T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

Yürüme Esnasında Ayakta Meydana Gelen Basınç Değişikliklerine Göre Parkinson Hastalığının Tespitinde Makine Öğrenmesi Algoritmasının Kullanılması

Emin ÖLMEZ

DANIŞMAN
Prof. Dr. Ahmet SERTBAŞ

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

Aralık, 2022

BÜTÇE DESTEKLERİ

Yürüme Esnasında Ayakta Meydana Gelen Basınç Değişikliklerine Göre Parkinson Hastalığının Tespitinde Makine Öğrenmesi Algoritmasının Kullanılması

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Akademik bitirme çalışman boyunca desteklerini eksik etmeyen danışmanım Prof. Dr. Ahmet SERTBAŞ'a müteşekkirim. Çalışmama yardımlarıyla destek veren ve tez çalışmanın bitmesine bilgisi ile destek olan Doç. Dr. Orhan AKBULUT'a teşekkür ederim. İlk günden son güne kadar hayatımın her anında yanımda olan kıymetli aileme en içten şekilde teşekkür ederim.

Aralık 2022 Emin ÖLMEZ

İÇİNDEKİLER Sayfa No

BEYAN ..... **iii**
BÜTÇE DESTEKLERİ ..... **iv**
TEŞEKKÜR ..... **v**
ŞEKİL LİSTESİ ..... **viii**
TABLO LİSTESİ ..... **ix**
SİMGE VE KISALTMA LİSTESİ ..... **xi**
ÖZET ..... **xii**
ABSTRACT ..... **xiii**
1. GİRİŞ **1**
1.1. TEZİN AMACI VE YAKLAŞIMI 3
2. GENEL TANIMLAR **4**
2.1. PARKİNSON HASTALIĞI 4
2.2. YÜRÜME 7
2.2.1. Yürüme fazları 9
2.2.2. Yürüme Analizi 12
2.2.3. Yürüme ve Parkinson 15
2.3. LİTERATÜR TARAMASI 17
2.4. Parkinson hastalığının tespitinde yürüyüş verisi ile yapılan çalışmalar 19
3. VERİ VE YÖNTEM **25**
3.1. MAKİNE ÖĞRENMESİ HAKKINDA GENEL BİLGİLER 25
3.2. KULLANILAN VERİ KÜMESİ 26
3.2.1. GA Veri Kümesi 27
3.2.2. JU veri kümesi 28
3.2.3. SI veri kümesi 29
3.3. VERİ KÜMESİNE UYGULANAN ÖN İŞLEMLER 30
3.3.1. Medyan Filtre 31
3.3.2. Normalizasyon işlemi 31
3.4. VERİ KÜMESİNDEN ÖZNİTELİK ÇIKARTILMASI 33
3.4.1. Ortalama Adım Süresi 34

3.4.2. Ortalama Adım Mesafesi 35
3.4.3. Ortalama Duruş Süresi 36
3.4.4. Frekans Sayısı 36
3.4.5. Öznitelikler Hakkında Genel Bilgiler 37
3.5. SINIFLANDIRMA 38
3.5.1. Destek Vektör Makineleri Sınıflama Algoritması 39
3.6. ÇAPRAZ DOĞRULAMA YÖNTEMLERİ 40
3.6.1. Sınama Seti Yöntemi (Holdout Method) 40
3.6.2. Birini Dışarda Bırak Çapraz Doğrulama (Leave-one-out cross validation) 40
3.6.3. K-Katlamalı Çapraz Doğrulama (KFold Cross Validation) 41
3.7. SINIFLANDIRMA PERFORMANSININ DEĞERLENDİRME ÖLÇÜTLERİ 41
3.7.1. Doğruluk 42
3.7.2. Duyarlılık 43
3.7.3. Özgünlük 43
3.7.4. Kesinlik 43
3.7.5. Matthews Korelasyon Katsayısı 43
3.8. ZAMAN KARMAŞIKLIĞI 44
4. DENEYSEL SONUÇLAR 45
4.1. VERİ KÜMESİ İÇİN MAKİNE ÖĞRENMESİ ALGORİTMASININ SONUÇLARI 46
4.1.1. GA Veri Kümesi İçin Makine Öğrenmesi Algoritmasının Sonuçları 50
4.1.2. Si Veri Kümesi İçin Makine Öğrenmesi Algoritmasının Sonuçları 52
4.1.3. JU Veri Kümesi İçin Makine Öğrenmesi Algoritmasının Sonuçları 55
4.2. BU TEZ ÇALIŞMASININ LİTERATÜRE KATKILARI VE SONUÇLARIN DEĞERLENDİRİLMESİ 58
5. SONUÇ VE ÖNERİLER 61
6. KAYNAKLAR 63
ÖZGEÇMİŞ 67

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Duruş ve salınım fazlarının gösterimi. [21]. 9

Şekil 2.2: Duruş fazının bölümlerinin gösterilmesi [21]. 10

Şekil 2.3: Salınım fazının bölümlerinin gösterilmesi [21]. 11

Şekil 2.4: Destek bölümlerinin gösterilmesi [21]. 12

Şekil 3.1: Sensör konumları 27

Şekil 3.2: Öznitelik çıkarma aşamasının genel gösterimi 33

Şekil 3.3: Sensörden alınan basınç değerlerin zamana göre gösterilmesi 35

Şekil 3.4: Frekans değerlerine ait histogramlar 38

Şekil 4.1: ROC eğrisi gösterimi 49

TABLO LİSTESİ

Sayfa No

Tablo 2.1:Yürüyüş ile ilgili literatürde yer alan çalışmalar hakkında bilgiler.....20

Tablo 3.1: Veritabanı için Demografik bilgiler.....27

Tablo 3.2: GA veri kümesine ait demografik bilgiler.....28

Tablo 3.3: JU veri kümesine ait demografik bilgiler.....29

Tablo 3.4: SI veri kümesine ait demografik bilgiler.....30

Tablo 3.5: Öznitelikler.....34

Tablo 3.6: Öznitelik değerleri.....37

Tablo 3.7: Karmaşıklık matrisi gösterimi.....42

Tablo 4.1: Öznitelikler için zaman karmaşıklığı değerleri.....46

Tablo 4.2: Çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değeri.....47

Tablo 4.3: Çapraz doğrulama kullanılarak elde edilen ortalama sınıflandırma değeri.....47

Tablo 4.4: Tüm veri için karmaşıklık matrisi sonuçları.....48

Tablo 4.5: Tüm veri için değerlendirme ölçütleri sonuçları.....49

Tablo 4.6: GA verisi için çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değeri.....50

Tablo 4.7: GA verisi için Çapraz doğrulama kullanılarak elde edilen ortalama sınıflandırma değeri.....50

Tablo 4.8: GA verisi için karmaşıklık matrisi sonuçları.....51

Tablo 4.9: GA verisi için değerlendirme ölçütleri sonuçları.....52

Tablo 4.10: SI verisi için çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değeri.....53

Tablo 4.11: SI verisi için çapraz doğrulama kullanılarak elde edilen ortalama sınıflandırma değeri.....53

Tablo 4.12: SI verisi için karmaşıklık matrisi sonuçları.....54

Tablo 4.13: SI verisi için değerlendirme ölçütleri sonuçları 54

Tablo 4.14: JU verisi için çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değeri 55

Tablo 4.15: JU verisi için çapraz doğrulama kullanılarak elde edilen ortalama sınıflandırma değeri 56

Tablo 4.16: JU verisi için karmaşıklık matrisi sonuçları 57

Tablo 4.17: JU verisi için değerlendirme ölçütleri sonuçları 57

Tablo 4.18: Literatürde yer alan öznitelik sayıları ile önerilen yöntemden kullanılan özniteliklerin karşılaştırılması 58

Tablo 4.19: Literatürde yer alan çalışmalar ile önerilen yöntemin doğruluk değerlerinin karşılaştırması 59

Tablo 4.20: Literatürde yer alan çalışmalar ile önerilen yöntemin duyarlılık, özgünlük ve MCC değerlerinin karşılaştırması 60

SİMGE VE KISALTMA LİSTESİ

Simgeler	**Açıklama**
m	: Metre
μ	: Ortama değeri
σ	: Standart sapma değeri
∑	: Toplam sembolü
dk	: Dakika

Kısaltmalar	**Açıklama**
EEG	: Elektroensefalografi
PH	: Parkinson Hastalığı
MRI	: Manyetik rezonans görüntüleme
BPHDÖ	: Birleşik Parkinson Hastalığı Değerleme Ölçeği
UPDRS	: Unified Parkinsons Disease Rating Scale
DVM	: Destek Vektör Makineleri
GP	: Gerçek Pozitif
YP	: Yanlış Pozitif
YN	: Yanlış Negatif
GN	: Gerçek Negatif
MCC	: Mathews Korelasyon Katsayısı

ÖZET

YÜKSEK LİSANS TEZİ

Yürüme Esnasında Ayakta Meydana Gelen Basınç Değişikliklerine Göre Parkinson Hastalığının Tespitinde Makine Öğrenmesi Algoritmasının Kullanılması

Emin ÖLMEZ

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

Danışman: Prof. Dr. Ahmet SERTBAŞ

Yürüyüş aktivitesi analizi, Parkinson hastalığını tespit etmek için kullanılan yöntemlerden biridir. Parkinson hastalığının yürüyüş aktivitesi normal bir insanın yürüyüşünden farklıdır. Bu çalışmada, Parkinson hastalığını saptamak için düşük boyutlu öznitelik vektör temsilini kullanan bir destek vektör makine tabanlı sınıflandırma yöntemi önerilmiştir. Öznitelik olarak ortalama duruş süresi, ortalama adım süresi, ortalama adim mesafe ve yürüyüş periyodunda elde edilen frekans değeri kullanılmıştır. Sınıflandırma işlemi için sadece O(n) zaman karmaşıklığına sahip 4 özellik değeri kullanılmaktadır. Deneysel sonuçlar, önerilen yöntemin bu birkaç özellik altında bile literatürde önerilen benzer çalışmalarla rekabet edebileceğini göstermektedir. Deneysel sonuçlara göre, tüm veri seti altında %85'e varan yüksek sınıflandırma performansı elde edilmiştir. Ayrıca veri setleri tek tek değerlendirildiğinde %91'e varan üstün sınıflandırma performansı elde edilmektedir.

Aralık 2022 , 80 sayfa.

Anahtar kelimeler: Sınıflandırma, Yürüyüş Analizi, Parkinson Hastalığı, Makine Öğrenimi, Destek Vektör Makinesi

ABSTRACT

M.Sc. THESIS

Using Machine Learning Algorithm in Detection of Parkinson's Disease According to Pressure Changes in Standing During Walking

Emin ÖLMEZ

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Computer Engineering

Computer Engineering Program

Supervisor: Prof. Dr. Ahmet SERTBAŞ

Thanks to the developing technology, Parkinson's disease can be detected by using datasets which are obtained from different sources. Gait activity analysis is one of the methods used to detect Parkinson's disease. The gait activity of Parkinson's disease differs from the gait of a normal person. In this study, a support vector machine-based classification method using low-dimensional feature vector representation is proposed to detect Parkinson's disease. Average stance time, average stride time, average stride distance and frequency value obtained during walking period were used as features. Only 4 feature values having O(n) time complexity are used for the classification process. Experimental results point out that the proposed method can compete with similar studies proposed in the literature, even under these few features. According to the experimental results, high classification performance, up to 85%, is obtained under the whole dataset. Moreover, superior classification performance, up to 91%, is obtained when the datasets are evaluated individually.

December 2022, 80 pages.

Keywords: Classification,Gait Analysis,Parkinson's Disease, Machine Learning, Support Vector Machine

1. GİRİŞ

Teknolojinin gelişmesi ile birlikte veri sayısında bir artış meydana gelmiştir. Artan verinin analiz edilmesi ile yararlı ve önemli çıkarımlar yapılarak bilgi elde edilebilmektedir. Bilginin elde edilmesi için verinin işlemesi gerekliliği ortaya çıkmıştır. Teknoloji ile birlikte veri işleme alanında da yenilikler yapılmıştır. Bu yenilikler sonucunda farklı yöntemler oluşturulmuş ve geliştirilmiştir. Bu yöntemlerden birisi de Makine Öğrenmesi yöntemidir.

Makine Öğrenmesi, matematiksel ve istatiksel yöntemleri kullanarak var olan verilerden anlamlı çıkarımlar yapan ve bu çıkarımlar ile daha önce tahmin edilmeyen verileri bulmaya çalışan bir programlama sistemidir [1]. Böylece verilerin derin bir şekilde analiz edilmesine olanak sağlamıştır.

Makine Öğrenmesi yöntemlerinde veriyi analiz ederken verinin yapısına göre veya probleme göre yöntem seçilmektedir. Her veri için tek bir makine öğrenmesi yöntemi bulunmamaktadır. Bu durum kullanılan veri için en uygun ve en iyi performans veren makine öğrenmesi yönteminin seçilmesi gerektiği anlaşılmaktadır. Modellerin oluşturulmasında bu durumlar dikkate alınmalıdır.

Günümüzde Makine öğrenmesi yöntemi; biyoloji, kimya, finans ve tıp gibi farklı alanlardaki veriler analiz ederek bilgi elde edilmeye çalışılmaktadır.

Makine Öğrenmesi yöntemi Biyoloji alanında genellikle tahmin ve yeni durumların keşfi için kullanılmaktadır. Bu tahmin ve keşifler genellikle DNA ve RNA proteinlerinin tahmininde, gen yapısının tespitinde veya regülasyonunda, proteinlerin yapısına göre ilaç oluşturulmasında gibi farklı alanlarda Makine Öğrenmesi algoritması kullanılmaktadır [3]. Biyolojide genellikle makine öğrenmesi algoritması deneysel sonuçların yetersiz olduğu yerleri tahmin etmek için kullanılmaktadır. Bu tahmin işlemi doğru bir şekilde yapılarak gelecekteki çalışmalar için bir yönlendirici görev üslenmesini sağlamaktır.

Makine öğrenmesinin kullanıldığı alanlardan biri de kimya alanıdır. Bu alanda genel olarak kimyasal deneyleri sonuçlarının hesaplanması işlemi yapılmaktadır. Bu kimyasal deneyler sırasında meydana gelen reaksiyonları hızları ve sonuçları tahmin edilmeye çalışılmakta ve

sınıflandırma işlemi yapılmaktadır [4]. Ayrıca molekül ve atom yapıları ile ilgili modeller oluşturmasında da kullanılmaktadır. Bu şekilde kimyasal deneylerin sonuçlarının deneyler yapılmadan tahmini yapılabilmekte ve deney sırasında oluşabilecek reaksiyon sonuçları bulunabilmektedir.

Makine öğrenmesi finans alanında yaygın bir şekilde kullanılmaktadır. Bunun nedeni yüksek boyutlu verinin işlenmesi ve karar işlemlerinin verilere dayalı olarak yapılmasından kaynaklanmaktadır. Bu durumlara çözümler bulmak için makine öğrenmesi algoritmalar kullanılmaktadır. Genel olarak kredi işlemeleri, varlıkların yönetilmesi, risk analizi, sistemin güvenliği ve ticari hamlelerin yönetilmesi gibi konularda çalışmalar yapılmaktadır.

Makine Öğrenmesi yöntemi kullanıldığı alanlardan birisi olan tıptır. Tıp alanda birçok farklı çalışma yapılmıştır. Bu çalışmalarda genellikler hastalığın tespit veya teşhis edilmesi üzerine yoğunlaşılmıştır [2]. Bu şekilde hastalığın tespit edilmesinde doktorlara yardımcı olan bir sistem oluşturulmayı amaçlanmaktadır. Oluşturulan sistemin güvenilir ve anlaşılır olması gerekmektedir. Ayrıca eksik veriler ve gürültülerle de baş edebilmesi gerekmektedir. Bu durumlar dikkate alınarak Makine Öğrenmesi yöntemleri geliştirilmiştir.

Tıp alanında genellikle teşhis işlemleri hastalığın meydana geldiği sisteme veya hastalığın oluşturduğu belirtilere göre yapılmaktadır. Hastalık sinir sisteminde meydana geliyorsa, sinir sistemindeki değişikliklere ve meydana geldiği bölgenin yapısına bakılarak tespit edilmeye çalışılmaktadır. Örneğin Parkinson, Epilepsi ve Huntington hastalıkları vücudun sinir sistemiyle ilişkili hastalıklardır. Bu durumlar dikkate alınarak hastalıklar doktorlar tarafından incelenerek tespit edilmeye çalışılmaktadır.

Sinir sisteminde meydana gelen hastalıklardan birisi olan epilepsi, sinir sisteminde yer alan beyin hücrelerinin normalden farklı bir şekilde elektrokimyasal tepkiler vermesi sonucu oluşan bir hastalıktır [5]. Hastalığın meydana gelme nedeni tam olarak bilinmese de beyine alınan darbeler sonucunda oluşan hasarlar, genetik faktörler, beyinde meydana gelen hastalıklar gibi durumlardan dolayı oluştuğu düşünülmektedir [6]. Hastada kriz anında bilinç kaybına yol açmakta ve istemsiz vücut kasılmaları meydana gelmektedir [6]. Bu kriz anları incelenerek doktorlar tarafından hastalık tespit edilmeye çalışılmaktadır. Ayrıca Elektroensefalografi (EEG) ile alınan epileptik sinyalleri incelenerek hastalık hakkında bilgiler elde edilmektedir. Günümüz teknolojisi ile EEG sinyalleri makine öğrenmesi yöntemleri kullanılarak hastalığın tespit edilmesi işlemi için araştırmalar yapılmaktadır.

Huntington hastalığı, sinir sisteminde yer alan nöronları hedef alan, genellik ile motor sistemi, bilişsel yapı ve psikiyatrik özellikleri etkileyen bir nörodejeneratif hastalıktır. Hastalık kalıtım yapısındaki kromozomunun bozulması sonucunda oluşmaktadır [7]. Bu neden ile kalıtım yolu ile geçen bir hastalıktır. Hastalık genel olarak yaşamın ilerleyen dönemlerinde ortaya çıkmaktadır. Hastada yürüme bozuklukları, kasılmalar, psikoloji problemler, koordinasyon bozuklukları gibi belirtiler meydana getirmektedir. Doktorlar tarafından meydana gelen belirtiler incelenerek hastalık tespit edilmeye çalışılmaktadır.

1.1. TEZİN AMACI VE YAKLAŞIMI

Bu tez kapsamında Parkinson Hastalığının (PH) ile ilgili veriler kullanılarak Makine Öğrenmesi yöntemleri ile PH tespit etmeyi amaçlamaktadır. Bu amaç ile birlikte Makine Öğrenmesi modeli oluşturulmuştur. Oluşturulan model ile farklı yürüyüş verileri kullanılarak Parkinson hastası ve sağlıklı bireyler arasında sınıflandırma işlemi yapılarak PH ayırt edilmeye çalışılmıştır. Böylece doktorlara yardımcı olabilecek bir sistem oluşturulmuştur.

2. GENEL TANIMLAR

2.1. PARKİNSON HASTALIĞI

PH, dünya genelinde Alzheimer's hastalığından sonra en çok görülen ikinci nörodejeneratif hastalıktır [8]. Hastalık genel itibariyle 50 yaş üzerindeki kişilerde ortaya çıkmaktadır. 50 yaş altı hastalarda görülme sıklığı tüm Parkinson hastalarına göre %10 oranı denk gelmektedir [9]. Yaş ilerledikçe Parkinson hastalığının görülme sıklığı artmaktadır. 65 yaş üzerindeki kişilerin dünya genelinde %2-3 görülürken bu oran 80 yaş üzerinde ise %10'a denk gelmektedir [8]. Günümüzde toplam Parkinson hastası sayısı 4 milyon bireyde olduğu tespit edilmiştir. Araştırmalar sonucunda, PH gelecek 10 yıl içerisinde yaklaşık iki kat artış olması düşünülmektedir. Ayrıca PH kadınlara oranla erkeklerde görülme durumu 2 kat fazladır [10].

PH, ilk olarak İngiliz Doktor James Parkinson tarafından 1817 tarihinde bir hastalık olarak ifade edilmiştir. İngiliz Doktor James Parkinson, PH ile ilgili araştırmalar sonucunda, "An Essay on the Shaking Palsy" adında 66 sayfalık bir kitap yayınlamıştır [11]. İngiliz Doktor James Parkinson yayınladığı kitap içerisinde PH'ın "duyularda ve zihin gücünde herhangi bir kayıp olmamasına rağmen, aktif halde olmayan kısımlarda kas gücünde azalma, istem dışı titremeler meydan geldiği, gövdeyi öne doğru eğilip yürüyüşten koşma durumuna geçiş" olarak tanımlamıştır. 1817 yılı sonrasında ise hastalık titreme felci (shaking palsy) olarak isimlendirilmiştir. Hastalığın günümüzdeki ismini 1865 yılında hastalığı ilk defa tespit eden İngiliz Doktor James Parkinson adına ithafen Jean-Martin Charcot tarafından 'Parkinson Hastalığı' olarak değiştirilmiştir [12].

İngiliz Doktor James Parkinson'unun kitabını yayınladıktan sonra hastalık neredeyse 60 yıl boyunca herhangi bir araştırma yapılmadı. 1872 yılında Jean Martin Charcot adında bir Fransız nörolog hastalık ile ilgili çalışmalar yapmıştır. Charcot çalışmaları ile Parkinson hastalığının önemini fark eden ilk kişidir. Charcot ve öğrencileri tarafından PH ilgili araştırmalar yapılarak hastalığın klinik spektrumu tanımlanmıştır. Ayrıca hastalığın iki tipte meydana geldiğini bulmuşlardır. Bunlar Titreme aşaması ve sertlik aşamalarıdır. Titreme aşamasında James Parkinson tanımladığı gibi hareketli olmayan kısımlarda titremeler meydana geldiği, Sertlik aşamasında ise hastanın istemsiz bir şekilde kasıldığı tespit edilmiştir. Araştırmanın sonucunda hastalığın fiziksel değişimleri hakkında bilgiler paylaşılmıştır [12].

1872 yılında Jean Martin Charcot araştırmalarından sonra PH ile araştırmaların sayısında artışlar meydana gelmiştir. Daha sonraki yıllarda, hastalığın beyindeki hücrelerin bozulması ile meydana geldiği anlaşılmıştır. 1960 yılında hastaların incelenmesi sonucunda beyinde kimyasal farklılıkların oluştuğu tespit edilmiştir. İncelemeler sonucunda beynin substantia nigra bölgesindeki sinir hücrelerin dejenere olduğu tespit edilmiştir. Bu hücrelerin vücuttaki hareket kontrolünü sağlayan dopamin seviyesini ayarladığı anlaşılmıştır. Bundan dolayı hastalarda düşük dopamin seviyeleri göründüğü tespit edilmiştir [12][13].

PH, sinir sisteminde yer alan ve çok yoğun miktarlarda dopamin üreten substantia nigra bölgenin bozulması sonucunda, vücudun istenen düzeyde dopamin üretmemesi veya bozuk bir şekilde üretmesi ile oluşan sinir sistemi hastalığıdır [13][14]. Dopamin, vücuda doğal olarak salgılan, sinir hücrelerinin haberleşmesine yardımcı olan ve vücudun hareket sistemini etkileyen bir kimyasaldır [15]. Ayrıca dopamin uyku düzeni, duygu tepkilerini ayarlayan özellikleri de bulunmaktadır.

Parkinson hastalığının meydana gelme nedeni tam olarak bilinmese de araştırmalar sonucunda genetik faktörlerin ve çevresel faktörlerin etkili olduğu düşünülmektedir. Bu iki faktörün bir arada veya ayrı ayrı meydana gelmesi sonucunda hastalık meydana geldiği düşünülmektedir [16].

Parkinson hastası olan kişilerin gen yapıları bilim insanları tarafından incelenmiştir. İncelemeler sonucunda bazı genlerin Parkinson hastalığı ile ilişkili olduğu keşfedilmiştir. Bu genlerde meydana gelen değişimler sonucunda hastalık meydana gelmesi olası bir durum olarak gözükmektedir. Fakat bu genlerde meydana gelen değişikler bazen hastalığın oluşmasına neden olmadığı görülmüştür. Bundan dolayı Parkinson hastalığı ve genetik faktörler arasındaki bağlantı hala araştırılmaktadır [16].

Parkinson hastalığının meydana gelmesi sebeplerinden biri de çevresel faktörler olduğu düşünülmektedir. Çevrede meydana gelen değişikler ve kişide oluşan hasarlar sonucunda hastalık meydana geldiği inanılmaktadır. Bunlar kafaya alınan yaralanmalar sonucunda beyinde meydana gelen hasar, ikamet edilen coğrafi yapının durumu, mesleki deformasyon, uzun süreli metal veya toksik yapılara maruz kalmak gibi farklı çevresel faktörler sonucunda hastalık oluştuğu düşünülmektedir. Ayrıca hastalık yaş ilerledikçe ortaya çıkma olasılığı artmaktadır. Diğer bir durum ise hastalık kadınlara göre erkeklerde hastalık daha yaygın bir şekilde görülmektedir [16].

