T.C.

TRAKYA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKÂ ALGORİTMALARI İLE GÖZ HAREKET VERİLERİNDEN PARKİNSON HASTALIĞININ ERKEN EVRE TESPİTİ VE DERECELENDİRİLMESİ

İLKE KURT

DOKTORA TEZİ

HESAPLAMALI BİLİMLER ANABİLİM DALI

Tez Danışmanı: Prof. Dr. OĞUZHAN ERDEM

İkinci Tez Danışmanı: Doç. Dr. SEZER ULUKAYA

EDİRNE-2025

İLKE KURT'un hazırladığı "**YAPAY ZEKÂ ALGORİTMALARI İLE GÖZ HAREKET VERİLERİNDEN PARKİNSON HASTALIĞININ ERKEN EVRE TESPİTİ VE DERECELENDİRİLMESİ**" başlıklı bu tez, tarafımızca okunmuş, kapsam ve niteliği açısından **Hesaplamalı Bilimler** Anabilim Dalında bir **Doktora tezi** olarak kabul edilmiştir.

Jüri Üyeleri:	İmza
Prof. Dr. Oğuzhan ERDEM	……
Dr. Öğr. Üyesi Aydın CARUS	……
Dr. Öğr. Üyesi Özlem UÇAR	……
Doç. Dr. Barış ÖZYER	……
Dr. Öğr. Üyesi Görkem SERBES	……

Tez Savunma Tarihi: 08/01/2025

Bu tezin Doktora tezi olarak gerekli şartları sağladığını onaylarım.

İmza

Prof. Dr. Oğuzhan ERDEM
Tez Danışmanı …….

Doç. Dr. Sezer ULUKAYA
İkinci Tez Danışmanı ……

Trakya Üniversitesi Fen Bilimleri Enstitüsü onayı

Doç. Dr. Filiz UMAROĞULLARI

Fen Bilimleri Enstitüsü Müdürü

T.Ü.FEN BİLİMLERİ ENSTİTÜSÜ

HESAPLAMALI BİLİMLER ANABİLİM DALI DOKTORA PROGRAMI

DOĞRULUK BEYANI

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

08 / 01 /2025

İlke KURT

Doktora Tezi

Yapay Zekâ Algoritmaları İle Göz Hareket Verilerinden Parkinson Hastalığının Erken Evre Tespiti Ve Derecelendirilmesi

T.Ü. Fen Bilimleri Enstitüsü

Hesaplamalı Bilimler Anabilim Dalı

ÖZET

İnsanoğlu görme duyusuna diğer duyulardan daha çok bağımlıdır. Bu tez çalışması, Parkinson hastalığının (PH) erken teşhisi ve evre derecelendirilmesinde yardımcı olacak bir sistem geliştirmeyi amaçlamaktadır. Göz ve görme ile ilgili problemler hastalığın temel belirtilerinin belirleşmesinden çok daha önce görülmeye başlamaktadır. Ancak bu alanda açık erişimli veri kümesinin olmaması yeni yöntem ve yaklaşım geliştirilebilmesini kısıtlamaktadır. Bu çalışmada, Videonistagmografi (VNG) sistemi kullanılarak PH ve sağlıklı bireylerin sakkadik ve pursuit göz hareketleri üzerindeki sinyalleri incelenmiş, bu veriler makine öğrenimi ve derin öğrenme teknikleriyle analiz edilmiştir. Bu kapsamda hem geleneksel yöntemlerle sinyallere ait spektral, fraktal, istatistiksel ve zamansal öznitelikler çıkarılmış hem de derin öğrenme mimarilerinden elde edilen derin öznitelikler kullanılmıştır. Destek Vektör Makineleri (DVM), Naive Bayes (NB), k-en Yakın Komşu (k-EYK), Kuadratik Diskriminant Analiz (KDA) gibi makine öğrenimi sınıflandırıcılarının göz hareketlerinden hastalığı tespit etme ve evre tayini gibi karmaşık sınıflandırma görevlerindeki başarıları incelenmiştir. Çalışmada yapılan filtreleme ve sarıcı öznitelik seçimi uygulamalarının birlikte kullanıldığı iki aşamalı bir öznitelik seçim yöntemi uygulanmış ve gereksiz özniteliklerin elenmesinin modelin sınıflandırma başarısını yükselttiği belirlenmiştir. Ayrıca, uzun-kısa vadeli bellek, konvolüsyonel sinir ağı ve çeşitli transfer öğrenme mimarileriyle yapılan değerlendirmeler, hastalığın tanısında derin öğrenme tabanlı yaklaşımların da etkinliğini ortaya koymuştur. Sakkadik göz hareketlerinin hastalığın erken evre tespitinde, pursuit

hareketlerin ise hastalığın ilerleyişinin izlenmesinde daha yüksek başarı gösterdiği gözlemlenmiştir. Makine öğrenimi uygulamasında her iki göz hareketinde %91-%95 arası doğruluk elde eden DVM algoritması ön plana çıkarken, derin öğrenme uygulamalarında ise %72,73 ile uzun-kısa vadeli bellek daha başarılı bir performans sergilemiştir. Ayrıca sinyallerin görüntü temsilleri ile yapılan uygulamalarda en yüksek başarı %79,55 doğrulukla GoogLeNet ile elde edilmiştir. Göz hareketlerinin analizine dayalı bu sistem, aynı zamanda nörolojik hastalıkların takibi ve tedavi süreçlerinin izlenmesinde objektif, kolay uygulanabilir ve verimli bir yöntem olarak önemli bir potansiyele sahiptir.

Yıl : 2025

Sayfa Sayısı : 105

Anahtar Kelimeler : Derin öğrenme, Göz hareketleri, Hibrit yaklaşım, Makine öğrenmesi, Parkinson hastalığı

PhD Thesis

Early Detection and Severity Evaluation of Parkinson’s Disease from Eye Movement Data with the Artificial Intelligence Algorithms

Trakya University Institute of Natural Sciences

Computational Science Department

ABSTRACT

Human beings are more dependent on the sense of sight than other senses. This thesis aims to develop a system that will help in the early diagnosis and stage grading of Parkinson's disease (PD). Oculo-visual dysfunctions begin to be seen much earlier than the basic symptoms of the disease. However, the lack of an open access dataset in this field restricts the development of new methods and approaches. In this study, the signals on saccadic and pursuit eye movements of PD and healthy individuals were examined using the Videonystagmography (VNG) system, and these data were analyzed with machine and deep learning techniques. In this context, both spectral, fractal, statistical and temporal features of the signals were extracted with traditional methods and deep features from deep learning architectures were utilized. The performance of machine learning classifiers, such as Support Vector Machines (SVM), Naive Bayes (NB), k-Nearest Neighbors (k-NN), and Quadratic Discriminant Analysis (QDA) in complex classification tasks such as disease detection from eye movements and stage determination has been investigated. A two-stage feature selection method was applied, combining filtering and wrapper-based feature selection techniques, and it was determined that eliminating unnecessary features increased the classification performance of the model. Furthermore, evaluations with Long Short-Term Memory (LSTM), Convolutional Neural Networks (CNN), and various transfer learning architectures demonstrated the effectiveness of deep learning-based approaches in disease diagnosis. It was observed that saccadic eye movements showed higher success in the early-stage

detection of the disease while pursuit movements were more effective in tracking disease progression. While the SVM algorithm come to the forefront in both eye movements in machine learning applications with the 91%-95% accuracy, long-short term memory showed a more successful performance with 72.73% in deep learning applications. Additionally, the hieghest success, with an accuracy rate of 79.55%, was achieved with GoogLeNet in applications with image representations of signals. This system based on eye movement analysis also has significant potential as an objective, easy-to-apply and efficient method in monitoring neurological diseases and treatment processes.

Year : 2025

Number of Pages : 105

Keywords : Deep learning, Eye movements, Hybrid approach, Machine learning, Parkinson’s disease

ÖNSÖZ

Bu çalışma, Trakya Üniversitesi Fen Bilimleri Enstitüsü Hesaplamalı Bilimler Anabilim Dalı'nda yapılan "Yapay Zekâ Algoritmaları İle Göz Hareket Verilerinden Parkinson Hastalığının Erken Evre Tespiti Ve Derecelendirilmesi " isimli doktora tez çalışmasını içermektedir.

Lisansüstü eğitimim boyunca her türlü desteği benden esirgemeyen, her zaman rehberlik eden değerli danışman hocam Sayın Prof. Dr. Oğuzhan ERDEM' e ve ikinci danışman hocam Sayın Doç. Dr. Sezer ULUKAYA' ya sonsuz teşekkürlerimi sunarım.

Çalışmanın gerçekleşebilmesi için gerekli verilerin toplanmasında yardım ve desteklerini esirgemeyen Trakya Üniversitesi Hastanesi Nöroloji, Kulak Burun ve Boğaz polikliniğinde görevli uzman ve asistan hekimlere, Odyoloji biriminde görevli tüm personel ve ekibe, ayrıca çalışmadaki işbirlikleri için Prof. Dr. Sibel GÜLER, Prof. Dr. Cem UZUN ve Doç. Dr. Erdoğan BULUT hocalarıma teşekkür ederim.

Videonistagmografi cihazından okülomotor hareketlere ait verilerin veri tabanından alınabilmesi için araştırma modülüne lisans erişim desteği sağlayan ERİŞÇİ Elektronik A.Ş.'ye destekleri için teşekkürlerimi sunarım.

Yürüdüğüm zorlu yolumda beni her daim destekleyen, benden çok yorulan, yıpranan ve bu süreçte sonsuz özveride bulunan canım aileme minnet ve teşekkürlerimi sunarım.

Birlikte çalıştığım proje ekip arkadaşlarıma, iş arkadaşlarıma teşekkür ve sevgilerimi sunarım.

Bu doktora tez çalışması Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) Yurt İçi Öncelikli Alanlar Doktora Burs Programı (2211-C) tarafından desteklenmiş, ayrıca Trakya Üniversitesi Bilimsel Araştırma Projeleri (TÜBAP) 2021/90 sayılı bilimsel projesi kapsamında gerçekleştirilmiştir.

İÇİNDEKİLER

ÖZET iv
ABSTRACT vi
ÖNSÖZ viii
İÇİNDEKİLER ix
ŞEKİLLER DİZİNİ xii
ÇİZELGELER DİZİNİ xiv
SİMGELER VE KISALTMALAR xvi
BÖLÜM 1: GİRİŞ 1
BÖLÜM 2: PARKİNSON HASTALIĞI HAKKINDA GENEL BİLGİLER 5
2.1. Hastalığın Tanımı 5
2.1.1. Hastalığın Belirtileri 6
2.1.1.1. Titreme 6
2.1.1.2. Katılık 7
2.1.1.3. Hareketlerde Yavaşlık 7
2.1.1.4. Duruş ve Yürüyüş Bozuklukları 7
2.1.1.5. Diğer Belirtiler 8
2.2. Hoehn ve Yahr Skalasına Göre Evre Değerlendirmesi 9
2.3. Parkinson Hastalığı ve Görme ilişkisi. 10
2.4. Okülomotor Göz Testleri ve Parkinson Hastalığı 11
2.4.1. Sakkadik Göz Hareketleri 12
2.4.2. Pursuit Göz Hareketleri 13
2.4.3. Optokinetik Nistagmus 14
2.4.4. Nistagmus 15
2.5. Parkinson Hastalığının Göz Hareketlerine Yönelik Yapılan Çalışmalar 15
BÖLÜM 3: MALZEME ve YÖNTEM 18
3.1. Çalışmanın Genel Yapısı 18
3.2. Verilerin Elde Edilmesi ve Veri Kümesinin Tanımı 19
3.3. Verilerin Hazırlanması 21
3.3.1. Sakkadik Göz Verileri 21

3.3.2. Pursuit Göz Verileri 22
3.4. Zaman Serilerinin Görüntüye Dönüştürülmesi 23
3.4.1.Yineleme Grafiği (Recurrence Plot) 24
3.4.2. Gramian Açısal Alan (Gramian Angular Field) 25
3.4.3. Markov Geçiş Alanı (Markov Transition Field) 26
BÖLÜM 4: MAKİNE ÖĞRENİMİ YÖNTEMLERİ KULLANILARAK VNG VERİLERİ İLE PH VE EVRE TESPİTİ 28
4.1. Makine Öğrenimi Uygulamaları 22
4.2. Öznitelik Çıkarımı 29
4.3. Normalizasyon Yöntemleri 31
4.4. Öznitelik Seçim Yöntemleri 32
4.4.1 Spearman Korelasyonu 33
4.4.2 Özyinelemeli Öznitelik Eliminasyonu (Recursive Feature Elimination) 34
4.5. Sınıflandırma Yöntemleri 34
4.5.1. Destek Vektör Makinalari (DVM) 35
4.5.2. Kuadratik Diskriminanat Analiz Algoritması 35
4.5.3. Naive Bayes Algoritması 35
4.5.4. k-En Yakın Komşu (k-EYK) Algoritması 36
4.6. Çapraz Doğrulama Yöntemleri 36
4.7. Model Performansının Değerlendirilmesi 37
4.7.1. Doğruluk 38
4.7.2. Hassasiyet 38
4.7.3. Kesinlik 39
4.7.4. Özgüllük 39
4.7.5. F-ölçütü 39
4.7.6. Matthews Korelasyon Katsayısı (MKK) 39
BÖLÜM 5: DERİN ÖĞRENİME YÖNTEMLERİ KULLANILARAK VNG VERİLERİ İLE PH VE EVRE TESPİTİ 40
5.1. Derin Öğrenme 40
5.1.1. Konvolüsyonel (Evrişimli) Sinir Ağları 41
5.1.1.1. Evrişim katmanı 42
5.1.1.2. Havuzlama Katmanı 42
5.1.1.3. Tam Bağlı Katman 43

5.2. Transfer Öğrenme 43
5.2.1. Residüel Sinir Ağları Mimarisi 44
5.2.2. VGG 45
5.2.3. GoogLeNet Mimarisi 45
5.2.4. Sinir Mimarisi Araması Ağı 46
5.3. Uzun-Kısa Vadeli Bellek 47
BÖLÜM 6: DENEYSEL SONUÇLAR 49
6.1. Makine Öğrenimi Uygulamaları 49
6.1.1 İki Aşamalı Öznitelik Seçim Yöntemi Uygulamasını Etkisi 53
6.2. Derin Öğrenme Yöntemlerinin Uygulamaları 59
6.2.1. Veri Arttırma 60
6.3. Hibrit Yöntem Uygulamaları 68
BÖLÜM 7: SONUÇ ve TARTIŞMA 75
KAYNAKÇA 78
EKLER 85
ÖZGEÇMİŞ 89

ŞEKİLLER DİZİNİ

Şekil 2.1. Sağlıklı ve PH bireylere ait dopamin seviye farklılığı 6
Şekil 2.2. Parkinson Hastalığı genel belirtileri 7
Şekil 2.3. Hastalık evre aşamaları 10
Şekil 3.1. Sistemin genel işlem basamakları 18
Şekil 3.2. Testler için katılımcıların uygun pozisyonda yerleştirilmesi..... 20
Şekil 3.3. Sakkadik göz hareketi testi sırasında VNG sistemi ile (i) HC (sağlıklı kontrol) (ii) PH katılımcılar tarafından üretilen sinyaller. 22
Şekil 3.4. Pursuit göz hareketi testi sırasında VNG sistemi ile (i) HC (sağlıklı kontrol) (ii) PH katılımcılar tarafından üretilen sinyaller….. 23
Şekil 3.5. Kontrol (sol) ve PH (sağ) katılımcılara ait örnek Yineleme Grafiği dönüşüm görselleri..... 25
Şekil 3.6. Kontrol (sol) ve PH (sağ) katılımcılara ait örnek Gramian Açısal Toplam Alan dönüşüm görselleri 26
Şekil 3.7. Kontrol (sol) ve PH (sağ) katılımcılara ait örnek Markov Geçiş Alan dönüşüm görselleri 27
Şekil 4.1. Makine öğrenimi uygulamaları işlem basamakları 29
Şekil 4.2. Bir- bireyi- dışarda- bırakma (BBDB) çapraz geçerleme uygulaması 37
Şekil 4.3. Sınıflandırıcı tahminine göre karmaşıklık matrisi 38
Şekil 5.1. Derin öğrenme uygulamaları işlem basamakları 40
Şekil. 5.2. Yapay zeka ve alt bileşenleri 41
Şekil 5.3. Temel Konvolüsyon Sinir Ağı..... 42
Şekil 5.4. ResNet18 mimarisi..... 44
Şekil 5.5. VGG16 mimarisi 45
Şekil 5.6. GoogLeNet mimari yapısı..... 46
Şekil 5.7. NasNet mimarisi 47
Şekil 6.1. Hasta-sağlıklı ayrımına yönelik derin öğrenme modellerinin sakkadik ve pursuit hareketlere göre doğruluk değerleri 63
Şekil 6.2 Hastalığın evre tayinine yönelik derin öğrenme modellerinin sakkadik ve pursuit hareketlere göre doğruluk değerleri. 64
Şekil 6.3. Hasta-sağlıklı ayrımına yönelik transfer öğrenme mimarilerinin sakkadik ve pursuit hareketlere göre başarım sonuçları 65

Şekil 6.4. Hastalık evre tayininde transfer öğrenme mimarilerine ait sakkadik ve pursuit hareketlere göre model doğruluk değerleri 67
Şekil 6.5. Hibrit yöntem uygulamaları işlem basamakları 68

ÇİZELGELER DİZİNİ

Çizelge 3.1. Hasta ve sağlıklı katılımcıların demografik bilgileri 20
Çizelge 3.2. Hasta bireylerin evrelere göre demografik bilgileri 21
Çizelge 4.1. Sakkadik göz hareketlerine ait zaman serilerinden elde edilen öznitelikler 30
Çizelge 6.1. Makine öğrenmesi sınıflandırıcıların hasta-sağlıklı ayrımı sonuçları 50
Çizelge 6.2. Makine öğrenmesi sınıflandırıcılarının hastalık evre tayini sonuçları 52
Çizelge 6.3. Hasta-sağlıklı ayrımında sakkadik göz hareketlerine göre iki aşamalı öznitelik seçim yöntemi sonrası tayin edilen ilk 20 öznitelik 54
Çizelge 6.4. Sakkadik göz hareketleri ve makine öğrenmesi sınıflandırıcıların öznitelik seçimi sonrası en belirleyici 20 öznitelik ile elde ettiği hasta-sağlıklı ayrımı sonuçları 55
Çizelge 6.5. Hastalık evre tayininde sakkadik göz hareketlerine göre iki aşamalı öznitelik seçim yöntemi sonrası belirlenen ilk 20 öznitelik 55
Çizelge 6.6. Sakkadik göz hareketleri ve makine öğrenmesi sınıflandırıcıların öznitelik seçimi sonrası en belirleyici 20 öznitelik ile hastalık evre tayini sonuçları 56
Çizelge 6.7. Hasta-sağlıklı ayrımında pursuit göz hareketlerine göre iki aşamalı öznitelik seçim yöntemi sonrası tayin edilen ilk 20 öznitelik 57
Çizelge 6.8. Makine öğrenmesi sınıflandırıcıların pursuit göz hareketleri ile hasta-sağlıklı ayrımı sonuçları 57
Çizelge 6.9. Pursuit göz hareketleri ile hastalık evre tayininde iki aşamalı öznitelik seçim yöntemi ile belirlenen ilk 20 öznitelik 58
Çizelge 6.10. Makine öğrenmesi sınıflandırıcılarının pursuit göz hareketleri hastalık evre tayini sonuçları 59
Çizelge 6.11. Zaman serilerini görüntüye dönüştürme yöntemleri 60
Çizelge 6.12. Hasta- sağlıklı ayrımı için geliştirilmiş CNN mimarisinde kullanılan parametreler..... 61
Çizelge 6.13. Hasta-sağlıklı ayrımına yönelik derin öğrenme uygulamaları sonuçları .. 63
Çizelge 6.14. Hastalık evre tayinine yönelik derin öğrenme uygulamaları sonuçları 64
Çizelge 6.15. Hasta-sağlıklı ayrımına yönelik transfer öğrenme uygulamaları sonuçları. 66
Çizelge 6.16. Hastalık evre tayinine yönelik transfer öğrenme uygulamaları sonuçları... 67
Çizelge 6.17. Derin özniteliklerin elde edildiği katman isimleri ve öznitelik sayıları.... 69
Çizelge 6.18. Hibrit yöntemin sakkadik göz hareketlerine göre hasta-sağlıklı ayrımı sonuçları 70

Çizelge 6.18. Hibrit yöntemin sakkadik göz hareketlerine göre evre tayini sonuçları ... 71
Çizelge 6.19. Hibrit yaklaşımın pursuit göz hareketleriyle hasta-sağlıklı ayrımı sonuçları 72
Çizelge 6.20. Hibrit yaklaşımın pursuit göz hareketleri ile evre tayini sonuçları..... 73

SİMGELER ve KISALTMALAR

Simgeler	**Açıklamalar**
C	: Maliyet parametresi
g	: Çekirdek genişliği
Kısaltmalar	**Açıklamalar**
AH	: Alzheimer Hastalığı
BBDB	: Bir-bireyi-dışarda-bırak (BBDB)
DaTscan	: Dopamin taşıyıcı taraması
DVM	: Destek Vektör Makinaları (Support Vector Machines)
EOG	: Elektro-okülografi
GN	: Gerçek negatif
GP	: Gerçek pozitif
H&Y	: Hoehn ve Yahr
INL	: İç çekirdek tabakası
KDA	: Kuadratik diskriminant analiz
k-EYK	: k-En Yakın Komşu (k-Nearest Neighbor)
LibSVM	: Destek vektör makinaları için kütüphane (Library for Support Vector Machines)
MKK	: Matthews korelasyon katsayısı
MRG	: Manyetik Rezonans Görüntüleme
MS	: Multiple Skleroz
NB	: Naive Bayes
PH	: Parkinson Hastalığı
SA	: Serebellar ataksi
SPECT	: Tek foton emisyonlu bilgisayarlı tomografi
YN	: Yanlış negatif
YP	: Yanlış pozitif
VNG	: Videonistagmografi
VOG	: Video-okülografi

BÖLÜM 1

GİRİŞ

Göz hareketleri, beyindeki motor ve nörolojik işlevlerin doğrudan bir yansımasıdır. Bu hareketlerin analizi nörolojik kökenli pek çok hastalığın erken teşhiş ve uygulanacak tedavide oldukça büyük bir öneme sahiptir. Çünkü göz hareketlerinin nörolojik hastalıklarla ilişkisi, beynin motor kontrol ve bilişsel işlevlerinin bir göstergesidir (Memetoğlu, 2022). Görme beynin çeşitli bölgelerinin ve nöral yapılarının (optik sinir, oküler motor kraniyal (kafa) sinirler, merkezi sinir sistemi ile bağlantılı gri cevher yapıları) birlikte uyum ve düzen içerisinde çalışması sonucu ortaya çıkan bir durumdur (TND, 2011). Özellikle Parkinson hastalığı (PH), Alzheimer hastalığı (AH), Multiple skleroz (MS), serebellar ataksi (SA) gibi bu düzeni çeşitli nedenlerle bozacak hastalıklarda göz hareketlerinde hastalıkla ilişkilendirilebilecek belirgin farklılıklar rastlanmaktadır (Leigh ve Zee, 2015).

Alzheimer hastalığı gibi demans (unutkanlık) türü nörolojik hastalıklarda göz hareketlerindeki bozukluklar bilişsel bozulmalarla paralel olarak gelişir (Klein vd., 2019; Leigh ve Zee, 2015). Alzheimer hastalarında görsel izleme ve dikkatle ilgili göz hareketlerinin bozulması, hastalığın ilerleyişiyle birlikte daha belirgin hale gelir (Hutton, 2008). Ayrıca AH'de göz bebeklerinin tepki süresi de uzar ve ışık değişimlerine karşı refleks yanıtları zayıflar (Crawford vd.,2005).

Serebellar ataksi, beyincik fonksiyonlarında bozulmalara yol açarak göz hareketlerinde denge kaybına neden olabilen bir nörolojik hastalıktır. Serebellum, göz hareketlerinin hassasiyetini ve koordinasyonunu sağladığından bu tür hastalıklar gözlerin uyumlu hareket etmemesine yol açar (Karaaslan vd., 2024; Leigh ve Zee, 2015). Bu hastalıkta özellikle nistagmus gibi belirtiler sıklıkla görülür.

Multiple Skleroz sinir hücrelerinin gövdesindeki miyelin kılıfın iltihaplanması sonucu oluşan bir hastalıktır (Öztürk vd. 20217). Hastalarında gözle ilgili belirtiler genellikle ataklar halinde ortaya çıkar ve çift görme, bulanık görme ve göz sinir iltihabı (optik nevrit) gibi belirtiler yer almaktadır. Ayrıca MS'de sabitlenme (fiksasyon) kararlılığı, yüksek göz kayması hata oranları ve bozulmuş takip gibi okülomotor işlev bozuklukları genellikle beyin sapı veya göz alanlarındaki lezyonlara bağlı olarak tanımlanmıştır (Corfield ve Langdon, 2018).

Parkinson hastalığı (PH), beyindeki dopamin üreten nöronların çeşitli etkenlerden kaynaklı tahribatı sonucu işlev bozukluğu ile tanımlanır ve bir dizi motor ve motor olmayan belirtilerin ortaya çıkmasına neden olur (Bloem vd.,2021). Hastalık tanısında invaziv (girişimsel) kan testlerinin yanı sıra manyetik rezonans görüntüleme (MRG), Dopamin taşıyıcı taraması (DaTscan), tek foton emisyonlu bilgisayarlı tomografi (SPECT) Dopamin taşıyıcı taraması (DaTscan) gibi nörogörüntüleme teknikleri ve genetik analiz yöntemlerinden yararlanılır (Bidesi vd., 2021; Politis, 2014). Bu yöntemler raporlama süreçleri zaman alıcı olabilen ve daha fazla uzmanlık gerektiren uygulamalardır. Ancak, klinik değerlendirmelere ek olarak, karar destek sistemleri gibi dijitalleştirilmiş sağlık teknolojileri tarafsız ve nicel bir değerlendirme sağlamanın yanı sıra profesyoneller arasındaki değerlendirmeleri de standartlaştırır (Kurt vd., 2019). Böylece bu sistemler sonuçların doğruluğunu ve tekrarlanabilirliğini iyileştirmeye de yardımcı olur.

PH, temel olarak hareket mekanizmasını etkileyen nörodejeneratif bir bozukluk olmasına rağmen, belirtilerin baskınlığı ve şiddeti hastadan hastaya değişir. Bu belirtiler, birçok araştırmacının hastalığı teşhis etmek için yardımcı karar destek sistemleri geliştirme konusunda ilgisini çekmektedir (Adams, 2017; Isenkul vd., 2014; Şakar vd. 2013; Tsanas vd., 2010).

PH'de göz hareketlerinin klinik değerlendirmeleri, öncelikle yarı-niceleyici puanlama sistemleri veya nitel gözlemler kullanan geleneksel yöntemleri takip eder (Armstrong, 2020). PH hastalarında pupil tepkisi, hareket algısı, görme keskinliği, sakkadik, pursuit, bakış gibi çeşitli göz hareketleri ve hatta görsel halüsinasyonlar dâhil olmak üzere çeşitli okülo-görsel işlev bozuklukları görülebilir (Armstong, 2015; Armstrong, 2017). PH'nin erken teşhisi, harekete mekanizmasına bağlı belirtiler klinik

olarak ortaya çıkmadan önce bile okülomotor göz hareketlerindeki anormallikleri ölçerek mümkün olabilir çünkü retinanın iç çekirdek tabakasında (INL) bulunan amakrin hücreleri çevreden algılanan bilgileri merkezi sinir sistemine iletirken dopamine ihtiyaç duyar (Armstrong, 2017).

Göz hareketleri, video-okülografi (VOG), elektro-okülografi (EOG) ve arama bobini manyetometresi (Sekar vd.,2024) dâhil olmak üzere çeşitli yöntemlerle göz izleme görevleri sırasında kaydedilebilir. Öte yandan, videonistagmografi (VNG), vestibüler ve okülomotor sistemlerini değerlendirmek için kullanılan invaziv olmayan bir tanı tekniğidir (Falls, 2019). Özel kameralar kullanarak göz hareketlerini kaydederek analiz eder ve sakkadik hız, gecikme ve doğruluk gibi okülomotor işlevler hakkında değerli bilgiler sunar (Lucero vd., 2017).

Literatürde VNG'nin PH'de kullanımıyla ilgili daha önce yayınlanmış çalışmalar sınırlıdır. Bu çalışmalar genellikle Parkinson hastalarının okülomotor hareketlerinin analizini incelemiş, hastalık tanısında veya karar destek sistemlerinde VNG kullanımını incelememiştir (Yu vd., 2024). Ayrıca göz hareketlerindeki değişimlerin hastalığın belirlenmesinde veya derecelendirilmesinde incelenmesi için açık erişimli herhangi bir veri kümesi mevcut değildir. Bu tez çalışması ile hem konulacak tanının güvenilirliğinin arttırılması hem de bu konu ile ilgili bir veri kümesinin oluşturulması amaçlanmıştır.

Bu tez çalışması nörolojik hastalıkların erken tespiti için olası invaziv olmayan bir tanı sistemi olarak karar destek sistemlerinde VNG'nin kullanılabilirliği, hastalığın göz hareketlerinden saptanabilmesi ve hastalık evre derecelendirmesi üzerine Parkinson hastalığı özelinde çalışılmıştır. Bu bağlamda, VNG ile toplanan göz hareketleri üç farklı perspektifte incelendi. İlk olarak geleneksel makine öğrenimi yöntemleri izlenerek toplanan göz sinyallerinden öznitelikler çıkartıldı. Elde edilen öznitelik kümelerinde çeşitli komşu ve mesafe parametreleriyle Destek Vektör Makineleri (DVM), Naive Bayes (NB), k-en Yakın Komşu (k-EYK), Kuadratik Diskriminant Analiz (KDA) sınıflandırıcıları test edildi. Veri kümelerinde öznitelik sayısının fazla olması kimi zaman modellerin problemle ilgili bağlantıları öğrenmesinde zorluk yaratabilmektedir. Bu durum sınıflandırma başarısını olumsuz yönde etkileyen bir faktördür. Bu nedenle modellerin problemle ilgili bilgi kazancı bakımından değerli olan öznitelikleri belirlemesi amacıyla iki aşamalı öznitelik seçimi algoritmaları kullanılmış ve bu özniteliklerin

sınıflandırma başarıları karşılaştırılmıştır. Tarafsız bir tahmin elde etmek için Bir-Bireyi-Dışarda-Bırak (BBDB) çapraz doğrulama yöntemini kullanıldı. Ek olarak, doğruluk, hassasiyet, Matthew's korelasyon katsayısı (MKK) ve F-skor metrikleri kullanılarak model performansı değerlendirildi. Diğer bir yaklaşımda ise hastaların göz hareketlerini otomatik olarak analiz edip, anlamlı özelliklerin çıkarılmasını otomatik sağlamak amacıyla derin ve transfer öğrenme yöntemleri kullanılmıştır. Zaman serilerinden elde edilen sinyaller farklı görüntü dönüşüm yöntemleri ile konvolüsyonel sinir ağı mimarilerine verilmiş, modellerin hastalığı tespit etme ve evrelerine göre ayırma başarımı araştırılmıştır. En son yaklaşımda ise, derin öğrenme mimarilerinden otomatik olarak elde edilen derin özniteliklerin geleneksel makine öğrenimi yöntemleriyle incelendiği hibrit bir yaklaşımın incelenmiştir.

Bu tez çalışmasında yer alan Bölüm 2'de, Parkinson hastalığı, okülomotor göz hareketleri, vestibüler değerlendirme ve bunların birbirleri ile olan ilişkileri hakkında genel bilgileri kapsarken, Bölüm 3'te tez çalışmasında izlenen yol haritasını, veri toplama ve hazırlık süreci hakkında bilgi sunulmaktadır. Bölüm 4 ve Bölüm 5 sırasıyla makine öğrenimi, öznitelik çıkarımında kullanılan yöntemleri, derin öğrenme ve transfer öğrenme mimarileri ile ilgili bilgileri içermektedir. Yapılan deneyler ve elde edilen sonuçlara Bölüm 6'da yer verilirken, sonuçların değerlendirilmesi ve ileri çalışmalar Bölüm 7'de anlatılmıştır.

