ardından, test kümesindeki öznitelikler önceden kurulmuş ağaç üzerine yerleştirilir ve bu işlem tüm öznitelikler için uygulanır. Karar ağacı her özniteliği sınıflardan birine atar. Hesaplanan OOB hata oranına göre ağaçlara ağırlık derecesi verilir. Hata oranı yüksek olan ağaç yapısı düşük ağırlık derecesi alırken, hata oranı düşük ağaç yapısı en yüksek ağırlık derecesine sahiptir. Sınıflandırma

işlemi için tüm ağaçlara belirlenen ağırlık derecelerine göre oylama işlemi uygulanır. En çok oyu alan ağaç yapısındaki öznitelikler en değerli öznitelik olarak seçilir. Ayrıca tüm ağaç yapısında kullanılan veriler farklı olduğundan RF yönteminde aşırı öğrenme durumuna karşı güçlüdür.

3.6. Sınıflandırma Yöntemleri

Sınıflandırma temel olarak, sınıfı bilinmeyen bir verinin, o veriye ait tüm öznitelikleri kullanılarak bir model yardımıyla hangi sınıfa ait olduğunun belirlenmesidir. Örüntünün çeşidi, örüntüden elde edilen özniteliklerin yapısı ve sayısı, işlem süresi ve karmaşıklığı gibi faktörlere göre tercih edilmesi gereken sınıflandırma yöntemi probleme göre farklılık gösterebilir.

Bu tez çalışmasında yaygın olarak tercih edilen sınıflandırma algoritmaları k-En Yakın Komşu (k-EYK) ve Destek Vektör Makineleri (DVM) kullanılmıştır.

3.6.1 Destek Vektör Makinaları (DVM)

Destek Vektör Makineleri (DVM) ikili sınıflandırma için sıklıkla kullanılan bir yöntemdir. Bunun en önemli sebebi; temelde düşük boyutta lineer olarak ayıramayacak bir veri kümesini, daha yüksek boyuta taşıyarak bir düzlem yardımıyla ayırmayı sağlamasıdır.

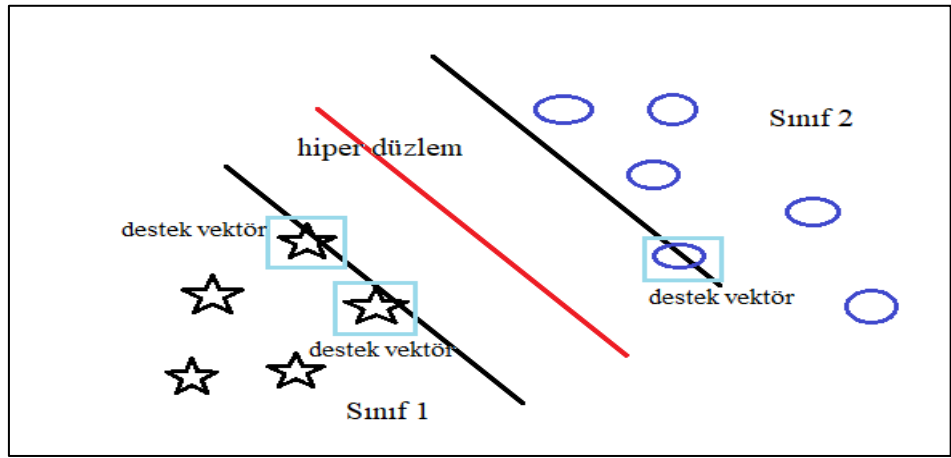
Hiper düzlem olarak kullanılan tanım iki sınıfı ayıran bir sınırı ifade eder. Veriyi en iyi şekilde birbirinden ayıran düzlemlerden hangisinin seçileceğini belirlerken iki hiper düzlem arasında en büyük boşluğa (uzaklığa) sahip olanları kullanmak en uygun yoldur.

Hiper düzlem sınırına yakın olan örnekler destek vektörler olarak nitelendirilir (Şekil 3.14). Vektörlerin sayısı sınıflandırma modelinin karmaşıklığı hakkında bilgi verir. En uygun hiper düzlemin belirlenmesi sınıflandırmanın performansını etkiler. Veri kümesindeki verilerin düzlemin doğru tarafında olmasının yanında düzleme belirli bir uzaklıkta bulunmaları gerekmektedir.

DVM algoritmasının başarılı olabilmesi için gereken önemli unsurlardan birisi çekirdek seçimi iken bir diğeri ise çekirdek genişliği (g) parametreleridir. Bu

parametrelerin doğru şekilde seçilmesi gerekir. Verilerin doğrusal ayrımı yerine daha üst boyutlarda ayrılması aşırı öğrenime neden olabilir. İstenmeyen bu olguyu maliyet parametresi (C) adı verilen, değeri arttıkça aşırı öğrenime neden olan kriter ile kontrol altına almak gerekir. Bu değer azaldıkça sınırlar daha basit hale gelir.

Sonuç olarak DVM algoritmasını bir veri kümesi üzerinde kullanmak için maliyet (C) parametresi, çekirdek türü, çekirdek genişliği (g) parametrelerinin belirlenmesi gereklidir. Bu parametrelerin değerleri probleme göre değişiklik gösterir ve genellikle deneysel çalışmalarda deneme yanılma yöntemi ile uygun değer belirlenir.



Şekil 3.14 DVM algoritmasının şekilsel gösterimi (Özkan, 2008) esinlenerek çizilmiştir.

3.6.2. k-En Yakın Komşu (k-EYK) Algoritması


Sınıflandırma yaparken mevcut verilerin birbirine olan uzaklık veya benzerlik prensibiyle sınıflandırma işlemini yapan k-en yakın komşu (k-EYK) algoritması, sınıflandırma yöntemleri arasında oldukça geniş bir kullanım yelpazesine sahiptir. Sınıfları belli olan bir örnek kümesindeki verilerden yararlanarak oluşturduğu modeli kullanarak test edilecek verinin hangi sınıfa ait olduğunu çeşitli parametrelerle belirler. Söz konusu yöntemde gözlem değerleri arasındaki uzaklıklardan yararlanılarak sınıflandırma işlemi yapılır (Silahtaroglu, 2008).

Uzaklık bağıntısından kasıt Öklid, Manhattan mesafeleri gibi bir uzaklık ölçütü ile uzaklığı belirlemektir. Sınıfı bilinmeyen test edilecek yeni verinin eğitim kümesi

üzerinde bulunan diğer verilerle olan uzaklığı farklı mesafe ölçütleri ile hesaplanarak, yeni gözlemin kendisine en yakın gözlem sınıfına aitliği belirlenir.

Öncelikle sınıflandırıcının ismindeki en yakın komşu sayısını belirten “k” değeri belirlenir. Bu değerin yüksek olması birbirine benzemeyen verilerin bir araya toplanmasına, ufak bir değer olması ise verilerin birbirine benzese de aynı sınıfta olamamasına neden olur. “k” değeri genellikle 3, 5 ve 7 olarak seçilir. Burada tek sayıda komşu örnek seçilmesinin sebebi test edilecek yeni verinin sınıf bilgisi var olan örneklere göre çoğunluk seçimiyle belirlenmesidir (Özkan, 2008).

En yakın komşu sayısının belirlenmesinden sonra, verilen nokta ile gözlemlenen tüm veriler arası mesafe hesaplanır ve bunlar arasından en küçük değerde olan “k” tanesi seçilir. Seçilen verilerin sınıf değerlerine bakıldığında en fazla hangi sınıf değeri tekrarlanıyor ise test edilen veri o sınıfa atanır (Şekil 3.15). Yöntemin optimisasyonu için çeşitli çapraz doğrulama yöntemleri kullanılabilir.



Şekil 3.15 : k-EYK ile sınıfı bilinmeyen verinin sınıflandırılması (Özkan, 2008) esinlenerek çizilmiştir.

3.7. Çapraz Doğrulama Yöntemleri

Makine öğreniminde uygun metodlar kullanılarak büyük veri kümelerine uygun modeller geliştirilebilmektedir. Ancak sınırlı sayıda veriden oluşan bir veri kümesi ile çalışılıyor ise, sistemi eğitirken kullanılan verileri test amacıyla kullanmak sistemde aşırı öğrenmeye sebep olabilir. Eğitim veri kümesinin yeterli büyüklükte olmadığı

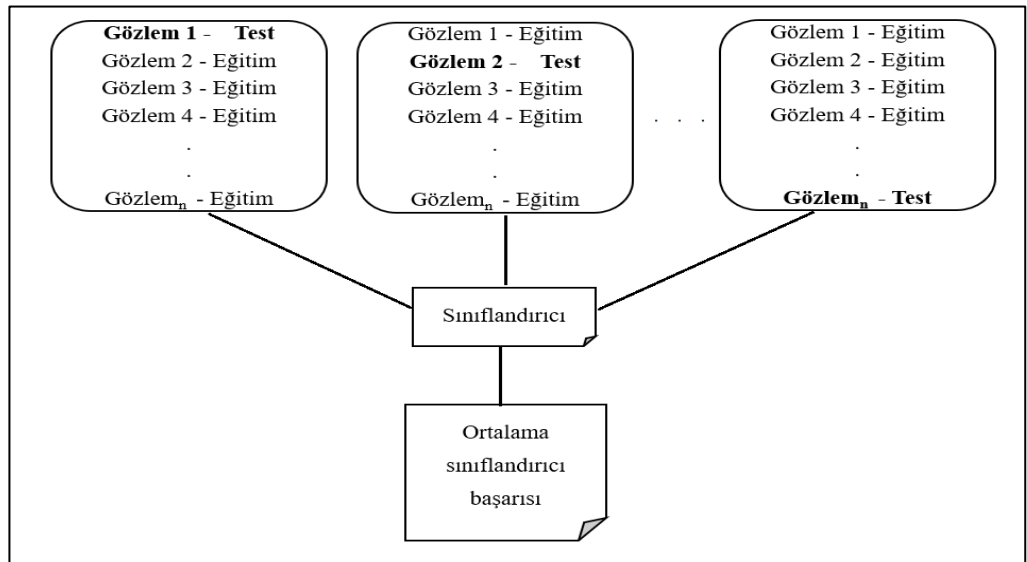
koşullarda bu sorunla karşılaşılabilir. Bu durumdan kaçınmak için verileri belli yöntemlerle alt kümelere ayırmak gereklidir.