Parkinson hastalığı belirtileri diğer hastalıklar gibi yavaş bir şekilde ortaya çıkmaktadır. Genel olarak hastalık vücudun belirli bir bölgesinde belirti vermektedir. Bu belirti genelde titreme olarak kendini göstermektedir. Hastalık ilerledikçe vücudun diğer taraflarında da belirtiler ortaya çıkmaktadır. Hastalık belirtileri olarak titreme, duruş bozuklukluları, kas sertliği, yazıyı küçük yazmaya meyil, koku kaybı, uyku problemi, hareket etme ve yürüyüş sorunları, ses bozuklukları, ifadesiz yüz gibi belirtiler meydana gelmektedir. Bu belirtiler arasında en belirginleri ise duruş bozuklukları, titreme, kas sertliği, hareket sorunlarıdır. Bu belirtiler tüm Parkinson hastalarında ortak bir şekilde görülmektedir. Diğer belirtiler ise hastadan hastaya değişiklik gösterebilmektedir [17].

Hastalığın en belirgin özelliklerine bağlı olarak hastalarda yürüyüş bozuklukları meydana gelebilmektedir. PH'sı kişilerin yürüyüşlerinde, ilk dönemlerinde normal bireyler göre yavaşlama ve adım mesafesinin kısalması gibi belirtiler görülmektedir. Bunun nedeni kalça, diz ve ayak bileğinde meydana gelen koordinasyon eksikliğinden kaynaklanmaktadır. İlerleyen dönemlerde hastalarda adım mesafeleri kısalması ile birlikte iki ayak aynı anda yerle temas etmeye başlar. Bu durum hastaların her iki ayaktan destek alarak yürümesine neden olur. Ayrıca hastalarda eğik duruş gibi duruş değişiklikleri, kişinin yürüyüş esnasında düşmesine neden olabilir. Hastalığın en ağır döneminde yürüme sırasında donmalar meydana gelir ve hasta adım atmayarak ayakta kalır. Bu durumdan dolayı hastaların dengesi ve duruş kontrolü azalacağından dolayı ciddi düşme riskleri bulunmaktadır. Bu nedenlerden dolayı yürüme fonksiyonlarını yerine getiremez ve tekerlekli sandalye ile hayatını devam etmek durumunda kalırlar [18].

PH'ın teşhisinde bilindik bir test bulunmamaktadır. Teşhis için hastanın geçmişi incelenir ve hastada meydana gelen belirtilere bakılarak teşhis konulmaya çalışılır. Fakat hastalığın kesin tanısının konulması için kan tetkikleri, Manyetik rezonans görüntüleme (MRI) ile elde edilen görüntülerin ve dopamin sisteminin incelenmesi ile teşhis konulabilmektedir.

Parkinson hastalığının tanısında Birleşik Parkinson Hastalığı Değerleme Ölçeği ((BPHDÖ) UPDRS (Unified Parkinsons Disease Rating Scale)) olarak isimlendirilen ve doktorlar tarafından belirlenen bir ölçek bulunmaktadır. Bu ölçek Parkinson hastalığının seviyelendirmesinde ve değerlendirilmesinde kullanılan en sık ölçektir. Ölçeklendirme işlemi hasta ve hasta yakınlarında alınan bilgiler sonucunda oluşturulmaktadır. Hasta ve hasta yakınlarında alınan bilgiler ise düşünce, depresyon, duygu değişiklikleri, konuşma durumu,

yemek yeme durumu, yazma durumu, yatakta dönme, yürüme, titreme ve denge gibi bilgiler bir anket çalışması ile hasta ve hasta yakınlarından alınmaktadır. Doktor tarafından yapılan incelemelerle ve elde edilen hasta ve hasta yakınlarından alınan bilgilere dayanarak puana dayalı bir ölçek belirlenmektedir. Bu ölçek doktor tarafından belirlenen nicel olmayan bir puanlama sistemidir.

Parkinson Hastalığının bilinen bir tedavi yöntemi bulunmamaktadır. Hastalığın belirtilerinin azalması için ilaç tedavisi uygulanmaktadır. İlaç olarak Parkinson hastalığının etki ettiği düşünülen dopamin maddesinin artırılmaya yönelik ilaçlar verilmektedir. Bu ilaçlar hastanın yaşı, hastalığın belirtilerinin şiddetine göre ilaç seviyeleri ayarlanmaktadır.

İlaçların etkisi yeterli düzeyde değil ve ilaçların kullanımları sonucunda yan etkiler ortaya çıkıyorsa cerrahi tedaviye de başvurulabilmektedir. Cerrahi tedavi ile beyine beyin pili denilen derin beyin stimülasyonu takılmaktadır. Bu şekilde hastalığının belirtileri belirli oranlarda azalma görülmekte ve hastalar günlük yaşam konforlarında hayatlarına devam etmektedir.

2.2. YÜRÜME

Yürüme, Karada yaşayan bacaklı canlıların genel hareketlerinden biridir. Diğer bir ifade ile canlıların bir yerden başka bir yere gitmeleri için ritmik bir şekilde yaptıkları hareket olarak tanılanabilir. Canlılarda yürüme iç güdüsel bir davranıştır. Bazı canlılar doğumdan hemen sonra yürüme davranışını gösterirken insan gibi bazı canlılar ise ilerleyen yaşlarda içgüdüsel olarak yürümeye başlarlar. Yürüme sırasında kazanılan bilgiler; yaşam koşuları, ırk, cinsiyet gibi durumlardan dolayı farklı yürüyüş yapıları Oluşabilmektedir. Zaman içerisinde yaş, kilo, boy ve hastalık durumlarına göre yürüyüş yapıları değişiklik gösterebilmektedir.

Yürüme, yaşamın ilk yıllarından beri canlıların hareket etmesinin sağlayan en eski aktivitelerden biridir. Yürümenin hakkında bilinen ilk araştırma milattan önce 350 yılında Aristo'ya aittir. Aristo yürüyüş yapısını incelemiş ve hareketin kaslara bağlı olarak gerçekleştiğini tespit etmiştir. Galen tarafından ise kasların sinirler tarafından yönetildiği tespit edilmiştir. Rönesans dönemine kadar çeşitli araştırmalar incelemeler devam etmiştir. Rönesans ve 19. Yüzyılda Borelli ve Marey insan yürüyüşü hakkında dinamik çalışmalar yayınlamışlardır. Fotoğraf makinesinin icadından sonra 1830 yılında Weber kardeşler tarafından görüntüye dayalı olarak modern anlamda yürüyüş yapısı incelenmiştir. Görüntü teknolojisi geliştikçe yürüyüş incelenmesinde farklı çalışmalar yapılmıştır. 1950 yılında Vernel

Inma ve Jacquelin Perry tarafından klinik olarak modern yapıda yürüyüş incelemesini başlatmışlardır. Vernel Inma ve Jacquelin Perry'i bilgisayar teknolojisini kullanarak yürüyüşleri 3 boyutlu olarak bilgisayar ortamında gösterilmesine olanak sağlayacak sistemi geliştirmişlerdir. Günümüzde hem laboratuvar ortamında yapılan araştırmalarda hem de bilgisayar ortamında yürüyüş incelenmektedir [19].

Yürüme; beyin, sinir hücreleri, kas dokusu ve kemiklerin koordineli bir şekilde çalışması ile oluşmaktadır. Beyin de oluşan yürüyüş isteği sinir hücreleri ile kas dokularına iletilir. Kas dokusunun kasılıp gevşeme ile hareket meydana gelmektedir. Kemik dokusu kasları bütün ve dengede kalmasını sağlamaktadır. Bunların yanı sıra yürüme için kaslarda yeterli gücün olması gerekmektedir. Kasların zayıflaması veya dengesiz olması durumunda yürüyüşün düzgün bir şekilde yapılamamaktadır. Bunun için vücut enerjiyi ihtiyaca göre minimum düzeyde harcayarak dengeyi sağlamaya çalışır. Enerji kullanımını aksatacak her türlü yapısal değişiklikler ve bozuklularda enerji ihtiyacı artacağı için yürüyüşte istenen düzeyde olmayacaktır [19].

Yürümenin gerçekleştirilmesinde önemli kriterlerden biri de vücut dengesidir. Vücut dengesi hareket sisteminin belirli bir düzen halinde çalışması olarak tanılanabilir. Bu düzen sağlıklı bir insanda yürüme veya dinleme halindeyken vücudun dik durmasını sağlamaktadır. Dengenin sağlanabilmesi için tüm kaslar, eklemler ve iç organlar belirli bir uyum içinde çalışmaktadır. Bunu yaparken tüm vücut denge merkezine uyarı gönderir ve denge merkezi bu uyarıları işleyerek vücudun dengesini sağlamak için gerekli uyarıları oluşturur. Yürüme sırasında dengenin sağlanmaması durumunda normal yürüyüşten farklı olarak bir hareket yapabilmekte veya dengesini sağlanamayarak düşülebilmektedir.

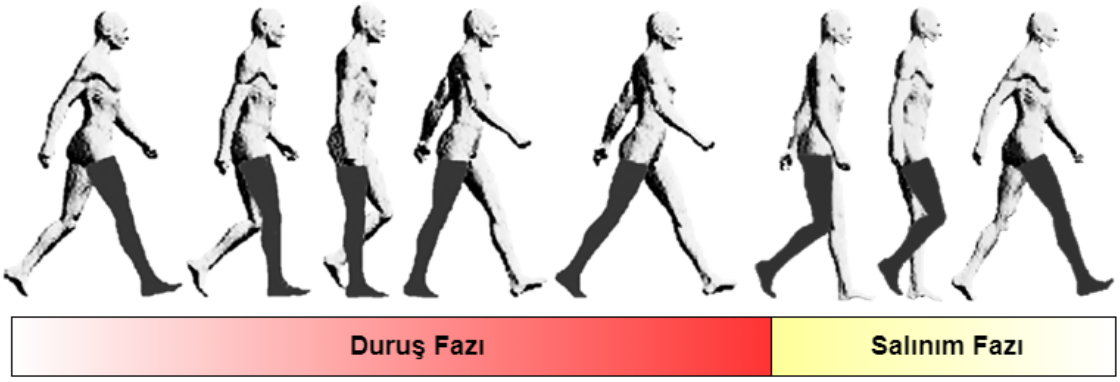
Günümüzde Ortopedik ve Nörodejeneratif hastalıkların tespitinde ve tedavisinde yürüyüş durumundan yararlanılmaktadır. Hastalığın yürüyüş üzerinde etkisine ve değişimine bakılarak hastalık hakkında bilgi elde edilebilmekte ve teşhis konulabilmektedir. Teşhisin konulabilmesi için hastalığın meydana getirdiği değişimler incelenmektedir. PH, Amiyotropik lateral skleroz gibi hastalıklar, kas ve sinir yapısında meydana gelen değişimler ile yürüyüş yapısında bozulmalara neden olmaktadır. Benzer şekilde Alzheimer hastalığı, inme, Serebral palsi, Duchenne Musküler Distrofi, Huntington hastalığı, omurilik hasarları, Perthes hastalıkları da yürüyüşü etkileyen Nörodejeneratif hastalıklarıdır. Ortopedik olarak ise kas yaralanmaları, spor kazaları gibi vücudun dengesini bozacak hastalıklar ve yaralanmalarda da yürüyüş durumda

değişiklikler meydana getirebilmektedir. Ayrıca vücuda takılan implantlar, ortezler ve protezler de yürüyüş üzerinde etki etmektedir.

Literatürde yürüyüş ve dengenin incelenmesinde farklı test yöntemleri kullanılmaktadır. Bunlar: 6 dakika yürüme testi, Tinetti performansa dayalı denge ve yürüme ölçeği, Standardize Mini Mental Test, Süreli Kalk ve Yürü Testi, 10 Metre Yürüme Testi, Türk Nöroloji derneğinin denge ve yürüme bozukluklarını değerlendirme formu gibi testlerdir [20].

2.2.1. Yürüme fazları

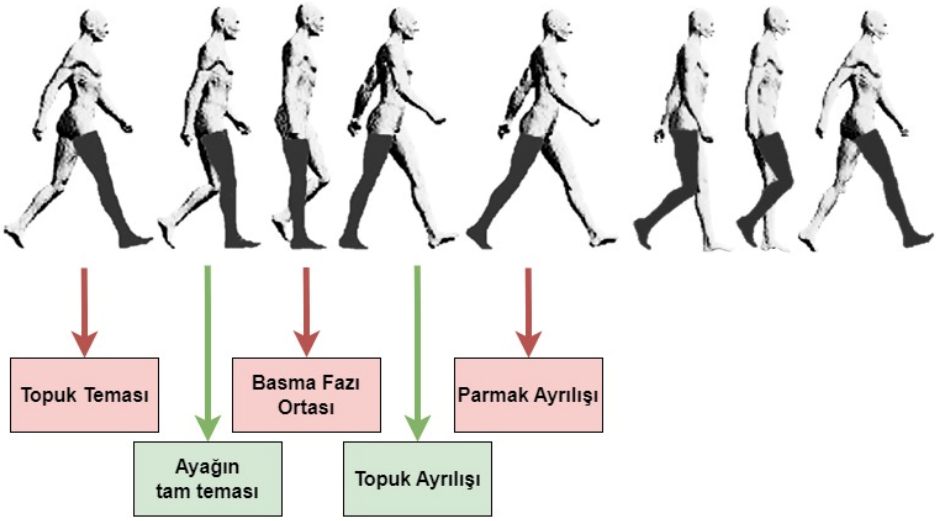
Yürüme sırasında bedenin bulunduğu yerden başka bir yere gidebilmesi için yürüyüş gerçekleşmesi gerekmektedir. Yürüyüş sırasında ayak topuğunun zemin ile temas ettiği andan başlayarak aynı ayağın tekrar topuk temasına kadar gecen işleme adım olarak ifade edilmektedir. Adımın belirli bir düzen halinde tekrarlanarak devam etmesine ise yürüme döngüsü olarak ifade edilmektedir. Adım her iki ayak içinde ölçülebilir bir değerdir. Bir ayak tam olarak yerle temas ettiğinde diğer ayağın öne doğru bir hareket yapmaktadır. Bundan dolayı her iki ayağın topuk temasları farklı zamanlarda gerçekleşmektedir. Bu nedenle adım ölçümü tek bir ayak üzerinden yapılmaktadır. Adım ise iki fazdan oluşmaktadır. Bunlar duruş ve salınım fazları olarak ifade edilmektedir. Sağlık insanlarda adımın %60'lık kısmını duruş fazı %40'lık kısmını ise salınım fazını temsil etmektedir. Bu oranlar herhangi bir hastalık durumunda değişiklik gösterebilmektedir. Şekil 2.1'de bir adımda duruş ve salınım fazları gösterilmiştir [21,22].



Şekil 2.1: Duruş ve salınım fazlarının gösterimi. [21].

Duruş Fazı: Adım sırasında topuğun zemin ile temasından başlayarak aynı ayağın parmak ucunun temasının kesilinceye kadar geçen bölümdür. Ayağın yer ile temas halinde olduğu

kısma denilmektedir. Bu kısım topuk teması, ayağın tam teması, duruş fazı ortası, topuk ayrılışı, parmak ayrılışı olarak 5 bölüme ayrılmaktadır. Bölümler şekil 2.2'de gösterilmiştir [21].



Şekil 2.2: Duruş fazının bölümlerinin gösterilmesi [21].

- **Topuk teması**: Duruş fazının başlangıcıdır. Kalça 30 derecelik açılı, diz kıvrılmadan düz bir şekilde ve ayak bileğin nötral pozisyonda olduğu bölümdür.

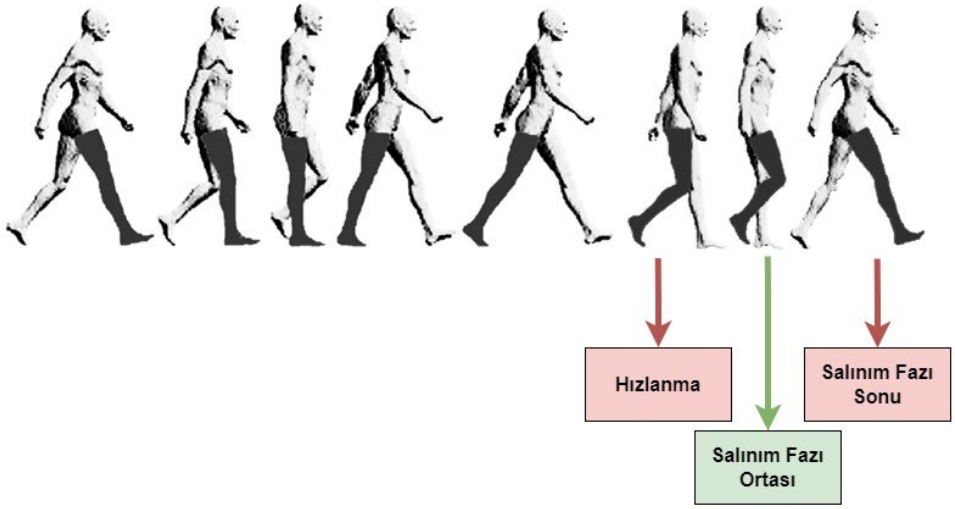
- **Ayağın tam teması:** Topuk temasının ardından gelen bölümdür. Bu bölümde tüm ayak tabanı yer ile temasın gerçekleştiği bölüm olarak ifade edilebilir. Bu aşamada diz 20 derecelik açı şeklinde ve ayak bileceği 10-15 derecelik plantar açı ile durmaktadır.

- **Duruş fazı ortası:** Ayağın tam temasından sonra gelen bölümdür. Bu kısımda vücut yer ile dikey konumda olduğu kısımdır. Ayak tabanın yer ile temasının sürdüğü kısımdır.

- **Topuk ayrılışı:** Duruş fazı ortası sonrasında gelen bölümdür. Bu kısımda ayağın topuk kısmının yer ile temasının kesildiği kısımdır. Bu kısımda kalça 10 derecelik açıda ve diz kırılmaya başlamaktadır.

- **Parmak ayrılışı:** Topuk ayrılışından sonra gelen ve duruş fazının son bölümü olan kısımdır. Bu kısımda ayak parmaklarının yer ile temasının kesildiği bölümdür. Bu bölüm bitikten sonra duruş fazı biterek salınım fazına geçilir. Bu kısımda diz kırılmış şekilde ve ayak bileği plantar açılı kırılmış şekildedir.

Salınım Fazı: Ayağın yer ile temasının kesildiği andan başlayarak aynı ayağın topuk temasına kadar geçen bölüme denir. Ayak bu fazda iken yer ile herhangi bir teması bulunmamaktadır. Bu kısım Hızlanma, salınım fazı ortası ve salınım fazı sonu olmak üzere 3 bölümden oluşmaktadır. Bölümler şekil 2.3'te gösterilmiştir [21].



Şekil 2.3: Salınım fazının bölümlerinin gösterilmesi [21].

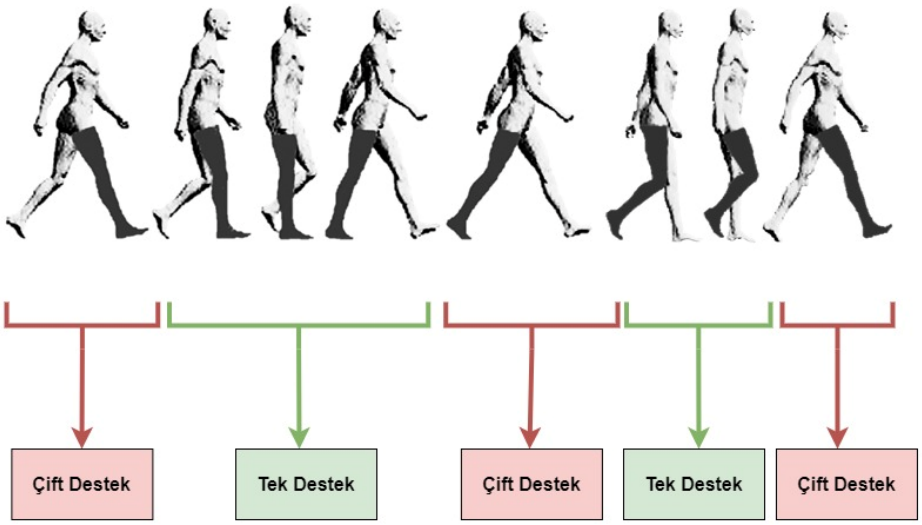
- **Hızlanma:** Bu bölüm salınımın fazının ilk kısmıdır. Ayak parmaklarının yerden ayrılması ile başlayan bölümdür. Kalça ve diz kırılma artar ve ayak bileği boşlukta sallanmaktadır.

- **Salınım fazı ortası:** Hızlanmadan sonra gelen ve salınım fazının ikinci bölümdür. Bu bölümde yeni bir adımın başlangıcı için ayak ileriye doğru hareket edildiği bölümdür. Kalça ve diz kırılmalar artar ve ayak bileği boşlukta sallanmaktadır.

- **Salınım fazı sonu:** Salınım fazı ortası bölümünden sonra gelen ve salınım fazının son bölümdür. Bu bölüm havada duran bacağın basan bacağı önüne geçmesiyle başlamaktadır. Bu bölümün bitişi ise ayağın topuk temasının gerçekleşmesi ile son bulmaktadır.

Yürüme döngüsü destek noktalarına göre incelendiğinde ise tek destek ve çift destek olmak üzere ikiye ayrılmaktadır. Tek destekte sadece bir ayağın zemin ile temas ettiğini bölümlerdir. Çift destek ise iki ayağın aynı anda zemin ile temas ettiği bölümlere denilmektedir. Çift destek bölümü yürüyüş döngüsünün %11'ine denk gelmektedir. Kişinin hızlı yürüme durumuna göre bu değer değişmektedir. Hızlı yürüdükçe çift destek süresi azalmaya başlar ve tek destek süresi

artmaktadır. Çift destek bölümü tamamen kalkması durumunda ise “koşma” olarak ifade edilen harekete geçilmiş olunur. Şekil 2.4’te bir adım da gerçekleşen çift destek ve tek destek kısımlarını göstermektedir [21].



Şekil 2.4: Destek bölümlerinin gösterilmesi [21].

2.2.2. Yürüme Analizi

Yürüme analizi, yürüyüşe neden olan kas- eklem hareketlerinin incelenmesine olanak sağlayan temel aşamalardan biridir. Nörolojik, ortopedik ve cerrahi hastalıkların tespiti edilmesi için yürüyüş incelenmesi ve analiz edilmesi ile gerçekleştirilebilmektedir. Yürüme analizi önemi hastalık tespitlerinde kullanıldığı için daha fazla artmaktadır.

Teknolojinin gelişime kadar olan süreçte gözleme dayalı olarak yürüyüş analiz edilmeye çalışılmıştır. Fakat bu incelemeler objektif bir yapıda olmadıkları için farklı kişiler tarafından benzer tanımlamalar yapılamamıştır. Bu da hastalığın tedavi ve tespitinin yanlış yapılmasına neden olmuştur. Bunun temel sebebi ise yürüyüş yapısının karmaşık olmasıdır. İnsan gözü saniyenin 1/12’sinden daha kısa süre içinde gerçekleşen olayları tespit edemez ve aynı anda bir den fazla düzlemde gerçekleşen olayları tespit edememektedir. Bu durumlardan dolayı temel yürüme bozuklukları olmak üzere hastalıkların tespitinde ayırt edici olması zorlaşmaktadır [23].

Günümüzde teknolojinin gelişmesi ile kameraya dayalı veya sensörlere dayalı veriler toplanmasının yolunu açmıştır. Yürüyüş verisi toplanacak kişilerin belirli bir alanda yürütülerek kamera veya sensörler yardımıyla bilgiler toplanarak kayıt altına alınmaktadır. Kayıt altına

alınan verilerin incelenmesi ve analiz edilmesi ile hastalıklar tespit edilmekte ve yürüyüş yapısı hakkında objektif bilgilere ulaşılmaktadır [23].

Yürüyüş analizi için toplanılan veriler genellikle kinematik, kinetik ve istatistiksel veriler olmak üzere üç kategoride sınıflandırılmaktadır. Bu üç kategori yürüyüşün farklı parametrelerine odaklanmaktadır [24].