BÖLÜM 2

PARKİNSON HASTALIĞI HAKKINDA GENEL BİLGİLER

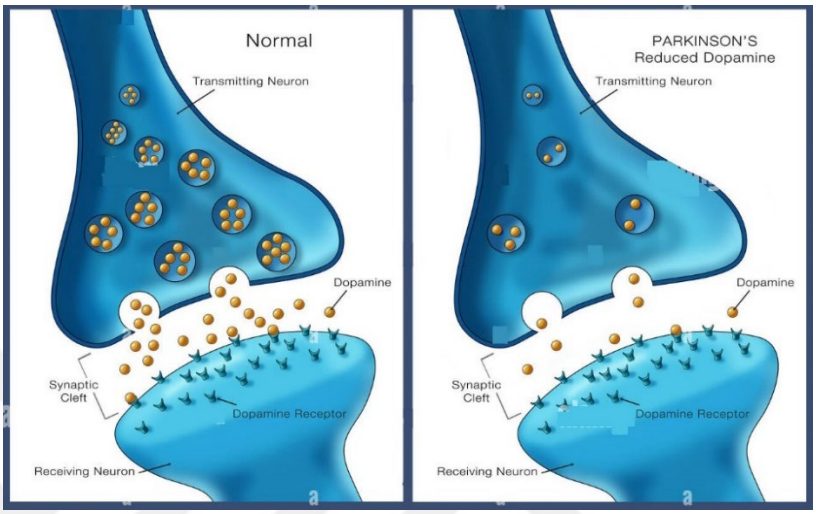
Bu bölümde, öncelikle Parkinson hastalığının tanımı, belirtileri, hastalığın evre derecelendirmesinde başvurulan değerlendirme ölçütleri hakkında bilgi verilmesinin yanı sıra hatalık ve göz/görme ilişkisi, sakkadik, pursuit, optokinetik, bakış, nistagmus gibi okülomotor göz testleri ile vestibüler sistemin ilişkisi ele alınacaktır. Ayrıca, videonistagmografi gibi tanı yöntemlerinin Parkinson hastalığındaki rolü incelenecektir.

2.1. Hastalığın Tanımı

Parkinson hastalığı, merkezi sinir sistemini etkileyen ve genellikle harekete bağlı belirtilerle kendini gösteren bir nörolojik hastalıktır. PH, hareketlerin kontrol mekanizmasından sorumlu dopamin adlı kimyasalın beyindeki belirli dopamin üretim merkezlerinde azalmaya başlamasıyla ortaya çıkan bir hastalıktır (TPHD, 2017). Dopamin, beyin hücreleri arasında sinyallerin iletilmesini sağlar ve motor hareketleri düzgün ve koordineli bir şekilde yapılmasına yardımcı olur. PH, zamanla ilerleyici bir seyir izler ve hastanın yaşam kalitesini önemli ölçüde düşürür (Özekmekçi vd.,2013).

Parkinson hastalığında dopamin seviyesi düştüğü için kişide hareketlerde yavaşlama, kas sertliği (rijidite), titreme ve denge sorunları görülür. Parkinson hastalığı, ilerleyici bir nörodejeneratif hastalık olup zaman içinde harekete bağlı olan ve harekete bağlı olmayan belirtilerle birlikte karmaşık bir klinik tabloya yol açar (Cakmur, 2011). Çoğunlukla 60 yaş ve sonrasında görülse de, genç yaşta başlayan vakalar da mevcuttur. Hastalığın kesin oluşma nedeni tam olarak bilinmemektedir. Fakat, kalıtımsal yatkınlık, çevresel faktörler ve yaşlanma gibi birden fazla unsurun bu hastalığın oluşmasında etkili olduğu düşünülmektedir (Akbayır vd., 2017). Ailesel Parkinson hastalığı nadiren görülür ve genetik mutasyonlar bu hastalığın erken yaşlarda ortaya çıkmasına neden olabilir.

Çevresel faktörler, özellikle pestisitlere maruz kalma gibi etmenler de hastalığın gelişiminde rol oynayabilir. Ayrıca, doğal yaşlanma sürecine bağlı olarak beyin hücrelerinin yaşlanması PH ortaya çıkma riskini artırabilir (Akbayır vd., 2017; Aygün vd.,2009).



Şekil 2.1. Sağlıklı ve PH bireylere ait dopamin seviye farklılığı (Fong vd., 2019)

2.1.1. Hastalığın Belirtileri

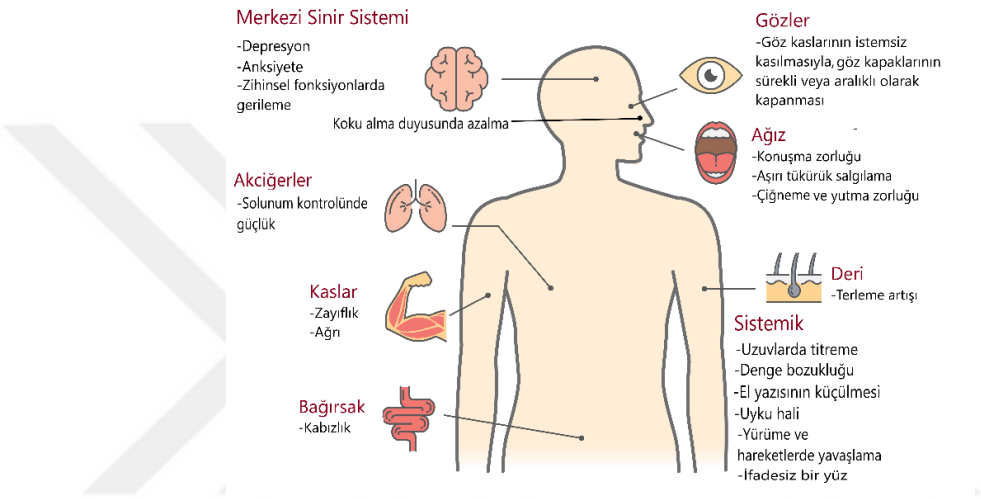
Parkinson hastalığı belirtileri, belirtilerin şiddeti, görülme biçimleri ve ilerleyişi hastadan hastaya değişkenlik gösterebilmektedir. Bu durum hasta bireylerin yaşam kalitelerini doğrudan etkileyen önemli bir unsurdur. Bu belirtilerden yola çıkılarak hastalığın semptomatik tedavisinde uygulanacak yöntemlere karar verilmektedir. Dolayısıyla gerek hastalık tanısı konulurken gerekse tedavi sürecinde belirtilerde meydana gelen değişiklikler hassasiyetle takip edilmelidir.

2.1.1.1. Titreme

Titreme, PH'de görülen en belirgin belirtilerinden biridir ve genellikle ellerde, parmaklarda, çenede ve dudaklarda görülür. Bu istemsiz hareketler, hastalar dinlenme halindeyken daha belirgin hale gelir. Uykuda titreme dururken, hasta uyandığında bu belirti geri döner. Titreme, günlük yaşam aktivitelerini zorlaştırabilir ve kişilerin sosyal etkileşimlerini olumsuz etkileyebilir.

2.1.1.2. Katılık

Parkinson hastalarında iskelet kaslarının istemsiz olarak kasılması sonucunda kaslarda sertleşme meydana gelir. Bu durum, hastaların hareket etmelerini zorlaştırabilir ve katılaşan bölgelerde ağrı hissedilebilir. Katılık, genellikle hastalığın ilerlemesiyle birlikte artar ve günlük aktiviteleri daha da zorlaştırır (Özekmekçi vd., 2013).



Şekil 2.2. Parkinson Hastalığı genel belirtileri (Nobelyum, 2025)

2.1.1.3. Hareketlerde Yavaşlık

Günlük aktivitelerin gerçekleştirilirken yavaşlama söz konusudur. Hasta tarafından hareketi planlarken, başlatırken ve sürdürürken gecikmeler yaşanır. Bu belirtiler genellikle vücudun bir tarafında başlar ve zamanla diğer tarafa yayılabilir.

2.1.1.4. Duruş ve Yürüyüş Bozuklukları

Hastalar, oturdukları yerden kalkarken veya yürümeye başlarken zorluk yaşayabilirler. Genellikle öne doğru eğik bir duruş sergilerler ve küçük adımlarla yürürler. Yürürken denge kaybı yaşanabilir ve bu durum düşmelere yol açabilir. Ayrıca, ayakların yere sürtülmesi gibi belirtilere de sıkça karşılaşılmaktadır (Özekmekçi vd., 2013; TPHD, 2017).

2.1.1.5. Diğer Belirtiler

Hastalar yazı yazarken harf boyutlarının küçülmesi ve el yazısının giderek daha sıkışık hale gelmesi gibi sorunlar yaşarlar (Demir, vd., 2024). Ayrıca, düğme ilikleme ve açma gibi ince motor becerilerde de zorluklar gözlemlenir. Gece yatakta dönerken de sıkıntılar yaşanabilir, bu durum günlük işlevlerin yerine getirilmesini zorlaştırır.

PH'de maske yüz olarak adlandırılan bir durum da gelişir. Dopamin eksikliği baş ve boyundaki kasların kontrol edilememesi nedeniyle yüz hareketlerinde belirgin bir yavaşlama ve donukluk oluşmasına yol açar. Sonuç olarak, duygusal ifadeler azalır ve hastalar daha az ifadesiz görünürler. Bu durum sosyal etkileşimlerde zorluklara neden olabilir.

Hastalığın başlangıcında motor belirtiler ön planda olsa da zihinsel ve ruhsal bozukluklar da hastalıkla birlikte sıkça görülür. PH bireyler demans (unutkanlık) gibi bilişsel sorunlar yaşayabilirler ve bu durum sosyal yaşamdan soyutlanmalarına yol açabilir. Ayrıca aşırı beslenme, kumar oynama veya tehlikeli eylemlerde bulunma gibi davranışlara eğilim de görülmektedir. Hastalık ilerledikçe hayal görme ve depresyon gibi ruhsal belirtiler belirginleşir (Pekel vd., 2017)**.**

Parkinson hastalarında uyku bozuklukları da yaygındır (Özekmekçi vd., 2013). Uyku sırasında rüyaların etkisiyle hareketlenme, bacakların veya kolların sallanması gibi durumlar meydana gelebilir. Bu tür hareketler bazen agresif davranışlara yol açabilir (Aygün vd., 2009). Ayrıca, gün içinde kontrolsüz uyuklama hali veya geceleri uyumama gibi sorunlar da sıkça görülmektedir.

Hastalığın ilerleyen safhalarında ses zayıflar; konuşmaların anlaşılması güçleşir ve ses tonu monotonlaşır. Bu durum, PH bireylerin %90'ında görülen yaygın bir belirtidir. Konuşma sırasında ritim kaybı, peltekleşme, kelime telaffuzlarında ve anlaşılabilirlikte zorluk, yutkunma zorluğuna bağlı ağızda akıntı gibi belirtilerle konuşma bozuklukları gözlenmektedir. Bu durum hasta bireylerin kendilerini ifade etmelerinde ve çevre ile iletişim kurmalarını zorlaştırmaktadır (Hancı vd.2024; Kurt vd., 2018).

Ayrıca, dopamin eksikliği sadece hareket sistemini değil, koku yolları ve diğer biyolojik sistemleri de etkileyebilir (Özekmekçi vd., 2013). Düzensiz bağırsak

hareketleri, kabızlık, idrar kaçırma gibi sindirim, boşaltım ve sinir sistemi etkileşimi sonucu oluşan belirtiler de hastalarda sıkça gözlemlenir (Aygün vd., 2009).

2.2. Hoehn ve Yahr Skalasına Göre Evre Değerlendirmesi

Hoehn ve Yahr (H&Y) ölçütü, Parkinson hastalığının ilerleme aşamalarını tanımlamak için yaygın olarak kullanılan bir sistemdir ve Melvin Yahr ile Margaret Hoehn tarafından oluşturulmuştur. **0** ile **5** arasında değişen beş evreden oluşan bu ölçeklendirme sisteminde her evre hastalığın motor belirtilerin artmasıyla ilişkilidir (Hoehn ve Yahr, 1967).

- **0**: Parkinson bulgusu yok.
- **1**: Semptomlar tek bir vücut tarafında görülür ve genellikle hafif olup günlük aktiviteleri etkilemez.
- **1,5**: Belirtiler tek taraflı görülmeye devam eder ve hareket bozuklukları merkezi eksen etrafında belirmeye başlar.
- **2**: Semptomlar her iki vücut tarafında da görülmeye başlar, ancak denge sorunları henüz belirgin değildir
- **2,5**: Çekme testi sonucunda hafif şiddette çift taraflı PH belirtisi var.
- **3**: İki yönlü hastalık belirtileri ile denge sorunları görülmeye, düşme riski oluşmaya başlar
- **4**: Çift taraflı görülen hastalık belirtileri ilerlemiştir ve hareket yeteneği oldukça kısıtlıdır. Bu evrede hastanın günlük yaşam aktiviteleri büyük ölçüde sınırlanır.
- **5**: Hastalığın en ileri evresidir. Çift taraflı görülen hastalık belirtileri mevcut ve hasta büyük ölçüde hareket edemez. Hasta tekerlekli sandalye kullanmak zorunda veya yataktan kalkamayacak durumda olabilir.

Ölçeğin basit ve kolay kullanılabilir olması en önemli avantajıdır. Şekil 2.3'te verilen görsel hastalığın evre ilerleyişine göre hastalara olan etkisini göstermektedir.



Şekil 2.3. Hastalık evre aşamaları (Sürmeli, 2024)

2.3. Parkinson Hastalığı ve Görme ilişkisi

Görme işlemi, ışığın göze girmesiyle başlayıp beynin görme merkezine ulaşan karmaşık bir sinir ağının çıktısıdır. Göz hareketleri beynin göz kaslarını koordine eden bir dizi mekanizma aracılığıyla gerçekleştirilir. Bu mekanizma merkezi sinir sisteminin görsellerin algılandığı sırada göz hareketlerini kontrol etmesiyle ilişkilidir (TND,2011). Retina tabakası ışığı biyopotansiyellere (elektriksel sinyallere) dönüştürerek iletiyi optik sinirler aracılıyla beyindeki görme merkezine iletir. Fovea gözün keskin görmeyi sağladığı küçük bir bölgedir. Göz hareketleri görüntülerin foveada odaklanmasını sağlayarak net bir görüş elde edilmesine olanak tanır. Bu nedenle, gözlerin doğru şekilde odaklanması ve sabitlenmesi önemlidir (Pehlivan, 2015).

Göz hareketleri sakkadik, pursuit, optokinetik ve nistagmus olmak üzere çeşitli türlere ayrılır (Przybyszewski vd., 2023). Bu hareketler istemli hareketler olabildiği gibi genellikle refleksif ve istem dışı gerçekleşir. Bu süreçte retina üzerindeki fotoreseptör hücreleri (koniler ve çubuklar) ışığı algılar ve bu bilgiyi elektriksel sinyallere dönüştürerek beyne iletilmesini sağlar (Pehlivan, 2016).

PH'da göz hareketleri beyinde bulunan dopamin üretim mekanizmalarının işlevini yerine getirememesi sonucu dopamin üretiminin azalması nedeniyle bozulur (Harnois ve Di Paulo, 1990). Bu durumda göz hareketlerini koordine eden sistemlerin özellikle sakkadik göz hareketleri (hızlı göz hareketleri), pursuit (göz takibi), gaze (göz pozisyonu) hareketleri ve optokinetik hareketlerinin bozulmasına yol açar (Armstrong, 2015; Srivastava vd.,2014).

Dopamin, retinadaki sinir iletimini sağlayan en önemli nörotransmitter maddedir. Sinir liflerindeki kayıplar PH erken tanısında önemlidir. Hastalık ilerledikçe görüş keskinliğinde zayıflık, kontrast duyarlılığında azalma, genellikle renkli görmede bulanıklık gözlenmektedir (Çağlayan ve Tokçaer, 2013). Hastaların yaklaşık %75'inde hızlı (sakkadik) ve yavaş izleme (smooth pursuit) gibi göz hareketlerinde bozukluklar görülmektedir. Yapılan testler sonucunda hem gözlerin verdiği tepki süresi hem de yatay düzlemde maksimum sakkadik göz hareket hızının Parkinsonlu bireylerde daha düşük olduğu gözlenmiştir (Armstrong, 2015). Ayrıca, azalmış göz kırpmaya bağlı olarak gözlerde kuruluk, batma gibi şikâyetler oluşabilmektedir.

Göz titremesi (nistagmus) ise gözlerin istem dışı ritmik hareketidir. Hastanın hareketli bir nesneye bakması sonucu ortaya çıkan anormal bir ritmik harekettir ve her iki gözün de ortak bir noktayı sabitleyebilme yeteneğinin Parkinsonlu hastalarda zayıf olduğu görülmüştür (Armstrong, 2015). 17 PH ve 22 sağlıklı bireyin farklı türlerde izledikleri kısa filmlere vermiş oldukları davranışsal ve duygusal değişimlere pupillerin verdiği tepkilerin pupillometre kullanılarak ölçüldüğü çalışmada (Schwartz vd, 2018), hasta bireylerde ve sağlıklı bireylerde olumsuz duygularda pupillerin genişleme hızlarının ve boyutlarının kontrol grubuna göre farklı oldukları belirlenmiştir. PH titreme, katılık, hareketlerde yavaşlama gibi klinik motor belirtilerinin açığa çıkmasından önce gözdeki belirtiler ile kendisini göstermektedir (Dikkaya vd., 2018). Bu sebeple göz hareket verilerinin objektif ve nesnel olarak değerlendirilmesi PH'nın erken evre tespitinde önemlidir.

2.4. Okülomotor Göz Testleri ve Parkinson Hastalığı

Parkinson hastalarında özellikle hastalığın ileri evrelerinde, denge sorunları ve düşme riski önemli bir sorundur. Parkinson kas sertliği, hareket yavaşlaması ve duruş

bozukluklarına yol açtığı için hastalar yürürken veya hareket ederken denge kaybı yaşayabilirler. Denge problemleri vestibüler sistemin yanı sıra, motor kontrol bozuklukları nedeniyle de meydana gelir.

Vestibüler sistem, dengeyi sağlamak için gerekli olan iç kulakta yer alan önemli bir duyusal sistemdir. Çevresel uyarılardan algılanan duyuya ait sinyallerini öncelikle göz hareketlerini kontrol eden sinir yapılarına ve cevap olarak verilen denge durumunun sağlanabilmesi amacıyla da kas ve hareket sistemine gönderir. PH'de dopamin eksikliğine bağlı vestibüler sistemin işlevinde de bozulmalar olabilir (Guo vd., 2018). Vestibüler sistemin etkilenmesi, hastaların yürüyüşlerinde anormaliklere ve duruş bozukluğu ve denge problemleri neden olur ve düşme riskini artırır.

Denge ve uzamsal yönelim için kritik bir yapı olan vestibüler sistem değerlendirilmesinde okülomotor göz testlerinden yararlanılmaktadır (Berliner vd., 2020). Videonistagmografi (VNG), göz hareketlerini kaydedip analiz ederek denge bozukluklarını değerlendiren bir invaziv olmayan bir testtir. VNG testleri, okülomotor bozuklukları ve vestibüler sistemle ilgili problemleri tespit etmek için kullanılabilir.

Parkinson hastalığında okülomotor göz testleri, hastalığın motor ve non-motor belirtilerinin değerlendirilmesinde oldukça önemli bir role sahiptir. Okülomotor sistem beyin sapı, serebellum ve kortikal yapılarla bağlantılıdır (Berliner vd., 2020; Guo vd., 2018). Hastalığın bu yapılar üzerindeki etkileri nedeniyle göz hareketlerinde yavaşlama veya anormal hareketlere neden olabilmektedir. Bu testler, göz hareketlerinin kontrolünü sağlayan sinir yollarının işlevselliğini inceleyerek, Parkinson hastalığının seyrini ve etkilerini anlamaya yardımcı olur (Lee vd., 2022).

2.4.1. Sakkadik Göz Hareketleri

Sakkadik hareketler, gözün belirli bir noktadan hızla başka noktaya geçiş yaptığı durumlardır (Purves vd., 2001; Temirbekov, 2018). Sakkadik hareketler beyin tarafından milisaniyeler içinde işlenerek görsel alanın anlamlı bir şekilde algılanması açısından oldukça önemli bir yere sahiptir. İki sabit nokta arasındaki mesafe, sakkadik hareketin büyüklüğü ve hızı hakkında bilgi verirken, sabit noktaları takip etme hızı ve doğruluğu da sakkadın frekansı hakkında bilgi sunar (Akkoyun vd., 2023). Sakkadik göz hareketleri

görsel algıyı anlamlı bir şekilde oluşturmanın ve çevremizdeki dünyayı doğru bir şekilde taramanın temel bileşenlerinden biridir. Bu hareketler, görsel dikkat, bilgi işleme ve çevresel uyaranlara tepki verme gibi önemli işlevleri yerine getirir (Sledzianowski vd., 2019).

İnsan gözü sürekli olarak çevremizdeki dünyayı tarar ve bu tarama sırasında gözler çevremizdeki belirli noktalar arasında hızlıca sıçrar. Sakkadik hareketlerin bir gözün sabit bir pozisyondan diğerine geçerken göz küresinin kısa mesafelerle kayması sonucu gerçekleştiği gözlemlenir. Bu hareketlerin beynin görsel dikkatini yönlendirmede, çevredeki uyarıcılara hızlı bir şekilde yanıt vermede ve görsel bilgiyi işlerken önemli bir rolü vardır (Srivastava vd.,2014).

VNG ile sakkadik göz hareket testi sırasında kişi başını oynatmadan sadece gözleri ile belirli yatay ve dikey eksen değerleri arasında oluşan uyarıları takip etmesi istenir. Test sonucunda aşağıda belirtilen parametrelerle kişinin okülomotor sisteminin düzgün çalışıp çalışmadığını değerlendirilir:

- ✓ ***Hız***: Gözlerin bir noktadan diğerine geçiş hızını ölçer.
- ✓ ***Amplitüd****:* Gözün hareket ettiği mesafeyi değerlendirir.
- ✓ ***Doğruluk***: Hedefe doğru odaklanma yeteneği değerlendirilir.
- ✓ ***Frekans****:* Sakkadik hareketlerin hangi sıklıkla gerçekleştiğini belirtir.

2.4.2. Pursuit Göz Hareketleri

Pursuit göz hareketleri hareketli bir nesneyi takip etmek için yapılan yavaş, sürekli ve düzgün göz hareketleridir (Temirbekov, 2018). Gözler nesne hareket etmeye başladığında onu takip edebilmek için odaklanır ve gözler hareket ettikçe bu hedefi görsel odaklamada kalabilmek için göz kasları sürekli olarak küçük ayarlamalar yapar (Purves vd., 2001).

Bu tür göz hareketleri görsel dikkat ve algının bir parçası olarak çevremizdeki değişen dünyaya adapte olabilmemizi sağlar. Pursuit hareketlerinin düzgün çalışması görsel algı ve hareketli hedeflere yönelik dikkatimizin verimli bir şekilde yönetilmesi açısından çok önemlidir.

VNG ile kaydedilen göz hareketlerinin doğru şekilde izlenip izlenmediğini, gözlerin hareketli nesneleri doğru şekilde takip edip etmediği değerlendirilmektedir (Temirbekov, 2018). Bu test, göz kaslarının işlevselliği ve göz hareketlerinin koordinasyonu hakkında önemli bilgiler sağlamaktadır. Test sırasında ekranda belirli hızda hareket eden bir hedefi kişiden sadece göz hareketleri ile takip etmesi istenir. Test sonucunda aşağıda belirtilen parametrelerle kişinin göz kaslarının koordinasyonunu ve gözlerin uyum sağlama yeteneğini değerlendirilir (Dal vd.,2021):

- ✓ ***Hız*:** Gözlerin hareketli hedefi takip etme hızıdır.
- ✓ ***Doğruluk:*** Gözlerin hedefe odaklanma ve izleme doğruluğudur
- ✓ ***Uyum*:** Gözlerin hedefin hareketine ne kadar uyum sağladığıdır.

2.4.3. Optokinetik Nistagmus

Optokinetik göz hareketleri (OKN) gözlerin hareketli bir ortamda, özellikle hızla geçen nesneleri takip etme yeteneğini ifade eder. Bu hareketler, çevremizdeki hareketleri net bir şekilde gözlemlememize ve uyaranlara hızlı bir şekilde adapte olmamıza yardımcı olur (Dal vd.,2021). Optokinetik göz hareketleri hem refleksif hem de istemli olarak ortaya çıkabilen bir göz hareketi türüdür ve görsel dikkatin yönlendirilmesi, görsel stabilitenin korunması gibi önemli rol oynar (Purves vd., 2001).

Optokinetik testler gözlerin hareketli bir nesneye uyum sağlama yeteneğini değerlendirmek için farklı hızlarda ve yönlerde hareket eden hedeflerle yapılır. Optokinetik hareketlerin değerlendirilmesi diğer göz hareket değerlendirme parametrelerini de içeren daha karmaşık bir yaklaşımdır.

- ✓ ***Pursuit hız***: Gözlerin hareketli hedefi takip etme hızıdır.
- ✓ ***Pursuit doğruluk***: Gözlerin hedefe odaklanma ve hedefi takip etme doğruluğudur.
- ✓ ***Sakkadik hareket ve fiksasyon:*** Hedefe odaklanan gözlerin yaptığı küçük düzeltici hareketler (sakkadik hareketler) ve gözlerin hedefi sabitleme süreci de test edilir.
- ✓ ***Hızlı ve yavaş hareketlere uyum:*** Test sırasında farklı hızlarla hareket eden hedefler kullanılarak gözlerin hızla hareket eden nesnelere ne kadar iyi uyum sağladığı değerlendirilir.

2.4.4. Nistagmus

Nistagmus, gözlerin istemsiz ve ritmik bir şekilde hareket ettiği bir durumdur. Bu hareketler göz kaslarının kontrolsüz ve tekrarlayan bir şekilde çalışması sonucu ortaya çıkar (Purves vd., 2001). Nistagmusun meydana gelmesi beynin görsel ve dengeye ilişkin sistemlerinin uyumsuz çalıştığını gösterir. Bu durum görme ve denge problemleri ile sonuçlanmaktadır (Dal vd.,2021).

Nistagmusun yönü, hızı, süresi ve tekrarı ile doğal ve uyarılan durumlardaki tepkisi göz hareketlerinde meydana gelen nistagmusların değerlendirilmesinde izlenilen parametrelerdir (Purves vd., 2001; Temirbekov, 2018). Nistagmusun yönü beyin ve vestibüler sistemdeki bozukluğun yerini belirlemek için önemli bir göstergedir. Nistagmusun hızı göz kaslarının ve beyin yapılarının işlevselliği hakkında bilgi içerir. Testler sırasında ne kadar süreyle devam ettiği ve tekrarlanma sıklığı da patalojik izlerin saptanması ve değerlendirilmesinde önemlidir.

2.5. Parkinson Hastalığının Göz Hareketlerine Yönelik Yapılan Çalışmalar

Parkinson hastalığı, dünya genelinde milyonlarca insanı etkisi altına alan nörodejeneratif bir hastalıktır. Hatalıkla ilişkilendirilen katılık, titreme ve hareket yavaşlığı gibi birincil belirtilerin ötesinde, PH'nin erken belirteçlerinden biri okülomotor kontrolün bozulmasından kaynaklı görme bozukluklarıdır (Armstrong, 2017). Sakkadik göz hareketleri de hastalığın tanısında etkili rol oynayan önemli bir biyobelirteçtir. Çünkü sakkad bozukluğuna bağlı üretilen farklı sinyal kalıpları beyin bölgelerindeki patolojiyi yansıtmaktadır (Anderson ve MacAskill, 2013). Sakkad analizinin PH'yi diğer parkinsonizim benzeri hastalıklardan ayırt etmede doğruluğu artırdığı gösterilmiştir (Termsarasab vd., 2015).

PH'nin okülomotor testlerin analizi ve çeşitli yapay zekâ yöntemleri ile değerlendirilmesine yönelik çalışmalar kısıtlıdır. Waldthaler vd. (2023), göz hareketlerini incelemek için prosakkad (uyaranla aynı yöne bakma) ve antisakkad (uyaranın tersi yöne bakma) görevlerini içeren bir çalışma yürütmüşlerdir. Bu görevler sırasında göz hareketinin, benzer belirtilere sahip ancak farklı patolojik kaynak nörolojik durumları ayırt etmede yararlı bir tanı aracı olduğu göstermişlerdir (Waldthaler vd., 2023).

Göz hareketi deneyi verilerine dayanarak PH ve AH'yi sınıflandırmak ve evrelemek için makine öğrenimi algoritmalarının kullanımını araştıran çalışmalar mevcuttur (Przybyszewski vd., 2023). Przybyszewski vd. (2016) diğer bir çalışmada, yazarlar bir karar ağacı algoritması eğitmek ve hastalığın evresini sınıflandırmak için 10 PD hastasındaki refleksif göz hareketlerinden gelen verileri kullanılmış ve %79'luk bir doğruluk elde edilmiştir (Przybyszewski vd., 2016).

Sledzianowski vd. (2019) yürüttükleri çalışmalarında (Przybyszewsk vd., 2016) kullandığı verilerle antisakkad göz hareketi verilerinde benzer sonuçlar bulundu. Bu çalışmada, 11 PH hastasının göz hareketlerinin antisakkadları kullanılarak C4.5 karar ağacı uygulaması ile elde edilen hastalık derecelendirme skorlarının Birleşik Parkinson Hastalığı Derecelendirme Ölçeğinde (BPHDÖ) ile uyumunu karşılaştırmışlar ve %91 doğruluk elde etmişlerdir (Sledzianowski vd.,2019).

Stuart vd (2019), göz hareketi verilerinden gelen özelliklerin PH hastalarında bilişsel gerilemenin bir öngörücüsü olduğunu göstermek için doğrusal karışık efekt modelleri kullandılar (Stuart vd.,2019). Yürütülen bir diğer çalışmada ise Brien vd. (2023), hata oranı da dahil olmak üzere bir sakkadik ve antisakkadik test deneyinden çeşitli nokta ve işlevsel özellikleri kullanarak, destek vektör makinesi, lojistik regresyon modeli ve rastgele orman algoritmalarıyla 3 alt sınıflandırıcıdan oluşan bir oylama sınıflandırıcısını eğitti. Önerdikleri sınıflandırma modeli, PH ile sağlıklı bireyler arasında ayrım yapmada %82 doğruluk elde etti (Brien vd., 2023).

Waldthaler vd (2023), yazarlar sakkad deneysel verileri üzerinde hiyerarşik bir kümeleme analizi gerçekleştirmişlerdir. 61 PH ve 25 kontrol bireye göz takibi (yatay ve dikey sakkadlar, antisakkadlar) ve nöropsikolojik testler yapıldı. Çalışmada R programlama ve ANOVA istatistik analizi ile göz takibi verilerine hiyerarşik küme analizi uygulandı. Kümeler demografik, klinik ve bilişsel özelliklere göre karşılaştırıldı (Waldthaler vd., 2023).

Uribarri vd. (2023), göz izleme verilerini kullanarak PH sınıflandırması için derin öğrenme algoritmalarının kullanımını vurgulamışlardır. Yürüttükleri çalışmada sakkadik göz hareketleri sırasındaki fiksasyon (sabitlenebilme) aralıklarını InceptionTime ve

ROCKET sınıflandırma modelinde kullanmışlar ve InceptionTime için %78 ve ROCKET için %88 doğruluk oranı elde etmişlerdir (Uribarri vd., 2023).

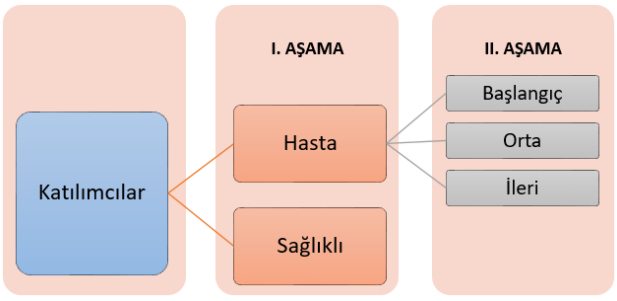
Kurt vd. (2024) ise, PH tespitinde invaziv olmayan bir tanı aracı olarak videonistagmografinin (VNG) kullanılabilirliğini makine öğrenimi yöntemleri kullanılarak incelemişlerdir. VNG ile kaydedilen göz hareketlerine ait sinyal analizi için Shannon dalgacık entropisinin ve bir bireyi dışarıda bırak çapraz doğrulama şemasıyla k-en yakın komşu (k-EYK) sınıflandırma algoritmasını kullanmışlardır. Sonuç olarak. PH hastalarını sağlıklı kontrollerden ayırt etmede %84,0 doğruluk ve %82,7 hassasiyet elde edilmiştir (Kurt vd., 2024).