Modelin doğruluğunu test etmek amacıyla kullanılan çapraz doğrulama yönteminde veri başlangıçta test ve eğitim verisi olarak ayrılır. Eğitim verisi, modelin kurulumu (eğitimi) aşamasında kullanılır iken test verisi modelin doğruluğunu eğitim verisiyle oluşturulan model üzerinde test eder.

Sınırlı sayıda veriden oluşan veri kümelerinde, verilerin eğitim ve test biçiminde bölünmesini sağlamak amacıyla bazı yöntemler kullanılır.

3.7.1. Birini Dışarda Bırakma (BDB) Çapraz Doğrulama

Veri kümesinin küçük olduğu durumlarda sıklıkla kullanılan bir yöntemdir. Bu yöntemde veri kümesindeki gözlemlerden bir tanesi test amacıyla dışarda tutularak ayrılır ve geri kalan veriler eğitim kümesini oluşturur. Oluşturulan model test verisi olarak ayrılan veri ile test edilerek doğruluk değeri elde edilir. Bu işlem sırasıyla veri kümesindeki bütün gözlemler için uygulanır (Şekil 3.16). Her gözlem verisi için elde edilen doğruluk değerlerinin ortalaması alınarak kullanılan sınıflandırma yönteminin doğruluk performansı oluşturulur.



Şekil 3.16: Birini dışarda bırakma (BDB) çapraz doğrulama yöntemi (Özkan, 2008) esinlenerek çizilmiştir.

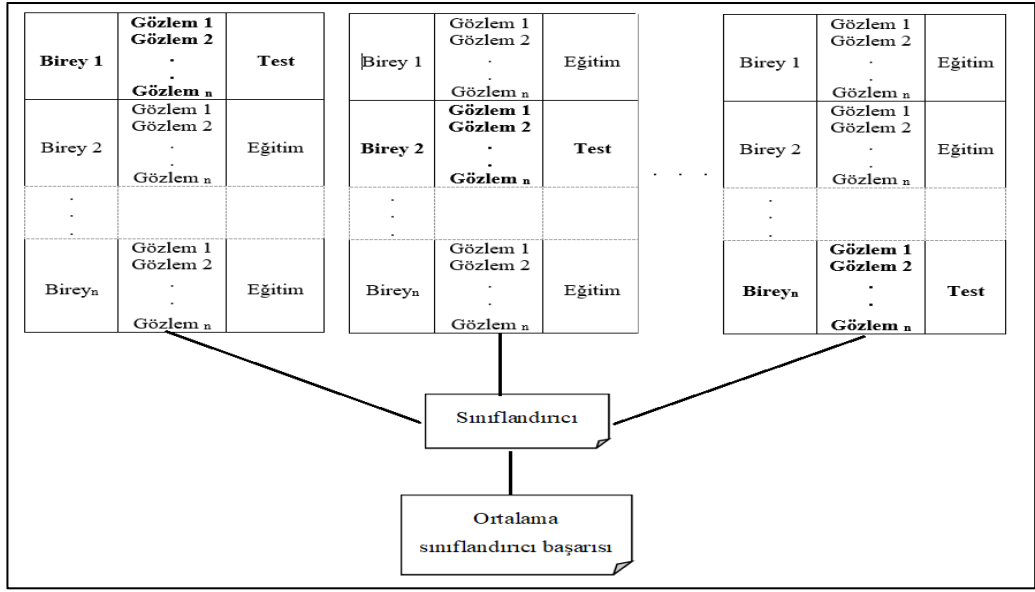
3.7.2. Bir Bireyi Dışarda Bırakma (BBDB) Çapraz Doğrulama

Bir kişiye ait birden fazla örnek verinin rahatlıkla elde edilebildiği biyomedikal alan, veri madenciliği ve makine öğrenimi uygulamalarının rahatlıkla kullanıldığı bir alandır. Bir kişiye ait birden fazla örnek içeren veri kümelerinin kullanıldığı uygulamalarda aşırı öğrenimi engellemek için birini dışarda bırakma (leave one subject out) çapraz doğrulama yönteminin yerine bir bireyi dışarda bırakma (leave one subject out) çapraz doğrulama yönteminin kullanılması bireyden bağımsız bir sınıflandırma yapılmasını sağlar.

Literatürde, ses ve konuşma sorunları yaşayan Parkinson hastaları ile yapılan önceki çalışmalarda kullanılan çapraz doğrulama yöntemlerinde bireye ait verilerin hem eğitim kümesi hem de test kümesi içerisinde bulunması sınıflandırmanın yanlı/tafıflı gerçekleşmesine neden olur. Bu tafıflılıđı önlemek, daha doğru sınıflandırma başarısı elde edebilmek için kişiden bağımsız sınıflandırma tafıflı sınıflandırma performansı sergileyen çalışma yapılmasına ihtiyaç duyulmaktadır (Vaicukynas, Verikas, Gelzinis, & Bacauskiene, 2017).

Bu yöntemde, her adımda bir bireye ait tüm gözlemler test kümesi olarak ayrılır, böylece eğitim kümesinde o bireye ait hiçbir gözlem bulunmaz. Bu sayede, benzer gözlemlerin bulunduğu eğitim kümesiyle oluşturulan modellerdeki yanıtıcı sınıflandırma ortadan kalmış olur. Veri kümesindeki diğer biretlere ait örnekler eğitim kümesi olarak kullanılır ve model eğitilir.

BBDB çapraz doğrulama yönteminde bireye ait verilerin çoğunda bireyi hasta olarak betimlendirilmişse birey hasta, aksi durumda ise sağlıklı olarak sınıflandırılır. Yöntemin genel doğruluk performansı her gözlemin doğru sınıflandırma başarısının ortalaması ile belirlenir. Şekil 3.17'de yöntemin şekilsel gösterimi verilmiştir.



Şekil 3.17: Bir bireyi dışarda bırakma çapraz doğrulama yöntemi (Özkan, 2008) esinlenerek çizilmiştir.

3.8. Değerlendirme Ölçütleri

Makine öğreniminde bir sınıflandırıcının başarısını ölçmek için pek çok farklı yöntem kullanılabilir. Değerlendirme ölçütü olarak kullanılan yöntemlerin temelinde pozitif ve negatif sınıflara ya da bu çalışmada olduğu gibi hasta ve sağlıklı gruplara ait örneklerin ne kadarının doğru ya da yanlış sınıflarda tahmin edilmesi yatmaktadır. Pozitif sınıfa ait bir örnek sınıflandırıcı tarafından da pozitif olarak tahmin edilmişse bu örneğe gerçek pozitif (GP), negatif olarak tahmin edilmişse yanlış pozitif (YP) olarak nitelendirilir. Ters durumlarında negatif sınıfa ait bir örnek sınıflandırıcı tarafından da negatif olarak edilmişse bu örneğe gerçek negatif (GN), pozitif olarak tahmin edilmişse yanlış negatif (YN) olarak nitelendirilir.

Çizelge 3.4. Sınıflandırıcı tahminine göre karmaşıklık matrisi

GERÇEK	TAHMİN		
		Pozitif	Negatif
	Pozitif	Gerçek Pozitif (GP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Gerçek Negatif (GN)

Çizelge 3.4'de bu değerler bir hata matrisi içinde verilmiştir. Bu tablodaki değerlerin toplamı veri kümesindeki örnek sayısını verir. Bu tablodan elde edilebilecek değerlendirme parametrelerinden bazıları doğruluk, kesinlik, hassasiyet, f-ölçütü ve Matthews korelasyon katsayısı ölçütleridir.

3.8.1. Doğruluk

İkili bir sınıflandırma sonrasında elde edilen doğru sınıflandırılmış örnek sayısının tüm veri kümesi eleman sayısına oranıdır. Bu tez çalışmasında kullanılan veri kümesi üzerinde bu ölçüt Parkinson hastası ve sağlıklı birey sayısının ne kadarının doğru sınıflarda tahmin edilebildiğini göstermektedir.

$$\text{Doğruluk} = \frac{GP+GN}{GP+YN+YP+GN} \quad (3.9)$$

3.8.2. Duyarlılık

Doğru sınıflandırılmış pozitif örneklerin istatistiksel gösterimidir. Tez çalışmasında kullanılan veri kümesinden doğru tahmin edilen hasta sayısının toplam hasta sayısına oranını ifade eder.

$$\text{Duyarlılık} = \frac{GP}{GP+YN} \quad (3.10)$$

3.8.3. Kesinlik

Doğru sınıflandırılmış negatif örneklerin istatistiksel gösterimidir. Tez çalışması kapsamında oluşturulan veri kümesinde bu ölçüt, hasta olarak tahmin edilen bireylerden kaç tanesinin gerçekten Parkinson hastası olarak sınıflandırıldığını gösterir.

$$\text{Kesinlik} = \frac{GP}{GP+YP} \quad (3.11)$$

3.8.4. F-ölçütü

F-ölçütü veya harmonik ortalama test edilen verilerin doğruluğunun ölçümüdür. Sınıflandırma sonrasında oluşan hata matrisinden elde edilen kesinlik ve duyarlılık ölçütleri tek başlarına anlamlı bir karşılaştırma sonucu çıkarılması için yeterli değildir. Her iki ölçütü beraber değerlendirmek daha doğru sonuçlar verir. F-ölçütü hesaplanırken kesinlik ve duyarlılığın harmonik ortalaması alınır.

$$F_ölçütü = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (3.12)$$

3.8.5. Matthews Korelasyon Katsayısı (MKK)

Matthews Korelasyon Katsayısı (MKK) makine öğreniminde yapılan sınıflandırma tahmininin kalitesini gösteren bir parametredir. Analiz edilen veri kümesi eleman sayısında dengesizlik olduğu durumlarda dahi, sınıflandırma işleminin rastgele yapılıp yapılmadığı hakkında sınıflandırmalar arasındaki korelasyon bilgisini veren bir ölçüttür. [-1, +1] arasında bir değer alır. Sınıflandırmanın doğruluğu arttıkça +1 değerine yakın, yanlış sınıflandırma ise sonucun -1 değerine yakın olması beklenir. Sınıflandırmanın rastgele yapıldığı durumlarda ise bu katsayı değeri 0 değeri civarındadır.

$$MKK = \frac{(GP \times GN) - (YN \times YP)}{\sqrt{(GP + YN)(GP + YP)(GN + YN)(GN + YP)}} \quad (3.13)$$

BÖLÜM 4

DENEYSEL SONUÇLAR

Bu tez kapsamında yapılan çalışmalarda amaç, hasta ve sağlıklı bireylerden elde edilen ses kayıtlarından sesin müzikal bilgileri yardımıyla ses bozukluklarını belirleyip, Parkinson hastalarını sağlıklı bireylerden ayırmaktır. Bu sebeple, farklı ses örneklerinden müzikal öznitelikler çıkartılmış ve farklı sınıflandırıcılara çeşitli çapraz doğrulama yöntemleri kullanarak elde edilen özniteliklerin Parkinson hastalığının teşhisindeki başarısı incelenmiştir. Ayrıca farklı öznitelik seçme algoritmaları kullanılarak en belirleyici öznitelikler seçilmiş ve bu algoritmaların sınıflandırma başarı performansları karşılaştırılmıştır.