Kinematik, yürüyüş hareketindeki kuvvetler dikkate alınmadan sadece yürüyüş oluşumu ile ilgilenen analiz türüdür. Kinematik analizde gövdenin, pelvisi, kakça ve diz ve ayak bileklerinin üç düzlem boyunca hareketlerini, açılarını, açısal hızı ve ivmesi ölçülür ve kayıt altına alınır. Bu gibi değerlerin kayıt altına alınması için kameralardan yararlanılarak alınmaktadır. Ayrıca kişiye takılan ivme ölçeler, hareket algılayıcılar tarafında bilgi toplanması işlemi de yapılır. Elde edilen veriler kullanılarak uzaydaki yer değişimlerine göre hareket açıları hesaplanmaktadır. Yürüme sırasında zamansal değişimlere bağlı olarak hız hesaplanabilmekte ve hıza bağlı olarak ise ivme değeri bulunabilmektedir. Bu elde edilen yürüyüş özellikleri incelenerek yürüyüş hakkında bilgiler elde edilebilmektedir [24].

Kinetik, yürüyüş sırasında ortaya çıkan yer çekimine karşı yapılan kuvvet, kas kuvvetleri, hareketi oluşturan veya kısıtlayan kuvvetler incelemektedir. Kuvvet değerlerin dikkate alındığı için sensörler yardımı ile kuvvet değerlerinin ölçülmesi gerekmektedir. Bu işlem için basınca duyarlı zemin üzerinde veya ayak tabanına yerleştirilen sensör verileri ile yer çekimine karşı yapılan tepki kuvveti bilgisi alınmaya çalışılmaktadır. Ayrıca kasların uygulama kuvvetlerini ölçmek için yürüyüş sırasında hareket eden kaslardan sensörler yardımı ile veriler alınabilmektedir. Toplanan sensör verileri incelenerek yürüyüş hakkında bilgiler elde edilmeye çalışılmaktadır. Ayrıca toplanan veriler sensörler tarafından alındığı için kinematik analiz için toplanan verilerden daha güvenli yapıdadırlar [24].

İstatistiksel veriler ise yürüyüş sırasında meydana gelen ve ölçülebilen bilgilerden oluşmaktadırlar. Bunlar yürüyüş hızı, adım süresi, kadans, adım uzunluğu, duruş süresi, duruş uzunluğu, salınım süresi, salınım uzunluğu, salınım/duruş oranı …vb. parametrelerdir.

- **Adım süresi (Stride Time):** Ayağın zemin ile temasından başlayarak aynı ayağın bir sonraki topuk temasına kadar geçen süre olarak tanımlanmaktadır. Normal bir insanda adım süresi ortalama olarak 1 saniye kadar sürmektedir [25]. Adım süresinde değişimler

yaş, boyun uzunluğu, kilo durumu, cinsiyet, hastalık durumlarına göre farklılıklar gösterebilmektedir.

- **Kadans:** Belirli zaman içerisinde atılan adım sayısı olarak ifade edilmektedir. Genel olarak kabul edilen süre ise 1 dakikadır. Bir dakika içeriğinde atılan adım sayılarının toplamına kadans olarak ifade edilir [26]. Sağlıklı bir kişide ortalama olarak kadans değeri erkeklerde 58 ± 23, Kadınlarda ise 56 ± 21 olarak değişmektedir [27]. Kadans değeri kişinin yürüyüş yapısına ve kişisel özelliklerine göre değişiklik göstermektedir. Kadans değerinde meydana gelen büyük değişiklikler yürüyüş yapısında değişimlere neden olduğu için hastalıkların tespitinde kullanılabilmektedir.

- **Adım Uzunluğu (Stride Length):** Bir adım boyunca kat edilen mesafe olarak tanımlanmaktadır. Bu mesafe aynı ayağın iki topuk basışı arasındaki mesafe olarak tanımlanabilmektedir. Sağlıklı bir kişide ortalama olarak 150 metredir. Adım uzunluğunda meydana gelecek değişimlerin incelenmesi ile hastalıklar tespit edilebilmektedir.

- **Yürüyüş Hızı:** Belirli bir süre içerisinde vücudun kat ettiği mesafe olarak tanılanabilmektedir. Genel olarak bir dakika içerisinde kat ettiği mesafe göre hesaplanmaktadır. Bundan dolayı hesaplama işlemi adım mesafesi ve kadans bağlı olarak hesaplanabilmektedir [26]. Denklem 2.1'de yürüyüş hızının hesaplaması işlemi gösterilmiştir. Sağlık bir kişide ortalama yürüyüş hızı 80 m /dk'dır. Hastalık durumlarında yürüme hızı yavaşlamakta veya çok düşük seviyelere düşmektedir [28]. Yürüyüş hızı incelenmesi ile hastalıklar hakkında bilgi elde edilebilmektedir.

$$\text{Hız (m/dk)} = \text{adım uzunluğu (m)} * \text{Kadans (adım/dk)} /120 \qquad (2.1.)$$

- **Duruş Süresi:** Adım sırasında topuğun zemin ile temasından başlayarak aynı ayağın parmak ucunun temasının kesilinceye kadar geçen kısmın süresine denilmektedir. Sağlıklı bir insanda ortalama olarak 0,6 saniye sürmektedir. Sürelerdeki değişimlere bakılarak hastalık tespiti için kullanılabilmektedir.

- **Duruş Uzunluğu:** Adım sırasında topuğun zemin ile temasından başlayarak aynı ayağın parmak ucunun temasının kesilinceye kadar kat edilen mesafeye denilmektedir.

- **Salınım Süresi:** Ayağın yer ile temasının kesildiği andan başlayarak aynı ayağın topuk temasına kadar geçen süreye denilmektedir. Sağlıklı bir insanda ortalama olarak 0,4 saniye sürmektedir. Süredeki değişimlere bakılarak hastalık tespiti yapılmaya çalışılmaktadır.

- **Salınım Uzunluğu:** Ayağın yer ile temasının kesildiği andan başlayarak aynı ayağın topuk temasına kadar kat edilen mesafeye denilmektedir.

- **Salınım/Duruş Oranı:** Bu oran aynı adım içerisinde yer alan salınım süresinin duruş süresine oranlanması ile hesaplanmaktadır. Oran genel olarak benzer şekilde ilerlemektedir. Salınım süresi, Duruş süresindeki artması veya azalması oran değiştirecektir. Bu değişimler hastalıklar hakkında bilgi verebilmektedir.

Laboratuvar veya doğal ortamda alınan veriler incelenerek anlamlı bilgi çıkartılır. Çıkartılan bilgiler ışığında hastalıkların tespitinde, Hastalıkların tedavisinde, bilimsel araştırmalar, Ortez ve protezlerin araştırmasında, Yeni protez tasarımlarında ve Eğitim için kullanılmaktadır.

2.2.3. Yürüme ve Parkinson

Parkinson Hastalığının temel sebeplerinden birisi olan dopamin, vücudumuzda hareket kontrolünü sağlamaktadır. Dopamin miktarında değişimler ve bozulmalar sonucunda yürüyüş ve hareket problemleri meydana gelmektedir. Bundan dolayı Parkinson hastası kişilerde yürüyüş sırasında adım uzunluğunda kısalma, kadans değerinin azalması, küçük adımlar ile yürüme, ayakları sürüyerek yürüme, ayak ucuna basarak yürüme, yürüyüş sırasında donma, yürüme düzensizliği, çift destek süresinin artması, yürümenin kontrolsüz bir şekilde hızlanması gibi belirtiler meydana gelmektedir [29]. Hastalığın diğer bir belirtisi ise Postüral dengesizliktir. Hastanın vücudu öne doğru eğik bir şekilde görülmektedir. Bunun sonucunda hastaların ayağa kalkma, yürüme ya da ayakta durma esnasında dengelerini sağlayamadıkları için düşebilmektedirler. Hastalar da meydana gelen düşmeler sonucu da yaralanmalar, eklem hasarları, kemiğin kırılması gibi birçok önemli probleme neden olmaktadır. İleri yaştaki hastalarda meydana gelen düşmeler ise daha büyük problemlere neden olmaktadır. Hastanın ilerleyen yaşından dolayı meydana gelebilecek herhangi bir vücut hasarının iyileşmesi uzun sürmekte veya kalıcı hasarlar bırakabilmektedir.

Parkinson hastalığın ilk evrelerinde yürüyüş, denge ve hareket sistemi ile ilgili belirtiler az görülmektedir. Hastalık ilerledikçe belirtilerin sayısı artmaktadır. Yürüyüş belirtilerinden veya

hareket sistemi belirtileri incelenerek ve analiz edilerek hastalığın teşhisi konulmaya çalışılmaktadır. Belirtilerin ilk başlangıcından itibaren tespit edilebilirse uygun dozda ilaçlara ile hastalık baskılanabilmekte ve hastanın konforu artırılabilmektedir. Hastalık erken evrelerinde tespit edilmez ve hastalık ilerler ise yüksek dozda ilaçlar kullanılsa bile hastalığa etki etmesi durumu olmamaktadır. Bu durumdan dolayı hastalığın erken evrelerinde tespit edilmesi önem arz etmektedir. Bu şekilde hastanın konforu artırabilir ve yaşam standartlarına uygun bir şekilde hayatını sürdürebilmesine olanak sağlanabilmektedir.

Yürüyüş verilerin incelenmesi için farklı kayıt yöntemleri bulunmaktadır. Bunlar Sensör teknolojileri, giyilebilir cihazlar, kamera sistemleri ve uzmanların görüşleridir. Sensör ve cihazlar tarafından alınan verilerin doğruluğu bakımından daha güvenli olduğu söylenebilmektedir. Elde edilen verilerin objektif bir şekilde analiz edilebileceği ve doğru sonuçların vereceği açıktır. Ayrıca sensör kullanımın kolay olması, taşınabilir olması ve uygun olması bir avantajdır [30]. Bu durumlardan dolayı elde edilen verilerin mühendislik yöntemleri ile yorumlanması ve incelenmesi ile birlikte Parkinson hastalığının erken tespit edilmesine olanak sağlamaktadır.

Yürüme sırasında veri toplanması için farklı teknolojiler kullanılmaktadır. Bunların bazıları 3 boyutlu kamera sistemleri, ayak tabanı yerleştirilen sensörler, giyilebilir cihazlar, akıllı telefon tabanlı yazlımlar, ivmeölçerler, jiroskoplar gibi teknolojiler kullanılmaktadır. Giyilebilir teknoloji olarak ayak bileğine veya diz kısmına takılan içerisinde sensörlerin olduğu cihazlar kullanılmaktadır. Bu sensörler vasıtasıyla adım bilgileri, yürüyüş bilgileri gibi sayısal değerler elde edilmektedir. Ayrıca ayak açısı, ayağın havadayken yerden yüksekliği, ayak hareketleri gibi verilerde toplanabilmektedir. Diğer bir yöntem olarak ise kameraya dayalı (3 boyutlu kamera, kameralar ... vb.) cihazlar kullanılarak yürüyüş verilerinin toplanabilmektedir. Kamera ile kayıt altına alındığı için yürüyüş anın tüm ayrıntılarına sahiptir. Bundan dolayı yürüyüş hakkında daha ayrıntılı bilgi verebilmektedir. Fakat sabit bir yerde olması ve sistemin kurulabilmesi için geniş bir alan olmasından dolayı avantajlı bir yapıda değildir. Ayak tabanına yerleştirilen sensörler kullanılarak yürüyüş verileri toplanabilmektedir. Ayağın farklı bölgelerine bir veya birden fazla sensör yerleştirilerek zaman bazında kuvvet değerleri toplanmaktadır. Yürüme sırasında her noktadan alınan kuvvet verileri anlık olarak bir cihaza kaydedilir. Bu şekilde kuvvet değerleri incelenerek veya yorumlanarak yürüyüş hakkında bilgiler elde edilmektedir.

Ayak tabanının altına yerleştirilen sensörler kullanılarak sağlıklı kişiler ve Parkinson hastası kişilerin arasındaki kuvvet farklılıklarına bakılarak hastalık tespit edilmeye çalışılmaktadır. Sağlıklı kişilerden farklı olarak Parkinson hastası olan kişilerin, yürüyüş sırasında daha fazla parmak uçlarına basmaya meyillidir. Bu durumun temel sebepleri öne doğru şekilde eğik durması ve kısa adımlar atmaya yönelmesidir. Hastalık ilerledikçe topuk alanındaki sensörlerden ölçülen kuvvet verileri azalmakta ve parmak uçlarındaki kuvvet değeri artmaktadır. Bu durumlardan dolayı Parkinson hastalığının tespitinde ayak altında yer alan sensörlerden yürüyüş sırasında alınan kuvvetlerin incelenmesi ile hastalık tespit edilmeye çalışılmaktadır. Bu alanda araştırmalar artmış ve yeni çalışmalar yapılmaya devam etmektedir [31].

2.3. LİTERATÜR TARAMASI

Parkinson hastalığının günümüzde bilinen bir tedavi yöntemi bulunmamaktadır. Parkinson hastası bireylerin yaşama şartlarının iyileştirilmesi ve hastalığın ilerlenmemesi için tedaviler uygulanması gerekmektedir. Fakat Parkinson hastalığının geç teşhis edilmesi veya farklı bir hastalık gibi algılanması durumlarında tedavi uygulanamamakta ve Hastalık ilerlemektedir. Bu durumlardan dolayı hastalığın erken teşhis edilmesi önem teşkil etmektedir.

Hastalığın tespit edilemeyip hastalığın ilerlemesi durumunda, ilaç tedavisi uygulansa bile belirtiler eski haline dönmemekte ve sadece ilerlenmesi durdurulabilmektedir. Hastalığın belirtilerini azaltmak için son çare olarak ise beyin pili adı verilen yöntem uygulanmaktadır. Bu şekilde hastalık belirtileri azaltılarak daha iyi bir yaşam sürebilmesi sağlanmaktadır. Fakat bu yöntemin uygulanması çeşitli nedenlerden dolayı risk barındırmaktadır. Parkinson hastası bireylerin yaşlarının yüksek olması, ameliyat sırasında enfeksiyon riskinin olması, beyin kanaması ve görme kaybı gibi riskler barındırmaktadır. Bu risklerden dolayı Parkinson hastası bireyler için beyin pili yöntemi son olarak düşünülen bir yöntem olarak görülmektedir. Bu durumlar dikkate alındığında hastalığın erken dönemlerinde tespit edilip hastalığın ilerlemesini durdurmak önemlidir.

Parkinson hastalığının tanısında UPDRS olarak isimlendirilen ve doktorlar tarafından belirlenen bir ölçek bulunmaktadır. Bu ölçeklendirme yöntemi Başlık 2.1. kısmında anlatılmıştır. Bu yöntemde hasta ve hasta yakınlarından alınan anket verilerin, puanlama sistemine göre doktorlar tarafından değerlendirilmesi ile hastalık tespit edilmeye

çalışılmaktadır. Bu durumdan dolayı hasta ve hasta yakınlarının verdiği bilgilere dayandığı için uzun sürmekte ve hatalı bilgi verme gibi durumlar olabilmektedir. Verilen bilgilerde hatalar veya yanlış olması durumunda Parkinson hastalığı tespit edilmemektedir. Bu sebeplerden dolayı hastalığın tespit edilmesinde UPDRS yöntemi dışında farklı yöntemlere yönelinmiştir.

Günümüz teknolojisinin gelişmesi ile bilgisayar dayalı yöntemlerin kullanımı farklı alanlara girmiştir. Bunlardan bir tanesi de sağlık alanındır. Parkinson hastalığın tespit edilmesinde bilgisayar dayalı yöntemler kullanılmakta ve kullanılmaya devam etmektedir. Bunun temel sebepleri ise UPDRS yönteminden farklı olarak objektif ve doğru sonuç vermesidir. Bu durumlardan dolayı Parkinson hastalığının tespitinde araştırmalar yapılmaktadır.

Araştırmalar genel olarak Parkinson hastalığının belirtilerinin sonucunda oluşan değişimlerin incelenmesi ile elde edilen verilere dayanmaktadır. Bu veriler kullanılarak yöntemler geliştirilmiştir. Bunlar; hastalarda meydana gelen ses değişimlerine bağlı geliştirilen yöntemler, Parkinson hastası bireylerin el yazısında meydana gelen değişimlerin incelendiği yöntemler, Hastalarda meydana gelen parmak titremesinin incelendiği yöntemler ve Parkinson hastası bireylerde meydana gelen yürüyüş değişimlerin incelenmediği yöntemlerdir.

Parkinson hastalığının tespit edilmesinde literatürde yer alan çalışmalardan biri de seste meydana gelen değişimlerin incelendiği yöntemlerdir. 2019 yılında 91 katılımcı (43 Parkinson hastası birey ve 48 kişide sağlıklı birey) ile yapılan çalışmada katılımcıların ses kayıtları alınmıştır. Alınan ses kayıtları incelenerek frekansa bağlı öznitelikler çıkartılmıştır. Çıkartılan öznitelikler derin öğrenme ağ yapısına girdi olarak verilerek Parkinson hastalığı tespit edilmeye çalışılmıştır. Sonuç olarak %89,15 oranında hastalık ayırt edildiği tespit edilmiştir [32].

2014 yılında yapılan bir araştırmada ise Parkinson hastalığının tespitinde el yazısı karakteri ve yazı yazarken elde meydana gelen değişimlerin incelenmesi ile tespit işlemi yapılmıştır. Bu çalışma için 37 Parkinson hastası bireyden ve 38 sağlıklı bireyden el yazısını ile belirlenen bir kelimeyi istenen alana yazmaları istenmiştir. Elde edilen el yazısı bilgileri kullanılarak yazının karakterini incelenmiş ayrıca el hareketleri ile ilgili bilgiler toplanmıştır. Elde edilen öznitelikler arasında seçim yapılarak destek vektör makinesi yöntemi kullanılarak hasta bireyler ve sağlıklı birey olarak sınıflandırma işlemi yapılmıştır. Sınıflandırma sonucunda %84 oranında doğru sınıflandırdığı tespit edilmiştir. Bu durumun sonucunda Parkinson hastalığının tespit edilmesinde kullanılabileceği anlaşılmıştır [33].

Parkinson hastalığının tespitinde literatürde kullanılan yöntemlerden biri de parmak titremesinin incelenmesi ile hastalığın tespit edildiği yöntemdir. Bu yöntem kullanılarak 2013 yılında yayınlanan çalışmada 49 Parkinson hastası birey ve 41 sağlıklı bireyden parmak verileri toplanmıştır. Toplanan veriler içerisinde parmağın serbest durumdaki hareketleri, parmak hareket ettirildiğinde meydana gelen hareket bilgisi ve başparmak ile işaret parmağının birbirlerine vurularak elde edilen sinyaller toplanmıştır. Bu toplanan sinyal verilerinden öznitelikler çıkartılarak evrimsel optimizasyon algoritmaları kullanılarak sınıflandırma işlemi yapılmıştır. Sınıflandırma sonucunda %95 civarında doğru çalıştığı tespit edilmiştir. Bu çalışma ile Parkinson hastalığının tespit edilmesinde evrimsel optimizasyon algoritmaların kullanılabileceği ve iyi performans verdiğini görülmüştür [34].

2.4. Parkinson hastalığının tespitinde yürüyüş verisi ile yapılan çalışmalar

Parkinson hastası bireylerde hastalık belirtisi olarak en dikkat çeken belirtilerden birisi de yürüyüşte meydana gelen değişimlerdir. Bu değişimlerde hastanın yürüyüş hızı, adım ve ayak hareketlerinde değişimler meydana getirmektedir. Bu değişimler sağlıklı bireyler göre farklı olduğu için hastalığın tespit edilmesinde kullanılmaktadır.

Literatürde yürüyüş verisi elde edilmesi için ayak tabanına yerleştirilmiş sensörler kullanılmaktadır. Sensör verileri ile dikey yer reaksiyon kuvveti adı veriler basınç tepkilerini toplamaktadır. Bu duruma yerin sensörlere uyguladığı tepki kuvvetinin Newton cinsinden kayıt altına alınması olarak ifade edilmektedir. Alınan veriler farklı makine öğrenmesi ve derin öğrenmesi yöntemleri kullanılarak Parkinson hastalığının tespitinde kullanılmıştır.

Parkinson hastalığının tespitinde yürüyüş verisi olarak PhysioNet yer alan “Parkinson hastalığı” verisi kullanılmıştır. Bu veri seti içerisinde 93 Parkinson hastası bireyden alınan ve 72 sağlıklı bireyden alınan yürüyüş verileri yer almaktadır. Bireylerden veriler alınırken, düz bir zeminde 120 saniye boyunca yürütülerek sensörler tarafından alınan basınç bilgileri kaydedilerek oluşturulmuştur. Literatürde yürüyüş ile ilgili yapılan çalışmalarda bu ve buna benzer veri setleri kullanılmıştır. Literatürde yer alan çalışmalar hakkında Tablo 2.1’de bilgiler verilmiştir.

Tablo 2.1:Yürüyüş ile ilgili literatürde yer alan çalışmalar hakkında bilgiler.

Referanslar	Domain	Öznitelik	Yöntem	Sonuç
[32]	Zaman	Ham Sensör Verileri	Evrişimli Sinir Ağı and Yapay Sinir Ağı	%88.1
[35]	Zaman	Ham Sensör Verileri	Q-geri yayılmalı Zaman Gecikmeli Sinir Ağı	%91.49, % 92.19 ve% 90.91
[36]	Zaman	Duruş Aşaması ve Salınım Aşaması	Temel Bileşen Analizi ve Öklid mesafeleri	% 81
[37]	Frekans	Mutlak değerlerin ortalaması, Katsayıların medyanı, Ortalama güç, Enerji, Maksimum değer, Standart sapma, Çarpıklık, Basıklık, Mutlak ortalama değerlerin oranı	Esnek Geri Yayılım Algoritması ile Sinir Ağı	%86.75
[38]	Frekans	Ortalama, Medyan, Her bir alt banttaki katsayıların mutlak değerlerinin standart sapması, Her bir alt banttaki dalgacık katsayılarının ortalama gücü, Bitişik alt bantların mutlak ortalama değerlerinin oranı	Ağırlıklı Bulanık Üyelik İşlevli Sinir Ağı	%77.33
[39]	Zaman	minimum, maksimum, medyan, basıklık, ortalama, çarpıklık, standart sapma ve ortalama mutlak sapma	Geri Yayılımlı Yapay Sinir Ağı	%89.97
[40]	Zaman - Frekans	Adım mesafesi, Adım süresi, Duruş aşaması , Sallanma aşaması Topuk kuvveti, Parmak altı kuvveti, Ayak parmağı kuvveti, Topuk için normalleştirilmiş kuvvet, Parmak altı için normalleştirilmiş kuvvet, Parmak için normalleştirilmiş kuvvet, Genlik, Güç dağılımı, Frekans dağılımı, Medyan frekans.	Lineer Diskriminant Analizi	%86.9
[41]	Zaman - Frekans	Sallanma süresi, Adım süresi, Duruş süresi ve Ayak vuruş profili	Destek Vektör Makineleri	%92.7
[42]	Zaman	Adım uzunluğu, Adım süresi, Uzun adım uzunluğu, Adım süresi, Sallanma aşaması, Duruş aşaması, Kadans, Topuk kuvveti, Maksimum ağırlık kabul kuvveti, Orta duruş kuvveti, İtme kuvveti, Parmak kuvveti.	Destek Vektör Makineleri	%100, %88.88, %100
[43]	Zaman	Ortalama, Standart sapma, enerji, entropi, korelasyon, Ardışık mutlak farklar, basıklık, çarpıklık, medyan, minimum, maksimum, varyans katsayısı	En Yakın Komşu Algoritması - Rastgele Orman	%92.96
[44]	Zaman	Entropi, Enerji, Korelasyon, Varyasyon katsayısı, Çarpıklık, Basıklık, Ortalama, Standart Sapma	Çok Katmanlı Algılayıcı Sinir Ağı	%88.89
[45]	Zaman	Ham Sensör Verileri	Evrişimli Sinir Ağı	%88.7

Yapay sinir ağı yönteminin farklı bir versiyonu olan gecikmeli yapay sinir ağı ile alınan veriler sınıflandırma ve ciddiyet tespitti işlemi yapılmıştır. Ayak tabanında alınan sensör bilgileri gecikmeli şekilde yapay sinir ağına gönderilmiş ve ağırlıklar güncellenerek Parkinson hastalığı tespit edilmiştir. Bu şekilde karar destek sistemi oluşturulmaya çalışılmıştır. Sonuç olarak üç farklı veri seti kullanılarak Parkinson hastası bireylerin ve sağlıklı bireylerin sınıflandırma performansı %91.49, % 92.19 ve% 90.91 şeklinde doğruluk değerleri elde edilmiştir [35].

Temel Bileşen Analizi yöntemi kullanılarak Parkinson hastalığı tespit edilmeye çalışılmıştır. Yürüyüş sırasında alınan sensör verileri kullanılarak Temel bileşen Analizi yöntemi ile Öznitelikler çıkartılmıştır. Çıkartılan Özniteliklerin azaltılması veya performansının değerlendirilmesinde ise Temel Bileşen Analizi yöntemi kullanılmıştır. Yöntem sonucunda en iyi performansa sahip öznitelikler bulunmuştur. Bulunan Öznitelikler kullanılarak Öklid mesafesine bağlı sınıflandırma işlemi yapılmıştır. Sınıflandırma sonucunda %81 oranında doğruluk elde edilmiştir [36].

