



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

**KOGNİTİF BOZUKLUĞU OLMAYAN
PARKİNSON HASTALARINDA ERKEN TANI
AMAÇLI KLİNİK KARAR DESTEK SİSTEMİ
GELİŞTİRİLMESİ**

Neslihan BAKİ

DOKTORA TEZİ

Doç. Dr. Nurhan GÜRSEL ÖZMEN

TRABZON-2024

BEYAN

Bu tez çalışmasının Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü Tez Hazırlama ve Yazım Kılavuzu standartlarına uygun olarak yapıldığını ve yazıldığını, tezin akademik ve etik kurallara bağlı kalınarak gerçekleştirilmiş özgün bir bilimsel araştırma eserim olduğunu, tezde yer alan ve bu tez çalışmasıyla elde edilmeyen tüm bilgi ve yorumlara kaynak gösterdiğimi ve kullanılan kaynakların kaynaklar listesinde yer aldığını, tezin çalışılması ve yazımı aşamalarında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Tarih
Neslihan BAKİ
(İmza)

İthaf

Bu doktora tezimi, benim bu günlere gelmem için hiçbir fedakârlıktan kaçınmayan ve her zaman yanımda olan canım anneme ithaf ediyorum.



TEŞEKKÜR

Teşekkür, en kıymetli söz... Hayat veren... Hayatım olan... Hayatımda var olan, bu güne kadar ben olmamı sağlayan her şeye öncelikle teşekkür ediyorum. Aileme, arkadaşlarıma, Devlete, Millete, bu vatan için feda olanlara (ki onlar sayesinde güvenle akademik hayatımıza da devam edebiliyoruz) en içten duygularıyla teşekkür ediyorum. Akademik hayatta katkısı olan tüm Hocalarıma teşekkür ediyorum. Bununla birlikte:

Değerli Bölüm Başkanım ve aynı zamanda Yüksek Lisans Tez Danışmanım Prof. Dr. Kemal TURHAN Hocama, engin vizyonu ve yapmak istediğim akademik çalışmalarımı destekleyerek o yönde yol almamı sağladığı ve başarıların asla tesadüf olmadığını gösterdiği için çok teşekkür ediyorum.

Kendisinden Biyoistatistik ve Tıp Bilişimi adına çok şey öğrendiğim ve aynı zamanda tez izlemede görev alan Sayın Doç. Dr. Burçin KURT Hocama, bana olan değerli katkıları ve nezaketi için çok teşekkür ediyorum.

Tez izlememde görev alan ve çok değerli katkılar sunan çok naif, çok saygıdeğer Elektrik-Elektronik Mühendisliği Bölüm Başkanı Prof. Dr. Ayten ATASOY Hocama kıymetli zamanını ayırdığı ve her zaman başarılı olabileceğimizi gösterdiği için çok teşekkür ediyorum.

Yüksek Lisans tez dönemimden beri takip ettiğim ve daha belli belirsiz literatürde çalışmaların olduğu dönemde Parkinson hastalarının EEG dalgalarında acaba değişim var mıdır, epilepsi de varmış ve karar destek sistemleri oluşturulmuş acaba böyle bir çalışma yapılabilir miyiz diye sorduğumda elbette olabilir diyerek beni destekleyen, yapılabileceğini gösteren, çalışmalarına yön verse de özünde ben olmama izin veren ve benim tez danışmanım olmayı kabul eden çok değerli doktora tez danışmanım Doç. Dr. Nurhan GÜRSEL ÖZMEN Hocama sonsuz teşekkür ediyorum.

Ve Sonsuz teşekkürler O'na...

Neslihan BAKİ

İÇİNDEKİLER

Sayfa

İÇ KAPAK SAYFASI

ONAY

BEYAN

İthaf

TEŞEKKÜR

İÇİNDEKİLER

vi

TABLolar DİZİNİ

x

ŞEKİLLER DİZİNİ

xii

KISALTMALAR, SİMGELER ve FORMÜLLER DİZİNİ

xvi

ÖZET

xix

ABSTRACT

xx

1. GİRİŞ ve AMAÇ

1

1.1. Tez Çalışmasının Amacı ve Literatüre Katkıları

3

2. GENEL BİLGİLER

5

2.1. Parkinson Hastalığının Tarihçesi ve Klinik Özellikleri

5

2.1.1. Parkinson Hastalığında Görülen Motor Belirtiler

5

2.1.2. Parkinson Hastalığında Görülen Motor Olmayan Belirtiler

7

2.2. Parkinson Hastalığının Etyolojisi

7

2.3. Parkinson Hastalığının Patofizyolojisi

8

2.4. Parkinson Hastalığının Tanı Kriterleri

9

2.4.1. Parkinson Hastalığının Klinik Değerlendirilmesi

10

2.4.1.1. Modifiye Hoehn ve Yahr Evrelemesi

10

2.4.1.2. Birleşik Parkinson Hastalığı Değerlendirme Ölçeği

10

2.4.1.3. Montreal Bilişsel Değerlendirme Ölçeği

10

2.5. Parkinson Hastalığının Tedavisi

11

2.6. Elektroensefalografi

12

2.6.1. Delta Dalgaları

14

2.6.2. Teta Dalgaları

14

2.6.3. Alfa Dalgaları

15

2.6.4. Beta Dalgaları	15
2.6.5. Gama dalgaları	15
2.6.6. Mu Ritmi	15
2.6.7. Elektroensefalografi Ölçümü	16
2.6.8. Dinlenme Durumu Elektroensefalografi	17
2.6.9. Parkinson Hastalığında Elektroensefalografi Biyobelirteçleri	17
2.7. Literatür Özeti	18
3. GEREÇ ve YÖNTEM	23
3.1. Kullanılan Veri Setleri	23
3.1.1. Iova Veri Seti	23
3.1.2. San Diego Veri Seti	25
3.1.3. Turku Veri Seti	26
3.2. Veri Analizi	29
3.2.1. Elektroensefalografi Veri Analizi	29
3.2.1.1. Önışleme Aşamaları	30
3.2.2. Ses Verisine Dönüştürülen Elektroensefalografi Veri Analizi	39
3.2.2.1. Önışleme	40
3.3. Makine Öğrenmesi Algoritmaları	47
3.3.1. Categorical Boosting Algoritması	48
3.3.2. Extreme Gradient Boosting Algoritması	48
3.3.3. K En Yakın Komşu Algoritması	49
3.3.4. Gradient Boosting Algoritması	49
3.3.5. Destek Vektör Makineleri	49
3.3.6. Lojistik Regresyon	51
3.3.7. Karar Ağacı Algoritması	51
3.3.8. Naive Bayes Algoritması	53
3.3.9. Rastgele Orman Algoritması	53
3.3.10. Derin Öğrenme Yöntemleri	54
3.3.10.1. Tekrarlayan Sinir Ağı	55
3.3.10.2. Uzun Kısa Süreli Bellek	55
3.3.10.3. Çok Katmanlı Algılayıcı	55
3.4. Sınıflandırma Modellerinin Performans Değerlendirmesi	56
3.4.1. Karışıklık Matrisi	56

3.4.2. Doğruluk	57
3.4.3. Duyarlılık	57
3.4.4. Kesinlik	57
3.4.5. F1 Skor	57
3.4.6. Eğri Altındaki Alan ve Alıcı İşletim Karakteristiği	58
3.4.7. Gerçek Pozitif Oran	58
3.4.8. Yanlış Pozitif Oran	58
3.4.9. Cohen Kappa Değeri	59
3.5. Klinik Karar Destek Sistemleri	59
4. BULGULAR	60
4.1. Elektroensefalografi Verisine Dayalı Kullanılan Özniteliklerin Ayırdediciliği	61
4.2. Tez Çalışmasında Önerilen Özniteliklerin Karşılaştırılması	71
4.3. Kanal Sayılarına Göre Sınıflandırma Sonuçları	74
4.3.1. Veri Setlerinin Ortak 31 Kanalına Göre Sonuçlar	74
4.3.1.1. Iowa Veri Seti 31 Kanal Sonuçları	75
4.3.1.2. San Diego Veri Seti 31 Kanal Sonuçları	77
4.3.1.3. Turku Veri Seti 31 31 Kanal Sonuçları	79
4.4. Tek Kanala Dayalı Sınıflandırma Sonuçları	81
4.4.1. Iowa Veri Seti Sensorimotor Korteks Tek Kanal Sonuçları	81
4.4.2. San Diego Veri Seti Sensorimotor Korteks Tek Kanal Sonuçları	85
4.4.3. Turku Veri Seti Sensorimotor Korteks Tek Kanal Sonuçları	88
4.4.4. Frontal ve Oksipital Bölge Tek Kanal Sonuçları	91
4.5. Veri Setlerinin Elektroensefalografi Alt Bantlarına Göre Sınıflandırılması	97
4.6. Diğer En Yüksek Alt Bant Sonuçları	107
4.6.1. Merkezi Kanal Elektroensefalografi Alt Bant Sonuçları	107
4.7. Veri Setlerinin Kanal Sayılarına Göre Karşılaştırılması	109
4.8. Üç Veri Setinde C3 Kanalının Birinci ve İkinci Senaryoya Göre Sonuçları	112
4.9. Tez Çalışmasında Önerilen Yeni Öznitelik Sınıflandırma Sonuçları	113
4.10. Ses Verisine Dönüştürülen Elektroensefalografi Verisinin Analizi	115
4.10.1. Ses Veri Setlerinde Öznitelik Çıkarımı ve Sınıflandırma Sonuçları	115
4.10.2. Müzik Öznitelikleri Çıkarımı ve Sınıflandırma Sonuçları	116
4.10.2.1. Iowa Veri Seti Müzik Öznitelikleri Çıkarılması ve Sınıflandırma Sonuçları	117

4.10.2.2. San Diego Veri Seti Müzik Öznitelikleri Çıkarılması ve Sınıflandırma Sonuçları	119
4.10.2.3. Turku Veri Seti Müzik Öznitelikleri Çıkarılması ve Sınıflandırma Sonuçları	122
4.11. Frontal ve Oksipital Kanalların Öznitelik Değerlendirmesi	126
4.12. Derin Öğrenme Algoritması Sınıflandırma Sonuçları	126
4.13. Veri Setlerinin Karşılaştırmalı Literatür Sonuçları	128
5. TARTIŞMA	131
6. SONUÇ ve ÖNERİLER	140
7. KAYNAKLAR	143
ÖZGEÇMİŞ	160