Tez çalışması boyunca verilerin işlenmesi, özniteliklerin çıkartılması ve hastalığın belirlenmesinde en değerli bilgileri sunan özniteliklerin seçilmesi, sonrasında sınıflandırılması işlemleri Matlab yazılım platformunda yapılmıştır.

4.1. Normalizasyon Yöntemlerinin Etkinliği

Çalışma kapsamında ilk aşamada 28 Parkinson hastası bireyden (B. E. Sakar vd., 2013) üç kez tekrarlanarak alınan uzatılmış /a/ ve /o/ sesleri ile 62 sağlıklı bireyden (Barry & Pützer, 2007) toplanmış tekrar edilmemiş /a/ ve /o/ seslerinden deneysel çalışma için bir veri havuzu oluşturulmuştur. Hasta ve sağlıklı bireylerden elde edilen ham ses örnekleri, kayıt sırasında oluşan ara seslerin ve kayıt tekrarları arasındaki sessiz geçen kısımların çıkartılmasıyla gürültüden arındırılmıştır. Ardından sinyal işleme ve analizinde yaygın olarak kullanılan Matlab yazılımında MIR-toolbox öznitelik çıkarım komutları her bir ses örneğine uygulanarak müzikal öznitelikler belirlenmiştir.

Öznitelik çıkarımının ardından, elde edilen tüm öznitelikler grup ayrımı yapılmaksızın *k*-En Yakın Komşu (*k*-EYK) ve Destek Vektör Makineleri (DVM)

sınıflandırıcılarına eğitim kümesi olarak verilmeden önce farklı değer aralıklarında bulunan verilerin dönüştürülmesi gerekmektedir. Bu amaçla, elde edilen öznitelik değerlerine göre hangi normalizasyon yönteminin daha uygun olduğunu belirlemek için verilere $[-1,+1]$ değer aralığındaki min-maks normalleştirme ve sıfır ortalama normalleştirme yöntemleri ayrı ayrı uygulanmıştır. Sınıflandırıcılardaki doğruluk performans sonuçları Çizelge 4.1’de gösterilmiştir. Birini-dışarda bırakma (BDB) çapraz doğrulama yöntemi uygulanan veri kümesinde k-EYK algoritmasında uzaklık metriği olarak Manhattan mesafesi kullanılmış ve k parametresinin değeri 3 olarak belirlenmiştir. DVM için ise LibSVM (Chang & Lin, 2011) gerçekleştirilmesi kullanılmış, dairesel çekirdek tipi ve çekirdeğe ait maliyet değeri 1000, gamma değeri 0,1 olarak seçilmiştir.

Çizelge 4.1 Çeşitli normalleştirme uygulamalarının farklı sınıflandırıcılardaki doğruluk performansı

Sınıflandırıcı	Normalleştirme Tekniği (%)		
	<i>Min-Maks (-1 +1)</i>	<i>Sfır Ortalama</i>	<i>Normalleştirmesiz</i>
k-EYK	82,13	79,69	68,39
DVM	86,24	80,50	57,14

Hasta ve sağlıklı bireylerden alınan ses örneklerinden çıkartılan öznitelikler değerlerine ilk başta hiçbir normalleştirme işlemi uygulanmadan k-EYK ve DVM sınıflandırıcılara beslenerek sırasıyla %68,39 ve %57,14 doğruluk değerleri elde edilmiştir. Sınıflandırıcıların performanslarını arttırabilmek adına veri madenciliği alanında yaygın kullanılan veri dönüştürme işlemlerinden min-maks normalleştirme ve sıfır ortalama normalleştirme işlemleri uygulandı. Sonuç olarak $[-1 +1]$ değerler arasındaki min-maks normalleştirme yöntemi k-EYK ve DVM sınıflandırma yöntemlerinde sırasıyla %82,13 ve %86,24 doğru sınıflandırma ile sıfır ortalama yönteminden daha iyi sonuç vermiştir.

4.2. Çapraz Doğrulama Yöntemlerinin Kıyaslanması

Normalleştirme yönteminin belirlenmesinin ardından, Parkinson hastası ve sağlıklı bireylerden elde edilen verilerle oluşturulacak olan modelin aşırı uyumluluk

göstermesini engellemek için çapraz doğrulama yöntemlerinin kullanılması gerekmektedir. Örnekleme sayısının az olduğu veri kümelerinde aşırı öğrenme durumunu engellemek için kullanılan birini-dışarda-bırakma (BDB) ve bir-bireyi-dışarda-bırakma (BBDB) çapraz doğrulama yöntemleri müzikal özniteliklerden oluşan veri kümesine uygulanmıştır.

BDB çapraz doğrulama yöntemi ile her bireye ait sadece bir ses örneğinin test verisi olarak ayrılıp, geri kalan örneklerin modelin eğitilmesinde kullanılmasıyla oluşan sistemin k-EYK ve DVM ile Parkinson hastalarıyla kontrol grubunu ayırma başarısı ölçülmüştür.

Biyomedikal alanında kullanılan veri kümelerinde aynı katılımcıya ait birden fazla veri örneği bulunabilir. Bu veri kümelerinde, eğer bireye ait tüm veriler sınıflandırmada kullanılacaksa, birini dışarda bırakma (BDB) yerine bir-bireyi-dışarıda-bırakma (BBDB) çapraz doğrulama yönteminin kullanılması daha doğrudur. Çünkü BDB çapraz doğrulama yönteminde bireylere ait örnekler tek tek sınanırken eğitim kümesinde de test kümesinde verisi bulunan bireye ait diğer verilerde bulunabilmektedir. Dolayısıyla bu yöntemle daha yüksek sınıflandırma yüzdesi elde edilebilmektedir. BBDB metodunda her adımda bir bireye ait bütün veriler test verisi olarak ayrılır, dolayısıyla eğitim kümesinde bu bireye ait tek bir örnek bile yer almaz ve daha tarafsız sonuçlar elde edilir.

Deneysel çalışmaların bu aşamasında müzikal özniteliklerle, 111 özniteliği ayrı ayrı değerlendirilmektense ton, tını, ritim, perde ve dinamik olmak üzere beş temel gruba ayrılmıştır. Öznitelik gruplarının BDB ve BBDB doğrulama yöntemleri uygulanarak sınıflandırıcılardan elde ettikleri başarı performansları k-EYK için Çizelge 4.2’de, DVM için Çizelge 4.3’te gösterilmiştir.

Çizelge 4.2 ve 4.3’ün de belirttiği gibi BBDB değerleri BDB değerlerinden daha düşüktür. Ancak, BBDB doğrulama yöntemi veri kümesinin ayrımı sırasında bireye ait tüm verileri test kümesi olarak ayırdığı için daha adil bir kıyaslama yapar. Çizelgelerin geneline bakıldığında zaman hem BDB modelinde hem de BBDB modelinde her iki sınıflandırıcı için ritim öznitelikleri daha yüksek performans sergilerken, perde grubu özniteliği her iki yöntemde de düşük performansa sahiptir.

Çizelge 4.2: k-EYK sınıflandırıcı için BDB ve BBDB çapraz doğrulama yöntemlerinin doğruluk sonuçları

Öznitelik Grubu	Çapraz Doğrulama Yöntem Doğruluğu (%)	
	BDB	BBDB
TON	95,33	89,28
TINI	96,29	93,68
RİTİM	97,33	96,42
PERDE	68,66	61,51
DİNAMİK	94,20	87,50

Çizelge 4.3: DVM sınıflandırıcı için BDB ve BBDB çapraz doğrulama yöntemlerinin doğruluk sonuçları

Öznitelik Grubu	Çapraz Doğrulama Yöntem Doğruluğu (%)	
	BDB	BBDB
TON	98,21	93,81
TINI	96,42	94,49
RİTİM	98,66	97,59
PERDE	58,66	62,90
DİNAMİK	95,33	93,30

k-EYK algoritması ile sınıflandırmada, BDB ile %95,33, BBDB ile %96,42 doğru sınıflandırma başarısına sahip olan ritim özneliğini farklı iki çapraz doğrulama yöntemlerinde sırası ile %96,29 ve %93,68 doğruluk yüzdeleriyle tını özelliği takip etmektedir. Parkinson hastalığının en farkedilir özneliklerinden olan ton değişimi ise sırasıyla %95,33 ve %89,28 doğruluk sonuçları ile her iki doğrulama yönteminde en başarılı üçüncü öznelik grubu olmuştur.

DVM sınıflandırma yönteminde ise, hem BDB hem de BBDB yöntemlerinde sırasıyla %98,66 ve %97,59 doğru sınıflandırma değerleri ile en başarılı grup ritim grubu öznelikleridir. Ritim grubunu BDB şemasında sırasıyla %98,21 ve %96,42 değerleri ile ton ve tını grupları takip etmektedir. BBDB yönteminde ise bu sıra %94,49 ve %93,81 sonuçları ile tını ve ton şeklindedir.