Sol ve sağ ayak altından alınan sensör verileri kullanılarak yeni sinyaller üretilmiştir. Sol ayakta T zamanda alınan maksimum sensör değerinden Aynı zamanda alınan minimum değerden çıkartılarak yeni bir t sinyali elde edilmiştir. Aynı işlem sağ ayaktan alınan sensör içinde yapılmıştır. Ayrıca sol ayakta yer alan t zamanda alınan sensör verilerinin toplamın aynı zamanda alınan sağ ayaktan alınan sensörlerin toplam değerinden çıkartılmıştır. Elde edilen yeni sinyal değerlerine dalgacık dönüşümü uygulanmıştır. Elde edilen frekans sinyallerinden 162 tane öznitelik çıkartılmıştır. Çıkartılan öznitelikler esnek geri yayılımlı yapay sinir ağı, Naive Bayes, Destek Vektör Makineleri yöntemleri kullanılarak Sınıflandırma işlemi yapılmıştır. Sınıflandırma sonucunda esnek geri yayılımlı yapay sinir ağı yöntemi kullanılarak %86,75 oranında doğruluk elde edilmiştir [37].

Yürüyüş sırasında alınan sensör verilerine 3 farklı önişlem uygulanmıştır. Önişlem sırasında sol ayağın altındaki sensörlerden gelen dikey yer tepki kuvvetlerinin maksimum ve minimum farkı alınarak yeni sinyal elde edilmiştir. Diğer bir ön işlemde ise sol ayakta yer alan sensör değerlerinden sağ ayaktaki sensör değerlerinin toplamı çıkartılarak yeni sinyal oluşturulmuştur Son olarak ise toplam farklarından elde edilen sinyal kullanılarak maksimum değerlerden minimum değer çıkartılarak yeni sinyal elde edilmiştir. Elde edilen sinyallere dalgacık dönüşümü uygulanmıştır. Elde edilen frekans değerlerinden öznitelikler çıkartılarak ağırlıklı bulanık üyelik fonksiyonuna sahip sinir ağı kullanılarak sınıflandırma işlemi yapılmıştır.

Sınıflandırma sonucunda %77.33 oranında doğruluk elde edilerek Parkinson hastalığı tespit edilmeye çalışılmıştır [38].

Parkinson hastası olan bireylerin yürüyüş yapıları analiz edilerek sağlıklı bireylerden ayırt edilmesi amacıyla sensör verilerinden istatistiksel öznitelikler çıkartılmıştır. Sensörler verilerinden çıkartılan öznitelikler minimum, maksimum, medyan, basıklık, ortalama, çarpıklık, standart sapma ve ortalama mutlak sapmayı içermektedir. Sınıflandırma işlemi için en iyi özniteliklerin seçilmesi işlemi için optimizasyon yöntemleri kullanılmıştır. Kullanılan optimizasyon yöntemleri Parçacık sürü optimizasyonu, Tabu arama algoritması gibi yöntemler kullanılarak en iyi öznitelikler belirlenmiştir. Belirlenen öznitelikler kullanılarak sınıflandırma algoritmaları ile sınıflandırma işlemi yapılmıştır. Sınıflandırma sonucunda Parkinson hastası bireylerin ayırt edilebildiği tespit edilmiştir ve %89.97 oranında doğruluk elde edilmiştir [39].

Parkinson hastalığının erken dönemlerinde titremeler meydana gelebilmektedir. Ayrıca erken dönemlerde yürüyüşte değişimler meydana gelebilmektedir. Parkinson hastalığının tespitinde hem yürüyüş verileri hem de titreme belirtileri incelenerek hastalığın tespit edilmesi hakkında literatürde araştırma yapılmıştır. Yapılan çalışmada yürüyüş verilerinden istatistiksel öznitelikler çıkartılmıştır. Titreme için alınan sensör verilerine frekans dönüşümü uygulanmış ve genlik, güç dağılımı ve frekans dağılımı gibi öznitelikler çıkartılmıştır. Lineer diskriminant analizi yöntemi kullanılarak elde edilen öznitelikler ile sınıflandırma işlemi yapılmıştır. Sınıflandırma sonucunda yürüyüş verileri kullanılarak %86.9 doğruluk elde edilmiştir. Titreme için çıkartılan öznitelikler kullanılarak ise %91.92 oranında doğruluk elde edilmiştir. Sonuç olarak iki belirtinin erken dönemlerde alınarak sınıflandırması sonucunda yüksek oranda hastalığın tespit edilebileceği anlaşılmıştır [40]. Literatürde yer alan farklı çalışmada ise benzer şekilde yürüyüş ve titreme belirtileri kullanılarak Parkinson hastalığının tespit edilmesi ile ilgili araştırma yapılmıştır. Yürüyüş sırasında ayak tabanından alınan sensör verileri ön işlemden geçirilerek öznitelikler çıkartılmıştır. Yürüyüş verilerinden öznitelik olarak adım süresi, duruş süresi, salınım süresi ve ayak vuruşu (sensör 1 ve sensör 8 için) bilgileri çıkartılmıştır. Ayrıca 16 Parkinson hastasından alınan titreme verileri kullanılarak öznitelikler çıkartılmıştır. Öznitelik çıkarma işlemi sırasında alınan titreme verilerine frekans dönüşümü uygulanmıştır. Çıkartılan öznitelikler ayrı bir şekilde Destek vektör makineleri yöntemi kullanılarak sınıflandırma işlemi yapılmıştır. Sınıflandırma sonucunda sağlıklı bir bireyi ile Parkinson hastası bireyden ayırt etmek için yürüyüş verilerin etkili olduğu tespit edilmiştir. Ayrıca titreme

verilerinin de benzer şekilde ayırt etmekte etkili olduğu anlaşılmıştır. Sonuç olarak yürüyüş verileri kullanılarak %92.7 oranında doğru ayırt ettiği tespit edilmiştir [41].

Üç farklı çalışmadan toplanan yürüyüş verileri kullanılarak Parkinson hastalığının tespiti için en önemli özniteliklerin bulmaya çalışılmıştır. Ayrıca yürüyüş parametreleri kullanılarak otomatik tespit edilebilen bir sistem oluşturmayı hedeflenmektedir. Bu durum için ayak tabanından alınan sensör verilerinden kinetik ve kinematik öznitelikler çıkartılmıştır. Çıkartılan öznitelikler arasından en iyi öznitelikler belirlenmesi için sınıflandırma işlemi uygulanmıştır. Sınıflandırma performansının değerlendirilmesine göre her bir veri seti için en iyi öznitelikler belirlenmiştir. Bunun sonucunda üç veri setinin doğruluk değerleri %100, %88.88 ve %100 olarak elde edilmiştir. Bu çalışmanın sonucunda farklı veri setleri için belirlenen özniteliklerin kullanılması Parkinson hastalığının tespitinde önemli olduğu görülmüştür [42].

Parkinson hastalığının tanısının konulması için verilerin ön işlem aşamasından geçirilmesinin önemi incelenmiştir. Yürüyüş sırasında ayak tabanından alınan sensör verilerinden gürültünün kaldırılması için Ortak Ortalama Referans, Medyan Ortak Ortalama Referans ve Ağırlıklı Ortak Ortalama Referans yöntemler uygulanmıştır. Daha sonra gürültüsüz verilere yerel ikili patern yöntemi uygulanılarak istatistiksel öznitelikler çıkartılmıştır. Çıkartılan öznitelikler Lojistik Regresyon, Rastgele Orman algoritması ve K-en yakın komşu yöntemlerinden yararlanılarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma sonucunda K-en yakın komşu yöntemi ile %92.96 doğruluk ile Parkinson hastalığı tespit edildiği görülmüştür. Ayrıca bu çalışmada sensör bazlı olarak incelemeler de yapılmıştır. Hangi sensörün Parkinson hastalığının tespitinde önemli olduğu incelenmiştir. Son olarak ise gürültünün azaltılması Parkinson hastalığının tespit edilmesinde önemli olduğu anlaşılmıştır [43].

Parkinson hastalığının tespitinde standart bir yaklaşım elde etmek için tek boyutlu yerel ikili patern yöntemi ve makine öğrenmesi algoritmaları kullanılarak yeni bir yaklaşım oluşturulmuştur. Tek boyutlu yerel ikili patern yöntemi kullanılarak ayak tabanından alınan sensör verilerinden histogramlar oluşturulmuştur. Oluşturulan histogramlar kullanılarak istatistiksel öznitelikler çıkartılmıştır. Öznitelikler kullanılarak Bayes ağları, naive bayes, lojistik regresyon, çok katmanlı algılayıcı, Kısmi C4.5 karar ağacı, Rastgele orman algoritması gibi farklı sınıflandırma yöntemleri ile Parkinson hastalığı tespit edilmeye çalışılmıştır. Önerilen yaklaşımın elde edilen doğruluğu değeri 108 Öznitelik kullanıldığında %88.8889 iken, seçilen 21 Öznitelik kullanıldığın ise %87.5817 olarak tespit edilmiştir. Bu çalışmada

Ayrıca literatürde yer alan zaman ve frekans bağlı öznitelik çıkarma yöntemlerinden farklı bir yöntem olan tek boyutlu yerel ikili patern yöntemi kullanılarak Parkinson hastalığı tespiti yapılmıştır [44].

Literatürde ayak tabanından alınan sensörleri gri görüntüye dönüştürerek evrişimli sinir ağı kullanılarak Parkinson hastalığı tespit edilmeye çalışılmıştır. Alınan sinyal verileri 2.4 saniye olacak şekilde parçalara bölünmüştür. Alınan sensör verileri dikey yer reaksiyon kuvvetine göre normalizasyon işlemi uygulanarak görüntü haline getirilmiştir. Görüntü boyutu 16X240 boyutlu gri görüntülerden oluşmaktadır. Oluşan görüntülere ayrıca etiket bilgisi de eklenmiştir. Görüntüler kullanılarak oluşturulan evrişimli sinir ağı ile sınıflandırma işlemi yapılmıştır. Sınıflandırma sonucunda %88.7 doğruluk elde edilmiştir [45]. Farklı bir çalışmada ise ayak tabanından alınan sensör değerleri spektrogram görüntüsüne dönüştürülerek evrişimli sinir ağına girdi olarak verilmiştir. Sonuç olarak Parkinson hastalığının tespitinde %88,17 oranda doğru sonuç verdiğini görülmüştür. Bu durumdan dolayı Parkinson hastalığının tespitinden evrişimli sinir ağı yönteminin uygulanabileceğini anlaşılmıştır [32].

3. VERİ VE YÖNTEM

3.1. MAKİNE ÖĞRENMESİ HAKKINDA GENEL BİLGİLER

Gün geçtikçe teknoloji, dijitalleşme ve sanayileşme artmaktadır. Bu durumlardan dolayı ortaya çok fazla sayıda veri çıkmaktadır. Ortaya çıkan verilerin içerisinde önemli bilgiler bulunmaktadır. Bu bilgilere erişebilmek için verinin analiz edilmesi, düzenlenmesi ve anlamlı hale getirilmesi gerekmektedir. Bu durumlara çözüm olarak veri madenciliği, makine öğrenmesi ve derin öğrenme gibi yeni metotlar geliştirilmiştir.

Geliştirilen metotların arasında yer alan makine öğrenmesi yöntemi, insanların öğrenme yapısını taklit ederek verinin analiz edilmesi sağlayan bilgisayar biliminin bir dalıdır. Makine öğrenmesi yöntemlerinde önceki veriler kullanılarak öğrenme işlemi gerçekleştirmektedir. Öğrenme işlemi sonrasında ise yeni verilerin tahmini, analizi ve sınıflandırmasını gerçekleştirebilmektedir. Bu şekilde büyük boyutlarda verilerden anlamlı bilgiler elde edilmektedir. Makine öğrenmesi konusunda birçok farklı algoritma ve yaklaşım bulunmaktadır. Ayrıca makine öğrenmesi üç konu üzerinde işlemler yapmaktadır. Bunlar ise Tahmin (prediction), kestirim (estimation) ve sınıflandırma (classification) olarak isimlendirilmektedir.

Makine öğrenmesi yöntemleri verinin elde edilmesi ve yapısı ile ilgilenmemektedir. Verileri kullanarak tahminler ve sınıflandırma işlemleri ile en iyi bilgiler veren yöntemler ile ilgilenmektedir. Bundan dolayı performansının artması ve azalması verinde yapılacak değişikliklere veya veriye eklenen yeni verilere bağlıdır. Eğer değişikler olumlu yönde devam ederse yöntemin performansı artmakta ve daha iyi öğrenmeye başlamaktadır. Yapılan değişiklikler olumsuz yönde değişirse yöntemin performansı azalmakta ve öğrenmesi gerilemektedir.

Elde edilen veriler, makine öğrenmesi yöntemlerine girdi olarak verilmeden önce ön işlemden geçirilmesi gerekmektedir. Bu şekilde veri makine öğrenmesi yöntemlerine uygun hale getirilir ve öğrenme performansı artırılmaktadır. Ayrıca veri de eksik, hatalı ve gereksiz olan verilerin çıkartılması gerekmektedir. Bu veriler gürültü verisi olarak isimlendirmektedir ve anlamlı bilgi çıkarmak için uygun değillerdir. Bu tür veriler makine öğrenmesi yöntemleri için uygun bir formata dönüştürülememektedir. Verilerden eksik, hatalı ve gereksiz bilgiler çıkartıldıktan sonra veriyi, makine öğrenmesi yöntemine uygun olacak şekilde ölçeklendirilmektedir. Son

olarak ise verilerden anlamlı bilgiler çıkartılarak girdi olarak makine öğrenmesine verilmektedir.

Verilerden çıkartılan anlamlı bilgilere "Öznitelik" olarak isimlendirilmektedir. Öznitelik bilgileri farklı istatistiksel yöntemler kullanılarak elde edilmeye çalışılmaktadır. Ayrıca Özniteliklerin yanında sınıf bilgisi de yer almaktadır. Bu sınıf bilgisi kullanılarak sınıflandırma sırasında öğrenme işleminin gerçekleşmesini kontrol etmek için kullanılmaktadır.

Makine öğrenmesi yöntemlerinde öğrenme işlemi için öznitelik ve sınıf bilgileri iki kısma ayrılmaktadır. Bunlar "eğitim" ve "test" olarak isimlendirilmektedir. Eğitim kısmı ile çıkartılan öznitelikler kullanılarak yöntemin öğrenmesi ve modeli oluşturmak için eğitimden geçirilmektedir. Test kısmında ise modelin test edilerek modelin performansı hesaplanmaktadır. Bu şekilde makine öğrenmesi modellerinin öğrenme süreci ve performansının belirlenmesi işlemleri yapılmaktadır.

Bu çalışmada makine öğrenmesi yöntemi kullanılarak sınıflandırma işlemi gerçekleştirilecektir. Bir sonraki bölümlerde veri ve yöntemler hakkında bilgiler verilecektir.

3.2. KULLANILAN VERİ KÜMESİ

Bu çalışmada, PhysioNet sitesinde yer alan "Parkinson hastalığında yürüyüş" adlı çalışmada yer alan veriler kullanılmıştır [46]. Bu veri kümesi içerisinde sağlıklı bireylerden ve Parkinson hastası bireylerden alınan yürüyüş verileri yer almaktadır. Veritabanında 93 Parkinson hastası birey ve 72 sağlıklı bireyden alınılarak toplanmıştır. Toplam olarak ise 165 kişiden veri toplanmıştır. Veriler toplanırken 3 farklı çalışmada elde edilen veriler birleştirilerek veritabanı oluşturulmuştur. 3 veri kümesi sırasıyla GA, JU ve SI isimleri kullanılarak isimlendirilmiştir. Bu üç çalışma başlıklar halinde incelenecektir.

Veritabanı oluşturulurken hem sağlıklı bireylere hem de Parkinson hastası bireyleri düz bir zemin üzerinde yaklaşık olarak 120 saniye boyunca, normal yürüyüş hızlarında yürümeleri istenmiştir. Bu yürüyüş sırasında her bir ayak tabanına yerleştirilen 8 sensörden veriler toplanmıştır. Ayak tabanına yerleştirilen sensör konumları Şekil 3.1.'de gösterilmektedir. 16 sensörden saniyede 100 örneklem alınacak şekilde basınç değerleri alınmıştır. Alınan basınç değerlerine dikey yer reaksiyon kuvveti olarak isimlendirilmektedir. Dikey yer reaksiyon kuvveti, zeminin ayak tabanına uygulandığı tepki kuvveti olarak tanımlanmaktadır. Ayrıca

sensör verileri elde edildikten sonra sağ ve sol ayaktaki sensör verilerin toplamını içeren 2 tane daha veri oluşturulmuştur.



Şekil 3.1: Sensör konumları

Veritabanında ayrıca kişinin demografik bilgiler ve hasta kişilerin hastalık şiddet değerleri de yer almaktadır. Demografik bilgilerin ortalama değerleri Tablo 3.1.'de gösterilmektedir. Hasta kişilerin şiddet değerleri hesaplanmasında Hoehn & Yahr evrelemesi ve UPDRS kullanılmıştır. Ölçümler incelendiğinde Parkinson hastası bireylerin başlangıç ve orta seviyelerde ölçeklendirildiği görülmektedir.

Tablo 3.1: Veritabanı için Demografik bilgiler

Sağlık durumu	**Veri sayısı**	**Ortalama Yaş**	**Cinsiyet yüzdesi(erkek)**	**Ortalama boy(m)**	**Ortalama Ağırlık**
Sağlıklı Birey	72	66	%56	1,68	72
Parkinson Hastası Birey	93	64	%63	1,68	73

3.2.1. GA Veri Kümesi

GA veri kümesi Galit Yogev ve ekip arkadaşları tarafından Parkinson ve sağlıklı bireyler arasındaki yürüyüş farklılıklarını tespit etmek için yaptığı çalışma sonucunda elde ettiği verilerden oluşmaktadır. Bu çalışmalarda kişilerin normal yürüyüşleri, çeşitli görevler verilerek

yürüyüş üzerinde değişimleri kontrol etmek için deneyler yapılmıştır. Bu deneylerden elde edilen normal yürüyüş verileri kullanılarak diğer iki çalışma ile birleştirilip bir veritabanı oluşturulmuştur [47].

Deneylerde basit görev, karmaşık görev, aritmetik görev ve normal yürüyüş olmak üzere 4 deney yapılmıştır. Basit görev sırasında kulaklık kullanılarak kişilere bir metin dinletilmiş ve bu metin ile ilgili sorular sorulmuştur. Karmaşık görevde ise aynı şekilde metin dinletildi. Fakat verilen 2 kelimenin sayılarında tespit etmeleri istenmiştir. Aritmetik görevde ise 500'den sürekli 7 çıkartılarak söylemeleri istendi. Bu deneyler sonucunda Parkinson ve sağlıklı bireyler arasındaki yürüyüş farklılıklarına bakılmıştır. İncelemeler sonucunda Parkinson hastalığı bulunan bireylerin yürüyüşünde farklılıklar olduğu ve yürüme problemleri yaşadığı tespit edilmiştir. Sağlıklı bireylerde herhangi bir farklılık olmadığı normal yürüyüşlerine devam ettiği görülmüştür [47].

Bu deneyde 28 sağlıklı birey ve 30 Parkinson hastası birey kullanılarak deneyler gerçekleştirilmiştir. Veritabanı birleştirilirken yürüyüş verilerinin düzgün bir şekilde kaydedildiği ve doğruluğu kesin veriler kullanılarak veritabanı eklenmiştir. Bundan dolayı birleştirilen veritabanında 18 sağlıklı birey ve 29 Parkinson hastası birey yer almaktadır. Bu verilerin demografik bilgileri aşağıdaki Tablo 3.2.'de gösterilmiştir.

Tablo 3.2: GA veri kümesine ait demografik bilgiler

Sağlık durum	Veri sayısı	Ortalama Yaş	Cinsiyet yüzdesi(erkek)	Ortalama boy(m)	Ortalama Ağırlık
Sağlıklı Birey	18	72	%56	1,67	72
Parkinson Hastası Birey	29	71	%69	1,70	74

3.2.2. JU veri kümesi

JU veri kümesi Justine Lowenthal ve ekip arkadaşları tarafından Parkinson hastası ve sağlıklı bireyler arasındaki yürüyüş değişimlerinin incelenmesi ve Parkinson hastalığında tedavisi için uygulanan yöntemin test edilmesi işlemi sırasında elde edilen verilerden oluşmaktadır. Bu çalışmada Ritmik İşitsel Stimülasyon adı verilen bir yöntem kullanılmıştır. Ritmik İşitsel Stimülasyon yöntemi, hastanın yürüyüş kandans değerine benzer bir ritim veren ve motor

cevabını dışarıdan düzenleyen bir sistemdir. Ritmik işitsel stimülasyon kullanılarak Parkinson hastası bireylerde meydana gelen değişimler incelenmiştir. Ritmik işitsel stimülasyon kullanılarak Parkinson hastası bireylerin adım uzunlukları artığı görülmektedir. Ritmik işitsel stimülasyonla ayrıca yürüme hızı ve salım süresinin de iyileştirildiği tespit edilmiştir [48].

Deney sırasında hem Parkinson hastası bireylere hem de sağlıklı bireylere Normal yürüyüş hızlarında yürümeleri istenmiştir. Ritmik işitsel stimülasyonun test edilmesi için kişilere ritmik işitsel stimülasyonun uygulandığı ve uygulanmadığı deneyler yapılmıştır. Bu deneyler sonucunda Parkinson hastası bireylerde iyileşmeler meydana geldiği tespit edilmiştir [48].

Bu deneyde 26 sağlıklı birey ve 29 Parkinson hastası birey gönüllü olarak deneye katılmışlardır. Elde edilen veriler diğer iki veri kümesi ile birleştirilerek veritabanı oluşturmuştur. Veritabanını oluşturmak için kişilerin normal yürüme hızlarında yürüdükleri veriler kullanılmıştır. Veritabanı oluşturulurken bir sağlıklı bireyin veri kayıt altına alınmamıştır. Bundan dolayı veritabanında 25 sağlıklı birey bulunmaktadır. Bu verilerin demografik bilgileri aşağıdaki Tablo 3.3'te gösterilmiştir.

Tablo 3.3: JU veri kümesine ait demografik bilgiler

Sağlık durum	**Veri sayısı**	**Ortalama Yaş**	**Cinsiyet yüzdesi(erkek)**	**Ortalama boy(m)**	**Ortalama Ağırlık**
Sağlıklı Birey	25	65	%48	1,69	71
Parkinson Hastası Birey	29	67	%55	1,66	70

3.2.3. SI veri kümesi

SI veri kümesi Silvi Frenkel-Toledo ve ekip arkadaşları tarafından Parkinson hastası ve sağlıklı bireylerin yürüyüş verileri kullanılarak yürüme hızları ve yürüyüş değişiklikleri arasındaki bağlantıyı incelenerek veri kümesi elde edilmiştir. Bu deneyin yapılmasının temel nedeni Parkinson hastası bireylerde meydana gelen adım süresi ve salınım süresindeki değişikliklerin incelenmesidir. Önceki yapılan çalışmalarda adım süresi ve salınım sürelerinin artığı tespit edilmiştir. Bu durumun farklı deneylerde araştırılarak açıklanmaya çalışılmıştır [49].

Deney hem hastalıklı bireylere hem de sağlıklı bireylere, dörder kez yürüme yolunda veya koşu bandı üzerinde farklı hızlarda yürümeleri istenmiştir. Bu hızlar bireylerin normal yürüme hızları, kendi seçtikleri yavaş hızda, yürüteç kullanılarak normal yürüme hızlarında ve yürüteç kullanılarak kendi seçtikleri yavaş hızlarda yürütülmüşlerdir. Yürüyüş bandı da ise normal yürüyüş hızlarının %80, %90 ve %110 hızlarında yürütülmüşlerdir. Ayrıca yürüteç kullanılarak normal hızda yürüme bandında yürütülmüşlerdir. Deney sonucunda normal yürüme hızlarında Parkinson hastası bireylerin sağlıklı bireylere kıyasla adım süresi ve salınım süresinde değişiklikler meydana geldiği ve artışlar gözlemlediği görülmüştür [49].