BÖLÜM 3

MALZEME ve YÖNTEM

3.1. Çalışmanın Genel Yapısı

Yürütülen bu tez çalışması, Parkinson hastalığının okülomotor hareketlerden sakkadik ve pursuit göz hareketleri ile belirlenmesi ve farklılaştırılması için derin öğrenme ve makine öğrenmesi tabanlı iki aşamalı hiyerarşik bir yapıya sahiptir. İlk seviyede sağlıklı ve hasta ayırımı yapan sınıflandırıcı modeli, ikinci seviyede hastalık evresini tespit edecek şekilde geliştirilmiştir. Hiyerarşik model, ilk seviyesinde sadece iki sınıf (sağlıklı ve hasta), ikinci seviyesinde ise üç sınıf (başlangıç, orta, ileri) olacak şekilde Şekil 3.1'de belirtildiği gibi oluşturulmuştur. Dolayısıyla ilk aşamada modelin eğitiminde toplanan sağlıklı ve hasta olarak etiketlenmiş tüm veriler, ikinci aşamadaki modelin eğitiminde ise sadece hastalığın derecesinin etiketlendiği hasta verileri kullanılmıştır. Her iki aşama sınıflandırıcılarının tasarımı için önce geleneksel makine öğrenmesi süreçleri ve yöntemleri uygulanmıştır. Ardından derin öğrenme yöntemlerinin problemin çözümündeki başarımı incelenmiştir. Son olarak derin öğrenme mimarilerinden elde edilmiş derin özniteliklerin makine öğrenmesi sınıflandırıcılarla birlikte kullanıldığı hibrit bir yaklaşım önerilmiştir.



Şekil 3.1. Sistemin genel işlem basamakları i) hasta-sağlıklı tespiti (1.aşama) ve ii) hastalık evresi tespiti (2.aşama)

3.2. Verilerin Elde Edilmesi ve Veri Kümesinin Tanımı

Tez çalışması kapsamında toplanacak verilerin elde edilmesi için Trakya Üniversitesi Nöroloji Anabilim dalı polikliniğine kayıtlı EK 1'de belirtilen çalışmaya dahil edilme kriterlerine uygun hastalar ile iletişime geçilerek çalışmaya gönüllü katılmak isteyen hastalarla veri toplanması adına gün ve saat verilerek randevu programı hazırlandı. Ayrıca nöroloji polikliniğine başvurmuş Parkinson hastalığı teşhisini yeni almış hastalar da çalışmaya dahil edildi.

Veri toplama sürecinden önce tüm denekler, göz izleme sinyallerinde yanıltıcı patolojik izler oluşturabilecek herhangi bir nörolojik ek hastalık (komorbidite) veya vestibüler sistem bozukluğunun (örn. Vertigo) bulunmadığını doğrulamak için nöroloji ve kulak burun boğaz bölümlerinde doktorlar tarafından muayene edildi.

Sağlıklı kontrol grubu bireyleri ise nöroloji, kulak burun ve boğaz (KBB) polikliniklerine başvurmuş ve hekimlerin gerekli kontrollerinden sonra çalışmayı olumsuz etkileyebilecek herhangi bir engeli bulunmayan ve çalışmaya dahil olmayı kabul eden hastalık tanısı almamış gönüllü bireylerden oluşmaktadır.

Potansiyel katılımcıların çalışmaya uygunluğunun uzman hekimlerce değerlendirilmesi sonrası aydınlatılmış onamları alındıktan sonra katılımcılardan veri toplama sırasında EK 2'de gösterilen anket soruları veri kümelerini daha iyi kategorize edebilmek ve hastalığı tanımlayıcı farklı öznitelikler arası ilişki çıkarımlarını yapabilmek için hem katılımcıların kendilerine hem de refakatçilerine soruldu. Demografik, hastalık tanımlayıcı belirtileri, Covid-19 geçirme durumu, aşı doz ve türleri, hastalık süreleri, hastalık belirtilerinin baskın olduğu taraf (el, kol ve bacak için titreme, uyuşma vb.), süresi, gözlük kullanma durumu, türü, vb. gibi bilgiler anket formunda her katılımcı için kaydedildi.

Tez çalışmasında hasta ve sağlıklı bireylere ait okülomotor göz hareketleri Trakya Üniversitesi Kulak Burun Boğaz polikliniğinde bulunan "VisualEyes 525" Videonistagmografi (VNG) sistemi (Interacoustics, Middelfart, Danimarka) ile kayıt altına alınmıştır. Kayıt, 100 Hz örnekleme frekansıyla binoküler olarak gerçekleştirildi. Katılımcılardan ekrandan 1 m uzakta oturmaları ve ekranda rastgele beliren noktaları takip etmeleri istendi. Katılımcılar, Şekil 3.2'de gösterildiği gibi baş hareketlerinden

kaynaklanan müdahaleleri önlemek için bu uyaranları yalnızca gözleriyle takip etmeleri talimatı verildi. Deneysel testlere başlamadan önce her bireyin kendi göz konumu ve durumuna göre 5 yönlü (merkez, yukarı, aşağı, sol ve sağ) kalibrasyon işlemi gerçekleştirildi.



Şekil 3.2. Testler için katılımcıların uygun pozisyonda yerleştirilmesi

Katılımcı bilgilerine Çizelge 3.1 ve Çizelge 3.2'de yer verilmiştir. Çizelge 3.1, hasta ve sağlıklı bireylerin ayrımı amacıyla geliştirilen modellerde kullanılan verilerin hasta ve sağlıklı gruplardaki katılımcı bilgilerini içermektedir. Çizelgelerde μ sembolü aritmetik ortalamayı, σ sembolü ise standart sapmayı ifade etmektedir.

Çizelge 3.1. Hasta ve sağlıklı katılımcıların demografik bilgileri

	Parkinson Hastası	**Sağlıklı Kontrol**
Katılımcı Sayısı	112	112
Cinsiyet dağılımı (Kadın/Erkek)	48 / 64	53 / 59
Yaş (μ ± σ yıl)	67,56 ± 9,12	63,05 ± 8,05
Yaş aralığı (μ ± σ yıl)	41 - 82	38 - 80
Hastalık süresi (μ ± σ yıl)	6,12± 5,13	-

Çizelge 3.2 ise, Parkinson hastası bireylerin Hoehn & Yahr ölçeği temel alınarak geliştirilen evre tayini modellerinde kullanılan verilere ait dağılımları göstermektedir.

Çizelge 3.2. Hasta bireylerin evrelere göre demografik bilgileri

	Başlangıç	**Orta**	**İleri**
Katılımcı Sayısı	69	26	17
Cinsiyet dağılımı (Kadın/Erkek)	29 / 39	14 / 11	5 / 12
Yaş (μ ± σ yıl)	67.33 ± 9.47	68.38 ± 8.23	67.41 ± 9.17
Hastalık süresi (μ ± σ yıl)	5.12 ± 4.36	5.01 ± 3.71	12.11 ± 5.93

Bu çalışmaya aktif levodopa/karbidopa bağırsak jeli (Duodopa) veya derin beyin stimülasyonu (DBS) cihazları olan hastalar dahil edilmemiştir. Semptomatik tedavi ilaçları semptom şiddetini azaltabilir veya baskılayabilir. Bu durum uygulanacak yapay zeka tabanlı algoritmaların karar verme sürecinde potansiyel yanılgılara yol açacaktır. Bunu engellemek için testler Parkinson hastaları ilaçlarını kullanmadıkları zamanda (off-state) gerçekleştirildi.

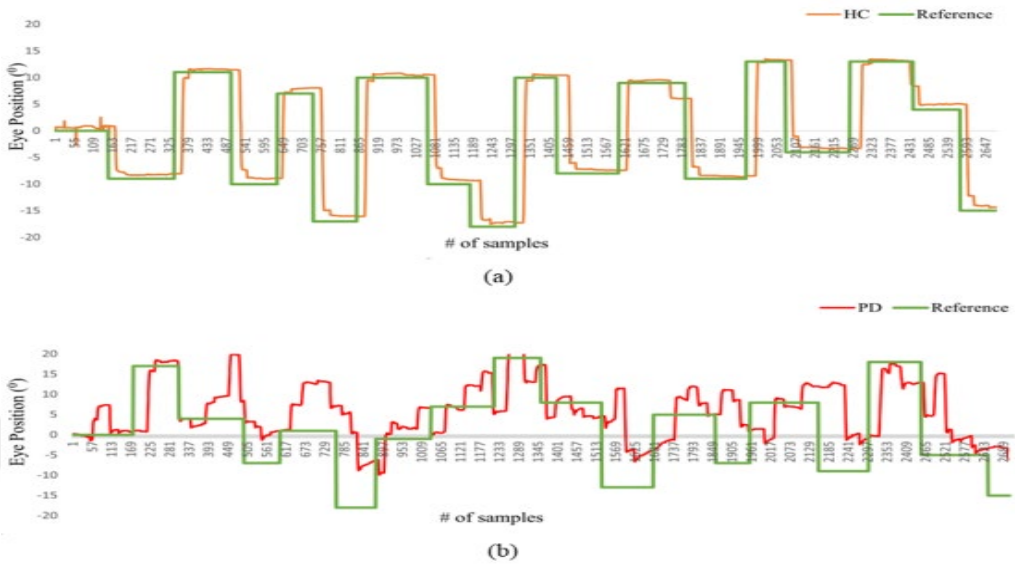
3.3. Verilerin Hazırlanması

3.3.1. Sakkadik Göz Verileri

Sakkadik göz hareketleri için katılımcılardan VNG sisteminin ekranında rastgele beliren bir uyarıyı yaklaşık 42 saniye boyunca takip etmeleri istendi. Zaman serisi desenlerindeki bu rastlantısallığı ortadan kaldırmak için, testlerde ekranda görülen uyarana ait referans sinyali ile testler sırasında katılımcıların göz hareketi sinyalleri arasındaki fark alınarak yeni bir veri kümesi oluşturuldu.

Şekil 3.3, sakkadik göz hareketi testi sırasında hem VNG sistemi hem de katılımcılar tarafından üretilen sinyalleri göstermektedir. Yeşil renkli sinyaller VNG sistemi tarafından üretilen referans sinyallerini ifade etmektedir. Turuncu ve kırmızı renkli zaman serileri sırasıyla sağlıklı kontrol (Şekil 3.3a) ve PH (Şekil 3.3b) bireylerinin uyaran sinyallerine yanıt olarak ürettikleri sinyalleri temsil etmektedir. Uyaran sinyali, test sırasında belirli dikey eksen sınırları dâhilinde çeşitli yatay konumlarda ekranda rastgele belirdi. Bu nedenle, çalışmada önerilen makine öğrenmesi ve derin öğrenme tabanlı modellerin sonuçlarının yanıltıcı olmasını önlemek ve daha standartlaştırılmış veri kümeleri elde etmek için bu rastgeleliğin açıklığa kavuşturulmasına ihtiyaç vardır. Bu

amaçla VNG ile toplanan katılımcıların referans sinyali ile yanıt sinyalleri arasındaki Öklid mesafesi bulunarak yeni zaman serileri oluşturuldu.

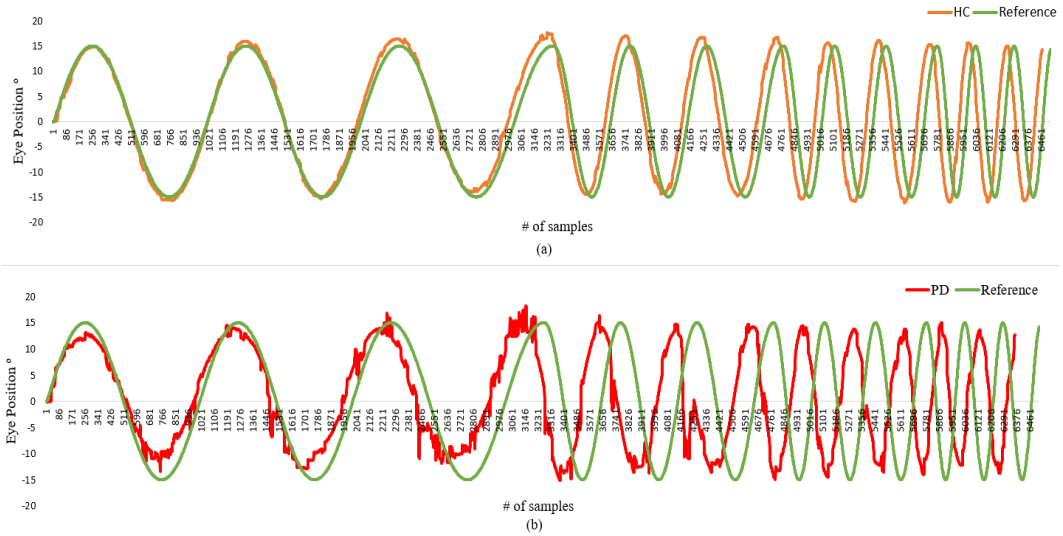


Şekil 3.3. Sakkadik göz hareketi testi sırasında VNG sistemi ile (i) HC (sağlıklı kontrol) (ii) PH katılımcılar tarafından üretilen sinyaller.

3.3.2. Pursuit Göz Verileri

Pursuit göz hareketlerinde ise katılımcılardan yaklaşık 60 saniye boyunca ekranda yatay eksende hareket eden kayan bir noktayı takip etmeleri istendi. Uyaran sinyali, test sırasında yavaş bir frekanstan hızlı bir frekansa doğru kademeli artış gösteren bir davranışa sahiptir. Buradaki amaç hareketli nesnelerin takibinde sergilenen uyumun ölçülebilmesidir. Bu testte referans sinyalleri her katılımcı için aynı olduğundan test boyunca kayıt altına alınan ölçümlerle oluşturulan veri kümeleri önerilen yapay zeka yöntemlerinde doğrudan kullanıldı.

Şekil 3.4, pursuit göz hareketi testi sırasında hem VNG sistemi hem de katılımcılar tarafından üretilen sinyalleri göstermektedir. Şekil 3.3'te olduğu gibi yeşil renkli sinyaller VNG sistemi tarafından üretilen referans sinyallerini ifade ederken turuncu ve kırmızı renkli sinyaller ise sırasıyla sağlıklı kontrol (Şekil 3.4a) ve hasta bireylere (Şekil 3.4b) ait örnek sinyalleri göstermektedir.



Şekil 3.4. Pursuit göz hareketi testi sırasında VNG sistemi ile (i) HC (sağlıklı kontrol) (ii) PH katılımcılar tarafından üretilen sinyaller.

3.4. Zaman Serilerinin Görüntüye Dönüştürülmesi

Derin öğrenme modelleri verilerden anlamlı özellikler çıkarmada oldukça etkili bir diğer yapay zeka yaklaşımıdır (Wang ve Oates, 2015a). Ancak, zaman serisi verileri genellikle zamana bağımlılıkları ve karmaşık doğrusal/doğrusal olmayan ilişkiler içerdiğinden, bu tür verilerden anlamlı bilgi çıkarımında yapısal düzenlemeler gerekebilir (Ko ve Yang, 2022). Derin öğrenme algoritmaları görsel özellikleri daha kolayca yakalayabildiği için görüntü dönüşümü bu süreçte önemli bir adımdır. Zaman serisi verilerinin derin öğrenme yöntemlerine uygulanması sırasında görüntü dönüşümleri verilerin model için daha anlaşılır ve işlenebilir hale gelmesini sağlar (Wang ve Oates, 2015b). Böylelikle, problem çözümüne yönelik daha doğru tahminler ve çıkarımlar yapılmasına yardımcı olabilmektedir.

Bu çalışmada, derin öğrenmesi mimarilerinde kullanılmak üzere göz hareketlerine ait bir boyutlu zaman serisi sinyallerin çeşitli matematiksel dönüşüm uygulamaları ile iki boyutlu görüntülere çevrilmiştir. Bu kapsamda, görsel dönüşümlerinde Gramian Açısal Alan (GAA), Yineleme Grafiği (YG) ve Markov Geçiş Alanı (MGA) yöntemleri kullanılmıştır.

3.4. 1. Yineleme Grafiği (Recurrence Plot)

Zaman serisi sinyallerinin Yineleme Grafiği (YG) ile görselleştirilmesi, karmaşık dinamiklerin ve yapısal özelliklerin anlaşılmasında güçlü bir yöntemdir. Zaman serilerinde tekrar eden desenlerin veya yapılarının varlığını tespit etmek için kullanılır. YG zaman serilerinin her iki noktasındaki benzerlikleri gösteren bir görselleştirme yöntemidir (Ko ve Yang, 2022; Küçük ve Yılmaz, 2024).

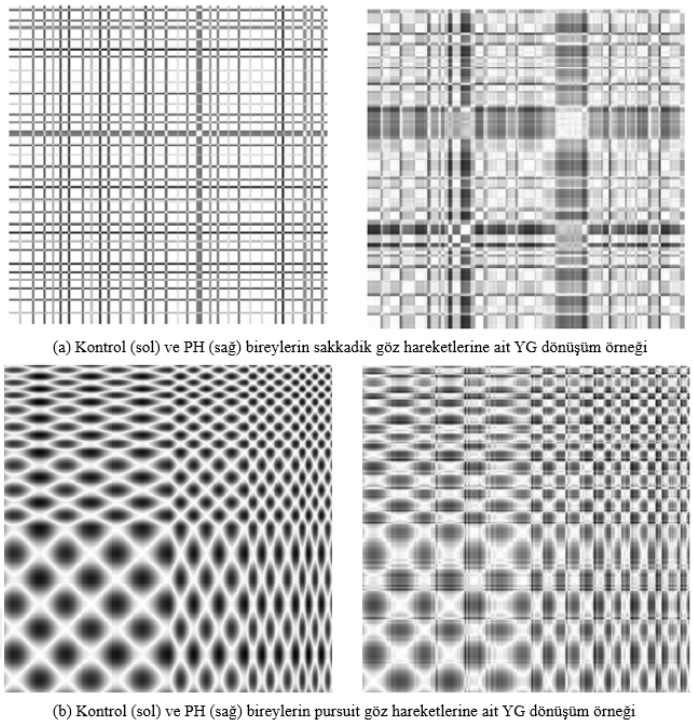
Yineleme grafiklerinin matematiksel temelinde, belirli bir zaman serisindeki iki noktanın birbirine yakın olup olmadığının kontrolü yer alır. Bu noktaların birbiri ile benzerliğini hesaplamada genellikle Öklid mesafesinden yararlanılır. Bu iki nokta arasındaki Öklid mesafesi şu şekilde hesaplanabilir:

$$d(x(i), x(j)) = \|x(i) - x(j)\| \tag{3.1}$$

Burada *x(i)* ve *x(j)* serilerdeki karşılaştırılacak farklı noktaları ifade etmektedir. Eğer *d(x(i), x(j))* olarak hesaplanan mesafe değeri, ϵ olarak ifade edilen bir eşik ile karşılaştırır ve benzer noktaları bir matris şeklinde görselleştirir. Bu görselleştirme, bir matrisin her bir hücresine karşılık gelen 1 veya 0 değerleriyle yapılır. 1 değeri, o iki zaman noktasının benzer olduğu, 0 değeri ise farklı olduğu anlamına gelir (Tang vd., 2020).

$$R(i,j) = \begin{cases} 1, & d((x(i), x(j)) < \epsilon \\ 0, & diğer\ durumlarda \end{cases} \tag{3.2}$$

Burada $R(i,j)$, zaman serisindeki i ve j noktaları arasındaki benzerliği belirtir. Şekil 3.5'te sağlıklı ile PH bireylere ait sakkadik ve pursuit göz hareketlerinden elde edilen zaman sinyallerinin Yineleme Grafiği dönüşümüne ait örnek görseller verilmiştir.



Şekil 3.5. Kontrol (sol) ve PH (sağ) katılımcılara ait örnek Yineleme Grafiği dönüşüm görselleri

3.4.2. Gramian Açısal Alan (Gramian Angular Field)

Gramian Açısal Alan (GAA), zaman serisini bir matris veya görsel olarak temsil etmek için matematiksel bir dönüşüm sağlar ve bu şekilde, zaman serilerindeki desenler ve ilişkiler daha kolay bir şekilde analiz edilebilir. Bu dönüşümü serilerin Kartezyen koordinat düzlemi yerine polar koordinat düzlemindeki temsillerini kullanarak oluşturur. GAA, zamansal korelasyonların yakalanmasını sağlayarak veriler hakkında yeni bir bakış açısı sağlar.

GAA dönüşümünde öncelikle zaman serisi verilerinin [-1, 1] veya [0, 1] gibi belirli bir aralığa yeniden ölçeklendirilerek normalize edilmesi gereklidir. Bu işlemden sonra, her bir zaman değeri için (x_i) için polar koordinat düzlemindeki θ_i açısı hesaplanır.

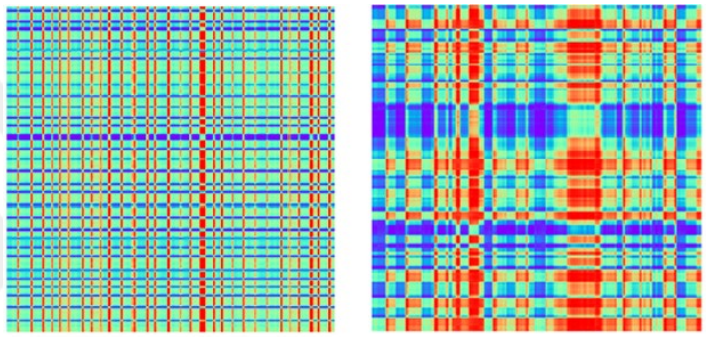
$$\theta_i = \arccos(x_i) \tag{3.3}$$

GAA dönüşümlerinde karşılıkların hesaplanmasında literatürde iki farklı yöntem önerildiği görülmektedir (Buz vd., 2020; Shukla vd., 2021). Gramian Açısal Fark Alanı (GAFA), görüntü oluşturmada zaman serisindeki her bir zaman noktasının açısal

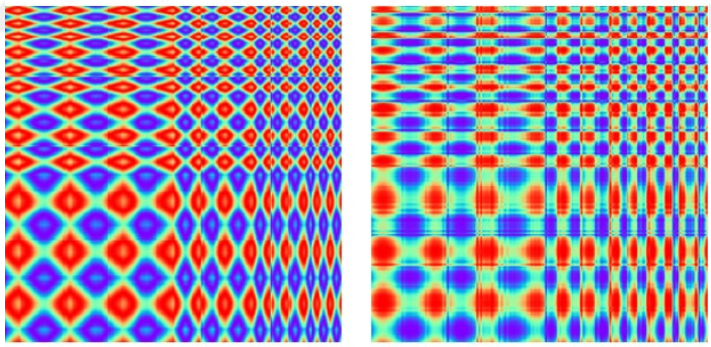
karşılıklarının farklarının sinüsünü alırken, bu tez çalışmasında da kullanılan Gramian Açısal Toplam Alan (GATA), açısal karşılıklarının toplamının kosinüs değerini kullanarak GAA matris yapısıyla görüntü oluşturur.

$$GATA[i,j] = \cos(\theta_i + \theta_j) = x_i x_j \sqrt{(1 - x_i^2)(1 - x_j^2)} \quad (3.4)$$

Şekil 3.6'da sağlıklı ile PH bireylere ait sırasıyla sakkadik ve pursuit göz hareketlerinden elde edilen zaman sinyallerinin Gramian Açısal Toplam Alan dönüşümüne ait örnek görsellere verilmiştir.



(a) Kontrol (sol) ve PH (sağ) bireylerin sakkadik göz hareketlerine ait GAA dönüşüm örneği



(b) Kontrol (sol) ve PH (sağ) bireylerin pursuit göz hareketlerine ait GAA dönüşüm örneği

Şekil 3.6. Kontrol (sol) ve PH (sağ) katılımcılara ait örnek Gramian Açısal Toplam Alan dönüşüm görselleri

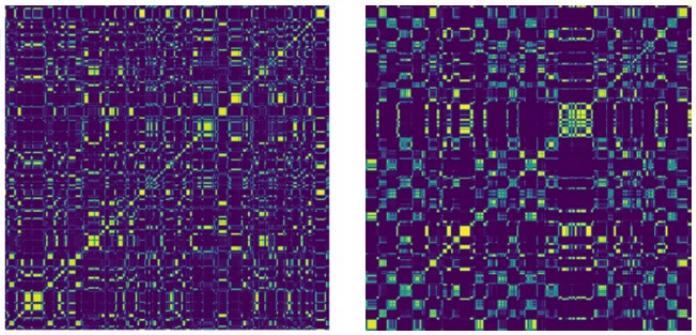
3.4. 3. Markov Geçiş Alanı (Markov Transition Field)

Zaman serilerinin görüntüye dönüştürülmesinde kullanılan yaklaşımlardan bir diğeri de Markov Geçiş Alanı (MGA) yöntemidir. Temelde MGA dönüşümü, zaman serisinin her bir değeri arasındaki geçiş olasılıklarını kullanarak, bir Markov zinciri modeli inşa eder. Bu modelin çıktısı, genellikle bir matris ya da görsel veri olur (Estebsari ve Rajabi, 2020).

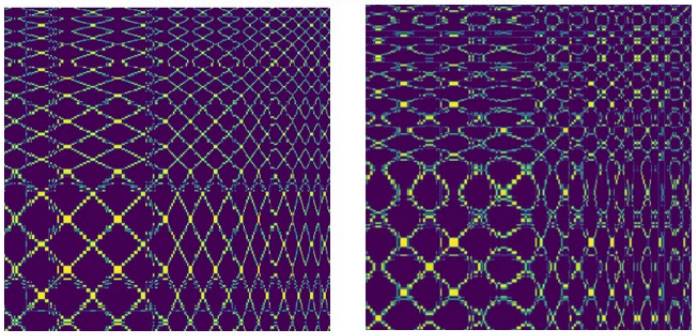
Bu dönüşümü sağlarken X zaman sinyalinin Q dağılım dilimleri ile olan ilişkisini zaman serisindeki her x_i ile bağlantılı q_i dilimlerini temel alarak çıkarır. Görselleştirmede kullanılacak Q x Q ağırlıklı yakınlık matrisi zaman ekseninde Markov zinciri biçiminde dağılım dilimleri arasındaki geçişlerin hesaplanmasıyla oluşturulmaktadır. Matriste bulunan her $w_{i,j}$, q_j dilimindeki bir noktanın q_i dilimindeki bir nokta tarafından takip edilme sıklığını ifade etmektedir. Matriste bulunan tüm elemanlar için bu hesaplamalar yapıldıktan sonra her bir satırdaki elemanların toplamının 1 olacak şekilde normalizasyon yapıldıktan sonra Markov geçiş matrisi elde edilmektedir (Buz vd., 2020).

$$M = \begin{bmatrix} w_{ij|x_1 \in q_i, x_1 \in q_j,} & \cdots & w_{ij|x_1 \in q_i, x_n \in q_j,} \\ \vdots & \ddots & \vdots \\ w_{ij|x_n \in q_i, x_1 \in q_j,} & \cdots & w_{ij|x_n \in q_i, x_n \in q_j,} \end{bmatrix} \tag{3.5}$$

Şekil 3.7'de sağlıklı ve PH bireylerin sakkadik ve pursuit göz hareketlerinden elde edilen zaman sinyallerinin Markov Geçiş Alanı dönüşümüne ait örnek görseller gösterilmektedir.



(a) Kontrol (sol) ve PH (sağ) bireylerin sakkadik göz hareketlerine ait MGA dönüşüm örneği



(b) Kontrol (sol) ve PH (sağ) bireylerin pursuit göz hareketlerine ait MGA dönüşüm örneği

Şekil 3.7. Kontrol (sol) ve PH (sağ) katılımcılara ait örnek Markov Geçiş Alan dönüşüm görselleri

BÖLÜM 4

MAKİNE ÖĞRENİMİ YÖNTEMLERİ KULLANILARAK VNG VERİLERİ İLE PH VE EVRE TESPİTİ

Bu bölümde öncelikle makine öğrenimi tanımlanması ve uygulama alanlarından bahsedilmiştir. Ayrıca tez çalışması kapsamında önerilen makine öğrenimi sisteminde kullanılan özniteliklerin, normalizasyon ve çapraz geçerleme yöntemleri ile sınıflandırma algoritmaları hakkında genel bilgilendirme yapılmıştır.

4.1. Makine Öğrenimi Uygulamaları

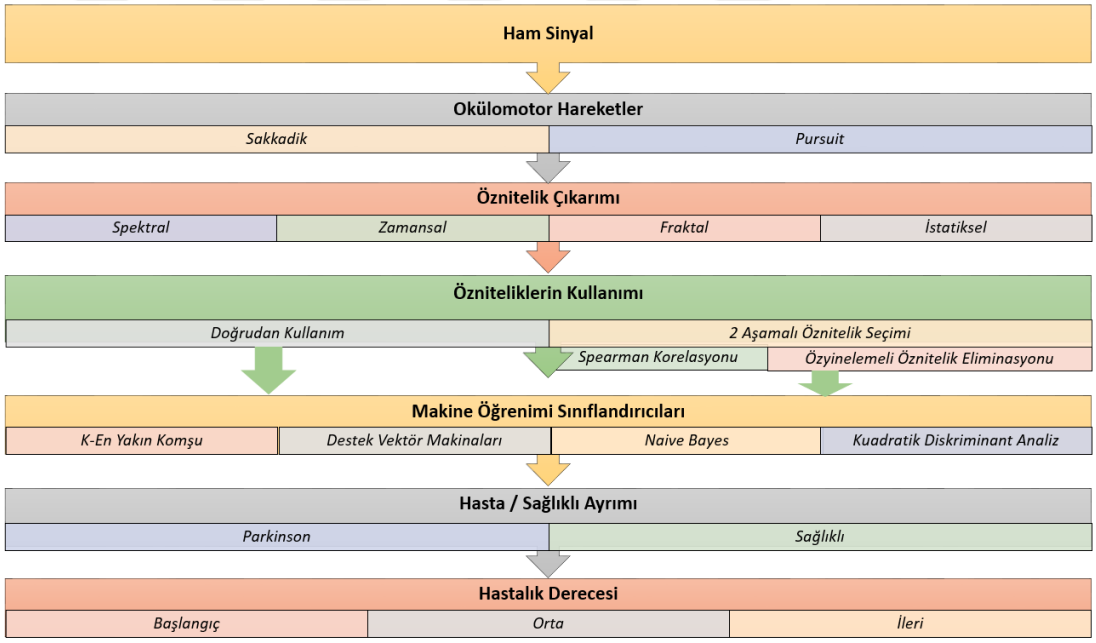
Makine öğrenmesi, mevcut bilgilere dayanarak belirli bir konu veya sorun hakkında analiz yapan ve sonuçlar çıkaran bir dizi tekniği ifade eder (Silahtaroğlu, 2008). Modelleme sürecinde farklı algoritmalar ve yaklaşımlar kullanılmaktadır.

Makine öğrenimi algoritmaları, anlamlı bilgiler çıkarmak için metin, resim ve sayısal ölçümler dahil olmak üzere çeşitli veri türlerini analiz eder. Ardından bu bilgiler, belirli bir soruna göre uyarlanmış bir çıkarım modeli geliştirmek için kullanılır. Veri türüne bağlı olarak, bu modeller önemli ölçüde farklılık gösterebilir. Örneğin, sınıflandırma teknikleri, hastalık semptomlarına göre sağlıklı ve hasta bireyleri ayırt etmeye yardımcı olabilirken daha büyük ve kapsamlı veri kümeleriyle yapılan analizlerde ise, veriler arasındaki benzerliklere dayalı olarak kümeler oluşturulup kategorize edilerek sonuçlara ulaşmak için kümeleme yöntemleri tercih edilebilir.