Parkinson hastalığında dopamin eksikliğine bağlı kas kontrol sisteminin etkilenmesi sonucu hasta bir dizi problemle karşı karşıya kalır. Hastalarda mimik, ağız ve dil kaslarının etkilenmesiyle seslerin doğru çıkartılamaması, nefes alma kapasitesinin azalması ve bilişsel kayıplar sonucu yaşanan duraksamalar seslerin ve kelimelerin çıkarım süresini etkilemektedir. Ayrıca boğaz ve yutak kaslarının hareket azlığına bağlı olarak yaşanan tükürük birikimiyle hastalarda ses çıkarımı ve konuşma ritminde bozulmalar görülmektedir. Bu sebeple ritmik özelliklerin hasta ve sağlıklı bireylerin ayırımında daha belirleyici olduğu elde edilen sonuçlarla da gözlemlenmiştir.

4.3. Sınıflandırma Yöntemlerinin Kıyaslanması

Özniteliklerin ana gruplar halinde kullanıldığı sınıflandırma yöntemlerinin başarılarının karşılaştırıldığı bu bölümde k-EYK algoritmasında uzaklık metriği olarak Manhattan mesafesi kullanılmış ve k parametresinin değeri 3 olarak belirlenmiştir. DVM için ise LibSVM (Chang & Lin, 2011) gerçekleştirilmesi kullanılmış, dairesel çekirdek tipi ve çekirdeğe ait maliyet değeri 1000, gamma değeri 0.1 olarak seçilmiştir. Uygulanan her iki sınıflandırma algoritmasında $[-1,+1]$ min-maks normalizasyon yöntemi kullanılmıştır.

Çizelge 4.4, ve Çizelge 4.5 sırasıyla BDB ve BBDB doğrulama şemaları uygulanan verilerde makine öğreniminde sıkça kullanılan iki sınıflandırma algoritmasının doğruluk, F ölçütü ve Matthews korelasyon katsayı değerlerinden oluşan başarı performanslarını göstermektedir. Perde grubu dışında diğer öznitelik gruplarında DVM, k-EYK sınıflandırma yöntemine göre daha yüksek performans sergilemiştir.

Sınıflandırma kalitesini belirten ölçütlerden birisi olan Matthews korelasyon katsayı değerinin sistemin başarısı arttıkça +1 değerine yakın olması beklenir. Hem Çizelge 4.4'te hem de Çizelge 4.5'te ifade edildiği üzere her iki sınıflandırıcıda da en düşük MKK katsayısı değeri elde eden öznitelik grubu perde grubu iken en yüksek performans sırasıyla 0,930 ve 0,947 değerleri ile ritim grubudur.

Çizelge 4.4: BDB çapraz doğrulama yöntemlerinin farklı sınıflandırma uygulamalarında doğruluk, f ölçütü ve MKK sonuçları

Öznitelik Grubu	Sınıflandırma Performansı					
	k-EYK			DVM		
	<i>Doğruluk (%)</i>	<i>MKK</i>	<i>F-ölçütü</i>	<i>Doğruluk (%)</i>	<i>MKK</i>	<i>F-ölçütü</i>
TON	95,33	0,930	0,945	98,21	0,937	0,981
TINI	96,29	0,917	0,961	96,42	0,925	0,961
RİTİM	97,33	0,926	0,972	98,66	0,964	0,988
PERDE	68,66	0,494	0,564	58,66	0,173	0,303
DİNAMİK	94,20	0,866	0,923	95,33	0,898	0,944

Sınıflandırma başarısının istatistiksel yöntemlerle ölçüldüğü F-ölçütünde ise sınıflandırmanın başarılı olarak adledilebilmesi için elde edilen sonucun +1'e yakın olması gereklidir. BDB çapraz doğrulama şeması kullanılarak eğitilen veri kümesinde (Çizelge 4.4) hem k-EYK hem de DVM sınıflandırıcılarda düşük performans sergileyen perde özneliği haricinde tüm öznitelik gruplarında en düşük 0,923 ile en yüksek 0,988 değerleri arasında sınıflandırma başarısı gözlenmiştir.

Çizelge 4.5: BBDB çapraz doğrulama yöntemlerinin farklı sınıflandırma uygulamalarında doğruluk, f ölçütü ve MKK sonuçları

Öznitelik Grubu	Sınıflandırma Performansı					
	k-EYK			DVM		
	<i>Doğruluk (%)</i>	<i>MKK</i>	<i>F-ölçütü</i>	<i>Doğruluk (%)</i>	<i>MKK</i>	<i>F-ölçütü</i>
TON	89,28	0,776	0,836	93,81	0,869	0,946
TINI	93,68	0,869	0,948	94,49	0,848	0,948
RİTİM	96,42	0,930	0,963	97,59	0,947	0,968
PERDE	61,51	0,311	0,564	62,90	0,256	0,629
DİNAMİK	87,50	0,742	0,800	93,30	0,814	0,924

BBDB ile eğitilen veri kümesinde ise (Çizelge 4.5) hem k-EYK hem de DVM sınıflandırıcılarda düşük performans sergileyerek sırasıyla 0,564 ve 0,629 sonuçlarını elde eden perde özniteliği haricinde diğer öznitelik gruplarında en düşük 0,800 ile en yüksek 0,968 değerleri arasında sınıflandırma başarısı gözlenmiştir.

BBDB ile eğitim modelinin BDB uygulamasına göre her iki sınıflandırma yönteminde de daha düşük doğruluk oranına sahip olmasına rağmen BBDB çapraz doğrulama yönteminin kişiden bağımsız ve tarafsız bir sınıflandırma performansı sunmasından dolayı makine öğreniminin bir sonraki adımı olan öznitelik seçimlerinin değerlendirilmesinde BBDB çapraz doğrulama yöntemi sonuçlarının incelenmesine karar verilmiştir.

4.4. Öznitelik Seçme Algoritmalarının Uygulanması

MIR-toolbox aracılığı ile çıkartılan öznitelikler (111 tane öznitelik) uygun normalleştirme, çapraz doğrulama yöntemlerinin belirlenmesinde ton, tını, ritim, perde ve dinamik temel öznitelik grupları altında işlem yapılarak, ilgili alanda sıklıkla kullanılan sınıflandırma algoritmaları ile öznitelik gruplarının hastalığın ayırımıdaki sınıflandırma başarıları incelenmiştir.

Öznitelik sayısı boyutu, işlem süresini ve sınıflandırma performansını etkileyen önemli unsurlardan birisidir. MIR-toobox ile çıkarılmış 111 özniteliğin tümünü kullanmak yerine sadece bazı yüksek seviyeli özniteliklerin kullanılması hem yapılan işlem sayısını azaltabilir hem de sınıflandırmaya olumsuz etki eden öznitelikleri eleyerek performans başarısını arttırabilir.


Yapılan bu tez çalışması kapsamında farklı öznitelik belirleme kriterlerine sahip çeşitli öznitelik seçme algoritmaları MIR-toolbox ile elde edilen Parkinson hastası ve sağlıklı birey verilerine uygulanmıştır. Belirlenen en iyi özniteliklerin hastalığın teşhisindeki bireysel katkı ve başarıları k-EYK ve DVM sınıflandırma algoritmalarında sergiledikleri performanslarla ölçülmüştür. Kullanılan tüm öznitelik seçme algoritmalarının belirlediği bilgi kazancının yüksek olduğu ilk 20 öznitelik Çizelge 4.6'de verilmiştir.

Çizelge 4.6: Farklı öznitelik seçim algoritmaları ile belirlenen ilk 20 öznitelik

#	LASSO	RELIEF	SBS	SFS	mRmR _{SP}	mRmR _{PR}	mRmR _{MI}	RF
1	15	34	11	34	34	34	1	59
2	34	11	15	4	57	15	73	61
3	36	35	34	1	59	57	72	57
4	51	36	36	27	61	11	103	58
5	4	51	45	8	60	59	65	15
6	11	15	51	9	15	51	67	30
7	57	57	52	65	36	36	74	76
8	35	1	53	2	58	28	58	74
9	27	60	55	43	30	26	20	36
10	104	59	59	31	11	18	2	34
11	77	20	64	56	51	35	33	29
12	18	55	77	73	18	17	31	18
13	69	7	86	74	26	13	19	11
14	20	62	95	26	17	10	32	26
15	32	43	102	12	1	60	35	28
16	76	5	108	13	35	24	28	20
17	50	63	110	5	28	23	30	35
18	108	40	28	6	13	19	18	51
19	103	53	20	10	24	27	108	13
20	37	30	67	15	29	21	26	31

4.4.1. En Küçük Mutlak Daralma Ve Seçme Operatörü (LASSO) ile Öznitelik Seçimi

MIR-toolbox ile çıkartılan öznitelikler lojistik mantıkla ikili sınıflandırma yaparak veri ilgi derecesi yüksek öznitelikleri doğru, ilgisiz olan öznitelikleri ise yanlış olarak gruplandırır. 111 öznitelik içerisinde LASSO ile belirlenen en iyi 20 öznitelik Çizelge 4.6’de verilmiştir. Atım spektumu (15), sıfır geçiş (34), roll-off 95 (36), MFCC-8 (51) bilgi kazancı en yüksek öznitelikler olarak belirlenmiştir. Doğrusal regresyona dayalı bu yöntemde hesaplanan ortalama kare hata (MSE) Şekil 4.1 de gösterilmiştir.




Şekil 4.1: Çapraz doğrulamalı LASSO ile MSE değerleri

Şekil 4.1’de MSE değeri 0,041574 olarak hesaplanmıştır. Sistemin etkinliği için MSE değerinin sıfıra yakın olması beklenir. Ayrıca farklı lambda değerleriyle farklı öznitelik alt kümeleriyle 100 farklı model kurarak sonuca ulaşan LASSO algoritmasında müzikal özniteliklerle 14. model de en düşük MSE değerine ulaşılmıştır.