Bu deneyde 36 Parkinson hastası birey ve 30 sağlıklı birey deney için gönüllü olmuşlardır. Normal yürüme hızlarında düz zemin üzerinde yürüdükleri veriler kullanılarak diğer veri kümeleri ile birleştirilerek veritabanı oluşturulmuştur. Veritabanı oluşturulurken 1 sağlıklı birey ve 1 de Parkinson hastası bireyin verileri veritabanına eklenmemiştir. Bundan dolayı veritabanında SI verisi olarak 35 Parkinson hastası birey ve 29 sağlıklı birey yer almaktadır. Bu verilerin demografik bilgileri aşağıdaki Tablo 3.4'te gösterilmiştir.

Tablo 3.4: SI veri kümesine ait demografik bilgiler

Sağlık durum	Veri sayısı	Ortalama Yaş	Cinsiyet yüzdesi(erkek)	Ortalama boy(m)	Ortalama Ağırlık
Sağlıklı Birey	29	58	%65	1,68	74
Parkinson Hastası Birey	35	62	%63	1,67	73

3.3. VERİ KÜMESİNE UYGULANAN ÖN İŞLEMLER

Veriler toplanırken sensörden kaynaklı gürültüler oluşabilmektedir. Bu gürültüler sonuçları olumsuz etkilemekte ve hatalı bilgi vermesine yol açabilmektedir. Bu durumlara çözüm olabilmesi için veriler ön işlemden geçirilmektedir.

Ön işlem sırasında verilerin gürültülerden kurtulmasının yanı sıra verilerin belirli bir forma uygun hale getirilmektedir. Bundan dolayı verilere normalizasyon işlemleri uygulanmaktadır.

Bu çalışmada, gürültülerin giderilmesi için 5 noktalı meydan filtre ve verilerin belirli bir formata uygun hale getirilmesi için vücut kitle indeksine göre normalizasyon işlemi

uygulanmıştır. Ayrıca yürüyüşün başlangıç etkisinden dolayı ilk 20 saniye içinde alınan veriler çıkartılmıştır.

3.3.1. Medyan Filtre

Medyan Filtre, sayısal sinyal işleme ve görüntü işleme yöntemlerinde kullanılan nonlinear bir filtreleme yöntemidir. Bu yöntemin temel amacı sinyal veya görüntü üzerindeki istenmeyen gürültülerin azaltılması veya yok edilmesi için kullanılmaktadır. Bu işlemi yaparken bulunduğu değerin komşu değerlerinin medyan değerini atamaktadır. Bulunduğu sinyal değerine veya piksel değerine komşu olan değerler küçükten büyüğe doğru sıralama işlemi yapılır. Sıralama sonrasında ortada bulunan ortanca değer medyan değeridir. Bu değer aranan konuma atamaktadır. Bu şekilde komşularından farklı veya anlamsız değerler varsa bu değerlerin yok edilmesi sağlar.

Bu çalışmada sensör verilerinden alınan verilere medyan filtre uygulanmıştır. Uygulama işlemi sırasında bulunan sensör verisinden 2 öncesi, 2 sonrası ve kendisine ait değerler alınarak küçükten büyüğe şekilde sıralamışlardır. Sıralama sırasında ortada kalan değer sensörün yeni değeri olmuştur. Bu işlem birer değer kaydırılarak tüm süre boyunca alınan sensör değerlerine uygulanmıştır. Benzer şekilde tüm verilere uygulanmıştır.

3.3.2. Normalizasyon işlemi

Normalizasyon genellikle veri bilimi alanında kullanılan bir yöntemdir. Bu yöntemin temel amacı farklı veri türleri arasında farklılığının tek bir tipe dönüştürülmesi veya veri içerisindeki aykırı değerlerin normalize edilerek anlamlı hale getirilmesi için kullanılmaktadır. Bu şekilde farklı veriler birleştirilirken aynı formata uygun hale getirilmek mümkün hale gelmektedir. Ayrıca verilerin daha anlamlı ve düzenli hale gelmesi içinde uygulanmaktadır [50].

Literatürde birçok normalizasyon yöntemi bulunmaktadır. Bunlar sırasıyla Min-Max Normalizasyonu, Z- Score Normalizasyonu gibi normalizasyon yöntemleridir. Ayrıca Problemin yapısına göre farklı normalizasyon yöntemleri de geliştirilmektedir. Böylelikle problemin yapısına göre veriler düzenlenmiş ve daha uygun hale getirilmiş olacaktır [50].

Min-Max Normalizasyonu, genel olarak verileri 0-1 arasına normalize etmektedir. Fakat farklı değerlerde de normalizasyon işlemi yapabilmektedir. Min-Max Normalizasyonu için kullanılan formül Denklem 3.1.'de gösterilmiştir.

$$X_{Normalize} = \frac{X-Min}{Max-Min}\ (NormalizeMax - NormalizeMin) + (NormalizeMin) \quad (3.1)$$

Denklemde NormalizeMax değeri normalize edilecek aralığın en yüksek değeridir. Genelde 1 değeri alınmaktadır. Denklemde NormalizeMin ise Normalize edilecek en küçük değeri göstermektedir. Bu değer genellikle 0 olarak alınmaktadır. X değerli ise normalize edilecek veri değerini göstermektedir. Min değeri ise tüm verideki minimum değer ve Max değeri ise verideki maksimum değeri göstermektedir. $X_{Normalize}$ değeri ise normalize edilmiş X değerini göstermektedir [36].

Z- Score, Normalizasyonda ise verilerin normalizasyon dağılımında gerçekleşme olasılıklarına göre normalize işleminin yapıldığı normalizasyon işlemidir. Bu şekilde veriler eksi veya artı değerler almaktadır. Bu durumun temel nedeni verilerin ortalamasından küçük olması durumunda eksi değerler alırken verilerin ortalamasından büyük olması durumda ise artı değerler almasıdır. Z- score normalizasyonun uygulanması için verinin ortalaması ve standart sapması hesaplanması gerekmektedir. Hesaplanan değerler kullanılarak Denklem 3.2. uygulanarak Normalize değerler elde edilmektedir.

$$X_{Normalize} = \frac{X-\mu}{\sigma} \quad (3.2)$$

Denklemde X değeri normalize edilecek veriyi göstermektedir. σ değeri ise verinin standart sapma değerini göstermektedir. μ ise verinin ortalama değeri göstermektedir. $X_{Normalize}$ değer ise normalize edilmiş X değerini göstermektedir [50].

Bu çalışma kapsamında projeye özgü olarak normalizasyon işlemi uygulanmıştır. Toplanılan sağlıklı bireylerin ve Parkinson hastası bireylerin vücut kitle indeksi hesaplanılarak verilere normalizasyon işlemi için kullanılmıştır. Bunun uygulanmasının temel sebebi kişinin boyu ve kilosunun yürüyüşe etki etmesidir. Bu durumdan dolayı vücut kitle indeksi göre normalize işlemi yapılarak bu etkiyi azaltmak amaçlanmıştır.

Vücut kitle indeksi hesaplanırken Denklem 3.3.'deki formül kullanılmıştır. Bu formüldeki bireyin boyu ve kilosu bilgilerini veri tabanı içerisinde yer alan demografik bilgilerden alınmıştır. Bu bilgiler kullanılarak Hem Parkinson hastası bireylerin hem de sağlıklı bireylerin vücut kitle indeks hesaplanmıştır.

$$Birey_{\text{vücut kitle indeks}} = \frac{Birey_{kilosu}}{Birey_{boyu}\ X\ Birey_{boyu}} \quad (3.3)$$

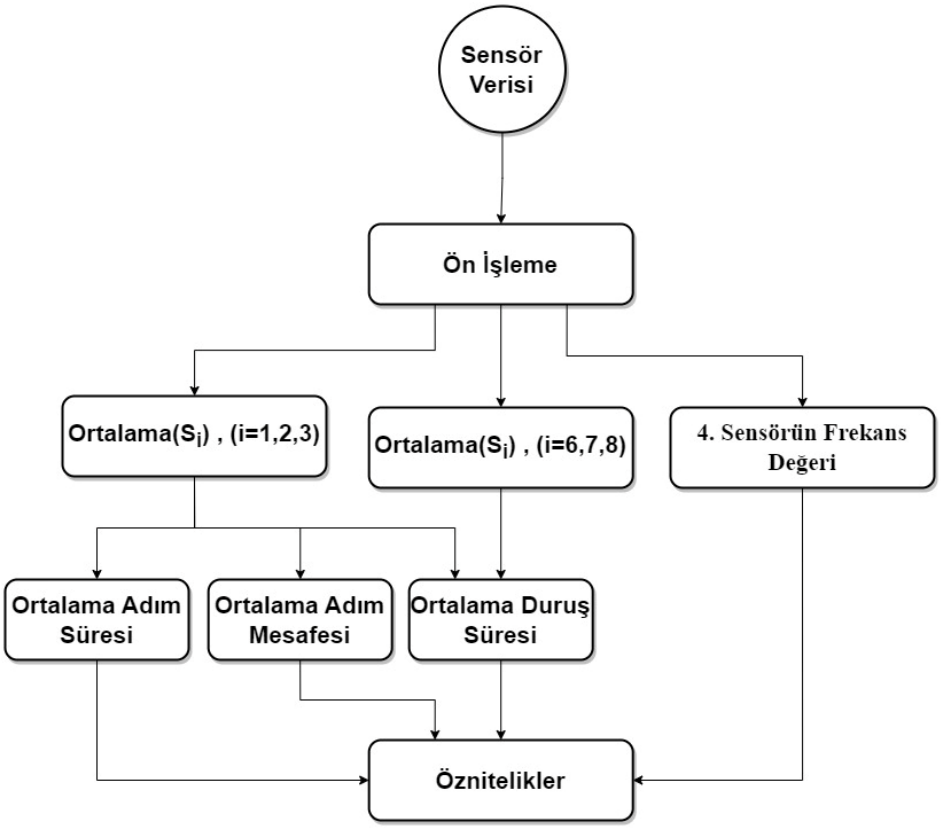
Bireylerden toplanan yürüyüş verilerine bireyin kendisine ait vücut kitle indeksine bölünmüştür. Bu işlem için Denklem 3.4.'deki formül uygulanarak normalizasyon değerleri hesaplanmıştır.

$$X_{Normalize} = \frac{X}{Birey_{vücut\ kitle\ indeks}} \tag{3.4}$$

Denklemde X değeri normalize edilecek veriyi göstermektedir. $Birey_{vücut\ kitle\ indeks}$ X verisine ait olduğu bireyin vücut kitle indeksidir. $X_{Normalize}$ değeri ise normalize edilmiş X değerini göstermektedir.

3.4. VERİ KÜMESİNDEN ÖZNİTELİK ÇIKARTILMASI

Bu aşamada, veride yer alan 16 sensörden sadece sol ayak altında yer alan 8 sensör (S:1-8 sensörleri) kullanılarak öznitelik çıkartılmıştır. Öznitelik çıkartılması işleminin genel akış şeması Şekil 3.2.'de gösterilmiştir.



Şekil 3.2: Öznitelik çıkarma aşamasının genel gösterimi

Öznitelikler çıkartılırken istatistiksel verilerden yararlanılmıştır. Bunlar duruş süresi, adım süresi, adım uzunluğu ...vb. öznitelikler kullanılmıştır. Ayrıca veride aynı zamanda alınan 8 sensörün içinden maksimum değere sahip sensör belirlenerek, zaman boyunca tekrar sayılarının hesaplanması ile frekans değeri bulunmaktadır. Diğer bir ifade ile süre boyunca maksimum değerin bulunduğu sensörler tespit edilir, 120 saniye içindeki toplam tekrar sayıların hesaplanması ile frekans değeri elde edilir.

Öznitelik ve sınıflandırma işlemleri için MATLAB (The MathWorks, Inc.) programı kullanılmıştır. Çıkartılan öznitelikler Tablo 3.5.'de gösterilmiştir.

Tablo 3.5: Öznitelikler

No:	**Öznitelik**
1	Ortalama Adım Süresi
2	Ortalama Duruş Süresi
3	Ortalama Adım Mesafesi
4	4. Sensörün Frekans Değeri

Öznitelik olarak 4 adet öznitelik çıkartılmıştır. Öznitelik çıkarım yöntemleri aşağıda başlıklar halinde incelenmiştir.

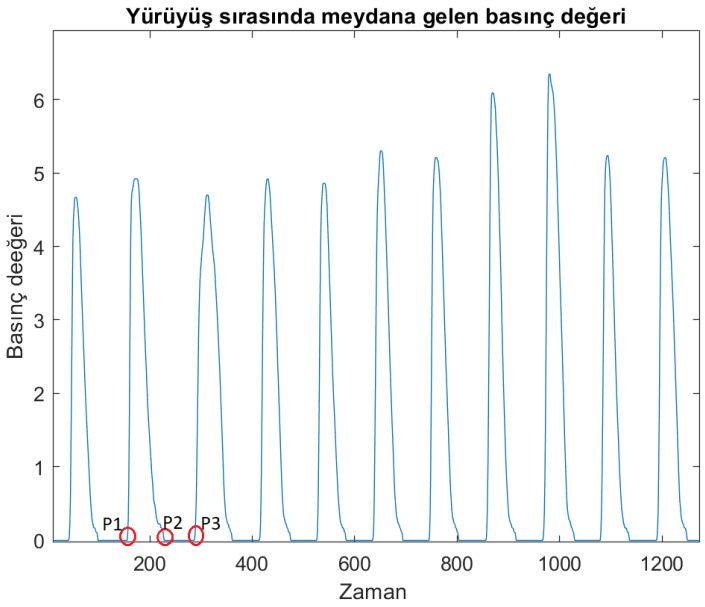
3.4.1. Ortalama Adım Süresi

Ortalama adım süresi, sağlıklı bireyin veya Parkinson hastası bireyin yürüyüş boyunca attığı adımların süresinin ortalaması olarak bulunmaktadır. Adım süresi, ayağın topuk temasından başlayarak aynı ayağın bir sonraki topuk temasına kadar geçen süre olarak tanımlanmaktadır. Bu durum birey yürüdükçe tekrarlanan bir döngü şeklinde devam etmektedir. Bundan dolayı sol ayağın topuk kısmında yer alan S_1, S_2 ve S_3 sensörleri incelenmiştir. Bu üç sensör benzer konumda oldukları için ve incelemeler sonucunda üç sensöründe benzer anlarda aynı kayıtları gerçekleştirdiği için bu üç sensör birleştirilerek tek bir sensör haline getirmesine karar verilmiştir. Bu işlem için Denklem 3.5.'deki formül kullanılmıştır.

$$\bar{S}_{(1,2,3)} = \frac{1}{3}\sum_{i=1}^{3} S_i \tag{3.5}$$

Üç sensörün aynı zamanda alınan değerler toplanmış ve üçe bölünerek tek bir sensör değeri elde edilmiştir. Yürüyüş boyunca tüm verilere uygulanmıştır. Oluşan yeni sensöre $\bar{S}_{(1,2,3)}$ olarak isimlendirilmiştir.

Şekil 3.3'te topuk kısmında bulunan sensörlerden oluşturulan $\bar{S}_{(1,2,3)}$ sensörünün zaman göre basınç değerlerinin grafiksel gösterimi yer almaktadır. Şekil 3.3'te P1 pozisyonundan başlayarak P3 pozisyonu kadar geçer süreye adım süresi olarak ifade edilmektedir. Her bir durum için adım süreleri elde edilir. Elde edilen sürelerinin ortalaması alınarak ortalama adım süresi özniteliği oluşturulmuştur.



Şekil 3.3: Sensörden alınan basınç değerlerin zamana göre gösterilmesi

3.4.2. Ortalama Adım Mesafesi

Ortalama adım mesafesi, sağlıklı bireyin veya Parkinson hastası bireyin yürüyüş boyunca attığı adımların, mesafesinin ortalaması olarak hesaplanmaktadır. Yürüyüş boyunca adım mesafesi, ayağın topuk temasından başlayarak aynı ayağın topuk temasına kadar geçen mesafe olarak tanımlanmaktadır. Bu durum birey yürüdükçe tekrarlanan bir döngü şeklinde gitmektedir.

Ortalama adım süresinde olduğu gibi topuk kısmında yer alan üç sensör Denklem 3.5. kullanılarak birleştirilerek tek bir sensör haline getirilmiştir. $\bar{S}_{(1,2,3)}$ sensörü kullanılarak her adımda geçen süre değerleri bulunmuştur.

Adım mesafesi Denklem 3.6.'daki formül kullanılarak hesaplanmıştır. Formülde yer alan adım süresi değerleri $\bar{S}_{(1,2,3)}$ sensörü kullanılarak hesaplanmıştır. Yürüyüş hızı bilgisi ise veritabanı içinde yer alan demografik bilgilerde yer almaktadır. Adım süreleri yürüyüş hızı ile çarpılarak adım mesafe değerleri elde edilmiştir. Elde edilen adım mesafe değerlerinin ortalaması alınarak ortalama adım mesafesi özniteliği elde edilmiştir.

$$Adım\ mesafesi = Adım\ süresi\ X\ Yürüyüş\ Hızı \tag{3.6}$$

3.4.3. Ortalama Duruş Süresi

Ortalama duruş süresi, sağlıklı bireyin veya Parkinson hastası bireyin yürüyüş boyunca her adımda ayağın yer ile temas ettiği sürelerin ortalamasıdır. Yürüyüş boyunca duruş süresi ayağın topuk temasından başlayarak aynı ayağın parmak ucu temasının kesilinceye kadar geçen süre olarak tanımlanmaktadır. Bu durum birey yürüdükçe tekrarlanan bir döngü şeklinde gitmektedir. Ayağın topuk kısmı ve ayağın parmak ucundaki sensörler kullanılarak hesaplanmaktadır. Ayağın topuk kısmında S_1, S_2 ve S_3 sensörleri yer almaktadır. Ayağın parmak ucu kısmında ise S_6, S_7 ve S_8 sensörleri yer almaktadır. Ayağın topuk kısmında yer alan sensörler benzer durumda oldukları için Denklem 3.5.'deki formül kullanılarak birleştirilerek tek bir sensör haline getirilmiştir. Benzer şekilde parmak ucunda yer alan 3 sensör incelenmiş ve benzer değerler aldığı görülmüştür. Bundan dolayı Denklem 3.7. kullanılarak üç sensör tek bir sensör haline getirilmiştir. Üç sensörün aynı zamanda alınan değerleri toplanmış ve üçe bölünerek tek bir sensör değeri elde edilmiştir. Yürüyüş boyunca tüm verilere uygulanmıştır. Oluşan yeni sensöre $\bar{S}_{(6,7,8)}$ olarak isimlendirilmiştir.

$$\bar{S}_{(6,7,8)} = \frac{1}{3}\sum_{i=6}^{8} S_i \tag{3.7}$$

$\bar{S}_{(1,2,3)}$ ve $\bar{S}_{(6,7,8)}$ Sensörleri kullanılarak topuk temasından başlayarak parmak ucu teması kesilinceye kadar geçen süreler hesaplanmıştır. Hesaplanan sürelerin ortalaması alınarak ortalama duruş süresi özniteliği elde edilmiştir.

3.4.4. Frekans Sayısı

Sol ayakta yer alan 8 sensörden, yürüme boyunca maksimum basınç değerleri gözlemlenmiştir. Gözlem değerlerinden elde edilen frekans değerleri için histogramlar oluşturulmuştur. GA, JU ve SI veri kümeleri için elde edilen histogramlar Şekil 3.4.'de gösterilmiştir. Şekil 3.4.'deki

grafiklerin, (a) kısmında yer alan histogramlar sağlıklı bireylere, (b) kısmında yer alan histogramlar ise Parkinson hastası olan bireyler ait frekans değerlerini göstermektedir.

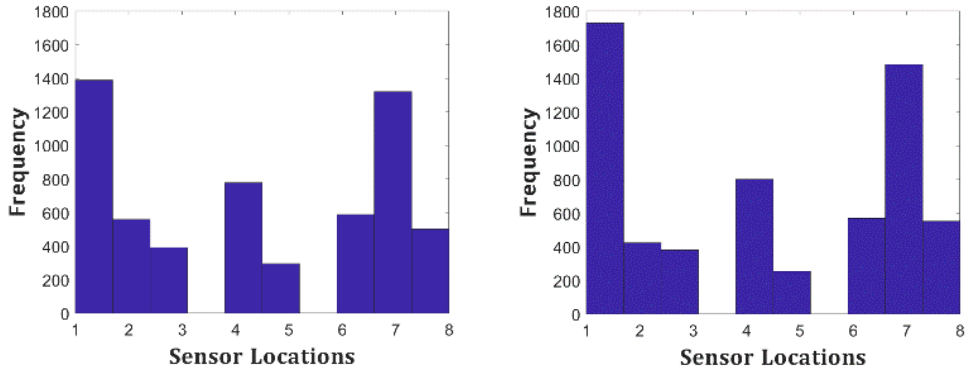
Histogramlar incelediğinde 4. sensörün frekans değerlerinde farklılıklar olduğu görülmektedir. GA verisi kümesine ait 4'üncü sensörlerin frekans değerleri birbirlerine yakın olduğu gözükmektedir. Fakat dikkatli bir şekilde incelendiğinde birbirlerine yakın olmasına rağmen sağlıklı kişilerin frekans değeri hastalıklı bireylere göre düşük olduğu görülmektedir. JU ve Sİ veri kümelerine ait histogramlar incelendiğinde ise 4. Sensöründeki sağlıklı bireylerin frekans değerleri, Parkinson hastası bireylere oranla daha düşük olduğu görülmektedir. Frekans farklılıklarından dolayı tüm zaman boyunca Parkinson hastası ve sağlıklı bireylerinin 4'üncü sensörün frekans sayıları bir öznitelik olarak alınmıştır.

3.4.5. Öznitelikler Hakkında Genel Bilgiler

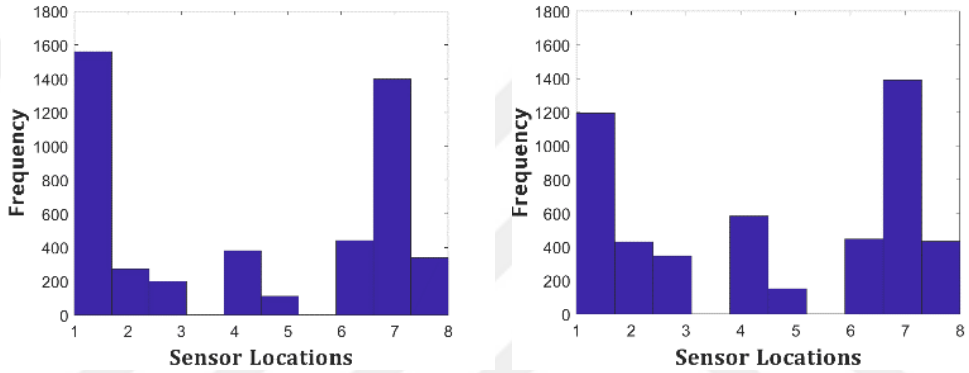
GA, SI, JU veri setlerinden çıkartılan özniteliklerin bazıları Tablo 3.6'da verilmiştir. Tablo 3.6 incelendiğinde Parkinson hastası bireylerin ortalama duruş süresi, ortalama adım süresi ve 4. Sensöre ait frekans değerlerinin sağlıklı bireylere göre yüksek çıktığı görülmektedir. Ortalama adım süresi ise sağlıklı bireyler göre Parkinson hastası bireylerin daha düşük olduğu görülmektedir. Bu durumlardan dolayı bu 4 öznitelik kullanılarak sınıflandırma işlemi yapılmıştır.

Tablo 3.6: Öznitelik değerleri

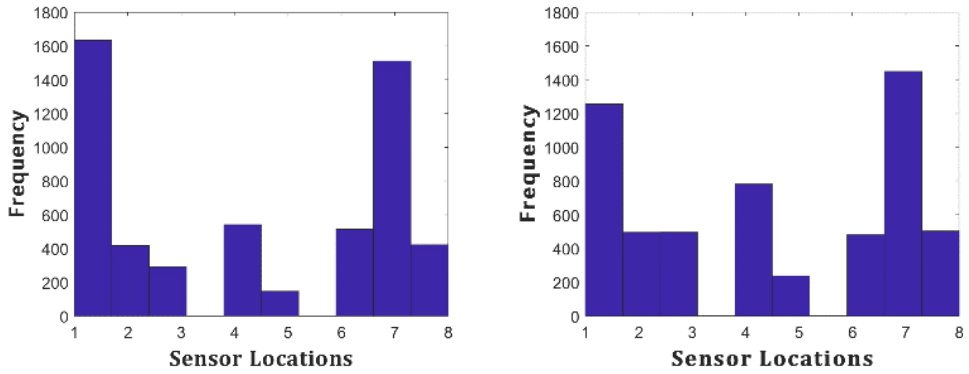
		Ortalama Duruş Süresi (saniye)	**Ortalama Adım Süresi(saniye)**	**Ortalama Adım Mesafesi (m)**	**4. Sensöre Ait Frekans Değeri**
GA	**Parkinson Hastası Birey**	0.90	1.16	0.83	954
	Sağlıklı Birey	0.76	1.09	1.48	802
JU	**Parkinson Hastası Birey**	0.82	1.12	1.03	617
	Sağlıklı Birey	0.77	1.07	1.48	299
SI	**Parkinson Hastası Birey**	1.00	1.25	1.41	838
	Sağlıklı Birey	0.76	1.05	1.54	694



GA Veri Kümesi



JU Veri Kümesi



SI Veri Kümesi

a) Sağlıklı bireyler b) Parkinson hastası bireyler

Şekil 3.4: Frekans değerlerine ait histogramlar

3.5. SINIFLANDIRMA

Sınıflandırma, sınıf bilgisi olmayan verilerin öznitelikler kullanılarak sınıfının belirlenmesi işlemdir. Sınıflandırma işleminin gerçekleştirilmesi için ilk olarak verilerin analiz edilmesi ve

özniteliklerin çıkartılması gereklidir. Doğru özniteliklerin kullanılması sınıflandırma performansı, güvenirliği ve hızı artırması açısından önem teşkil etmektedir. Bundan dolayı sınıflandırma işlemi için özniteliklerin belirlenmesi ve analiz edilmesi gerekmektedir.