TABLÖLAR DİZİNİ

Tablo No		Sayfa
Tablo 1.	En yaygın kullanılan frekans bantları	16
Tablo 2.	Veri setlerinde yer alan SK ve PH grubunun demografik bilgileri	28
Tablo 3.	Veri setlerinin ölçüm parametreleri	28
Tablo 4.	Analiz yapılan kalan sayıları	31
Tablo 5.	Makine öğrenme yöntemlerinde kullanılan parametreler ve yaygın seçilen değerleri	54
Tablo 6.	Karışıklık matrisi	56
Tablo 7.	Tez çalışmasında ele alınan veri işleme düzeni	60
Tablo 8.	Çalışmada kullanılan ve önerilen öz nitelikler	61
Tablo 9.	Iova veri seti 31 kanal ortalaması 10 katlı çapraz doğrulama sonuçları	75
Tablo 10.	San Diego veri seti 31 kanal ortalaması 10 katlı çapraz doğrulama sonuçları	77
Tablo 11.	Turku veri seti 31 kanal ortalaması 10 katlı çapraz doğrulama sonuçları	79
Tablo 12.	Iova veri seti birinci senaryo tek kanal doğruluk sonuçları	83
Tablo 13.	Iova veri seti ikinci senaryo tek kanal doğruluk sonuçları	84
Tablo 14.	San Diego veri seti birinci senaryo tek kanal doğruluk sonuçları	86
Tablo 15.	San Diego veri seti ikinci senaryo tek kanal doğruluk sonuçları	87
Tablo 16.	Turku veri seti birinci senaryo tek doğruluk sonuçları	89
Tablo 17.	Turku veri seti ikinci senaryo tek kanal doğruluk sonuçları	90
Tablo 18.	Iova veri seti birinci senaryo frontal ve oksipital kanallar doğruluk sonuçları	92
Tablo 19.	Iova veri seti ikinci senaryo frontal ve oksipital kanallar doğruluk sonuçları	93
Tablo 20.	San Diego veri seti birinci senaryo frontal ve oksipital kanallar doğruluk sonuçları	94
Tablo 21.	San Diego veri seti ikinci senaryo frontal ve oksipital kanalların doğruluk sonuçları	95

Tablo 22.	Turku veri seti birinci senaryo frontal ve oksipital kanal doğruluk sonuçları	96
Tablo 23.	Turku veri seti ikinci senaryo frontal ve oksipital kanal doğruluk sonuçları	97
Tablo 24.	Iova veri setine ait 10 kanal alt bant doğruluk sonuçları	100
Tablo 25.	San Diego veri seti 10 kanal alt bant doğruluk sonuçları	102
Tablo 26.	Turku veri seti 10 kanal alt bant doğruluk sonuçları	104
Tablo 27.	Iova veri seti dört merkezi kanal alt bant doğruluk sonuçları	105
Tablo 28.	San Diego veri seti dört merkezi kanal alt bant doğruluk sonuçları	106
Tablo 29.	Turku veri seti dört merkezi kanal alt bant doğruluk sonuçları	107
Tablo 30.	Iova veri seti altı merkezi kanal alt bant doğruluk sonuçları	108
Tablo 31.	Turku veri seti altı merkezi kanal alt bant doğruluk sonuçları	109
Tablo 32.	Farklı veri setlerindeki kanal sayısı performansı	112
Tablo 33.	Üç veri setinde C3 kanalı yedi özniteliğe ait karşılaştırmalı sınıflandırma sonuçları	113
Tablo 34.	Yeni öznitelikler ile CatBoost algoritması ile karşılaştırmalı doğruluk sonuçları	115
Tablo 35.	Iova veri setine ait ses öznitelikleri ile sınıflandırma sonuçları	118
Tablo 36.	San Diego veri setine ait ses öznitelikleri ile sınıflandırma sonuçları	120
Tablo 37.	Turku veri setine ait ses öznitelikleri sınıflandırma sonuçları	123
Tablo 38.	Ses verisi üzerinden çıkarılan özniteliklerin sınıflandırma sonuçlarının karşılaştırılması	125
Tablo 39.	Fp1 ve O1 kanalı PSD Delta ve PSD Alfa öznitelik değerlendirmesi	126
Tablo 40.	Derin öğrenme 31 kanal doğruluk sonuçları	127
Tablo 41.	Iova veri seti literatür sonuçları	128
Tablo 42.	San Diego veri seti literatür sonuçları	129
Tablo 43.	Turku veri seti literatür sonuçları	130

ŞEKİLLER DİZİNİ

Şekil No		Sayfa
Şekil 1.	PH'nin genel durumu, görülme sıklığı, 2040 yılındaki öngörüler	4
Şekil 2.	Bazal gangliyon ve bileşenlerinin anatomisi	9
Şekil 3.	Uluslararası 10-20 elektrot yerleşim sistemi	13
Şekil 4.	Elektroensefalografi alt bantları	14
Şekil 5.	Iova veri seti 63 kanal EEG elektrot konumları	24
Şekil 6.	Iova SK ham EEG görüntüsü	24
Şekil 7.	San Diego veri seti 32 kanal EEG elektrot konumları	25
Şekil 8.	San Diego SK ham EEG görüntüsü	26
Şekil 9.	Turku veri seti 64 kanal EEG elektrot konumları	27
Şekil 10.	Turku SK ham EEG görüntüsü	27
Şekil 11.	Elektroensefalografi verisinin analiz şeması	29
Şekil 12.	Filtre türleri	32
Şekil 13.	Iova veri seti SK 63 kanal PSD grafikleri	35
Şekil 14.	San Diego veri seti SK 40 kanal PSD grafikleri	36
Şekil 15.	Turku veri seti SK 64 kanal PSD grafikleri	36
Şekil 16.	Ses verisinin analiz şeması	39
Şekil 17.	SK grubu bir kişiye ait wav uzantılı ses temsili	42
Şekil 18.	Nota müzik temsili	43
Şekil 19.	Piyano klavyesi ve notaların müzik temsili	43
Şekil 20.	Doğrusal ayrılma durumu	50
Şekil 21.	Doğrusal ayrılamama durumu	51
Şekil 22.	Çalışma işleyişi	52
Şekil 23.	Iova PSD Delta özniteliği PH ve SK karşılaştırması	62
Şekil 24.	Iova PSD Alfa özniteliği PH ve SK karşılaştırması	62
Şekil 25.	Iova PSD Gama özniteliği PH ve SK karşılaştırması	63
Şekil 26.	Iova MSF özniteliği PH ve SK karşılaştırması	63
Şekil 27.	Iova wSMI Delta özniteliği PH ve SK karşılaştırması	64
Şekil 28.	Iova wSMI Alfa özniteliği PH ve SK karşılaştırması	64
Şekil 29.	Iova wSMI Gama özniteliği PH ve SK karşılaştırması	65
Şekil 30.	San Diego PSD Delta özniteliği PH ve SK karşılaştırması	65

Şekil 31.	San Diego PSD Alfa özniteliği PH ve SK karşılaştırması	66
Şekil 32.	San Diego PSD Gama özniteliği PH ve SK karşılaştırması	66
Şekil 33.	San Diego MSF özniteliği PH ve SK karşılaştırması	67
Şekil 34.	San Diego wSMI Delta özniteliği PH ve SK karşılaştırması	67
Şekil 35.	San Diego wSMI Alfa özniteliği PH ve SK karşılaştırması	68
Şekil 36.	San Diego wSMI Gama özniteliği PH ve SK karşılaştırması	68
Şekil 37.	Turku PSD Delta özniteliği PH ve SK karşılaştırması	68
Şekil 38.	Turku PSD Alfa özniteliği PH ve SK karşılaştırması	69
Şekil 39.	Turku PSD Gama özniteliği PH ve SK karşılaştırması	69
Şekil 40.	Turku MSF özniteliği PH ve SK karşılaştırması	70
Şekil 41.	Turku wSMI Delta özniteliği PH ve SK karşılaştırması	70
Şekil 42.	Turku wSMI Alfa özniteliği PH ve SK karşılaştırması	70
Şekil 43.	Turku PH ve SK wSMI Gama özniteliği karşılaştırması	71
Şekil 44.	Iova birinci özniteliği PH ve SK karşılaştırması	71
Şekil 45.	Iova ikinci özniteliği PH ve SK karşılaştırması	72
Şekil 46.	Iova dördüncü özniteliği PH ve SK karşılaştırması	72
Şekil 47.	San Diego birinci özniteliği PH ve SK karşılaştırması	72
Şekil 48.	San Diego ikinci özniteliği PH ve SK karşılaştırması	73
Şekil 49.	San Diego dördüncü özniteliği PH ve SK karşılaştırması	73
Şekil 50.	Turku birinci özniteliği PH ve SK karşılaştırması	73
Şekil 51.	Turku ikinci özniteliği PH ve SK karşılaştırması	74
Şekil 52.	Turku dördüncü özniteliği PH ve SK karşılaştırması	74
Şekil 53.	Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri	76
Şekil 54.	Farklı sınıflandırıcıların karışıklık matrisleri	76
Şekil 55.	Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri	78
Şekil 56.	Farklı sınıflandırıcıların karışıklık matrisleri	78
Şekil 57.	Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri	80
Şekil 58.	Farklı sınıflandırıcıların karışıklık matrisleri	80
Şekil 59.	Iova C3 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü	82
Şekil 60.	Iova veri seti birinci senaryo sınıflandırma sonuçları	83
Şekil 61.	Iova veri seti ikinci senaryo sınıflandırma sonuçları	84
Şekil 62.	San Diego C3 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü	85
Şekil 63.	San Diego veri seti birinci senaryo sınıflandırma sonuçları	86

Şekil 64.	San Diego veri seti ikinci senaryo kanal bazlı sınıflandırma sonuçları	87
Şekil 65.	Turku C3 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü	88
Şekil 66.	Turku veri seti birinci senaryo en başarılı sınıflandırma sonuçları	90
Şekil 67.	Turku veri seti ikinci senaryo en başarılı sınıflandırma sonuçları	91
Şekil 68.	Iova veri seti birinci senaryo frontal ve oksipital kanal bazlı karşılaştırması	92
Şekil 69.	Iova veri seti ikinci senaryo frontal ve oksipital kanal bazlı karşılaştırması	93
Şekil 70.	San Diego veri seti birinci senaryo frontal ve oksipital kanal bazlı karşılaştırması	94
Şekil 71.	San Diego veri seti ikinci senaryo frontal ve oksipital kanal bazlı karşılaştırması	96
Şekil 72.	Turku veri seti birinci senaryo sınıflandırıcıların frontal ve oksipital kanal bazlı karşılaştırması	97
Şekil 73.	Turku veri seti ikinci senaryo sınıflandırıcıların frontal ve oksipital kanal bazlı karşılaştırması	98
Şekil 74.	Seçilen merkezi kanalların yerleşim düzeni	98
Şekil 75.	Iova veri seti 10 kanalın bağıl PSD dağılımları	99
Şekil 76.	Iova veri seti EEG alt bantları 10 kanal sınıflandırma sonuçları	100
Şekil 77.	San Diego veri seti 10 kanalın bağıl PSD dağılımları	101
Şekil 78.	San Diego veri seti EEG alt bantları 10 kanal sınıflandırma sonuçları	102
Şekil 79.	Turku veri seti 10 kanalın bağıl PSD dağılımları	103
Şekil 80.	Turku veri seti EEG alt bantları 10 kanal sınıflandırma sonuçları	104
Şekil 81.	Seçilen dört merkezi kanalın yerleşim düzeni	105
Şekil 82.	Seçilen altı merkezi kanalın yerleşim düzeni	108
Şekil 83.	Iova veri seti kanal sayılarına göre sınıflandırma sonuçları	110
Şekil 84.	San Diego veri seti kanal sayılarına göre sınıflandırma sonuçları	110
Şekil 85.	Turku veri seti kanal sayılarına göre sınıflandırma sonuçları	111
Şekil 86.	Senaryolara göre en yüksek C3 kanalı için sınıflandırma sonuçları	113
Şekil 87.	Iova SK kroma ortalaması	117
Şekil 88.	Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri	118
Şekil 89.	Farklı sınıflandırıcıların karışıklık matrisleri	119
Şekil 90.	San Diego SK kroma ortalaması	120

