



**İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**PARKİNSON HASTALIĞI'NIN TEŞHİSİ İÇİN
VERİ TOPLAMA VE ÖRÜNTÜ TANIMA SİSTEMİ**

Bilg.Müh. Muhammed Erdem İSENKUL
Bilgisayar Mühendisliği Anabilim Dalı
Yüksek Lisans Programı

Danışman
Prof.Dr. Ahmet SERTBAŞ
Yrd.Doç.Dr. Olcay KURŞUN (İkinci Danışman)

Haziran, 2011

İSTANBUL



**İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**PARKİNSON HASTALIĞI'NIN TEŞHİSİ İÇİN
VERİ TOPLAMA VE ÖRÜNTÜ TANIMA SİSTEMİ**

Bilg.Müh. Muhammed Erdem İSENKUL
Bilgisayar Mühendisliği Anabilim Dalı
Yüksek Lisans Programı


Danışman
Prof.Dr. Ahmet SERTBAŞ
Yrd.Doç.Dr. Olcay KURŞUN (İkinci Danışman)
Haziran, 2011


İSTANBUL

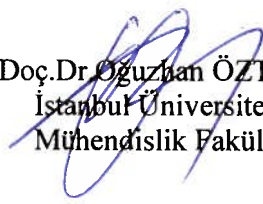
Bu çalışma 28/06/2011 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans programında Yüksek Lisans Tezi olarak kabul edilmiştir.


Tez Jürisi


Prof.Dr. Ahmet SERTBAŞ (Danışman)
İstanbul Üniversitesi
Mühendislik Fakültesi


Prof.Dr. Aydın AKAN
İstanbul Üniversitesi
Mühendislik Fakültesi


Yrd.Doç.Dr. Muhammed Ali AYDIN
İstanbul Üniversitesi
Mühendislik Fakültesi


Yrd.Doç.Dr. Öguzhan ÖZTAŞ
İstanbul Üniversitesi
Mühendislik Fakültesi


Yrd.Doç.Dr. Niyazi KILIÇ
İstanbul Üniversitesi
Mühendislik Fakültesi

ÖNSÖZ

Bu çalışma, İstanbul Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda yapılan "**Parkinson Hastalığı'nın Teşhisi için Veri Toplama ve Örüntü Tanıma Sistemi**" adlı yüksek lisans tez çalışmasını içermektedir.

Yüksek lisans öğrenimim sırasında ve tez çalışmalarım boyunca gösterdiği her türlü destek ve yardımlarından dolayı çok değerli danışman hocam, Sayın Prof.Dr.Ahmet SERTBAŞ'a,

Bu çalışmanın yürütülmesinde her türlü bilgisini ve deneyimini bana aktaran ayrıca birçok konuda bana farklı bir bakış açısı kazandıran ve tezin hazırlanmasında yardımını eksik etmeyen çok değerli hocam, Sayın Yrd.Doç.Dr. Olcay KURŞUN'a,

Bize bu çalışmayı yapabilmem için gereken her türlü imkanı sağlayan, tıbbi bilgilerini bizlerden esirgemeyen Cerrahpaşa Tıp Fakültesi Nöroloji Ana Bilim Dalında görev yapan, Sayın Uzm.Dr. Şakir DELİL'e,

Ayrıca; bu çalışma boyunca deneyimlerini ve yardımlarını esirgemeyen başta Araş. Gör. Ergün GÜMÜŞ ve Öğr. Gör. Betül ERDOĞDU olmak üzere tüm çalışma arkadaşlarıma,

Çalışmaya katılan tüm hastalara, en içten dileklerle teşekkür ederim.

Ve son olarak eğitim hayatım boyunca bana yol gösteren, destek olan ve her zaman yanımda olan sevgili annem ve babama en içten duygularıyla teşekkür eder, sevgilerimi sunarım.

Haziran, 2011

Muhammed Erdem İSENKUL

İÇİNDEKİLER

ÖNSÖZ.....	II
İÇİNDEKİLER	III
ŞEKİL LİSTESİ.....	V
TABLO LİSTESİ	VI
SEMBOL LİSTESİ	VII
ÖZET.....	VIII
SUMMARY	IX
1.GİRİŞ	1
2. GENEL KISIMLAR	4
2.1. HASTALIĞIN TANIMI	4
2.2 PARKİNSON HASTALIĞININ KLİNİK ÖZELLİKLERİ	5
2.2.1 Tremor	5
2.2.2 Rijidite.....	6
2.2.3 Akinezi/Bradikinezi	6
2.2.4 Postüral Instabilite	7
2.2.5 Parkinson Hastalığında Konuşma Bozukluğu	8
2.3. PARKİNSON HASTALIĞINDA BİLGİSAYARLI TEŞHİS ÇALIŞMALARI	9
3. MALZEME VE YÖNTEM	12
3.1. VERİ TOPLAMA SİSTEMİ	13
3.1.1. Hasta Kayıt Formu	13
3.1.1.1. Hasta Bilgileri.....	13
3.1.1.2. Hastalık Geçmişi.....	14
3.1.1.3 Fiziksel Muayene	15
3.1.2. Ses Kayıt Veritabanı	17
3.1.2.1. Ses Örneklerinin Toplanması.....	17
3.1.2.2. Ses Kayıtlarının Ayırıştırılması.....	22

3.2. SESTEN ÖZİNİTELİK ÇIKARTMA	24
3.2.1 Praat Yazılımı	24
3.2.1.1. <i>Jitter Sınıfı Öznitelikler</i>	27
3.2.1.2. <i>Shimmer Sınıfı Öznitelikler</i>	28
3.2.1.3. <i>Çıkarılan Diğer Öznitelikler</i>	30
3.2.2. Toplanan Özniteliklerin Düzenlenmesi	31
3.3. ETKİLİ ÖZİNİTELİK GRUPLARININ SEÇİMİ	32
3.4. ÖRÜNTÜ TANIMA VE İSTATİKSEL ANALİZ	33
3.4.1. En Yakın k-Komşu Algoritması	34
3.4.2. SVM (Destek Vektör Makineleri) Algoritması	35
4. BULGULAR	37
5. TARTIŞMA VE SONUÇ	44
KAYNAKLAR	47
EK-A HASTA KAYIT FORMU	51
EK-B VERİ TOPLAMA VE ÖRÜNTÜ TANIMA İŞLEM ŞEMASI	52
ÖZGEÇMİŞ	53

ŞEKİL LİSTESİ

Şekil 3.1	: Mikrofon desibel ve volüm ayarları	19
Şekil 3.2	: Hastaya ait orijinal ses dalga formu	20
Şekil 3.3	: Sessizleştirme işlemi sonrasında oluşan yeni dalga formu	20
Şekil 3.4	: Ses şiddeti eşik değerinden düşük bir hastanın dalga formu.....	21
Şekil 3.5	: Gürültü filtreleme sonrası oluşan ses dalga formu	21
Şekil 3.6	: Hasta ses kayıt örnekleri.....	22
Şekil 3.7	: Ayrıştırılacak kelimenin editörde seçilmesi	23
Şekil 3.8	: Kırpma işlemi sonrası ses dalga formu	23
Şekil 3.9	: Ses kayıt veri tabanı	24
Şekil 3.10	: Praat ana ekranı	25
Şekil 3.11	: Örnek bir ses dosyası için dalga formu analizi.....	26
Şekil 3.12	: Seçilen ses dalgası için Praat raporu	26
Şekil 3.13	: Toplanan veriler tablosu	31
Şekil 3.14	: KNN sınıflandırıcı	34
Şekil 3.15	: SVM algoritması sonrasında iki sınıf arasında sınır çizgileri	36
Şekil 4.1	: 09 numaralı ses örneğinin kernel parametrelerine göre SVM yöntemi başarı grafiği.....	42
Şekil 4.2	: 09 numaralı ses örneğinin en yakın komşu parametrelerine göre KNN yöntemi başarı grafiği.....	43
Şekil 4.3	: Tüm ses örnekleri kullanılarak MRMR yönteminde seçilen özneliklerin sayılarına göre KNN-SVM yöntemleri başarı grafiği.....	43

TABLO LİSTESİ

Tablo 4.1	: Ses verisi toplanan hastaların hastalık,cinsiyet ve yaş bilgileri tablosu.....	37
Tablo 4.2	: Ses verisi toplanan kontrol grubunun hastalık,cinsiyet ve yaş bilgileri tablosu.....	38
Tablo 4.3	: Çıkarılan özneliklerin UPDRS değerleriyle korelasyonu.....	39
Tablo 4.4	: Öznelik seçimi yapılmadan her bir ses örneğinin SVM yöntemi sonrası kernel çeşitlerine göre sınıflandırma başarı oranları.....	40
Tablo 4.5	: Öznelik seçimi yapılmadan her bir ses örneğinin KNN yöntemi sonrası en yakın komşu sayılarına göre sınıflandırma başarı oranları... ..	41

SEMBOL LİSTESİ

apq3	: 3 noktalı genlik deęişim katsayısı
apq5	: 5 noktalı genlik deęişim katsayısı
apq11	: 11 noktalı genlik deęişim katsayısı
dB	: desibel
F	: periyotlar veya genlikler arası fark
G	: genlik
Hz	: saniye başına düşen devir sayısı
HTN	: harmonik-gürültü oranı
Hz	: saniye başına düşen devir sayısı
I	: ortak bilgi
KNN	: en yakın k-komşu
MRMR	: toprak basıncı katsayısı
NTH	: gürültü-harmonik oranı
P	: periyot
ppq5	: 5 noktalı periyot deęişim katsayısı
PH	: Parkinson hastalığı
rap	: baęıl ortalama deęişimi
SVM	: destek vektör makineleri
TRAP	: tremor-rijidite-akinezi-postural instabilite
UPDRS	: Birleşik Parkinson Hastalığı Deęerlendirme Ölçeęi
wav	: dalga formu ses dosyası

ÖZET

PARKİNSON HASTALIĞI'NIN TEŞHİSİ İÇİN VERİ TOPLAMA VE ÖRÜNTÜ TANIMA SİSTEMİ

Parkinson hastalığı, sinir sistemini etkileyen motor refleksleri, konuşma, düşünme, davranış ve diğer hayati fonksiyonların kısmen veya tamamen kaybolmasına neden olan bir nörolojik hastalıktır. Parkinson hastalığı, hastaların yaklaşık %90'ında konuşma ve motor yeteneklerinin (yazma, denge, vb.) bozulmasına sebep olmaktadır ve çoğunlukla yaşlı kişilerde görülmektedir.

Günümüzde hastaların bilgileri yaş, cinsiyet, tedavi durumu gibi veriler tutulmaktadır. Bu verilere ek olarak, bu tezde önerilen el yazısı ve ses kaydı gibi hastalığın gelişimi ve tedavi sürecine büyük ölçüde katkı sağlayabilecek bilgiler de saklanması tedavi sürecinde büyük önem arz etmektedir. Halihazırda alınan bilgiler kağıt üzerinde saklandığından ve arşivlerde kaldığından, bu durum ses gibi elektronik ortamda tutulması gereken veriler için uygun değildir. Bu yüzden hastaların gelişme ya da gerileme gibi değişimlerini takip etmek ve bu verilerden istatistiki çıkarımlar/öngörüler yapmak zor olmaktadır.

Bu tez kapsamında hastaların bu türlü bilgilerini kayıt ve analiz edebilen bir sistem geliştirilmesi hedeflenmiştir. Çalışmaya katılan tüm hastaların tıbbi muayeneleri sonrasında sosyal bilgileri de toplanmış, bu verilere ek olarak her bir hasta için ayrı bir ses kayıt veritabanı oluşturulmuştur. Ayrıca Parkinson Hastalarından alınan verilerin doğruluğunu anlayabilmek için, Parkinsonlu olmayan hastalar veya tamamen sağlıklı olan bireylerden oluşan bir kontrol grubu içinde bu veri bankası oluşturulmuştur.

Toplanan tüm veriler arasındaki ilişkiler, SVM (Destek Vektör Makineleri) ve KNN (En Yakın Komşu) algoritmaları kullanılarak analizleri yapılmıştır. Ayrıca öznitelik seçiminde kullanılan MRMR (Minimum Artıklık-Maksimum İlişki) yönteminin bu çalışmadaki başarı oranı ölçülmüştür. Elde edilen sonuçlara göre doğru ses bilgileri ve kayıtları seçilerek oluşturulan ses bilgileri sayesinde, hasta ve sağlıklı bireylerin sadece ses kayıtları incelenerek hastalık teşhisi ve hastalık gelişim takibi yapılabileceği görülmüştür. Bu sayede tüm doktorlara karar destek aşamasında yardımcı olabilecek bir sistem geliştirilmiştir.

Tez kapsamında oluşturmayı hedeflediğim sistem, bir hastanın verilerinden onun Parkinson hastası olup olmadığını, Parkinson hastası değil ise risk grubunda olup olmadığını öngörebilmeyi hedeflemiş olup, özellikle ses verilerinin işlenmesi elde ettiğim sonuçlar, ileride yapılması muhtemel uzaktan teşhis teknolojisi için bir basamak olacağı düşünülmektedir.

SUMMARY

A DATA COLLECTION AND PATTERN RECOGNITION SYSTEM FOR DIAGNOSIS OF PARKINSON'S DISEASE

Parkinson's disease is a neurologic defect that causes partial or full loss in motor reflexes, speech, behavior, mental processing and other vital functions. It is generally observed in old people and causes disorders in speech and motor abilities (writing, balance etc.) of 90% of patients.

Nowadays important data of these patients such as age, gender, treatment process is stored. In addition to this data, also handwriting and speech samples which can make important contributions to monitor progress and treatment of the disease are kept. But this data is usually left on paper work and not used to monitor any amelioration/deterioration in patient's situation or make statistical forecasts about progress of disease.

In this study, I aimed to prepare a system which saves and analyzes such data of patients. This system saves patients' social and disease informations. In addition to these data created speech database system for patients' voice records. Also, in order to understand accuracy of the data from Parkinson's disease patients, a data bank created for control group which contains healthy people or patients without Parkinson's disease.

In this system we used two classification method which are Support Vector Machines and k-nearest neighbour algorithm to analyse relationship between human voice with Parkinson Disease level. Also we used Minimum Redundancy-Maximum Relevance (MRMR) algorithm to determine hit ratio of analysed features. With this methods, we found that prediction and classification of patients from healthy subjects is possible with correct voice features and samples. As a result of this, system will be a decision support for medical doctors.

The system will decide whether a person is likely Parkinson or not. If not, it will determine whether the person is in risk group or not. As a result the proposed system will be a step for remote diagnosis technology.

1.GİRİŞ

Parkinson hastalığı genelde hastanın motor becerileri, konuşması ve diğer vücut işlevlerinde zarara yol açan bir merkezi sinir sistemi bozukluğudur. İlk kez 1817’de İngiliz Doktor James Parkinson tarafından tanımlanan ve “sallayıcı ya da titrek felç” [1] olarak nitelendirilen hastalık, dünyada 4 milyondan fazla kişiyi etkileyen yaygın bir nörolojik sağlık sorundur. Türkiye’de 200 bin Parkinson hastası olduğu tahmin edilmektedir. Ülkemizde belli bir yaş grubunda Alzheimer’dan sonra en sık görülen hastalık olan Parkinson, beyindeki dopamin maddesinin eksikliğiyle kendini göstermektedir. Hastalık 65 yaş ve üzerindeki her 100 kişiden birinde görülmektedir. Parkinson, sinsi seyreden ve sürekli ilerleyen bir hastalıktır [2]. Yaşla birlikte ağırlaşan ve görülme sıklığı artan hastalığın en önemli belirtisi, ses ve motor fonksiyonlarındaki bozulmalardır. Doktor tarafından yapılan muayene sonunda;

- Kişinin yazdıklarının okunaksız olması, küçük yazmaya başlamak,
- Konuşma bozukluğu, kısık sesle ve donuk konuşmak,
- Yavaş yürümek, yürürken ayakları yere sürmek,
- Vücudun öne doğru eğik bir şekilde durması,
- Depresyon, sıkıntılı ruh hali,
- Yürürken kolların sallanmaması gibi belirtilere rastlanır.

Görülen bu semptomlar kişilerin işlerini ve günlük aktivitelerini tek başlarına sağlıklı bir biçimde yürütmelerine engel olmaktadır. Bu yüzden hastalığın ilk evrelerinde hastanın iş hayatından ve sosyal hayattan soyutlanması, ileri evrelerinde ise yaşamlarını başkalarından yardım alarak sürdürmek zorunda kalmaları hastalığın psikolojik olarak etkilenmelerine neden olmaktadır [3].

Bu çalışma kapsamında hastalığın en önemli belirtilerinden olan konuşma bozukluklarının teşhisi için bilgisayar destekli sistemler kullanılmıştır. Ayrıca zaten toplanmakta olan hasta geçmişi gibi bilgiler de matbu formlardan dijital ortama

geçirilip, bilgilerin saklanması, bilgi güvenliğinin sağlanması, bilgilerin kolaylıkla ulaşılabilir olması, bilgisayar destekli örüntü tanıma ve istatistiksel analiz edilebilmesi mümkün olmuştur.