Sınıflandırma işlemi, denetimli öğrenme yöntemi kullanmaktadır. Denetimli öğrenme yöntemi, verilere ait sınıf bilgisine sahip olduğu, bu sınıf bilgisi kullanılarak veriyi eğitim ve test olarak iki ayrıldığı bir yöntemdir. Ayrılan verinin eğitim kısmı ile makine öğrenmesi algoritmalarının eğitilir ve bu eğitim sırasında sınıf bilgisi kullanılmaktadır. Eğitim sonucunda bir model oluşmaktadır. Test verisi ile ise bu modelin performansı teste edilmektedir.

Denetimli öğrenme algoritmalarına örnek olarak: En yakın komşu algoritması, Destek vektör makineleri (DVM), Naive bayes, Lojistik Regresyon, Karar ağaçları ...vb. algoritmalar örnek olarak verilebilir. Bu çalışma DVM algoritması kullanılmıştır.

3.5.1. Destek Vektör Makineleri Sınıflama Algoritması

DVM, genel olarak sınıflandırma problemleri için kullanılan denetimli öğrenme algoritmalarından biridir. DVM algoritması genel olarak iki sınıflı veriler üzerine uygulanmaktadır. Algoritmanın popülerliği artması ve iyi bir performans göstermesinden dolayı çoklu sınıflı veriler üzerinde de çalışmalar yapılmıştır [51].

DVM algoritması bir düzlem üzerinde yer alan noktaları, ikiye ayıracak en iyi hiper düzlemi bulmayı amaçlamaktadır. Hiper düzlem ile verilerin iki farklı bölgeye ayrılmış olur. Hiper düzlemin hesaplanmasında çekirdek adı veriler fonksiyonlar kullanılmaktadır. Bu fonksiyonlar doğrusal veya doğrusal olmayan fonksiyonlardır. Çekirdek fonksiyonları verinin türüne göre veya düzlem üzerindeki dağılımlarına göre belirlenmektedir [51].

Veriler doğrusal bir şekilde ayrılması durumunda iki sınıf arasına sonsuz sayıda hiper düzlem çizilebilmektedir. En uygun Hiper düzlemi bulabilmek için iki sınıf için destek noktaların belirlenmesi gerekmektedir. Bu destek noktaları arasında kalan bölgeye marjin adı verilmektedir. Bu bölgenin tam ortasından da hiper düzlem çizilmektedir. Bu şekilde yeni gelecek olan verinin sınıflandırma işlemi bu hiper düzleme göre yapılmaktadır. Bazı durumlarda destek noktaları tam olarak belirlenememekte ve bazı noktalar marjinin içerisinde kalmaktadır. Bu durumlarda veri doğrusal olarak ayrılmadığı anlamına gelmektedir. Böyle bir durumda ise doğrusal olmayan fonksiyonlar kullanılarak sınıflandırma işlemi yapılmaktadır [37].

DVM algoritmasında kullanılan çekirdekler; Doğrusal, Polinom, Gauss, Gauss RBF çekirdek fonksiyonlarıdır. Bunlardan farklı olarak yeni çekirdek fonksiyonları geliştirilmektedir.

Bu çalışmada DVM algoritmasının kullanılmasına karar verilmiştir. Bunun temel sebebi ikili sınıflandırma işlemi için iyi bir performans vermesidir. Ayrıca veri yapısının DVM algoritması için uygun olmasından dolayı seçilmiştir.

3.6. ÇAPRAZ DOĞRULAMA YÖNTEMLERİ

Çapraz Doğrulama yöntemi ile algoritmanın performansını artırmak için verilerin birkaç kısma ayrılıp işlemlerden geçirilmesi olarak tanımlanabilir. Bu işlemin yapılmasının temel sebebi aynı veriler kullanılarak algoritma eğitilmesi durumunda oluşan modelin aşırı öğrenmesine neden olmasıdır. Bu da makine öğrenmesi yöntemlerinde istenmeyen bir durumdur. Bu durumu önlemek ve anlamlı sonuçlar elde etmek için çapraz doğrulama yöntemi uygulanmaktadır.

Çapraz doğrulama yöntemi ile veriler birbirinden bağımsız iki kısma ayrılmaktadır. Bunlar eğitim ve test olarak isimlendirilmektedir. Ayrılma işlemi sırasında eğitimde olan veriler sadece eğitim kısmında test kısmında yer alan veriler ise sadece test kısmında yer almaktadır. Bu durumun nedeni algoritma test edilirken hiç karşılaşmadığı veriler ile test etmektir. Bu şekilde daha gerçeğe yakın test uygulanmakta ve modelin performansı gerçek bir şekilde test edilmektedir.

Çapraz doğrulama yöntemi olarak ise genelde bilinenler, Sınama Seti Yöntemi (Holdout Method), Birini Dışarda Bırak Çapraz Doğrulama (Leave-one-out cross validation), K-Katlamalı Çapraz Doğrulama (K-Fold Cross Validation) kullanılmaktadır. Bu çalışma kapsamı boyunca K- Katlamalı Çapraz doğrulma yöntemi kullanılmıştır.

3.6.1. Sınama Seti Yöntemi (Holdout Method)

Bu yöntemde veriler eğitim ve test olarak ikiye ayrılmaktadır. Eğitim kısmı ile test kısmı birbirinden bağımsız veriler içermektedir. Eğitim verisi kullanılarak model eğitilmektedir. Eğitim sonrasında modelin performansı ve başarımı test verisi ile test edilmektedir.

3.6.2. Birini Dışarda Bırak Çapraz Doğrulama (Leave-one-out cross validation)

Birini dışarda bırak çapraz doğrulama yönteminde, veri setinde yer alan bir veri test olarak ayrılır. Geriye kalan tüm veri seti ise eğitim için kullanılmaktadır. Eğitim sonucunda oluşan modeli test edilmesi ise bir tane veri ile gerçekleştirilir. Bu şekilde modelin başarım performansı

test edilir ve sonuç kaydedilir. Bu şekilde tüm veride yer alan değerler test olacak şekilde tekrarlanır. Geriye kalan veriler ile yeni modeller oluşturulup ayrı bırakılan test verisi ile test işlemi gerçekleştirilir ve sonuçlar kayıt altına alınır. Kaydedilen test başarım performanslarının ortalaması alınarak genel başarım performansı elde edilir ve bu değer sınıflandırıcının başarım performansı olur.

3.6.3. K-Katlamalı Çapraz Doğrulama (KFold Cross Validation)

K katlamalı çapraz doğrulama yönteminde veriler belirlene K değeri kadar kısımlara ayrılmaktadır. Ayrılan her bir kısım test olarak ayrılmakta, geriye kalan kısımlar ise eğitim için kullanılmaktadır. Bu şekilde sırasıyla ilk kısımdan başlayarak test için ayrılmakta geriye kalan kısmılar modeli eğitmek için kullanılmaktadır. Elde edilen modelin performansı ayrılan test kısmı ile test edilmekte ve elde edilen sonuçlar kayıt altına alınmaktadır. Bu işlem her parça test olana kadar devam etmektedir. Kaydedilen test sonuçlarının ortalaması alınarak sınıflandırma başarım performansı elde edilmektedir.

K katlamalı çapraz doğrulama yönteminin Birini Dışarda Bırak Çapraz Doğrulama yönteminden farklı olarak tek bir veri dışarıda bırakmak yerine bir veri kısmı dışarıda bırakılmaktadır. Bu kısım belirlenmesi ise toplam veri sayısını belirlenen K değerine bölünmesi ile bulunmaktadır. Örneğin 100 veri olan bir veri setine 5 katlamalı çapraz doğrulama uygulandığında her bir kısım 100/5'ten 20 adet veri içermektedir. Bu kısımlar sırayla test olarak kullanılarak eğitim sırasında modelin performansını test edilmesi için kullanılmaktadır.

Literatürde genel olarak K-Katlamalı Çapraz Doğrulama yöntemlerinde K değeri 3,5,10 değerleri alınmaktadır. Bu çalışmada K değeri 3 ve 5 değeri olan K-Katlamalı çapraz doğrulama yöntemi kullanılmıştır.

3.7. SINIFLANDIRMA PERFORMANSININ DEĞERLENDİRME ÖLÇÜTLERİ

Makine öğrenmesi yöntemlerinin sınıflandırma performansının değerlendirilmesinde kullanılan farklı değerlendirme ölçütleri bulunmaktadır. Bu değerlendirme ölçütleri; doğruluk, duyarlılık, özgünlük, kesinlik, hatırlama, F-skor ve Matthews Korelasyon Katsayısı olarak isimlendirmektedir. Bu değerlendirme ölçütlerinin hesaplanması için eğitim sonucunda elde edilen modele test verilerinin uygulanarak sonuç değerlerinin elde edilmesi gerekmektedir. Elde edilen sonuç değerleri tablo haline getirilmektedir. Bu tabloya karmaşıklık matrisi denilmektedir. Bu tablo tahmin ve gerçek değerlerin birbiri ile karşılaştırılması ile elde

edilmektedir. Tablo 3.7.'de karmaşıklık matrisi gösterilmiştir. Ayrıca matris içindeki yer alan değerler hakkında bilgiler de verilmiştir.

Tablo 3.7: Karmaşıklık matrisi gösterimi

		TAHMİNİ DEĞERLER	
		POZİTİF	**NEGATİF**
GERÇEK DEĞERLER	**POZİTİF**	Gerçek Pozitif(GP)	Yanlış Negatif(YN)
	NEGATİF	Yanlış Pozitif(YP)	Gerçek Negatif(GN)

Tabloda verilen karmaşıklık matrisini, Tahmin değerlerin gerçek sınıflarına atanıp atanmadığının kontrolü için oluşturulmuştur. Tahmin sonucunda pozitif sınıfa ait bir veri gerçek sınıfı olan pozitif sınıfa atanmışsa bu veriye gerçek pozitif (GP) olarak isimlendirilmektedir. Tahmin sonucunda negatif sınıfa atanmış fakat gerçekte pozitif sınıfta olması gerekli ise bu verilere yanlış negatif (YN) olarak isimlendirilmektedir. Tahmin sonucunda pozitif sınıfa atanmış fakat gerçek sınıf negatif sınıfa ait ise bu veriye yanlış pozitif (YP) olarak isimlendirilmektedir. Tahmin sonucunda negatif sınıfa atanmış ve gerçekte de negatif sınıfta olan verilere ise gerçek negatif (GN) olarak isimlendirilmektedir. Karmaşıklık matrisinde yer alan değerlerin toplamı test veri setinde yer alan veri sayısına eşittir. Yani GP, GN, YP ve YN değerlerinin toplamı test için kullanılan veri sayısına eşittir.

Karmaşıklık matrisi ve matrisleri kullanılarak bu çalışmada doğruluk, hassasiyet, özgünlük, kesinlik ve Matthews Korelasyon Katsayısı değerleri Hesaplanmıştır. Belirtilen değerlendirme ölçütleri kullanılarak sonuçlar karşılaştırılmış ve değerlendirilmiştir.

3.7.1. Doğruluk

Sınıflandırma sonucunda elde edilen karmaşıklık matrisinde yer alan doğru sınıfa atanmış verilerin toplam veri sayısına oranlanmasıdır. Karmaşıklık matrisinde doğru sınıfa atanan GP ve GN değerlerinin toplam veri setine yani $GP+GN+YP+YN$ toplamına bölünmesidir. Denklem 3.8. de hesaplama denklemi gösterilmiştir.

$$Doğruluk = \frac{GN+GP}{GN+GP+YP+YN} \tag{3.8}$$

Bu çalışmada Parkinson hastası bireylerin ve sağlıklı bireylerin doğru sınıfa atandığını tahmin etmek için kullanılmıştır. Bu şekilde doğru sınıfa atanan verilerin oranı tahmin edilmiştir.

3.7.2. Duyarlılık

Sınıflandırma sonucunda elde edilen karmaşıklık matrisinde yer alan pozitif sınıfta tahmin edilmiş gerçek pozitif verilerin, yani GP verisinin, karmaşıklık matrisinde yer alan tüm gerçek pozitif değerle yani GP + GN değerine oranındır. Bu çalışmada Parkinson hastası olarak tahmin edilen ve gerçekten de Parkinson hastası olan bireylerin toplam Parkinson hastası sayısına oranlanmasını temsil etmektedir. Denklem 3.9. da hesaplama işleminin denklemi yer almaktadır.

$$Duyarlılık = \frac{GP}{GP+YN} \tag{3.9}$$

3.7.3. Özgünlük

Sınıflandırma sonucunda elde edilen karmaşıklık matrisinde yer alan negatif sınıfta tahmin edilmiş gerçek negatif verilerin, yani GN verisinin, karmaşıklık matrisinde yer alan tüm gerçek negatif değerle yani GN + YP değerine oranındır. Bu çalışmada sağlıklı birey olarak tahmin edilen ve gerçekten de sağlıklı birey olan bireylerin toplam sağlıklı bireylerin sayısına oranlanmasını temsil etmektedir. Denklem 3.10. da hesaplama işleminin denklemi yer almaktadır.

$$\text{Özgünlük} = \frac{GN}{GN+YP} \tag{3.10}$$

3.7.4. Kesinlik

Sınıflandırma sonucunda elde edilen karmaşıklık matrisinde yer alan gerçek değeri pozitif olan, tahmini değeri pozitif olan verilerin, yani GP verisinin, karmaşıklık matrisinde yer alan tüm gerçek pozitif değerle yani GP + YP değerine oranındır. Bu çalışmada Parkinson hastası olarak tahmin edilen ve gerçekten de Parkinson hastası olan bireylerin Parkinson hastası olarak tahmin edilen toplam Parkinson hastası bireylerin sayısına oranlanmasını temsil etmektedir. Denklem 3.11. da hesaplama işleminin denklemi yer almaktadır.

$$Kesinlik = \frac{GP}{GP+YP} \tag{3.11}$$

3.7.5. Matthews Korelasyon Katsayısı

Mathews Korelasyon Katsayısı (MCC), sınıflandırma işleminin sonucunda elde edilen tahminlerin kalitesini göstermektedir. Bunun nedeni sınıflandırma işleminde veride dengesiz bir dağılımda olup olmadığını kontrol eden ve bu dağılımın soncunda verilerin sınıflandırma için rastgele olarak dağılmadığını gösteren bilgi ölçütüdür. Bu işlemi yaparken sınıflar

arasındaki korelasyona bakılmaktadır. MCC değerinin hesaplanması için Denklem 3.12. kullanılmaktadır.

$$MCC = \frac{(GP*GN)-(YN*YP)}{\sqrt{(GP+YN)*(GP+YP)*(GN+YN)*(GN+YP)}} \quad (3.12)$$

MCC değeri hesaplandığında -1 ve +1 arasında değerler almaktadır. Sınıflandırma sonucunda doğru sınıf tahminlerinin sayısı artıkça MCC değeri +1 değerine yaklaşmaktadır. Tam tersi sınıflandırma sonucunda yanlış sınıfa ait tahminlerin sayısında artış meydana gelmesi durumunda ise MCC değeri -1 doğru yaklaşmaktadır. Sınıflandırma sonucunda rastgele bir şekilde yapılmış ise MCC değeri 0 olarak hesaplanmaktadır.

3.8. ZAMAN KARMAŞIKLIĞI

Zaman karmaşıklığı bir kodun veya metodun tam olarak çalıştığında geçen süre olarak tanımlanmaktadır. Bu süre metodun veya kodun kaç kere çalışacağına bağlı olarak hesaplanabilmektedir. Bundan dolayı metodun çalışma değerine bakılarak hesaplanabilmektedir. Genel olarak en kötü senaryo olan tüm durumların gerçekleşme durumuna bakılarak hesaplama işlemi yapılır. Bu durumdaki zaman karmaşıklıklarına Büyük - O notasyonu ile gösterilmektedir. Ortalama durumlar için ise Teta notasyonu ile gösterilmektedir. En iyi durum ise Omega notasyonu ile gösterilmektedir.

Büyük – O notasyonun hesaplanması, metot veya metotların çalışmasına bağlı olarak hesaplandığı için O(1), O(log n), O(n), O(n^2), O(n^3) olarak farklı notasyon türleri ile gösterilmektedir. Burada yer alan n değeri fonksiyonun kaç defa çalışacağını gösteren değerdir.

4. DENEYSEL SONUÇLAR

Bu çalışmada Parkinson hastası bireylerin sağlıklı bireylerden ayrımını tespit etmek ve hastalığın erken evrelerinde tespit edilerek hasta bireylere erken tedavi başlatılması için yeni bir yöntem önerilmiştir. Önerilen yöntemde yürüyüş sırasında ayak tabanından alınan sensör verileri kullanılarak makine öğrenmesi yöntemi olan DVM yöntemi ile Parkinson hastası bireylerin sağlıklı bireylerden ayrımının yapıldığı bir model geliştirmektir.

Çalışmada kullanılan veri seti 3 farklı çalışmanın bireyleştirilmesi ile oluşturulan PhysioNet veritabanına ait olan "Parkinson hastalığında yürüyüş" veri setidir. Bu veri seti oluşturulurken kullanılan veriler ise GA, SI ve JU isminde çalışmalardan alınmıştır. GA veri setinde 18 sağlıklı birey ve 29 Parkinson hastası birey bulunmaktadır. SI verinde ise 29 sağlıklı birey ve 35 Parkinson hastası birey bulunmaktadır. JU veri setinde ise 25 sağlıklı birey ve 29 Parkinson hastası birey bulunmaktadır. Toplam veri seti ise 72 sağlıklı birey ve 93 Parkinson hastası birey bulunmaktadır. Veri alınırken 120 saniye boyunca bir zemin üzerinde Parkinson hastası ve sağlıklı bireyler yürütülmüştür. Bu sırada ayak tabanına yerleştirilen sol da 8 sensör ve sağda 8 sensör olmak üzere toplam 16 sensörden veriler alınarak kaydedilmiştir. Kayıtlar kullanılarak veri seti oluşturulmuştur. Her bir veri ayrı ayrı ele alınmış ve toplam olarak incelenmiştir.

Sensörden alınan verilerde doğası gereği gürültüler oluşabilmektedir. Bu gürültüleri azaltmak veya gidermek için verilere 5 noktalı medyan filtre uygulanmıştır. Filtreli verilerin ilk 20 saniyelik kısmı yürüyüş başlangıç etkisinden dolayı çıkartılmıştır. Daha sonra kalan verilere normalizasyon işlemi uygulanmıştır. Normalizasyon işlemi olarak vücut kitle indeksine göre yapılmıştır. Ön işlem aşamasında geçirilen verilerden öznitelikler çıkartılmıştır. Öznitelik çıkarma işlemi sadece ayağın sol tarafından alınan sensör verileri kullanılmıştır. Öznitelik olarak 4. Sensörün frekans değeri, ortalama duruş süresi, ortalama adım süresi ve ortalama adım mesafesi olmak üzere 4 adet öznitelik kullanılmıştır. Öznitelik matrisi eğitim ve test olarak ikiye ayrılmıştır. Eğitim ve test olarak ayrılması için K katlamalı çapraz doğrulama yöntemi kullanılmıştır. Verinin sayısının az olmasından dolayı 3 ve 5 katlamalı çapraz doğrulama yöntemi tercih edilmiştir. Eğitim verisi ile makine öğrenmesi yöntemi olan DVM eğitilmiş ve test verisi ile model test edilmiştir. Tüm işlemler MATLAB (The MathWorks, Inc.) uygulaması üzerinde yapılmıştır.

Bu tez çalışmasında sınıflandırma performansını etkileyen en önemlisi olan öznitelikler üzerine odaklanılmıştır. Öznitelik sayısındaki artış, sınıflandırma performansını artırabilmektedir. Fakat fazla öznitelik kullanımı boyutsallık lanetine de yol açabilmektedir. Ayrıca fazla öznitelik kullanılması sınıflandırma işleminin uzun sürmesine ve çok fazla miktarda hesaplama işleminin yapılmasına neden olmaktadır. Bu durumlardan dolayı bu tez çalışmasında az bir miktarda öznitelik kullanılarak yüksek doğrulukta sınıflandırma performansının elde edilmesine odaklanılmıştır.

Bu tez kapsamında çıkartılan özniteliklerin zaman karmaşıklıklarına da dikkat edilmiştir. Az miktardan öznitelik kullanılarak minimum zaman karmaşıklığı ile öznitelikler çıkartılması hedeflenmektedir. Her bir özniteliğin zaman karmaşıklığı değerleri Tablo 4.1'de gösterilmiştir. 4. Sensörün Frekans değerinin hesaplanması, ortalama adım süresi ve ortalama adım mesafesi öznitelikleri O(n) karmaşıkta hesaplanırken ortalama duruş süresi ise O(n)+O(logn) karmaşıklıkta hesaplanmaktadır. Toplam karmaşıklık değeri 4O(n)+O(logn)'dir. Bu durumda öznitelik çıkartma işlemi O(n) karmaşıklıkta hesaplandığı anlaşılmaktadır. Bu durum öznitelik çıkartımı için en kötü durumu göstermektedir.

Tablo 4.1: Öznitelikler için zaman karmaşıklığı değerleri

Öznitelikler	**Zaman Karmaşıklığı**
4.Sensörün Frekans değerinin hesaplanması	$O(n)$
Ortalama Duruş Süresi	$O(n) + O(logn)$
Ortalama Adım Süresi	$O(n)$
Ortamalama Adım Mesafesi	$O(n)$
Toplam	$4O(n) + O(logn)$

Zaman karmaşıklıkları incelendiğinde öznitelik çıkarma işlemini literatürde yer alan öznitelik çıkarma yöntemlerine göre iyi performans verdiği görülmektedir. Bu durumda sınıflandırma işlemi için kısa sürede özniteliklerin çıkartılmasına ve hızlı bir şekilde Parkinson hastalığının tespit edilmesine olanak sağlamaktadır.

4.1. VERİ KÜMESİ İÇİN MAKİNE ÖĞRENMESİ ALGORİTMASININ SONUÇLARI

PhysioNet veritabanına ait olan "Parkinson hastalığında yürüyüş" veri seti önerilen yöntem uygulanmıştır. Önerilen yöntem içerisinde 4 adet öznitelik çıkartılarak öznitelik vektör temsili elde edilmiştir. Elde edilen öznitelikler ve sınıflandırma etiketleri K-katlamalı çapraz doğrulama ile eğitim ve test olarak ikiye ayrılmıştır. K değeri olarak ise 3 ve 5 katlamalı çapraz

doğrulama kullanılmıştır. Eğitim verileri ile makine öğrenmesi yöntemi olan DVM algoritması kullanılarak model oluşturulmuştur. Model oluşturulurken farklı çekirdek fonksiyonları kullanılmıştır. Kullanılan çekirdek fonksiyonları lineer, gauss, polinom ve RBF fonksiyonlarıdır. Bu fonksiyonlar ile oluşturulan modellerin performansı test verisi kullanılarak test edilmiştir. Test sonucunda oluşan sınıflandırma performansları Tablo 4.2 ve Tablo 4.3.'de gösterilmektedir.