Şekil 91.	Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri	121
Şekil 92.	Farklı sınıflandırıcıların karışıklık matrisleri	121
Şekil 93.	Turku SK kroma ortalaması	122
Şekil 94.	Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri	123
Şekil 95.	Farklı sınıflandırıcıların karışıklık matrisleri	124
Şekil 96.	Üç veri seti 31 kanal için en yüksek EEG ve müzik öznelitliklerinin karşılaştırmalı sınıflandırma sonuçları	125



KISALTMALAR, SİMGELER ve FORMÜLLER DİZİNİ

Kısaltmalar

ABD	Amerika Birleşik Devletleri
AUC	Eğri Altındaki Alan
AH	Alzheimer Hastalığı
BG	Bazal Gangliyon
BİLSTM	Çift Yönlü Uzun Kısa Süreli Bellek
BPHDÖ	Birleşik Parkinson Hastalığı Değerlendirme Ölçeği
CatBoost	Kategorik Arttırma Algoritması
CNN 2D	Evrişimli Sinir Ağı 2 Boyutlu
BT	Bilgisayarlı Tomografi
C	Sentral
CENS	Kroma Enerji Normalize İstatistikleri
CPU	Merkezi İşlem Birimi
CQT	Sabit Q Dönüşümü
DBS	Derin Beyin Stimülasyonu
DVM	Destek Vektör Makinesi
DWPT	Ayrık Dalgacık Paket Dönüşümü
EEG	Elektroensefalografi
XGBoost	Aşırı Gradyan Arttırma
EMG	Elektromyografi
F	Frontal
fMRG	Fonksiyonel Manyetik Rezonans Görüntüleme
FP	Frontal Kutup
GB	Gradient Boosting
GPO	Gerçek Pozitif Oran
GP	Gerçek Pozitifler
GN	Gerçek Negatifler
GPe	Dış Globus Pallidus
Gpi	İç Globus Pallidus
KA	Karar Ağacı Algoritması
KAC	Kolmogorov Algorithmic Karmaşıklık
K-NN	K En Yakın Komşu Algoritması

LSTM	Uzun Kısa Süreli Bellek
LR	Lojistik Regresyon
MCNN	Modifiye CNN
MEG	Manyetoensefalografi
MIBG	M-İyodobenzil-Guanidin Kardiyak Sintigrafi
MIDI	Müzikal Enstrüman Dijital Arayüzü
MLP	Çok Katmanlı Algılayıcı
MMSE	Mini Mental Durum Sınavı
MoCA	Montreal Bilişsel Değerlendirme Ölçeği
MRG	Manyetik Rezonans Görüntüleme
MRS	Manyetik Rezonans Spektroskopi
MSF	Median Spektral Frekans
NAART	Kuzey Amerika Yetişkin Okuma Testinden Alınan Puanlar
NB	Naive Bayes Sınıflandırıcı
O	Oksipital
P	Perital
PDCNNet	Evrişimşel sinir ağı
PET	Pozitron Emisyon Tomografisi
PH	Parkinson Hastalığı
POW	Sinyal Gücü
PSD	Güç Spektral Yoğunluğu
RNN	Tekrarlayan Sinir Ağı
ROC	Alıcı İşletim Karakteristiği
RO	Rastgele Orman Algoritması
REM	Hızlı Göz Hareketi
relPOW	Bağıl Güç
SE	Spektral Entropi
SK	Sağlıklı Kontrol
SNC	Substantia Nigra Pars Kompakta
SN	Substansiya Nigra
SNr	Substantia Nigra Pars Reticulata
SPECT	Tek Foton Emisyonlu Bilgisayarlı Tomografi Görüntü Tabanlı Test
STFT	Kısa Zamanlı Fourier Dönüşümü

STN	Subtalamik Nükleus
vMRG	Volümetrik Manyetik Rezonans Görüntüleme
VQT	Değişken Q Dönüşümü
WHO	Dünya Sağlık Örgütü
wPLI	Ağırlıklı Faz Gecikme Endeksi
wSMI	Ağırlıklı Sembolik Karşılıklı Bilgi
YP	Doğru Negatifler
YPO	Yanlış Pozitif Oran
YN	Yanlış Negatifler



ÖZET

Kognitif Bozukluğu Olmayan Parkinson Hastalarında Erken Tanı Amaçlı Klinik Karar Destek Sistemi Geliştirilmesi

Günümüzde parkinson hastalığı (PH), sıklığı ve yarattığı sorunlar nedeniyle tüm dünyada önemi gittikçe artan bir sağlık sorunu haline gelmiştir. Hastalığın teşhis edilmesi zordur ve etkili tedavi ve ilaç kullanımı bugüne kadar tam olarak sağlanamamıştır. Bu tez çalışmasında yapay zeka yaklaşımı aracılığıyla dinlenme durumu elektroensefalografi (EEG) verisinden, kognitif bozukluğu olmayan hastalarda PH'yi erken dönemde tespit edebilecek, ucuz, etkili bir tahmin modeli geliştirilmesi amaçlanmıştır. Bu amaçla bu tez çalışmasında, üç farklı üniversiteye ait hazır EEG veri setleri yeni öznitelik yaklaşımları kullanılarak ve ilk kez kullanılan öznitelikler önerilerek, farklı makine öğrenmesi yöntemleri ile sınıflandırılmış ve sonuçlar literatürdeki yöntemlerle karşılaştırmalı olarak sunulmuştur. Öncelikle verilerin frekans domeni güç spektral yoğunluğu üzerinden çıkarılan öznitelikleri kullanılarak, PH ve kontrol grubu verileri başarılı şekilde sınıflandırılmıştır. Bu süreçte ayrıca başarılı sonuç veren yeni spektral öznitelikler önerilmiştir. İkinci olarak PH'de yine ilk kez denenilen bir yöntem olan EEG verisinin ses verisine dönüştürülmesi ve onun üzerinden müzik öznitelikleri çıkarılması yoluyla sınıflandırma yapılmıştır. Çalışma sonuçları kullanılan kanal sayısı, öznitelik türü ve kullanılan makine öğrenmesi yöntemleri açılarından ayrı ayrı değerlendirilmiş ve literatürle karşılaştırmalı olarak sunulmuştur. Elde edilen en başarılı sonuçlara göre Iowa veri setinde tek kanal ve yedi spektral öznitelik ile yapılan sınıflandırmada CatBoost algoritması kullanılarak 10 katlı çapraz doğrulama ile %96.67 sonucuna ulaşılmıştır. EEG altbantları ile yapılan sınıflandırmada ise, 18 merkezi kanal, dört spektral öznitelik ile 4-8 Hz ve 10 merkezi kanal 11 spektral öznitelik ile 8-12 Hz'de ayrı ayrı olarak yine CatBoost algoritması ile tüm metriklerde %100'lük sonuca ulaşılmıştır. Ses verisinden elde edilen kroma tabanlı müzik özniteliklerine göre yine 31 kanalda CatBoost algoritması ile %96.67 doğruluk elde edilmiştir. Bu çalışmadan elde edilen sonuçların, literatürde aynı veri setleri ile şimdiye kadar elde edilen sonuçlardan daha iyi olduğu görülmektedir. Dolayısıyla, tez çalışmasının sonuçlarının, PH analizi ve klinik olarak erken teşhisi için umut vadeci ve tercih edilebilir bir seçenek olduğu düşünülmektedir.

Anahtar Sözcükler: Elektroensefalografi, Klinik karar destek sistemleri, Makine öğrenmesi, Nörodejeneratif hastalıklar, Parkinson hastalığı

ABSTRACT

Development of a Clinical Decision Support System for Early Diagnosis in Parkinson's Patients Without Cognitive Impairment

Today, Parkinson's disease (PD) has become an increasingly important health problem all over the world due to its frequency and the problems it creates. The disease is difficult to diagnose, and effective treatment and medication for PD have not been fully achieved to date. In this thesis study, it is aimed to develop an inexpensive, effective prediction model that can detect PD at an early stage in patients without cognitive impairment, using resting-state electroencephalography (EEG) data through an artificial intelligence approach. For this purpose, in this thesis study, ready-made EEG data sets belonging to three different universities were classified with different machine learning methods by using new feature approaches and features used for the first time were proposed, and the results were presented comparatively with the methods in the literature. First of all, using the features extracted from the frequency domain power spectral density of the data, the PH and control group data were successfully classified. In this process, new spectral features have also been proposed with successful results. Secondly, classification was made by converting EEG data into audio data and extracting musical features from it, a method that was tried for the first time in PD. The study results were evaluated separately in terms of the number of channels used, feature type and machine learning methods used and presented in comparison with the literature. According to the most successful results obtained, 96.67% was achieved with 10-fold cross-validation using the CatBoost algorithm in the classification made with a single channel and seven spectral features in the Iova data set. However, in the classification made with EEG subbands, 18 central channels and four spectral features at 4-8 Hz, and 10 central channels and 11 spectral features at 8-12 Hz separately, again with the CatBoost algorithm, a 100% result was achieved in all metrics. According to the chroma based musical features obtained from the audio data, 96.67% accuracy was again achieved with the CatBoost algorithm in 31 channels. It appears that the results obtained from this study are better than the results obtained so far with the same data sets in the literature. Therefore, the results of the this thesis are thought to be a promising and preferable option for PD analysis and early clinical diagnosis.

Keywords: Electroencephalography, Clinical decision support systems, Machine learning, Neurodegenerative diseases, Parkinson disease

1. GİRİŞ ve AMAÇ

Parkinson hastalığı (PH), titreme, sertlik, denge ve koordinasyon güçlüğü gibi istenmeyen veya kontrol edilemeyen hareketlere neden olan, sıklığı ve yarattığı sorunlar nedeniyle tüm dünyada önemi gittikçe artan bir beyin hastalığıdır. Belirtiler genellikle yavaş yavaş başlar ve zamanla hastalık ilerledikçe kişilerde yürüme ve konuşma zorlukları, zihinsel ve davranışsal değişiklikler, uyku sorunları, depresyon, hafıza güçlükleri ve yorgunluk ortaya çıkabilir. İnsan sağlığını tehdit eden kronik bir hastalık olmasının yanında, PH'nin, hem bireylere hem de ülkelerin sağlık sistemlerine maliyeti oldukça yüksektir. Bu hastalığın biyobelirteçlerini tanımlamada ilerleme görülmesine rağmen, günümüzde hala genetik olmayan PH vakalarını teşhis etmek için herhangi bir kan veya laboratuvar testi bulunmamaktadır (1). Doktorlar genellikle kişinin tıbbi geçmişine ve nörolojik muayene bulgularına bağlı olarak hastalığı teşhis eder. Asıl önemli husus, bu hastalığa karşı etkili tedavi ve ilaç kullanımının bu güne kadar tam olarak geliştirilememiş olmasıdır. Diğer birçok hastalık da PH'ye benzer özelliklere sahip olmasına rağmen farklı tedavi gerektirirler. Bu nedenle PH'de erken teşhis, tedavi seçimini etkilediği için oldukça önemlidir. Türkiye'de yaklaşık 150-200 bin PH'li olduğu ve Parkinson Derneği verilerine göre, dünya genelinde bu sayının 10 milyonu aştığı bilgisi verilmiştir. 2040 yılı öngörüsü ise 12 milyondan fazla kişinin hayatını etkileyebileceği yönündedir (2). Detaylı olarak Şekil 1'de konu ile ilgili bilgiler yer almaktadır. Bu rakamlar da PH'de erken teşhisin ne kadar önemli olduğunu göstermektedir. Erken teşhis ile hasta için daha iyi bir yaşam kalitesi ve ülke için daha etkili ve mali açıdan daha uygun bir sağlık hizmeti sağlanacaktır.