4.4.2. RELIEF algoritması ile Öznitelik Seçimi

k-EYK sınıflandırma algoritması prensibine sahip RELIEF algoritmasında, yüksek değeriğe sahip özniteliklere uzaklık Öklid mesafe ölçüm parametresiyle hesaplanan değerler, özniteliklerin ağırlıkları olarak atanır (Şekil 4.2). En düşük performans gösteren özniteliklere sıfır atanarak öznitelik veri kümesinden çıkartılır. Belirlenen öznitelik gücü en yüksek 20 öznitelik Çizelge 4.7’de verilmiştir. RELIEF algoritması sonucu sıfır geçiş (34), atım spektrumu (11), roll-off 85 (35), roll-off (36), MFCC-8 (51) öznitelikleri en hastalık ayırımı için en belirleyici öznitelik olarak seçilmiştir.



Şekil 4.2. Özniteliklerin RELIEF ile elde edilen ağırlık değerleri

4.4.3. Minimum Artıklık Maksimum Bağlantı (mRmR) ile Öznitelik Çıkarımı

Parkinson hastası ve sağlıklı bireylerin ayırımında en belirleyici özneliğin tespit etmek amacıyla kullanılan mRmR algoritmasında literatürde bu çalışma konusunda farklı filtreleme methodları kullanılmıştır. Genel olarak Shannon entropi değerine dayanan ortak bilgi (MI), Pearson korelasyon katsayısı (PE) ve Spearman korelasyon katsayıları (SP) kriter olarak belirlenmiştir. Yapılan bu deneysel çalışmada kullanılan tüm methodların belirlediği özneliklerin sınıflandırma performansına nasıl etki ettiği incelenmiştir. Çizelge 4.6'da belirtildiği gibi Spearman ve Pearson korelasyon katsayılarında genel olarak ritim ve tını grubu öznelikler ağırlıklı olarak seçilmiş iken, ortak bilginin kullanımında ise ton ve tını grubu öznelikleri ilk sıralarda verilmiştir.


4.4.4 Ardışık İleri ve Geri Yönde Seçim (SFS/SBS) ile Öznitelik Seçimi

Normaleştirme işlemleri uygulanmış hasta ve sağlıklı bireylere ait özneliklere ileri ve geri yönde ardışık seçim algoritması uygulanmıştır. Seçilen özneliğin kararlılığını arttırmak için her adımda öznelik değeri hesaplanmasında kullanılan Monte Carlo tekrar sayısının yüksek bir değerde uygulanması gerekir. Bu amaçla her adımda tekrar sayısı 10 olarak kullanılmıştır. Hem ileri yönlü hem de geri yönlü seçim ile belirlenen en iyi 20 öznelik Çizelge 4.6'da verilmiştir. İleri yönlü ardışık seçimde sıfır geçiş, dalgalanma kuvveti, karekök ortalama enerjisi öznelikleri en iyi ilk üç öznelik olarak belirlenirken, geri yönlü ardışık seçimde ritim grubu özneliği olan atım spektrumu ve tını grubu özneliği olan sıfır geçiş öznelikleri en değerli öznelikler olarak seçilmiştir.

4.4.5. Rastgele Orman ile Öznitelik Seçimi

Rastgele Orman, algoritması, prensibi bakımından her döngüsünde farklı ağaç yapısı kurduğundan dolayı program her çalıştırıldığında farklı öznelikleri en iyi olarak belirler. Bu sebeple, rastgele orman algoritmasından elde edilecek sonuçları optimize etmek için algoritma 100 kere çalıştırılmış ve her döngüde seçilen özneliklerin histogramı çıkartılarak bilgi kazancı en yüksek müzikal öznelikler belirlenmiştir (Şekil

4.3). Şekil 4.3 ve Çizelge 4.7’den anlaşılacağı üzere RF öznelik seçim algoritması bilgi kazancı en yüksek öznelik olarak pürüzlülük (59,61,57,58), atım spektrumu (15), emerge event (30), örtülü spektrakromagram (76,74), roll-off 95 (36) ve sıfır geçiş (34) özelliklerini veriyor.




Şekil 4.3. RF yöntemiyle belirlenen en iyi özneliklerin histogram gösterimi

4.5. Öznitelik Seçme Algoritmalarının Kıyaslanması

Öznitelik seçim yöntemlerinin veri kümesine uygulanmasının ardından belirlenen ilk 20 öznitelik, BBDB çapraz doğrulama yöntemi ile DVM ve k-EYK sınıflandırıcılara beslenerek seçilen özniteliklerin başarı performansları ölçülmüştür. Şekil 4.4 ve 4.5 sırası ile DVM ve k-EYK kullanılarak öznitelik sayısı bazında sınıflandırıcıların doğruluk değerlerini vermektedir. Şekillerde y eksenini doğruluk değerlerini verirken, x eksenini ise ilk 20 özniteliği temsil etmektedir.

Şekil 4.4'te gösterilen grafikteki DVM sınıflandırma algoritması kullanılarak elde edilen sonuçlara göre ortak bilgi filtre yöntemini kullanan mRmR algoritması dışındaki diğer uygulamalar daha dengeli ve tutarlı sonuçlar vermektedir. LASSO algoritması ile en yüksek %98.48 doğru sınıflandırma başarısı ilk 9 öznitelik ile elde edilmiştir. RELIEF algoritması 11 adet öznitelik kullanarak %97,44'lük bir performans sergilemiş, Rastgele orman algoritması ise ilk 7 öznitelikte %97,85 doğru sınıflandırma başarısı göstermiştir. Ardışık öznitelik seçim yöntemlerinden ileri yönlü seçim algoritması geri yönlü seçime göre öznitelik sayısı arttıkça daha yüksek ve tutarlı bir performans sergilemiştir. Ancak SBS ile ilk 7 öznitelikte %97,26'lık bir başarı sergilerken, SFS ilk 9 öznitelikte %97,73'lik bir sonuç elde edilmiştir.


Farklı filtre yöntemlerinin kullanıldığı mRmR algoritmalarında, deneylerde kullanılan öznitelik seçim uygulamaları içerisinde ilk 7 öznitelik ve %99,74 ile en yüksek sınıflandırma performansı gösteren Spearman korelasyon katsayısı kullanan mRmR yöntemidir. mRmR_{PR} ile ilk 9 öznitelikte %98,35'lik bir sonuç elde edilirken mRmR_{MI} ilk özniteliklerde sistemin en düşük performansı sergilemiştir ancak öznitelik sayısı arttıkça doğruluk oranı da artış göstermiştir.



Şekil 4.4: Seçilen özniteliklerin DVM sınıflandırıcıda doğruluk performansı

Şekil 4.5'te gösterilen grafikteki k-EYK sınıflandırma algoritması kullanılarak elde edilen sonuçlara göre, LASSO algoritması ile en yüksek %96,21 doğru sınıflandırma başarısı ilk 10 öznitelik ile elde edilmiştir. RELIEF algoritması 11 adet öznitelik kullanarak %92,42'lik bir performans sergilemiş, Rastgele orman algoritması ise %95,45 doğru sınıflandırma başarımını ilk 12 öznitelikte göstermiştir. Ardışık öznitelik seçim yöntemlerinden ileri yönlü seçim algoritması geri yönlü seçime göre genel olarak daha yüksek ve tutarlı bir performans sergilemiştir. Ayrıca SBS ile ilk 4 öznitelikte sistemin en düşük sınıflandırma değeri gözlenmiştir ancak 14 öznitelik kullanıldığında %97,07'lik bir başarı performansı elde edilmiştir. SFS ile ilk 13 öznitelikte %95,20'lik bir sonuç elde edilmiştir. Farklı filtre yöntemlerinin kullanıldığı mRmR algoritmalarında, deneylerde kullanılan öznitelik seçim uygulamaları içerisinde mRmR_{PR} 13 öznitelik kullanarak %98,20'lik bir sonuç elde ederken, mRmR_{PR} ile ilk 13 öznitelikte %98,21'lik bir sonuç elde edilmiştir. Öznitelik sayısı arttıkça en düşük performansı sergileme eğilimi gösteren mRmR_{MI} üç öznitelik kullanarak %93,58 doğru sınıflandırma göstermiştir.

Grafikteki değerler dikkate alındığında, Rastgele orman ve Spearman korelasyonunun kullanıldığı mRmR_{SP} algoritmalarının diğer yöntemlere göre daha tutarlı bir performans sergilediği gözlenmektedir. İlk 6 öznitelik kullanılarak elde edilen sınıflandırma başarıları baz alındığında, Rastgele orman öznitelik seçme yöntemi mRmR_{SP} yöntemine göre daha yüksek performans sergilemiş, ancak artan öznitelik sayısıyla mRmR_{SP} yöntemi daha yüksek başarı sağlamıştır. Genel olarak k-EYK sınıflandırma ile elde edilen değerlerin DVM ile elde edilenlerden daha düşük olduğu söylenebilir ancak mRmR_{MI} özniteliklerinin k-EYK sınıflandırıcıda genel olarak daha dengeli sonuçlar verdiği sonucuna varabiliriz.



Şekil 4.5: Seçilen özniteliklerin k-EYK sınıflandırıcıda doğruluk performansı

4.6. Ton Farkının Sınıflandırma Performansına Etkisi

Parkinson hastası ve sağlıklı bireylerin ayırımında kullanılan yöntemlerin başarısını farklı açıdan ölçmek için sağlıklı veri kümesindeki bireylerin farklı ses tonlarındaki verileri kullanılmış ve ses tonunun hasta bireyleri tanımada ne kadar etkisi olduğu yapılan başka bir çalışmada incelenmiştir. Tez kapsamında daha önce yapılmış çalışmalardan yola çıkarak DVM sınıflandırıcısının daha yüksek doğruluk değeri elde etmesi ve BBDB çapraz doğrulama yöntemi ile daha bireyden bağımsız özgül değerler elde edilmesinden dolayı bu bölümde yapılan çalışmalarda DVM ve BBDB yöntemleri ile çalışılmıştır.

İlk olarak veri kümesinde bulunan Parkinson hastası bireylerin ses verileri ile sağlıklı bireylerin normal, yüksek ve alçak tondaki ses kayıtlarından elde edilen müzikal öznitelikler temel gruplar halinde DVM sınıflandırıcıya verilmiş, ton bazında elde edilen sonuçlar Çizelge 4.8’de gösterilmiştir.