Son zamanlarda yapılan birkaç çalışmada görülmüştür ki özellikle ses kayıtlarından çıkarılan disfoni yani hastalıktan kaynaklanan ses tellerindeki bozulma, hastalığın teşhisi ve takibinde önemli rol oynamaktadır. Dolayısıyla fiziksel muayene esnasında alınan ses örnekleri dijital ortamda alınarak, doktorlara karar destek sunma mahiyetinde, bilgisayar destekli istatistiksel ve örüntü tanıma yöntemleri ile değerlendirilmiştir. Böylece, hasta bilgilerinin ve bu tür kayıtlarının dijital ortamda tutulmasının yanı sıra, kişinin ileride Parkinson'a yakalanma potansiyeli olup olmadığını ya da ne seviyede hasta olduğunu, tedaviye yanıt verip vermediğini ve hastalığın ilerleme hızını tahmin edebilecek bilgisayar destekli bir sistem kurulması hedeflenmiştir.

Tezin amacı Parkinson hastalığının teşhis ve tedavi aşamalarında bilgisayar destekli veri toplama, saklama ve analizi yapabilecek bir sistem tasarlayarak bu süreci daha kaliteli ve daha kolay kılabilmektir. Bu konuda İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Nöroloji Bölümü veri toplama ve saklama konusunda sıkıntılarının olduğunu bunu yapabilecek bir sistem ile gelen hastaların tedavi aşamalarını daha rahat inceleyebileceklerini, teşhis ve tedavideki sürecin kısılacağını belirtmiştir. Bu doğrultuda çalışmanın ilk basamağı, hali hazırda farklı yöntemlerle alınan hastaya ait ses kaydı, ve hasta geçmişi gibi bilgileri bilgisayar destekli sistemlerle alarak bu bilgilerin dijital ortamlarda saklanmasını sağlamak olmuştur. 50 yaş üzeri 21 Parkinson hastasından alınan bu bilgiler ve ses kayıtları, dijital ortama dökülerek işlenebilecek veri haline getirilmiştir. Daha sonra hastalardan toplanan bu bilgileri istatistiksel analizler ve farklı örüntü tanıma yöntemleri kullanılarak karar destek sistemleri oluşturulmuştur. Karar destek sistemlerden biri, var olan bilgileri kullanarak hastalığın olup/olmadığını, diğeri ise var olan bilgileri ve Birleşik Parkinson Hastalığı Değerlendirme Ölçeği'ni (Unified Parkinson's Disease Rating Scale - UPDRS) kullanarak hastalığın gelişimini, ileride hasta olma ihtimalini tespit etmek amacıyla kullanılmıştır.

Her ne kadar geliştirmesi hedeflenen sistem hasta verilerinin hastane içerisinde bilgisayar destekli toplanması, saklanmasını ve incelenebilmesini içerse de, gelişen

bilgisayar teknolojileri ile hastaların uzaktan izlenmesinin de mümkün kılındığını göz ardı etmemek ve bu sistemin ileride bu hastaların hastaneye gitmeye gerek kalmadan evlerinden de kullanılabileceği daha gelişmiş bir sistemin alt yapısını oluşturduğunu da vurgulamak gerekir. Hali hazırda hastanelerde yapılan bazı fiziksel muayeneleri evlerinde de yapabilme olanağı, bu hastaların çektikleri zorluklar ve ulaşım maliyetlerini azaltmaya da katkı yapabilir. Dolayısıyla, bu çalışmada altyapısı kurulan böyle ileri bir uzaktan teşhis sistemi, hasta, hasta yakınları ve hastane personeli için sosyal, psikolojik ve maddi açılardan büyük kolaylıklar sağlayacaktır.

Genel Kısımlar bölümünde tezde adı geçen Parkinson Hastalığı'nın genel tanımı, erken teşhiste ses ve el yazısı gibi semptomların tedavi sürecindeki etkileri ve bu konuda bugüne kadar yapılmış olan çalışmalardan bahsedilmektedir.

Malzeme ve Yöntemler bölümünde, bu tezde kullanılan, Parkinson hasta ve Sağlıklı kontrol sosyal, fiziksel ve ses kayıt bilgilerinin toplanma aşamaları, ses kayıtlarından öznitelik çıkartılma süreci, bu bağlamda kullanılan yazılımlar ve verideki örüntülerin analizi için kullanılan yöntemler anlatılmaktadır.

Bulgular bölümünde, veri toplama işlemi sonucunda Parkinson hastalığına sahip olan hastalar ile kontrol gruplarının istatistiksel ve örüntü tanıma yöntemleriyle karşılaştırılmaları ve bu karşılaştırmalar sonunda elde edilen bulgular incelenmiştir.

Son olarak Tartışma ve Sonuç bölümünde, elde edilen sonuçların, literatürdeki veriler ile olan uyumu ve tez paralelinde ileride yapacağım çalışmalardan bahsedilmektedir.

2. GENEL KISIMLAR

2.1. HASTALIĞIN TANIMI

Parkinson hastalığı ilk kez 1817 yılında İngiliz hekim James Parkinson tarafından, “shaking palsy” diğer adıyla titrek felç ismiyle tanımlanmıştır [1]. Günümüzde bu araştırmacının adıyla anılan ve bugünkü anlamda felç özelliği taşımayan hastalık, tanınması gereken en önemli ve en sık görülen parkinsonizm tipidir. Parkinsonizm kelimesi belirli bir hastalıktan çok, değişik nedenlerle ortaya çıkan bir dizi belirtille tanınan bir durumu çağırır [3].

Parkinson Hastalığı (PH) genellikle 50 yaş üstü kişilerde ortaya çıkan belirtileri yavaş seyredip artan biçimde ilerleyen nörolojik bir hastalıktır [1,3]. Tüm Parkinson hastalarının sadece %5 ila 10’unda hastalık başlangıcı 20 ila 40 yaşları arasındadır. Parkinson hastalığının çıkış sıklığı genellikle aynıdır [3,4]. Erkeklerde, kadınlarda bu hastalığın görülme oranı 4/3 oranında daha fazladır [2].

Parkinson hastalığı başlangıçta anlaşılabilir, çünkü hastalık semptomları genellikle rahatsız edici düzeye gelene kadar hasta tarafından fark edilmez yada göz ardı edilir [2]. Başlangıç dönemindeki bu belirsiz semptomlardan sonra istirahat tremoru, akinez/bradikinezi, rijidite gibi belirtiler ortaya çıkar [3]. Motor belirtiler ortaya çıkmadan önce hastada çabuk yorulma veya kişiliklerinde değişimler gözlemlenebilir. Genellikle hastalar kol ve omuzlarındaki ağrıdan yakınabilirler. Muayene sırasında stres altında oldukları için el parmaklarında veya ayaklarında istirahat tremorunda artışlar görülür. Ayrıca yürürken kolun az sallanması ve aynı anda elde titreme semptomu denilen “tremorun” oluşması, hastalığın teşhisi açısından göz ardı edilmemesi gereken bulgulardır [5].

Hastalığın motor belirtileri genellikle istirahat tremoru ile başlar. Hastalık boyunca tremordaki düzensizlik devam eder. Her hastada değişen düzeylerde bradikinezi vardır.

Hasta dikkatle incelendiğinde günlük basit işlerde güçlük yaşadığı görülür. Düğme iliklemede güçlük, yazılarda küçülmeler veya ivme değişikliği, genel anlamda yavaş hareket etme ve alet kullanmada zorlanmalar hastalığın uzun süreden beri var olduğunu ortaya çıkartabilir. Hastaların başvuru yakınmaları arasında yürüyüş, rijidite ve postür ile ilgili refleks mekanizmalarını etkilenmesine bağlı olarak sandalyeden zor kalkma, yatakta dönme veya dengeyi sağlama güçlüğü yer alabilir. Bazı hastaların yüz ifadelerindeki donukluklar veya duruşlarında kamburlaşma hastalığın belirtileri arasında gösterilebilir. Bu belirtilerle beraber bu tezde üzerinde çalışılan konu, fonasyondaki değişimler, volüm kayıpları ve disfoni yani sesin yapısının bozulması gibi belirtilerde mevcuttur [5,6].

2.2 PARKINSON HASTALIĞININ KLİNİK ÖZELLİKLERİ

Parkinson hastalığının kardinal özelliklerini 4 ana madde halinde TRAP adı altında gruplanabilir; Tremor, Rijidite, Akinezi-Bradikinezi ve Postural İnstabilite. Bunlara ek olarak vücuttaki eğiklik ve motor fonksiyonlarında donma gibi özellikler Parkinson hastalığında sıklıkla karşılaşılan belirtilerdendir.

Hastalık seyri boyunca hastalığın ilerleme veya gerileme gibi durumlarını kontrol etmek için bazı yöntemler kullanılmaktadır. İlk olarak hastalar Hoehn-Yavr adı verilen ve semptomların tek veya çift oluşu, düşmelerin ortaya çıkması, denge sorunları, destek gereksinimi veya yatağa bağımlı hale gelme gibi aşamalara göre değerlendirilirler. Ayrıca hastalık semptomlarının artışı veya azaldığını değerlendirmek ve hastaların tedaviye verdikleri tepkiyi izlemek için mental, ses ve motor fonksiyon testi yani “Birleştirilmiş Parkinson Hastalığı Değerlendirme Ölçeği (UPDRS)” kullanılır.

2.2.1 Tremor

İstirahat tremoru Parkinson hastalığında karşılaşılan en genel ve en erken ortaya çıkan semptomlarından biridir. Bu tremorlar tek taraflı olup, hareket esnasında veya uykuda ortadan kaybolur, fakat belli bir süre sonra tekrar belirir. Sıklıkla işaret ve baş parmağın ritmik hareketi ile şekillenir. Bazı hastalarda el ve kolun basitçe öne arkaya hareketi şeklinde olabilir. İstirahat tremoru ayrıca dudaklarda, çenede de görülebilir. Buna bağlı olarak seste titreşimler oluşturabilir. Tipik frekansları 4 ile 6 Hz düzeyinde seyreder.

Tremor diğer kardinal belirtilere göre daha yavaş bir ilerleme gösterir. Hastalığın ileri dönemlerinde yüz, dudaklar, dil ve çenede de tremor görülebilir. Alt ekstremitelerde tremor hasta yatar veya oturur pozisyonda iken ortaya çıkar, ayaklarda pedala basar tarzdadır [5].

Bazı hastalarda bu titreşimler vücudun içerisinde yani gözle görülmeyen biçimde gerçekleşir. Bu durum “internal tremor” olarak adlandırılır. Hastalarda ayrıca postural ve kinetik tipte aksiyon tremorları gözlenebilir, ancak hastalıkta ön planda değildirler [5].

2.2.2 Rijidite

Rijidite, hastanın boyun veya gövdesinin pasif hareketi esnasında hekimin her yöne ve tüm hareket genliği boyunca hissettiği dirence verilen addır. Hareketin hız ve şiddetinden etkilenmez. Sıklıkla ensefalopatilerde ortaya çıkan ve aralıklı devam eden “gegenhalten” ise uygulanan bir kuvvete karşı ortaya çıkan tonus artışıdır [3,5,6]. Rijidite tüm kas gruplarında görülebilir. Hareket boyunca kesintili olarak algılanması, altta gözle görülen veya görülmeyen istirahat tremorunun da var olduğuna işaret eder [5].

Rijidite istemli hareket hızını sınırladığı halde, rijiditesi olan bazı hastalar motor işlevlerini rahat sürdürebilirler ve bradikinezi, hastanın özürülüğünde rijiditeden daha belirleyici bir rol oynar [5].

2.2.3 Akinezi/Bradikinezi

Vücutta hareketin olmayışına akinezi, hareketlerin yavaşlamasına ise bradikinezi denir. Bradikinezi Parkinson hastalığının en önemli karakteristik klinik özelliklerinden olmakla beraber, depresyon gibi bazı hastalıklarda da görülebilir. Hastalarda sadece istemli motor hareketlerinde değil aynı zamanda mimiklerinde, yürürken kollarını sallamada veya yutkunma gibi istem dışı hareketlerde de azalma görülür. Akinezi ve bradikinezi semptomları neredeyse tüm PH hastalarında bulunur [6,7].

Diğer Parkinson semptomlarında olduğu gibi, bradikinezi hastanın mental durumuna bağlı olarak değişir. Örneğin bradikinezi hareketsiz bir hastanın, aynı ortamda yangın

var diye bağırıldığında koşması gibi duyuşsal uyarımlarla deęişkenlik göstermektedir [6].

Hastalığın ilk dönemlerinde hareket şiddetinde azalma söz konusuyken zamanla bu duruma bradikinezi veya akinezi de eklenir. Bu durum önce parmak uçları, el gibi küçük kaslarla kısıtlıyken, ilerleyen dönemlerde tüm kas grupları da bundan etkilenmeye başlar. Bu sebeple, PH elin sürekli yapması gereken motor işlevler veya düğme ilikleme gibi kompleks motor işlevlerde zorlanmalar meydana getirir. İşaret parmağı ile başparmağın birbirine ardı sıra deędirilerek tekrarlanan hareketlerde frekans ve şiddet azalması gözlemlenir. Hastaların konuşmaları monoton ve alçak seste yani hipofoniktir. Bazı basit kelimelerin tam olarak ifade edilemedięi, kelimeler arasında duraklama yapılmadan, bütün kelimelerin bir arada okunduęu taşifemi adı verilen bir konuşma görülür [5,7].

2.2.4 Postüral Instabilite

Vücudun dik durmasını, yürüyüş esnasında dengemizi kaybetmemek postüral refleksler sayesinde olmaktadır. Postüral reflekslerin dengesizlięi, PH belirtileri arasında en fazla engele neden olanı ve tedaviye en az yanıt veren semptomlarındanır. Hastada önce kol ile başlayan, daha sonra buna gövde ve boyunda eklenerek öne eğik bir postür gelişir. Hasta zamanla düşme eğilimi gösterir. Bu refleksler test edilirken hastadan yaklaşık 10-15 adım yürümesi ve geriye dönmesi istenir. Sağlıklı kişiler normalde, dönerken fazladan bir adıma ihtiyaç duymazlar. Ancak Parkinson hastaları sıklıkla iki yada daha fazla adım atarak yön deęiştirir veya düşme meyli gösterir. Başka bir uygulamada hekim hastayı geriye doğru çeker. Normalde hasta en fazla bir veya iki adım geriye gelmeli, sonrasında durmalıdır. Postüral refleksleri azalmış bir hasta sandalyeye oturma girişiminde aniden, kontrol- süz bir biçimde sandalyeye çöker. Bu belirtiyeye de “sitting en bloc” adı verilir [5].

Öne eğik gövdenin denge merkezini koruyabilmek ve düşmemek için adımlarını öne atan hasta arkadan itiliyormuşçasına gitgide daha hızlı yürür. Yürüyüşte meydana gelen bu deęişikliğe “festination” adı verilir [5].

2.2.5 Parkinson Hastalığında Konuşma Bozukluğu

Parkinson hastalarının ortalama %80'inde hastalığın ilerleyen safhalarında konuşma ile ilgili sorun yaşayacakları bilinmektedir. Bu problemler hastanın monoton veya anlaşılmaz konuşmalarıyla açık bir şekilde belirgin hale gelmektedir. Hastalar konuşurken kelimeler arasında duraksamalar yaşamakta ve bir konuşmaya başlamadan önce normalden daha uzun bir süre beklemektedirler. Bazı zamanlar hastalar, bellek bozukluğu ya da demans hastası izlenimi vermemek için tereddüt yaşamaktadırlar. Diğer zamanlarda konuşma, normalden daha hızlı ve sık olarak aynı kelimeler tekrar yinelenir. Açığa çıkan bu problemlerde hastanın bunama veya bellek bozukluğu sorunu olduğu izlenimi verebilir ve gerçek hastalık geri planda kalabilir [8].

Parkinson hastalığı hastanın düzgün konuşma yeteneğini oldukça fazla etkileyen bir rahatsızlıktır. Bu sebeple, konuşma bozukluğu hastalığın en kötü belirtilerinden biri olarak kabul edilir. Birçok hasta, başka insanlarla açık ve net bir biçimde iletişim kuramadıkları için kendilerini psikolojik olarak diğerlerinden soyutlamaktadırlar. Bu sebeple hastalar kendilerinin demans yani bunama hastalığına yakalandıkları gibi bir hisse kapılırlar [8].

Dizartri Parkinson hastalığı ile ilişkili başka bir konuşma sorunudur. Bu konuşma sorunu, yavaş, zayıf ya da tutarsız konuşma gibi şekillerde kendini göstermektedir. Aynı zamanda sesin tonu ve şiddeti de dizartriden etkilenir ve sonunda konuşma anlaşılmaz hale gelir.

Konuşma kaslarının zayıflaması ve Parkinson rahatsızlığı nedeniyle bu kaslardaki koordinasyon problemleri hastada dizartrinin ortaya çıkmasına sebep olmaktadır. Dizartrinin şiddeti hastadan hastaya değişebilir. Bazı hastalarda bu sorunun çok hafif etkileri olsa da, bazı hastalarda problem çok şiddetli biçimde olabilmektedir.

Konuşma terapileri genellikle bazı hastalarda bu sorunun çözümünde yardımcı olabilir. Ses tellerini ve kaslarını geliştirmek için yapılan ses egzersizleri, Parkinson hastalığından kaynaklanan konuşma zorluklarının düzelmesi konusunda etkilidirler. Ayrıca doğru bir ilaç kullanımıyla beraber yapılan bu egzersiz ve terapiler sayesinde son derece iyi sonuçlar elde edilebilmektedir [8,9].