Parkinson hastalığının tanısında klinik muayene ve kişilerin tıbbi geçmişleri oldukça önemlidir. Hastalığın teşhisinde özel bir test bulunmadığından hastalardan manyetik rezonans görüntüleme (MRG), kan tetkikleri, lomber ponksiyon (bel bölgesinden bir iğneyle omurga kanalına girilerek beyin-omurilik sıvısı alınması işlemi) gibi ek tetkikler istenebilmektedir (1, 3). Ancak, bu yöntemler de kesin bir çözüm olmamakla birlikte, nörologların karar verme sürecinde destekleyici olmaktadır. Hastalığın erken dönem teşhisinde %30'a kadar varan hata oranlarına rastlanmaktadır (4). Bu nedenle, günümüzde PH'nin erken evre teşhisi için çalışmalar sürdürülmektedir. Elektroensefalografi (EEG) kayıtlarından erken evre PH teşhisi de son yıllarda üzerinde çalışılan araştırma konularındandır (5, 6).

Yaşın ilerlemesiyle beraber beyin yapısında oluşan değişikliklerle çeşitli işlevsel bozukluklar ortaya çıkmaktadır. Bu işlev bozuklukları kişilerin hayatında sıkça rastlanan demans, Alzheimer hastalığı (AH), hafif kognitif bozukluk olarak kendini gösterebilmektedir. Bellek, dil ve mantıklı düşünme de dahil olmak üzere bütün zihinsel yetilerde ilerleyici kötüleşme, gündelik etkinlikleri ve davranışları yerine getirme yetisinde değişiklikler nedeniyle zorluk yaşanması kognitif (bilişsel) bozukluk olarak adlandırılır. Bu tez çalışmasının amacı, kognitif bozukluğu olmayan PH’de dinlenme durumuna ait EEG kayıtlarındaki elektriksel potansiyellerin değişimleri tespit edilerek, erken dönemde hastalığın daha spesifik şekilde belirlenerek teşhis edilmesine, dolayısıyla, hastalık ilerlemesinden kaynaklanan bakıma yönelik maliyetlerin ve gereksiz test maliyetlerinin düşürülmesine katkı sunmaktır. Bu nedenle bu çalışmada, EEG’ye ilişkin belirleyici öznitelikler tespit edilerek, makine öğrenmesi yöntemleriyle PH tanısında hekimlere yardımcı akıllı bir klinik karar destek sistemi geliştirilmesi amaçlanmıştır.

Tez kapsamında, açık kaynak kodlu EEG verileri kullanılarak, araştırmalar yapılmıştır. Parkinson hastalarına ve sağlıklı kontrollere (SK) ait olan üç farklı EEG veri seti kullanılarak, sinyal işleme yapılmış ve farklı makine öğrenmesi yöntemlerinden Kategorik Arttırma (CatBoost), Aşırı Gradyan Arttırma (XGBoost), K En Yakın Komşu Algoritması (KNN), Gradyan Arttırma (GB), Destek Vektör Makinesi (DVM), Lojistik Regresyon (LR), Karar Ağacı (KA), Naive Bayes (NB), Rastgele Orman (RO) algoritmaları kullanılarak sınıflandırma yapılmıştır. Ayrıca, derin öğrenme yöntemlerinden olan Tekrarlayan Sinir Ağı (RNN) ile Uzun Kısa Süreli Bellek (LSTM) birlikte hibrit olarak ve Çok Katmanlı Algılayıcı (MLP) yöntemleri de kullanılmıştır.

Günümüz hastaneleri ve tıbbi kurumlardaki tıbbi bilgi sistemleri gittikçe büyümekte olup, bu bilgilerin işlenmesinde geleneksel veri analizi yöntemleri yetersiz kalmaktadır. Ancak, bilgisayar temelli analiz yöntemleri ile bu problem ile başa çıkılabilmektedir. Makine öğrenmesi yöntemlerinin tıbbi verilerin analizinde kullanılmasının avantajları, teşhis doğruluğunu artırmak, maliyetleri düşürmek ve iş yükünü azaltmaktır.

1.1. Tez Çalışmasının Amacı ve Literatüre Katkıları

Bu çalışmanın hedefleri aşağıdaki gibi belirlenmiştir:

1. İlk hedef, kognitif bozukluğu olmayan PH'nin erken evre teşhisi için erken dönemde hastalığın teşhis edilmesini kolaylaştıracak tanı yöntemlerine karar vermektir.
2. İkinci hedef, EEG cihazından alınan verilerin öznitelliklerinin belirlenmesi, yeni öz nitelik çıkarım algoritması hazırlanması ve EEG verilerinin analiz edilmesidir.
3. Üçüncü olarak, elde edilen öznitelik vektörlerinin farklı makine öğrenmesi yöntemleriyle sınıflandırılmasıdır. Bu yöntemlerin performanslarının kanal sayısı, öznitelik yöntemi ve makine öğrenmesi yöntemleri açılarından kıyaslaması yapılacaktır.
4. Son olarak, PH tanısında hekimlere yardımcı akıllı bir klinik karar destek sistemi geliştirilmesi amaçlanmıştır. Böylece, hastalığın erken dönemde teşhis edilmesi, dolayısıyla, hastalık ilerlemesinden kaynaklanan bakıma yönelik maliyetlerin ve gereksiz test maliyetlerinin düşürülmesine katkı sunması hedeflenmiştir.

Parkinson'a yakalananların sayısı 2040 yılında 12 milyonu aşabilir


Hastalığa yakalananların çoğunluğunu 60 yaş üstü kişiler oluştururken, dünya genelinde 10 milyondan fazla kişi Parkinson ile mücadele ediyor

Parkinson nedir?

- İlk kez 1817'de Londralı doktor James Parkinson tarafından tanımlandı
- Yaşın ilerlemesiyle beyinde dopamin salgılayan hücrelerin azalmasına bağlı olarak ortaya çıkıyor
- Hareket bozukluklarına ve istem dışı hareketlere neden oluyor
- En yaygın belirtileri kas sertliği, hareket sıkıntısı ve titreme

Bazı ülkelere göre Parkinson hastalığından hayatını kaybedenlerin sayısı (2019)

Her 100 bin kişide vefat sayısı



Dünya geneli Parkinson hastası sayısı **10 milyon**

Parkinson kaynaklı ölüm sayısı (2019) **329 bin**

Şekil 1. PH'nin genel durumu, görülme sıklığı, 2040 yılındaki öngörüler (WHO'dan,7)

2. GENEL BİLGİLER

2.1. Parkinson Hastalığının Tarihçesi ve Klinik Özellikleri

Parkinson hastalığı, ilk olarak James Parkinson tarafından 1817 yılında sallanma felci üzerine bir deneme adlı yazısı ile tanıtılmıştır (8). Burada parkinsonizm bir sendrom olarak belirtilmiş ve en sık görülen şekli olan PH olarak bilinen idiyopatik tipi ilk kez tanımlamıştır (9).

Hastalığın görülme sıklığı tüm yaş grupları için yılda 100 bin kişide 1,5 ile 22 arasında değişmektedir. Bu sonuçlar çalışma popülasyonunun demografik özelliklerine, tanı kriterlerine ve vaka tanımlama kaynağına göre farklılık gösterebilmektedir. PH görülme sıklığı yaşla birlikte artmaktadır. Hastalığın, 40 yaşından önce başlaması çok nadir olmakla birlikte, 60 yaşından sonra görülme sıklığı hızla yükselmektedir (10). Erkeklerde PH'nin görülme insidansı kadınlara göre yaklaşık olarak %50 daha fazla olmakla birlikte, bu fark ileri yaş gruplarında azalmaktadır (10-12).

Parkinson hastalığı, dopamin hormonunun üretilmesinden sorumlu beyin bölgesi olan substantia nigradaki (SN) sinir hücrelerinin kaybedilmesi nedeniyle ortaya çıkan ilerleyici nörodejeneratif bir hastalıktır. Burada yer alan sinir hücreleri, sinirlerarası iletimi sağlayan dopamin adlı hormonun üretilmesini sağlar. Bu bölgedeki sinir hücrelerinin azalması ve hasar görmesi dopamin üretiminin azalmasına neden olmaktadır. Dopaminin normal seviyesinin altına inmesi vücudun normal işlevlerini yerine getirmesinde sorunlara yol açmaktadır (1, 13). Substantia nigra bünyesinde 800 bin civarında hücre bulunmaktadır. Hastalık semptomlarının ortaya çıkması için bu hücrelerin en az %60-80'inin kaybolması gerekmektedir. Yaşamları süresince hiçbir PH belirtisi olmadan, başka bir nedenden kaybedilen kişiler vardır. Bu kişilerin beyinleri histopatolojik ve morfolojik olarak incelendiğinde ise SN'de %50 civarında hücre kaybı gözlenmiştir (14).

Parkinson hastalığında dört ana belirti ortaya konulmuştur; hareket eksikliği olarak bilinen hipokinezi ya da hareketlerde yavaşlama yani bradikinezi, bilek, omuz ve boyun gibi bölgelerde sertlik, dopamin ve nörotransmitterlerin dengesizliği nedeniyle oluşan dinlenme durumundayken titreme ve normal vücut postürünü sağlayamama olarak bilinen postural instabilitedir (15). Hastalarda görülen bu motor bozuklukların yanı sıra, mekan algısı ve oryantasyonu gibi vizyospasyal yeti kayıplarının hastalığın erken evresinden itibaren görüldüğü bildirilmiştir (16). Hastalık tanısı konulurken genellikle kişide bradikinezi, sertlik ve istirahatte titremenin olmasına bakılmaktadır (17-19).

Parkinson hastalığının yaklaşık %75-80'ini idiyopatik yani hastalığın nasıl geliştiği bilinmeyen PH oluşturmaktadır. Hastalık, sinsi olarak başlar ve kademeli olarak seyredir. Hastalığın ana semptomları ortaya çıkmadan önce spesifik olmayan belirtilerden oluşan dört ile altı yıl süren prodromal bir dönemin olduğu tespit edilmiştir (20-21). Bu erken ve nonspesifik belirtiler genellikle, klasik PH motor belirtileri ortaya çıktıktan sonra hastaların geçmişi değerlendirildiğinde anlaşılmaktadır (22). Tek yanlı olarak, genelde üst ekstremitelerde başlangıçlı ince hareketlerde yavaşlama, tutukluk, beceriksizlik, tremor, rijidite, bradikinezi, postural instabilite hastalığın ana semptomları olup, yürüme bozukluğu, postür değişiklikleri, konuşma bozukluğu, disfaji, siyalore, mikrografi, otonom fonksiyon bozuklukları, sebore, göz hareketlerinde bozukluk, konjonktivit, ağrılar, duyuşal yakınmalar, depresyon, uyku bozuklukları, demans, psikoz, hızlı göz hareketli (REM) uyku evresi davranış bozuklukları klinik tabloda yer alabilmektedir (20-26).

Parkinson hastalığına en belirgin şekilde nöroinflamasyon eşlik etmektedir (27). Bu inflamasyonun mikrogliya adlı hücrelerden kaynaklandığı not edilmiştir (28). Mikroglialar, myleoid hücre kökenli santral sinir sistemi hücreleridir.