Ancak bu tür modellere başvurmadan önce verilerin uygun hale getirilmesi gerekmektedir. Bu süreçte, verilerin doğrudan kullanılabilmesi için uygun olmayan verilerin çıkarılması, farklı ölçekteki verilerin belirli bir aralığa dönüştürülmesi, eğer varsa eksik verilerin tamamlanması gibi ön işleme adımları önem taşır. Makine

öğreniminde analiz edilen veriler, toplanan örneklerden elde edilir ve her örneğe ait kullanılabilir tüm bilgiler öznitelik olarak adlandırılmaktadır (Alpaydin, 2009). Ayrıca, çıkarım yapmak için her örneğin ait olduğu sınıf bilgileri de gereklidir. Makine öğrenimi uygulamalarında veri kümesi genellikle eğitim ve test olmak üzere iki kümeye ayrılır. Problemle ilgili modelin oluşturulmasında eğitim kümesine ayrılan veriler kullanılırken, modelin başarısını ölçmek amacıyla karşılaştırılacak veriler ise test kümesinde yer alır. Bu yapı sayesinde, makine öğrenimi algoritmaları etkili bir şekilde çalışarak anlamlı sonuçlar elde edebilir.

Şekil 4.1, tez çalışması kapsamında önerilen hiyerarşik yapının geleneksel makine öğrenimi yöntemleriyle değerlendirilmesi için önerilen sistemin akış şemasını göstermektedir.



Şekil 4.1. Makine öğrenimi uygulamaları işlem basamakları

4.2. Öznitelik Çıkarımı

Hasta ve sağlıklı bireylerden kaydedilen sakkadik göz hareketine ait sinyaller yeniden yapılandırıldıktan sonra elde edilen yeni sinyallerden ve pursuit hareketlere ait sinyallerden Çizelge 4.1'te belirtilen zaman serilerinin istatistiksel, zamansal, fraktal ve spektral özelliklerine ait yeni öznitelikler çıkarılmıştır. Öznitelik çıkarımında Python Tsfel kütüphanesinden (Barandas vd., 2020) ve MATLAB (MathsWorks, 2024b) sinyal

işleme fonksiyonlarından yararlanılmıştır. Tabloda verilen 66 öznitelikten bazılarının farklı katsayı ve dereceleri kullanılarak elde edilen türevleri ile birlikte çıkarılan öznitelik sayısı 140'tır.

Spektral, istatistiksel, zamansal ve fraktal öznitelikler sinyallerin daha derinlemesine incelenmesine olanak tanır ve patolojik durumlar veya anormallikler gibi önemli bilgileri ortaya çıkarır. Spektral öznitelikler, frekans bileşenlerini inceleyerek enerji dağılımı ve frekans karakteristiklerini tanımlar. İstatistiksel öznitelikler, sinyalin genel yapısını değerlendirerek merkezi eğilim, yayılma ve uç değerleri belirleyerek anormallikleri tespit etmeye yardımcı olur. Zamansal öznitelikler, sinyalin zaman içindeki değişimlerini ve düzenini analiz ederken, fraktal öznitelikler sinyalin yapısal karmaşıklığını ve kendine benzerliğini analiz ederek doğrudan gözlemlenemeyen ince özelliklerin anlaşılmasını sağlar.

Çizelge 4.1. Sakkadik göz hareketlerine ait zaman serilerinden elde edilen öznitelikler

Tür	**Öznitelik**	
İstatistiksel	Mutlak enerji	Ortalama mutlak sapma
	Ortalama güç	Medyan
	Entropi	Ortanca mutlak sapma
	Histogram	Minimum
	Çeyrekler açıklığı	Ortalama karekökü
	Kurtozis	Eğrilik
	Maksimum	Standart sapma
	Ortalama	Varyans
Zamansal	Eğrinin altındaki alan	Negatif dönüm noktaları
	Otokorelasyon	Tepeden tepeye mesafe
	Ağırlık merkezi	Pozitif dönüm noktaları
	Lempel-Ziv Karmaşıklığı	Sinyal mesafesi
	Ortalama mutlak fark	Eğim
	Ortalama fark	Toplam mutlak fark
	Ortanca mutlak fark	Sıfır geçiş oranı
	Ortanca fark	Komşuluk noktaları

Çizelge 4.1. Sakkadik göz hareketlerine ait zaman serilerinden elde edilen öznitelikler (devam)

Spektral	Temel frekans İnsan menzili enerjisi Doğru tahmin kepstral katsayıları Mel-frekans kepstral katsayıları Maksimum güç spektrumu Maksimum frekans Ortanca frekans Güç bant genişliği Spektral ağırlık merkezi Spektral azalma Spektral mesafe Spektral entropi Spektral basıklık	Spektral pozitif dönüm noktaları Spektral düşüş Spektral artış Spektral çarpıklık Spektral eğim Spektral yayılma Spektral varyans Dalgacık mutlak ortalaması Dalgacık enerjisi Dalgacık standart sapması Dalgacık entropisi Dalgacık varyansı
Fraktal	Trendsizleştirilmiş dalgalanma analizi Higuchi fraktal boyutu Yeniden ölçeklendirilmiş aralık analizi	Maksimum fraktal uzunluğu Çok ölçekli entropi Petrosian fraktal boyutu

4.3. Normalizasyon Yöntemleri

Öznitelik normalizasyonu, probleme ait veri özelliklerinin modelin öğrenme sürecine eşit şekilde katkıda bulunmasını sağlayan makine öğreniminde kritik bir ön işleme adımıdır. Öznitelikler normalleştirildiğinde uygulanan yapay zeka modelleri probleme ait izleri daha iyi belirleyebilmekte ve algoritmaların performanslarını iyileştirerek daha doğru tahminlerde bulunmasına yardım etmektedir.

Yapay zeka yöntemlerinde kullanılmak üzere veri kümesi oluşturma sürecinde, verilerile ilgili tekrar, kayıp veya yetersizlik gibi sorunları önlemek için verileri etkili bir şekilde düzenlemek çok önemlidir. Bu düzenleme, gereksiz veri tekrarlarının engellenmesini, veri bozulmasının önüne geçilmesini ve farklı yöntemler kullanıldığında bile veri kümesinin tutarlı bir şekilde çalışmasını sağlamayı amaçlar. Literatürde verilerin ortalama ve standart sapma değerlerini kullanarak yeni dönüşümlerini sağlayan sıfır-ortalama normalleştirme veya veri kümesindeki en küçük ve en büyük değerleri

kullanarak normal dağılımlarını sağlayan minimum-maksimum normalleştirme gibi yöntemler sıklıkla tercih edilmektedir (Silahtaroğlu, 2008). Ancak bazı durumlarda özniteliğe ait yeni değerlerde de normal dağılımı olumsuz etkileyebilecek uç değerler varlığını koruyabilir. Bu tür durumlarda, Denklem 4.1'de belirtildiği üzere aralık değerleri üzerinde yapılan formül güncellemeleriyle istenen sınırlar içinde kullanılabilecek hale getirilebilir.

$$yeni_{değer} = \frac{değer - min_{değer}}{maks_{değer} - \min_{değer}} (yeni_maks_{değer} - yeni_min_{değer}) + yeni_min_{değer} \quad (4.1)$$

Parkinson hastası ve sağlıklı kontrollerden elde edilen pursuit sinyallerle yeniden yapılandırılmış sakkadik zaman serilerinden çıkartılan veri kümesine hem geleneksel makine öğrenimi hem de derin özniteliklerin makine öğrenimi yöntemlerindeki başarımını inceleyen hibrit yaklaşımda [-1,+1] değer aralığındaki minimum-maksimum normalizyon yöntemi kullanılmıştır.

4.4. Öznitelik Seçim Yöntemleri

Öznitelik seçimi, bir modelin performansını artırmak ve işlem süresini kısaltmak için en belirleyici ve anlamlı özelliklerin seçilmesidir. Tüm öznitelikleri kullanmak yerine yalnızca önemli olanları kullanmak, modelin daha kolay yorumlanmasını sağlar ve gereksiz özniteliklerin kaldırılmasıyla boyut ve işlem sayısı azalır. Bu durum da sınıflandırma performansını olumlu yönde etkiler (Budak, 2018).

Literatürde öznitelik seçimi için üç ana yöntem bulunur: (i) Filtre Yöntemleri, (ii) Sarıcı Yöntemler ve (iii) Gömülü Yöntemler. Filtre yöntemleri, öznitelikler arasındaki istatistiksel ilişkiler (örneğin Ki-kare, Pearson korelasyonu gibi) kullanarak öznitelikleri sıralar. Sarıcı yöntemler, farklı öznitelik alt kümeleri oluşturur, her birini test eder ve en iyi performansı gösteren alt küme seçilir. Gömülü yöntemler, problemle ilgili en iyi bağlantıları öğrenerek model oluşturur ve düzenleme (regularizasyon) yöntemleri gibi optimizasyon teknikleriyle modelin karmaşıklığını azaltır. Bu yöntemlerin her biri, modelin doğruluğunu artırmak ve işlem süresini azaltmak için kullanılır (Budak, 2018).

Tez çalışmasında hem hasta sağlıklı ayrımı hem de hastalık evre derecelendirmesinde kullanılacak en betimleyici özniteliklerin belirlemek için filtre ve

sarıcı yöntemlerin kullanıldığı iki aşamalı bir öznitelik seçim yöntemi önerilmiştir. Zaman serilerinden spektral, zamansal, istatistiksel ve fraktallık kategorilerine ait 140 özniteliğe ilk aşamada Spearman sıralama korelasyonu uygulanmış ve öznitelikler önem sırasına göre sıralanmıştır. Spearman korelasyonu ile özniteliklerin birbirleriyle olan ilişkisinin hızlı bir şekilde belirlenmesi ve önemli olanların seçilmesi için ön filtreleme yapılması amaçlanmıştır. Bu ön filtreleme uygulaması ile bir sonraki aşamada kullanılacak ilk 70 öznitelik belirlenmiştir.

İkinci aşamada ise Özyinelemeli Öznitelik Eliminasyonu (ÖÖE, Recursive Feature Elimination, RFE) yapılarak korelasyon ile ön filtreden geçerek seçilen 70 özniteliğin içinden sadece korelasyonu yüksek olanların değil, modelin öğrenmesi için gerçekten önemli olan özniteliklerin seçilmesi amaçlanmıştır. ÖÖE uygulaması sonucunda en etkili 20 öznitelik belirlenmiştir.

4.4.1. Spearman Korelasyonu

Spearman korelasyon özelliği seçimi yöntemi, değişkenler arasındaki ilişkinin gücünü ve yönünü değerlendirmek için kullanılan istatistiksel bir tekniktir. Denklem 4.2'de ρ olarak hesaplanan Spearman sıralama korelasyon katsayısı, iki değişkenin ne kadar ilişkili olduğunu, aralarındaki ilişkinin monoton bir fonksiyon kullanılarak ne kadar iyi tanımlanabileceğini değerlendiren parametrik olmayan bir ölçüdür. Doğrusal ilişkileri ölçen Pearson korelasyonunun aksine, Spearman korelasyonu değerlerin gerçek sayısal değerlerinden ziyade sıralarına odaklanır. Bu, onu aykırı değerlere karşı sağlam hale getirir ve normallik varsayımlarını karşılamayan sıralı veriler veya sürekli veriler için uygun hale getirir (Baskar vd., 2020).

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2-1)} \tag{4.2}$$

Spearman'ın sıra korelasyonu, özellikle doğrusal olmayan ilişkiler veya normal olmayan dağılımlı verilerle uğraşırken, makine öğreniminde özellik seçimi için güçlü bir araçtır (Saeys vd.,2008). Aykırı değerlere karşı sağlamlığı ve esnekliği, onu veri bilimcileri ve makine öğrenimi uygulayıcılarının araç setinde olmazsa olmaz bir yöntem haline getirir.

4.4.2. Özyinelemeli Öznitelik Eliminasyonu (Recursive Feature Elimination)

Özyinelemeli Öznitelik Eliminasyonu (ÖÖE, Recursive Feature Elimination, RFE) en alakalı özelliklere odaklanarak ve tahmin gücüne çok az katkıda bulunanları atarak model performansını artıran güçlü bir özellik seçimi aracıdır (Shahraki vd. 2020). Yinelemeli yapısı, özellik önemine göre kapsamlı değerlendirme ve ayarlamaya olanak tanır ve bu da onu verimli makine öğrenimi modelleri oluşturmak için veri bilimcisinin araç setinde değerli bir yöntem haline getirir.

ÖÖE, makine öğreniminde daha az önemli özellikleri sistematik bir şekilde kaldırarak modelin performansını artırmaya yönelik bir özellik seçimi yöntemidir. Bu süreç, ilk olarak tüm özellikler kullanılarak bir modelin eğitilmesiyle başlar. Ardından, modelin katsayıları veya özelliklerin önem dereceleri değerlendirilerek en az önemli olan özellikler belirlenir. Bu özellikler veri kümesinden çıkarılır ve model, kalan özelliklerle yeniden eğitilir. Bu adımlar, belirli bir sayıda özellik kalana veya model performansını önemli ölçüde etkilemeyecek şekilde devam eder (Jeon ve Oh, 2020). ÖÖE, modelin genelleme yeteneğini artırarak aşırı uyumu azaltabilir ve böylece daha iyi performans elde edilmesini sağlar. Ayrıca, farklı model türlerine uygulanabilirliği sayesinde esnek bir yöntem sunar ve özellikler arasındaki doğrusallığı yöneterek modelin kararlılığını artırabilir.

4.5. Sınıflandırma Yöntemleri

Sınıflandırma, bilinmeyen bir verinin ait olduğu sınıfın veriye ait tüm nitelikler yardımıyla bir model tarafından belirlenme işlemidir. Problem çözümüne ait sınıflandırma yönteminin seçimi araştırılan soruna göre farklılık gösterebilirken verinin doğası, ondan türetilen niteliklerin düzenlenmesi, miktarı ve karmaşıklık gibi faktörlerden de etkilenir.

Bu tez çalışmasının makine öğrenimi ve derin özniteliklerin kullanıldığı hibrit yaklaşımda sınıflandırma yöntemi olarak Destek Vektör Makineleri (DVM), Naive Bayes (NB), k-En Yakın Komşu (k-EYK) ve Kuadratik Diskriminant Analiz (KDA) kullanılmıştır.

4.5.1. Destek Vektör Makineleri (DVM)

Destek Vektör Makineleri (DVM), sınıflandırma problemlerinde yaygın olarak başvurulan bir makine öğrenimi tekniğidir. Bu yöntem, düşük boyutta doğrusal olarak ayrılamayan veri kümelerini daha yüksek boyutlara aktararak hiper düzlem aracılığıyla ayırmayı mümkün kılar. Hiper düzlem sınıflar arasındaki ayrım sınırını temsil eder ve bu sınırı belirlerken destek vektörleri olarak adlandırılan sınırına en yakın örnekler kullanılır. DVM'nin başarısı için en uygun hiper düzlemi bulmak kritik öneme sahiptir. Uygun hiper düzlemin belirlenmesi sınıflar arasındaki en büyük boşluğu (marjini) maksimize ederek gerçekleştirilir.

DVM algoritmasının etkinliği, çekirdek seçimi ve çekirdek genişliği (g) gibi parametrelerin doğru belirlenmesine bağlıdır. Doğru seçim yapılmadığında aşırı öğrenme riski ortaya çıkabilir. Bu durum maliyet parametresi (C) ile kontrol altına alınır. C değeri arttıkça modelin karmaşıklığı artar, azaldıkça ise daha basit sınırlar elde edilir. Bu parametreler probleme göre değişiklik gösterseler de deneysel yöntemlerle optimize edilir.

4.5.2. Kuadratik Diskriminanat Analiz Algoritması

Kuadratik diskriminant analizi (KDA), istatistik tabanlı sınıflandırma işlemi yapan algoritmalardan birisidir (Hastie, 2009). Bu yöntem, özellikle normal dağılım gösteren bağımsız değişkenlerin varlığında ve gruplar arasındaki varyans-kovaryans matrislerinin eşit olmadığı durumlarda etkilidir. KDA, her bir sınıf için ayrı bir kovaryans matrisine sahip olduğu için sınıflar arasındaki ayrımı daha iyi yapabilir (Tharwat, 1016).

4.5.3. Naive Bayes Algoritması

Naive Bayes sınıflandırma algoritması, istatistiksel öğrenme alanında yaygın olarak kullanılan bir yöntemdir ve temelini Bayes teoremine dayanır (Özkan, 2008). Bu algoritma, belirli bir sınıfa ait olma olasılığını hesaplamak için koşullu olasılıktan yararlanır.

$$P(X|Y) = \frac{P(Y|X) \cdot P(X)}{P(Y)} \tag{4.3}$$

Burada P(X|Y), Y gözlemi verildiğinde X sınıfının olma olasılığı iken, P(Y|X) ise X sınıfı verildiğinde Y gözleminin oluşma ihtimalini ifade eder. P(X) ve P(Y) ise sırasıyla X sınıfı ve Y gözlemine ait olasılık değerlerini göstermektedir.

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

K-en yakın komşu (k-EYK) algoritması, sınıflandırma işlemlerinde sıkça tercih edilen bir yöntemdir ve veriler arasındaki uzaklık veya benzerlik temelinde çalışmaktadır (Silahtaroğlu, 2008). Bu algoritma, sınıf bilgisi bilinen bir eğitim kümesinden yararlanarak test verisinin hangi sınıfa ait olduğunu tayin eder. Sınıflar arasındaki mesafeleri hesaplamak için Öklid veya Manhattan gibi uzaklık ölçütleri kullanılır. Algoritmanın temelinde, "k" sayısının belirlenmesi yatar. Bu değer en yakın komşuların sayısını ifade eder ve genellikle 3, 5 veya 7 olarak seçilir. Daha yüksek "k" değerleri benzer olmayan verilerin bir araya gelmesine yol açarken, düşük değerler benzer verilerin farklı sınıflarda yer almasına neden olabilir (Özkan, 2008). Sınıflandırma sürecinde test noktasının eğitim kümesindeki diğer tüm verilerle olan mesafesi hesaplanır ve en yakın "k" komşu seçilir. Bu komşuların sınıf değerleri arasında en sık tekrarlanan sınıf test edilen veri için atanır. Yöntemin doğruluğunu artırmak için çapraz doğrulama gibi optimizasyon teknikleri de kullanılabilir.

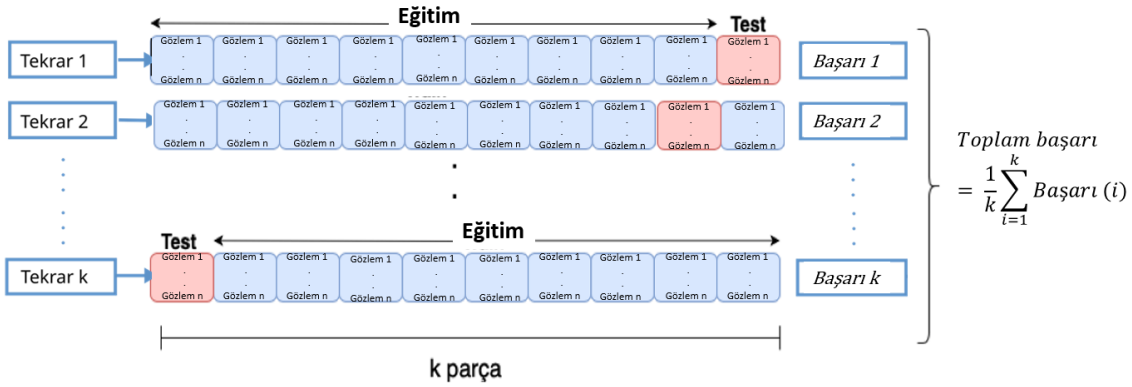
4.6. Çapraz Doğrulama Yöntemleri

Makine öğreniminde büyük veri kümeleri kullanılarak etkili modeller geliştirmek mümkündür. Ancak sınırlı sayıda veriye sahip olunduğunda eğitim verilerinin test amacıyla kullanılması aşırı öğrenmeye (overfitting) yol açabilir. Eğitim veri kümesinin yetersiz olduğu koşullarda verilerin belirli yöntemlerle alt kümelere ayrılması gereklidir. Çapraz doğrulama bu anlamda önemli bir tekniktir. Burada veriler başlangıçta eğitim ve test kümesi olarak ayrılır. Eğitim kümesinden modelin eğitimi için yararlanılırken, test kümesi ise oluşturulan modelin doğruluğunu değerlendirmek amacıyla kullanılır.

Biyomedikal alanda, bir kişiye ait çok sayıda örnek verinin elde edilebilmesi makine öğrenimi ve veri madenciliği uygulamalarının yaygın olarak kullanılmasını sağlamaktadır. Ancak, bireylere ait verilerin hem eğitim hem de test kümesinde yer alması sınıflandırma sonuçlarının yanlı olmasına neden olabilir. Bu yanlılığı önlemek ve

daha doğru sınıflandırma sonuçları elde etmek için Bir-Bireyi-Dışarda-Bırakma (BBDB) çapraz doğrulama tekniği tercih edilmelidir. Bu uygulamada, her bir adımda test kümesi sadece bir bireye ait bütün gözlemleri içerirken o bireye ait hiçbir gözlem eğitim kümesinde yer almaz. Yöntemin başarısı da tüm verilere ait doğru sınıflandırma başarısının ortalaması alınarak belirlenir. Böylece, benzer gözlemleri içeren eğitim kümesinin oluşturduğu modellerdeki yanıltıcı sınıflandırmalar engellenmiş olur. Bu yaklaşım bireyden bağımsız sınıflandırma yaparak modelin genelleme yeteneğini artırmakta ve daha güvenilir sonuçlar elde edilmesine olanak tanımaktadır (Vaiciukynas vd., 2017)

Tez çalışması kapsamında makine öğrenimi uygulamalarında BBDB çapraz geçerleme yöntemi kullanılmıştır. Şekil 4.2'de uygulanan çapraz geçerleme yönteminin görseli yer almaktadır.

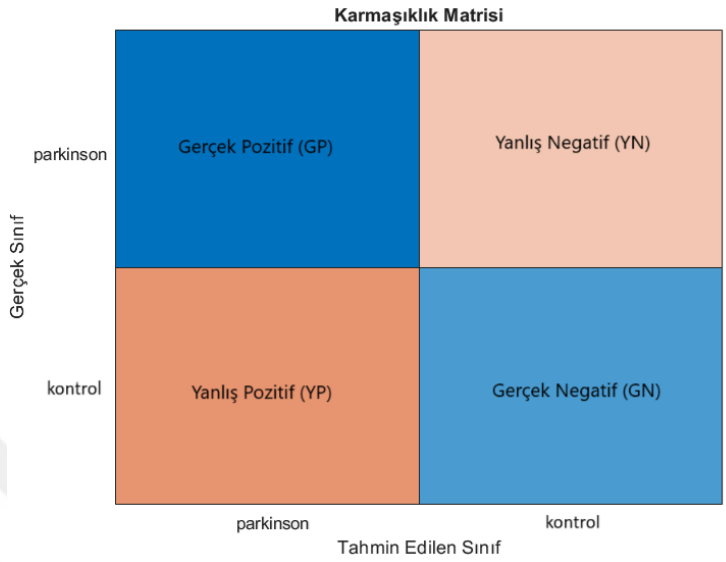


Şekil 4.2. Bir-bireyi- dışarda- bırakma (BBDB) çapraz geçerleme uygulaması

4.7. Model Performansının Değerlendirilmesi

Değerlendirme yöntemleri, sınıflandırıcının performansını anlamak ve geliştirmek için kritik öneme sahiptir. Başarı ölçütleri, her bir tahminin doğruluğunu belirlemek amacıyla gerçek sınıf etiketleriyle karşılaştırma yaparak hesaplanır. Sınıflandırıcı pozitif sınıfa ait bir örneği doğru şekilde pozitif olarak tahmin ediyorsa buna gerçek pozitif (GP) denir. Eğer yanlış bir sınıf olarak tayin ediyor ise bu örnek yanlış pozitif (YP) olarak adlandırılır. Benzer şekilde negatif sınıfta bulunması gereken bir

örneği sınıflandırıcı negatif olarak tahmin ediyorsa bu durum gerçek negatif (GN) olarak nitelendirilirken pozitif olarak tahmin edilirse yanlış negatif (YN) olarak tanımlanır.



Şekil 4.3. Sınıflandırıcı tahminine göre karmaşıklık matrisi

Şekil 4.3'te belirtilen ifadeler karmaşıklık matrisi için verilmiştir. Bu matristen elde edilebilecek modellerin sınıflandırma performanslarını değerlendirmek amacıyla kullanılan bazı değerlendirme ölçütleri aşağıda verilmiştir. Hastalık evre tayini gibi 3 sınıflı problemlerde her bir ölçüt sınıf bazında değerlendirir. Modelin genel başarısı ise her sınıf için ayrı hesaplanan bu değerlerin ortalaması alınarak belirlenmektedir.

4.7.1. Doğruluk

Sınıflandırma işlemi sonrasında modelin sınıflarını doğru tahmin ettiği verilerin tüm verilere oranını ifade eden bir ölçüttür. Yapılan tez çalışmasında ölçüt hasta ve sağlıklı bireylerin kaç tanesinin doğru sınıflarda tahmin edilebildiğini ifade etmektedir.

$$Doğruluk = \frac{GP+GN}{GP+YN+YP+GN} \tag{4.4}$$

4.7.2. Hassasiyet

Model tarafından hasta olarak tahmin edilmiş gerçek hasta sayısının tüm hasta sayısına oranlanmasıyla elde edilen bir ölçüttür.

$$Duyarlılık = \frac{GP}{GP+YN} \quad (4.5)$$

4.7.3. Kesinlik

Model tarafından hasta olarak sınıflandırılan verilerin kaç tanesinin gerçekten hasta sınıfına ait olduğu bilgisini veren istatistiksel bir orandır.

$$Kesinlik = \frac{GP}{GP+YP} \quad (4.6)$$

4.7.4. Özgüllük

Kullanılan sınıflandırıcı modellerin negatif sınıfı doğru tahmin edebilme oranını ifade eden bir kriterdir. Tez çalışmasında kontrol grubuna ait verilen kaç tanesinin gerçekten kontrol sınıfına ait olduğunu gösterir.

$$\text{Özgüllük} = \frac{GN}{GN+YP} \quad (4.7)$$

4.7. 5. F-ölçütü

Hassasiyet ve kesinlik ölçütlerinin harmonik ortalamasıyla hesaplanan F-ölçütü özellikle dengeli olmayan sınıflarda modelin başarısını gösteren önemli bir metriktir.

$$F_\text{ölçütü} = \frac{2\times Hassasiyet\times Kesinlik}{Hassasiyet+Kesinlik} \quad (4.8)$$

4.7.6. Matthews'in Korelasyon Katsayısı (MKK)

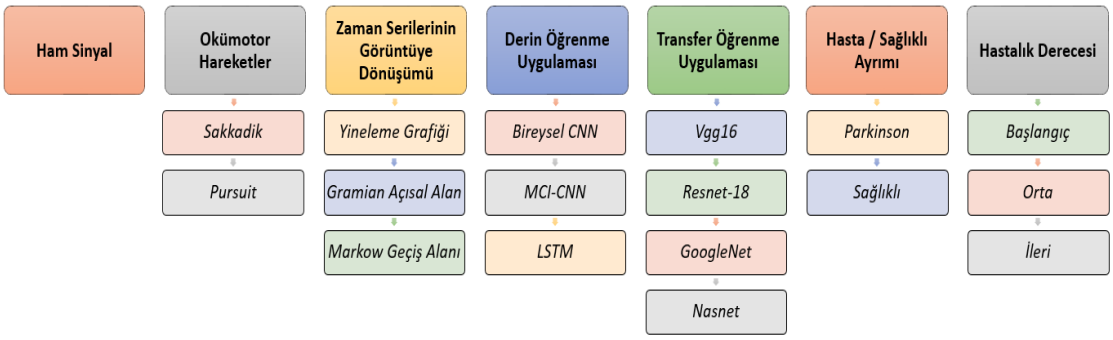
Matthews'in Korelasyon Katsayısı (MKK) sınıflandırma tahmin başarısını değerlendirmeye yönelik kullanılan bir ölçüttür. Özellikle veri setlerinde sınıf dengesizliğinin bulunduğu durumlarda bile, yapılan sınıflandırmaların rastgele olup olmadığını gösteren bir ölçüt olarak işlev görür. Bu katsayının değeri ±1 arasında değişir. Modelin doğruluğu arttıkça katsayı +1'e yaklaşırken, yanlış sınıflandırmaların oranı yükseldikçe değer -1'e yaklaşır. Eğer sınıflandırmalar tamamen rastgele yapılırsa, MKK değeri sıfıra yakın olur.

$$MKK = \frac{(GP\times GN)-(YN\times YP)}{\sqrt{(GP+YN)(GP+YP)(GN+YN)(GN+YP)}} \quad (4.9)$$

BÖLÜM 5

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK VNG VERİLERİ İLE PH VE EVRE TESPİTİ

Bu bölümde, öncelikle derin öğrenme uygulamalarından bahsedilmiştir. Ayrıca tez çalışması kapsamında uygulanan derin öğrenme yöntemlerinde izlenen yol ve kullanılan mimariler hakkında genel bilgilendirme yapılmıştır. Tezde izlenen derin öğrenme uygulamalarının adımları ve kullanılan yöntemler Şekil 5.1'de özetlenmiştir.



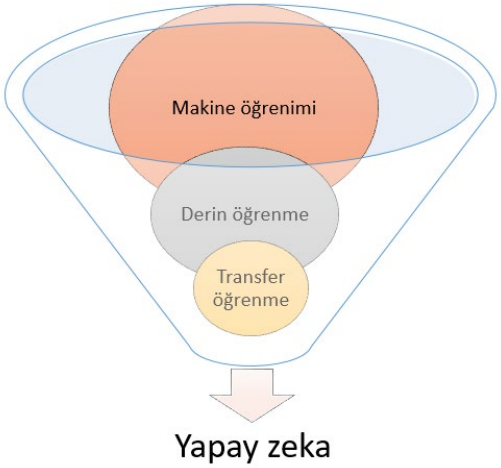
Şekil 5.1. Derin öğrenme uygulamaları işlem basamakları

5.1 Derin Öğrenme

Veri miktarlarının hızla arttığı günümüzde, bu büyük veriyle başa çıkabilmek ve anlamlı sonuçlar elde edebilmek için daha karmaşık model yapıları ve yeni algoritmalar geliştirilmesi kaçınılmaz hale gelmiştir. 1980'lerin sonlarına doğru yapay sinir ağları, makine öğrenmesi ve yapay zekâ gibi alanlar büyük ilgi görmeye başlamıştır. Derin öğrenme Şekil 5.2'de de görüldüğü üzere, makine öğrenimine ait daha özelleştirilmiş bir alt yapay zekâ uygulamasıdır. Bu alandaki temel amaç, bilgisayara bir görevi nasıl yerine

getireceğini öğretmek değil, bunun yerine bilgisayarın verilerden kendi başına öğrenerek bu görevi nasıl tamamlayacağını keşfetmesidir (Hinton vd., 2006).

Derin öğrenme geleneksel makine öğrenimi yaklaşımlarından farklı olarak, çok katmanlı sinir ağları yapısından faydalanarak verilerden daha derin ve anlamlı çıkarımlar yapar (Bengio vd. 2017). Başta görüntü tanıma, ses dosyalarını metne dönüştürme ve doğal dil işleme gibi zorlu problemlerin çözümünde etkili görev almasının yanında sağlık alanında özellikle medikal görüntü analizinde, hastalık tanı ve sınıflandırmada, kişiselleştirilmiş tıp ve tedavi planlaması gibi çeşitli alanlarda da başvurulan yöntemler arasındadır.

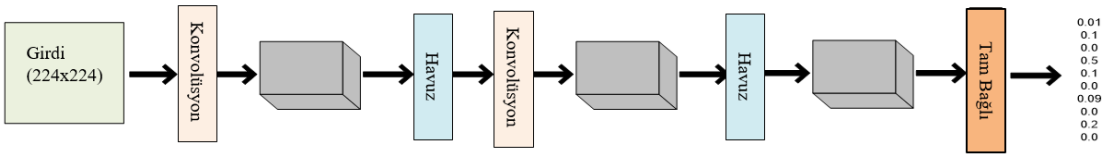


Şekil 5.2. Yapay zeka ve alt bileşenleri

5.1.1. Konvolüsyonel (Evrişimli) Sinir Ağları

Konvolüsyonel Sinir Ağları (CNN), temel derin öğrenme algoritmalarından biri olarak, özellikle görüntü işleme ve bilgisayarlı görü gibi alanlarda önemli bir yere sahiptir. Bu algoritmalar, verileri çok katmanlı bir nöron yapısı üzerinden işlemektedir. Giriş katmanından başlayarak sırasıyla gizli katmanlar ve çıktı katmanına doğru ilerleyen CNN'ler, her katmanda verilerin daha derin özelliklerini öğrenerek karmaşık ilişkileri modelleyebilir (O'Shea ve Nash, 2015). Katmanlar arasında ağırlıklarla birbirine bağlanan nöronlar, verilerin anlamlı bir biçimde işlenmesini ve doğru çıktılar elde edilmesini sağlar. Gizli katmanlarda yer alan evrişimli katmanlar, verilere ait daha anlamlı özelliklerini çıkarmak için kritik bir rol oynar, bu da modelin doğruluğunu

artırarak etkili sonuçlar elde edilmesine olanak tanır (Hinton vd., 2006). Şekil 5.3'te temel CNN mimarisine ait bir örnek gösterilmektedir.