2.3. PARKİNSON HASTALIĞINDA BİLGİSAYARLI TEŞHİS ÇALIŞMALARI

Parkinson hastalığı teşhis ve tedavisinde bugüne kadar tıbbi muayeneler sonucunda tanı konulmuştur. Hastalığın semptomları fiziksel olarak hastayı etkilediği için teşhisin bilgisayar ile yapılıp yapılamayacağı birçok çalışma için araştırma konusu olmuştur. Günümüzde ise teknolojik gelişmelerin artmasıyla araştırmacılar Parkinson hastalığını uzaktan teşhis için bilimsel çalışmalar yapılmaktadır. Bu çalışmalar özellikle el yazısı ve konuşma üzerinde yoğunlaşmıştır. Aşağıda bu konularla ilgili yapılan örnek çalışmalardan bahsedilmektedir.

Parkinson hastalığının teşhis, takip ve tedavisinde yazı örnekleri büyük önem taşımaktadır. Bunun sebebi Parkinson hastalığının en önemli göstergelerinden olan ellerde titreme ve kişinin yazdıklarının okunaksız olması, küçük yazmaya başlama gibi belirtilerin yazı örnekleri ile tespit edilmesidir. Bu sebeple dijital tablet bilgisayarlar üzerinde alınan yazım örnekleri son zamanlarda yapılan çalışmaların temelini oluşturmaktadır. Bunlardan biri Gemmert ve arkadaşlarının [10] yaşları 54 ile 82 arasında değişen 13 adet kontrol ve Parkinson hastası deneği kullanarak yaptıkları çalışmadır. Bu çalışmada her hastadan, 1,0, 1,5, 2,0, 3,5 cm uzunluklarında 'lllllll' şeklinde 12 tane şablon çizimleri istenmiştir. Çizilen şablonlar üzerinde yapılan ölçümler sonucunda, Parkinson hastalarının 1,5 cm ve üstü şablonlarda kontrol hastalarına göre istenen uzunluğu belirgin bir şekilde tutturamadıkları gözlemlenmiştir. Ayrıca Parkinson hastalarında yazım ivmesinin kontrol grubuna göre oldukça düşük olduğu gözlenmiştir. Böylece Parkinson hastalığı için çizilen karakter boyutunun hasta ve sağlıklı bireylere ayırmada etkili olduğu görülmüştür.

Ünlü ve arkadaşları [11] ise dijital tablet uygulamasına ek olarak yazım sırasında 3 koordinat eksenindeki basıncı ve el hareketlerini kaydeden özel bir elektronik kalem kullanarak Parkinson hastalığını teşhis etmeye çalışmışlardır. Çalışmalarında 28 hasta ve 28 kontrol deneği kullanmışlardır. Bu kişilere yazdırılan farklı örnek şablonlarla birbirlerinden ayırt edici ve x-y yönlerindeki yazım basıncındaki farka dayalı bir özellik çıkarmışlardır. Bu özelliği kullanarak Parkinson semptomlarıyla, normal titreme semptomlarını ayırt edebilmeyi hedeflemişlerdir.

Atilla ve arkadaşlarına benzer bir çalışmayı Aly ve arkadaşları [12] geleneksel kağıt – kalem ortamını korumayı hedefleyerek bilgisayara bağlı bir dijital tablet üzerinden gerçek zamanlı olarak yapmışlardır. Dijital tablet ve uçlu girdi aygıtı ile yapılan çizimlerin tam zamanı, $x - y$ koordinatları, girdi aygıtı üzerindeki basınç ve kayma miktarı ölçülmüştür. Bu veriler Fourier dönüşümü ile incelenmiş ve Birleşik Parkinson Hastalığı Değerlendirme Ölçeği'ne göre Parkinson hastası olan ve aynı yaştaki kontrol deneklerinin sonuçları çıkarılmıştır. Kullanılan sistemin klinik muayene ve değerlendirmenin yerini tutmayacağı fakat tanı aşamasında yardımcı olabileceği gözlenmiştir.

Bu çalışmalardan farklı olarak Wang ve arkadaşları [13], kişilerin motor reflekslerinin uyumunu ve performansını spiral analiz yöntemini elektronik tabletlerle ölçerek, bu reflekslerin fonksiyonunu ne kadar yitirdiğini veya ne kadar çalıştığını, hastalık hakkında bilgi ve erken teşhis imkanını öğrenmeyi amaçlamışlardır. Hastaların kendi el yazılarıyla üzerine beyaz kağıt tutturulmuş elektronik tablet üzerine çizilen Arşimet spirallerinden aldıkları bilgiler doğrultusunda, hastaları ve normal kontrol deneklerini birbirinden ayırıp sınıflandırma yapabilmışlardır.

Hastalığın en önemli belirtilerinden olan konuşma bozukluğu, kısık ses ve donuk konuşma birçok çalışmaya taban oluşturmuştur. Bu çalışmalardan ilki Little ve arkadaşlarının [14], Parkinson hastalığına bağlı olarak ortaya çıkan disfoniye ölçerek hastalığın şiddetini derecelendirmeyi hedefleyen çalışmalarıdır. Yapmış oldukları çalışmada 31 denek kullanılmıştır bunlardan 23 tanesi Parkinson hastasıdır. Bu kişilere uyguladıkları konuşma testlerini bir mikrofon aracılığıyla kaydedip, sesteki titreşim, ton, ses düzeyi kişiye has özellikleri çıkartıp, hangisinin bu hastalıkta kullanılabileceğini bulmuşlardır. Bu özellikler sayesinde kişinin hastalığının hangi evrede olduğu ve tedavi sürecinin başarısı gibi sonuçları elde etmeyi hedeflemişler ve %94 gibi bir başarı sonucuna ulaşmışlardır.

Benzer bir yöntemle sahip olan fakat kişinin hastalığının ilerleme ya da gerileme eğilimini tahmin etmeyi hedefleyen çalışmalarıyla Tsanas ve arkadaşları [15], 42 Parkinson hastasından topladıkları ~6000 ses kaydıyla konuşmadaki ses özelliklerini sinyal işleme algoritmaları sayesinde karakterize ederek, kullanılabilir özelliklerini ayırt

etmişlerdir. Diğer çalışmada olduğu gibi bu çalışmada da mikrofon aracılığıyla yapmış oldukları konuşma testleriyle bu özellikleri çıkarabilmişlerdir.

Little ve arkadaşlarının çalışmasında çıkarılan ses örneklerini kullanarak yaptıkları çalışmada Revett ve arkadaşları [16], örneklerden elde ettikleri çeşitli frekansları kullanılarak kurallar çıkarmışlardır. Daha sonra bu kurallar filtreleme yöntemleriyle azaltılmış ve sınıflandırma algoritmasına verilmiş, %90 başarı sağlanmıştır. Bu çalışma aslında yöntemi denemek amaçlı yapılmış ve Parkinson benzeri hastalıklarda elde edecek verim, çalışmanın bir sonraki aşamasını oluşturmuştur.

Revett ve arkadaşlarından farklı olarak Tsanas ve arkadaşları [17], bir kişinin hastalığının ilerleme ya da gerileme eğilimini tahmin etmeyi hedefleyen çalışmalarından sonra ses sinyallerini logaritmik olarak dönüştürmüş ve doktorların hastalığın tespitinde sıklıkla kullandığı Birleşik Parkinson Hastalığı Değerlendirme Ölçeği'yle elde edilecek sonuçlara eşleştirmişlerdir. Klasik Birleşik Parkinson Hastalığı Değerlendirme Ölçeği uygulamasının aksine bütün testler hastanın evinde kendi yönetiminde gerçekleşmiştir. Ve logaritmik olarak dönüştürülmüş ses sinyallerinin ham ses sinyallerine göre çok iyi klinik bilgiler sağladığı görülmüştür.

Tez çalışmam da Parkinson hastalığının konuşma üzerindeki etkileri incelenmiş, oluşturulan veri toplama sistemiyle elde edilen veriler karşılaştırılmıştır. Bölüm 3'te oluşturduğum sistem ve kullanılan sınıflandırma yöntemleri hakkında bilgi verilmiştir.

3. MALZEME VE YÖNTEM

Temelde bu çalışmanın iki ana amacı bulunmaktadır. İlki, farklı yöntemlerle toplanan hastaya ait çeşitli bilgilerin dijital platformda birleştirilmesidir. Hasta geçmişi, muayene esnasında hastanın konuşurulması ile alınan ses verilerinin hepsi kendilerine özgü teknoloji bazlı yöntemlerle alınıp dijital ortamda bir arada saklanmıştır. Böylece hastaya ait veriler kolaylıkla saklanıp, görüntülenecek, ve incelenecektir. Diğer amaç ise toplanan verilerin istatistiksel analizler ve örüntü tanıma yöntemleri kullanılarak değerlendirilmesini sağlayacak bilgisayar destekli bir sistem kurmaktır. Bu sistemle gerekli verileri dijital ortamda saklanan bir kişinin ileride Parkinson olabilecek potansiyel bir hasta olup olmadığı, ne seviyede hasta olduğu ve hastalığın ilerleme hızı tahmin edilmesi hedeflenmiştir.

Bu çalışmaya, Kasım 2010-Mayıs 2011 tarihleri arasında Cerrahpaşa Tıp Fakültesi, Nöroloji Anabilim Dalı'nda kayıtları bulunan veya birime gelip Parkinson hastalığı tanısı konan 21 hasta alındı. Ayrıca kontrol gruplarının oluşturulması için yine aynı birimden ve İstanbul Üniversitesi Medikososyal Birimi, İç Hastalıkları Bölümünden 15 kontrol hastası, ve 5 tane tamamen sağlıklı bireyler bu çalışmaya dahil olmuştur. PH ve kontrol grubunda bulunan bireylerin çalışmaya alınma kriterleri aşağıda maddeler halinde verilmiştir.

1. Parkinson Hastalarının 50 yaş ve üzeri olması,
2. Kontrol Grubunda bulunan hastaların Parkinson şüphesi taşımaması,
3. Sağlıklı bireylerin bilinen nörolojik bir hastalığının bulunmaması gerekmektedir.

Yukarıdaki kriterleri sağlayan gruptaki bireylerin bilgileri aşamalı olarak sisteme kaydedilip, istatistiksel analizlerinin yapılabilmesi için kullanılabilir özniteliklerinin çıkartılması ve bahsedilen örüntü tanıma yöntemleriyle analizi gerçekleştirilmiştir.

3.1. VERİ TOPLAMA SİSTEMİ

Bu çalışmada yapılan veri toplama aşamaları iki şekilde yapılmaktadır. Öncelikle hastaların muayene öncesi ve sonrasında bilgilerinin eksiksiz alınabilmesi ve sisteme kaydolabilmeleri için tez için hazırlanan hasta kayıt formunun doldurulması gerekmektedir. Bu sayede her bir hasta için farklı referans numaraları verilip, hasta bilgilerine ulaşmada veya istatistiksel analizin daha rahat yapılabilmesi amaçlanmıştır. Hasta kayıt formları doldurulduktan sonra tamamen sessiz bir ortamda hastalara, içerisinde farklı sesleri bulunduğu kelime grupları söylenilerek günlük hayatta kullanılan bilgisayara bağlı bir mikrofon tarafından ses kayıtları alınmaktadır. Toplanan tüm bilgilerle hasta veritabanı oluşturulmuştur.

3.1.1. Hasta Kayıt Formu

İlk olarak genellikle tüm hastanelerde hemşire ya da hasta kabul görevlileri tarafından bir form doldurularak oluşturulan ve hastanın PH geçmişinin bulunduğu hasta kartlarının veritabanına aktarılması için, özgün bir form oluşturulmuştur. Form üç ana başlıktan oluşmaktadır; “Hasta Bilgileri” , “Hastalık Geçmişi” ve “Fiziksel Muayene”dir. “Hasta Bilgileri” bölümünde hastaların kimlik ve sosyal bilgileri bulunmaktadır. “Hastalık Geçmişi” ise doktor muayenesinden önce hastayı daha iyi tanımak ve hastalığı hakkında bilgi sahibi olmak için oluşturulmuştur. “Fiziksel Muayene” kısmında gelen tüm Parkinson hastalarının fiziksel muayene test sonuçları sayısal olarak bu bölümde kaydedilmektedir. Bunların haricinde “Görüşler” kısmında doktorun veya formu dolduran kişinin hasta hakkındaki değerlendirmeleri, ileride faydalanabilecekleri ortak görüşlerinin bulunduğu bir bilgi bölümü de bulunmaktadır.

3.1.1.1. Hasta Bilgileri

- *Hasta Referans Numarası:* Her bir hastanın farklı dosya numarası bulunduğu için yeni oluşturulan formda da aynı numaralardan yararlanılmıştır. Dosya numarası bulunmayan veya hastaneye yeni kayıt yaptıran hastalar için her biri birbirinden farklı bir referans numaraları oluşturulmuştur. Bu numaralar sayesinde hem doktorun hasta bilgilerine erişimi hem de örüntü tanıma ve istatistiksel analiz işlemleri daha kolaylaştırılması hedeflenmiştir.
- *Adı,*
- *Soyadı,*

- *Yaş,*
- *Meslek,*
- *Öğrenim Durumu,*
- *Cinsiyet,*
- *Sigara Kullanımı:* Her bir hastanın geçmişte veya şuanda kullandığı paket/gün oranı tutulmaktadır. Böylece sigaranın hastalık üzerindeki etkisi de incelenebilmektedir.

3.1.1.2. Hastalık Geçmişi

- *Teşhis:* Bu bölüm, hastaların doktor muayenesi sonucu ortaya çıkan teşhisin bulunduğu kısımdır. Parkinson hastaları için IPH (Idiyopatik Parkinson Hastalığı) kısaltması kullanılmaktadır. Ayrıca aynı bölüm farklı hastalıklar içinde kullanıldığı için farklı hastalıklardan oluşan kontrol grupları da bu form ile kayıt yapılabilmektedir.
- *Hastalık Başlangıcından İtibaren Geçen Süre:* Hastalığın ilk teşhisinden itibaren geçen süre bilgisi bu bölümde yıl cinsinden tutulmaktadır. Bu sayede hastalığın ilerleme durumu, başlangıçla arasındaki farkı daha iyi incelenebilmektedir.
- *Semptomlar:* Parkinson hastalığı birçok hastada farklı şekillerde ortaya çıktığı için doktorun muayene sonucunda gördüğü semptomlarda formlarda bilgi olarak tutulması gerekmektedir. Böylece semptomların hastalığın seyirindeki değişimi veya etkileri kontrol edilebilmektedir.
- *Kalıtım:* Parkinson hastalarının yaklaşık yüzde 10-15'inin ailesinde Parkinson hastalığına yakalanmış başka bireyler de bulunur. Ama hastalığın kalıtsal olduğunu gösteren kesin bir bulgu yoktur. Hastalığın gelişiminde yapısal bir yatkınlığın önem taşıdığı düşünülmektedir. Bu sebeple kalıtım bilgisinin de formda ayrıca tutulması ve sınıflandırma yaparken bu etkeninin de göz önünde bulundurulması gerekmektedir [6,18].
- *Hastalık Seyri:* Parkinson hastalığı seyir hızı ve etkisi farklı dönemlerde değişkenlik göstermektedir. Hastalığın stabilliği, artışı, azalışı veya ilaç kullandıktan sonraki etkileri bu bölümde alınıp veri olarak tutulmaktadır.

3.1.1.3 Fiziksel Muayene

Kayıt formunun son bölümü olan “Fiziksel Muayene” ‘de hasta doktor tarafından fiziksel ve tıbbi muayenelere tabi tutulmaktadır. Muayeneye ek olarak, iki farklı yetersizlik ölçeği kullanılarak alınan rakamsal değerler sayesinde hastanın PH seviyesi belirlenmiştir. Çalışmada Hoehn-Yahr ölçeği ve Birleşik Parkinson Hastalığı değerlendirme ölçeği kullanılmıştır.

Hoehn-Yahr ölçeği Parkinson hastalığının ilerleme belirtilerini tanımlamak için kullanılan yaygın bir sistemdir. 1967 yılında Melvin Yahr ve Margaret Hoehn tarafından “Neurology” dergisinde özgün bir makale olarak yayımlandı. Orijinal ölçekte 1 ile 5 arasında tanımlanan evreler bulunmaktaydı. Fakat daha sonra 0 evresi önerilmiş ve buna ek olarak 1,5 ve 2,5 evreleri de bu ölçeğe dahil olmuştur. Değişikliklerle beraber 0 ile 5 arasında verilen rakamlar, hastanın engellilik evrelerini tanımlamakta kullanılmıştır. 0: Parkinson bulgusu yok. 1: Tek tarafta Parkinson hastalığı belirtileri var. 1,5: Tek taraflı ve aksiyel tutulumlu belirtiler var. 2: İki taraflı Parkinson hastalığı belirtileri var ve yürüme güclüğü yok. 2,5: Çekme testi sonucunda hafif şiddette iki taraflı Parkinson hastalığı belirtisi var. 3: İki taraflı Parkinson hastalığı belirtileri ve çok az yürüme güclüğü var. 4: İki taraflı Parkinson hastalığı belirtileri ve orta derecede yürüme güclüğü var, hasta bu evrede kendi başına yaşayamayacak durumda. 5: İki taraflı Parkinson hastalığı belirtileri var ve hasta yürüyemiyor. Hasta tekerlekli iskemle kullanmak zorundadır ya da yatağa bağımlıdır [19].

Birleşik Parkinson Hastalığı Değerlendirme Ölçeği (UPDRS) Parkinson hastalığı boyunca hastaları takip etmek için kullanılan bir değerlendirme ölçeğidir. On/Off dönemi adı verilen hastanın ilaç kullanmadan önce veya kullandıktan sonraki durumlarına göre ayrı değerlendirilir. Aşağıda maddeler halinde verilen bölümlerden oluşmaktadır [20].