2.1.1. Parkinson Hastalığında Görülen Motor Belirtiler

Tremor, bradikinezi, rijidite, denge ve postür bozuklukları en temel motor belirtilerdir. Tremor, PH'nin dört temel bulgusu içinde yer almaktadır. En fazla dikkat çeken ve özgün olması nedeniyle hekime en sık başvurma nedenini oluşturan belirtidir. Hastalık süresince vakaların %75-85'inde ortaya çıkmakla birlikte yavaş seyretmektedir (29-31). Tremor istirahat halinde ortaya çıkar, asimetrik ve genellikle elin alt bölümünden başlar ve hastalık ilerledikçe üst kısmına doğru yayılır. Daha sonra kol ve bacaklarda, dil ve çenede de ortaya çıkabilir (32-35). İstemli olarak hareket edildiğinde ve uykuda azaldığı görülmektedir.

Bradikinezi, hareketleri başlatma ve ilerlemede güçlük, hareket zamanında uzama, hareketi planlama, sıralama ve aynı zaman diliminde birden fazla işi yapamama, hareketlerin azalması anlamına gelmektedir. Bradikinezi, erken evre PH' de en fazla özürllülük oluşturan, bazal gangliyon (BG) disfonksiyonunun en belirgin bulgusudur. Bu hastalığın tanısının konulmasında "Birleşik Krallık Parkinson Hastalığı Derneği Beyin Bankası" tanı kriterlerine göre, bradikinezi bulgusunun olması gerekmektedir (29, 36). Göz kırpma sayısının düşmesi, mimik hareketlerinin azalması yani bradimiminin olması, yutma

fonksiyonunun azalmasına baęlı ağızda tükürük birikimi yani siyalorenin varlığı, çiğneme ve yutma zorluęunun olması bradikinezinin temel bulgularını oluřturmaktadır (36, 37).

Rijidite, bir ekstremitenin tüm yönlere yapılan pasif hareketi esnasında oluřan direncin artıřına denilmektedir. Agonist ve antagonist kasların birlikte kasılması sırasında ortaya çıkan tonusun artması ile oluřmaktadır (36, 38). Hafif ve erken evre vakalarda rijidite, karřı ekstremitede tekrar eden hareketler yaptırılarak ačíęa çıkarılmaktadır. Rijidite çoęunlukla boyun ve gövdede fleksiyon gibi duruř bozuklukları ile beraber bulunmaktadır (36, 39, 40).

Postüral instabilite ve donma ise ayakta durma ya da oturma esnasında kendilięinden oluřan ve içinde bulunulan vücut duruřunun devamını saęlayan postüral reflekslerin kaybedilmesi ya da bozulmasıdır (41). Parkinson hastalıęında süreç ilerledikçe gövde öne eğilir, çene göęüs bölgesine deęer, diz ve dirseklerde ise yarı fleksiyonluk bir duruř sergilenir. Bu bulguda, gövde fleksiyondayken ileriye doęru giderek hızlanan bir yürüyüř şekli ortaya çıkmaktadır (40). Denge ve postür bozuklukları, genellikle hastalıęın ileri döneminde oluřmaktadır. Bu durum düřmelerin en önemli nedeni olarak görölmektedir (40, 42, 43).

2.1.2. Parkinson Hastalıęında Görölen Motor Olmayan Belirtiler

Motor olmayan belirti ve bulgular genellikle hastalık süreci ve yař ilerledikçe ortaya çıkmaktadır. Koku duyusunda azalma, REM uyku davranıř bozukluęu, depresyon ve kabızlık vb. bulgular ise hastalık oluřmadan yıllar önce ačíęa çıkabilmektedir. Olfaktor fonksiyon bozukluęu yani koku alma kaybı, vakaların %90'ında bulunmaktadır (44). Ortostatik hipotansiyon ve idrar kaçıřma da geç evrede görölebilmektedir (44-46). Aęrı da hastaların yaklařık dörtte üçlük bölümünde görölebilmektedir.

2.2. Parkinson Hastalıęının Etyolojisi

Nörodejeneratif hastalıkların çoęunun nedeni tam olarak bilinmemektedir (47). Bununla birlikte, yař, genetik ve çevresel faktörler olmak üzere üç ana faktörün hastalıęın gelişiminde etkili olduęu gösterilmiřtir.

Hastaların yaklařık %80'i kırk ile yetmiř yařları arasında bulunduęundan yařlı hastalıęı olarak kabul edilse de, sadece yařlıları etkileyen bir hastalık deęildir. Hastaların yaklařık yüzde 5'i ise yirmi ile kırk yařları arasında hastalıęa yakalanmaktadır (47). Bu hastalıęa sahip kiřilerin yaklařık %15'inin ailesinde hastalık bulunmaktadır. Genetik


değişikliklerin PH'nin gelişime neden olma mekanizmaları ya da hastalığın gelişme riskini nasıl etkilediği tam anlamıyla bilinmemektedir. Bununla birlikte, dopamin üretimini sağlayan sinir hücrelerinde, bazı gen mutasyonlarının istenmeyen proteinleri parçalayan hücre mekanizmasını bozduğu bilinmektedir. Bu durum sonucunda parçalanmamış proteinler birikmekte ve bu hücrelerin bozulmasına ya da ölümüne neden olabilmektedir (48). Yapılan bazı çalışmalarda PH'ye, herbisit, pestisit maruziyetinin ve içme suyu ya da direk havada asılı bulunan zehirli maddelerin neden olabileceğinden bahsedilmiştir. Ayrıca, metallere fazla düzeyde maruz kalmak da bir risk olabilmektedir. Literatürde, travmatik beyin hasarı geçirmiş olanlarda bu hastalığın görülme oranının daha yüksek olduğu belirtilmiştir. Bununla birlikte, kafein, sigara, D vitamini ve fiziksel aktivitelerin PH'ye yakalanma oranını düşürdüğü kaydedilmiştir (49).

2.3. Parkinson Hastalığının Patofizyolojisi

Hastalığa neden olan patofizyolojik durumlar BG ismi verilen subkortikal yapılarda oluşmaktadır. Substantia nigra, beynin derinliklerinde bulunan çok küçük bir alandır. Anatomik olarak beynin iki yarı küresinde birer adet SN vardır. Hastalık seyrinde genel olarak sağ ya da sol taraftan biri daha önce etkilenmektedir. Hastalarda, özellikle erken dönemlerde, genel olarak bedenlerinin sağ veya sol tarafında belirtilerin başladığı görülmektedir. Beynin SN bölgesinde dopamin üretimini sağlayan nöronların kaybedilmesi ve bunun yanında lewy cisimcikleri olarak bilinen alfa-sinüklein protein kümelerinin bulunması PH'nin ayırt edilmesini sağlamaktadır. Bu bölgedeki nöronların değişikliğe uğraması nedeniyle, beynin vücut hareketlerini üretme yeteneği bozulmaktadır. Bu bozulmalar, PH'nin karakteristik belirtilerine sebep olmaktadır (47).

Subkortikal yapılardan olan BG'de, PH'ye neden olan patofizyolojik olaylar oluşmaktadır. Bazal gangliyon, korteks ve talamus arasında bulunan ve bunlar arasında bağlantıyı sağlayan bölümdür (50). Beyin ağırlığının çok küçük bir alanını oluşturan BG, motor merkezlerle hareketi kontrol eden çok önemli elektrokimyasal bağlantılarının olması nedeniyle hayati bir bileşendir (47). Bazal gangliyon, motor işlevler ile hafıza ve öğrenme gibi bilişsel görevlerin kolaylaştırılmasında çok önemli bir rol üstlenmektedir. Bunlar arasında duruşu düzenlemek, dengeyi sağlamak, yeniden öğrenme, somatik, vestibüler, görsel ve işitsel olarak duysal entegrasyon, amaca yönelik olarak öğrenilmiş otomatik hareketler, hareketi planlamak ya da başlatmak, bilişsel ve duygusal durum gibi birçok önemli görevin gerçekleştirilmesinde rol almaktadır (50-52). Motor çıktı üzerinde

doğrudan kontrolü olmayan BG, bu motor işlevleri yerine getirmek amacıyla temel olarak dopamini kullanmaktadır. Bazal gangliyonlarda, korteksten gelen girdiyi işleyen ve talamusa yansıtan striatumu oluşturan kaudat nükleus ve putamen, globus pallidus ekterne (GPe), globus pallidus interne (GPi), substantia nigra pars reticulata (SNr), substantia nigra pars kompakta (SNc), subtalamik nükleus (STN) ve SN'den oluşan birbirine bağlı bileşenleri bulunmaktadır. Bu işleyiş Şekil 2'de yer almaktadır.



Şekil 2. Bazal gangliyon ve bileşenlerinin anatomisi (Dana'dan, 53)

2.4. Parkinson Hastalığının Tanı Kriterleri

Hastalığın belirtileri başlangıçta hafif seyretmektedir ve belirtiler hastadan hastaya da değişebilmektedir. Bu da doğru tanı koyulmasını zorlaştırmaktadır. Bu nedenle hastalara sıklıkla yanlış tanıları konulmaktadır.

Hastalığın teşhisi genel olarak klinik değerlendirme, tıbbi öykü, ilaca yanıt ve görüntüleme testleri yapılarak konulmaktadır (54, 55). Klinik değerlendirmede, nöroloji uzmanı hastanın reflekslerini, koordinasyonunu ve hareket açıklığını kontrol edebilmektedir. Nörolog ayrıca hastanın aile öyküsü, yaşam tarzı ve önceki tıbbi tedavileri hakkında bilgi alabilmektedir. Hastalık belirtilerinin, objektif olarak bir ölçüsü bulunmamaktadır. Hastalığın göstergesi olabilecek motor semptomlardaki ince

değişiklikler saptanamamaktadır. Hastalığın tanısının konulmasında “Birleşik Krallık Parkinson Hastalığı Derneği Beyin Bankası” klinik tanı kriterleri kullanılmaktadır (56).

2.4.1. Parkinson Hastalığının Klinik Değerlendirilmesi

2.4.1.1. Modifiye Hoehn ve Yahr Evrelemesi

Hastalığın evrelendirilmesinde Modifiye Hoehn ve Yahr Evreleme ölçeği kullanılmaktadır. Bu ölçeğin, Türkçe geçerlilik ve güvenilirliği gösterilmiştir. Beş evreden oluşan ölçekte, evre arttıkça hastalığın ilerlemiş safhada olduğu anlaşılmaktadır. Ölçek, hastalık bulgusunun olmadığı sıfırcı evreden başlayarak, hastalık bulgusunun en fazla arttığı evre beşe kadar devam etmektedir. Evre beş, hastanın yatağa bağımlı hale geldiği, en ileri hastalık safhasıdır (57).