Şekil 5.3. Temel Konvolüsyon Sinir Ağı

5.1.1.1. Evrişim katmanı

Evrişim katmanı, CNN mimarisinin en önemli bileşenlerinden biridir ve temel işlevi, görüntülerden önemli özellikleri çıkarmaktır. Bu katman, bir dizi konvolüsyon filtresinden oluşur. Her filtre, bir çekirdek (kernel) matrisiyle belirlenir ve bu çekirdek, eğitim sürecinin başında rastgele ağırlıklarla atanır. Eğitim boyunca çekirdek, ağın doğru özellikleri çıkarabilmesi için ayarlanır. CNN, çok kanallı görüntüleri işleyebildiği için, evrişim işlemi yalnızca tek bir vektör formatında değil, çoklu kanallara sahip bir görüntü formatında yapılır. Bu sayede, çok boyutlu veriler üzerinde derinlemesine analizler yapılmaktadır (Bengio vd. 2017; Indolia vd., 2018).

5.1.1.2. Havuzlama Katmanı

Havuzlama katmanı, derin öğrenme modellerinde özellikle görüntü işleme görevlerinde kritik bir rol oynamaktadır. Bu katman, giriş verisinin boyutunu azaltarak daha karmaşık katmanların hesaplama yükünü hafifletir ve modelin daha hızlı çalışmasını sağlar. Havuzlama işleminde genel olarak maksimum havuzlama (max pooling) yöntemi tercih edilmektedir. Görüntü belirli alt bölgelere ayrılır ve her bir alt bölgeden yalnızca en yüksek değer seçilir. Örneğin, 2x2 boyutunda bir filtre kullanılarak uygulanan maksimum havuzlama işlemi, her adımda 2 birim kayarak sağa veya aşağıya hareket eder (Bengio vd., 2017).

Havuzlama katmanının temel amacı veri boyutunu küçültmek olsa da, bu işlem sırasında filtre sayısı değişmez. Yani, havuzlama katmanı yalnızca verinin boyutlarını azaltırken, modelin öğrenme kapasitesini etkileyen özelliklerin sayısını korur. Bu özellik,

derin öğrenme ve yapay sinir ağlarının performansını artırırken aynı zamanda aşırı uyumu önlemeye yardımcı olur.

5.1.1.3. Tam Bağlı Katman

Tam bağlantılı katman, derin öğrenme mimarilerinde önemli bir rol oynar ve geleneksel sinir ağlarındaki nöron düzenine benzer bir yapı sunar. Her bir düğüm, önceki katmandaki tüm düğümlere doğrudan bağlanarak, verilerin işlenmesine olanak tanır. Bu katman, havuzlama katmanından gelen çıktıları alır ve bu verileri düzleştirerek bir vektör haline dönüştürür (Bengio vd., 2017). Tam bağlantılı katmanın en büyük avantajı, karmaşık ilişkilerin öğrenilmesine olanak tanımasıdır; ancak, çok sayıda parametre içermesi nedeniyle eğitim süreci genellikle uzun ve hesaplama açısından yoğun olur. Bu durum, modelin performansını olumsuz etkileyebilir ve aşırı uyum (overfitting) riskini artırabilir.

Bu nedenle, tam bağlantılı katmanda düğüm ve bağlantı sayısının azaltılması kritik bir ihtiyaç haline gelir. Bırakma (dropout) gibi teknikler kullanılarak, modelin genel performansını artırmak ve aşırı uyumu önlemek için düğümlerin rastgele devre dışı bırakılması sağlanır. Bu yöntem, modelin daha genelleyici olmasına katkıda bulunur ve eğitim sürecinin daha verimli hale gelmesini sağlar.

5.2. Transfer Öğrenme

Transfer öğrenme, özellikle sınırlı veri, yetersiz hesaplama gücü ve zaman kısıtlamaları gibi zorluklarla başa çıkmak için geliştirilmiş etkili bir tekniktir. Bu yaklaşım, daha önce büyük veri kümeleri ile eğitilmiş bir modelin öğrendiği bilgileri yeni bir görevde kullanarak daha iyi başlangıç noktaları sağlar. Yani, uzun süre eğitim almış bir modelin sahip olduğu özellikler ve ağırlıklar, benzer bir görevde yeniden kullanılabilir. Bu sayede, sıfırdan yeni bir model eğitmek yerine önceden eğitilmiş bir modelin bilgi birikiminden faydalanarak daha hızlı ve verimli bir eğitim süreci elde edilir. Transfer öğrenme, daha az veriyle çalışarak daha hızlı ve başarılı modeller geliştirilmesine olanak tanır.

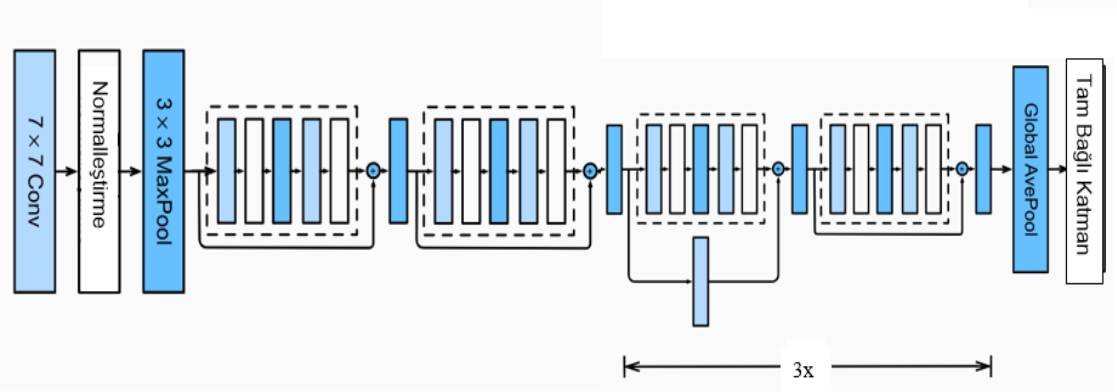
Tıpkı insanların problemi çözmek için önceki deneyimlerini kullanarak çözüme daha hızlı ulaşmaları gibi transfer öğrenme sayesinde büyük veri kümeleriyle eğitilmiş

bir modelin öğrendiği ağırlıklar, daha küçük ve etiketlenmiş verilerle eğitilen başka bir modelde kullanılabilir. Böylelikle, veri setinin boyutu küçük olsa da, daha önce elde edilen bilgiler yeni bir görevde etkili bir şekilde uygulanabilir.

Bu tez çalışmasında görüntü türüne dönüştürülen zaman serileri önceden eğitilmiş Residüel Sinir Ağları (ResNet18), Görsel Geometri Grubu (Visual Geometry Group, VGG16) ağı, Sinir Mimarisi Araması Ağı (Neural Architecture Seerch,NasNet) ve GoogLeNet modellerine girdi olarak verilmiştir.

5.2.1. Residüel Sinir Ağları Mimarisi

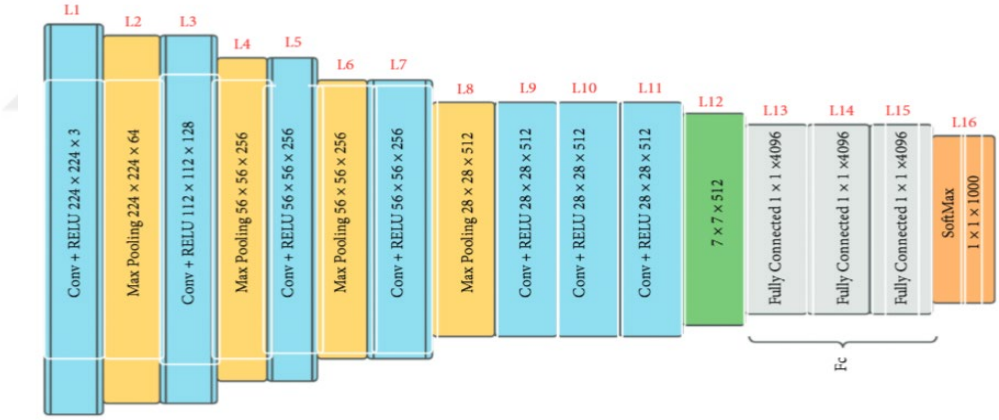
Derin öğrenme alanında aşırı öğrenme problemini çözmek için amacıyla 2015 yılında Microsoft Research tarafından geliştirilen "Residual Network" (ResNet) mimarinin temel özelliği, bazı katmanların gelen veriyi atlayarak doğrudan çıkışa bağlanmasıdır. Bu yapıya "residual connection" (artık bağlantı) denir. Bu bağlantılar, ağın öğreneceği bağlantıları kolaylaştırarak öğrenme kapasitesini artırır ve böylece aşırı öğrenmeyi azaltmada etkili olur (He vd., 2016). Bu nedenle, ResNet daha derin bir yapıya sahip olmasına rağmen VGG ağlarına kıyasla daha düşük bir karmaşıklığa sahiptir ve etkileyici sonuçlar elde eder. ResNet'in farklı katman sayısına sahip ResNet-18, ResNet-50 ve ResNet-101 olmak üzere farklı çeşidi bulunmaktadır.Tez çalışması kapsamında uygulanan mimari 18 katmanlı yapıya sahip Resnet18'dir. Şekil 5.4'te Resnet18 mimarisinin temel gösterimi bulunmaktadır.



Şekil 5.4. ResNet18 mimarisi

5.2.2. VGG

Oxford Üniversitesi'nde *Visual Geometry Group* (VGG) tarafından geliştirilmiş, geniş bir kullanım alanına sahip konvolüsyonel sinir ağı (CNN) mimarisidir. VGG16 ve VGG19 olmak üzere iki farklı mimari yapısı bulunmaktadır. Tez çalışmasında kullanılan VGG16 modeli, Şekil 5.5'tegösterildiği gibi 13 konvolüsyonel katman ve 3 tam bağlantılı katmandan oluşan basit ama güçlü bir derin öğrenme mimarisidir. Konvolüsyonel katmanlar, görsel verilerden özellikler çıkarmak için kullanılırken, tam bağlantılı katmanlar ise modelin çıktısını sınıflandırmak için kullanılır (Hasan vd. 2021). VGG16'nın temel yapısında 3x3 konvolüsyonel filtrelerin kullanımı, modelin daha derin katmanlarla soyut özellikleri öğrenmesine olanak sağlar. Basit ancak derin yapısı nedeniyle büyük hesaplama gücü gerektiren bir modeldir. Buna rağmen, transfer öğrenme ile VGG16'nın güçlü özelliklerinden faydalanarak, daha küçük veri kümeleriyle bile yüksek performans elde etmek mümkündür.

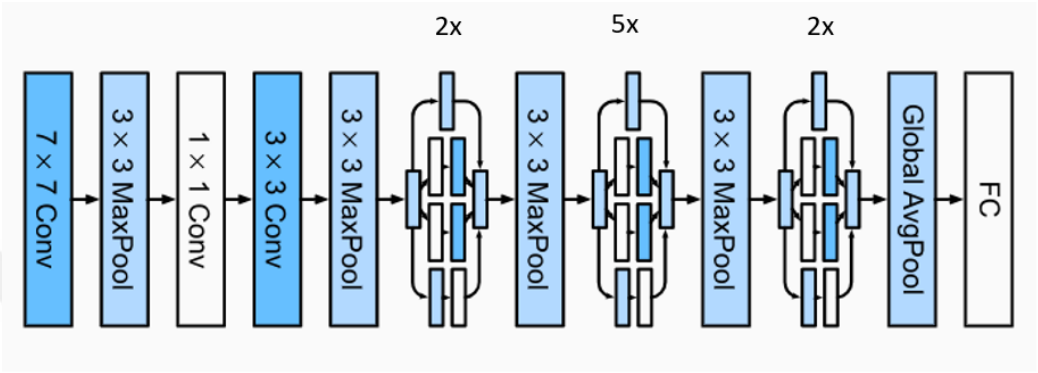


Şekil 5.5. VGG16 mimarisi (Hasan vd. 2021).

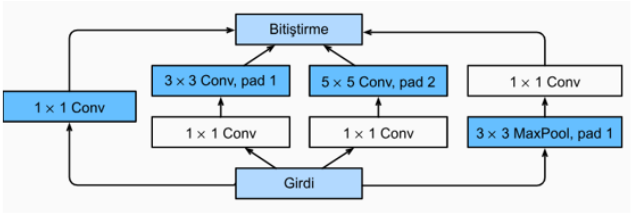
5.2.3.GoogLeNet Mimarisi

GoogLeNet, geleneksel CNN mimarilerinden önemli farklılıklar gösteren bir yapıya sahiptir. Modelin temel özelliği Şekil 5.6(b) de belirtildiği gibi başlangıç blok yapısını kullanmasıdır. Bu yapılar, farklı büyüklükteki konvolüsyonel filtreleri paralel olarak uygular ve çıktılarını birleştirir. Bu sayede model, farklı ölçeklerdeki özellikleri aynı anda çıkararak problemle ilgili daha zengin temsiller oluşturabilir. Başlangıç blokları

ağın daha verimli çalışmasına olanak tanı ancak modelin derinliğini de artıran bir yapıdır. GoogLeNet mimarisinin diğer önemli özelliği de küresel ortalama havuzlama (*global average pooling)* katmanının kullanımıdır. Bu katman, diğer geleneksel mimarilerdeki tam bağlantılı katmanların yerine kullanılır ve özellik haritasının ortalamasını modelin aşırı öğrenme riskini azaltarak genelleme kabiliyetini artırır (Szegedy vd., 2015).



(a) GoogLeNet mimarisi



(b) GoogLeNet başlangıç blok yapısı

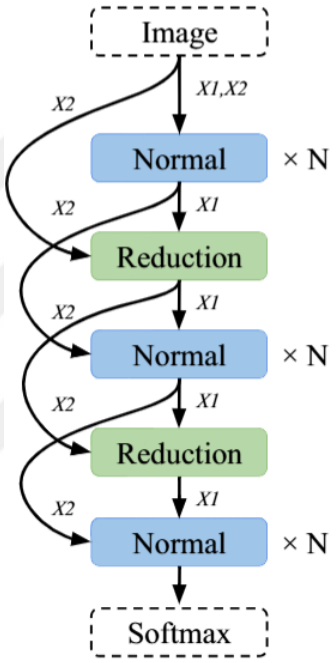
Şekil 5.6. GoogLeNet mimari yapısı

5.2.4. Sinir Mimarisi Araması Ağı

Sinir Mimarisi Araması Ağı (Neural Architecture Search, NasNet), Google Brain ekibi tarfından önerilen derin öğrenme modellerinin performansını artırmayı amaçlayan yenilikçi bir yaklaşımdır (Zoph vd., 2018). NASNet'in mimarisinin temelinde, her katman için bir dizi hücre tasarımı yer alır. Bu hücreler, konvolüsyon ve havuzlama katmanları gibi farklı tiplerdeki katmanları içerir. Hücrelerin yapıları NAS algoritması tarafından otomatik olarak optimize edilir. Böylece, kendini optimize eden ve görev için en uygun yapıyı keşfeden bir mimari elde edilmiş olur. En uygun modeli bulurken ağın temel yapı taşlarını (örneğin, konvolüsyonel katmanlar) keşfetmek yerine, küçük yapı

taşlarını (hücreleri) optimize eder ve bu hücreleri daha büyük ağlarda birleştirerek en iyi performansı elde etmeyi amaçlar.

Ayrılabilir evrişim ve ortaklama gibi basit bloklardan oluşması model karmaşıklığının azaltmasını sağlayan bir etkendir. Bu özellik mimarinin yüksek doğruluk oranları elde edilmesine olanak tanır. Özellikle, modelin performansını artırmak için kullanılan pekiştirmeli öğrenme yöntemi, eğitim sürecinde daha etkili sonuçlar elde edilmesini sağlar.



Şekil 5.7. NasNet mimarisi (Termritthikun vd., 2023)

5.3. Uzun-Kısa Vadeli Bellek

Uzun-kısa vadeli bellek (Long Short-Term Memory, LSTM) modeli, derin öğrenme ve yapay sinir ağları alanında özellikle zaman serisi verilerinin işlenmesi ve sıralı verilerin analizi konusunda önemli bir yere sahiptir. LSTM bir tür geri beslemeli yapay sinir ağı (Recurrent Neural Network, RNN) mimarisidir. Geleneksel RNN mimarisi her ne kadar zaman serisi gibi sıralı veriler için geliştirilmiş olsa da sıralı verilerin önceki adımlarından gelen bilgiyi unutmaya meyilli bir yapıya sahip olduğu için serilerdeki uzun süreli bağımlılıkları öğrenmekte sıkıntı yaşamaktadır. LSTM mimarileri ise sıralı verilerdeki bilgilerin ne zaman unutulup ne zaman hatırlanacağını öğrenebilen

unutma ve hatırlama mekanizması içeren özel hücre yapılarıyla RNN'de yaşanan öğrenme sıkıntısını gidermek için geliştirilmiştir (Gref vd., 2016).

LSTM mimarilerinde bulunan hücrelerde bilgi akışı üç ana kapı tarafından düzenlenir. İlk olarak, *unutma kapısı* geçmiş hücre durumundan hangi bilginin silineceğini belirler. Bu kapı, 0 ile 1 arasında bir değer üretir. 0 değeri bilgilerin tamamen silineceğini, 1 değeri ise bilginin tamamen saklanacağını ifade eder (Hu vd., 2020; Landi vd., 2021). G*iriş kapısı* ise yeni verilerin ne kadarının hücreye eklenmesi gerektiğine karar verir. Bu kapı hangi değerlerin güncellenmesi gerektiğini belirleyen ve güncellemelerin önem derecesini ölçen iki bileşenden oluşur. Güncellenme sürecinde unutma kapası tarafından silinen bilgiler dışlanırken, giriş kapasıyla yeni bilgiler hücreye eklenmektedir. Son olarak, *çıkış kapısı* ise hücrenin mevcut durumuna bakarak hangi bilginin dışarıya aktarılacağını belirler. Bu çıkarılan bilgi, bir sonraki zaman adımına veya modelin nihai sonucuna aktarılır (Landi vd., 2021). Bu kapıların öğrenme süreci boyunca her bir zaman adımında elde edilen bilgilere göre sigmoid ve tanh aktivasyon fonksiyonları ile güncellenmesi LSTM mimarisinin sıralı verilerdeki uzun vadeli ilişkileri ve sinyal üzerindeki farklılıkları daha iyi öğrenebilmesine yardımcı olur (Smagulova ve James, 2019).

BÖLÜM 6

DENEYSEL SONUÇLAR

Bu tez çalışması doğrultusunda yürütülen uygulamalardaki temel amaç sağlıklı kontrol ve hasta katılımcılardan elde edilen okülomotor göz hareket sinyalleri ile ilk etapta Parkinson hastalarını sağlıklı bireylerden ayırmak, sonrasında ise hasta bireyleri evrelerine göre derecelendirmesini yapmaktır. Bu sebeple, klinik öneme de sahip sakkadik göz hareketlerine öncelik verilmiş, bu sinyallerden farklı yapay zeka yaklaşımları ile öznitelikler çıkartılmış ve farklı sınıflandırıcılar ve mimarilerle oluşturulan modellerin Parkinson hastalığının tespitinde ve evre tayinindeki başarısı incelenmiştir. Ayrıca makine öğrenimi uygulamalarında iki aşamalı öznitelik seçme tekniği uygulanarak problemle ilgili en betimleyici öznitelikler belirlenmiş, derin öğrenme mimarilerinden elde edilen derin özniteliklerin klasik makine öğrenimi uygulamalarındaki sınıflandırma başarı performansları karşılaştırılmıştır.

Tezin bu bölümünde yürütülen çalışmada önerilen yöntemlere ait sırasıyla makine öğrenimi uygulamaları ile derin öğrenme yöntemlerine ait deneysel sonuçlar ve son olarak da hem derin hem makine öğrenimi uygulamalarının birlikte kullanıldığı hibrit yaklaşıma ait bugulara yer verilmiştir.

6.1. Makine Öğrenimi Uygulamaları

Tez çalışmasında kullanılan özniteliklerin çıkartılmasında hem Pyhton Tsfel kütüphanesinden hem de MATLAB (MathsWorks, 2024b) sinyal işleme fonksiyonlarından yararlanılmıştır. Ayrıca, verilerin işlenmesi, sakkadik ve pursuit göz hareketlerinin hastalıkla ilişkili özniteliklerinin belirlenmesi ve sonrasında sınıflandırılması MATLAB ile yürütülmüştür.

Hasta ve sağlıklı bireylere ait sakkadik ve pursuit göz hareket sinyallerinin Çizelge 4.1'de belirtilen istatistiksel, zamansal, fraktal ve spektral özelliklerine ait yeni öznitelikler çıkarılmıştır. Bu öznitelikler kullanılarak oluşturulan makine öğrenmesi tabanlı model ilk aşamada hasta sağlıklı ayrımı yaparken, sonraki aşamada Parkinson hastası bireyleri evrelerine göre sınıflandırmayı amaçlamaktadır. Bu kapsamda verilere (-1,+1) normalizasyon işlemi uygulandı ve sınıflandırma algoritmalarında BBDB çapraz geçerleme yöntemi tercih edildi. Farklı uzaklık ölçütleri ve komşuluk değerlerinin incelendiği k-EYK algoritmasının yanı sıra, Naive Bayes (NB), destek vektör makineleri (DVM) ve kuadratik diskriminant analiz (KDA) yöntemlerinin model performans başarısı doğruluk, hassasiyet, kesinlik, özgüllük, Matthew Korelasyon Katsayısı (MKK) ve F-skor ölçütleri ile incelendi.

DVM algoritmasında LibSVM (Chang, 2011) gerçekleştirmesi kullanılmıştır. Doğrusal, radyal, polinomal ve sigmoid çekirdek türleri de ayrı ayrı test edilmiş, en iyi sonuç veren çekirdek türünün C değeri 1 ve g değeri 0,001 olan doğrusal çekirdek türü olduğu tespit edilmiştir. Hasta-sağlıklı ayrımı amacıyla k-EYK algoritması kullanılarak oluşturulan modellerde ilk etapta Öklid, Manhattan, Chebyshev ve Minkowski gibi uzaklık ölçütleri ile 3, 5, 7 ve 9 komşu değerlerinin sınıflandırma başarısı test edilmiştir. Yapılan deneysel çalışmalarda %66,9 ile %78,5 arasında doğruluk elde ederken en iyi sınıflandırmayı k komşu değeri 3 ve Chebyshev uzaklık ölçütünün birlikte kullanılması elde etmiştir. Çizelge 6.1 (a) ve Çizelge 6.1 (b) sırasıyla sakkadik göz hareketleri ve pursuit göz hareketleri ile en yüksek sınıflandırma başarısı gösteren k- EYK sınıflandırıcı ile DVM, NB ve KDA algoritmalarının elde ettiği sonuçları içermektedir.

Çizelge 6.1. Makine öğrenmesi sınıflandırıcıların hasta-sağlıklı ayrımı sonuçları

(a) Sakkadik göz hareketlerine ait sonuçlar

Sınıflandırıcı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
k-EYK	78,57	79,46	78,07	77,68	0,788	0,572
DVM	**91,51**	**91,07**	**91,89**	**91,96**	**0,915**	**0,830**
NB	78,57	66,96	87,21	90,18	0,758	0,587
KDA	70,09	53,57	80,00	86,61	0,642	0,426

(b) Pursuit göz hareketlerine ait sonuçlar

Sınıflandırıcı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
k-EYK	87,05	**96,43**	81,20	77,68	0,882	0,754
DVM	**89,73**	88,39	**90,83**	91,07	**0,896**	**0,795**
NB	77,23	61,61	89,61	**92,86**	0,730	0,573
KDA	62,05	31,25	81,40	92,86	0,452	0,306

Çizelge 6.1 (a)'da yer alan sonuçlar değerlendirildiğinde tüm değerlendirme ölçütlerinde DVM algoritmasının % 91.51 doğruluk oranıyla hasta sağlıklı ayrımında kullanılan diğer yöntemlere göre oldukça üstün bir sınıflandırma başarımı sergilediği görülmektedir. Ayrıca, sakkadik göz hareket sinyallerinden çıkartılan spektral, istatistiksel, zamansal ve fraktal özelliklerin DVM sınıflandırıcıyla % 91,07 hassasiyetle hastalığın varlığını tespit edebildiği görülmüştür.

Çizelge 6.1 (b)'de yer alan pursuit göz hareketi verilerine göre DVM algoritması yüksek doğruluk, hassasiyet, özgüllük ve F-skoru ile en yüksek performansı sergileyerek hasta ve kontrol sınıflarını genel olarak daha dengeli ve başarılı bir şekilde ayırt etmektedir. k-EYK algoritması özellikle hastaları tanımada etkili olup, özgüllük ve MKK değerleri DVM'ye göre daha düşük olduğu için daha az dengeli bir performans göstermiştir. NB ise sağlıklı sınıfı doğru tanımada iyi bir özgüllük sonucu sunsa da genel doğruluk ve hassasiyet gibi metriklerde daha düşük performans sergilemiştir.

Çizelgelerden elde edilen sonuçlarda makine öğrenimi modellerinin her birinin farklı derecelerde başarı göstermesinin nedeni sakkadik ve pursuit göz hareketlerinin farklı doğasının etkili olduğu düşünülmektedir. Pursuit hareketler genellikle daha istikrarlı bir hareket desenine sahip olduğundan bazı sınıflandırıcılar bu tür hareketleri daha iyi anlayabilir. Özellikle k-EYK algoritması ve pursuit hareketlerin birlikte kullanıldığı modelin sakkadik hareketlere göre daha yüksek başarı elde etmesi, algoritmanın sakkadik hareketlerdeki hızlı değişimleri anlamada kısmen yetersiz kaldığını göstermektedir.

Çalışmanın diğer aşamasında Parkinson hastası bireyler için hastalık evre tayini üzerine çalışma yürütülmüştür. Bir önceki hasta-sağlıklı ayrımında kullanılan sınıflandırma yöntem ve modelleri evre tayini için de kullanılmıştır. Bu aşamada, geliştirilen modellerde evreler Hoehn&Yahr ölçeğinden yola çıkılarak temelde erken,

orta ve ileri evre olmak üzere 3 ana sınıf olarak etiketlenmiştir. Çizelge 6.2 (a) ve Çizelge 6.2 (b)'de sırasıyla hastalık derecelendirmede k- EYK, DVM, NB ve KDA sınıflandırıcıların sakkadik ve pursuit göz hareketlerinden elde ettiği sonuçlara yer verilmiştir.

Çizelge 6.2. Makine öğrenmesi sınıflandırıcılarının hastalık evre tayini sonuçları

(a) Sakkadik göz hareketlerine ait sonuçlar

Sınıflandırıcı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
k-EYK	74,10	94,20	72,22	41,86	0,818	0,441
DVM	**94,64**	**97,10**	**94,37**	**90,70**	**0,957**	**0,886**
NB	75,00	81,15	78,87	65,12	0,800	0,467
KDA	62,50	62,16	100.00	20,33	0,767	0,120

(b) Pursuit göz hareketlerine ait sonuçlar

Sınıflandırıcı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
k-EYK	70,54	92,75	69,57	34,88	0,795	0,351
DVM	82,14	88,41	83,56	72,09	0,859	0,618
NB	**84,82**	91,30	**85,14**	**74,42**	**0,881**	**0,675**
KDA	61,61	**100,00**	61,61	0,00	0,762	0,00

Çizelgedeki sonuçlar değerlendirildiğinde her bir göz hareketinin hastalığın evrelerinin belirlenmesinde farklı derecelerde etkili olduğu görülmektedir. Hastalığın erken evrelerinde sakkadik göz hareketlerinde oluşan farklılıkları DVM daha iyi doğruluk ve diğer metriklerde yüksek değerler elde ederek yakalamayı başarmıştır.

Hassasiyet ölçütü, herhangi bir tıbbi durumun varlığını veya yokluğunu bildiren biyomedikal bilimde önemli bir değerlendirme ölçütüdür. Yapay zeka tabanlı geliştirilen modellerde o duruma sahip olanları doğru bir şekilde tahmin etme yeteneğinin başarısını verir. Sakkadik hareketlerin daha düşük doğrulukla daha yüksek hassasiyet elde etmesi hastalığın başlangıç evrelerinde bile sakkadik hareketlerin etkili bir gösterge olabileceğini ancak daha ileri evrelerde bu hareketlerin daha zorlayıcı hale gelmesi nedeniyle doğruluk oranında düşüş yaşandığını göstermektedir. Pursuit hareketlerinin elde ettiği hassasiyet değerleri genellikle yüksek, ancak özgüllük oranlarının daha düşük olduğu görülmüştür. Bu durum PH'deki dopamin eksikliğinin hareketli bir hedefi izlemek için gerekli olan

göz kaslarını koordine etme yeteneğini azaltan bir durum olması nedeniyle hastalığın ilerleyen evrelerinde daha pursuit hareketlerin ön plana çıkan bir belirteç olabileceğini göstermektedir.

F-skor ise, özellikle dengeli veri dağılımına sahip olmayan veri kümelerinde modelin doğruluğunun bir ölçüsüdür. Başarılı bir sınıflandırma modelinde bu ölçütün 1 değerine yakın olması beklenir. Çizelge 3.2'de verilen evrelere göre hasta dağılımının eşit sayılarda olmadığı görülmektedir. Tez çalışması kapsamında önerdiğimiz makine öğrenmesi tabanlı sistemin gerek hasta-sağlıklı ayrımında gerekse de hastalık evre tayininde geliştirilecek yapay zeka yöntemlerinde %84,8-%94,6 doğrulukla ve 0,88-0,95 F-skor değerleriyle başarılı sonuçlar alan DVM sınıflandırma algoritmasının kullanılmasının diğer sınıflandırma modellerine göre daha avantajlı olduğu gözlenmiştir.

6.1.1 İki Aşamalı Öznitelik Seçim Yöntemi Uygulamasını Etkisi

Öznitelik sayısının miktarı sınıflandırma performans başarımı ve işlem süresi üzerinde önemli bir etkiye sahiptir. Sinyallerden elde edilen 140 özniteliğin tamamını kullanmak yerine hastalıkla ilişkisi yüksek özniteliklerin seçilmesi problem çözümüne yönelik hem işlem sayısını azalmasına hem de modelin öğrenme karmaşıklığını azaltarak sınıflama başarısını artmasına destek sağlar.

Çalışmada, hasta ve sağlıklı bireyler arasındaki ayrımın yanı sıra hastalık evrelerinin derecelendirilmesinde kullanılacak en etkili özniteliklerin belirlenmesi için iki aşamalı bir öznitelik seçim yöntemi önerilmiştir. İlk aşamada zaman serilerinden elde edilen 140 öznitelik spektral, zamansal, istatistiksel ve fraktallık kategorilerine ayrılmıştır. Bu özniteliklere Spearman sıralama korelasyonu uygulanarak önem sırasına göre sıralama yapılmıştır. Bu işlem öznitelikler arasındaki ilişkilerin hızlı bir şekilde belirlenmesi ve önemli olanların seçilmesi amacıyla bir ön filtreleme sağlamıştır. Sonuç olarak, bu aşamada kullanılacak ilk 70 öznitelik belirlenmiştir.

İkinci aşamada ise Özyinelemeli Öznitelik Eliminasyonu (ÖÖE) yöntemi kullanılarak ön filtrelemeden geçen 70 öznitelik arasından yalnızca modelin öğrenmesi için kritik öneme sahip olanlar seçilmiştir. Bu uygulama sonucunda Çizelge 6.3 ve Çizelge 6.5'te sakkadik, Çizelge 6.7 ve Çizelge 6.9'da ise pursuit hareketler için en

belirleyici ilk 20 öznitelik verilmiştir. Elde edilen öznitelikler hem Parkinson hastası hem de sağlıklı bireylerden elde edilen göz sinyal verilerine uygulanmış ve hastalığın teşhisinde en etkili özniteliklerin katkıları DVM, NB, k-EYK ve KDA sınıflandırma algoritmaları ile ölçülmüştür.