- *Mental Durum, Davranış ve Ruhsal Durum:* 4 sorudan oluşan, toplam 16 puanlık bu bölümde, hastayla ile yaklaşık 10 dakika süren bir görüşme yapılır. Görüşme sonunda hastadaki entelektüel yıkım, düşünce bozukluğu, depresyon ve motivasyon durumlarına göre her bir soru 4 puan üzerinden değerlendirilir.

Puanın yüksek olması, hastanın ruhsal ve mental anlamda kötü olduğunu göstermektedir.

- *Günlük Yaşam Aktiviteleri:* 13 sorudan oluşan, toplam 52 puanlık bu bölümde hastanın günlük yaşam aktivitelerini ne ölçüde yapabildiği test edilir. Konuşma, yutkunma, salivasyon durumu, yazı yazma kabiliyeti, günlük ihtiyaçlarını karşılayabilme, tremor ve Parkinsonizme ilgili duysal yakınmaları bu bölümde incelenir. Puanın yüksek olması, hastalığın hastanın günlük hayatını etkileme seviyesini ne ölçüde arttırdığını göstermektedir.
- *Motor Muayene:* Hastanın motor refleks kabiliyetlerinin değerlendirildiği bu bölüm 14 sorudan oluşmaktadır. UPDRS ölçeğinin 56 puanlık kısmını kapsamaktadır. Muayene esnasında Parkinson hastalığının semptomları hasta üzerindeki etkileri incelenmektedir. Rijidite, konuşmadaki volüm kayıpları, yüz ifadesi, istirahat tremoru, ellerdeki aksiyon veya postüral tremor, parmak frekansları, el hareketlerinin amplitüdü, ayak hareketleri, duruştaki postür durumu ve genel denge testleri yapılmaktadır. Puanın yüksek olması, hastadaki Parkinson hastalığı semptomlarının ne derece arttığını göstermektedir.

Yapılan tüm testler klinik gözlem ve görüşmeler ile yapılmaktadır. Çoğunlukla klinisyen ve araştırmacılar, bir kişinin Parkinson hastalığının ilerlemesini takip etmek için UPDRS ölçeğinin Motor Muayene bölümünden faydalanırlar.

Bilimsel araştırmacılar için ise UPDRS ölçeğinin tamamından faydalanılmaktadır ve bu sayede toplam skora göre hastanın tedaviden aldığı yarar ölçülebilmektedir. Nörologlar ise bu ölçekten semptomların ne derece ilerlediğini görmek için faydalanılmaktadır [21].

Zamanla UPDS puanları hastalığın ilerlemesi hakkında öngörülerde bulunur. Örneğin bazı hastaların belirtileri hafif bir titreme ile başladığı için motor skoru ilk dönemlerde 10'dan daha düşük çıkabilmektedir. Fakat hastaların çoğu için "mental durum, davranış ve ruh hali" skorları bu dönemde biraz daha fazlalaşabilmektedir. Bu yüzden toplam skordaki değişimlerin hastalığın her döneminde incelenmesi Parkinson hastalığının tedavisinde büyük önem taşımaktadır [22].

3.1.2. Ses Kayıt Veritabanı

Bir kişinin Parkinson hastası olduğunu gösterebilecek bir diğer belirti ise kişinin sesinde oluşabilecek disfoni adı verilen sorunlardır. Disfoni, hastalığın ilk göstergelerinden olmakla birlikte hastalığın belirtilerinin gelişimini takip etmek açısından önemli bir yere sahiptir. Seste gürlük, net olmama, pürüzlülük, düşüş ve titreme disfoniye ait tipik belirtilerdir. Bu belirtiler sese ait çeşitli frekansların analizi ile belirlenebilmektedir. Bu kapsamda şu anda hastanelerde uygulanan sadece muayene sırasında hasta konuşturularak dinlenen ve dijital ortama kaydedilmeyen ses kayıtları mikrofon ile alınmıştır. Çünkü Parkinson hastası bir kişinin sesinden, sesinin titremesine bağlı olarak hastalıkla ilgili erken teşhis sağlanabileceği düşünülmektedir.

Bu bağlamda çalışmada, her bireyle ortalama 2 dakika süren bir konuşma testi yapılmıştır. Alınan bu ses kayıtları, editör programıyla içeriğindeki farklı ses gruplarına göre 26 farklı ses dosyasına ayrılmıştır. Sonuçta 21'i PH hastası, 20'si kontrol grubu olmak üzere toplam 1066 farklı ses dosyası oluşturulup dijital ortamda kaydedilmek ve daha sonra işlenmek üzere veritabanına kaydedilmiştir.

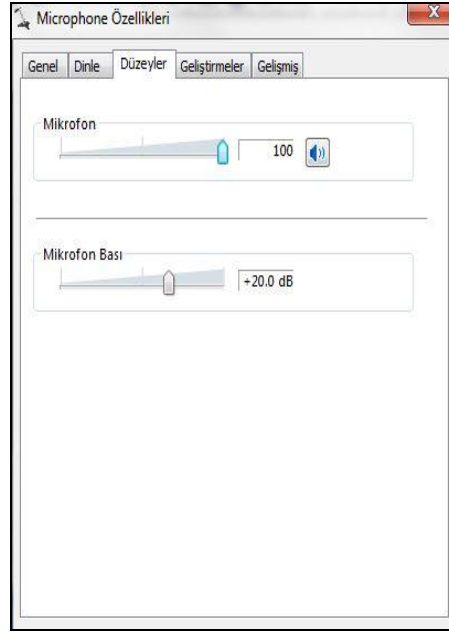
3.1.2.1. Ses Örneklerinin Toplanması

Ses örneklerinin alınması için öncelikle doğru kelime ve ses gruplarının belirlenmesi gerekmektedir. Çünkü hastanın konuşacağı yada çıkaracağı bir ses, Parkinson'u ayırt edici bir bulgu elde etmemizi sağlayabilmektedir. Bu sebeple söylenecek kelimeler seçilirken sesteki değişimin en rahat görüleceği ses grupları bu çalışmada kullanılmıştır.

Parkinson ve benzer nörolojik hastalıklarda ses zayıflaması, telaffuz bozukluğu, konuşma akıcılığında hızlanma gibi konuşma bozukluğu olan hastaların söylediklerini başkalarının anlayabilmesi bazen çok zor olmaktadır. Konuşma kaslarını en iyi şekilde kullanmak ve nefes kontrolünü daha iyi sağlayabilmek için yapılan bazı konuşma egzersizleri bulunmaktadır. Bu egzersizler hastanın en çok zorlandığı kelimelerden ve seslerden oluştuğu için, önceden böyle bir egzersiz ya da alıştırma yapmayan bir hasta için zor olacaktır. Bu sebeple çalışmamda örnek bir ses egzersizinden alınmış 26 farklı kelime ve ses, hastalarda söylenmek üzere kullanılmıştır [23]. Ses örneklerinin alınma prosedürü aşağıda maddeler halinde sırasıyla verilmiştir.

- 1) Derin nefes alınız ve tekrar verinceye kadar sürekli bir ses tonu yaratınız. Sesiniz kuvvetli bir şekilde devam ettiği sürece her bir ses tonunu sürdürünüz. Ses tonu giderek azalıyorsa daha fazla devam etmeyiniz.
 - Nefes alınız “Aaaaaa” deyiniz ve dinleniniz.
 - Nefes alınız “Oooooo” deyiniz ve dinleniniz.
 - Nefes alınız “Uuuuuu” deyiniz ve dinleniniz.
- 2) BİR den ON a kadar sayı sayınız, o sırada her sayı arasında nefes alınız. Her bir sayıyı kuvvetli, güçlü bir tonda söylemeye gayret ediniz.
- 3) Kısa cümlecikler kurarak kelimeleri bir anda akıcı olarak söyleyiniz.
 - Kuş sesi, taşı at.
 - Eve gel, narı al.
 - Şuna bak, pili tak.
 - Topu tut, saati kur.
- 4) Her bir cümlecik için sesinizi hafif yüksek bir ses tonunda kullanarak kısa cümlecikler kurunuz ve tekrarlayınız. Sizi dinleyen kişinin odanın karşı köşesinde oturduğunu düşününüz.
 - Kitap
 - Gülme
 - Korkma
 - Perde
 - Şarkı
 - Saksı
 - Yemek
 - Tente
 - Dolmuş

Çalışmada, yukarıdaki prosedürler uygulanmadan önce ses kayıt sisteminin kurulumu gerçekleştirilmiştir. Ses verileri 44100/saniye örnekleme hızında, *Realtek High Definition* ses kartı mevcut olan kişisel dizüstü bilgisayarda ve *Audacity 1.3 Digital Sound Editor* yazılımı kullanılarak kaydedilmiştir. Öncelikle ortamdaki ses gürültüsünün en aza indirilebilmesi için mikrofon bas düzeyi +20dB düzeyinde tutulmuştur (Şekil 3.1).




Şekil 3.1 : Mikrofon desibel ve volüm ayarları

Gerekli mikrofon ayarları yapıldıktan sonra, hasta mikrofondan 30 cm uzakta olacak şekilde yüzü, kaydı alan kişiye dönük bir biçimde oturtulur. Daha sonra ses editör programı açılıp yeni bir dosya oluşturulur. Dosya ismi hastanın referans numarası olacak şekilde adlandırılır. Hastaya kayıta dikkat etmesi gereken kurallardan bahsedildikten sonra kontrol araç çubuğundan kayıt tuşuna basılarak kayda başlanır.

Kelimelerin uzunluğu hastanın durumuna göre değişkenlik gösterebilmektedir. Bu yüzden kayıt esnasında ses kaydının tekrar alınması gereken durumlar ortaya çıkabilmektedir. PH hastaları kendilerini baskı ortamında olduklarını hissettiklerinde, motor reflekslerinde artışlar gözlemlenir, ellerinde veya ayaklarında titremelerde artış yaşanır. Buna bağlı olarak kelimelerde yanlış telaffuzlar artar, ve her yanlış yaptığını hissettiklerinde heyecan ve stres artışı olduğu için nefeste değişim görülür. Bu da ses kaydını olumsuz bir biçimde etkiler.


Bunun dışında farklı sebeplerde ses kaydının tekrar alınmasını gerektirebilir. Örnek olarak, hastadaki duyma problemleri, ilk seferde söyleneni anlayamama veya söyleyeceği kelimeyi yanlış telaffuz etme gibi çeşitli durumlar gösterilebilir. Bu tür olumsuzluklarda, kayıt alındığı esnada kayıt durdurulmadan uygulanan prosedür tekrar

edilir. Yeterli ve sağlıklı bir kayıt alındığına kanaat getirilirse bir sonraki kelimeye geçilebilir. Her bir kelime veya söz grubu arasında yaklaşık 1-2 saniyelik boşluklar bırakılarak hem hasta açısından rahatlama, hem de ilerde işlenecek ham ses verisinin 26 farklı sese ayrılıp, aradaki istenmeyen sesleri veya gürültülerden kurtulma işlemi de kolaylaştırılmış olur.




Şekil 3.2 : Hastaya ait orjinal ses dalgası formu

Şekil 3.2 te 6212 referans numaralı hastaya ait ses kaydından alınan dalga formunu temsil etmektedir. Ses dalgalarının yoğun biçimde bulunduğu yerler hastanın o anki konuşmasını göstermektedir. 33,5. – 35. saniyeler arasındaki frekanstaki değişim, nefes verme veya mikrofona değme gibi dış etkenlerden kaynaklanan istenmeyen ses frekanslarının oluşması durumunu göstermektedir. Kayıt bittikten sonra böyle bir durumla karşılanılırsa biçimlendirme araç çubuğundan o alan seçilerek düzeltilir, yani sessizleştirme işlemi yapılır. Her bir gürültü ve istenmeyen sesler bu şekilde düzeltilerek yeni ses dalgası formu oluşturulmuş olur (Şekil 3.3).




Şekil 3.3 : Sessizleştirme işlemi sonrasında oluşan yeni dalga formu

Bazı durumlarda hastanın ses frekans düzeyi, yani volümü oldukça azdır, hastanın sesinden daha çok ortamın sesi duyulmaktadır. Bunun sonucunda hastadan veri örneği almak oldukça zorlaşır (Şekil 3.4).



Şekil 3.4 : Ses şiddeti eşik değerinden düşük bir hastanın dalga formu

Bu tip durumlarda hasta biraz daha mikrofona yaklaştırılarak, olabildiğince sesli biçimde kelimeleri söylemesi beklenir. Sonuç alınamazsa kayıt bitiminde, bu tür bölümler editör yardımıyla gürültü filtrelemesinden geçirilir. Bu işlemde öncelikle sadece ortam gürültüsünün olduğu bir örnek profil alınır. Eğer aynı ortamdaysa bir kayıt oluşturularak veya hasta ses kaydı üzerinden hastanın konuşmadığı bölümler seçilerek filtre için gereken profil oluşturulur. Daha sonra gürültü filtresi tüm kayıta uygulanarak ses gürültüden arındırılmış olur (Şekil 3.5). Tüm bu işlemler sonucunda elde edilen ham ses kayıtları, farklı kelime gruplarının birbirinden ayırt edilme işlemi için, önceden referans numaralarına göre oluşturulan klasörlerde kaydedilir.



Şekil 3.5 : Gürültü filtreleme sonrası oluşan ses dalga formu


3.1.2.2. Ses Kayıtlarının Ayrıştırılması

Tüm ses kayıtları toplandıktan sonra, aynı hasta veri çeşitliliği arttırmak ve karakteristik özelliklerini ortaya çıkarmak için ham ses direk olarak işlenilmemektedir. Söylenen her bir kelime veya ses grubu farklı bir veri olarak değerlendirilip parçalanması gerekmektedir. Bazı kayıtlar cümle bazında, bazıları ise tek değerlendirilmesi gerekmektedir. Örneğin hastanın BİR den ON a kadar sayması sırasında ortaya çıkan gecikmeleri ortadan kaldırmak için, her bir sayı ayrı bir kelime olarak değerlendirilmektedir. Böylelikle tek bir hastadan 26 farklı örnek ses dosyası ortaya çıkarılmaktadır (Şekil 3.6).

1394.wav	Length: 00:02:22 Size: 23,8 MB
1394_01.wav	Length: 00:00:00 Size: 87,0 KB
1394_02.wav	Length: 00:00:00 Size: 68,9 KB
1394_03.wav	Length: 00:00:00 Size: 74,9 KB
1394_04.wav	Length: 00:00:00 Size: 74,9 KB
1394_05.wav	Length: 00:00:00 Size: 96,1 KB
1394_06.wav	Length: 00:00:00 Size: 102 KB
1394_07.wav	Length: 00:00:00 Size: 65,1 KB
1394_08.wav	Length: 00:00:00 Size: 59,0 KB
1394_09.wav	Length: 00:00:00 Size: 89,3 KB
1394_10.wav	Length: 00:00:00 Size: 84,7 KB
1394_11.wav	Length: 00:00:00 Size: 91,6 KB


Şekil 3.6 : Hasta ses kayıt örnekleri

Ses kayıtlarının parçalanma işlemi yine “Audacity” ses editör programı ile yapılmaktadır. Öncelikle istenilen kelimenin bulunduğu zaman aralıkları bulunur ve o aralık işaretlenir (Şekil 3.7).



Şekil 3.7 : Ayrıştırılacak kelimenin editörde seçilmesi

İstenilen kelime başlangıçtan bitişe kadar doğru olduğunu test etmek için tekrar dinlenir. Dinleme sonucunda seste kopukluk, eksiklik veya fazlalık varsa aralık arttırılır veya azaltılır. İstenilen dalga formuna ulaşıldığında editör araç çubuğundan “Kırp” seçeneği seçilerek frekans aralığı, orijinal kayıttan ayrılır (Şekil 3.8).



Şekil 3.8 : Kırpma işlemi sonrası ses dalga formu

En son işlem ise sesin dışarı çıkartma yani farklı bir dosya olarak kaydedilme işlemidir. Ses kayıtlarının bütün olarak değerlendirilebilmesi için referans numaralarına ve sıralamalarına dikkat edilmesi gerekmektedir. Parçalanmış ses kaydı önce hasta referans numarası daha sonra ses kaydının sıra numarasına göre “.wav” uzantılı olarak sisteme kaydedilmektedir. Ayrıştırılan 26 ses kaydı ve orijinal dosya her bir hasta için ayrılan

ses kayıt veritabanında saklanmaktadır (Şekil 3.9). Ve böylece veri toplama işlemi bitirilmektedir.