2.4.1.2. Birleşik Parkinson Hastalığı Değerlendirme Ölçeği

Birleşik Parkinson Hastalığı Değerlendirme Ölçeği (BPHDÖ), Türkçe geçerlilik ve güvenilirliği bulunan bu ölçektir. Fahn, Elton ve BPHDÖ Geliştirme Komite üyeleri tarafından 1987 yılında geliştirilmiştir. Bu ölçek, dört bölümden oluşmaktadır. Bu ölçek ile mental durumlar, günlük yaşam aktiviteleri, motor işlevleri ve tedavi komplikasyonları belirlenmektedir. BPHDÖ testi, hiçbir bulgunun bulunmadığı sıfır ile en şiddetli bulguların yer aldığı dört arasında puan verilerek değerlendirilmektedir. İlk bölümde düşünce, davranış ve duygulanımı değerlendiren dört madde yer almaktadır. İkinci bölümde 13 maddeden oluşan günlük yaşam aktiviteleri, üçüncü bölüm 14 maddenin yer aldığı motor muayeneyi ve dördüncü bölüm ise motor komplikasyonları içermektedir. Hastalık kötüleştikçe ölçek puanı yükselmektedir (58).

2.4.1.3. Montreal Bilişsel Değerlendirme Ölçeği

Montreal Bilişsel Değerlendirme Ölçeği (MoCA), hafif bilişsel bozukluk için hızlı bir tarama testi olarak geliştirilmiştir. Bu ölçek, dikkat ve konsantrasyon, yürütücü işlevler, bellek, dil, görsel-mekansal beceriler, soyut düşünme, hesaplama ve yönelimden oluşan farklı bilişsel boyutları değerlendirmektedir (59). Bu ölçek, özellikle bilişsel etkilenmenin erken döneminde etkilidir.

Hastalıkta, bilişsel işlevlerde bozulma ve demansa gidişin erken ve daha hızlı saptanabilmesi amacıyla nöropsikolojik ve klinik değerlendirmenin yanı sıra, ayrı ayrı veya kombinasyon halinde kullanılan çok çeşitli teknikler vardır. Bunlar arasında EEG, MRG, bilgisayarlı tomografi (BT) taramaları, volümetrik manyetik rezonans görüntüleme

(vMRG), fonksiyonel manyetik rezonans görüntüleme (fMRG), manyetik rezonans spektroskopisi (MRS), pozitron emisyon tomografisi (PET) ve görüntü tabanlı testler tek foton emisyonlu bilgisayarlı tomografi (SPECT), M-iyodobenzil-guanidin kardiyak sintiskan (MIBG) bulunmaktadır (60-63). Bu testler, hastalıkla ilişkili beyindeki değişiklikleri belirlemeye yardımcı olabilmektedir. Bununla birlikte, örneğin; MRG testinin PH teşhisinde maliyet, erişilebilirlik, güvenlik, zaman, hareket artefaktları ve kapalı alan korkusu gibi bazı sınırlamaları bulunmaktadır. Bu nedenle, EEG dışındaki görüntüleme yöntemleri oldukça maliyetlidir ve her zaman kolay olarak erişilememektedir. PH'nin tespit edilmesinde kan testleri de kullanılabilmektedir (64, 65). Ancak, hastalığı tespit edebilecek hiçbir spesifik kan testi bulunmamaktadır. Bu testler, dopamin ve diğer nörotransmitter düzeylerini ölçmekte ve uzmanların, PH'ye işaret edebilecek belirli belirteçlerin varlığını saptayabilmesine rağmen, PH'nin sebebini tespit edememektedir. Bu sebeple, hastalığın kesin nedenini belirlemek amacıyla kullanılamamaktadır. Hastalık ile ilişkili genetik mutasyonlar da olabilmektedir. Bunları saptamak için genetik testler de bulunmaktadır. Bütün bu nedenlerden dolayı, PH'nin erken dönemde saptanması ve yönetimini sağlamak amacıyla güvenilir ve doğru teşhis ve sınıflandırma araçlarının geliştirilmesi oldukça önemlidir. Halihazırda, bozukluğun karmaşık ve heterojen doğası nedeniyle, PH için daha iyi teşhis ve sınıflandırma modellerine oldukça fazla ihtiyaç duyulmaktadır.

2.5. Parkinson Hastalığının Tedavisi

Günümüzde PH için kesin bir tedavi yöntemi yoktur. Yapılan tıbbi müdahaleler belirti ve bulguların hafifletilmesini sağlayarak hastaların yaşam kalitesini arttırmaya yöneliktir. Hastalıkta, medikal ve nöro cerrahi olarak iki ana tedavi yöntemi uygulanmaktadır (66). Bu yöntemlere ek olarak, fizik, konuşma terapisi ve palyatif bakım da hastalığın farklı aşamalarındaki ihtiyaçlarına ve semptomlarına göre hastalara yardımcı olabilmektedir (67).

Hastalığın medikal tedavisinde Levodopa kullanımı yaygındır. Beyinde dopaminerjik nöronların hasara uğraması nedeniyle dopamin üretimi azalmıştır. Dopaminin azalması, hastalığın motor bulgularının oluştuğunu göstermektedir. İlaç tedavisi ile dopamin seviyelerini artırmak ilk düşünülen yaklaşımdır. Hastalığın tedavisinin altın standardı olarak bilinen Levodopa, kan-beyin bariyerini geçebilen bir dopamin öncü


maddesidir. Ağızdan alınan bu ilaç, rijidite ve bradikinezi gibi motor bozukluklar ile birlikte çok çeşitli PH belirti ve bulgularını hafifletmektedir (68).

Hastalığın cerrahi tedavisinde Derin Beyin Stimülasyonu (DBS) yöntemi uygulanır. Bu yöntemde, hastanın beynine kalıcı olarak yerleştirilen bir elektrot implantı aracılığı ile yüksek frekanslı elektrik darbeleri verilmektedir. Bu elektrot daha sonra göğüste deri altına yerleştirilen bir puls yapıcı ile kontrol edilmektedir. Bu yöntem, bradikinezi ve katılık gibi PH'nin motor semptomlarını önemli ölçüde azaltmaya ve hastaların alması gereken Levodopa dozajının azaltılmasına da yardımcı olabilmektedir. Bu yöntem, hasta ilaç kullanmaya başladıktan sonra hastalığın ilerleyen aşamalarında gerçekleştirilmektedir. Bu da özellikle, hastaların ilaç tedavilerinin uzun süreli kullanımının yan etkilerini yaşamaya başladıktan sonra oldukça önemli hale gelmektedir (69, 70).

2.6. Elektroensefalografi

Canlıların beyin hücreleri elektriksel uyarılarla iletişim kurar ve uyku sırasında bile bu uyarılar aktiftir. Elektroensefalografi, kafa derisine takılan küçük elektrotlar vasıtasıyla, beyindeki elektriksel aktiviteyi ölçme işlemidir. Elektroensefalografi, uygulama kolaylığı olması ve nispeten ucuz olması sebebiyle pek çok psikiyatrik ve nörolojik hastalığın tanı ve takip sürecinde yaygın ve güvenilir bir yöntem olarak önerilmektedir. Hans Berger tarafından 1929 yılında ilk EEG kaydı gerçekleştirildikten sonra günümüze kadar ölçüm ve analiz konularında oldukça fazla yol katedilmiştir. Fiziksel anlamda tam periyodik olmayan fakat ritmik olan bu elektriksel potansiyellerin frekansları, beyin aktivitesine göre 0.5-70 Hz aralığında, genlikleri de 5-400 mikrovolt aralığında değişmektedir (71). Elektroensefalografi kayıtları, uluslararası bir ölçüm sistemi ile gerçekleştirilmektedir. Uluslararası 10-20 ölçüm sisteminde, beyin çapının önden arkaya ve soldan sağa doğru %10 veya %20 oranında ayrıldığı bir mesafe kesri ile yerleştirilir. Kafatasında nasyon ve inyon arasına çizilen bir hat boyunca beş nokta işaretlenir. Beş nokta; frontal kutup (Fp), frontal (F), sentral (C), perital (P) ve oksipital (O) olmak üzere sıralanır. Şekil 3'de 10-20 elektrot yerleşim sistemi yer almaktadır. Çift olan rakamlar (2, 4, 6, 8) kafatasının sağ yarı küresine, tek olan rakamlar (1, 3, 5, 7) ise sol yarı küreye karşılık gelmektedir. Kafatasının merkezindeki elektrotu ise Z elektrotu göstermektedir. Bu sistemle yerleştirilen elektrotlardan iki nokta birleştirilerek aralarındaki potansiyel fark ölçülmektedir. Tek kutuplu ve çift kutuplu olmak üzere iki çeşit birleştirme metodu bulunmaktadır. Tek kutuplu birleştirmede, genel olarak Cz veya kulakların arka tarafı referans nokta olarak


alınmaktadır. Çift kutuplu birleştirmede ise referans nokta durumu bulunmamaktadır. Elektrot çiftlerinden birbirine yakın olanlar seçilerek ortak gerilim önlenmeye çalışılmaktadır.



Şekil 3. Uluslararası 10-20 elektrot yerleşim sistemi (Özmen'den, 72)

Elektroensefalografi verilerinin toplanması ve analizinin üstün yönleri ve eksik yönleri vardır. Başlıca avantajı, beyin aktivitesini milisaniye mertebesinde geniş bir zamansal çözünürlükle gerçek zamanlı olarak izleme yeteneğine sahip birkaç teknikten biri olmasıdır. Bu sayede, nörolojik rahatsızlıkların tespitinde yaygın olarak kullanılmaktadır. Ayrıca kişiye herhangi bir zararının olmaması, sessiz ve kolay uygulanabilir olması, onu fMRI veya PET gibi diğer görüntüleme tekniklerinden avantajlı kılmaktadır. Ancak, EEG analizi için ileri işaret işleme ve akıllı karar verme algoritmalarının kullanımı gerekmektedir. Uzamsal çözünürlüğü düşük olduğundan, ölçüm esnasında elektrotların doğru yerleştirilmesi konusunda dikkat ve hassasiyet gerekmektedir.

Elektroensefalografi dalgaları Yunan rakamları kullanılarak frekans aralıklarına göre adlandırılmaktadır. En yaygın olarak incelenen dalga biçimleri arasında delta (0,1-4 Hz), teta (4-8 Hz), alfa (8-12 Hz), beta (13-30 Hz), sigma (12-16 Hz) ve gama (30-63 Hz) bulunmaktadır. Şekil 4'de EEG alt bantları sunulmuştur.



Şekil 4. Elektroensefalografi alt bantları (Sanei'den, 73)

2.6.1. Delta Dalgaları

Delta dalgaları 0.1-4 Hz frekans aralığında yer almaktadır. Genliği en yüksek ve en yavaş olan dalgadır. Bu dalgalar derin uykuya ilişkilendirilmiştir. Uyanık durumda gözlenmesi halinde beyinde fiziksel kusurlar olduğu düşünülmektedir. Ancak, bir yaşına kadar olan yeni doğmuş bebeklerde üçüncü ve dördüncü derece uykuda görülmesi oldukça normaldir. Genellikle yetişkinlerde frontal aralıklı ritmik delta ve çocuklarda posterior olarak oksipital aralıklı ritmik delta en belirgindir (74).

2.6.2. Teta Dalgaları

Teta dalgaları, 4-8 Hz frekans aralığındadır ve 20 mikrovolt'un üzerinde genliğe sahiptirler. Uyanık durumdaki yetişkinlerde görülmesi normal değildir. Ancak, 13 yaşına kadar uyku esnasında çocuklarda gözlenmesi doğaldır. Teta dalgalarının gözlendiği en geniş tepe noktası 7 Hz civarındır. Yaşa göre fazla teta anormal aktiviteyi temsil etmektedir. Fokal subkortikal lezyonlarda fokal bir bozukluk olarak görülebilmektedir. Teta dalgaları, rahatlama, meditasyon yapma ve yaratıcı durumlarla ilişkilendirilmiştir (74, 75).