A. Sakkadik Göz Hareket Verileri

Sakkadik göz hareketleri genellikle çevreden gelen görsel bilgileri tararken ortaya çıkan hızlı, ani ve kesintili hareketlerdir. Çizelge 6.3'te yer alan bilgilere göre sinyalin spektral özelliklerinin hastalıkla ilişkili bilgi çıkarımlarında daha etkin rol oynadığı görülmektedir. Merkezi sinir sisteminin ortamdaki çevresel uyaranlardan ne kadar bilgi toplandığı ve göz hareketlerinin bu bilgilere nasıl tepki verdiği sinyalin fraktallık özelliklerine göre analiz edilebilir. *Yeniden ölçeklendirilmiş aralık analizi*, *Higuchi fraktal boyutu* gibi sinyallerin fraktallığına ait özniteliklerin seçim algoritmaları tarafından en belirleyici öznitelikler arasında tercih edilmesi de sakkadik hareketlerin her ne kadar belirli bir zaman diliminde düzensiz gibi görünseler de farklı bir zaman diliminde hastalıkla ilgili izlerin çıkarılabileceğini göstermektedir.

Çizelge 6.3. Hasta-sağlıklı ayrımında sakkadik göz hareketlerine göre iki aşamalı öznitelik seçim yöntemi sonrası tayin edilen ilk 20 öznitelik

Öznitelik Adı	
Yeniden ölçeklendirilmiş aralık analizi	Spektral düşüş
Sinyal mesafesi	Ortanca mutlak fark
Spektral varyans	Dalgacık enerjisi 4
Ortanca mutlak sapma	Dalgacık standart sapması 4
Higuchi fraktal boyutu	Dalgacık varyansı 4
Histogram	Dalgacık enerjisi 2
Dalgacık enerjisi 3	Dalgacık standart sapması 2
Dalgacık standart sapması 3	Dalgacık varyansı 2
Dalgacık varyansı 3	İnsan menzili enerjisi
Ortanca	Güç bant genişliği

Çizelge 6.4, tez çalışması kapsamında hasta-sağlıklı ayrımı probleminde geleneksel makine öğrenimi yaklaşımlarında kullanılmak üzere önerilen iki aşamalı öznitelik seçim yöntemi sonrası elde edilen sakkadik göz hareketlerine ait yeni öznitelik alt-kümelerinin sınıflandırma başarım sonuçlarını göstermektedir.

Çizelge 6.4. Sakkadik göz hareketleri ve makine öğrenmesi sınıflandırıcıların öznitelik seçimi sonrası en belirleyici 20 öznitelik ile elde ettiği hasta-sağlıklı ayrımı sonuçları

Sınıflandırıcı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
k-EYK	83,93	86,61	81,25	82,20	0,843	0,680
DVM	**93,75**	**87,50**	**100,00**	**85,83**	**0,933**	**0,882**
NB	77,68	71,43	83,93	81,63	0,762	0,558
KDA	69,64	63,39	75,89	72,45	0,676	0,396

Çizelgelerden elde edilen görüldüğü üzere öznitelik seçiminin etkilerine bakarak, bu iki aşamalı öznitelik seçimin hasta-sağlıklı ayrımı probleminde K-EYK ve DVM sınıflandırıcılarında doğru şekilde uygulandığı ve sonuçların iyileştirilmesine katkı sağladığı görülmüştür. NB ve KDA sınıflandırma yöntemleri genellikle daha basit ve daha hızlı modeller olmasına rağmen hasta sağlıklı ayrımında DVM ve k-EYK sınıflandırıcılarına göre daha az başarı sergilemesi bu algoritmaların verinin doğrusal olmayan ve karmaşık yapıların varlığında öznitelikler arası ilintileri yeterince modelleyememesi olabilir.

Çizelge 6.5, PH'nin sakkadik göz hareketleri kullanılarak hastalığın evre tayini için seçilen öznitelikleri sunmaktadır. Bu öznitelikler, iki aşamalı bir seçim süreci sonucunda belirlenmiş ve hastalık sınıflandırma modelinin başarımını artırmaya yönelik en anlamlı özellikler olarak seçilmiştir. Çizelge 6.6 ise seçilen bu özniteliklerle kurulan farklı sınıflandırma modellerinin sonuçlarını içermektedir.

Çizelge 6.5. Hastalık evre tayininde sakkadik göz hareketlerine göre iki aşamalı öznitelik seçim yöntemi sonrası belirlenen ilk 20 öznitelik

Öznitelik Adı	
İnsan menzili enerjisi	Eğrinin altındaki alan
Lempel-ziv karmaşıklığı	Negatif dönüm noktaları
Dalgacık enerjisi 6	Pozitif dönüm noktaları
Histogram	Sinyal mesafesi
Çarpıklık	Toplam mutlak fark
Otokorelasyon	MFCC 10
Çeyrekler açıklığı	Spektral varyans
Ortalama	Higuchi fraktal boyutu
Trendsizleştirilmiş dalgalanma analizi	Dalgacık enerjisi 3
Varyans	Spektral azalma

Çizelge 6.6. Sakkadik göz hareketleri ve makine öğrenmesi sınıflandırıcıların öznitelik seçimi sonrası en belirleyici 20 öznitelik ile hastalık evre tayini sonuçları

Sınıflandırıcı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
k-EYK	71,43	88,41	44,19	71,76	0,792	0,371
DVM	**95,54**	**100,00**	**88,37**	**93,24**	**0,965**	**0,908**
NB	75,89	85,51	83,72	89,86	0,814	0,479
KDA	68,75	73,91	60,47	75,00	0,745	0,342

Hastalık evre tayininde ise iki aşamalı öznitelik seçimin sonrası elde edilen özniteliklerle DVM'nin en yüksek başarıyı göstermesi, bu algoritmanın PH'nin evrelerini ayırt etme konusunda daha etkili olduğunu göstermektedir. Ayrıca, NB ve KDA algoritmalarının sınıflandırma performanslarında artış gözlenmiştir. Özellikle evre tayininde sınıflar arası dengeli dağılım olmamasına rağmen F-skor ve MKK ölçütlerinde iyileşme gözlenmesi PH'nin klinik özellikleriyle ilişkili olarak göz hareketlerindeki belirtiler arasındaki bağıntıları daha iyi modelledikleri göstermektedir.

İnsan menzili enerjisi, beyin aktivitesi ve göz hareket dinamiği hakkında bilgi veren önemli bir değerlendirmedir. Sakkadik göz hareketleri sırasında beyin aktivitelerinde belirgin bir değişiklik oluşur ve insan menzili enerjisi ile ölçülebilir. Seçilen öznitelikler arasında tez çalışması kapsamında önerilen özniteliklerden biri olan *insan menzili enerjisinin* de yer alması hastalığın tespit edilebilmesinde ve hastalık seyrinin takip edilebilmesinde geliştirilecek sistemlerde kullanılmasının önemini vurgulamaktadır.

B. Pursuit Göz Hareket Verileri

Pursuit göz hareketleri gözlerin hareket eden bir nesneyi izleme yeteneğidir. Bu hareketler, düzgün ve kesintisiz bir şekilde nesneyi takip etmek için beyin tarafından koordine edilir. PH'de hareket yavaşlığının varlığı gözlerin hareketli bir hedefi takip ederken daha yavaş hareket etmesi veya gözlerin düzgün bir şekilde hedefi takip edememesi şeklinde kendini gösterebilir. Çizelge 6.7, pursuit göz hareket verileri ile oluşturulan makine öğrenimi modelinde iki aşamalı öznitelik seçimi ile belirlenen ilk 20 özniteliği gösterirken Çizelge 6.8 bu özniteliklerin hasta sağlıklı ayrımındaki başarım sonuçlarını vermektedir.

Çizelge 6.7. Hasta-sağlıklı ayrımında pursuit göz hareketlerine göre iki aşamalı öznitelik seçim yöntemi sonrası tayin edilen ilk 20 öznitelik

Öznitelik Adı	
Dalgacık entropisi	Negatif dönüm noktaları
Ortalama fark	Histogram
Spektral artış	MFCC 5
Ortalama mutlak fark	Dalgacık mutlak ortalaması
Spektral mesafe	Pozitif dönüm noktaları
Petrosian fraktal boyutu	Eğrinin altındaki alan
Kurtozis	Maksimum güç spektrumu
MFCC 2	Ortalama mutlak sapma
MFCC 8	MFCC 10
Ağırlık merkezi	Ortanca fark

PH, pursuit göz hareketlerinin hızında, yöneliminde ve genliğinde belirgin değişikliklere yol açabilen hareket kontrol mekanizmasını etkileyen bir hastalıktır. Bu nedenle, *dalgacık enerjisi, spektral varyans, MFCC* gibi frekans temelli özniteliklerin seçilmesi pursuit hareketlerdeki dalga değişimlerini ve frekans özelliklerini yakalayarak hastalığın etkilerini tespit etmekte ön plana çıkmaktadır. Ayrıca, *otokorelasyon ve toplam mutlak fark* gibi zaman serisi öznitelikler de PH bireylerin göz hareketleri arasındaki ardışıklığın değişkenliği ve hızındaki düzensizlikler hakkında bilgi vermektedir. *Histogram, çarpıklık, varyans, eğrinin altındaki alan* gibi istatistiksel öznitelikler ise, genlikteki asimetriyi ve dağılım farklılıklarını, PH ve sağlıklı bireylerde daha belirgin olabilecek uç değerleri yansıtarak hastalıkla olan ilişkiyi ortaya çıkarmakta önemlidir. PH'de dopamin iletim mekanizmasındaki düzensizlikler göz hareketlerinde de karmaşıklık ve düzensizliklere yol açabilir. Pursuit hareketler ise genellikle daha durağan ve belirli bir yapıya sahiptir. *Lempel-Ziv karmaşıklığının* kullanılmasının bu sinyallerdeki hastalıkla ilişkilendirilen düzensizliklerin tespitinde önemli bir yöntem olduğu görülmüştür.

Çizelge 6.8. Makine öğrenmesi sınıflandırıcıların pursuit göz hareketleri ile hasta-sağlıklı ayrımı sonuçları

Sınıflandırıcı	**Doğruluk (%)**	**Hassasiyet (%)**	**Özgüllük (%)**	**Kesinlik (%)**	**F-skor**	**MKK**
k-EYK	87,05	91,07	84,30	83,04	0,876	0,743
DVM	**94,20**	**100,00**	**89,60**	88,39	**0,945**	**0,890**
NB	78,13	66,07	87,06	90,18	0,751	0,580
KDA	66,07	39,29	84,62	**92,86**	0,537	0,381

Hastalık evre tayininde ise hangi özniteliklerin hastalığın evresine göre farklılaştığı, hangilerinin ön plana çıktığını belirlemek adına pursuit göz hareket sinyallerinden elde edilen özniteiklere iki aşamalı öznitelik seçimi uygulandı. Çizelge 6.9'da hastalık evre tayininde ön plana çıkan ilk 20 özniteliğin isimlerine yer verilmiştir.

Çizelge 6.9. Pursuit göz hareketleri ile hastalık evre tayininde iki aşamalı öznitelik seçim yöntemi ile belirlenen ilk 20 öznitelik

Öznitelik Adı	
Çok ölçekli entropi	Komşuluk noktaları
Minimum	MFCC 10
MFCC 2	Spektral artış
Sinyal mesafesi	Spektral eğim
Temel frekans	MFCC 4
MFCC 1	Histogram
Dalgacık mutlak ortalaması	Maksimum
MFCC 5	Sıfır geçiş oranı
Kurtozis	Eğim
Eğrilik	Petrosian fraktal boyutu

Hastalığın evrelerine göre yapılan ayrımda PH evresi ve seyri ilerledikçe sinyallerin karmaşıklığında da artması olasıdır. *Çok ölçekli entropi* ve *komşuluk noktaları* göz hareketlerindeki düzensizlikleri ve bozulmaları edebilen önemli öznitliklerdir. Bu özellikler evreler arası farklılıkları daha iyi ayırt etmede ön plana çıkmaktadır. *Temel frekans* ise hastalığın motor belirtilerin şiddetiyle bağlantılıdır ve göz hareketlerinin hızındaki yavaşlamayı yansıtır. D*algacık mutlak ortalaması* ise göz hareketlerindeki ritmik bozulmaları gösterir. Ayrıca *MFCC* ise göz hareketlerinin zaman-dalga biçimlerini tanımlayarak hastalığın evrelerine göre farklılıklarını daha hassas bir yaklaşımla ayırt edilmesine olanak tanır. *Spektral artış ve spektral eğim*, göz hareketlerinin frekans bileşenlerindeki değişiklikleri evre bazında tespit etmek için önemli bir rol oynamaktadır.

Çizelge 6.10'da ise belirlenen bu özniteliklerin çeşitli makine öğrenimi yöntemlerinde elde ettiği sınıflandırma başarımlarına yer verilmiştir. Çizelge 6.2 (b) ve Çizelge 6.10'da yer alan sonuçlar karşılaştırıldığında kullanılan tüm makine öğrenimi algoritmaların sınıflandırma performanslarında iyileşme elde edilmiştir. Bu durum, öznitelik seçimi sonrasında belirlenen özniteliklerle oluşturulan modellerin, özellikle evre geçişlerinde bazı hasta verilerinin birbirine yakın olması gibi modeli yanıltıcı faktörlere

rağmen hastalığın ciddiyetine bağlı farklılıkları, düzensizlikleri yakalamada daha başarılı olduğu görülmüştür.

Çizelge 6.10. Makine öğrenmesi sınıflandırıcılarının pursuit göz hareketleri hastalık evre tayini sonuçları

Sınıflandırıcı	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
k-EYK	74,11	89,86	73,81	48,84	0,810	0,435
DVM	**91,96**	**97,10**	90,54	83,72	**0,937**	**0,830**
NB	88,39	94,20	87,84	79,07	0,909	0,753
KDA	66,96	37,50	**91,30**	**96,43**	0,532	0,420

6.2. Derin Öğrenme Yöntemlerinin Uygulamaları

Derin öğrenme yöntemleri, yapay zeka uygulamalarının karmaşık problemleri daha etkin bir şekilde çözebilmesine olanak tanıyan makine öğreniminin daha özelleştirilmiş bir alt uygulamasıdır. Tez çalışmasının bu bölümünde okülomotor göz hareketlerinden gelen sinyallerdeki Parkinson hastalığına ait patolojik izlerin geleneksel makine öğrenmesi yöntemleri yerine derin öğrenme yöntemleriyle de saptanabilirliği araştırılmıştır.

Bu kapsamda, VNG ile kaydedilen zaman serisi sakkadik göz hareketleri 1 boyutlu (1B) konvolüsyonel sinir ağ mimarisine verilmiş ancak veri sayısı azlığı nedeniyle aşırı öğrenme durumu meydana gelmiştir. Hem bu problemi gidermek hem de CNN modellerinin görüntü verilerinden problemlerle ilgili karmaşık detayları daha iyi analiz etmesi sebebiyle zaman serisi göz sinyalleri Yineleme grafiği (YG), Gramian açısal alan (GAA) ve Markov geçiş alanı (MGA) yöntemleri ile görüntüye dönüştürülmüştür. Çizelge 6.11, çalışmanın bu bölümünde kullanılan yöntemlerle 112 kontrol 112 PH bireysen elde edilen görüntü sayılarını göstermektedir.

CNN mimarilerin görüntüye dönüştürülen sakkadik ve pursuit göz hareketi görüntülerinden hastalıklı ilgili izleri saptamadaki başarısını gözlemlemek adına farklı derin öğrenme yaklaşımları test edilmiştir. Her görüntü dönüşüm yöntemi başarısı hem ayrı CNN mimarilerinde bireysel olarak test edilmiş, hem çok kanal girişli CNN (Multi-channel input CNN, MCI-CNN) yapısında denenmiş hem de daha büyük veri kümeleri ile önceden eğitilmiş mimariler (VGG16, ResNet-18, NasNet ve GoogLeNet)

kullanılarak transfer öğrenme yaklaşımları ile incelenmiştir. Ayrıca sonuçlar zaman serilerine uygun derin öğrenme mimarisi olan uzun-kısa vadeli bellek (Long Short-Term Memory, LSTM) modeliyle de karşılaştırılmıştır

Çizelge 6.11. Zaman serilerini görüntüye dönüştürme yöntemleri

Yöntem	**Toplam görüntü sayısı**
Yineleme Grafiği	112* 2= 224
Gramian Açısal Alan	112* 2= 224
Markov Geçiş Alanı	112* 2= 224
Toplam:	3*224 = 672

Verilerin eğitim, validasyon ve test kümelerine dağılımları katılımcı sayısına göre aşağıdaki oranlarla gerçekleştirilmiştir:

- Eğitim kümesi: 75% = 168 kişi (84 PH, 84 Kontrol)
- Test kümesi: 12.5% = 28 kişi (14 PH, 14 Kontrol)
- Validasyon kümesi: 12.5% = 28 kişi (14 PH, 14 Kontrol)

6.2.1. Veri Arttırma

Derin öğrenme uygulamalarının birden fazla gizli katmana sahip olması geleneksel makine öğrenimi yöntemlerine göre öznitelik çıkarımını otomatik yapabilmesi bu yöntemlerin üstünlükleri arasındadır. Ancak, derin öğrenme yaklaşımlarının başarılı sonuç vermesi kullanılan veri kümesindeki örnek sayısı ile oldukça ilişkilidir. Modelde aşırı uyumu engellemek ve daha genellenebilir sonuçlar elde etmek için makine öğreniminin aksine çok fazla veriye gereksinim duyulmaktadır. Bu amaçla eğitim kümelerine aşağıda belirtilen veri arttırma işlemleri uygulanmıştır:

- *Döndürme:* [0, 15, 30, 45, 90, 180] derecelik açılarla döndürme
- *Büyütme:* [0.8, 1.2] değerleri arasında rastgele büyütme
- *X ekseninde kaydırma*: [-20, 20] belirtilen sınırlar içerisinde X ekseninde rastgele kaydırma işlemi
- *Y ekseninde kaydırma:* [-20, 20] belirtilen sınırlar içerisinde Y ekseninde rastgele kaydırma işlemi
- Belirtilen sınırlar içerisinde [-20, 20] hem X hem Y eksende aralığında rastgele kaydırma

Veri arttırma işlemi sonrası YG, GAA, MGA yöntemleriyle kurulan modellerde eğitim, validasyon ve test kümelerinin veri sayısı sırayla 1680, 28, 28 olurken; MCI-CNN modelinde bu değerler 5040, 84 ve 84'tür. Görüntüye dönüştürülen zaman serilerinin boyutları dönüşüm sonrasında 640x480 boyutunda elde edilmektedir. Hem CNN mimarilerinde hem de transfer öğrenme mimarilerinde kullanılmak üzere görsellerin boyutları 224x224 olacak şekilde ayarlanmıştır.

Oluşturulan CNN mimarisinin veri sayısının kısıtlı olmasından dolayı aşırı öğrenmesini önlemek adına daha basit bir mimari kullanılmıştır. Modele ait parametrelere ise Çizelge 6.12'de yer verilmiştir.

Çizelge 6.12. Hasta- sağlıklı ayrımı için geliştirilmiş CNN mimarisinde kullanılan parametreler

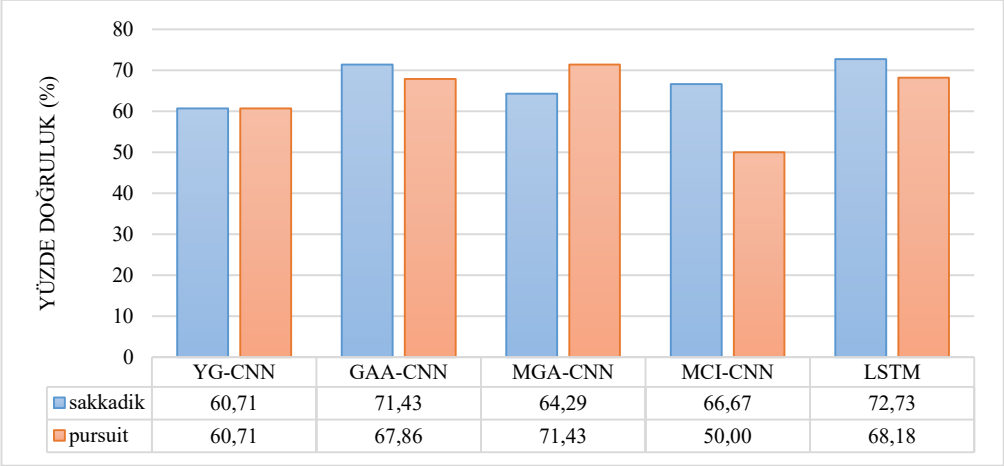
Katman	Çıkış
Giriş katmanı	224x224x3
2 Boyutlu Evrişim	224x224x32
Relu	224x224x32
Maksimum Havuzlama	112x112x32
2 Boyutlu Evrişim	112x112x32
Relu	112x112x64
Maksimum Havuzlama	56x56x64
Bırakma Katmanı	56x56x64
2 Boyutlu Evrişim	56x56x128
Relu	56x56x128
Maksimum Havuzlama	28x28x128
2 Boyutlu Evrişim	28x28x256
Relu	28x28x256
Bırakma Katmanı	28x28x256
Maksimum Havuzlama	14x14x256
Düzleme	50176
Tam Bağlı YSA	1024
Relu	1024
Tam Bağlı YSA	512
Relu	512
Tam Bağlı YSA	2x1
Sigmoid	2x1

Görüntüler CNN mimarilerine verilmeden önce normalizasyon işlemine tabi tutulmuştur. Ardından görsel türlerine uygun hiperparametre ayarlaması "Grid Search"

uygulaması yapılarak girdi veri türlerine uygun kapsamlı bir tarama yapılmıştır. Optimizer olarak Momentumlu Stokastik Gradyan İnişi (Stochastic gradient descent with momentum, “sgdm”) algoritmasının daha başarılı olduğu görülmüştür. Bırakma katmanı değerleri YG, GAA ve MGA görselleri ayrı ayrı kullanıldığında 0.2 olarak seçilmişken, çok kanal girdili CNN modelinde 0.5 olarak belirlenmiştir. Benzer şekilde görselleştirme yöntemlerinin bireysel test edildiği modellerde mini-batch boyutu 16, MCI-CNN yapısında ise 32 olarak kullanılmıştır. Hasta-sağlıklı problemine uygun geliştirilen modellerde en sondaki aktivasyon fonksiyonu ikili sınıflandırma işlemine uygun olacak şekilde “Sigmoid” aktivasyon fonksiyornu seçilirlen, hastalık evre derecelendirme probleminde çoklu sınıf kullanımından dolayı “Softmax” aktivasyon fonksiyonu kullanılmıştır.

Uzun-kısa vadeli bellek (LSTM) mimarisinde ise gizli birim sayısı 20 olarak belirlendi. Aşırı öğrenmeyi önlemek amacıyla modele bırakma katmanı eklendi. Bırakma değeri 0.1 seçilerek her eğitim adımında ağırlıkların %10'unun rastgele sıfırlanması sağlandı. LSTM modelinde optimizer olarak “Adam” algoritmasının daha başarılı olduğu görülmüştür. Aktivasyon fonksiyonu seçiminde CNN uygulamalarında izlenen yöntemler uygulanmıştır.

PH ve sağlıklı bireylerden elde edilen zamana bağlı sakkadik ve pursuit göz hareket sinyallerinden elde edilen çeşitli görselleştirme teknikleriyle oluşturulan CNN mimarisi, hasta ve sağlıklı bireyleri ayırt etme doğruluğunu değerlendirmek için kullanılmıştır. Bu yöntemlerin her biri için sınıflandırma başarı oranlarına Çizelge 6.13’te yer verilmiştir. Şekil 6.1 ise hasta-sağlıklı ayrımına yönelik derin öğrenme modellerinin sakkadik ve pursuit hareketlere göre doğruluk değerlerini sunmaktadır.



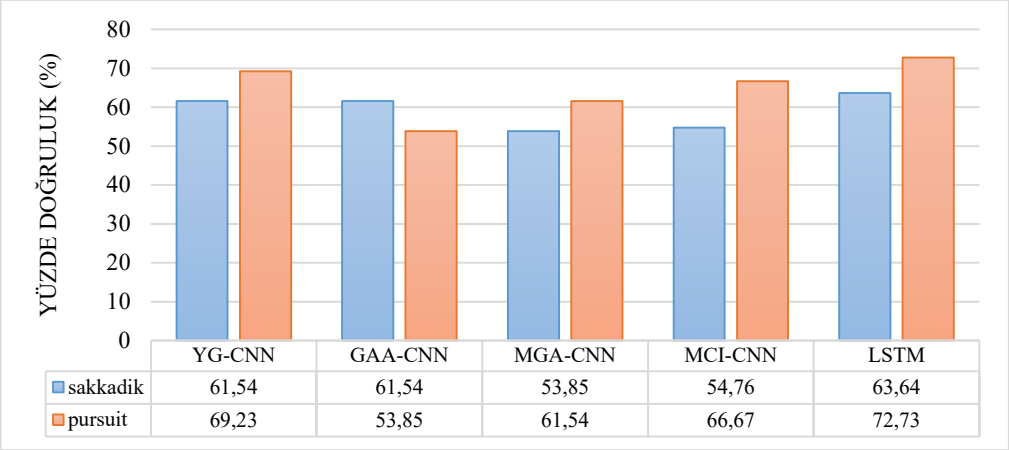
Şekil 6.1. Hasta-sağlıklı ayrımına yönelik derin öğrenme modellerinin sakkadik ve pursuit hareketlere göre doğruluk değerleri

Çizelge 6.13. Hasta-sağlıklı ayrımına yönelik derin öğrenme uygulamaları sonuçları

Yöntem		**Sakkadik**			**Pursuit**		
		Hassasiyet (%)	**Özgüllük (%)**	**F-skor**	**Hassasiyet (%)**	**Özgüllük (%)**	**F-skor**
CNN	**YG**	80,00	56,52	0,41	57,14	**71,43**	0,68
	GAA	**100,0**	63,64	0,60	**100,0**	60,87	0,53
	MGA	83,33	59,09	0,50	71,43	**71,43**	**0,71**
	MCI	65,91	67,50	0,67	50,00	50,00	0,50
LSTM		66,67	**85,71**	**0,77**	70,00	66,67	0,66

GAA dönüşümünün uygulandığı CNN modelinin hem sakkadik hem de pursuit hareketlerde yüksek hassasiyet sağlarken özgüllük değerinin düşük kaldığı görüşmüştür. Bu model hasta sağlıklı ayrım sırasında Parkinson hastalarını doğru şekilde sınıflandırmakta ancak sağlıklı bireyleri tahmin etmede zorluk yaşadığını göstermektedir. LSTM modeli, her iki göz hareketinde de yüksek özgüllük ve kabul edilebilir doğruluk ve hassasiyet göstermiştir. Bu model, sağlıklı bireyleri doğru şekilde tanıma konusunda güçlü ve hastaları da makul bir oranda doğru sınıflandırmaktadır. Hem MGA dönüşüm yönteminin bireysel uygulandığı CNN modeli hem de MCI-CNN modeli her iki durumda da genel olarak dengeli sonuçlar elde etmiştir.

Şekil 6.2'de yer alan grafikte PH'nin evrelerine göre ayrımına yönelik geliştirilen çeşitli derin öğrenme modellerinin elde ettiği doğruluk değerleri gösterilmiştir. Çizelge 6.14'ta ise bu modellere ait diğer değerlendirme ölçütü sonuçları verilmiştir.



Şekil 6.2. Hastalığın evre tayinine yönelik derin öğrenme modellerinin sakkadik ve pursuit hareketlere göre doğruluk değerleri

Çizelge 6.14. Hastalık evre tayinine yönelik derin öğrenme uygulamaları sonuçları

Yöntem		**Sakkadik**			**Pursuit**		
		Hassasiyet (%)	**Özgüllük (%)**	**F-skor**	**Hassasiyet (%)**	**Özgüllük (%)**	**F-skor**
CNN	**YG**	66,67	**50,00**	0,70	66,67	**100,0**	0,80
	GAA	58,33	0,00	0,70	58,33	0,00	0,70
	MGA	62,50	40,00	0,62	61,54	0,00	0,76
	MCI	60,61	33,33	0,67	65,00	**100,0**	0,78
LSTM		**77,78**	0,00	**0,73**	**72,73**	0,00	**0,84**

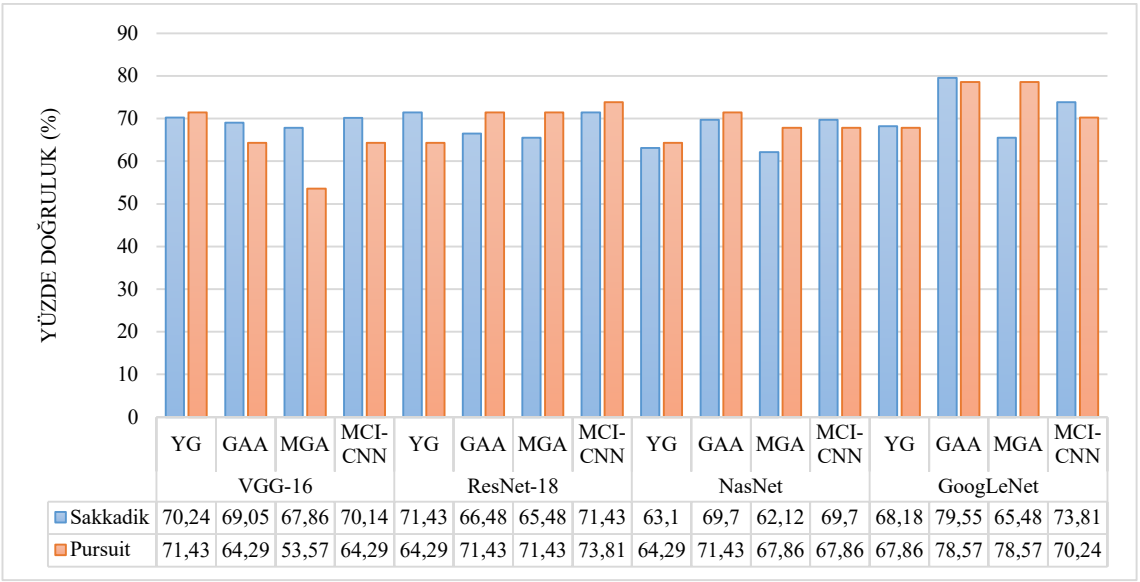
Hem grafik hem de çizelgedeki sonuçlar değerlendirildiğinde LSTM mimarisi her iki göz hareketinde de doğruluk, hassasiyet ve F-skor değerleri bakımından uygulanan yöntemler arasında en başarılı yöntem olmuştur. Bu model, başlangıç evresi hastaları için doğru sınıflandırma ve hassasiyet açısından iyi sonuçlar göstermektedir ancak orta ve ileri evredeki hasta bireyleri ayırmada aynı başarıyı yakalayamamıştır. Orta ve ileri evre hastaların analizi için ise daha yüksek özgüllüğe ve dengeli bir performansa sahip CNN modelleri tercih edilebilir.

Veri kümesindeki örnek sayısının hasta evre tayininde azalması, aynı zamanda evrelere göre veri dağılımının dengesizliği, sakkadik göz hareket sinyallerinin kişiden kişiye değişen özellikleri ile birleştiğinde, CNN tabanlı mimarilerle elde edilen sonuçların genellenebilirliğini olumsuz etkilemektedir. Özellikle hastalık evre derecelendirilmesinde, bu değişkenliklerin doğruluk oranlarına yansıması modelin farklı evreler arasında tutarlı ve güvenilir bir ayrım yapabilmesini zorlaştırmaktadır. Ayrıca,

sakkadik göz hareketlerinde VNG sisteminden gelen referans sinyallerindeki bireysel farklılıklar da aynı göz hareket sinyallerinin her bireyde farklı şekilde algılanmasına neden olarak modelin evre ayırma doğruluğunu sınırlamaktadır.