0264-OutputAlındı	Date modified: 30.03.2011 14:15
0853-OutputAlındı	Date modified: 30.03.2011 14:15
1148-OutputAlındı	Date modified: 30.03.2011 14:15
1394-OutputAlındı	Date modified: 30.03.2011 14:15
3656-OutputAlındı	Date modified: 30.03.2011 14:15
4337-OutputAlındı	Date modified: 30.03.2011 14:15
5550-OutputAlındı	Date modified: 30.03.2011 14:15
5670-OutputAlındı	Date modified: 30.03.2011 14:15
5805-OutputAlındı	Date modified: 30.03.2011 14:15
6094-OutputAlındı	Date modified: 30.03.2011 14:15
6097-OutputAlındı	Date modified: 30.03.2011 14:15
6212-OutputAlındı	Date modified: 30.03.2011 14:15

Şekil 3.9 : Ses kayıt veritabanı

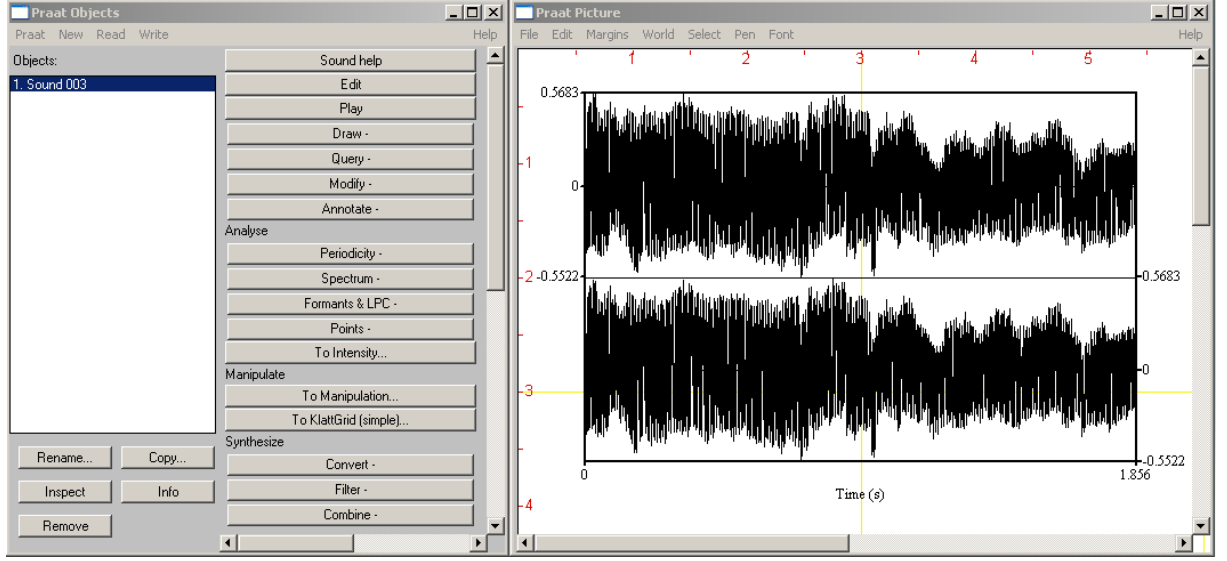
3.2. SESTEN ÖZNETELİK ÇIKARTMA

Çalışmada toplanan ses örneklerinin incelenmesi ve örüntü tanıma işlemlerinin yapılabilmesi için özniteliklerinin çıkartılması gerekmektedir. Bu sebeple ses kayıtları wav formatında Praat akustik analiz programına aktarılarak analiz verileri elde edilmiştir.

3.2.1 Praat Yazılımı

Praat, ses ve konuşma örneklerinden alınan akustik sinyallerin analizi için geliştirilmiş, toplu işlemler için kullanıcıya betik desteği sunan esnek bir yazılımdır. Praat yazılımı ile spektografi, yoğunluk ve atım analizleri yapılabilmektedir.

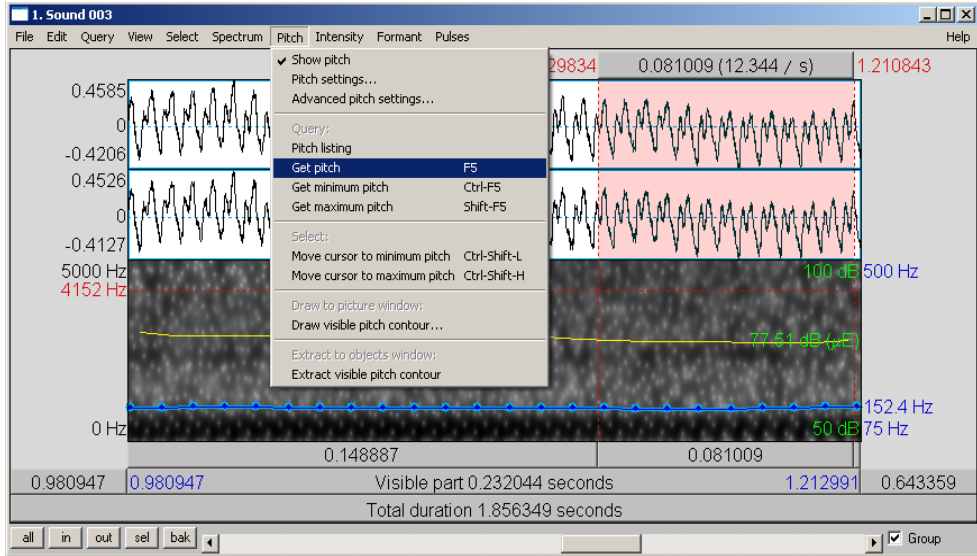
Program çalıştırıldığında şekil 3.10 te görüldüğü gibi iki pencere açılmaktadır. Soldaki pencerede (PraatObjects) yazılımla açılmış olan ses dosyaları listelenmektedir. Sağdaki pencerede (PraatPicture) ise seçilen ses dosyası dalga formunda grafik arayüzde gösterilmektedir.



Şekil 3.10: Praat ana ekranı

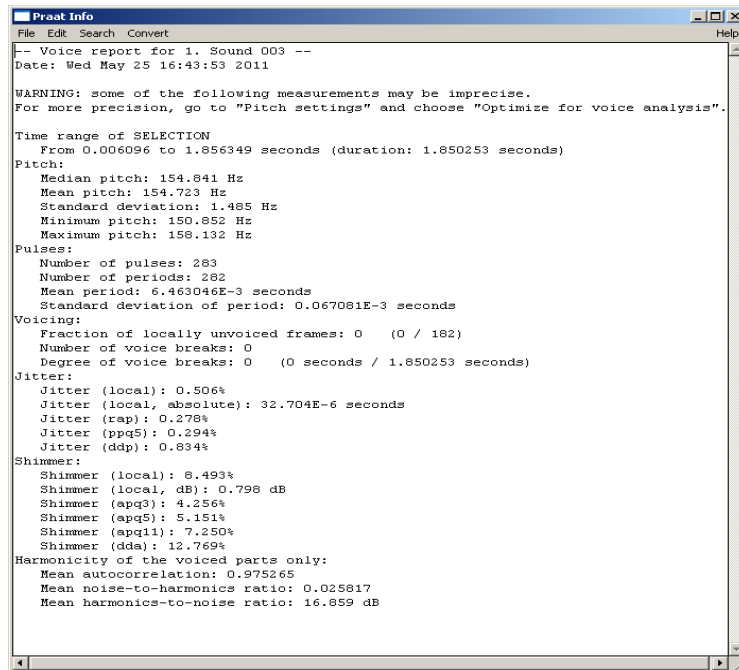
Yazılımda “Edit” menüsü aracılığıyla kayıtlı ses dosyalarının görüntülenmesi, oynatılması ve bu dosyalardan bilgi çıkarımı işlemleri gerçekleştirilebilmektedir. Klinik çalışmalarda en çok kullanılan bölüm burasıdır. Bu menü aracılığıyla bir ses dosyasının dalga formu, yoğunluk, spektrogram ve atım analizi kısaca şu şekilde yapılmaktadır [24]:

1. PraatObjects penceresinde işlenecek ses dosyası seçildikten sonra Edit düğmesine basılır. Eğer kaydedilen sesin sadece belirli bir zaman aralığındaki alt parçası işlenecek ise yeni açılan pencerede bu aralık seçilir.
2. Yeni pencerenin menü çubuğundaki “Pitch” ve “Intensity” başlıkları aracılığıyla dalga formunda görülen ses verisinin üzerindeki atım (mavi noktalar) ve yoğunluk (sarı çizgi) şekil 3.11 de olduğu gibi gözlemlenebilir, “Get Pitch” ve “Get Intensity” seçenekleri ile de seçilen zaman aralığındaki ortalama atım frekansı ve yoğunluk raporlanabilmektedir.



Şekil 3.11 : Örnek bir ses dosyası için dalga formu analizi

3. Ses analizi “Pulses” menüsündeki “Voice Report” bölümünden yapılabilmektedir. Bunun için öncelikle “Show pulses” seçeneği işaretlenmeli ardından da raporu çıkartılmak istenen bölgenin seçimi yapılmalıdır. Bu işlemin ardından seçilen bölgedeki temel özellikleri ve değerlerini listeleyen bir rapor ekrana gelmektedir. Bu rapor şekil 3.12 daki gibidir.



Şekil 3.12: Seçilen ses dalgası için Praat raporu

4. Söz konusu raporda bir grup “Jitter”, “Shimmer” ve diğer özniteliklerin ölçümleri görülmektedir ve aşağıda alt başlık olarak verilen gruplara ayrılmaktadırlar [25].

3.2.1.2. Jitter Sınıfı Öznitelikler

Jitter, vokal kord vibrasyonlarındaki mikro değişikliklerinin temel ölçümlerinden biridir [26]. Sesin temel frekansındaki periyodlar arasındaki kısa süreli pertürbasyonları gösterir [27]. Jitter grubundan 5 farklı öznitelik çıkarılabilmektedir. Aşağıda formülü verilen denklemlerde P: Periyodu, G: Genliği, F: Periyodlar veya genlikler arası farkı ifade etmektedir.

- Jitter (local): Ardışık periyotlar arasındaki mutlak farkların ortalamasının ortalama periyoda bölünmesiyle elde edilir. Bu veri, elde edilen ses örneklemede perdeye ait kısa süreli değişikliklerin göreceli bir değerlendirmesidir [25].

$$J(local) = \frac{\frac{1}{T-1} \cdot \sum_{t=1}^T |P(t) - P(t+1)|}{\frac{1}{T} \cdot \sum_{t=1}^T P(t)} \quad (3.1)$$

- Jitter (local, absolute): Ardışık periyotlar arasında, mikro saniyeler ile ölçülen mutlak farkın ortalamasıdır [28].

$$J(local, absolute) = \frac{1}{T-1} \cdot \sum_{t=1}^{T-1} |P(t) - P(t+1)| \quad (3.2)$$

- Jitter (rap): Relative Average Perturbation (Bağıl Ortalama Değişim) olarak bilinmektedir. Bir periyot ile o periyodun kendisinin ve komşu iki periyodun birleşiminden elde edilen ortalama değer arasındaki mutlak farkların ortalaması bulunur. Bu değer ortalama periyoda bölünür.

$$J(rap) = \frac{\frac{1}{T-2} \cdot \sum_{t=2}^{T-1} \left| P(t) - \frac{P(T-1) + P(t) + P(t+1)}{3} \right|}{\frac{1}{T} \cdot \sum_{t=1}^T P(t)} \quad (3.3)$$

- Jitter (ppq5): Five-point Period Perturbation Quotient (5 Noktalı Period Değişimi Katsayısı) olarak bilinir. Bir periyot ile o periyodun kendisinin ve komşu dört periyodun (sağdan ve soldan 2’şer adet) birleşiminden elde edilen ortalama değer arasındaki mutlak farkların ortalaması bulunur. Bu fark ortalama periyoda bölünür.

$$J(ppq5) = \frac{\frac{1}{T-4} \cdot \sum_{t=3}^{T-2} \left| P(t) - \frac{P(t-2) + P(t-1) + P(t) + P(t+1) + P(t+2)}{5} \right|}{\frac{1}{T} \cdot \sum_{t=1}^T P(t)} \quad (3.4)$$

- Jitter (ddp): Ardışık periyotlar arasındaki ardışık farklar arasındaki mutlak farkın ortalaması bulunur. Bu değer ortalama periyoda bölünür. Praat’taki “Get Jitter” seçeneğiyle elde edilen değer budur.

$$J(ddp) = \frac{\frac{1}{T-2} \sum_{t=1}^{T-2} |F(P(t), P(t+1)) - F(P(t+1), P(t+2))|}{\frac{1}{T} \sum_{t=1}^T P(t)} \quad (3.5)$$

3.2.1.2. Shimmer Sınıfı Öznitelikler

Shimmer sesteki genlik değişimini temsil etmektedir. Shimmer grubundan 6 farklı öznitelik çıkarılabilmektedir. Aşağıda formülü verilen denklemlerde P: Periyodu, G: Genliği, F: Periyotlar veya genlikler arası farkı ifade etmektedir [25].

- Shimmer (local): Ardışık periyotların genlikleri arasındaki mutlak farkların ortalamasının ortalama genliğe bölünmesiyle elde edilir.

$$S(local) = \frac{\frac{1}{T-1} \sum_{t=1}^{T-1} |G(t) - G(t+1)|}{\frac{1}{T} \cdot \sum_{t=1}^T G(t)} \quad (3.6)$$

- Shimmer (local, dB): Ardışık periyotların genlikleri arasındaki mutlak farkların 10 tabanındaki logaritmik değerlerinin ortalaması bulunur. Bu sayı 20 ile çarpılır.

$$S(local, dB) = \frac{20}{T-1} \cdot \sum_{t=1}^{T-1} \log_{10} |G(t) - G(t+1)| \quad (3.7)$$

- Shimmer (apq3): Three-point Amplitude Perturbation Quotient (3 Noktalı Genlik Değişim Katsayısı) olarak bilinmektedir. Bir periyodun genliği ile o periyodun kendisinin ve komşu iki periyodunun genliklerinin birleşiminden elde edilen ortalama genlik arasındaki mutlak farkların ortalaması bulunur. Bu değer ortalama genliğe bölünür.

$$S(apq3) = \frac{\frac{1}{T-2} \sum_{t=2}^{T-1} \left| G(t) - \frac{G(t-1) + G(t) + G(t+1)}{3} \right|}{\frac{1}{T} \cdot \sum_{t=1}^T G(t)} \quad (3.8)$$

- Shimmer (apq5): Five-point Amplitude Perturbation Quotient (5 Noktalı Genlik Değişim Katsayısı) olarak bilinmektedir. Bir periyodun genliği ile o periyodun kendisinin ve komşu dört periyodun genliklerinin (sağdan ve soldan 2'şer adet) birleşiminden elde edilen ortalama genlik arasındaki mutlak farkların ortalaması bulunur. Bu fark ortalama genliğe bölünür.

$$S(apq5) = \frac{\frac{1}{T-4} \sum_{t=3}^{T-2} \left| G(t) - \frac{G(t-2) + G(t-1) + G(t) + G(t+1) + G(t+2)}{5} \right|}{\frac{1}{T} \cdot \sum_{t=1}^T G(t)} \quad (3.9)$$

- Shimmer (apq11): Eleven-point Amplitude Perturbation Quotient (11 Noktalı Genlik Değişim Katsayısı) olarak bilinmektedir. Bir periyodun genliği ile o periyodun kendisinin ve komşu on periyodun genliklerinin (sağdan ve soldan 5'er adet) birleşiminden elde edilen ortalama genlik arasındaki mutlak farkların ortalaması bulunur. Bu fark ortalama genliğe bölünür.

$$S(apq11) = \frac{\frac{1}{T-10} \sum_{t=6}^{T-5} |G(t) - \frac{G(t-5) + G(t-4) + \dots + G(t+5)}{11}|}{\frac{1}{T} \cdot \sum_{t=1}^T G(t)} \quad (3.10)$$

- Shimmer (ddp): Ardışık periyotların genlikleri arasındaki ardışık farklar arasındaki mutlak farkların ortalaması bulunur. Praat'taki "Get Shimmer" seçeneğiyle elde edilen değer budur.

$$S(ddp) = \frac{1}{T-2} \sum_{t=1}^{T-2} |F(G(t), G(t+1)) - F(G(t+1), G(t+2))| \quad (3.11)$$

3.2.1.3. Çıkartılan Diğer Öznitelikler

- Harmonik-Gürültü Oranı (HTN): Akustik periyotluğun derecesini gösterir. Harmonik birimi desibel dir. Bir ses sinyalindeki enerjinin %80'lik kısmı periyodik kısım kalan %20'lik kısmı da gürültü ise HNR değeri $10 \times \log_{10}(\frac{80}{20}) \cong 6dB$ şeklinde bulunur. Harmonik, ses kalitesini ölçmek ve periyodik sinyale sahip herhangi bir dalganın sinyal/gürültü oranını bulmak için kullanılabilir.
- Gürültü-Harmonik Oranı (NTH): Ses dalgasındaki gürültünün periyodik sinyale oranıdır.
- Otokorelasyon (Auto-Correlation): $f(t)$ gibi sürekli bir sinyalin τ birimlik gecikmeye sahip olduğu düşünülürse bu sinyalin korelasyon değeri $R_f(\tau)$ olmak üzere, denklem 3.12 deki gibi hesaplanır:

$$R_f(\tau) = \int f(t)f(t + \tau)dt \quad (3.12)$$

- Bölgesel sessiz pencerelerin oranı (Fraction of locally unvoiced frames): 1 saniye uzunluğundaki bir ses dalgası 0.01 saniyelik 100 adet pencereye bölündüğünde seçilen bir eşik değerinin altında atıma sahip olan pencerelerin sayısıdır.
- Ses kesintisi sayısı (Number of voice breaks): Pitch tabanına bölündüğünde ardışık iki darbe arasındaki mesafenin 1.25'den büyük olduğu aralıkların toplam sayısı.
- Ses kesintisi derecesi (Degree of voice breaks): Ses kesintilerinin toplam süresinin incelenen sesin toplam süresine oranıdır.

3.2.2. Toplanan Özniteliklerin Düzenlenmesi

Şekil 3.12 de görülen özellik grupları her hasta ses kayıt örneği için ayrı bir metin dosyasında saklanmaktadır. PH grubundaki 21 ve kontrol grubundaki 20 kişinin 26'şar ses örneği için toplamda 1066 adet rapor dosyası oluşturulmuştur. Bu raporların tek bir ortamda birleştirip, matris haline getirilmesi için ufak bir uygulama yazılmış ve 1066 x 26 boyutlu bir veri matrisi oluşturulmuştur. Bu matris Şekil 3.13'de excel dosyası formatında görülmektedir.