Tablo 4.2: Çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değeri

	3-Katlamalı Çapraz Doğrulama	**5-Katlamalı Çapraz Doğrulama**
VeriSeti / Çekirdek	**Veri Setinin Tümü**	**Veri Setinin Tümü**
Lineer	81.8	84.8
Gauss	78.2	84.8
Polinom	78.2	81.8
RBF	81.8	78.8

Tablo 4.3: Çapraz doğrulama kullanılarak elde edilen ortalama sınıflandırma değeri

	3-Katlamalı Çapraz Doğrulama	**5-Katlamalı Çapraz Doğrulama**
VeriSeti / Çekirdek	**Veri Setinin Tümü**	**Veri Setinin Tümü**
Lineer	76.9	76.9
Gauss	75.7	75.7
Polinom	73.9	74.5
RBF	76.9	75.7

Tablo 4.2 ve Tablo 4.3.'de test verisinin sınıflandırma performansları gösterilmektedir. Bu değer Parkinson hastası bireylerin ve sağlıklı bireylerin doğru şekilde sınıflandırdığını gösteren değerlerdir. Tablo 4.2'deki bilgiler 3 ve 5 katlamalı çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değerini göstermektedir. Tablo 4.3 ise 3 ve 5 katlamalı çapraz doğrulama sonucunda elde edilen ortalama sonucu göstermektedir. Tablo 4.2 ve Tablo 4.3. incelendiğinde 5 katlamalı çapraz doğrulama yöntemi 3 katlamalı çapraz doğrulama yöntemine göre genel olarak daha iyi performans gösterdiği görülmektedir. Bu durumdan dolayı

sınıflandırma karşılaştırmalarında 5 katlamalı çapraz doğrulama yöntemi sonucunda elde edilen sonuçlar kullanılmıştır.

Tablo 4.2 ve Tablo 4.3. incelendiğinde Tablo 4.2 de yer alan sonuçlar Tablo 4.3. göre daha yüksek değerli sonuçlar vermiştir. Bunun temel sebebi maksimum değere sahip çapraz doğrulama yönteminin seçilmesidir. Bundan dolayı performans karşılaştırmalarında maksimum doğruluk değerine sahip değerler kullanılmıştır.

Tablo 4.2 yer alan çekirdek değerlerin incelendiğinde 5 katlamalı çapraz doğrulama kullanılarak elde edilen sonuçlarda lineer ve gauss çekirdekler benzer değerlerde sonuçlar elde ettiği görülmüştür. Diğer 2 çekirdek değerleri linner ve gauss çekirdeklerden daha düşük performans göstermişlerdir. Bu durumdan dolayı lineer ve gauss çekirdek fonksiyonları tüm veriseti için en yüksek doğruluk değerine sahip sınıflandırma değerleridir. Bu değerler kullanılarak literatürde yer alan çalışmalar ile karşılaştırma yapılmıştır.

Maksimum değere sahip 5 katlamalı çapraz doğrulama ile ayrılan test verisinde 13 Parkinson hastası birey ve 20 sağlıklı birey yer almaktadır. Gauss çekirdek sahip DVM yöntemi ile oluşturulan modele test verisi uygulanmıştır. Uygulama sonucunda elde edilen karmaşıklık matrisi Tablo 4.4'te yer almaktadır.

Tablo 4.4: Tüm veri için karmaşıklık matrisi sonuçları

		Tahmini Değerler	
		Parkinson Hastası	**Sağlıklı Birey**
Gerçek Değerler	**Parkinson Hastası**	12	1
	Sağlıklı Birey	4	16

Tablo 4.4 incelendiğinde, test sonucunda 13 Parkinson hastası bireyden 1 adet kişiyi yanlış sınıflandırarak sağlıklı birey olarak tahmin etmiştir. Benzer şekilde 20 sağlıklı birey arasından 4 adet kişiyi ise Parkinson hastası olarak sınıflandırmıştır. Sınıflandırma sonucunda elde edilen doğruluk değeri ise Tablo 4.3'te gösterildiği gibi %84.8 olarak belirlenmiştir.

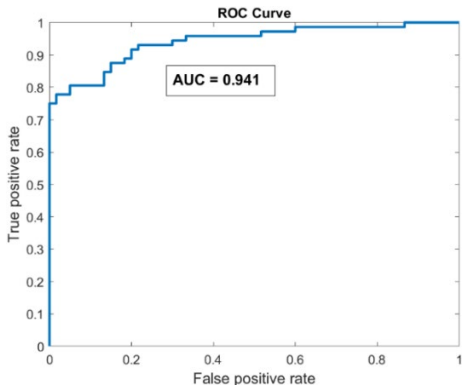
Tablo 4.4'te yer alan karmaşıklık matrisi kullanılarak Duyarlılık, Özgünlük, Kesinlik ve Matthews Korelasyon Katsayısı değerlendirme ölçütleri hesaplanmıştır. Hesaplana sonuçlar Tablo 4.5.'te yer almaktadır.

Tablo 4.5: Tüm veri için değerlendirme ölçütleri sonuçları

Değerlendirme ölçütleri	Test Verisi
Duyarlılık	0.92
Özgünlük	0.80
Kesinlik	0.75
MCC	0.71

Tablo 4.5.'de Duyarlılık incelendiğinde Parkinson hastası bireyleri yüksek oranda doğru tespit ettiği görülmektedir. Özgünlük değeri incelendiğinde ise sağlıklı bireylerin yüksek bir doğruluk ile doğru sınıflandırdığı anlaşılmıştır. Kesinlik bilgisi ile ise tahmin edilen Parkinson hastası bireylerinin doğru bir şekilde de tahmin edilme oranına göstermektedir. Bu oran istenilen düzeylerdedir. MCC değeri ise doğru sınıfa atanmış verilerde 1'e yakın değerler almaktadır. Tablo 4.5. incelendiğinde 1 yakın değer olan 0.71 değerinin almıştır. Bu durumlar incelendiğinde Parkinson hastası bireylerinin tespitinde önerilen yöntemin yüksek oranda performans verdiği anlaşılmaktadır. Böylece önerilen yöntem kullanılarak Parkinson hastalığı tespit edilebilmektedir.

Sınıflandırma modelleri başarı değerlendirme ölçütlerinden bir diğeri olan ROC Eğrisidir. ROC eğrisi Duyarlılık değeri ile Özgünlük değerinin grafiksel olarak gösterilmesi ile elde edilen gösterim şeklidir. Grafiğin y ekseninde Duyarlılık oranı yani doğru pozitif oran değeri, X ekseninde ise Özgünlük oranı yani doğru negatif oran değerini temsil etmektedir. Oluşan eğrinin altında kalan alana ise eğrinin altında kalan alan (AUC) olarak isimlendirmektedir. Elde edilen özgünlük ve duyarlılık verileri kullanılarak oluşturulan ROC eğrisi Şekil 4.1'de gösterilmektedir. Ayrıca AUC değeri 0.941 olarak bulunmuştur. Bulunan değer Şekil 4.1'de gösterilmiştir.



Şekil 4.1: ROC eğrisi gösterimi

4.1.1. GA Veri Kümesi İçin Makine Öğrenmesi Algoritmasının Sonuçları

GA veri kümesine önerilen yöntem uygulanmıştır. Önerilen yöntem içerisinde 4 adet öznitelik çıkartılarak öznitelik vektörü temsili elde edilmiştir. Elde edilen öznitelikler ve sınıflandırma etiketleri K-katlamalı çapraz doğrulama ile eğitim ve test olarak ikiye ayrılmıştır. K değeri olarak ise 3 ve 5 katlamalı çapraz doğrulama kullanılmıştır. Eğitim verileri ile makine öğrenmesi yöntemi olan DVM algoritması kullanılarak model oluşturulmuştur. Model oluşturulurken farklı çekirdek fonksiyonları kullanılmıştır. Kullanılan çekirdek fonksiyonları lineer, gauss, polinom ve RBF fonksiyonlarıdır. Bu fonksiyonlar ile oluşturulan modellerin performansı test verisi kullanılarak test edilmiştir. Test sonucunda oluşan sınıflandırma performansları Tablo 4.6. ve Tablo 4.7.'de gösterilmektedir.

Tablo 4.6: GA verisi için çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değeri

	3-Katlamalı Çapraz Doğrulama	**5-Katlamalı Çapraz Doğrulama**
VeriSeti / Çekirdek	**Veri Setinin Tümü**	**Veri Setinin Tümü**
Lineer	86.7	88.9
Gauss	93.8	88.9
Polinom	87.5	88.9
RBF	81.3	88.9

Tablo 4.7: GA verisi için Çapraz doğrulama kullanılarak elde edilen ortalama sınıflandırma değeri

	3-Katlamalı Çapraz Doğrulama	**5-Katlamalı Çapraz Doğrulama**
VeriSeti / Çekirdek	**Veri Setinin Tümü**	**Veri Setinin Tümü**
Lineer	81	81.1
Gauss	82.9	78.9
Polinom	78.7	78.9
RBF	80.8	78.9

Tablo 4.6. ve Tablo 4.7.'de test verisinin sınıflandırma performansları gösterilmektedir. Bu değer Parkinson hastası bireylerin ve sağlıklı bireylerin doğru şekilde sınıflandırdığını gösteren değerlerdir. Tablo 4.6.'deki bilgiler 3 ve 5 katlamalı çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değerini göstermektedir. Tablo 4.7. ise 3 ve 5 katlamalı çapraz

doğrulama sonucunda elde edilen ortalama sonucu göstermektedir. Tablo 4.6. ve Tablo 4.7. incelendiğinde 5 katlamalı çapraz doğrulama yöntemi 3 katlamalı çapraz doğrulama yöntemine göre genel olarak daha iyi performans gösterdiği görülmektedir. Bu durumdan dolayı sınıflandırma karşılaştırmalarında 5 katlamalı çapraz doğrulama yöntemi sonucunda elde edilen sonuçlar kullanılmıştır.

Tablo 4.6. ve Tablo 4.7. incelendiğinde Tablo 4.6. de yer alan sonuçlar Tablo 4.7. göre daha yüksek değerlerdir. Bunun temel sebebi maksimum değere sahip çapraz doğrulama yönteminin seçilmesidir. Bundan dolayı performans karşılaştırmalarında maksimum doğruluk değerine sahip değerler kullanılmıştır.

Tablo 4.6. yer alan çekirdek değerlerin incelendiğinde 5 katlamalı çapraz doğrulama kullanılarak elde edilen sonuçların benzer değerlerde olduğu görülmüştür. Bu durumdan dolayı Tüm veride kullanılan çekirdek yöntemine benzer olması adına gauss çekirdeğinin kullanılması karar verilmiştir. GA veri kümesi için %88.9 oranında doğruluk değerine sahip olan gauss çekirdeği kullanılmıştır.

Maksimum değere sahip 5 katlamalı çapraz doğrulama ile ayrılan test verisinde 7 Parkinson hastası birey ve 2 sağlıklı birey yer almaktadır. Gauss çekirdeği kullanılan DVM yöntemi ile oluşturulan modele test verisi uygulanmıştır. Uygulama sonucunda elde edilen karmaşıklık matrisi Tablo 4.8.'de yer almaktadır.

Tablo 4.8: GA verisi için karmaşıklık matrisi sonuçları

		Tahmini Değerler	
		Parkinson Hastası	**Sağlıklı Birey**
Gerçek Değerler	**Parkinson Hastası**	6	1
	Sağlıklı Birey	0	2

Tablo 4.8. incelendiğinde test sonucunda, 7 Parkinson hastası bireyden 1 adet kişiyi yanlış sınıflandırarak sağlıklı birey olarak tahmin etmiştir. Ayrıca 2 sağlıklı birey doğru bir şekilde tahmin etmişti. Sınıflandırma sonucunda elde edilen doğruluk değeri ise tablo 4.6.'da gösterildiği gibi %88.9 olarak belirlenmiştir.

Tablo 4.8.'de yer alan karmaşıklık matrisi kullanılarak Duyarlılık, Özgünlük, Kesinlik ve Matthews Korelasyon Katsayısı değerlendirme ölçütleri hesaplanmıştır. Hesaplana Tablo 4.9.'da yer almaktadır.

Tablo 4.9: GA verisi için değerlendirme ölçütleri sonuçları

Değerlendirme ölçütleri	**Test Verisi**
Duyarlılık	0.86
Özgünlük	1
Kesinlik	1
MCC	0.76

Duyarlılık incelendiğinde Parkinson hastası bireyleri yüksek oranda doğru tespit ettiği görülmektedir. Özgünlük değeri incelendiğinde ise sağlıklı bireyleri doğru bir şekilde sınıflandırdığı anlaşılmıştır. Kesinlik bilgisi ile ise tahmin edilen Parkinson hastası bireylerinin doğru bir şekilde de tahmin edilme oranına göstermektedir. Bu oran bakıldığında doğru bir şekilde Parkinson hastası bireylerin tahmin edildiği görülmektedir. MCC değeri ise doğru sınıfa atanmış verilerde 1'e yakın değerler almaktadır. Tablo 4.9. incelendiğinde 1 yakın değer olan 0.76 değerinin almıştır.

4.1.2. Si Veri Kümesi İçin Makine Öğrenmesi Algoritmasının Sonuçları

SI veri kümesine önerilen yöntem uygulanmıştır. Önerilen yöntem içerisinde 4 adet öznitelik çıkartılarak öznitelik vektörü temsili elde edilmiştir. Elde edilen öznitelikler ve sınıflandırma etiketleri K-katlamalı çapraz doğrulama ile eğitim ve test olarak ikiye ayrılmıştır. K değeri olarak ise 3 ve 5 katlamalı çapraz doğrulama kullanılmıştır. Eğitim verileri ile makine öğrenmesi yöntemi olan DVM algoritması kullanılarak model oluşturulmuştur. Model oluşturulurken farklı çekirdek fonksiyonları kullanılmıştır. Kullanılan çekirdek fonksiyonları lineer, gauss, polinom ve RBF fonksiyonlarıdır. Bu fonksiyonlar ile oluşturulan modellerin performansı test verisi kullanılarak test edilmiştir. Test sonucunda oluşan sınıflandırma performansları Tablo 4.10. ve Tablo 4.11.'de gösterilmektedir.

Tablo 4.10: SI verisi için çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değeri

	3-Katlamalı Çapraz Doğrulama	**5-Katlamalı Çapraz Doğrulama**
VeriSeti / Çekirdek	**SI**	**SI**
Lineer	81	84.0
Gauss	85.7	84.6
Polinom	81	84.6
RBF	81.8	84.6

Tablo 4.11: SI verisi için çapraz doğrulama kullanılarak elde edilen ortalama sınıflandırma değeri

	3-Katlamalı Çapraz Doğrulama	**5-Katlamalı Çapraz Doğrulama**
VeriSeti / Çekirdek	**SI**	**SI**
Lineer	73.4	73.2
Gauss	73.5	78.1
Polinom	73.5	74.8
RBF	78.3	75.1

Tablo 4.10. ve Tablo 4.11.'de test verisinin sınıflandırma performansları gösterilmektedir. Bu değer Parkinson hastası bireylerin ve sağlıklı bireylerin doğru şekilde sınıflandırdığını gösteren değerlerdir. Tablo 4.10.'deki bilgiler 3 ve 5 katlamalı çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değerini göstermektedir. Tablo 4.11. ise 3 ve 5 katlamalı çapraz doğrulama sonucunda elde edilen ortalama sonucu göstermektedir. Tablo 4.10. ve Tablo 4.11. incelendiğinde 5 katlamalı çapraz doğrulama yöntemi 3 katlamalı çapraz doğrulama yöntemine göre genel olarak daha iyi performans gösterdiği görülmektedir. Bu durumdan dolayı sınıflandırma karşılaştırmalarında 5 katlamalı çapraz doğrulama yöntemi sonucunda elde edilen sonuçlar kullanılmıştır.

Tablo 4.10. ve Tablo 4.11. incelendiğinde Tablo 4.10. de yer alan sonuçlar Tablo 4.11. göre daha yüksek değerlerdir. Bunun temel sebebi maksimum değere sahip çapraz doğrulama yönteminin seçilmesidir. Bundan dolayı performans karşılaştırmalarında maksimum doğruluk değerine sahip değerler kullanılmıştır.

Tablo 4.10. yer alan çekirdek değerlerin incelendiğinde 5 katlamalı çapraz doğrulama kullanılarak elde edilen sonuçların benzer değerlerde olduğu görülmüştür. Bu durumdan dolayı tüm veride kullanılan çekirdek yöntemine benzer olması adına gauss çekirdeğinin kullanılması karar verilmiştir. SI veri kümesi için %84.6 oranında doğruluk değerine sahip gauss çekirdeği kullanılmıştır.

Maksimum değere sahip 5 katlamalı çapraz doğrulama ile ayrılan test verisinde 8 Parkinson hastası birey ve 5 sağlıklı birey yer almaktadır. Gauss çekirdeği kullanılan DVM yöntemi ile oluşturulan modele test verisi uygulanmıştır. Uygulama sonucunda elde edilen karmaşıklık matrisi Tablo 4.12'de yer almaktadır.

Tablo 4.12: SI verisi için karmaşıklık matrisi sonuçları

		Tahmini Değerler	
		Parkinson Hastası	**Sağlıklı Birey**
Gerçek Değerler	**Parkinson Hastası**	8	0
	Sağlıklı Birey	2	3

Tablo 4.12 incelendiğinde test verisinin, 8 Parkinson hastası bireyin tümü doğru sınıf olarak tahmin edilmiştir. Ayrıca 5 sağlıklı bireyin 3'ü doğru bir şekilde tahmin edilmiş ve 2 birey ise Parkinson hastası olarak tahmin edilmiştir. Sınıflandırma sonucunda elde edilen doğruluk değeri ise Tablo 4.10 de gösterildiği gibi %84.6 olarak belirlenmiştir.

Tablo 4.12'de yer alan karmaşıklık matrisi kullanılarak Duyarlılık, Özgünlük, Kesinlik ve Matthews Korelasyon Katsayısı değerlendirme ölçütleri hesaplanmıştır. Hesaplana sonuçlar Tablo 4.13.'de yer almaktadır.

Tablo 4.13: SI verisi için değerlendirme ölçütleri sonuçları

Değerlendirme ölçütleri	**Test Verisi**
Duyarlılık	1
Özgünlük	0.6
Kesinlik	0.8
MCC	0.70

Duyarlılık incelendiğinde Parkinson hastası bireyleri doğru bir şekilde tespit ettiği görülmektedir. Özgünlük değeri incelendiğinde ise sağlıklı bireyleri 0.60 oranında doğru sınıflandırdığı hesaplanmıştır. Kesinlik bilgisi ile ise tahmin edilen Parkinson hastası bireylerinin doğru bir şekilde de tahmin edilme oranına göstermektedir. Bu oran bakıldığında yüksek oranda Parkinson hastası bireylerin tahmin edildiği görülmektedir. MCC değeri ise doğru sınıfa atanmış verilerde 1'e yakın değerler almaktadır. Tablo 4.13. incelendiğinde 1 yakın değer olan 0.70 değerinin almıştır.

4.1.3. JU Veri Kümesi İçin Makine Öğrenmesi Algoritmasının Sonuçları

JU veri kümesine önerilen yöntem uygulanmıştır. Önerilen yöntem içerisinde 4 adet öznitelik çıkartılarak öznitelik vektörü temsili elde edilmiştir. Elde edilen öznitelikler ve sınıflandırma etiketleri K-katlamalı çapraz doğrulama ile eğitim ve test olarak ikiye ayrılmıştır. K değeri olarak ise 3 ve 5 katlamalı çapraz doğrulama kullanılmıştır. Eğitim verileri ile makine öğrenmesi yöntemi olan DVM algoritması kullanılarak model oluşturulmuştur. Model oluşturulurken farklı çekirdek fonksiyonları kullanılmıştır. Kullanılan çekirdek fonksiyonları lineer, gauss, polinom ve RBF fonksiyonlarıdır. Bu fonksiyonlar ile oluşturulan modellerin performansı test verisi kullanılarak test edilmiştir. Test sonucunda oluşan sınıflandırma performansları Tablo 4.14. ve Tablo 4.15.'de gösterilmektedir.

Tablo 4.14: JU verisi için çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değeri

	3-Katlamalı Çapraz Doğrulama	**5-Katlamalı Çapraz Doğrulama**
VeriSeti / Çekirdek	**SI**	**SI**
Lineer	94.4	90.9
Gauss	88.9	90.9
Polinom	94.4	90.0
RBF	83.3	81.8

Tablo 4.15: JU verisi için çapraz doğrulama kullanılarak elde edilen ortalama sınıflandırma değeri

	3-Katlamalı Çapraz Doğrulama	**5-Katlamalı Çapraz Doğrulama**
VeriSeti / Çekirdek	**SI**	**SI**
Lineer	87.0	85.1
Gauss	81.4	79.6
Polinom	85.1	83.4
RBF	77.7	76

Tablo 4.14. ve Tablo 4.15.'de test verisinin sınıflandırma performansları gösterilmektedir. Bu değer Parkinson hastası bireylerin ve sağlıklı bireylerin doğru şekilde sınıflandırdığını gösteren değerlerdir. Tablo 4.14.'deki bilgiler 3 ve 5 katlamalı çapraz doğrulama kullanılarak elde edilen maksimum sınıflandırma değerini göstermektedir. Tablo 4.15. ise 3 ve 5 katlamalı çapraz doğrulama sonucunda elde edilen ortalama sonucu göstermektedir. Tablo 4.14. ve Tablo 4.15. incelendiğinde 5 katlamalı çapraz doğrulama yöntemi 3 katlamalı çapraz doğrulama yöntemine göre genel olarak daha iyi performans gösterdiği görülmektedir. Bu durumdan dolayı sınıflandırma karşılaştırmalarında 5 katlamalı çapraz doğrulama yöntemi sonucunda elde edilen sonuçlar kullanılmıştır.

Tablo 4.14. ve Tablo 4.15. incelendiğinde Tablo 4.14. de yer alan sonuçlar Tablo 4.15. göre daha yüksek değerlerdir. Bunun temel sebebi maksimum değere sahip çapraz doğrulama yönteminin seçilmesidir. Bundan dolayı performans karşılaştırmalarında maksimum doğruluk değerine sahip değerler kullanılmıştır.

Tablo 4.14. yer alan çekirdek değerlerin incelendiğinde 5 katlamalı çapraz doğrulama kullanılarak elde edilen sonuçların benzer değerlerde olduğu görülmüştür. Bu durumdan dolayı tüm veri de kullanılan çekirdek yöntemine benzer olması adına gauss çekirdeğinin kullanılması karar verilmiştir. JU veri kümesi için %90.9 oranında doğruluk değerine sahip gauss çekirdeği kullanılmıştır.

Maksimum değere sahip 5 katlamalı çapraz doğrulama ile ayrılan test verisinde 6 Parkinson hastası birey ve 5 sağlıklı birey yer almaktadır. Gauss çekirdeği kullanılan DVM yöntemi ile oluşturulan modele test verisi uygulanmıştır. Uygulama sonucunda elde edilen karmaşıklık matrisi Tablo 4.16.'de yer almaktadır.

Tablo 4.16: JU verisi için karmaşıklık matrisi sonuçları

		Tahmini Değerler	
		Parkinson Hastası	**Sağlıklı Birey**
Gerçek Değerler	**Parkinson Hastası**	6	0
	Sağlıklı Birey	1	4

Tablo 4.16. İncelendiğinde test sonucunda, 6 Parkinson hastası bireyin tümü doğru sınıf olarak tahmin edilmiştir. Ayrıca 5 sağlıklı birey 4'ü doğru bir şekilde tahmin edilmiş ve 1 birey ise Parkinson hastası olarak tahmin edilmiştir. Sınıflandırma sonucunda elde edilen doğruluk değeri ise Tablo 4.14'te gösterildiği gibi %90.9 olarak belirlenmiştir.

Tablo 4.16.'da yer alan karmaşıklık matrisi kullanılarak Duyarlılık, Özgünlük, Kesinlik ve Matthews Korelasyon Katsayısı değerlendirme ölçütleri hesaplanmıştır. Hesaplana sonuçlar Tablo 4.17.'te yer almaktadır.

Tablo 4.17: JU verisi için değerlendirme ölçütleri sonuçları

Değerlendirme ölçütleri	**Test Verisi**
Duyarlılık	1
Özgünlük	0.8
Kesinlik	0.86
MCC	0.83

Duyarlılık incelendiğinde Parkinson hastası bireyleri doğru bir şekilde tespit ettiği görülmektedir. Özgünlük değeri incelendiğinde ise sağlıklı bireyleri 0.80 oranında doğru sınıflandırdığı hesaplanmıştır. Kesinlik bilgisi ile ise tahmin edilen Parkinson hastası bireylerinin doğru bir şekilde de tahmin edilme oranına göstermektedir. Bu oran bakıldığında yüksek oranda Parkinson hastası bireylerin doğru tahmin edildiği görülmektedir. MCC değeri ise doğru sınıfa atanmış verilerde 1'e yakın değerler almaktadır. Tablo 4.17. incelendiğinde 1 yakın değer olan 0.83 değerinin almıştır.