Bir diğer önemli zorluk ise, Parkinson hastalığı ile okülomotor göz hareketlerinden elde edilen bilgilerin karmaşıklığı ve biyomedikal verilerin sınırlı sayıda kullanılabilirliğidir. Bu durum halihazırda hiperparametre optimizasyon sürecinin uzun olduğu, veri sayısının fazla olduğu durumlarda daha başarılı öğrenebilme yeteneğine sahip evrişimli sinir ağı mimarileri tarafından problemle ilgili önemli bilgilerin saptanabilirliği açısından bir engel oluşturmakta ve testlerde sınıflandırma başarısını olumsuz yönde etkilemektedir. Bu bağlamda, önceden eğitilmiş CNN mimarileri kullanılarak yapılan testler özellikle görüntü dönüştürme yöntemlerinin sınıflandırma başarımlarını değerlendirme noktasında önemli bir alternatif sunmuştur.

Tez çalışmasının bu aşamasında görüntü dönüştürme yöntemleri ile elde edilen zaman serisi temsillerinin önceden eğitilmiş modellerdeki performansı incelenmiştir. Şekil 6.3, sakkadik ve pursuit göz hareket serilerinin görüntü dönüşümü sonrası elde edilen görsellerinin hem bireysel hem de çok kanal girdili model yaklaşımlarının sırasıyla Resnet-18, VGG-16, GoogLeNet ve NasNet mimarileri ile transfer öğrenme uygulamasından elde edilen doğruluk değerlerine ait grafikleri sunmaktadır.



	VGG-16				ResNet-18				NasNet				GoogLeNet			
	YG	GAA	MGA	MCI-CNN	YG	GAA	MGA	MCI-CNN	YG	GAA	MGA	MCI-CNN	YG	GAA	MGA	MCI-CNN
Sakkadik	70,24	69,05	67,86	70,14	71,43	66,48	65,48	71,43	63,1	69,7	62,12	69,7	68,18	79,55	65,48	73,81
Pursuit	71,43	64,29	53,57	64,29	64,29	71,43	71,43	73,81	64,29	71,43	67,86	67,86	67,86	78,57	78,57	70,24

Şekil 6.3. Hasta-sağlıklı ayrımına yönelik transfer öğrenme mimarilerinin sakkadik ve pursuit hareketlere göre başarım sonuçları

Çizelge 6.15'te hasta-sağlıklı ayrımına yönelik uygulanan çeşitli transfer öğrenme modellerine ait diğer değerlendirme ölçüt sonuçlarına yer verilmiştir.

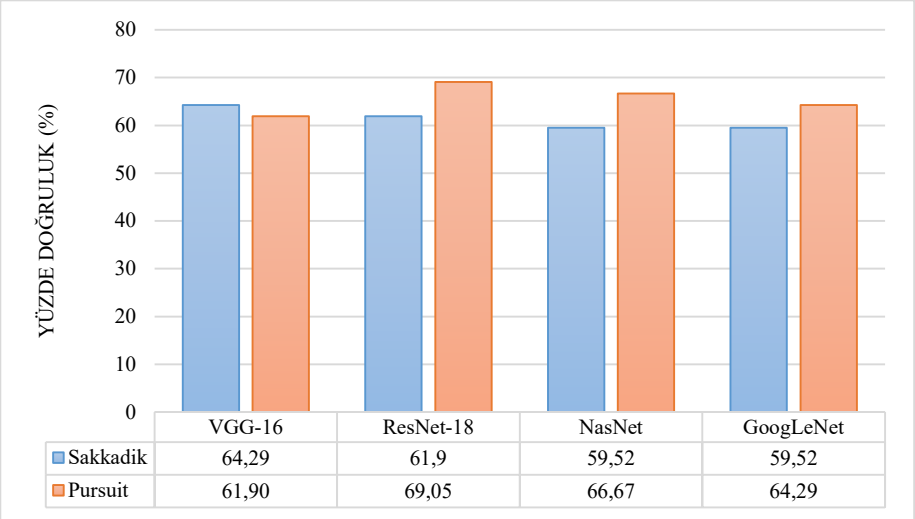
Çizelge 6.15. Hasta-sağlıklı ayrımına yönelik transfer öğrenme uygulamaları sonuçları

Yöntem		Sakkadik			Pursuit		
		Hassasiyet (%)	Özgüllük (%)	F-skor	Hassasiyet (%)	Özgüllük (%)	F-skor
VGG-16	**YG**	71,79	68,89	0,69	**100,0**	63,64	0,60
	GAA	**90,00**	62,50	0,58	83,33	59,09	0,50
	MGA	82,61	62,30	0,58	53,85	53,33	0,52
	MCI-CNN	66,67	**75,76**	0,73	62,00	67,65	0,67
ResNet-18	**YG**	69,57	73,68	0,72	66,67	62,50	0,62
	GAA	63,64	65,00	0,65	71,43	71,43	0,71
	MGA	65,12	65,85	0,66	80,00	66,67	0,67
	MCI-CNN	71,43	71,43	0,71	71,74	76,32	0,75
NasNet	**YG**	62,79	63,41	0,63	64,29	64,29	0,64
	GAA	78,28	65,12	0,64	75,00	68,75	0,69
	MGA	64,71	65,63	0,65	77,78	63,16	0,61
	MCI-CNN	69,70	69,70	0,69	65,31	71,43	0,70
GoogLeNet	**YG**	62,50	57,14	0,53	**100,0**	60,87	0,53
	GAA	88,24	72,41	**0,75**	72,22	**90,00**	**0,81**
	MGA	67,57	63,83	0,63	**100,0**	70,00	0,73
	MCI-CNN	76,32	71,74	0,72	90,48	63,49	0,60

Hem grafik hem de çizelgedeki sonuçlar değerlendirildiğinde sakkadik hareketler üzerine yapılan testlerde modellerin genellikle daha iyi performans gösterdiği, ancak pursuit hareketlerin katılımcılar için daha zorlayıcı olduğu ve bazı modellerin bu görevde daha düşük sonuçlar verdiği gözlenmiştir. GoogLeNet mimarisinin hem sakkadik hem de pursuit hareketlerde diğer modellere göre daha yüksek doğruluk bakımından daha başarılı olduğu görülmüştür. Sakkadik hareketler için çoğu modelde özgüllük değeri %60-75 arasında değişmektedir. Tüm dönüşüm yöntemlerinin birlikte kullanıldığı çok kanal girişli MCI-CNN modeli ve VGG-16 mimarisi %75 özgüllük değeri ile sağlıklı bireyleri sınıflandırmada başarılı olmuştur. Pursuit hareketler değerlendirildiğinde GoogLeNet ve VGG-16 gibi mimarilerin hastalığa ait izleri daha hassas ve başarılı bir şekilde yakaladığı görülmektedir.

Hastalık evre derecelendirmesinde ise veri sayısı ve dağılımı oldukça azaldığı için bu süreç sadece çok kanal girdi modeli (MCI-CNN) üzerinden sonuçlar alınmıştır. Elde

edilen doğruluk değerlerine Şekil 6.4'de, diğer değerlendirme sonuçlarına ise Çizelge 6.16'da yer verilmiştir.



Şekil 6.4. Hastalık evre tayininde transfer öğrenme mimarilerine ait sakkadik ve pursuit hareketlere göre model doğruluk değerleri

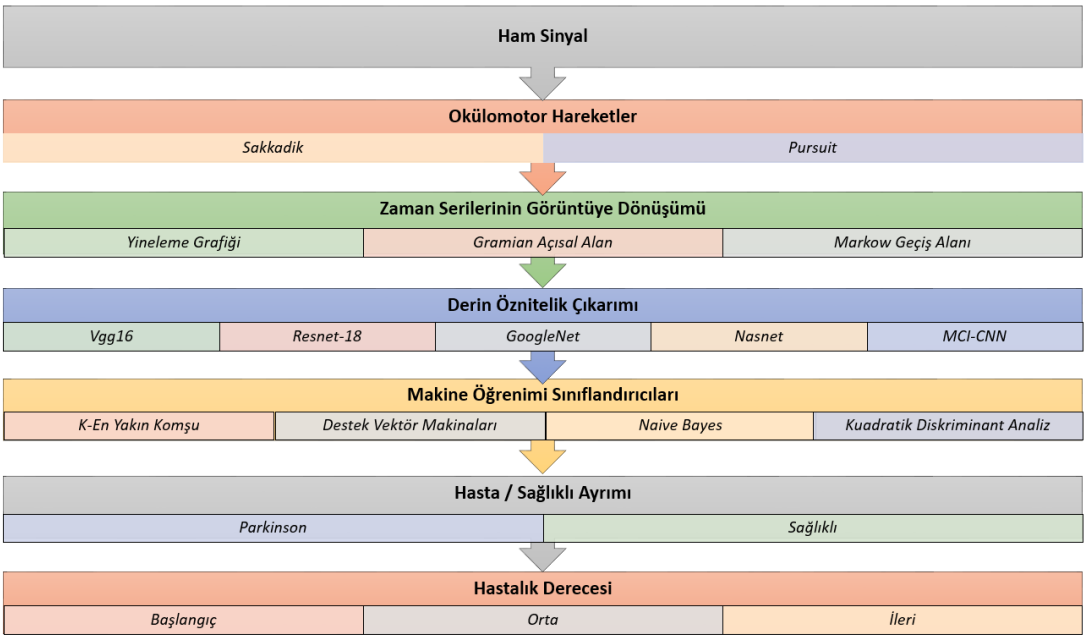
Genel olarak sakkadik hareketlerin değerlendirilmesinde tüm modeller birbirine yakın bir sınıflandırma performansı sergilemiş, ancak VGG-16 mimarisinin diğer modellere göre yüksek bir sonuç elde ettiği görülmüştür. Pursuit göz hareketlerinde ise en yüksek ve dengeli performansı ResNet-18 mimarisi göstermiştir. Özellikle pursuit hareketlerde bu modelin doğruluk, hassasiyet ve özgüllük gibi değerlendirme değerlerinin yüksek olması bu modelin PH'nin evrelerine göre sınıflandırılmasında diğer modellere kıyasla daha uygun olduğunu göstermektedir. Bu durum ResNet mimarisinin daha derin katmanlardan gelen bilgilerle hatalığın evrelerine ait farklılıkları, daha karmaşık ilişkileri ve özellikleri öğrenerek diğer yöntemlere göre doğru ve sağlam sonuçlar üretmesini sağlamıştır.

Çizelge 6.16. Hastalık evre tayinine yönelik transfer öğrenme uygulamaları sonuçları

Yöntem	**Sakkadik**			**Pursuit**		
	Hassasiyet (%)	**Özgüllük (%)**	**F-skor**	**Hassasiyet (%)**	**Özgüllük (%)**	**F-skor**
VGG-16	51,06	**60,00**	0,65	64,71	50,00	0,73
ResNet-18	**63,41**	50,00	**0,76**	**69,70**	**66,67**	**0,78**
NasNet	62,16	40,00	0,73	67,65	62,50	0,76
GoogLeNet	60,98	0,00	0,74	65,71	57,14	0,75

6.3. Hibrit Yöntem Uygulamaları

Bu bölümde tez çalışması dâhilinde yürütülen çalışmalarda hem hasta-sağlıklı ayrımında hem de hastalık evre tayininde derin öğrenme ve makine öğrenimi yöntemlerinin birlikte kullanıldığı hibrit bir yöntem önerildi. Bu aşamada uygulanan yöntemlerin işlem basamaklarına Şekil 6.5'te yer verilmiştir.



Şekil 6.5. Hibrit yöntem uygulamaları işlem basamakları

Önceden eğitilmiş modeller genellikle büyük verilerle eğitilmiş ve genelleme yeteneği yüksek olan modellerdir. Bu modellerin genellikle son katmanları, problemle ilgili çok sayıda bilgi öğrendiği için problemle ilgili geleneksel öznitelik çıkarım yöntemleri ile yakalanamayan bağlantıların belirlenmesi amacıyla derin öznitelikleri çıkarmak için kullanılır.

Okülomotor testlerden gelen göz hareketlerine ait zaman serilerinin çeşitli hesaplamalarla elde edilen farklı görüntü temsilleri kullanarak önceden eğitilmiş VGG-16, ResNet-18, NasNet, GoogLeNet derin öğrenme mimarileri ile kendi derin öğrenme yöntemimiz MCI-CNN modelimizden derin öznitelik çıkarımı yapılmıştır. Çizelge 6.17'de derin öğrenme mimarilerinden çıkarılan öznitelik sayısı ve çıkarıldığı katmanlara yer verilmiştir.

Çizelge 6.17. Derin özniteliklerin elde edildiği katman isimleri ve öznitelik sayıları

Model	Öznitelik Çıkarım katmanları	Çıkarılan Öznitelik Sayısı
Vgg16	fc7	4096
Resnet18	fc1000	1000
NasNet	predictions	1000
GoogLeNet	pool5-7x7_s1	1024
MCI-CNN	fc1	1024

İlgili katmanlardan çıkartılan derin öznitelikler kullanılarak geliştirilen hibrit model, tez çalışmasında önerilen sistemin genelinde olduğu gibi öncellikle hasta sağlıklı ayrımı yaparken, sonraki aşamada Parkinson hastası bireyleri evrelerine göre sınıflandırmayı amaçlamaktadır. Bu kapsamda verilere geleneksel makine öğrenimi uygulamalarında olduğu gibi (-1,+1) normalizasyon işlemi uygulandı ve sınıflandırma algoritmalarında BBDB çapraz geçerleme yöntemi tercih edildi. Farklı uzaklık ölçütleri ve komşuluk değerlerinin incelendiği k-EYK algoritmasının yanı sıra, NB, DVM ve KDA sınıflandırıcıların model performans başarısı doğruluk, hassasiyet, Matthew Korelasyon Katsayısı (MKK) ve F-skor ölçütleri ile incelendi.

DVM algoritmasında LIBSVM gerçekleştirmesi C değeri 1 ve g değeri 0,001 olan doğrusal çekirdek türü ile yürütülmüştür. Hasta-sağlıklı ayrımı amacıyla k-EYK algoritması kullanılarak oluşturulan modellerde ilk etapta Öklid, Manhattan, Chebyshev ve Minkowski gibi uzaklık ölçütleri ile 3, 5, 7 ve 9 komşu değerlerinin sınıflandırma başarısı test edilmiş, en iyi sonuçların k komşuluk değeri 3 ile Manhattan uzaklık ölçütü elde etmiştir. Çizelge 6.18 ve Çizelge 6.19 sırasıyla sakkadik göz hareketi sinyallerinden çeşitli derin öğrenme modellerinden elde edilen derin özniteliklerin hasta-sağlıklı ayrımında ve hastalığın derecelendirilmesinde makine öğrenimi yöntemleri ile birleştirildiğindeki sınıflandırma başarımını belirtmektedir.

Çizelge 6.18. Hibrit yöntemin sakkadik göz hareketlerine göre hasta-sağlıklı ayrımı sonuçları

Derin Öznitelik	Yöntem	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
VGG-16	k-EYK	81,40	79,46	83,33	82,66	0,81	0,63
	DVM	**83,78**	**79,46**	**88,10**	**86,97**	**0,83**	**0,68**
	NB	66,37	59,82	72,92	68,84	0,64	0,33
	KDA	64,14	58,93	69,35	65,78	0,62	0,28
ResNet-18	k-EYK	82,29	79,17	85,42	84,44	0,81	0,64
	DVM	**85,12**	**82,44**	**87,80**	**87,11**	**0,84**	**0,70**
	NB	68,45	50,00	86,90	79,25	0,61	0,40
	KDA	64,14	43,15	85,12	74,36	0,54	0,31
NasNet	k-EYK	81,85	79,17	84,52	83,65	0,81	0,63
	DVM	**84,08**	**81,55**	**86,61**	**85,89**	**0,83**	**0,68**
	NB	67,11	57,44	76,79	71,22	0,63	0,34
	KDA	62,80	55,65	69,94	64,93	0,59	0,25
GoogLeNet	k-EYK	80,06	77,38	82,74	81,76	0,79	0,60
	DVM	**83,78**	**77,38**	**90,18**	**88,74**	**0,82**	**0,68**
	NB	65,33	49,70	80,95	72,29	0,58	0,32
	KDA	51,64	25,30	77,98	53,46	0,34	0,40
MCI-CNN	k-EYK	78,72	77,08	**80,36**	79,69	0,78	0,58
	DVM	**86,31**	**87,42**	76,00	**80,00**	**0,86**	**0,73**
	NB	66,52	72,32	60,71	64,80	0,68	0,33
	KDA	55,06	56,25	53,87	54,94	0,55	0,10

Çizelge 6.18'de yer alan sakkadik hareket değerlerine göre sonuçlar sınıflandırıcı bazında incelendiğinde hasta-sağlıklı ayrımı probleminde tüm modellerde yüksek doğruluk ve düşük yanlış pozitif oranları ile DVM ön plana çıkmaktadır. Özellikle MCI-CNN**,** ResNet-18 ve NasNet gibi modellerle birlikte kullanıldığında DVM etkili sonuçlar elde etmektedir. NB'in elde ettiği doğruluk oranı genellikle % 65,33 ile % 68,45 arasında değişmektedir ve oldukça düşük MKK değerleri ile sınıflandırma işlemini gerçekleştirdiği gözlenmektedir. Bu da modelin, sakkadik göz hareket serilerinin farklı temsillerinden elde edilen derin özniteliklerin Parkinson hastalığı gibi karmaşık bir sınıflandırma probleminde yeterli performansı göstermediğini belirtmektedir. KDA'nın ise, özellikle MCI-CNN, GoogLeNet ve VGG-16 ile birlikte oldukça düşük MKK değerlerine sahip olması bu modelin tahminlerinin rastgele olduğunu ve sınıflandırma başarısının zayıf olduğunu göstermektedir.

Elde edilen sonuçlar model bazlı değerlendirildiğinde VGG-16 ve GoogLeNet mimarilerine ait derin özniteliklerin hibrit yaklaşımda diğer derin özniteliklere göre sınıflandırma başarısının daha düşük olduğu görülmektedir. Bu durum bu modellerin daha derin ve fazla parametreye sahip mimariler olmasından kaynaklanıyor olabilir. Çünkü modellerin problemle ilgili daha fazla ve/veya detaylı öznitelik çıkarması kimi zaman özellikle makine öğrenimi uygulamalarında sınıflandırma başarısını olumsuz etkileyebilecek gereksiz bilgi ve ilişkilerin de veri kümesinde var olmasına yol açmaktadır.

MCI-CNN mimarisinden elde edilen derin özniteliklerin DVM sınıflandırıcı ile daha kullanılan yöntemler içerisinde daha başarılı sınıflandırma değeri alması modelin farklı kanallardan gelen verileri birleştirerek problemle ilgili güçlü temsil yeteneklerine sahip bilgileri elde etmesinden kaynaklanmaktadır.

Çizelge 6.19. Hibrit yöntemin sakkadik göz hareketlerine göre evre tayini sonuçları

Derin Öznitelik	Yöntem	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
VGG-16	k-EYK	73,81	48,72	81,40	44,19	0,46	0,29
	DVM	**80,50**	**77,00**	**84,00**	**82,80**	**0,79**	**0,61**
	NB	55,95	37,18	61,63	22,66	0,28	0,01
	KDA	61,61	0,00	80,23	0,00	0,00	0,23
ResNet-18	k-EYK	72,62	56,41	77,52	43,14	0,48	0,31
	DVM	**81,50**	**82,00**	**81,00**	**81,19**	**0,82**	**0,63**
	NB	63,10	42,31	69,38	29,46	0,35	0,11
	KDA	61,61	0,00	80,23	0,00	0,00	0,23
NasNet	k-EYK	70,83	44,87	78,68	38,89	0,42	0,23
	DVM	**82,00**	**96,00**	68,00	**75,00**	**0,84**	**0,68**
	NB	61,01	37,18	68,22	26,13	0,31	0,40
	KDA	61,61	0,00	**80,23**	0,00	0,00	0,23
GoogLeNet	k-EYK	71,43	37,18	**81,78**	38,16	0,38	0,19
	DVM	**81,00**	**92,00**	70,00	**75,41**	**0,83**	**0,64**
	NB	65,18	34,62	74,42	29,03	0,32	0,10
	KDA	61,61	0,00	80,23	0,00	0,00	0,23
MCI-CNN	k-EYK	69,05	57,69	72,48	38,79	0,46	0,27
	DVM	**80,00**	**76,00**	**84,00**	**82,61**	**0,79**	**0,60**
	NB	59,82	73,08	55,81	33,33	0,46	0,24
	KDA	61,61	0,00	80,23	0,00	0,00	0,23

Çizelge 6.19'da yer alan sonuçlara göre modellerin hasta sağlıklı ayrımına yönelik problem çıkarımında sergiledikleri öğrenebilme yeteneği ve başarısını hastalık evre tayininde sürdüremedikleri görülmüştür. Bu durum hâlihazırda kısıtlı olan veri sayısının evre tayini aşamasında daha da azalmasından ve gruplar arası dağılımın dengeli olmamasından kaynaklandığı düşünülmektedir. Ancak NasNet'in hastalık evrelerini belirlerken görsel verilerdeki karmaşık ilişkileri tespit etme konusunda diğer modellere kıyasla daha yüksek bir başarıya sahip olduğu gözlemlenmiştir. Bu da onun probleme yönelik ayarlanabilir optimal mimarisi ile elde edilen özniteliklerin makine öğrenimi sınıflandırıcıları ile daha iyi yorumlanabildiği ve genelleyebildiğini göstermektedir.

Çizelge 6.20 ve Çizelge 6.21 sırasıyla pursuit göz hareketi sinyallerinden çeşitli derin öğrenme modellerinden elde edilen derin özniteliklerin hasta-sağlıklı ayrımında ve hastalığın derecelendirilmesinde makine öğrenimi yöntemleri ile birleştirildiğindeki sınıflandırma başarımını belirtmektedir.

Çizelge 6.20. Hibrit yaklaşımın pursuit göz hareketleri ile hasta-sağlıklı ayrımı sonuçları

Derin Öznitelik	Yöntem	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
VGG-16	k-EYK	77,83	**77,08**	78,57	78,25	**0,78**	0,56
	DVM	**77,98**	69,64	**86,31**	**83,57**	0,76	**0,57**
	NB	61,16	61,90	60,42	61,00	0,61	0,22
	KDA	52,53	75,89	29,17	51,72	0,62	0,57
ResNet-18	k-EYK	**79,17**	75,30	83,04	81,61	0,78	**0,59**
	DVM	77,23	68,75	**85,71**	**82,80**	0,75	0,55
	NB	58,93	51,19	66,67	60,56	0,56	0,18
	KDA	77,53	**83,04**	72,02	74,80	**0,79**	0,55
NasNet	k-EYK	77,98	**72,62**	83,33	81,33	**0,77**	0,56
	DVM	**78,13**	68,15	88,10	**85,13**	0,76	**0,57**
	NB	61,90	33,63	**90,18**	77,40	0,47	0,29
	KDA	56,85	53,57	60,12	57,32	0,55	0,14
GoogLeNet	k-EYK	78,27	71,13	85,42	82,99	0,76	0,57
	DVM	**78,72**	71,43	86,01	**83,62**	0,77	**0,58**
	NB	61,90	33,04	**90,77**	78,17	0,46	0,29
	KDA	75,29	**87,50**	63,09	70,33	**0,78**	0,52
MCI-CNN	k-EYK	77,83	69,94	85,71	83,04	0,76	0,56
	DVM	**78,13**	**79,17**	77,08	77,55	**0,78**	0,56
	NB	77,68	62,80	**92,56**	**89,41**	0,74	**0,58**
	KDA	56,10	45,54	66,67	57,74	0,51	0,13

Çizelge 6.20'deki hasta-sağlıklı ayrımına yönelik elde edilen sonuçlar değerlendirildiğinde PH teşhisi için ResNet-18 modelinin k-EYK sınıflandırıcısı genel olarak en iyi performansı sergilemiştir. Ancak, NasNet ve GoogLeNe**t** mimarilerinin daha yüksek kesinlik ve özgüllük değeri elde etmesi, bu mimarilerin kontrol grubuna ait olan özellikleri daha doğru tanıdığını ifade etmektedir.

Çizelge 6.21. Hibrit yaklaşımın pursuit göz hareketleri ile evre tayini sonuçları

Derin Öznitelik	Yöntem	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F-skor	MKK
VGG-16	k-EYK	74,11	30,77	87,21	42,11	0,36	0,20
	DVM	**87,20**	**60,26**	**95,35**	**79,66**	**0,67**	**0,62**
	NB	66,07	08,97	83,33	14,00	0,11	0,09
	KDA	65,48	25,60	84,50	40,76	0,30	0,17
ResNet-18	k-EYK	72,62	37,18	83,33	40,28	0,39	0,21
	DVM	**88,10**	**64,10**	**95,35**	**80,65**	**0,71**	**0,65**
	NB	56,25	08,97	70,54	08,43	0,10	0,20
	KDA	63,99	30,85	82,17	06,12	0,05	0,17
NasNet	k-EYK	77,98	56,41	84,50	52,38	0,54	0,39
	DVM	**87,20**	**58,97**	**95,74**	**80,70**	**0,68**	**0,62**
	NB	68,75	21,79	82,95	27,87	0,24	0,05
	KDA	63,39	20,56	81,78	04,08	0,03	0,19
GoogLeNet	k-EYK	73,81	35,90	85,27	42,42	0,39	0,23
	DVM	**89,88**	**67,95**	**96,1**	**85,48**	**0,76**	**0,70**
	NB	68,75	34,62	79,07	33,33	0,34	0,14
	KDA	61,61	30,85	80,23	05,56	0,05	0,23
MCI-CNN	k-EYK	79,17	61,54	84,50	54,55	0,58	0,44
	DVM	**90,18**	**66,67**	**97,29**	**88,14**	**0,76**	**0,71**
	NB	74,70	33,33	87,21	44,07	0,38	0,23
	KDA	62,20	20,56	80,23	03,77	0,03	0,20

DVM sınıflandırıcısının, pursuit hareketlere ait zaman serilerinin görsel temsillerinden hastalığı evrelerine göre ayırmada neredeyse tüm derin öğrenme modellerde en iyi performansı sunduğu görülmektedir. Makine ve derin öğrenme mimarilerinin birlikte kullanımı sadece geleneksel derin öğrenme yöntemleri uygulamasına göre daha başarılı sonuçlar elde etmiştir. MCI-CNN ve GoogLeNet gibi modellerin ise Parkinson evrelerinin doğru tespiti için tercih edilebilecek yöntemler olduğu görülmüştür.

Dengeli dağılımı olmayan veri kümelerinde doğruluk değerlendirme kriteri önerilen modellerin geçerliliği ve başarısı hakkında yanıltıcı sonuç verebilir. Bu durum veri modellerin veri sayısı çok olan sınıfa yönelik yanlı bir karar verme eğilimi gerçekleştirmesinden kaynaklıdır. Bu gibi sonuçlarda modelin başarısı analiz edilirken F-skor ve MKK değerlendirme ölçütlerinden de yararlanmak gereklidir. Sakkadik göz hareketlerinin kullanıldığı modellerde DVM haricindeki özellikle NB ve KDA sınıflandırıcılarıyla kurulan modellerde gerek F-skor gerekse MKK değerlerinin beklenenin altında olması, bu modellerin çıkarılan derin özniteliklerle sınıflar arasındaki ayrımı yakalayamamış olmasından kaynaklı bir sonuç olduğu göstermektedir. DVM algoritmasının genelleyebilme özelliğinin diğer modellere göre daha yüksek olması, sınıflar arasında dengesiz dağılım varlığında bile sınıflar arasındaki farkları daha net bir şekilde ortaya çıkarabilme kabiliyeti onu diğer yöntemlere göre daha üstün kılmıştır.

Okülomotor testlerden sakkadik ve pursuit göz hareketleri ile elde edilen derin özniteklerle kurulan hibrit yaklaşımın yalnızca derin öğrenme mimarileri kullanımına göre hem hasta-sağlıklı ayrımında hem de hastalık evre değerlendirmesinde modellerin başarısına anlamlı katkı sağladığı görülmüştür.

BÖLÜM 7

SONUÇ VE TARTIŞMA

Parkinson hastalığının ortaya çıkmasının üzerinden oldukça uzun bir süre geçmesine rağmen, hastalığın erken dönemde tanımlanması ve kesin bir tedavisinin bulunması hala mümkün olmamıştır. Hastalığa yönelik mevcut tedaviler hastalığın semptomatik belirtilerinden kaynaklanan, hastaların günlük aktivitelerini daha rahat gerçekleştirmelerine yardımcı olan uygulamalardır. PH, hasta ve hasta yakınları için oldukça zorlu bir süreç oluşturur. Bu nedenle, hastalığın teşhisinin konulması ve ilerleyişinin izlenmesi için daha kolay uygulanabilir yöntemlerin geliştirilmesi gereklidir. Hastalıkta görülen harekete bağlı olmayan belirtilerin hastalıkla ilişkilendirilen titreme, kaslarda katılık ve hareket yavaşlığı gibi baskın belirtilerinde çok daha önce görülmeye başlanması, bu belirtilere ait verilerin daha kolay elde edilebilmesi literatürde birçok araştırmacının Parkinson hastalığının teşhisi ve değerlendirilmesi dikkatini çekmiştir.

Bu tezde, katılımcılardan Videonistagmografi sistemiyle kaydedilmiş sakkadik ve pursuit testler sonucu oluşan okülomotor göz hareket sinyallerinin taşıdığı izlerin hasta ve sağlıklı bireylerin ayrılmasında ve hasta bireylerin evre derecelendirmesinde kullanılmak üzere uzmanların karar verme süreçlerine yardımcı olacak sistem geliştirmek amaçlanmıştır. Bu sistem makine ve derin öğrenme yöntemlerinin birlikte kullanıldığı hibrit bir yaklaşımı içermektedir.

Parkinson hastalığında vestibüler sistemle ilgili bulgular, hastalığın seyrini ve tedavi yaklaşımlarını anlamada önemli bir yere sahiptir. Denge kaybı, vertigo ve göz hareketlerindeki anormallikler gibi belirtiler, hastaların yaşam kalitesini etkileyebilir. Bu nedenle, vestibüler sistemin değerlendirilmesi ve tedavi stratejilerinin oluşturulması Parkinson yönetiminde kritik bir unsur olarak öne çıkmaktadır.

112 PH ve 112 sağlıklı kontrol bireye ait okülomotor göz hareket sinyallerinden zaman serilerinin analizinde kullanılan spektral, fraktal, istatistiksel ve zamansal öznitelikler çıkartılmıştır. Spektral, fraktal, istatistiksel ve zamansal öznitelikler gibi farklı öznitelik türlerinin birleşimi özellikle Parkinson hastalığının çeşitli göz hareketlerinden tespit edilebilirliği ve evre tayini gibi karmaşık bir sınıflandırma görevinde önemli bilgiler sunmaktadır. Filtreleme ve sarıcı öznitelik seçim uygulamasını içeren iki aşamalı öznitelik seçiminden sonra model başarılarının artması**,** bu özniteliklerin birbirine ne kadar katkı sağladığını ve gereksiz olanların elenmesinin modelin doğru tahmin yapma kapasitesini artırdığını göstermiştir**.** DVM sınıflandırıcının makine öğrenimi uygulamalarında en iyi performans gösteriyor olması, bu algoritmanın özniteliklerin çeşitliliği ve doğruluğuyla iyi bir uyum sağladığını ve daha az hata ile sınıflandırma başarısı elde ettiğini göstermektedir. Elde edilen sonuçlar, PH'nin evre tayininde sakkadik ve pursuit göz hareketlerinin önemli bir biyobelirteç olarak kullanılabileceğini de göstermektedir. Özellikle DVM'nin yüksek başarı oranı, bu yöntemle geliştirilecek sistemlerin klinik uygulamalarda kullanılabilirliğini göstermektedir. Özellikle sakkadik göz hareketlerinde Naive Bayes (NB) ve KDA (Kuadratik Diskriminant Analiz) daha düşük performans göstermektedir. Özellikle NB doğrusal ve basit yapısının etkisiyle Parkinson hastalığının karmaşıklığını ve dengesiz veri yapısını yeterince iyi modelleyememektedir. KDA ise veri seti ve özellikler arasında doğrusal olmayan ilişkileri yeterince etkili bir şekilde öğrenememiştir, bu yüzden düşük doğruluklar ve zayıf sınıflandırma sonuçları elde edilmiştir.