	A	B	C	D	E	F	G	H	I	J	K
1	Birey_Sample	Jitter (local)	Jitter (local, absolute)	Jitter (rap)	Jitter (ppq5)	Jitter (ddp)	Shimmer (local)	Shimmer (local, dB)	Shimmer (apq3)	Shimmer (apq5)	Shimmer (apq1)
2	0006_01	0,7920000	0,000597	0,4720000	0,4460000	1,4150000	7,6320000	0,7330000	3,8310000	3,8110000	5,52400
3	0006_02	0,9400000	0,000682	0,5380000	0,4500000	1,6150000	8,5610000	0,7670000	4,2790000	4,3760000	7,21100
4	0006_03	0,6520000	0,000479	0,4000000	0,3340000	1,2010000	11,0710000	0,9550000	6,1890000	6,3990000	7,97300
5	0006_04	2,7260000	0,0002147	1,4510000	1,5060000	4,3520000	17,8400000	1,5970000	9,3510000	8,8800000	27,88200
6	0006_05	3,4410000	0,0002553	1,5630000	1,2740000	4,6890000	11,4960000	1,1230000	5,7480000	7,6650000	10,60100
7	0006_06	5,2910000	0,0002827	2,9720000	2,8660000	8,9170000	13,2690000	1,2100000	5,9890000	10,1710000	15,30000
8	0006_07	3,1130000	0,0002254	1,6370000	2,1660000	4,9110000	15,4320000	1,4680000	5,6140000	7,4070000	8,05300
9	0006_08	3,7210000	0,0002884	2,3420000	1,8090000	7,0250000	10,9310000	0,9870000	6,2280000	6,1830000	9,28500
10	0006_09	6,9250000	0,0005205	3,5710000	5,1300000	10,7120000	18,7190000	1,5810000	8,4690000	10,4370000	21,24800
11	0006_10	6,5910000	0,0005014	3,5940000	3,0200000	10,7830000	14,6800000	1,3510000	8,0780000	7,9740000	14,58800
12	0006_11	8,3430000	0,0006145	5,4330000	5,4780000	16,3000000	17,3620000	1,5140000	8,3090000	9,8260000	
13	0006_12	2,8210000	0,0002015	1,4320000	1,5610000	4,2960000	17,2560000	1,5490000	8,4660000	9,2740000	17,92600
14	0006_13	1,4290000	0,0001081	0,5050000	0,4020000	1,5160000	28,5130000	2,2620000	18,7720000	18,3470000	
15	0006_14	3,9060000	0,0002643	1,8330000	2,0530000	5,4980000	15,5110000	1,3860000	7,3970000	9,4930000	26,75800
16	0006_15	1,4920000	0,0001076	0,6140000	0,7950000	1,8430000	11,0470000	1,1000000	4,0920000	5,5160000	11,23900
17	0006_16	2,2620000	0,0001584	0,8890000	1,3670000	2,6670000	12,0780000	1,0950000	4,5910000	5,8800000	11,32400
18	0006_17	2,6560000	0,0001926	1,0510000	1,1310000	3,1520000	14,2750000	1,3740000	6,8770000	9,8750000	10,89400
19	0006_18	4,3170000	0,0002919	1,9580000	1,8100000	5,8750000	12,0850000	0,9990000	6,3680000	6,5580000	
20	0006_19	2,6370000	0,0001911	1,2120000	1,1330000	3,6350000	13,4690000	1,2780000	5,9870000	9,0080000	14,29100
21	0006_20	3,3550000	0,0002293	1,3750000	1,7480000	4,1250000	14,3440000	1,2980000	7,3630000	11,0200000	19,96000
22	0006_21	2,9330000	0,0002239	1,3900000	1,4630000	4,1690000	10,8860000	0,9880000	5,6630000	7,5100000	8,10500

Şekil 3.13 : Toplanan veriler tablosu

Her bireyden 26 adet farklı ses örneği alındığından uç noktadaki örneklerin sınıflandırma başarısını olumsuz yönde etkilemesine engellemek amacıyla, bir ön işleme adımı olarak söz konusu örnek kümelerinin sırasıyla minimum, maksimum, ortalama, standart sapma, maksimum-minimum farkı gibi yeni öznitelikler hesaplanmıştır. Bu işlemle örnek sayısı birey sayısına indirilmiş, öznitelik sayısı 5 katına çıkarılarak 41 x 130 boyutlu yeni bir veri matrisi elde edilmiştir. Bir sonraki adımda bölüm 3.3 te değinileceği gibi bu özniteliklerden sınıflandırma başarısına en yüksek katkısı olan öznitelik alt grupları çıkartılmıştır.

3.3. ETKİLİ ÖZİNTELİK GRUPLARININ SEÇİMİ

Öznitelik seçme yöntemleri girdi boyutunu azaltmaları ve toplam veri kümesinde katkısı fazla olmayan veriyi elemek gibi özellikleriyle örüntü tanıma algoritmalarının daha hızlı çalışmalarına ve daha başarılı sonuçlar elde etmelerine olanak sağlar. Bu sebeple çalışmada etkili özniteliklerin belirlenmesi işlemi için MRMR (Minimum Artıklık Maksimum İlişki) öznitelik seçme yöntemi kullanılmıştır. MRMR yöntemi sınıf bilgileriyle veri kümelerindeki özniteliklerden en ilişkilerini seçerken, diğer bir yandan bu öznitelikler arasındaki artıklığı minimuma indirmeye çalışmaktadır [29].

MRMR algoritması her özneliği birbirinden bağımsız bir rastlantı değişkeni olarak görür ve iki rastgele seçilmiş değişkenler, X ve Y, arasındaki benzerlik bilgisi denklem 3.13 teki gibi ifade edilir.

$$I(X, Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p_1(x) p_2(y)} \right) \quad (3.13)$$

Denklem 3.14 te verilen $p(x, y)$ X ve Y nin birleşik dağılım fonksiyonunu, $p_1(x)$ ve $p_2(y)$ ise X ve Y rastlantı değişkenlerinin diğer bir deyişle özniteliklerinin marjinal olasılık dağılım fonksiyonlarını göstermektedir [22].

MRMR yaklaşımına göre, en iyi $m-1$ adet özneliği barındıran S kümesine eklenecek m . öznelik, denklem 3.14 deki kriteri sağlamalıdır:

$$\max_{x_j \in X - S_{m-1}} \left[I(x_j, T) - \frac{1}{m-1} \sum_{x_i \in S_{m-1}} I(x_j; x_i) \right] \quad (3.14)$$

Denklem 3.14'de verilen X tüm öznelik kümesini; T hedef değişkenini; x_i i. özneliğini; I ise ortak bilgiyi simgelemektedir. Diğer bir ifadeyle, bu kriteri en büyük kılacak yeni x_j özneliğinin T hedef değişkeniyle olan korelasyonunun yüksek, S kümesindeki mevcut özneliklerle olan ikili korelasyonlarının ortalamasının da düşük olması gerekmektedir [30].

Denklem 3.14, yeni eklenecek x_j özneliğinin entropisine bağlı olarak denklem 3.15 te görüldüğü gibi tekrar yazılabilir.

$$\max_{x_j \in X - S_{m-1}} \left[H(x_j) \left(\frac{I(x_j, T)}{H(x_j)} - \frac{1}{(m-1)H(x_j)} \sum_{x_i \in S_{m-1}} I(x_j; x_i) \right) \right] \quad (3.15)$$

Bu denklemde $H(x_j)$ aday özneliğin entropisini simgelemektedir. Buna göre S kümesiyle ve hedeflenen değişkenle (T) olan benzerlikleri arasındaki fark en büyük olan yani T değişkenin tahmini için mevcut özneliklere en çok desteği sağlayan yeni öznelik, S alt kümesine eklenecek bir sonraki eleman olarak seçilir [30].


3.4. ÖRÜNTÜ TANIMA VE İSTATİKSEL ANALİZ

Seçilen öznelikler çok boyutlu bir öznelik vektöründe toplanarak farklı sınıflandırma/regresyon algoritmalarıyla tasarlanmış modellere verilmiştir. Bu modellerin kurulmasında bazı parametrik olmayan sınıflandırma yöntemleri kullanılmıştır. Tezin amacına uygun olarak, bu yöntemlerle kişinin hasta olup olmadığı ve hastalık şüphesi olan hastaların tespiti yapılmış, sonucunda yöntemlerin çalışmadaki doğruluk oranları belirlenmiştir.

Çalışmada kullanılan ses verilerinin istatistiksel analiz ve örüntü tanıma işlemlerinin yapılabilmesi ve karşılaştırılmalarının yapılması için kNN (en yakın k-komşu) ve SVM (destek vektör makineleri) algoritmalarından faydalanılmıştır.

3.4.1. En Yakın k-Komşu Algoritması

Uygulaması kolay, fakat etkili sınıflandırma yöntemlerinden biri *en yakın komşu* yöntemidir. Yöntem sınıfı önceden belirlenmemiş özniteliği, x_{yeni} , kendisine en Öklid mesafesi en yakın olan komşusunun sınıfına bakarak sınıflandırır. Fakat en yakın komşu yöntemi ayrık değerlere karşı çok duyarlıdır. Bu sebeple genellikle aynı algoritmadan türetilmiş benzer bir yöntemden faydalanılır ve yöntem *kNN (en yakın k-komşu)* yöntemi olarak adlandırılır. *kNN* yönteminde en yakın k tane komşu belirlenir. Bu yakınlık belirlenirken seçilen eğitim kümesindeki noktaların mutlak mesafesine bakılır. Bu mesafenin minimum olduğu k komşu belirlendikten sonra, bütün komşuların sınıflarına bakılır ve ağırlığı en fazla olan sınıf seçilir. Mesafenin aynı olması durumunda, k noktadan rastgele biri seçilir veya eşit olan tüm noktalar, k . en yakın komşudan uzak olmayacak şekilde kullanılır. Bazı durumlarda direk olarak sınıfını belirlemek yerine, şüpheli seçeneğini de sınıflandırmada kullanmak işe yarayabilir. Çünkü, eğer kazanan sınıfın oranı belirlenen eşik değerinden düşükse, o konumda tahmin mümkün olmayacaktır [31,32].



Şekil 3.14 : KNN sınıflandırıcı [32]

Şekil 3.14 te veri kümesine yeni eklenen *yuvarlak* örneğin, sınıflandırılmasını göstermektedir. Eğer $k=3$ olarak seçilirse örneğe en yakın 3 komşu belirlenir. Bulunan komşular düz çizgiyle belirlenen dairede görülebilmektedir. Bu durumda yeni gelen örnek, *üçgen* sınıfının daha yoğun olmasından dolayı *üçgen* olarak sınıflandırılacaktır. Bunun dışında k değeri 5 olarak değiştirilirse, kesik çizgiyle belirtilen alan içerisindeki 5 komşu seçilecek ve en fazla olan grup yeni örneğin sınıfını belirleyecektir, yani örnek *kare* sınıfına atanacaktır [32].

En yakın k -komşu algoritmasında k değerinin tek olması olası problemleri ortadan kaldıracaktır. Çünkü çift sayı seçiminde sınıf ağırlığı bazı durumlarda eşit olabileceğinden, genellikle k sayısı tek sayı olarak seçilmektedir. Ayrıca referans alınacak komşu sayısını arttırmak, sınıflandırıcının varyansını düşürmekte, fakat x_i nin kendisinden çok uzaktaki bir değerle de karşılaştırma yapabilmesini, yani eğilimini arttırmasına neden olacaktır. Bu yüzden eğilim-varyans değişkenleri dengenin hata oranını en aza indirecek şekilde yapılması gerekmektedir [31].


3.4.2. SVM (Destek Vektör Makineleri) Algoritması

Destek Vektör Makinesi, diğer adıyla SVM yöntemi, veriyi analiz edip örüntülerinin belirlenmesi için kullanılan, günümüzde oldukça yaygın olarak kullanılan bir algoritmadır. SVM, sınıflandırma ve değişkenler arası bağlantıyı incelemek için kullanılmaktadır. SVM yönteminde girdi olarak oluşturulan veri kümesini ve her bir girdi için belirlenen tahminleri, 2 farklı sınıfa ait olmak şartıyla, kullanılmaktadır. Oluşturulan eğitim veri örnekleri algoritma içerisinde işlenerek verinin modellemesi yapılır [31,33,34].

Bu modelde bulunan, uzay düzlemindeki noktalar her bir örneği temsil etmektedir ve bu noktalar sınıf bilgilerine göre bölünerek birbirlerinden olabildiğince uzak tutulur. Düzlem üzerinde oluşturulan noktalar denklem 3.16 de olduğu gibi tanımlanmıştır [34,35].

$$D = \{(x_i, y_i) \mid x_i \in \mathcal{R}^p, y_i \in \{-1,1\}\}_{i=1}^n \quad (3.16)$$

SVM n-boyutlu bir uzay oluşturarak, noktalar arasında sınır belirler ve iki farklı sınıfa ayırır. Sınır, iki gruba da en uzak olan yerde bulunmalıdır. Algoritma bu işlemi yaparken öncelikle her iki sınıfa da yakın birbirlerine paralel iki sınır çizgisi oluşturur. Daha sonra bu çizgiler birbirlerine yaklaştırılarak sınır çizgisi belirlenir. Yeni eklenen örnekler bu uzay düzlemindeki bulunduğu bölgeye bakılarak, sınıf bilgisi tahmin edilmeye çalışılır [34] (Şekil 3.19).



Şekil. 3.15 : SVM algoritması sonrasında iki sınıf arasındaki sınır çizgileri [33]

4. BULGULAR

Oluşturulan sistem ile 21 i hasta, 20 si kontrol grubu olmak üzere 41 bireyden bilgi toplanmıştır. Bu kişilerin 26 sı erkek, 15 i bayandan oluşmaktadır. Yaş grupları 45-80 yaş arasında değişmektedir. Hasta ve kontrol grubunun listesi tablo 4.1 ve tablo 4.2 de görüldüğü gibidir. Evre, UPDRS ve teşhisten itibaren geçen süre kontrol grubu için söz konusu olmadığından N/A ile gösterilmiştir.

Tablo 4.1 : Ses verisi toplanan hastaların hastalık,cinsiyet ve yaş bilgileri tablosu

Birey Referans No	Cinsiyet	Yaş	Evre (H&Y)	Hastalık Teşhisinden itibaren geçen süre (yıl)	UPDRS
H0001	E	69	2	2	23
H0002	E	60	2	0,5	8
H0170	E	65	2	0,8	16
H0194	E	54	3	4	46
H0264	E	77	2	2	40
H1148	E	52	2	4	11
H1394	K	76	4	6	45
H1418	E	62	1	3,5	12
H3656	E	62	2	2	24
H4337	E	73	2	2	32
H5100	K	61	1	1	23
H5550	E	77	0	0,3	5
H5670	E	72	2	4	31
H5805	E	64	3	10	55
H6097	K	71	2	3	32
H6212	E	60	2	4	26
H9026	K	69	3	5	46
H0148	K	71	2	2	23
H0853	E	55	1	3	20
H6094	E	43	1	1	5
H0003	K	74	3	5	45
H0148	K	60	1	1	5

Tablo 4.2 : Ses verisi toplanan kontrol grubu hastalık,cinsiyet ve yaş bilgileri tablosu
(H&Y: Hoehn ve Yavr Evresi)

Birey Referans No	Cinsiyet	Yaş	Evre (H&Y)	Hastalık Teşhisinden itibaren geçen süre (yıl)	UPDRS
S0001	E	54	N/A	N/A	N/A
S0002	E	60	N/A	N/A	N/A
S0003	K	53	N/A	N/A	N/A
S0004	E	59	N/A	N/A	N/A
S0005	K	74	N/A	N/A	N/A
S0006	E	54	N/A	N/A	N/A
S0007	E	45	N/A	N/A	N/A
S0008	K	50	N/A	N/A	N/A
S0009	E	71	N/A	N/A	N/A
S0010	K	83	N/A	N/A	N/A
S0011	K	67	N/A	N/A	N/A
S0012	E	77	N/A	N/A	N/A
S0013	K	65	N/A	N/A	N/A
S0014	E	53	N/A	N/A	N/A
S0015	K	57	N/A	N/A	N/A
S0016	K	74	N/A	N/A	N/A
S0017	K	47	N/A	N/A	N/A
S0018	E	68	N/A	N/A	N/A
S2542	K	70	N/A	N/A	N/A
S5560	E	70	N/A	N/A	N/A

Referans numaralarıyla belirtilen bireylerden toplanan 1066 farklı ses kaydı örneği SVM ve KNN sınıflandırma algoritmalarında çalıştırılmak üzere öznitelikleri çıkartılmıştır. Çıkartılan öznitelik değerleri öncelikle işlenmeden, tek bir birey için tüm ses örnekleri kullanılarak algoritmaya verilmiştir. Böylece her bir ses kaydı, farklı bir birey olarak değerlendirilmiştir. Fakat sınıf bilgileri sabit tutulduğundan, algoritma 41 bireyi, 1066 farklı örnek gibi algılamaktadır. Daha sonra özniteliklerin sırasıyla maksimum, minimum, ortalama ve standart sapmaları bulunarak tekrar bütün örnekler kişi bazında değerlendirilmiştir.

Tüm bu öznelikler karşılığı olan UPDRS ile korelasyonuna bakılıp hangi özneliklerin sınıflandırmada daha iyi olacağı hakkında bilgi vermektedir. Tablo 4.3 te, kullanılan tüm özneliklerin normal, maksimum, minimum, ortalama ve standart sapmaları hesaplanılarak bulunan değerlerinin UPDRS değerleriyle korelasyonları verilmiştir.