4.2. BU TEZ ÇALIŞMASININ LİTERATÜRE KATKILARI VE SONUÇLARIN DEĞERLENDİRİLMESİ

Bir sınıflandırma görevinde, öznitelik çıkarma aşaması, sınıflandırma performansı için çok önemli olabilmektedir. Öznitelik sayısındaki artış, sınıflandırma performansını artırdığı gibi, boyutsallık lanetine de yol açabilmektedir. Öznitelik sayısı arttıkça öznitelik alanı da büyümektedir. Bu bağlamda, çalışma süresi genellikle Öznitelik sayısı ile artar. Bu nedenle, sınıflandırma görevi için çok büyük miktarda hesaplamaya ihtiyaç duyulabilir. Bu çalışmada, Parkinson hastalığı sınıflandırma görevi için düşük boyutlu bir öznitelik vektör temsili kullanılmıştır.

Önerilen yöntem sayesinde çok az miktarda öznitelik kullanılarak Parkinson hastalığı tespit edilebilmektedir. Öznitelik çıkarma işlemi kısa zaman aldığı için tespit işlemi ve sınıflandırma performansı az sürede bitmektedir. Bu durum hastalığın tespitinin hızlı bir şekilde tespit edilerek erken tedavinin başlamasına olanak sağlamaktadır.

Literatürde yürüyüş verilerinden Parkinson hastalığının tespit edilmesinde farklı çalışmalar yapılmıştır. Yapılan çalışmalar incelendiğinde genel olarak çok sayıda öznitelik kullanıldığı görülmüştür. Literatürde yer alan çalışmalar ve önerilen yöntemde kullanılan öznitelik sayıları Tablo 4.18.'de gösterilmektedir.

Öznitelik çıkarma yöntemleri incelendiğinde ise zaman ve frekans gibi farklı alanlar kullanılarak özniteliklerin çıkarıldığı görülmektedir. Bundan dolayı öznitelik çıkarma işlemi sınıflandırma performansını ve hesaplama maliyetini artırabilmektedir. Böylece hastalık tespit edilmesi uzamaktadır. Bu durum dikkate alındığında literatürde yer alan çalışmalardan farklı olarak önerilen öznitelik çıkarma yöntemi sadece zaman alanından elde edilen az sayıda öznitelikten oluşmaktadır. Ayrıca önerilen öznitelikler kullanılarak tatmin edici sınıflandırma sonuçları elde edilmektedir.

Tablo 4.18: Literatürde yer alan öznitelik sayıları ile önerilen yöntemden kullanılan özniteliklerin karşılaştırılması

İlgili Çalışmalar	[32]	[35]	[36]	[37]	[38]	[40]	[42]	[43]	[44]	[45]	Önerilen Yöntem
Öznitelik Sayısı	1472	60	100	156	40	10	12	30	108	2328	4

Tablo 4.18 incelendiğinde, önerilen yöntemde kullanılan öznitelik sayısının karşılaştırılan yöntemlere göre önemli ölçüde az olduğu görülmektedir. [32,44]'deki yöntemler öznitelikleri elde etmek için derin öğrenme yaklaşımlarına uygulanırken, [36]'deki yöntem öznitelik uzayının boyutunu azaltmak için PCA yaklaşımını kullanmaktadır. Öte yandan, [40, 42]'deki yöntemler zaman-frekans alanını kullanırken, [39, 41]'deki yöntemler sadece frekans alanını kullanır. Önerilen yöntemde ise sadece zaman alanı kullanılarak 4 adet öznitelik çıkartılmıştır. Bu durumlardan dolayı çok az ve karmaşık olmayan öznitelikler kullanılarak sınıflandırma işlemi yapılmıştır.

Literatürde yer alan çalışmalar ile önerilen yöntemin değerlendirme ölçütleri kullanılarak performans karşılaştırılması yapılmıştır. Değerlendirme ölçütleri içinde yer alan doğruluk değerli karşılaştırma sonuçları Tablo 4.19.'da verilmiştir. Ayrıca diğer karşılaştırma ölçütleri olan duyarlılık, özgünlük ve MCC kriterlerinin performans karşılaştırması ise Tablo 4.20.'de verilmiştir. Önerilen yöntemde kullanılan DVM algoritmasında kullanılan çekirdek değerlerinden elde edilen sonuçlar arasından en iyi performansı veren gauss çekirdeği dikkate alınarak karşılaştırma işlemi yapılmıştır. Karşılaştırma her bir veri kümesine (GA, SI, JU) göre ve veri setinin tamamına göre ayrı ayrı yapılmıştır. Tablo 4.19'da belirtilen sınıflandırma doğruluklarına bakıldığında, önerilen yöntem ile elde edilen sınıflandırma sonuçlarının doğruluk açısından diğer yöntemlerle rekabet edebileceği görülmüştür.

Tablo 4.19: Literatürde yer alan çalışmalar ile önerilen yöntemin doğruluk değerlerinin karşılaştırması

	Doğruluk			
Veri Seti / **İlgili Çalışmalar**	**GA**	**SI**	**JU**	**Tüm**
[32]	-	-	-	88.1
[35]	91.49	92.19	90.91	-
[36]	-	-	-	81.0
[37]	-	-	-	86.7
[38]	-	-	-	77.3
[40]	92.25	90.0	92.5	86.9
[42]	88.88	100	100	-
[43]	92.92	90.70	76.56	92.9
[44]	-	-	-	88.9
[45]	-	-	-	88.1
Önerilen Yöntem	88.9	84.6	90.9	84.8

Tablo 4.20.'de verilen sınıflandırma sonuçları göz önüne alındığında, önerilen yöntemin, duyarlılık ve özgüllük açısından karşılaştırılan yöntemlere göre tatmin edici bir performansa sahip olduğu görülmektedir. Tablo 4.20'de görüldüğü gibi önerilen yöntemin, tahmin edilen sınıflar ile gerçek sınıflar arasında MCC puanı açısından dengeli bir uyumda olduğu tespit edilmiştir

Tablo 4.20: Literatürde yer alan çalışmalar ile önerilen yöntemin duyarlılık, özgünlük ve MCC değerlerinin karşılaştırması

	Duyarlılık				**Özgünlük**				**MCC**			
Veri Seti / **İlgili Çalışmalar**	**GA**	**SI**	**JU**	**Tüm**	**GA**	**SI**	**JU**	**Tüm**	**GA**	**SI**	**JU**	**Tüm**
[32]	-	-	-	-	-	-	-	-	-	-	-	-
[35]	0.77	0.94	0.74	-	0.55	0.90	0.83	-	-	-	-	-
[36]	-	-	-	0.86	-	-	-	0.76	-	-	-	-
[37]	-	-	-	-	-	-	-	-	-	-	-	-
[38]	-	-	-	0.81	-	-	-	0.65	-	-	-	-
[40]	-	-	-	0.72	-	-	-	0.81	-	-	-	-
[42]	-	-	-	-	-	-	-	-	-	-	-	-
[43]	-	-	-	0.88	-	-	-	0.88	-	-	-	-
[44]	-	-	-	0.89	-	-	-	0.82	-	-	-	-
[45]	-	-	-	-	-	-	-	-	-	-	-	-
Önerilen Yöntem	0.86	1	1	0.92	1	0.60	0.8	0.80	0.76	0.70	0.83	0.71

Tablo 4.19. ve Tablo 4.20. incelendiğinde doğruluk kriteri ile elde edilen sınıflandırma sonuçlarına göre tüm veri setinde %85'e varan yüksek sınıflandırma performansı elde edilmektedir. Öte yandan, veri setleri tek tek değerlendirildiğinde %91'e varan üstün sınıflandırma performansı elde edilmektedir. Ayrıca duyarlılık kriterine göre önerilen yöntem karşılaştırılan yöntemler arasında en iyi performansı sergilemektedir.

5. SONUÇ VE ÖNERİLER

PH bilinen en eski hastalıklardan biridir. James Parkinson tarafından 1817 yılında hastalık olarak tanımlanmıştır. Hastalık keşfedildikten sonra hastalık üzerine çok fazla araştırma ve çalışma yapılmıştır. Günümüzde de araştırma ve çalışmalar sürmektedir. Hastalığın bilinen bir tedavisinin olmaması ve tespit yönteminin teorik ve gözleme dayalı olmasından dolayı hastalığın erken tespit edilmesinde birçok çalışmalar yapılmıştır. Bu çalışmalar ile hastalık erken tespit edilerek hastalığın ilerlemesi yavaşlatılabilmektedir. Ayrıca teorik ve gözleme dayalı yöntemlerin subjektif olduğundan dolayı daha hızlı ve objektif yöntemlerin araştırması yapılmıştır.

Parkinson hastalığının belirtilerinden birisi olan yürüyüş değişimleri araştırmacıların ilgi odağı olmuştur. Bunun temel sebebi yürüyüş analiz edilmesi objektif bir şekilde yapılması, kolay ve ulaşılabilir bir yöntem olması ve hastalığın tespitinde sadece yürüyüş bilgisinin alınarak konforlu bir şekilde hastalık tespit edildiği için çok fazla tercih edilmektedir.

Bu tez kapsamına "Parkinson hastası bireylerden ve sağlıklı bireylerden alınan yürüyüş verilerinden az miktarda öznitelik çıkartılarak Parkinson hastalığı tespit edilebilir mi?" sorusuna odaklanılmış ve araştırılmıştır. Bu durumdan dolayı az miktarda çıkartılan öznitelikler kullanılarak makine öğrenmesi yöntemi kullanılarak Parkinson hastası birey ile sağlıklı birey arasında ayrım yapabilen bir yöntem geliştirilmiştir.

Makine öğrenmesi yöntemi olarak DVM yöntemi kullanılmıştır. Sınıflandırma performansını etkileyecek gürültülü veriler ön işlemden geçirilerek kaldırılmıştır ve normalizasyon işlemi uygulanmıştır. Verilerden daha sonra öznitelikler çıkartılmış ve çapraz doğrulama yöntemleri ile eğitim ve test şeklinde ayrılarak sınıflandırma işlemi yapılmıştır ve çapraz doğrulama yöntemleri karşılaştırılmıştır. Bu işlemler MATLAB programı üzerinde gerçekleştirilmiş ve incelenmiştir.

Veri seti 3 farklı çalışmanın bireyleştirilmesi ile oluşturulan PhysioNet veritabanına ait olan "Parkinson hastalığında yürüyüş" veri setidir. Bu veri seti oluşturulurken kullanılan veriler ise GA, SI ve JU isminde çalışmalardan alınmıştır. GA veri setinde 18 sağlıklı birey ve 29 Parkinson hastası birey bulunmaktadır. SI verinde ise 29 sağlıklı birey ve 35 Parkinson hastası birey bulunmaktadır. JU veri setinde ise 25 sağlıklı birey ve 29 Parkinson hastası birey bulunmaktadır. Toplam veri seti ise 72 sağlıklı birey ve 93 Parkinson hastası birey

bulunmaktadır. Veri alınırken 120 saniye boyunca bir zemin üzerinde Parkinson hastası ve sağlıklı bireyler yürütülmüştür. Bu sırada ayak tabanına yerleştirilen sol da 8 sensör ve sağda 8 sensör olmak üzere toplam 16 sensörden veriler alınarak kaydedilmiştir.

Bu çalışmada, Parkinson hastalığını tespit etmek için düşük boyutlu bir öznitelik vektör temsili önerilmiştir. Önerilen yöntem sayesinde, sınıflandırma performansından ödün vermeden düşük zaman karmaşıklığına sahip az sayıda öznitelik kullanılarak tespit edilebildiği görülmüştür.

Sınıflandırma sonuçlarına göre tüm veri setinde %85'e varan yüksek sınıflandırma performansı elde edilmiştir. Öte yandan, veri setleri tek tek değerlendirildiğinde %91'e varan üstün sınıflandırma performansı elde edilmiştir.

Gelecekte yapılacak çalışmalarda daha fazla katılımın sağlandığı veri setleri kullanılarak sınıflandırma işlemi yapılabilir. Bu şekilde yüksek performansa sahip sınıflandırma yöntemleri geliştirilebilir. Bu çalışmada kullanılan az miktardaki öznitelik sayısında azaltma işlemi yapılarak bir veya iki öznitelik kullanılarak yüksek performansa sahip sonuçlar oluşturulabilir. Yürüyüş verisine ek olarak farklı belirtilerden alınan veriler birleştirilerek daha kapsamlı bir tespit yöntemi oluşturulabilir. Hastalığın tespitinin yanı sıra hastalığın evrelerinin belirlendiğin yeni bir sınıflandırma yöntemi geliştirilebilir.

Parkinson hastalığının tespit yöntemi mobil uygulama haline getirilerek yürüyüş sırasında hasta olup olmadığını kontrol eden bir sistem oluşturulabilir. Bu şekilde günlük yürüyüş sırasında hastanın yürüyüş bilgilerini kendisi inceleyerek Parkinson olup olmadığını tespit edebilir. Bu şekilde bir durum ile karşılaşması durumunda ise hastaneye başvurarak erken dönemde hastalık tespit edilip tedavisine başlanabilir.

Veri setleri genişletilerek veya yapısı farklılaştırılarak derin öğrenme yöntemleri kullanılarak Parkinson hastalığı tespit edilebilir. Bu şekilde günümüzde popüler olan derin öğrenme yöntemi kullanılarak daha iyi sonuçlar elde edilebilir.

6. KAYNAKLAR

[1]. Akay, E. Ç., 2018, Ekonometride yeni bir ufuk: Büyük veri ve makine öğrenmesi, *Sosyal Bilimler Araştırma Dergisi*, *7*(2), 41-53.

[2]. Deo, R. C., 2015, Machine learning in medicine, *Circulation*, *132*(20), 1920-1930.

[3]. Xu, C., & Jackson, S. A., 2019, Machine learning and complex biological data, *Genome biology*, *20*(1), 1-4.

[4]. Artrith, N., Butler, K. T., Coudert, F. X., Han, S., Isayev, O., Jain, A., & Walsh, A., 2021, Best practices in machine learning for chemistry, *Nature chemistry*, *13*(6), 505-508.

[5]. Sanei, S., & Chambers, J. A., 2013, *Introduction to EGG*, EEG signal processing, In: Chambers J. A., Sanei S., Chapter 1, John Wiley & Sons, Ltd, ISBN 978-0-470-02581-9, 25-58.

[6]. Organization W. H. O., 2020, *World Health Organization: Epilepsy* https://www.who.int/news-room/fact-sheets/detail/epilepsy, [Ziyaret Tarihi: 02.09.2022].

[7]. Ghosh, R., & Tabrizi, S. J., 2018. Huntington disease, *Handbook of clinical neurology*, *147*, 255-278.

[8]. Poewe, W., Seppi, K., Tanner, C. M., Halliday, G. M., Brundin, P., Volkmann, J. and Lang, A. E., 2017, Parkinson disease, *Nature reviews Disease primers*, *3*(1), 1-21.

[9]. Sweeney P., 2013 Cleveland Clinic, *Parkinson's Disease,* https://my.clevelandclinic.org/health/diseases/8525-parkinsons-disease-an-overview [Ziyaret tarihi: 10.09.2022].

[10]. Dorsey, E. A., Constantinescu, R., Thompson, J. P., Biglan, K. M., Holloway, R. G., Kieburtz, K., and Tanner, C. M., 2007, Projected number of people with Parkinson disease in the most populous nations, 2005 through 2030, *Neurology*, *68*(5), 384-386.

[11]. Parkinson, J., 2002, An essay on the shaking palsy, *The Journal of neuropsychiatry and clinical neurosciences*, *14*(2), 223-236.

[12]. Goetz, C. G., 2011, The history of Parkinson's disease: early clinical descriptions and neurological therapies, *Cold Spring Harbor perspectives in medicine*, *1*(1), a008862.

[13]. Parkinsons.org, 2009, *Parkinson's Disease Information, Parkinson's Disease History*, http://www.parkinsons.org/parkinsons-history.html, [Ziyaret Tarihi: 12.09.2022].

[14]. Chou K. L., 2022, Patient *education: Parkinson disease symptoms and diagnosis (Beyond the Basics),* https://www.uptodate.com/contents/parkinson-disease-symptoms-and-diagnosis-beyond-the-basics, [Ziyaret Tarihi:15.09.2022].

[15]. healthdirect.gov, 2021, dopamin, https://www.healthdirect.gov.au/dopamine, [Ziyaret Tarihi:01.10.2022].

[16]. Parkinsons.org, 2009, *Understanding Parkinson's, Causes*, https://www.parkinson.org/understanding-parkinsons/causes , [Ziyaret Tarihi: 05.10.2022].

[17]. Sveinbjornsdottir, S., 2016, The clinical symptoms of Parkinson's disease, *Journal of neurochemistry*, *139*, 318-324.

[18]. Mirelman, A., Bonato, P., Camicioli, R., Ellis, T. D., Giladi, N., Hamilton, J. L. and Almeida, Q. J., 2019, Gait impairments in Parkinson's disease, *The Lancet Neurology*, *18*(7), 697-708.

[19]. Yavuzer, G., 2014, Yürüme analizi ve temel kavramlar. *Türk Ortopedi ve Travmatoloji Birliği Derneği Dergisi, İstanbul*, *13*, 304-308.

[20]. ŞAHİN ONAT, Ş., ÜNSAL DELİALİOĞLU, S., & ÖZEL, S., 2014, Geriatrik Popülasyonda Dengenin Fonksiyonel Durum ve Yaşam Kalitesi ile İlişkisi, *Turkish Journal of Physical Medicine & Rehabilitation/Turkiye Fiziksel Tip ve Rehabilitasyon Dergisi*, *60*(2).

[21]. Esentürk S., 2014, *Yürüme Siklusu Nedir?* https://www.podolojiturkiye.org/blog/2014/10/14/yurume-siklusu-nedir [Ziyaret Tarihi:15.10.2022].

[22]. Şeker, A., Talmaç, M. A. and Sarıkaya, İ., 2014, Yürüme biyomekaniği, *TOTBİD Dergisi*, *13*, 314-324.

[23]. Yavuzer, G., 2009, Üç boyutlu niceliksel yürüme analizi, *Acta Orthopaedica Traumatologica Turcica*, *43*(2), 94-101.

[24]. Tönük, E., 2014, Yürüme ve hareket analizi sistemleri: teknik ayrıntılar, *Türk Ortopedi ve Travmatoloji Birliği Derneği (TOTBİD) Dergisi*, *13*, 309-313.

[25]. Clayton, H. M., 1995, Comparison of the stride kinematics----. *Am J Vet Res*, *56*(7).

[26]. Whittle M. W., 2007, *Applications of gait analysis,* An Introduction to Gait Analysis, Chapter 5, Butterworth-Heinemann, ISBN: 978-0750688833, 177-193.

[27]. Öztekin, H. C., 2022, Kadans ve Kadans' ı Etkileyen Faktörlerin Değerlendirilmesi, *Mevlana Tıp Bilimleri Dergisi*, *2*(1), 10-14.

[28]. Alsancak, S., 2015, Yürüyüş terminolojisi, *Ankara Sağlık Hizmetleri Dergisi*, *14*(2), 1-6.

[29]. Altun, A. M., Ozbek, S. E., Zarifoglu, M., and Özkaya, G., 2013, Parkinson Hastalığında yürüme ve dengenin değerlendirilmesi, *Parkinson Hastalığı ve Hareket Bozuklukları Dergisi*, *16*(1-2), 1-8.

[30]. Hubble, R. P., Naughton, G. A., Silburn, P. A. and Cole, M. H., 2015, Wearable sensor use for assessing standing balance and walking stability in people with Parkinson's disease: a systematic review, *PloS one*, *10*(4), e0123705.

[31]. Kimmeskamp, S. and Hennig, E. M., 2001, Heel to toe motion characteristics in Parkinson patients during free walking, *Clinical biomechanics*, *16*(9), 806-812.

[32]. Johri, A. and Tripathi, A., 2019, Parkinson disease detection using deep neural networks. In *2019 Twelfth international conference on contemporary computing (IC3),* 08-10 August 2019 and Noida, India, IEEE, pp. 1-4.

[33]. Drotár, P., Mekyska, J., Rektorová, I., Masarová, L., Smékal, Z. and Faundez-Zanuy, M., 2014, Analysis of in-air movement in handwriting: A novel marker for Parkinson's disease, *Computer methods and programs in biomedicine*, *117*(3), 405-411.

[34]. Lones, M. A., Smith, S. L., Alty, J. E., Lacy, S. E., Possin, K. L., Jamieson, D. S. and Tyrrell, A. M., 2013, Evolving classifiers to recognize the movement characteristics of Parkinson's disease patients, *IEEE Transactions on Evolutionary Computation*, *18*(4), 559-576.

[35]. Jane, Y. N., Nehemiah, H. K. and Arputharaj, K., 2016, A Q-backpropagated time delay neural network for diagnosing severity of gait disturbances in Parkinson's disease, *Journal of biomedical informatics*, *60*, 169-176.

[36]. Medeiros, L., Almeida, H., Dias, L., Perkusich, M. and Fischer, R., 2016, A gait analysis approach to track parkinson's disease evolution using principal component analysis. In *2016 IEEE 29th International Symposium on Computer-Based Medical Systems (CBMS)*, 20-24 June 2016 and Belfast and Dublin, Ireland, IEEE, pp. 48-53.

[37]. Baby M. S., Saji A. J., Kumar C. S., 2017, Parkinsons disease classification using wavelet transform-based feature extraction of gait data, *In 2017 International Conference on Circuit, Power and Computing Technologies (ICCPCT)*, 20-21 April 2017 and Kollam, India, IEEE, pp. 1-6.

[38]. Lee, S. H. and Lim, J. S., 2012, Parkinson's disease classification using gait characteristics and wavelet-based feature extraction, *Expert Systems with Applications*, *39*(8), 7338-7344.

[39]. Lim, C. M., Ng, H., Yap, T. T. V. and Ho, C. C., 2015, GAIT ANALYSIS AND CLASSIFICATION ON SUBJECTS WITH PARKINSONâ€™ S DISEASE, *Jurnal Teknologi*, *77*(18).

[40]. Perumal, S. V. and Sankar, R., 2016, Gait and tremor assessment for patients with Parkinson's disease using wearable sensors, *Ict Express*, *2*(4), 168-174.

[41]. Abdulhay, E., Arunkumar, N., Narasimhan, K., Vellaiappan, E., and Venkatraman, V., 2018, Gait and tremor investigation using machine learning techniques for the diagnosis of Parkinson disease, *Future Generation Computer Systems*, *83*, 366-373.

[42]. Andrei, A. G., Tăuțan, A. M., & Ionescu, B. (2019, November). Parkinson's disease detection from gait patterns. In *2019 E-Health and Bioengineering Conference (EHB),* 21-23 November 2019 and Iasi, Romania, IEEE, pp. 1-4.

[43]. Özel, E., Tekin, R. and Kaya, Y., 2021, Implementation of Artifact Removal Algorithms in Gait Signals for Diagnosis of Parkinson Disease, *Traitement du Signal*, *38*(3).

[44]. Ertuğrul, Ö. F., Kaya, Y., Tekin, R. and Almalı, M. N., 2016, Detection of Parkinson's disease by shifted one dimensional local binary patterns from gait, *Expert Systems with Applications*, 56, 156-163.

[45]. Hoang, N. S., Cai, Y., Lee, C. W., Yang, Y. O., Chui, C. K. and Chua, M. C. H., 2019, Gait classification for Parkinson's Disease using Stacked 2D and 1D Convolutional Neural Network. In *2019 International Conference on Advanced Technologies for Communications (ATC),* 17-19 October 2019 and Hanoi, Vietnam, IEEE, pp. 44-49.

[46]. Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G. and Stanley, H. E., 2000, PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals, *circulation*, *101*(23), e215-e220.

[47]. Yogev, G., Giladi, N., Peretz, C., Springer, S., Simon, E. S. and Hausdorff, J. M., 2005, Dual tasking, gait rhythmicity, and Parkinson's disease: which aspects of gait are attention demanding?, *European journal of neuroscience*, *22*(5), 1248-1256.

[48]. Hausdorff, J. M., Lowenthal, J., Herman, T., Gruendlinger, L., Peretz, C. and Giladi, N., 2007, Rhythmic auditory stimulation modulates gait variability in Parkinson's disease, *European Journal of Neuroscience*, *26*(8), 2369-2375.

[49]. Frenkel-Toledo, S., Giladi, N., Peretz, C., Herman, T., Gruendlinger, L. and Hausdorff, J. M., 2005, Effect of gait speed on gait rhythmicity in Parkinson's disease: variability of stride time and swing time respond differently, *Journal of neuroengineering and rehabilitation*, *2*(1), 1-7.

[50]. Yavuz, S. and Deveci, M., 2012, İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağin Performansina Etkisi, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187.

[51]. Metlek, S. and Kayaalp, K., 2020 *Destek Vektör Makineleri*, Makine Öğrenmesinde, Teoriden Örnek MATLAB Uygulamalarına Kadar Destek Vektör Makineleri, Kaya İ,Chapter 2, İksad Yayınevi, ISBN: 978-625-7279-74-1, pp. 21-59.