2.6.3. Alfa Dalgaları

Alfa, 8-12 Hz frekans aralığında değişen dalgalar (74). Hans Berger, gözlemlediği ilk ritmik EEG aktivitesine alfa dalgası adını vermiştir. Başın her iki yarı küresinin arka bölümünde oksipital kortekste en iyi şekilde gözlenmektedir. Baskın tarafta genliği daha yüksek olan arka temel ritim olarak da adlandırılmaktadır. Sağlıklı kişilerde rahat durumdayken görülen esas ritimdir. Özellikle gözler kapalı haldeyken, arka kafa bölümlerinde uyumlu bir şekilde görüntülenmesi beklenmektedir. Gözler açık haldeyken, stres durumunda ve dikkatin yükseldiği anlarda alfa aktivitesi yok olmaktadır.

2.6.4. Beta Dalgaları

Beta, 13-30 Hz frekans aralığında yer almaktadır. Genellikle beynin her iki tarafında da simetrik dağılımlı olarak görülmektedir. En belirgin olarak beynin ön tarafında motor aktivitelerinin fazla olduğu frontal lobda bulunmaktadır. Beta frekansı motor davranışla yakından ilişkilidir ve genellikle aktif hareketler sırasında azalır. Genellikle 5-30 mikrovolt gibi düşük voltaja sahiptirler. Çoklu ve değişken frekanslara sahip düşük genlikli beta genellikle aktif olma, meşgul olma veya endişeli düşünme ve aktif konsantrasyon ile ilişkilidir. Uyanık veya endişeli olan ya da gözleri açık olan hastalarda baskın ritimdir (74).

2.6.5. Gama Dalgaları

Gama, yaklaşık 30-100 Hz frekans aralığında yer almaktadır. Gama ritimlerinin, belirli bir bilişsel veya motor işlevi yerine getirmek amacıyla farklı nöron topluluklarının bir ağına bağlanmasını temsil ettiği düşünülmektedir (74). Bu bandın bilinç mekanizmasını yansıttığı düşünülmektedir. Farklı modüller beyin fonksiyonlarının bir araya gelmesiyle yeniden yapılanabilir bir şekilde hareket ederler.

2.6.6. Mu Ritmi

Mu ritmi (Sensorimotor Ritim), ilk olarak Gastaut tarafından tepe noktası üzerinde ve presantral motor korteks boyunca iki taraflı olarak, C3, Cz ve C4 elektrot yerleşimlerinde bulunan 8-12 Hz'lik bir dalga olarak tanımlanmıştır (76). Mu ritmi vücut hareketsiz olduğunda normal bir ritim olarak mevcuttur. Ancak, kişi bir motor hareket gerçekleştirdiğinde veya hareketi düşündüğünde ritim zayıflamaktadır. Yani, tıpkı alfa ritminde olduğu gibi, o bölgenin işlevi çağrıldığında mu ritminin yerini yalnızca daha hızlı aktivitenin alması daha olasıdır. Mu dalgaları ve alfa dalgaları aynı frekans bandına

sahiptir. Ancak, alfa dalgaları oksipital kortekste gözlenmektedir (77). En yaygın kullanılan alt bant frekansları Tablo 1’de sunulmuştur.

Tablo 1. En yaygın kullanılan frekans bantları.

Bant	Frekans (Hz)	Amplitüd (μ V)	Oluştığı Yer
Alfa (α)	8-12	10-150	Oksipital/Parietal
μ -Ritmi	9-11	Değişken	Presantral/Postsantral
Beta (β)	13-30	25	Genellikle Frontal
Teta (θ)	4-7	Değişken	Değişken
Delta (δ)	< 3	Değişken	Değişken

2.6.7. Elektroensefalografi Ölçümü

Elektroensefalografi kayıtları, kafa yüzeyine yapıştırılan elektrotlar veya kafatasına geçirilen elektrot başlıkları ile gerçekleştirilmektedir. Kayıtlar esnasında kişilerin sakin bir ortamda olmaları ve hareket etmemeleri esastır. Kişinin hareketleri esnasında ve ışık, ısı, ses gibi dış kaynaklara bağlı artefaktlar (bozucu sinyalleri/etkileri) oluşmaktadır. Bu nedenle bazı tedbirler alınmaktadır. Standart EEG kayıtları, her biri 10 saniye olan 150–300 veya daha fazla sayıda kayıttan oluşmaktadır. Kayıtların doğru olması için hastanın sedatif ilaç almaması ve uzun süreli aç kalmaması gerekmektedir. Gözlerin açık ve kapalı olması durumunda EEG işaretleri farklı olmaktadır. Aşırı sinirlilik veya uyuklama hali de normal alfa ritmini baskılamakta ve kas kaynaklı artefaktları artırmaktadır (78). Parkinson hastaları için EEG kayıtları yapılırken, kişilerin ilaçlı veya ilaçsız olma durumları, hareket etmemeleri önem taşımaktadır. Kayıtların doğru yorumlanması için de karakteristik normal ve anormal ritimler ile temel ritimlerin tanınması, değişikliklerin ortaya koyulması için artefaktların temizlenmesi ve uygun ön işleme ve veri işleme tekniklerinin kullanılması önem taşımaktadır.

2.6.8. Dinlenme Durumu Elektroensefalografi

Dinlenme durumu EEG'si, beyin aktivitesinin yani herhangi bir belirli duysal yöntemle ilişkili olmayan, herhangi bir görev gerçekleştirmediğinde ortaya çıkan spontane sinirsel aktivitenin genel bir ölçümünü sağlamaktadır (79). Günümüzde AH ve PH gibi nörolojik rahatsızlığı olan hastaların dinlenme durumu EEG'leri yaygın şekilde kullanılmaktadır (80, 81). Dinlenme durumu EEG'si, katılımcılardan gözleri kapalı durumda, rahatlamaları ama uyanık kalmaları istenerek, kısa bir süre boyunca kaydedilmektedir. Dinlenme durumu, gözler açıkken de ortaya çıkmaktadır (82).

2.6.9. Parkinson Hastalığında Elektroensefalografi Biyobelirteçleri

Hastalık şiddetini veya semptomatolojisini tanımlarken altta yatan nedenlerin ortaya konulması zordur. Bu kapsamda yeni biyobelirteçlerin tanımlanması önem arz eder. Bu sayede, hastalığın ciddiyetini değerlendirebilmek için, yeni ölçüm yöntemlerinin kullanımı sağlanır. Biyobelirteçler, objektif olarak ölçülen ve normal biyolojik süreçleri, patofizyolojik süreçleri veya terapötik bir müdahaleye farmakolojik yanıtı gösteren bir faktördür. İyi bir biyobelirteç, yanlılığa veya önyargıya duyarlı değildir, ucuzdur, kolayca ulaşılabilir ve zararsızdır. Kortikal durumu niceliksel olarak yansıtan bir ölçüm aracı olan EEG gerekli biyobelirteçleri sağlayabilir. Elektroensefalografinin yaygın, ucuz ve invaziv olmayıp, kolay uygulanabilir olması, onu PH'nin altında yatan kortikal tutulum mekanizmasını incelemek için son derece uygun bir aday haline getirmektedir (83-85). Bu hem hastalar hem de doktorlar için yararlıdır. Elektroensefalografi metriklerinin türü genel olarak kortikal ritimlerin spektral ölçümleri, karmaşıklık ve bağlantısallık ölçümleri şeklinde üç gruba ayrılabilir. Elektroensefalografi metrikleri çok fazla miktarda olabilmektedir. Değişkenlerin yanı sıra küresel, bölgesel ve hatta elektrot düzeyindeki değişimler de doğrudan etki yaratmaktadır (86).

Spektral analizler, EEG verisi üzerinden yapılan doğrusal ölçümlerdir. Pek çok çalışma, PH'de beyin aktivitesinin spektral analizine odaklanmıştır. Bu çalışmalarda rastgele süreç teorisi durumunda, EEG sinyali genellikle doğrusal bir stokastik süreç olarak ele alınarak incelenmiştir. Spektral analizle, özellikle beta bandında, PH ile ilişkili çeşitli patolojik beyin ritmi tespit edilmiştir. Bununla birlikte, EEG alt bantlarındaki bu tür anormallikler zaten hastalığın erken evrelerinde meydana gelmektedir. Ayrıca, bir dizi çalışma PH'de, EEG'deki en yaygın anormalliğin beyin aktivitesinde genel yavaşlama olduğu sonucuna varmıştır (86).

Karmaşıklık, doğrusal olmayan bir yöntemdir. Bu tür doğrusal olmayan yöntemler, bilgi teorisine veya dinamik sistem teorisine (kaos veya fraktal gibi) ait oldukları için spektral analizden farklıdır. Karmaşıklık ölçümleri ile PH tarafından üretilen nörosinyallerdeki anormal dinamikler hakkında değerli sonuçlara ulaşılmıştır (86).

Bağılantısallık ölçümleri birden fazla beyin bölgesi arasındaki karşılıklı bağımlılığı yansıtırken, bu karşılıklı bağımlılığın tutarlılığının veya gücünün, beyin bölgeleri arasındaki senkronizasyonu yansıttığı kabul edilmektedir (86).

2.7. Literatür Özeti

Bugüne kadar literatürde PH'nin teşhisi için çok çeşitli kliniksel tanımlar ve sınıflandırma sistemleri uygulanmıştır. Motor inceleme, nöbetler, uyku aşamaları ve epilepsi gibi çeşitli nörolojik ve fizyolojik bozuklukların analizi için EEG yaygın olarak kullanılmaktadır. Bu kısımda PH'nin tanısında EEG kullanımına yer veren çalışmalara değinilmiştir. Alfa ve teta bandındaki EEG salınımlarının özellikle bilişsel ve hafıza performansını yansıttığına dair kanıtlar sunulmaktadır. Bununla birlikte, yaş ve hafıza performansı ile ilişkili olarak bireyler arası büyük farklılıklar gözlemlendiğinden de bahsedilmiştir (87).

Elektroensefalografi, PH'nin benzersiz özelliklerini tanımlayabilen potansiyel elverişli bir teşhis yöntemi olarak kabul edilmiştir (88). Bu yöntemi kullanan araştırmacılar, PH'lilerin, normal yaşlı yetişkinlere göre daha yüksek EEG anormallik oranlarına sahip olduğunu gözlemlemiştir. Parkinson hastaları, SK grupları ile kıyaslandığında, dinlenme durumundaki salınımlı beyin aktivitelerinde yavaşlama olduğu ve faz-genlik eşleşmesinde değişiklikler olduğu gösterilmiştir (89-92). Ayrıca PH'de, EEG'nin beta ve gama gücünün azaldığını ortaya koyan çalışmalar da bulunmaktadır (93, 94). Yapay zeka ve örüntü tanıma teknolojilerinin gelişmesiyle birlikte, bilgisayar destekli teşhise dayalı araçlar PH'nin erken teşhisi için bir çözüm olarak görülmüştür. Son yıllarda PH'yi otomatik olarak saptamak için çeşitli gelişmiş makine öğrenimi veya derin öğrenme algoritmaları ile EEG sinyal işleme konularında giderek artan sayıda çalışmalar yapılmaktadır (5, 6). Mei ve arkadaşlarının yapmış olduğu literatür taramasında, EEG ile PH tiplerini evre olarak ayırmaya yönelik sınıflandırma çalışmaları sıralanmıştır (95). EEG ile elektromyografi (EMG) birlikte kullanılarak hareket yönü ve bilişsel işlev bozukluğunu tespit etmeye dayalı çalışmalar da bulunmaktadır (96-100). Channa ve arkadaşları, PH'deki tremor şiddetini sinyal işleme ile ayırtmaya yönelik çalışmalar yapmıştır (101).