Tablo 4.3 : Çıkarılan özneliklerin UPDRS değerleriyle korelasyonu

Öznelik	Normal-UPDRS	Mean-UPDRS	Max-UPDRS	Min-UPDRS	Std.Sapma-UPDRS
Jitter (local)	0,1972	0,4050	0,2104	0,5331	0,1302
Jitter (local, absolute)	0,2180	0,3635	0,2377	0,4586	0,2403
Jitter (rap)	0,2254	0,4204	0,1743	0,5113	0,0945
Jitter (ppq5)	0,1997	0,4324	0,1136	0,5093	0,0791
Jitter (ddp)	0,2254	0,4204	0,1743	0,5110	0,0945
Shimmer (local)	0,1155	0,1649	0,1179	0,2765	0,0101
Shimmer (local, dB)	0,1272	0,1958	0,2034	0,3215	-0,0552
Shimmer (apq3)	0,0895	0,1315	-0,0883	0,3443	-0,1449
Shimmer (apq5)	0,0703	0,1046	-0,0064	0,4442	-0,0546
Shimmer (apq11)	0,2142	0,4245	0,2417	0,2702	0,2545
Shimmer (dda)	0,0895	0,1315	-0,0883	0,3443	-0,1449
AC	-0,0284	-0,0415	-0,1358	-0,1822	0,1153
NTH	0,0278	0,0412	0,2116	0,1018	0,1606
HTN	-0,0643	-0,1114	-0,2895	-0,1859	-0,2494
Median pitch	-0,0285	-0,0382	0,0383	-0,0841	-0,0046
Mean pitch	-0,0325	-0,0430	0,1442	0,0222	0,0790
Standard deviation	-0,0600	-0,1284	0,1547	-0,1326	0,0486
Minimum pitch	0,0031	0,0045	0,1392	-0,1736	0,1239
Maximum pitch	-0,0501	-0,0961	-0,0141	-0,0008	0,0207
Number of pulses	-0,0025	-0,0087	0,1048	-0,1791	0,1028
Number of periods	0,0010	0,0034	0,1063	-0,1842	0,1072
Mean period	0,0172	0,0198	0,0151	-0,1376	0,0624
Standard deviation of period	-0,0233	-0,0497	0,1601	0,1560	0,0823
Fr. of Local Unvoiced frames	0,0447	0,0950	0,1394	-0,0895	0,1309
Number of voice breaks	-0,0350	-0,1746	-0,2443	0,0000	-0,1965
Degree of voice breaks	-0,0466	-0,1683	0,0018	0,0000	-0,1132

Tablo 4.3 te karşılaştırılan özneliklerde korelasyon değerleri en yüksek değişkenlerin özneliklerin ortalamaları ve minimum değerleri alınarak bulunduğu görülmüştür. Bu sebeple sınıflandırma işlemleri yapılırken, tüm veriyi ham işlemek yerine, özneliklerin ortalaması çıkarılarak ya da minimum değerleri temel alınarak algoritmalara verildiğinde sınıflandırma başarı oranının artması beklenmektedir.

Ses örneklerinin sınıflandırmadaki etkisini belirlemek için her bir ses örneği ayrı ayrı değerlendirilmiştir. En iyi öznetelik seçimi yapılmadan ve her bir bireyi dışarda bırakarak oluşturulan eğitim kümesi, SVM algoritmasında farklı kernel tipleri kullanarak ses örneklerinin başarı oranları incelenmiştir. Test için ise dışarıda bırakılan örnek kullanılmıştır. Elde edilen verilere göre maksimum başarı oranı 07 id numaralı ses örneğinde %73,17 oranında görülmüştür. Aynı şekilde quadratic kernel da %68, polynomial kernel da %63,41 ve son olarak rbf kernel da %60,98 oranında başarı elde edilmiştir. Tablo 4.4 te SVM sınıflandırıcı yöntemi kullanılarak her bir ses örneğinin kernel tipine göre başarı oranları verilmiştir.

Tablo 4.4 : Öznetelik seçimi yapılmadan her bir ses örneğinin SVM yöntemi sonrası kernel çeşitlerine göre sınıflandırma başarı oranları

	SVM Sınıflandırıcı Yöntemi (%)			
	linear	quadratic	polynomial	rbf
Örnek 01	63,41	56,10	53,66	14,63
Örnek 02	63,41	53,66	51,22	21,95
Örnek 03	58,54	51,22	53,66	19,51
Örnek 04	56,10	65,85	60,98	36,59
Örnek 05	51,22	56,10	63,41	53,66
Örnek 06	68,29	51,22	58,54	17,07
Örnek 07	73,17	63,41	60,98	60,98
Örnek 08	58,54	58,54	60,98	51,22
Örnek 09	51,22	65,85	56,10	39,02
Örnek 10	58,54	63,41	60,98	48,78
Örnek 11	56,10	51,22	43,90	19,51
Örnek 12	43,90	56,10	53,66	53,66
Örnek 13	41,46	39,02	51,22	46,34
Örnek 14	41,46	56,10	53,66	41,46
Örnek 15	65,85	53,66	58,54	36,59
Örnek 16	46,34	48,78	41,46	9,76
Örnek 17	56,10	68,29	60,98	36,59
Örnek 18	60,98	43,90	51,22	41,46
Örnek 19	36,59	48,78	31,71	43,90
Örnek 20	56,10	51,22	60,98	34,15
Örnek 21	43,90	53,66	53,66	39,02
Örnek 22	34,15	53,66	51,22	12,20
Örnek 23	48,78	46,34	48,78	46,34
Örnek 24	46,34	31,71	53,66	17,07
Örnek 25	73,17	46,34	48,78	17,07
Örnek 26	60,98	53,66	63,41	53,66
Ortalama	54,41	53,38	54,13	35,08

Aynı işlem KNN yöntemi kullanılarak yapıldığında ise toplam başarı oranında düşüş olduğu fakat maksimum başarının oranın arttığı gözlemlenmiştir. 10 id numaralı ses örneğinin en yakın 3 komşu seçildiğinde %73,17 lik başarı performansını verdiği görülmüştür. Ayrıca gözlemlenecek en yakın komşu sayısının arttıkça başarı oranın düşeceği belirlenmiştir.


Tablo 4.5: Öznitelik seçimi yapılmadan her bir ses örneğinin KNN yöntemi sonrası en yakın komşu sayılarına göre sınıflandırma başarı oranları (k=en yakın komşu değeri)

	KNN Sınıflandırıcı Yöntemi (%)				
	k=3	k=5	k=7	k=9	k=11
Örnek 01	41,46	48,78	43,9	43,9	41,46
Örnek 02	53,66	46,34	43,9	46,34	46,34
Örnek 03	46,34	51,22	41,46	48,78	36,59
Örnek 04	63,41	46,34	41,46	48,78	46,34
Örnek 05	63,41	70,73	65,85	70,73	65,85
Örnek 06	60,98	63,41	65,85	63,41	63,41
Örnek 07	63,41	56,1	53,66	63,41	60,98
Örnek 08	51,22	58,54	58,54	53,66	51,22
Örnek 09	51,22	51,22	53,66	51,22	56,1
Örnek 10	73,17	60,98	70,73	68,29	48,78
Örnek 11	46,34	36,59	51,22	46,34	43,9
Örnek 12	51,22	53,66	39,02	43,9	48,78
Örnek 13	46,34	46,34	46,34	36,59	31,71
Örnek 14	43,9	46,34	34,15	36,59	41,46
Örnek 15	60,98	43,9	46,34	39,02	46,34
Örnek 16	39,02	46,34	56,1	48,78	41,46
Örnek 17	68,29	68,29	68,29	68,29	58,54
Örnek 18	43,9	46,34	51,22	39,02	43,9
Örnek 19	39,02	43,9	39,02	34,15	34,15
Örnek 20	43,9	43,9	43,9	48,78	53,66
Örnek 21	46,34	41,46	41,46	43,9	48,78
Örnek 22	48,78	43,9	36,59	39,02	43,9
Örnek 23	58,54	53,66	53,66	58,54	39,02
Örnek 24	43,9	48,78	39,02	31,71	43,9
Örnek 25	56,1	60,98	56,1	53,66	63,41
Örnek 26	43,9	48,78	48,78	53,66	53,66
Ortalama	51,88	51,03	49,62	49,25	48,22

Herhangi bir öznitelik seçimi yapılmadan, tüm öznitelikler kullanılarak alınan sonuçların başarı oranları %50 civarında seyretmiştir. Bununla beraber MRMR yönteminin sistem üzerinde ne kadar etkili olduğunu görmek için bütün veriler algoritmaya verilmiş, en iyi sonuç veren öznitelikler belirlenmiştir. Alınan sonuçlara göre en iyi 5 özneliğin sırasıyla Otokorelasyon(AC), Shimmer (APQ11),

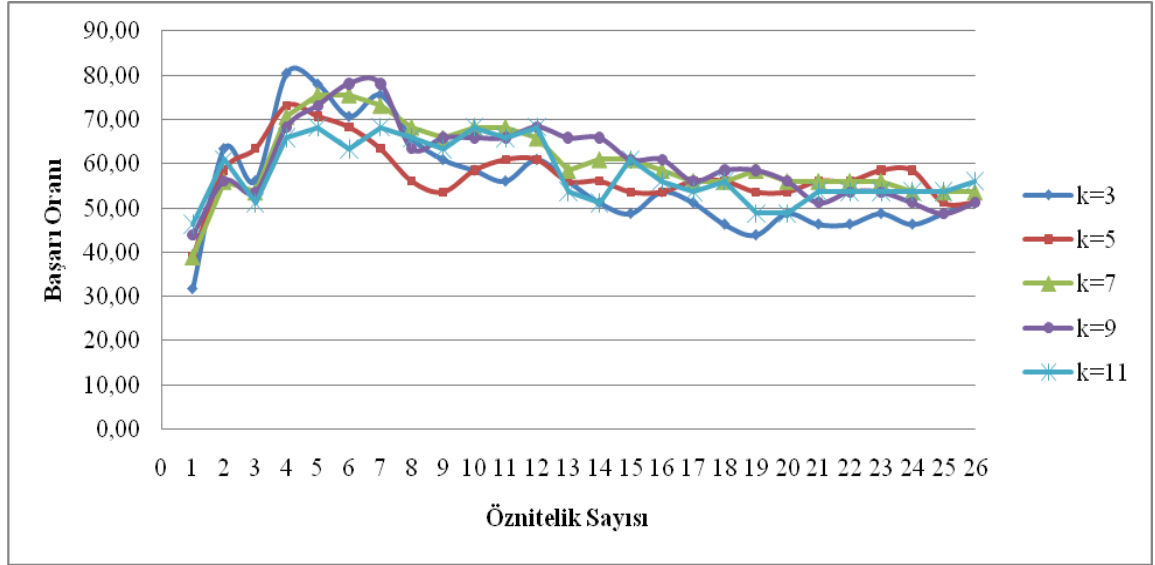
Standard Deviation of Period, Ses Kesinti Derecesi ve Gürültü-Harmonik Oranı (NTH) olduğu belirlenmiştir. Kullanılan en iyi öznitelikler sırasına göre SVM ve KNN yöntemleriyle test edilmiştir.

SVM yönteminde her bir ses örneği tek tek incelenmiş olup, en iyi örneğin 09 id numaralı örnek yani “ALTP” kelimesinin olduğu belirlenmiştir. Farklı kernel çeşitleri kullanılarak yapılan testlerde en iyi öznitelikler birer birer artırılıp başarı oranındaki değişim gözlemlenmiştir. Şekil 4.1 de grafiği verilen test sonuçlarına göre, en yüksek başarı oranlarının en iyi 5 öznitelik kullanıldığında elde edildiği görülmüştür. Bunun yanı sıra RBF kernel tipinin %78.04 lük bir oranla en yüksek başarı oranı verdiği görülmüştür. Fakat kullanılan öznitelik sayısının artmasıyla RBF kernel tipinde ciddi bir düşüş yaşandığı, diğer kernel çeşitlerinin daha istikrarlı olduğu görülmüştür.



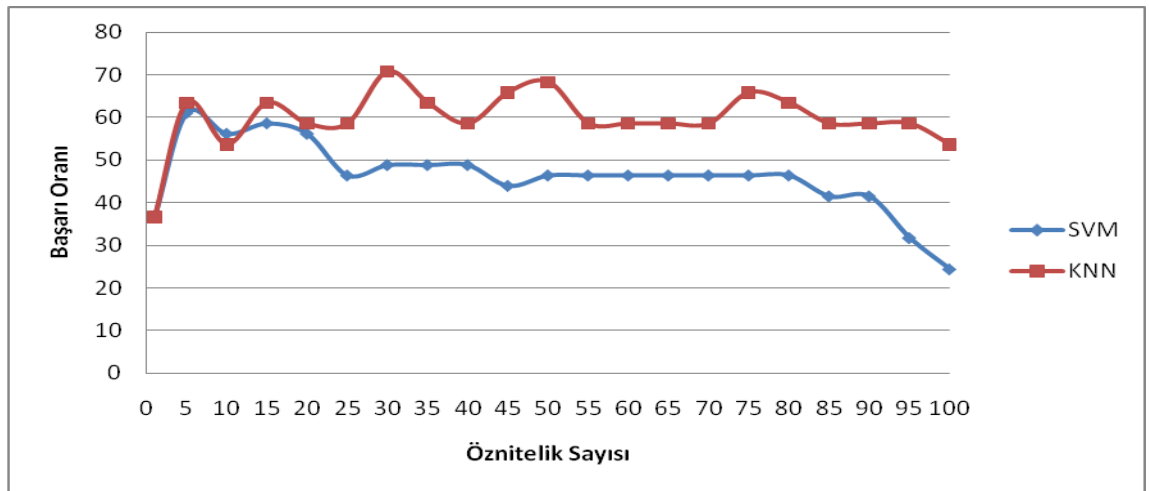
Şekil 4.1 : 09 numaralı ses örneğinin kernel parametrelerine göre SVM yöntemi başarı grafiği (Linear, Quadratic, RBF, Polynomial)

Aynı test KNN yöntemi üzerinde uygulandığında, 09 id numaralı ses örneğinin başarı oranının diğerlerinden daha fazla olduğu görülmüştür. En iyi 5 öznitelik ve en yakın 3 komşu seçilerek maksimum başarı oranı %73.17 bulunmuştur. Şekil 4.2 de verilen grafikte en yakın komşu değerlerinin, öznitelik sayısına bağlı doğruluk oranları gösterilmektedir.



Şekil 4.2 : 09 numaralı ses örneğinin en yakın komşu parametrelerine göre KNN yöntemi başarı grafiği (k=3,5,7,9,11)

Tezde yapılan son çalışmada, KNN ve SVM yöntemleri bütün ses örnekleri üzerinde denenmiş, minimum, maksimum, standart sapma, ortalama çıkartılarak bulunan öznitelikler MRMR algoritmasına verilerek en iyi öznitelikler belirlenmiştir. Sınıflandırmada kullanılan özniteliklerin sayısı her iki sınıflandırma yöntemi içinde farklı noktalarda optimumdur. Sistem için KNN nin SVM e göre daha kararlı olduğu görülmüştür. Şekil 4.3 te verilen grafikte, tüm ses örnekleri için MRMR yöntemiyle seçilen öznitelik sayılarının iki yöntem üzerindeki başarı oranı değişimi gösterilmektedir.



Şekil 4.3 : Tüm ses örnekleri kullanılarak MRMR yönteminde seçilen öznitelik sayılarına göre knn-svm sınıflandırma yöntemleri başarı grafiği

5. TARTIŞMA VE SONUÇ

Ülkemizde, Parkinson hastalığı ile ilgili yapılan çalışmalar çok kısıtlı, bilgisayar destekli karar destek sistemlerinin hastanelerde kullanımı da pek yaygın değildir. Her ne kadar sesten Parkinson teşhisi 2000li yıllarda yurt dışında yapılmaya başlanmışsa da, farklı araç-gereçlerle ses ve yazı ölçümleri yaparak bu verileri örüntü tanıma yöntemleri kullanarak hastaların Parkinson hastalığıyla ilgilerini tespit edecek olan çalışma sayısı oldukça azdır.

Bu tezde, hastaların ses bilgilerini dijital ortamda alarak ve sistemde var olan bir hastanın varsa veritabanından eski ses kayıtlarını da kullanarak, bu verilerin istatistikî analizini yapan ve böylece doktorlara bilgisayarlı bir karar destek sistemi olarak kullanılacakları bir sistem geliştirilmiştir. Bunun yanında yazı ve ses analizi gibi konularda, doktorun kendi duyu organlarını kullanarak yapacağı şahsi çıkarımlarına destek mahiyetinde, örüntü tanıma yöntemleriyle bu verilerden Parkinson ile alakalı doneleri eksiksiz olarak çıkartmaya yardımcı olması hedeflenmiştir.

Oluşturulan veri toplama sisteminde farklı kişilerden birçok ses verisi toplanmıştır. Bu verileri hasta olup olmama durumuna göre sınıflandırma yapılmıştır. Oluşturulan farklı eğitim seti algoritmalara sunularak, farklı iki yöntemle sınıflandırma yapılmıştır. Bunlardan biri destek vektör makineleri (SVM) algoritması diğeri ise en yakın k-komşu algoritmasıdır. Ses verilerinden öznitelik çıkartılmasında Praat akustik analiz programı, özniteliklerin sınıflandırılmasında ise MATLAB teknik programlama dili kullanılmıştır.