Yüksek ve normal ses tonlarının kullanıldığı çalışmalarda perde grubu öznitelikleri haricinde diğer öznitelik gruplarının %90 üzerinde doğru sınıflandırma performansı elde ettiği görülmektedir. Normal ses tonunda %97,59 ile ritim grubu en yüksek değeri elde ederken, yüksek tonlu veri kümesinde %95,33 bir değer ile ton grubu öznitelikleri yüksek performans sergilemiştir. Alçak ses tonu veri kümesinin kullanıldığı çalışmalarda tını grubu %88,39 doğruluk değeri ile diğer öznitelik gruplarına göre daha ön plana çıkmasına rağmen genel olarak daha düşük sonuçlar sergilemiştir.

Çizelge 4.7: Farklı ses tonlarının öznitelik seçimi öncesi doğruluk değerleri

Öznitelik Grubu	Ses Tonuna Göre Sınıflandırma Doğruluğu (%)		
	<i>Normal</i>	<i>Yüksek</i>	<i>Alçak</i>
TON	93,81	95,33	53,89
TINI	94,49	93,56	88,39
RİTİM	97,59	95,00	82,53
PERDE	62,90	60,46	57,05
DİNAMİK	93,30	94,54	74,21

Çalışmanın ikinci aşamasında öznitelik seçme algoritmalarının belirlediği 20 öznitelik farklı tondaki veri kümelerine uygulanmış ve sınıflandırma doğrulukları Çizelge 4.8’de gösterilmiştir.

Çizelge 4.8: Farklı ses tonlarının öznitelik seçimi sonrası doğruluk değerleri

Öznitelik Seçimi	Ses Tonuna Göre Sınıflandırma Doğruluğu (%)		
	<i>Normal</i>	<i>Yüksek</i>	<i>Alçak</i>
LASSO	98,48	97,73	93,18
RELIEF	97,44	98,21	93,48
SFS	97,93	98,86	95,20
SBS	97,26	97,73	93,94
mRmR_SP	99,74	98,48	96,21
mRmR_PR	98,36	96,97	94,70
mRmR_MI	98,21	96,08	93,94
RF	96,21	96,88	92,42

Öznitelik seçimi uygulamalarının sınıflandırma performansına en büyük katkısı alçak ses tonundaki veri kümesine olmuştur. mRmR_{SP} öznitelik çıkarımı algoritması ile belirlenen öznitelikler ile %96,21’lik bir sonuç elde edilmiştir. Öznitelik çıkarımı uygulamasının sonrasında sınıflandırmayı olumsuz yönde etkileyen özniteliklerin veri kümesinden çıkartılmasıyla sınıflandırma performansı her üç veri kümesinde de %90’nın üzerine çıkmıştır.

BÖLÜM 5

SONUÇ VE TARTIŞMA

Parkinson hastalığının ilk teşhisinin üzerinden neredeyse 200 yıl geçmesine ve birçok araştırmacının bu konu üzerinde çalışmasına rağmen Parkinson hastalığının olası erken teşhisi ve akabinde uygulanacak kesin tedavisi hala bulunamamıştır. Parkinson hastalığı gerek hasta bireyler gerekse onun bakımını sağlayan bireyler için oldukça zahmetli bir sürece sahiptir. Bu sebeple hastalığın tanısı ve ilerleyişini takip edebilmek için zahmetsiz yöntemler geliştirilmedi. Elde edilebilirliğinin ve uygulanabilirliğinin kolay, maliyetin ucuz, noninvaziv² bir yöntem olmasından dolayı hasta içinde teşhis sırasında bir sıkıntı yaratmadığı için, literatürde pek çok araştırmacı Parkinson hastalığı teşhisinde ses kısıklığına başvurmuştur.

Bu tezde, hastalardan alınan ses sinyallerinin müzikal özniteliklerinden yararlanılarak hasta ve sağlıklı bireylerin ayrılmasında uzmanlara yardımcı olacak bilgisayar tabanlı bir karar destek sistemi geliştirilmiştir.

UCI veri tabanından, Parkinson hastası Türk bireylerden toplanmış uzatılmış /a/ ve /o/ seslilerinin kayıtları ile, SVD veri tabanından sağlıklı Alman bireylere ait sürdürülmüş /a/ ve /o/ seslilerinin kayıtları kullanılarak çok uluslu bir tahmin ve sınıflandırma sistemi oluşturulmuştur. Ses verilerinden özniteliklerin çıkartılmasında MIR-toolbox öznitelik çıkarım aracı kullanılmış özniteliklerin sınıflandırılması, uygun eğitim modelinin belirlenmesinde ise Matlab programlama platformu kullanılmıştır.

² Noninvaziv yöntemler, deri altına girmeyi gerektirmeyen, cilt içine veya vücut içine herhangi bir alet yerleştirmeden uygulanan diğer bir deęişle kan dökmeden yapılan tıbbi prosedürlerdir.

Hasta ve kontrol deneklerinden toplanan ses örneklerinden çıkartılan müzikal özniteliklerin farklı sınıflandırıcılara beslemeden önce elde edilen öznitelik değerlerine göre hangi normalizasyon yönteminin daha uygun olduğunu belirlemek amacıyla verilere literatürde sıkça kullanılan farklı normalleştirme yöntemleri uygulanmış, öznitelik çıkarımı sırasında özniteliklerin aldığı değerlere göre verilerin min-maks normalizasyon yöntemi ile $[-1,+1]$ arasında düzenlenmesinin sınıflandırmada daha başarılı olduğu gözlenmiştir.

Sınırlı sayıda veriden oluşan veri kümelerinde, sistemin aşırı öğrenim sonucunda yüksek sonuçlar vermesini önlemek amacıyla verilerin eğitim ve test biçiminde bölünmesini sağlamak için bazı yöntemler kullanılır. Parkinson hastalığının tespitinde ses sinyallerinden elde edilen müzikal verilerinin analizinde, sınıflandırmada aşırı öğrenimi engellemek için birini dışarıda bırakma (BDB) ve bir bireyi dışarıda bırakma (BBDB) çapraz doğrulama yöntemleri kullanılmıştır. BDB çapraz doğrulama yönteminde, test kümesinde kullanılan örnek verinin bir bireyin sadece bir ses kaydı, aynı bireye ait diğer ses kayıtlarının eğitim kümesinde olmasından dolayı test ve eğitim kümeleri arasında kesişmeye neden olmaktadır ve taraflı bir sınıflandırma başarısı ölçülmektedir. BBDB yönteminde ise, test kümesinde bir bireye ait tüm ses kayıtları bulunmakta ve diğer bireylerin ses örnekleri eğitim kümesi olarak kullanılmaktadır. Dolayısıyla, BBDB çapraz doğrulama yöntemi kişiden bağımsız ve tarafsız bir sınıflandırma performansı sunmaktadır.

Parkinson hastalığında kasların kontrol mekanizmasının etkilenmesi sonucu seslerinde meydana gelen değişiklikler hastalığın ayırımında oldukça belirleyici özelliklerdir. Bu değişikliklerin sesin hangi temel özelliğinde meydana gelip hastalığın ayırımında daha ön plana çıktığını belirlemek amacıyla MIR-toolbox ile çıkartılan öznitelikler sesin ton, tını, ritim, perde ve dinamiklik özelliklerine göre kategorilere ayrılmıştır. Elde edilen yeni veri alt kümelerinin k-EYK ve DVM sınıflandırıcılardaki başarı performansları ölçülmüş, sırasıyla ritim, tını, ve ton temel gruplarının hastalığın tespitinde daha ön plana çıktığı gözlenmiştir.

Öznitelik sayısı boyutu işlem süresini ve sınıflandırma performansını etkileyen önemli unsurlardan birisidir. Tüm öznitelikleri kullanmak yerine sınıflandırmaya

olumsuz etki eden öznitelikleri eleyerek sadece bazı yüksek seviyeli özniteliklerin kullanılması performans başarısını arttırabilir. Bu doğrultuda tüm ses örnekleri LASSO, RELIEF, SFS, SBS, RF ve en iyi özniteliği belirlemede farklı kriterleri kullanan mRmR (mRmR_{SP}, mRmR_{PR}, mRmR_{MI}) öznitelik seçme algoritmalarının artan öznitelik sayısına göre başarı oranları incelenmiştir. Tüm özniteliklerin kullanıldığı durumda k-EYK sınıflandırıcı ile %82,13, DVM sınıflandırıcı ile %86,21 doğruluk elde ederken, öznitelik seçimi sonrasında sınıflandırmayı olumsuz etkileyen özniteliklerin veri kümesinden çıkartılması sonucunda doğruluk oranları k-EYK ile en yüksek %98,21'e, DVM ile en yüksek %99,74'e çıkmıştır. Genel olarak DVM ile 7-9 öznitelik arasında en yüksek doğruluk oranları elde edilmişken, bu oran k-EYK sınıflandırıcıda 11-14 öznitelik arasındadır. Ayrıca DVM sınıflandırıcıda öznitelik sayısını arttıktça daha kararlı bir azalma göstermektedir. Elde edilen sonuçlar doğrultusunda en yüksek performans tını ve ritim grubu özniteliklerinde sergilenmiştir. Bu sonuçlarla, literatürde sesin temel frekansı (f_0) ile yapılan çalışmaların yanında sesteki müzikal etkilerinde hastalığın tanısında önemli bir rol, alternatif bir yöntem olabileceği görülmüştür.

Konuşma ve ses çıkarımı parmak izi gibi kişiye özgüdür ve kullandığı dile göre farklı izler taşır. Parkinson hastası ve sağlıklı bireylerin ayırımında kullanılan yöntemlerin başarısını farklı açıdan ölçmek için sağlıklı veri kümesindeki bireylerin farklı ses tonlarındaki verileri kullanılmış ve ses tonunun hasta bireyleri tanımada ne kadar etkisi olduğu yapılan bir başka çalışmada incelenmiştir. Bu çalışma sonucunda normal ve yüksek ses tonlarında alçak ses tonuna göre daha yüksek başarı sağlanmıştır. Alçak ses tonunda düşük performans sergilenmesi, Parkinson hastalığının seste ton kısıklığı, sesin yumuşaması ve tekdüzelik gibi belirtilerinin hastalığın ilk evrelerinde olan bireylerde daha hafif hissedilmesinden dolayı bazı hasta bireylerin sağlıklı olarak sınıflandırılmasından kaynaklanmaktadır.