Parkinson hastalığı, merkezi sinir sistemini etkileyen nörolojik bir olması bu hastalığın erken teşhisi, tedavi sürecinin etkinliğini artırmak adına büyük önem taşır. Bu nedenle tez çalışmasında, PH ve sağlıklı bireylerden bazı göz hareket sinyallerine bağlı elde edilen zaman serilerine çeşitli görselleştirme teknikleri uygulanmıştır. Gramian açısal alan, yineleme grafiği ve Markov geçiş alanı yöntemleri ile görüntüye dönüştürülen zaman serilerinin taşıdığı bilgiler derin öğrenme tabanlı bir yaklaşım olan Konvolüsyonel Sinir Ağı (CNN) mimarilerinde ve transfer öğrenme yöntemlerinde, hasta ve sağlıklı bireyleri ayırt etme doğruluğunu değerlendirmek için kullanılmıştır. Ayrıca sonuçlar zaman serilerinin değerlendirilmesinde tercih edilen uzun-kısa vadeli bellek (LSTM) mimarisi ile de karşılaştırılmıştır.

Bu çalışmada, hem PH-sağlıklı ayrımı hem de hastalık evre tayini uygulamalarında kullanılmak üzere yeni toplanan bir veri türü sunulmuştur. Daha önce yayınlanmış, açık erişimli veri kümelerinden (Tsanas, vd., 2010; Şakar, vd. 2013; Isenkul, vd., 2014; Adams, 2017) farklı olarak hastalığın göz hareketi belirtilerinden oluşmuş yeni bir veri kümesinin tanıtılmasıyla biyomedikal verilerle çalışan araştırmacıların ilgisini çekmesi beklenmektedir. Göz takibi, nörolojik rahatsızlıkları olan hastalarda hastalık tespiti ve ilerlemesini değerlendirmek için sözel olmayan ve zihinsel olarak daha az çaba gerektiren bir yaklaşım sunmaktadır. PH'nin dejeneratif yapısı zamanla göz hareketleri gibi motor belirtilerin yoğunluğunu ve yapısını da etkiler. VNG ile toplanan ve hastalığın göz hareketlerini yapay zeka yöntemleri ile kapsamlı inceleyen benzer bir çalışma bulunmadığından, bu çalışmanın bu alanda yapılan öncü bir çalışma olacağı düşünülmektedir.

Elde edilen sonuçlar değerlendirildiğinde hastalığın erken evre tesptine yönelik geliştirilecek sistemlerde sakkadik göz hareketlerinin analiz edilmesinin daha başarılı olacağı, hastalığın seyrinin takip edileceği sistemlerde ise pursuit hareketlerin incelenmesinin daha yüksek başarı sağlayacağı görülmüştür. Ancak bu araştırma yeni yöntem ve tekniklerle geliştirilmeye açıktır. Bu bağlamda, gelecekteki yürütülecek çalışmaların bir parçası olarak optokinetik ve bakış göz hareketi gibi diğer okülomotor göz hareketlerinden ve bu testler sırasında oluşan pupil reflekslerinden gelen bilgilerle hem hastalığın farklı yönlerle daha etkili ve bütüncül değerlendirilmesi sağlanacak hem de önerilen derin öğrenme yöntemlerinin sınıflandırma başarım performansları ve genelleştirilebilirliğini iyileştirilmesi sağlanacaktır.

Ayrıca, VNG sistemi ve göz hareketlerinin nöroloji kliniklerinde kullanımı, multidisipliner yaklaşımlar ile hastalık belirtilerinin izlenmesi açısından büyük bir potansiyele sahiptir. Bu çalışma, Parkinson hastalığı üzerinden yapılan incelemelere odaklanılmış olsa da burada kullanılan yöntemlerin, diğer nörolojik rahatsızlıkların tanısında ve tedavi süreçlerinde hastalığın seyrinin takip edilmesinde kolay uygulanabilirlik ve objektif değerlendirme sunarak etkili bir şekilde kullanılabileceği düşünülmektedir.

KAYNAKÇA

Adams, W. R. (2017). High-accuracy detection of early Parkinson's Disease using multiple characteristics of finger movement while typing. *PloS one*, 12(11).

Akbayır, E., Şen, M., Ay, U., Şenyer, S., Tüzün, E., & Küçükali, C. İ. (2017). Parkinson hastalığının etyopatogenezi. *Deneysel Tıp Araştırma Enstitüsü Dergisi, 7*(13), 1-23.

Akkoyun, M., Koçoğlu, K., Eraslan Boz, H., Keskinoğlu, P., & Akdal, G. (2023). Saccadic eye movements in patients with mild cognitive impairment: A longitudinal study. *Journal of Motor Behavior*, 55(4), 354–372. https://doi.org/11080/00222895.2023.2202620.

Alpaydin, E. (2009). *Introduction to machine learning*: MIT press.

Armstrong, M. J., & Okun, M. S. (2020). Diagnosis and treatment of Parkinson disease: a review," *Jama*, 323(6), 548-56

Armstrong, R. A. (2015). Oculo-visual dysfunction in Parkinson's disease. *Journal of Parkinson's Disease,* 5(4), 715-726.

Armstrong, R. A. (2017). Visual dysfunction in Parkinson's disease. *International Review of Neurobiology,* 134, 921-946.

Anderson, T.J., & MacAskill, M.R. (2013). Eye movements in patients with neurodegenerative disorders. *Nature Reviews Neurology, 9*, 74-85.

Aygün, D., Türkel, Y., & Onar, M. K. (2009). Parkinson hastalığında motor olmayan belirtilerin tanı ve tedavisi. *Parkinson Hastalığı ve Hareket Bozuklukları Dergisi, 12*, 80-9

Barandas, M., Folgado, D., Fernandes, L., Santos, S., Abreu, M., Bota, P., & Gamboa, H. (2020). TSFEL: Time series feature extraction library. *SoftwareX*, 11, 100456.

Baskar, S., Dhulipala, V.R.S., & Shakeel, P.M. (2020). Hybrid fuzzy based spearman rank correlation for cranial nerve palsy detection in MIoT environment. *Health Technology*. 10, 259–27 https://doi.org/11007/s12553-019-00294-8

Berliner, JM, Kluger BM, Corcos DM, Pelak VS, Gisbert R., & McRae C.(2020). Patient perceptions of visual, vestibular, and oculomotor deficits in people with Parkinson's disease. *Physiotherapy theory and practice*, 36(6):701-8.

Bengio, Y., Goodfellow, I., & Courville, A. (2017). Deep learning (Vol. 1). Cambridge, MA, USA: MIT press.

Bloem, B. R., Okun, M. S., & Klein, C., (2021). Parkinson's disease, *The Lancet,* 397(10291), 2284-2303.

Bidesi, N. S., Vang Andersen, I., Windhorst, A. D., Shalgunov, V.,& Herth, M. M. (2021). The role of neuroimaging in Parkinson's disease, *Journal of Neurochemistry*, 159(4), 660-689.

Brien, D.C., Riek, H.C., Yep, R., Huang, J., Coe, B.C., Areshenkoff, C.N., Grimes, D., Jog, M.S., Lang, A., Marras, C., Masellis, M., McLaughlin, P.M., Peltsch, A., Roberts, A.C., Tan, B., Beaton, D., Lou, W., Swartz, R.H., & Munoz, D. (2023). Classification and staging of Parkinson's disease using video-based eye tracking. *Parkinsonism & related disorders*, 105316 .

Bojrab, D. I., Lai, W., & Bojrab, D. I. (2019). Electronystagmography and videonystagmography. *Diagnosis and Treatment of Vestibular Disorder*s, 45-65.

Budak, H. (2018). Özellik seçim yöntemleri ve yeni bir yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22, 21-31.

Buz, A. C., Demirezen, M. U., & Yavanoğlu, U. (2020). A novel approach and application of time series to image transformation methods on classification of underwater objects. *Gazi Mühendislik Bilimleri Dergisi*, 7(1), 1-11.

Cakmur, R. (2011). Parkinson hastalığı ve medikal tedavisi. *Klinik Gelişim*, 53-58.

Chang, C.-C., & Lin, C.-J. (2011). LIBSVM: a library for support vector machines. *ACM transactions on intelligent systems and technology (TIST), 2*(3), 27.

Crawford, T. J., Higham, S., Renvoize, T., Patel, J., Dale, M., Suriya, A., & Tetley, S. (2005). Inhibitory control of saccadic eye movements and cognitive impairment in Alzheimer's disease. *Biological psychiatry*, 57(9), 1052-106

Corfield, F., & Langdon, D. (2018). A systematic review and meta-analysis of the brief cognitive assessment for multiple sclerosis (BICAMS). *Neurology and therapy,* 7, 287-306.

Çağlayan, H. Z. B., & Tokçaer, A. B. (2013). Parkinsonizmde nörooftalmolojik özellikler. P*arkinson Hastalığı ve Hareket bozuklukları Dergisi*, 16(1-2), 23-29.

Dal, B. T., Göksu, N., Gökdoğan, Ç., & Kemaloğlu, Y. K. Genç erişkinlerde videonistagmografi ile yapılan okülomotor test sonuçlarının incelenmesi. *Ergoterapi ve Rehabilitasyon Dergisi*, 9(1), 1-6.

Demir, B., Ayna Altuntaş, S., Kurt, İ., Ulukaya, S., Erdem, O., Güler, S., & Uzun, C. (2024). Cognitive activity analysis of Parkinson's patients using artificial intelligence techniques. Neurological Sciences, 1-9.

Dikkaya, F., Özkök, A., & Delil, Ş. (2018). Parkinson hastalığında retina sinir lifi tabakası ve makula kalınlığının değerlendirilmesi. *Dicle Tıp Dergisi*, 45(3), 335-34

Estebsari, A., & Rajabi, R. (2020). Single residential load forecasting using deep learning and image encoding techniques. *Electronics,* 9(1), 68.

Falls, C. (2019). Videonystagmography andposturography," Vestibular Disorders, 2019, 82, 32-38.

Fong, C., Dong, Z. & West R.M. (2019). The effects of ph on the kinetics of the follow-up reaction of dopamine o-quinone.

Guo L, Normando EM, Shah PA, De Groef L, Cordeiro MF. (2018). Oculo-visual abnormalities in Parkinson's disease: possible value as biomarkers. *Movement Disorders.*33(9):1390-406.

Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2016). LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10), 2222-2232.

Hancı, N. B., Kurt, İ., Ulukaya, S., Erdem, O., Güler, S., & Uzun, C. (2024). Hybrid voice spectrogram-chromogram based deep learning (HVSC-DL) model for the detection of Parkinson's disease. *In 2024 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, pp. 161-165. IEEE.

Hastie, T. (2009). The elements of statistical learning: data mining, inference, and prediction.

Hasan, M. R., Fatemi, M. I., Monirujjaman Khan, M., Kaur, M., & Zaguia, A. (2021). Comparative analysis of skin cancer (benign vs. malignant) detection using convolutional neural networks. *Journal of Healthcare Engineering*, (1),

Harnois C, Di Paolo T. (1990). Decreased dopamine in the retinas of patients with Parkinson's disease. I*nvestigative ophthalmology & visual science,* 31(11), 2473-5.

He Kaiming, Xiangyu Zhang, Shaoqing Ren ve Jian Sun (2016). Deep residual learning for ımage recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition,* 770-778.

Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.

Hu, X., Yuan, S., Xu, F., Leng, Y., Yuan, K., & Yuan, Q. (2020). Scalp EEG classification using deep Bi-LSTM network for seizure detection. *Computers in Biology and Medicine,* 124, 103919.

Hutton SB. (2008). Cognitive control of saccadic eye movements. *Brain and Cognition*, 68, 327–34)

Hoehn, M. M., & Yahr, M. D. (1967). Parkinsonism: onset, progression, and mortality. *Neurology*, 17(5), 427-427.

Hoffman, J. E., & Subramaniam, B. (1995). The role of visual attention in saccadic eye movements, *Perception & Psychophysics,* 57(6), 787-795.

Isenkul, M., Sakar, B., & Kursun, O., (2014). Improved spiral test using digitized graphics tablet for monitoring Parkinson's disease, *International Conference on E-Health and Telemedicine (ICEHTM-2014)*, 5, 171-175.

Jankovic, J. (2008). Parkinson's disease: clinical features and diagnosis. *Journal of Neurology, Neurosurgery & Psychiatry, 79*(4), 368-376.

Jeon, H., & Oh, S. (2020). Hybrid-recursive feature elimination for efficient feature selection. *Applied Sciences*, *10*(9), 3211. https://doi.org/13390/app10093211

Karaaslan, Z., Hanağası, H. A., Gurvit, İ. H., & Bilgiç, B. (2024). Nörodejeneratif ataksilerde ve Niemann pick tip C'de video-okülografi değerlendirmesi. *Neuropsychiatry*, 61, 101-106.

Klein C, & Ettinger U.(2019). Eye movement research book- an ıntroduction to its scientific foundations and applications. Springer Press.

Ko, D. -W., & Yang, J. -J. (2022). EEG-based schizophrenia diagnosis through time series ımage conversion and deep learning. *Electronics*, 11(14), 2265.

Kurt, İ., Ulukaya, S., & Erdem, O. (2018). Musical feature based classification of Parkinson's disease using dysphonic speech. *2018 41st International Conference on Telecommunications and Signal Processing (TSP),* Athens, Greece, pp. 1-4, IEEE.

Kurt, İ., Ulukaya, S., & Erdem, O. (2019). Classification of Parkinson's disease using dynamic time warping, *27th Telecommunications Forum (TELFOR)*, p.1-4. IEEE.

Kurt, İ., Ulukaya, S., Erdem, O., Güler, S., & Uzun, C. (2024). Shannon wavelet entropy-based machine learning applications in Parkinson's disease diagnosis with videonystagmography. *In 2024 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, pp. 127-131. IEEE.

Küçük, A., & Yilmaz, D. (2024). Analysis of electromyography signals with recurrence plots in detection of knee disorders. *8th International Artificial Intelligence and Data Processing Symposium (IDAP)*, pp. 1-6.

Landi, F., Baraldi, L., Cornia, M., & Cucchiara, R. (2021). Working memory connections for LSTM. *Neural Networks*, 144, 334–341.

Lee J-Y, Martin-Bastida A, Murueta-Goyena A, Gabilondo I, Cuenca N, & Piccini P. (2022). Multimodal brain and retinal imaging of dopaminergic degeneration in Parkinson disease. *Nature Reviews Neurology*, 18(4):203-2

Leigh, R. J., & Zee, D. S. (2015). The neurology of eye movements. Oxford University Press, USA.

Lucero, B. M., Adams, M. J., & Turner, C. J., (2017). Introduction to quantitative engineering design methods via controls engineering, *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 31(4), 458-475.

Memetoğlu, M. E. (2022). Gözler beynin aynasıdır. Pupilometri ve psikolojideki uygulamaları. *Türkiye Bütüncül Psikoterapi Dergisi*, 5(10), 101-108.

Nobelyum (2025). *Parkinson hastalığında; eerken tanının ve tedavide egzersizin önemi,* Nobelyum. Erişim tarihi 16 Ocak 2025, https://www.nobelyum.com/guncel-gelismeler/parkinson-hastaliginda-erken-taninin-ve-tedavide-egzersizin-onemi

O'Shea, K. (2015). An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458.

Özekmekçi, S., Apaydın, H., Oğuz, S., & Zileli, İ. (2013). Parkinson hastalığı hasta ve yakınları için el kitabı.

Özkan, Y. (2008). *Veri madenciliği yöntemleri*: Papatya Yayıncılık Eğitim.

Öztürk, S., Aytaç, G., Kızılay, F., & Sindel, M. (2017). Multipl skleroz. *Akdeniz Tıp Dergisi*, 3(3), 137-147.

Pekel, N. B., Yıldız, D., Sığırlı, D., Güneş, A., & Seferoğlu, M. (2017). Parkinson hastalarında depresyon, anksiyete bozukluğu ve uyku kalitesinin değerlendirilmesi. *Uludağ Üniversitesi Tıp Fakültesi Dergisi, 43*(3), 91-96.

Pehlivan, F. (2015). *Biyofizik:* Pelikan Yayıncılık.

Pehlivan, F. (2016). *Tıbbifizik*: Pelikan Yayıncılık

Politis, M. (2014). Neuroimaging in Parkinson disease: from research setting to clinical practice. *Nature Reviews Neurology*, 10(12), 708-722.

Przybyszewski, A. W., Śledzianowski, A., Chudzik, A., Szlufik, S., & Koziorowski, D. (2023). Machine learning and eye movements give ınsights into neurodegenerative disease mechanisms. *Sensors*, *23*(4), 2145.

Przybyszewski, A.W., Kon, M.A., Szlufik, S., Szymanski, A., Habela, P., & Koziorowski, D.M. (2016). Multimodal learning and intelligent prediction of symptom development in individual Parkinson's patients. *Sensors (Basel, Switzerland), 16*.

Purves, D., Augustine, G. J., Fitzpatrick, D., Katz, L. C., LaMantia, A. S., McNamara, J. O., & Williams, S. M. (2001). Types of eye movements and their functions. *Neuroscience,* 20, 361-39

Robinson, D. A. (2022). Behavior of the saccadic system: Metrics of timing and accuracy, *Progress in Brain Research*, 267(1), 329-353.

Sakar, B. E., Isenkul, M. E., Sakar, C. O., Sertbas, A., Gurgen, F., Delil, S., & Kursun, O. (2013). Collection and analysis of a Parkinson speech dataset with multiple types of sound recordings. *IEEE Journal of Biomedical and Health Informatics, 17*(4), 828-834.

Schwartz, R., Rothermich, K., Kotz, S. A., Pell, M. D. (2018). Unaltered emotional experience in Parkinson's disease: Pupillometry and behavioral evidence. *Journal of clinical and experimental neuropsychology*, 40(3), 303-316.

Saeys, Y., Abeel, T., Van de Peer, Y. (2008). Robust Feature Selection Using Ensemble Feature Selection Techniques. In: Daelemans, W., Goethals, B., Morik, K. (eds) Machine learning and knowledge discovery in databases. ECML PKDD 2008. *Lecture Notes in Computer Science*, vol 5212. Springer, Berlin, Heidelberg.

Sekar, A., Panouill`eres, M. T., & Kaski, D.(2024). Detecting abnormal eye movements in patients with neurodegenerative diseases–current insights, *Eye and Brain*, 3-16.

Shukla, J., Panigrahi, B. K., & Ray, P. K. (2021). Power quality disturbances classification based on gramian angular summation field method and convolutional neural networks. I*nternational Transactions on Electrical Energy Systems,* 31(12).

Shahraki, A., Abbasi, M., & Haugen, Ø. (2020). Boosting algorithms for network intrusion detection: A comparative evaluation of Real AdaBoost, Gentle

AdaBoost and Modest AdaBoost. *Engineering Applications of Artificial Intelligence*, 94, 10377

Silahtaroğlu, G. (2008). *Veri madenciliği*. Papatya Yayınları, İstanbul.

S. Indolia, A. K. Goswami, S. P. Mishra, and P. Asopa. (2018). Conceptual understanding of convolutional neural network- a deep learning approach. *Procedia Computer Science*, vol. 132, pp. 679–688,

Sledzianowski, A., Szymanski, A., Drabik, A., Szlufik, S., Koziorowski, D. M., & Przybyszewski, A. W. (2019). Measurements of antisaccades parameters can improve the prediction of Parkinson's disease progression. *Intelligent Information and Database Systems: 11th Asian Conference, ACIIDS 2019*, pp. 602-614.

Smagulova, K., & James, A. P. (2019). A survey on LSTM memristive neural network architectures and applications. *The European Physical Journal Special Topics*, 228(10), 2313-2324.

Srivastava, A., Sharma, R., Sood, S.K., Shukla, G., Goyal, V.K., & Behari, M. (2014). Saccadic eye movements in Parkinson's disease. *Indian Journal of Ophthalmology, 62*, 538 - 544.

Stuart, S., Lawson, R.A., Yarnall, A.J., Nell, J., Alcock, L., Duncan, G., Khoo, T.K., Barker, R.A., Rochester, L., & Burn, D.J. (2019). Pro-saccades predict cognitive decline in Parkinson's disease: ICICLE-PD. *Movement Disorders, 34*.

Sürmeli, T. (2024). Erişkin psikiyatrisi Parkinson, Erişim tarihi 16 Ocak 2025, https://www.tanjusurmeli.com.tr/parkinson.

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D.& Rabinovich, A. (2015). Going deeper with convolutions. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).

Tang, Z. Z., Zeng, X., Guo, Z., & Song, M. (2020). Malware traffic classification based on recurrence quantification analysis. *International Journal of Network Security,* 22(3), 449-459.

Temirbekov, D. (2018). Vertigo ve denge sorunlarına güncel yaklaşım. Curr Pract ORL, 14(1), 10-2

Termsarasab, P., Thammongkolchai, T., Rucker, J. C., & Frucht, S. J. (2015). The diagnostic value of saccades in movement disorder patients: a practical guide and review. *Journal of clinical movement disorders*, 2, 1-1

Termritthikun, C., Jamtsho, Y., Muneesawang, P., Zhao, J., & Lee, I. (2023). Evolutionary neural architecture search based on efficient CNN models population for image classification. *Multimedia Tools and Applications*, 82(16), 23917-23943.

Tharwat, A. (2016). Linear vs. quadratic discriminant analysis classifier: a tutorial. *International Journal of Applied Pattern Recognition*, 3(2), 145-18

TND, (2011). Nöro-oftalmoloji tanı algoritmaları, Türk Nöroloji Derneği, Nöro-oftalmoloji Çalışma grubu

TPHD,T.P.H. D. (2017). Parkinson nedir?, Erişim tarihi 16 Ocak 2025. http://parkinsondernegi.com/parkinson-nedir/

Tsanas, A., Little, M. A., McSharry, P. E., & Ramig, L. O. (2010). Accurate telemonitoring of Parkinson's disease progression by noninvasive speech tests. *IEEE transactions on biomedical engineering, 57*(4), 884-893.

Uribarri, G., Huth, S.E., Waldthaler, J., Svenningsson, P., & Frans'en, E. (2023). Deep learning for time series classification of Parkinson's disease eye tracking Data. *ArXiv, abs/2311.16381*.

Vaiciukynas, E., Verikas, A., Gelzinis, A., & Bacauskiene, M. (2017). Detecting Parkinson's disease from sustained phonation and speech signals. *PloS one, 12*(10).

Termsarasab, P., Thammongkolchai, T., Rucker, J. C., & Frucht, S. J. (2015). The diagnostic value of saccades in movement disorder patients: a practical guide and review. *Journal of clinical movement disorder*s, 2, 1-1

Wang, Z., & Oates, T. (2015a). Spatially encoding temporal correlations to classify temporal data using convolutional neural networks. arXiv preprint arXiv:1509.07481..

Wang, Z., & Oates, T. (2015, July). Imaging time-series to improve classification and imputation. *24th International Conference on Artificial Intelligence,* pp. 3939-3945.

Whitney, A. W. (1971). A direct method of nonparametric measurement selection. *IEEE Transactions on Computers, 100*(9), 1100-1103.

Wirdefeldt, K., Adami, H.-O., Cole, P., Trichopoulos, D., & Mandel, J. (2011). Epidemiology and etiology of Parkinson's disease: a review of the evidence. *European Journal of Epidemiology, 26*(1), 1.

Yacoubian, T. (2017). Neurodegenerative disorders: Why do we need new therapies? *Drug Discovery Approaches for the Treatment of Neurodegenerative Disorders* pp. 1-16.

Yu, Y., Wang, J., Si, L., Sun, H., Liu, X., Li, X., & Yan, W. (2024). Smooth pursuit and reflexive saccade in discriminating multiple-system atrophy with predominant parkinsonism from Parkinson's disease. *Journal of Clinical Neurology* (Seoul, Korea), 20(2), 194.

Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. *IEEE conference on computer vision and pattern recognition,* pp. 8697-871

EKLER

EK 1. Ön değerlendirmeler/Çalışmaya uygunluğun belirlenmesi

EK1.A. Çalışmaya Dâhil Olma Kriterleri

Kriter	Sağlıklı Gönüllüler	Parkinson Hastası Gönüllüler
Yaş Aralığı	35-85 yaş	35-85 yaş
Yürüyüş	Bağımsız olarak yürüyüş yapabilmek	Bağımsız olarak yürüyüş yapabilmek
Yürüyüşü Engelleyici Hastalık	Bulunmamak	Bulunmamak
Anadil	Türkçe	Türkçe
Okur-Yazarlık	Okur-yazar olmak	Okur-yazar olmak
Görme Sorunları	Anatomik görme engeli olmamak	Anatomik görme engeli olmamak
Ses Üretimi ve Konuşma	Engelleyici anatomik bozukluk olmamak	Engelleyici anatomik bozukluk olmamak
Psikolojik Sorunlar	Ruhsal ve psikolojik sorun olmamak, anti-depresan kullanmamak	Ruhsal ve psikolojik sorun olmamak, anti-depresan kullanmamak
Sinir ve Hareket Sistemi İlaçları	Sinir ve hareket sistemini olumsuz etkileyecek ilaç kullanmamak	Sinir ve hareket sistemini olumsuz etkileyecek ilaç kullanmamak
Komutlara Uygunluk	Yeterlilikte komutları uygulayabilmek	Yeterlilikte komutları uygulayabilmek
Nörolojik Sorunlar	İletişim kabiliyetini etkileyecek nörolojik sorun olmamak	İletişim kabiliyetini etkileyecek nörolojik sorun olmamak
Uzuv Kaybı	El ve ayaklarda uzuv kaybı olmamak	El ve ayaklarda uzuv kaybı olmamak
Kemoterapi veya Radyoterapi	Geçmişinde olmamak	Geçmişinde olmamak
Baş ve Boyun Travması	Baş ve boyunda travma geçirmemiş olmak	Baş ve boyunda travma geçirmemiş olmak
Parkinson Dışı Nörolojik Hastalık	Bulunmamak	Bulunmamak

EK 1.B. Çalışmaya Dışında Kalma Kriterleri

Kriter	Sağlıklı Gönüllüler	Parkinson Hastası Gönüllüler
Yürüyüşü Engelleyen Hastalıklar	Nefes darlığı, kalp rahatsızlığı, tansiyon hastalığı, ortopedik rahatsızlık	Nefes darlığı, kalp rahatsızlığı, tansiyon hastalığı, ortopedik rahatsızlık
Anadil	Türkçe olmamak	Türkçe olmamak
Okur-Yazarlık	Okur-yazar olmamak	Okur-yazar olmamak
Görme Sorunları	Anatomik görme engeli olmak (miyop, hipermetrop, astigmat, göz tansiyonu gibi)	Anatomik görme engeli olmak (miyop, hipermetrop, astigmat, göz tansiyonu gibi)
Ses Üretimi ve Konuşma	Ses üretimi ve konuşmayı engelleyen anatomik bozukluk	Ses üretimi ve konuşmayı engelleyen anatomik bozukluk
Psikolojik Sorunlar	Ruhsal ve psikolojik sorun, anti-depresan kullanımı	Ruhsal ve psikolojik sorun, anti-depresan kullanımı
Sinir ve Hareket Sistemi İlaçları	Sinir ve hareket sistemini olumsuz etkileyecek ilaç kullanımı	Sinir ve hareket sistemini olumsuz etkileyecek ilaç kullanımı
Komutlara Uygunluk	Yeterlilikte komutları uygulayamamak	Yeterlilikte komutları uygulayamamak
Nörolojik Sorunlar	İletişim kabiliyetini etkileyecek nörolojik sorunlar	İletişim kabiliyetini etkileyecek nörolojik sorunlar
Uzuv Kaybı	El ve ayaklarda uzuv kaybı olmak	El ve ayaklarda uzuv kaybı olmak
Kemoterapi veya Radyoterapi	Kemoterapi veya radyoterapi geçmişi olmak	Kemoterapi veya radyoterapi geçmişi olmak
Baş ve Boyun Travması	Baş ve boyun travması geçirmiş olmak	Baş ve boyun travması geçirmiş olmak
Yaş Aralığı	20 yaşından küçük, 79 yaşından büyük olmak	20 yaşından küçük, 79 yaşından büyük olmak
Yürüyüş Hareketi	Bağımsız olarak yürüyüş yapamamak	Bağımsız olarak yürüyüş yapamamak
Enfeksiyonlar	Konuşmasına engel olan alerjik veya gribal enfeksiyon	Konuşmasına engel olan alerjik veya gribal enfeksiyon

EK 2. Çalışmaya katılan katılımcı bilgi formu

GÖNÜLLÜ BİLGİ VE KAYIT FORMU				
KİŞİSEL BİLGİLER				
Referans Numarası				
Adı- Soyadı				
Yaş				
Cinsiyet				
Boy				
Kilo				
Sigara Kullanımı	**Evet**	**Hayır**	**Evet ise kaç yıl:**	
Alkol kullanımı	**Evet**	**Hayır**	**Evet ise kaç yıl:**	
Kuyu Suyu Tüketimi	**Evet**	**Hayır**	**Evet ise kaç yıl:**	
Ağır Metale Maruz Kalma	**Evet**	**Hayır**	**Evet ise kaç yıl:**	
Tarım İlacına Maruz Kalma	**Evet**	**Hayır**	**Evet ise kaç yıl:**	
Koku kaybı	**Evet**	**Hayır**	**Evet ise kaç yıl:**	
Tat Almada Değişim	**Evet**	**Hayır**	**Evet ise kaç yıl:**	
İşitme Kaybı	**Evet**	**Hayır**	**Evet ise kaç yıl:**	
Kulak Çınlaması	**Evet**	**Hayır**	**Evet ise kaç yıl:**	
Terleme Oranı	**Normal**	**Yoğun**	**Çok Yoğun**	
Covid-19 Durumu/ Yapılan Aşılar (Doz-Tür)				
Gözlük Kullanımı	**Hipermetrop**	**Miyop**	**Hepsi:**	**Yok:**
Kullanılan El	**Sağ**	**Sol**		
Uykuda Kabus/ Bağırma	**Var**	**Yok**	**Taraf:**	

Yutma Zorluğu	**Var**	**Yok**	
Bacaklarda Uyuşma	**Var**	**Yok**	**Taraf:**
Kollarda Uyuşma	**Var**	**Yok**	**Taraf:**
Bacaklarda Kramp	**Var**	**Yok**	**Taraf:**
Kollarda Kramp	**Var**	**Yok**	**Taraf:**
	Hastalık bilgileri		
Hastalık Başlangıcından İtibaren Geçen Süre			
Kabızlık			
Titreme	**Var:**	**Yok:**	**Taraf:**
Katılık Hissi	**Var:**	**Yok:**	**Taraf:**
Denge Problemi/ Düşme	**Var:**	**Yok:**	**Taraf:**
Yürürken Ayak Sürtme	**Var:**	**Yok:**	**Taraf:**
Aile Geçmişi			
Unutkanlık			
Kronik Hastalık			
Duadopa			
Kullanılan İlaçlar			
UPDRS puanı			
Hoehn-Yahr puanı			

ÖZGEÇMİŞ

Ortaokul eğitimini Bayraktar Türk Maarif Koleji'nde, lise eğitimini ise Lefkoşa Türk Maarif Koleji'nde tamamladı. 2014 yılında Yakın Doğu Üniversitesi Mühendislik Fakültesi Biyomedikal Mühendisliği Bölümü'nden hem bölüm hem de mühendislik fakültesi birinciliği ile mezun oldu. 2016 yılında Trakya Üniversitesi Fen Bilimleri Enstitüsü Hesaplamalı Bilimler Anabilim Dalı'nda başladığı yüksek lisans eğitimini 2018 yılında *"Makine Öğrenmesi Yöntemleri Kullanılarak Sesin Müzikal Öznitelikleri ile Parkinson Hastalığının Tespiti*" başlıklı tez çalışması ile tamamladı. 2019 yılında başladığı doktora eğitimini de yine aynı anabilim dalında tamamlamaktadır. 2023 yılından itibaren Edirne Teknik Bilimler Meslek Yüksekokulu Elektronik ve Otomasyon Bölümü Biyomedikal Cihaz Teknolojileri Programında öğretim görevlisi olarak çalışmaya devam etmektedir. Sağlıkta yapay zeka uygulamaları, biyomedikal sinyal işleme, ses işleme, biyomekanik, yürüyüş ve göz hareket analizi alanlarında akademik çalışmalarını sürdürmektedir.

TEZ ÇALIŞMASI KAPSAMINDA HAZIRLANAN YAYINLAR

1. **Kurt, İ**., Ulukaya, S., Erdem, O., Güler, S., & Uzun, C. (2024). Shannon Wavelet Entropy-based Machine Learning Applications in Parkinson's Disease Diagnosis with Videonystagmography. *In 2024 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, pp. 127-131.