Öncelik çıkartılan özniteliklerin her biri UPDRS skorlarıyla korelasyonları hesaplanarak sınıf bilgisini taşıyan en iyi özniteliklerin, her bir hastanın 26 örneğinin jitter ve shimmer özniteliklerinin ortalaması ve minimum değerleri olduğu belirlenmiştir.

Öznitelikler dışında her bir örnek kelime bazında da değerlendirmiştir. Çünkü söylenen bazı kelimelerdeki karmaşıklık ya da sadelik, sınıflandırmayı ne yönde etkileyeceği bilinmediği için her biri farklı değerlendirilmiştir. Tüm özniteliklerin ortalaması kullanılarak elde edilen yeni değerler iki sınıflandırma yönteminde de kullanılmıştır. Elde edilen sonuçlara göre, iki farklı yönteminde ortalama aynı başarı sonuçları verdiği

görülmüştür. Fakat en iyi sonuçların farklı örneklerde görülmesi her bir ses örneğinin aynı oranda başarılı olamayacağını göstermektedir.

Tüm özniteliklerin kullanılması da artık veya sınıf hakkında hiçbir bilgi içermeyen değerleri barındırabileceğinden kullanılabilir özniteliklerin de ayrıştırılması gerekmektedir. Bu sebeple veri kümesinde MRMR öznitelik seçme algoritması uygulanmıştır. En iyi özniteliklerin sayısı birer birer arttırılarak KNN ve SVM sınıflandırma başarı oranları gözlemlenmiştir. Sınıflandırma maksimum başarı oranları KNN de %73 iken, SVM de %78 de kalmıştır. En iyi başarı oranı elde edilen ses örneği öznitelik seçilmeden önceki performansına bakıldığında, SVM de %20 lik, KNN de ise %40 lık bir artış olmuştur. Bu oranlara göre öznitelik seçiminin başarı performansına olumlu yönde katkısı olduğu söylenebilmektedir.

İki yöntemin de kullandıkları parametreler incelediğinde Destek vektör makineleri algoritmasında lineer kernel tipinin daha optimum sonuçlar verdiği, fakat rbf yönteminde en yüksek başarı elde ettiği görülmüştür. Dezavantaj olarak, kullanılan öznitelik artışında rbf kernel tipinde ciddi bir başarı düşüşü yaşanmaktadır. Diğer sınıflandırma yöntemi olan en yakın k-komşu algoritmasında ise en optimum komşu değeri 3 olarak belirlenmiştir. Bunun sebebi ise komşu sayısı arttıkça birbirinden çok daha uzak olan sınıflar değerlendirmeye katılacak böylece başarı oranında düşme yaşanacaktır.

Son yapılan performans analizinde tüm ses örnekleri, MRMR en iyi öznitelik seçme algoritmasında işlenmiş, artan öznitelik sayısına göre başarı oranları incelenmiştir. İşlem sonucunda kullanılan özneliğin artması SVM yönteminde olumsuz etkileri olduğu gözlemlenmiş, KNN yönteminde ise bu etkinin daha az ve stabil olduğu belirlenmiştir. Maksimum başarı oranlarının KNN yönteminde %70, SVM yönteminde %60 lar da olması tüm ses örneklerinin kullanılması ve korelasyonu az olan bilgilerin aynı eğitim kümesinde olmasından kaynaklanmaktadır.

Sonuç olarak, farklı yöntemler kullanılarak ham bir sesten hastalık bilgilerinin tespitini gösterebilecek bir çalışma yapılmıştır. Literatürde kullanılan yöntemlere ek olarak en yakın komşu algoritmasında bu sistemde kullanılmak üzere uygulanmış ve SVM

yöntemine yakın başarı sonuçları alınmıştır. Farklı özneliklerin bulunması, alınan ses kayıtlarının kalitesinin artırılması veya farklı sınıflandırma yöntemleri kullanılması sistemin başarı performansını olumlu yönde etkileyecektir. Veri toplama aşamasında toplanan tüm bilgiler ileriki çalışmalar için bir otomasyon sistemi tasarlanılarak saklanabileceğinden, hem araştırmacılar için hem de hastane personeli için çalışmalarını kolaylaştıracak bir sistem olarak önerilebilmektedir.

Gerek kullanılan verilerin kendi hastalarımızdan toplanmış olması, gerekse toplanan verilerin kapsamı düşünülecek olursa bu çalışma başta ülkemizde olmak üzere, dünyada da birçok çalışmaya referans olacak niteliktedir. Toplanacak bu verilerin hastalığın teşhis ve tedavisinde yol gösterici olabilmesi için kullanılan farklı örüntü tanıma algoritmalarından daha iyi sonuçlar alabilmek için ses ve bir ileriki aşama olan el yazısı gibi verilerin bir arada kullanılması ve kullandığımız verilere uyarlanması esnasında, kullanılan algoritmaların geliştirilmesi ve Parkinson verilerine uyarlanması yeni yöntem ve algoritmaların çıkışına ışık tutacaktır.

Çalışma, bunun bir ileri safhası olan telefon aracılığıyla hastaneye gitmeden hastalık teşhisine de bir temel oluşturacağından, ülkemiz için de büyük önem arz etmektedir. E-devlet, e-egitim gibi, e-sağlık hizmetleri hem ülke ekonomimizi kalkındıracak, hem de yaşam kalitesini arttıracaktır. Ayrıca çalışmamda her ne kadar sadece Parkinson hedef alınmış olsa da, geliştirilen sistem Alzheimer gibi diğer nörolojik hastalıklarda da bazı küçük uyarlamalarla kullanılabilir. Ayrıca e-sağlık uygulamaları için de örnek bir durum-çalışması olacağından, diğer araştırmacılar da bu çalışmadan referans alabileceklerdir.

KAYNAKLAR

1. ADAMS, R.D., and VİCTOR, M., and ROPPER, AH., 1997, *Principles of Neurology* 6th ed., NY: McGraw-Hill, New York, 1067-1078.
2. WATERS, CH., Çev: Büyükkal B., 2000, *Parkinson Hastalığının Tanı ve Tedavisi* , Turgut Yayıncılık ve Tic. A.Ş., İstanbul.
3. FAHN, S., and PRZEDBORSKI, S., 2000, *Parkinsonizm. In: Rowland LP ed. Merritt's Textbook of neurology. 10 th ed.*, Lippincott Williams & Wilkins, Philadelphia, 9789752771819, s679-s693
4. QUİNN, N., and CRITCHLEY, P., and MARSDEN, CD., 1987, Young onset Parkinson's Disease. *Mov Disord.*, 2(2), 73-91.
5. ERTAN, S., 2005, Parkinson Hastalığının Klinik Özellikleri, *Nörolog Olmayanlar için Nöroloji, Ocak 2005 İstanbul*, 42:249-254.
6. DELİL, Ş., 2001, *Parkinson Hastalığında Levodopa'ya Bağlı Motor Komplikasyonların Gelişmesinde Rol Oynayan Etkenler*, Uzmanlık Tezi. İstanbul Üniversitesi.
7. DEWEY, RB., 2000, *Jr. Clinical Features of Parkinson's Disease. In: Parkinson's disease and movement Disorder edt by Adler CH., Ahlskog JE. Humana Press, New Jersey, 71-84.*
8. PARKER, J., 2007, *Speech Dysfunctions In Parkinson's Disease* [online], http://www.selfgrowth.com/articles/Speech_Dysfunctions_In_Parkinson_s_Disease.html [Ziyaret Tarihi: 25 Nisan 2011].
9. MCNAMARA, P., Ph.D., 2010, *Parkinson's Disease-Related Speech and Language Problems* [online], http://parkinsons.about.com/od/signsandsymptomsofpd/a/speech_problems.htm [Ziyaret Tarihi: 27 Nisan 2011].

10. VAN GEMMERT, A.W.A., and ADLER, CH., and STELMACH, G.E., 2003, Parkinson's disease patients undershoot target size in handwriting and similar tasks, *J Neurol Neurosurg Psychiatry*, Vol. 74, pp. 1502-1508.
11. ÜNLÜ, A., and BRAUSE, R., and KRAKOW, K., 2006, Handwriting Analysis for Diagnosis and Prognosis of Parkinson's Disease, *Proc. Int. Symp. Biological and Medical Data Analysis*, LNCS Vol. 4345, pp. 441-450.
12. ALY, N.M., and PLAYFER, J.R., and SMITH, S.L., and HALLIDAY, D.M., 2007, A Novel Computer-Based Technique for The Assessment of Tremor in Parkinson's Disease, *Age and Ageing*, 36: 395–399.
13. WANG, H., and YU, Q., and KURTIS, M., and FLOYD, A., and SMITH, W., and PULLMAN, S., 2008, Spiral analysis—Improved clinical utility with center detection, *Journal of Neuroscience Methods*, Vol. 171, No. 2, pp. 264-270.
14. Max. A. Little, Patrick E. McSharry, Eric J. Hunter, Jennifer Spielman, Lorraine O. Ramig, Suitability of Dysphonia Measurements for Telemonitoring of Parkinson's Disease, *IEEE Transactions on Biomedical Engineering*, Vol. 56, No. 4, pp. 1015-1022, 2009.
15. TSANAS, A., and LITTLE, M.A., and MCSHARRY, P.E., and RAMIG, L.O., 2009, Accurate Telemonitoring of Parkinson's Disease Progression by Non-Invasive Speech Tests, *Nature Precedings*, hdl:10101/npre.2009.3920.1.
16. REVETT, K., and GORUNESCU, F., and SALEM, A.B.M., 2009, Feature Selection in Parkinson's Disease: A Rough Sets Approach, *Proceedings of the International Multiconference on Computer Science and Information Technology*, pp. 425 – 428.
17. TSANAS, A., and LITTLE, M.A., and MCSHARRY, P.E., RAMIG, L.O., 2010, Enhanced Classical Dysphonia Measures and Sparse Regression for Telemonitoring of Parkinson's Disease Progression, *IEEE International Conference on Acoustics Speech and Signal*, pp. 594-597.
18. GASSER T., 1998, Genetics of Parkinson's Disease, *Ann Neurol*, 44(suppl 1):S53-S57.
19. HOEHN, M., and YAHR M., 1967, Parkinsonism: onset, progression and mortality, *Neurology*, 17 (5): 427–42.

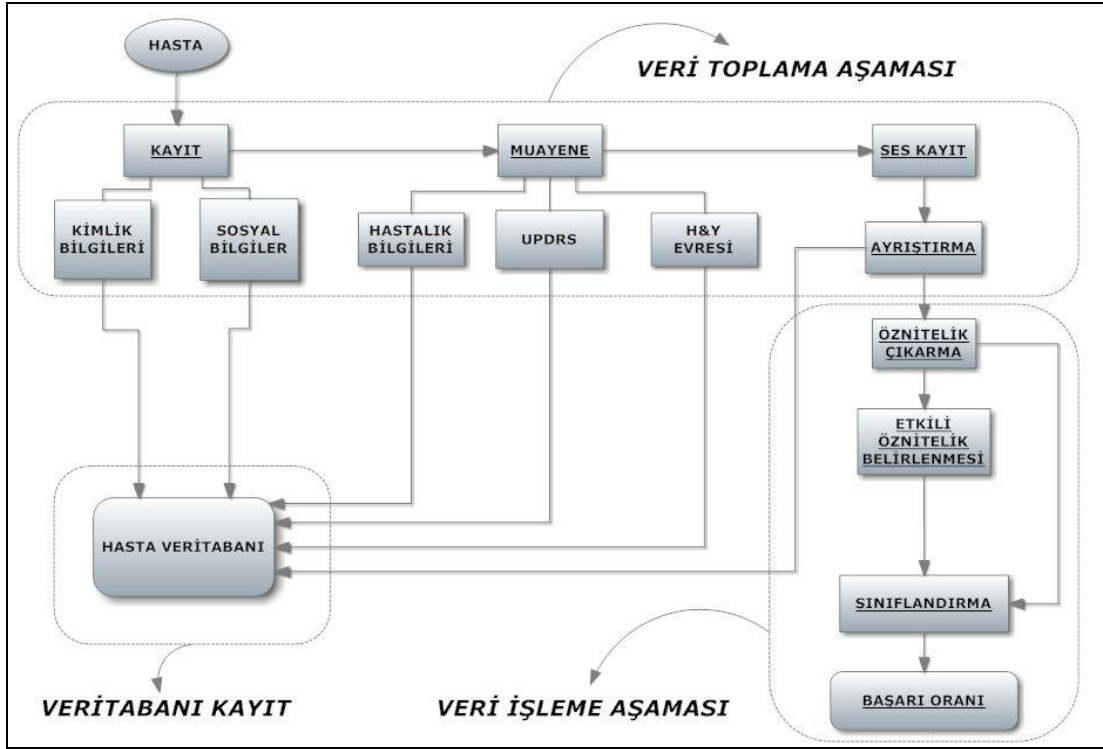
20. SHARGEL, L., 2003, *Comprehensive pharmacy review 5th edition*, Lippincott Williams & Wilkins, ISBN: 978-0781744867, p. 998.
21. Parkinson's Disease Foundation, 2009, *Frequently Asked Questions* [online], http://www.pdf.org/pdf/fs_frequently_asked_questions_10.pdf [Ziyaret Tarihi 30 Nisan 2011].
22. ROSENBAUM, R. B., 2006, *Understanding Parkinson's Disease: A Personal and Professional View*, Greenwood Publishing Group, ISBN 9780275991661.
23. USLU, T., 2008, *Parkinson Hastalığı ve Parkinsonizmde Rehabilitasyon* [online], <http://www.saglikdanis.com/hastalikgoster.asp?hid=264> [Ziyaret Tarihi: 02 Mayıs 2011].
24. LIESHOUT, P.V., 2005, *Praat Short Tutorial* [online], <http://www.slp.utoronto.ca/Assets/SLP+Digital+Assets/Misc+Resarch+Lab+Files/Oral+Dynamics+Lab/PrattMan.pdf> [Ziyaret Tarihi: 05.03.2011]
25. BOERSMA, P., and WEENINK, D., 2010, *Manual Page of Praat v5.2.07*, Praat Acoustic Speech Analysis Software.
26. WOLFE, V., and MARTIN, D., 1997, Acoustic correlates of dysphonia: type and severity, *J. Commun Disord*, 30(5), 403-415.
27. TITZE, I.R., 1995, *Workshop on Acoustic Voice Analysis: Summary Statement*, Iowa, IA: National Center for Voice and Speech.
28. BOERSMA, P., and WEENINK, D., 2008, *Praat Manual Version 4.2.17*, Phonetic Sciences Department, University of Amsterdam.
29. DING, C., and PENG, H.C., 2003, Minimum Redundancy Feature Selection from Microarray Gene Expression Data, *Proc. Second IEEE Computational Systems Bioinformatics Conf.*, Aug. 2003, pp. 523-528.
30. SAKAR, C.O., and KURSUN, O., 2010, Telediagnosis of Parkinson's Disease Using Measurements of Dysphonia, *Journal of Medical Systems*, vol. 34(4), pp. 591-599. DOI: 10.1007/s10916-009-9272-y
31. WIESNER, V., and EVERS, L., 2004, *MSc in Bioinformatics: Statical Data Mining*, Thesis(MSc), University of Oxford.
32. WIKIPEDIA, 2011, *k-Nearest Neighbor Algorithm* [online], http://en.wikipedia.org/wiki/K-nearest_neighbor_algorithm [Ziyaret Tarihi: 10 Mayıs 2011]

33. WIKIPEDIA, 2011, *Support Vector Machine* [online], http://en.wikipedia.org/wiki/Support_vector_machine [Ziyaret Tarihi: 18 Mayıs 2011]
34. ŞEKER, Ş.E., 2009, *SVM (Support Vector Machine, Destekçi Vektör Makinesi)*, <http://www.bilgisayarkavramlari.com/2008/12/01/svm-support-vector-machine-destekci-vektor-makinesi/> [Ziyaret Tarihi: 18 Mayıs 2011]

EK-A HASTA KAYIT FORMU

HASTA BİLGİ VE KAYIT FORMU	
<u>Kişisel Bilgiler:</u>	Tarih:
Hasta Referans No:	
Adı:	Eğitim Durumu:
Soyadı:	Meslek: Ev Hanımı
Yaş:	Sigara Kullanımı:
Cinsiyet:	
<u>Hastalık Bilgileri:</u>	
Teşhis:	
Hastalık başlangıcından itibaren geçen süre:	
Semptomlar:	
Kalıtım:	
Hastalık Seyri:	
Hoehn-Yavr Puanı:	UPDRS Puanı:
<u>Görüşler:</u>	

EK-B VERİ TOPLAMA VE ÖRÜNTÜ TANIMA İŞLEM ŞEMASI



ÖZGEÇMİŞ

Muhammed Erdem İSENKUL 24.12.1987 tarihinde İstanbul ili Fatih semtinde doğdu. İlk ve orta öğrenimini Adem Çelik İlköğretim Okulunda, lise öğrenimini ise Özel Fatih Fen Lisesinde tamamladı. 2004 yılında Fatih Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği (İngilizce) bölümünde lisans eğitimine başladı. 2009 yılında mezun oldu. 2009 yılının Ekim ayında İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı'nda Yüksek Lisans Eğitimine başladı. Aynı yılın Şubat ayında ise Yüksek Lisans eğitimi gördüğü İstanbul Üniversitesi, Bilgisayar Mühendisliği Ana Bilim Dalı'nda Araştırma Görevlisi olarak göreve başladı. Halen Araştırma Görevlisi olarak çalışmalarına devam etmektedir.