Yürütülen tez çalışması, bu alanda yapılan daha önceki çalışmalarla kıyaslandığında sesin müzikal özniteliklerinin hastalığın tespitinde başarılı bir şekilde kullanılabileceğini gösteren ilk çalışma olması sebebiyle başta ülkemiz olmak üzere dünyada da birçok çalışmaya referans olacak niteliktedir. İleriki çalışma olarak cep telefonu veya ses kayıt cihazı üzerinden daha fazla veri toplanarak gerçek zamanlı bir model oluşturulması ve oluşturulan bu modelin geliştirilmesi hedeflenmiştir. Ayrıca bu

alıřmada her ne kadar sadece Parkinson hastalıęı hedef alınmıř olsa da, bu alıřmanın bir sonraki adımı olarak mzikal zelliklerin Multipl skleroz, Huntington hastalıęı, Amyotrofik lateral skleroz gibi merkezi sinir sistemini etkileyen dięer nrodejeneratif hastalıklarda da etkili bir řekilde kullanılabileceęi dřnlmektedir.

BÖLÜM 6

KAYNAKÇA

- Akbayır, E., Şen, M., Ay, U., Şenyer, S., Tüzün, E., & Küçükali, C. İ. (2017). Parkinson Hastalığının Etyopatogenezi. *Deneyisel Tıp Araştırma Enstitüsü Dergisi*, 7(13), 1-23.
- Alhussein, M. (2017). Monitoring Parkinson's Disease in Smart Cities. *IEEE Access*, 5, 19835-19841.
- Alpaydin, E. (2009). *Introduction to machine learning*: MIT press.
- Asuncion, A., & Newman, D. (2007). UCI machine learning repository.
- Aygün, D., Türkel, Y., & Onar, M. K. (2009). Parkinson hastalığında motor olmayan belirtilerin tanı ve tedavisi. *Parkinson Hastalığı ve Hareket Bozuklukları Dergisi*, 12, 80-90.
- Bakır, S. (2015). *Kulak Burun Boğaz Notları* (S. Bakır Ed.). Ankara: Derman Tıbbi Yayıncılık.
- Barry, W., & Pützer, M. (2007). Saarbrücken voice database. *Institute of Phonetics, Universität des Saarlandes*, <http://www.stimmdatenbank.coli.uni-saarland.de>.
- Bayestehtashk, A., Asgari, M., Shafran, I., & McNames, J. (2015). Fully automated assessment of the severity of Parkinson's disease from speech. *Computer speech & language*, 29(1), 172-185.
- Benba, A., Jilbab, A., Hammouch, A., & Sandabad, S. (2015). *Voiceprints analysis using MFCC and SVM for detecting patients with Parkinson's disease*. Paper presented at the Electrical and Information Technologies (ICEIT), 2015 International Conference on.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Budak, H. (2018). Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, DOI: 10.19113/sdufbed. 01653-Online Yayınlanma: 19117.19105. 12018.
- Cakmur, R. (2011). Parkinson hastalığı ve medikal tedavisi. *Klinik Gelişim*, 53-58.
- Cantürk, İ., & Karabiber, F. (2016). A Machine Learning System for the Diagnosis of Parkinson's Disease from Speech Signals and Its Application to Multiple Speech Signal Types. *Arabian Journal for Science and Engineering*, 41(12), 5049-5059.

- Chang, C.-C., & Lin, C.-J. (2011). LIBSVM: a library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, 2(3), 27.
- Das, R. (2010). A comparison of multiple classification methods for diagnosis of Parkinson disease. *Expert Systems with Applications*, 37(2), 1568-1572.
- Ding, C., & Peng, H. (2005). Minimum redundancy feature selection from microarray gene expression data. *Journal of bioinformatics and computational biology*, 3(02), 185-205.
- Dixon, S. (2006). *Onset detection revisited*. Paper presented at the Proceedings of the 9th International Conference on Digital Audio Effects.
- Elemetrics, K. (1993). Multi-Dimensional Voice Program (MDVP).[Computer program.]. *Pine Brook, NJ: Author*.
- Eskidere, Ö., & Ertaş, F. (2009). Mel frekansı kepstrem katsayılarındaki değişimlerin konuşmacı tanımaya etkisi. *Uludağ University Journal of The Faculty of Engineering*, 14(2).
- Eyben, F., Wöllmer, M., & Schuller, B. (2010). *Opensmile: the munich versatile and fast open-source audio feature extractor*. Paper presented at the Proceedings of the 18th ACM international conference on Multimedia.
- Fastl, H. (1982). Fluctuation strength and temporal masking patterns of amplitude-modulated broadband noise. *Hearing Research*, 8(1), 59-69.
- Fonti, V., & Belitser, E. (2017). Feature selection using lasso. *VU Amsterdam Research Paper in Business Analytics*.
- Foote, J., & Uchihashi, S. (2001). *The beat spectrum: A new approach to rhythm analysis*. Paper presented at the null.
- Gerçeker, M., Yorulmaz, İ., & Ural, A. (2000). Ses ve konuşma. *KBB ve Baş Boyun Cerrahisi Dergisi*, 8, 71-78.
- Gülgezen, G., Çataltepe, Z., & Yu, L. MRMR Algoritması Kullanılarak Kararlı Öznitelik Seçimi Stable Feature Selection Using MRMR Algorithm.
- Harte, C., Sandler, M., & Gasser, M. (2006). *Detecting harmonic change in musical audio*. Paper presented at the Proceedings of the 1st ACM workshop on Audio and music computing multimedia.
- <http://fizyosaglik.com>.
- <http://www.odyolojivedilkonusma.com>.,<http://www.odyolojivedilkonusma.com/?pnum=36&pt=Ses+ve+Konu%C5%9Fman%C4%B1n+Olu%C5%9Fumu>
- <https://www.ilacrehberi.com>., <https://www.ilacrehberi.com/h/parkinson-hastaligi/>
- <https://www.inploid.com>.,<https://www.inploid.com/t/parkinson-hastaligi-nedir-belirtileri-nelerdir/30271/>
- J Holmes, R., M Oates, J., J Phyland, D., & J Hughes, A. (2000). Voice characteristics in the progression of Parkinson's disease. *International Journal of Language & Communication Disorders*, 35(3), 407-418.

- Jankovic, J. (2008). Parkinson's disease: clinical features and diagnosis. *Journal of Neurology, Neurosurgery & Psychiatry*, 79(4), 368-376.
- Juslin, P. N. (2000). Cue utilization in communication of emotion in music performance: Relating performance to perception. *Journal of Experimental Psychology: Human perception and performance*, 26(6), 1797.
- Kaynar, O., Arslan, H., Görmez, Y., & Işık, Y. E. (2018). Makine Öğrenmesi ve Öznitelik Seçim Yöntemleriyle Saldırı Tespiti. *International Journal of InformaticsTechnologies*, 11(2).
- Kira, K., & Rendell, L. A. (1992). A practical approach to feature selection *Machine Learning Proceedings 1992* (pp. 249-256): Elsevier.
- Kurt, İ., Ulukaya, S., & Erdem, O. (2018). *Musical Feature Based Classification of Parkinson's Disease Using Dysphonic Speech*. Paper presented at the 2018 41st International Conference on Telecommunications and Signal Processing (TSP).
- Lartillot, O. (2012). MIR Toolbox Manual [Instruction Manual].
- Lartillot, O., Cereghetti, D., Eliard, K., Trost, W. J., Rappaz, M.-A., & Grandjean, D. (2013). *Estimating tempo and metrical features by tracking the whole metrical hierarchy*. Paper presented at the The 3rd International Conference on Music & Emotion, Jyväskylä, Finland, June 11-15, 2013.
- Lartillot, O., & Toiviainen, P. (2007). *A Matlab toolbox for musical feature extraction from audio*. Paper presented at the International conference on digital audio effects.
- Lartillot, O., Toiviainen, P., & Eerola, T. (2008). A matlab toolbox for music information retrieval *Data analysis, machine learning and applications* (pp. 261-268): Springer.
- Little, M. A., McSharry, P. E., Hunter, E. J., Spielman, J., & Ramig, L. O. (2009). Suitability of dysphonia measurements for telemonitoring of Parkinson's disease. *IEEE transactions on biomedical engineering*, 56(4), 1015-1022.
- Marill, T., & Green, D. (1963). On the effectiveness of receptors in recognition systems. *IEEE transactions on Information Theory*, 9(1), 11-17.
- Momo, N., & Uddin, J. (2017). *Speech Recognition Using Feed Forward Neural Network and Principle Component Analysis*. Paper presented at the International Symposium on Signal Processing and Intelligent Recognition Systems.
- Orozco-Aroyave, J., Hönig, F., Arias-Londoño, J., Vargas-Bonilla, J., Daqrouq, K., Skodda, S., . . . Nöth, E. (2016). Automatic detection of Parkinson's disease in running speech spoken in three different languages. *The journal of the Acoustical Society of America*, 139(1), 481-500.
- Özekmekçi, S., Apaydın, H., Oğuz, S., & Zileli, İ. (2013). Parkinson Hastalığı Hasta ve Yakınları İçin El Kitabı.
- Özkan, Y. (2008). *Veri madenciliği yöntemleri*: Papatya Yayıncılık Eğitim.

- Pampalk, E., Rauber, A., & Merkl, D. (2002). *Content-based organization and visualization of music archives*. Paper presented at the Proceedings of the tenth ACM international conference on Multimedia.
- Paul Boersma, D. W. (2013). Praat: doing phonetics by computer (Version 5.3.51, retrieved 2 June 2013).
- Pekel, N. B., Yıldız, D., Sığırlı, D., Güneş, A., & Seferoğlu, M. (2017). Parkinson Hastalarında Depresyon, Anksiyete Bozukluğu ve Uyku Kalitesinin Değerlendirilmesi. *Uludağ Üniversitesi Tıp Fakültesi Dergisi*, 43(3), 91-96.
- Perju-Dumbrava, L. D., Kovacs, G. G., Pirker, S., Jellinger, K., Hoffmann, M., Asenbaum, S., & Pirker, W. (2012). Dopamine transporter imaging in autopsy-confirmed Parkinson's disease and multiple system atrophy. *Movement Disorders*, 27(1), 65-71.
- Plomp, R., & Levelt, W. J. M. (1965). Tonal consonance and critical bandwidth. *The journal of the Acoustical Society of America*, 38(4), 548-560.
- Poewe, W., & Scherfler, C. (2003). Role of dopamine transporter imaging in investigation of parkinsonian syndromes in routine clinical practice. *Movement Disorders*, 18(S7).
- Pohle, T., Pampalk, E., & Widmer, G. (2005). *Evaluation of frequently used audio features for classification of music into perceptual categories*. Paper presented at the Proceedings of the Fourth International Workshop on Content-Based Multimedia Indexing.
- Ramezani, H., Khaki, H., Erzin, E., & Akan, O. B. (2017). *Speech features for telemonitoring of Parkinson's disease symptoms*. Paper presented at the Engineering in Medicine and Biology Society (EMBC), 2017 39th Annual International Conference of the IEEE.
- Revet, K., Gorunescu, F., & Salem, A.-B. M. (2009). *Feature selection in Parkinson's disease: A rough sets approach*. Paper presented at the Computer Science and Information Technology, 2009. IMCSIT'09. International Multiconference on.
- Rueda, A., & Krishnan, S. (2017). *Feature analysis of dysphonia speech for monitoring Parkinson's disease*. Paper presented at the Engineering in Medicine and Biology Society (EMBC), 2017 39th Annual International Conference of the IEEE.
- Sakar, B. E., Isenkul, M. E., Sakar, C. O., Sertbas, A., Gurgun, F., Delil, S., . . . Kursun, O. (2013). 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., & Kursun, O. (2010). Telediagnosis of Parkinson's disease using measurements of dysphonia. *Journal of medical systems*, 34(4), 591-599.
- Shannon, C. E. (1948). A mathematical theory of communication. *Bell system technical journal*, 27(3), 379-423.
- Silahtaroglu, G. (2008). Veri madenciliği. *Papatya Yayınları, İstanbul*.

- TDK,T.D.K. *Büyük Türkçe Sözlüğü.*
http://www.tdk.gov.tr/index.php?option=com_bts&arama=kelime&guid=TDK.GTS.5c04f5df43bdd5.34587549
- Titze, I. R., & Martin, D. W. (1998). Principles of voice production: ASA.
- Torun, Ş. (1991). *Parkinsonlularda Konuşma Fonksiyonunun Subjektif ve Objektif (Elektrolaringografik) Yöntemlerle incelenmesi.* (Uzmanlık Tezi), Anadolu Üniversitesi, Eskişehir.
- TPHD,T.P.H. D. (2017). Parkinson Nedir?,<http://parkinsonderneği.com/parkinson-nedir/>
- Tsanas, A., Little, M. A., McSharry, P. E., & Ramig, L. O. (2010a). Accurate telemonitoring of Parkinson's disease progression by noninvasive speech tests. *IEEE transactions on biomedical engineering*, 57(4), 884-893.
- Tsanas, A., Little, M. A., McSharry, P. E., & Ramig, L. O. (2010b). *Enhanced classical dysphonia measures and sparse regression for telemonitoring of Parkinson's disease progression.* Paper presented at the Acoustics Speech and Signal Processing (ICASSP), 2010 IEEE International Conference on.
- Tsanas, A., Little, M. A., McSharry, P. E., Spielman, J., & Ramig, L. O. (2012). Novel speech signal processing algorithms for high-accuracy classification of Parkinson's disease. *IEEE transactions on biomedical engineering*, 59(5), 1264-1271.
- Tysnes, O.-B., & Storstein, A. (2017). Epidemiology of Parkinson's disease. *Journal of Neural Transmission*, 124(8), 901-905.
- Tzanetakis, G., & Cook, P. (2002). Musical genre classification of audio signals. *IEEE Transactions on speech and audio processing*, 10(5), 293-302.
- Uğurel, B., Eranil, Ö., Berrin, A., & Doğan, M. (2012). Erken Başlangıçlı Parkinson Hastalığında Psikojenik Disfoni: Olgu Sunumu. *Parkinson Hastalığı ve Hareket Bozuklukları Dergisi.*
- Vaiciukynas, E., Verikas, A., Gelzinis, A., & Bacauskiene, M. (2017). Detecting Parkinson's disease from sustained phonation and speech signals. *PloS one*, 12(10), e0185613.
- Whitney, A. W. (1971). A direct method of nonparametric measurement selection. *IEEE Transactions on Computers*, 100(9), 1100-1103.
- Wirdefeldt, K., Adami, H.-O., Cole, P., Trichopoulos, D., & Mandel, J. (2011). Epidemiology and etiology of Parkinson's disease: a review of the evidence. *European Journal of Epidemiology*, 26(1), 1. doi: 10.1007/s10654-011-9581-6
- Yacoubian, T. (2017). Neurodegenerative Disorders: Why Do We Need New Therapies? *Drug Discovery Approaches for the Treatment of Neurodegenerative Disorders* (pp. 1-16): Elsevier.

EKLER

EK 1. Ses örneklerinden çıkartılan müzikal bazlı özneliklerin Türkçe karşılıkları

No	Öznelik	No	Öznelik
1	Karesel ortalamanın karekökü	27	Başlama Noktası (min)
2	Düşük Enerji	28	Başlama Noktası (ranj)
3	En iyi perde değeri	29	Başlama Noktası (ort)
4	Dalgalanma Kuvveti (ort)	30	Başlama Noktası (var)
5	Dalgalanma Kuvveti (std)	31	Başlama Noktası (kurt)
6	Dalgalanma Kuvveti (medyan)	32	Başlama Noktası (skew)
7	Dalgalanma Kuvveti (maks)	33	Başlangıç Yoğunluğu
8	Dalgalanma Kuvveti (min)	34	Sıfır-geçiş
9	Atım Spektrumu (maks)	35	Roll-of 85
10	Atım Spektrumu (min)	36	Roll-off 95
11	Atım Spektrumu (ranj)	37	Parlaklık
12	Atım Spektrumu (ort)	38	Geometrik Merkez
13	Atım Spektrumu (var)	39	Yayılm
14	Atım Spektrumu (kurt)	40	Çarpıklık
15	Atım Spektrumu (skew)	41	Basıklık
16	Nokta Çıkarımı (ort)	42	Düzensizlik
17	Nokta Çıkarımı (std)	43	Entropi
18	Nokta Çıkarımı (medyan)	44-56	MFCC 1-13
19	Nokta Çıkarımı (maks)	57	Pürüzlülük (maks)
20	Nokta Çıkarımı (min)	58	Pürüzlülük (min)
21	Spektral Akı (ort)	59	Pürüzlülük (ranj)
22	Spektral Akı (std)	60	Pürüzlülük (ort)
23	Spektral Akı (medyan)	61	Pürüzlülük (var)
24	Spektral Akı (maks)	62	Pürüzlülük (kurt)
25	Spektral Akı (min)	63	Pürüzlülük (skew)
26	Başlama Noktası (maks)	64	Düzensizlik

EK 1. Ses örneklerinden çıkartılan müzikal bazlı özneliklerin Türkçe karşılıkları
(devam)

No	Öznelik	No	Öznelik
65	Spektral Kromagram (maks)	75	Örtülü Spektral Kromagram (ort)
66	Spektral Kromagram (min)	76	Örtülü Spektral Kromagram (var)
67	Spektral Kromagram (ranj)	77	Örtülü Spektral Kromagram (kurt)
68	Spektral Kromagram (ort)	78	Örtülü Spektral Kromagram (skew)
69	Spektral Kromagram (var)	79-102	Anahtar Kuvveti 1-24
70	Spektral Kromagram (kurt)	103	Anahtar
71	Spektral Kromagram (skew)	104	Mod (en iyi)
72	Örtülü Spektral Kromagram (maks)	105	Mod (toplam)
73	Örtülü Spektral Kromagram (min)	106-111	Tonal Ağırlık Merkezi 1-6
74	Örtülü Spektral Kromagram (ranj)		

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı- Soyadı: İlke KURT

Doğum Tarihi ve Yeri: 23.08.1990/ İzmir

EĞİTİM BİLGİLERİ

- 2016-** TC. Trakya Üniversitesi (Yüksek Lisans)
Hesaplamalı Bilimler
- 2015- 2016** Yıldız Teknik Üniversitesi (Yüksek Lisans)-Kayıt Silme
Biyomühendislik
- 2009-2014** Yakın Doğu Üniversitesi (Hazırlık + Lisans)
Biyomedikal Mühendisliği (İngilizce)
(%100 Burslu-3.78 Genel Ortalama)
(Fakülte ve Bölüm Birinciliği)
- 2005-2009** Türk Maarif Koleji (Lise)
Fen Bilimleri
- 2002-2005** Bayraktar Türk Maarif Koleji (Ortaokul)

YABANCI DİL

İngilizce Okuma: İleri, Yazma: İleri, Konuşma: İleri (YDS - 68,75)

Almanca Okuma: Başlangıç, Yazma: Başlangıç, Konuşma: Başlangıç

YAYINLAR

Kitap Bölümü

1. Kiliç Y., Çakir Koç R., **Kurt İ.**, Gözütok K., Özkan B., Özkan B., et al., "*Polymer-Based Biocomposites*", in: *Biomaterials for Tissue Engineering*, Razavi M., Eds., Bentham Science Publishers (Invited), Oxford, pp.49-89, 2017

KONGRE/ KONFERANS SUNUMU

Uluslararası Bilimsel Toplantılarda Sunulan ve Bildiri Kitabında Basılan Bildiriler (Proceedings)

1. **İ. KURT**, S. ULUKAYA & O. ERDEM, *Musical Feature Based Classification Of Parkinson's Disease Using Dysphonic Speech*, 41st International Conference On Telecommunication And Signal Processing (TSP 2018), Athens, Greece, 2018. (July 2018)
2. T. ADALI, E. KAVALCI & **İ. KURT**, *Electrically Conductive Silk Fibroin/glycerine/polypyrrol Biofilms For Biomedical Applications*, European Biotechnology Congress 2014, Lecce, Italy,2014. (May 2014)