Güntekin ve arkadaşları, bilişsel bozuklukları olan PH hastalarında delta yanıtlarını analiz etmek amacıyla işitsel basit uyaranlar ve işitsel Oddball paradigmaları uygulayarak, PH olan hastalarda SK'lılara göre hedef stimülasyonun sunulması üzerine delta yanıtlarında azalma olduğunu tespit etmiştir (102). Maharramova ve arkadaşları, kognitif bozukluğu olmayan PH'li ve SK'lı bireylerde istirahat EEG kayıtlarını güç analizi yöntemiyle inceleyerek, PH'li motor semptomları ağırlaşan olgularda teta gücünü daha yüksek bulmuş ve teta gücündeki bu artışın kötüleşen motor semptomlar ile ilişkili olabileceğini düşünmüştür (103). Mantar ve arkadaşları, kognitif bozukluğu olmayan PH ve hafif kognitif bozukluğu ve/veya demansı olan PH'lilerde, SK'lılara göre görsel kognitif uyaran sırasında açığa çıkan alfa ve beta yanıtlarının nasıl değişiklik gösterdiğini incelenmiş ve hafif kognitif bozukluğu ve demansı olan PH olgularının hedef uyaran sırasında açığa çıkan beta yanıtlarını diğer iki gruba göre daha düşük bulmuştur. Beta faz kilitlenmesi sonuçlarına göre her üç grup C3, Cz, P3, O1, Oz ve O2 elektrotları arasında farklılık görülmüştür. Aynı şekilde, alfa faz kilitlenmesi analiz sonuçlarına göre de F3, Fz, F4, P4 ve O2 elektrotlarında gruplar arasında farklılık izlenmiştir (104). Çadırcı ve arkadaşları, kognitif bozukluğu bulunmayan PH tanısı ile izlenen ve PH tanısı almış, aynı zamanda hafif kognitif bozukluğu ve/veya parkinson demansı olan PH'li ve SK'lı bireylerin olaya ilişkin EEG koherans analizinde, hedef uyaran sırasında açığa çıkan delta yanıtlarının hedef olmayan uyarandan daha yüksek olduğunu göstermiştir. Teta frekans bandında lokasyon değişkeni ve gruplar arasında fark anlamlı bulunmuştur. Tüm grupların birlikte değerlendirildiği nöropsikometri ve koherans değerlerinin korelasyon analizinde, çizgi yönünü belirleme testi ve yüz tanıma testleriyle, delta frekans bandında C3, P3 bölgesinde yer alan elektrot çifti arasında pozitif korelasyon görmüştür. Parkinson hastalarında olaya ilişkin delta ve teta koherans değerlerinin SK'lılardan daha düşük olduğunu göstermiştir (105).

Chaturvedi ve arkadaşları 2017 yılında, 50 PH'li ve 41 SK grubundan oluşan yüksek çözünürlüklü EEG ölçümlerini karşılaştırarak, temporal sol bölgedeki teta gücünün ve orta sol bölgedeki alfa1/teta oranının sınıflandırmada en etkili değişkenler olduğunu ortaya koymuştur. Makine öğrenme yöntemlerinden sırasıyla, LR ile %56, RO ile %78, DVM ile %74 ve J48 KA ile %68 doğruluk sonuçlarını elde etmiştir (106). Quynh Tran ve arkadaşları aynı yıl, EEG sinyallerinden birkaç tane bağımsız bileşenin ayırt edici frekans tabanlı öznelitliklerini S-dönüşümü ayrışması yaparak çıkarmıştır. Bayes sinir ağları kullanılarak frekans tabanlı öznelitlikler ile yaptıkları sınıflandırmada %86,2

doğruluk, %88 özgüllük ve %84,2 hassasiyet elde etmiştir (107). Yuvaraj ve arkadaşları 2018 yılında, EEG sinyallerinin yüksek dereceli istatistiksel özniteliklerini çıkararak, DVM makine öğrenme yöntemi kullanarak yaptıkları çalışmada PH sınıflandırmasında %99,62 doğruluğa ulaşmıştır (108). Betrouni ve arkadaşları 2019 yılında, PH'de Güç Spektral Yoğunluğu (PSD) öznitelikleri ile bilişsel bozulmanın seviyesini beş gruba ayırmak için DVM ve KNN makine öğrenme yöntemi ile sırasıyla %84 ve %88 oranında sınıflandırma doğruluğuna ulaşmıştır (109). Anjum ve arkadaşları 2020 yılında, EEG'den PH tespiti için bir doğrusal tahmine dayalı kodlama ile yaptıkları sınıflandırmada %85,7 doğruluğa ulaşmıştır (110). De Oliveira ve arkadaşları aynı yıl, fotik stimülasyonu, kısmi yönlendirilmiş tutarlılık öznitelikleri ve RO makine öğrenmesi yöntemi ile %99'un üzerinde sınıflandırma doğruluğu elde etmiştir (111). Khare ve arkadaşları 2021 yılında, EEG'den PH tespiti için otomatik ayrıştırma için otomatik olarak ayarlanabilir bir Q dalgacık dönüşümü önermiştir. Analiz için temsili EEG alt bantlarından beş öznitelik çıkarmış ve en küçük kareler DVM yöntemini kullanarak başarılı şekilde sınıflandırmıştır (112). Khare ve arkadaşları bir başka çalışmalarında ise EEG sinyallerini kullanarak PH'nin tespitine yönelik PH evrişimsel sinir ağı (PDCNNNet) isimli otomatik bir arayüz geliştirmiştir (113). Loh ve arkadaşları aynı yıl, dinlenme durumu EEG verisinden 16 SK ve 15 PH'li bireyin verilerine Gabor dönüşümü uygulayarak iki boyutlu evrişimli sinir ağı modelini eğitmek için EEG verilerini spektrogramlara dönüştürerek %99,46 sınıflandırma doğruluğu elde etmiştir (114). Barua ve arkadaşları 16 SK ve 15 PH'li bireyden oluşan dinlenme durumu EEG verisi ile yeni aspirin deseni, istatistiksel momentler ve maksimum mutlak havuzlama öznitelik çıkarımı yaparak, KNN algoritması ile %100 doğruluk elde etmiştir (115). Lee ve arkadaşları 2022 yılında, Hjorth parametresi ve GB makine öğrenmesi yöntemi ile yaptıkları sınıflandırmada %89,3 doğruluk ile bir tahmin yöntemi önermiştir (116). Aljalal ve arkadaşları aynı yıl, ilaçlı ve ilaçsız PH'liyi saptamak amacıyla yeni, verimli, ortak uzamsal örüntüler ve entropiye dayalı yaklaşımlar ile %95 ile %99 arasında değişen sonuçlar elde etmiştir (117). Shaban ve arkadaşları yine aynı yıl, 16 SK ve 15 PH'li bireyden oluşan dinlenme durumu EEG verisi ile sürekli dalgacık dönüşümü öznitelik çıkarımı ve iki boyutlu evrişimsel sinir ağı (CNN 2D) algoritması ile %99,8 doğruluk sonucu elde etmiştir (118). Suuronen ve arkadaşları 2023 yılında, EEG örnek entropisine dayalı makine öğrenimini kullanarak, elektrot sayısı ve yerleşiminin PH ve SK'lı kişilerin sınıflandırmasını nasıl etkilediğini araştırmıştır. Sınıflandırma için optimize edilmiş kanal setlerini seçmek için özel bir bütçe tabanlı arama algoritması

kullanarak %76 doğruluk değerine ulaşmıştır. Seçilen bölgeler sağ ön, sol temporal ve orta hat oksipital bölgeleri içermektedir. Kanalların rastgele seçilen alt kümeleriyle yapılan karşılaştırma ile sınıflandırıcı performansının yalnızca nispeten küçük kanal bütçeleriyle arttığını göstermiştir (119). Göker yine aynı yıl, 14 PH ve 14 SK'lı bireyden oluşan dinlenme durumu EEG veri setinde EEG sinyallerinin 1-49 Hz arasındaki frekanslarının PSD'sini Periodogram, Welch ve Multitaper spektral analiz yöntemleri kullanarak ayrı ayrı hesaplanmış ve üç farklı deneyin her biri için 49 öznitelik vektörü çıkararak çift yönlü uzun kısa süreli bellek algoritması ile Welch spektral analizini birleştiren model ile %97,92 doğruluk sonucuna ulaşmıştır (120). Karakaş ve arkadaşları aynı yıl, PH ile ilişkilendirilen EEG sinyallerindeki beta aktivitesi ve genlik azalmasını kullanarak, 61 PH ve 61 SK'lı bireyden oluşan üç veri seti ve dinlenme durumu gözler açık veri ile Iova verisinde %85.7, Turku verisinde %63.25 doğruluk sonucuna ulaşmıştır (121). Chawla ve arkadaşları aynı yıl, 16 SK ve 15 PH'li bireyden oluşan dinlenme durumu EEG verisi ile esnek analitik dalgacık dönüşümü yaparak altı entropi özniteliği ve KNN algoritması ile %95.85 doğruluk değerine ulaşmıştır (122).

Son yıllarda veri boyutlarının artması ile birlikte derin öğrenme yöntemlerinin uygulama alanı da artmıştır. Literatürde PH tanısı için farklı veri setleri ile denenmiş %80'den, %100 sınıflandırma doğruluğuna ulaşabilen derin öğrenme çalışmaları da yer almaktadır (123, 124). Ancak, derin öğrenme yöntemi uzun eğitim süresi ve büyük veri seti gerektirdiği için gerçekte uygulamada zorluklar oluşabilmektedir. Bu nedenle bu çalışmada öncelikle makine öğrenme yaklaşımları kullanılmıştır. Bu modeller karmaşık olmadığından ve uzun bir eğitim süresi veya büyük miktarda bilgisayar belleği gerektirmediğinden daha çok tercih edilmektedir.

Bu doktora tezi kapsamında dinlenme durumu PH tanısında öznitelik çıkarımı için ilk kez önerilen Kolmogorov Algoritmik Karmaşıklık (KAC) özniteliği şizofreni hastalarının SK grubu ayırma yönüne yönelik yapılan bir çalışmada kullanılmıştır. Akar ve arkadaşları, şizofreni olanların beyin bölgelerinde EEG karmaşıklığını tespit etmek için KAC özniteliğinin diğer tahmin edicilere göre daha duyarlı olduğunu göstermiştir (125). Ayrıca Vicnesh ve arkadaşları, EEG'den epilepsi hastalığının teşhis edilmesine yönelik olarak yaptıkları bir çalışmada, dört adet lineer olmayan KAC, tekil değer ayrışımı, hareketlilik ve permütasyon entropisi özniteliğini kullanarak, KAC özniteliği ile en yüksek sonuca ulaşmıştır (126).

Parkinson hastaları ve SK'lıları kategorize etmek amacıyla KN ve arkadaşları, mutluluk, üzüntü, korku, öfke, şaşkınlık ve iğrenme gibi duygusal EEG uyaranları ile her bir EEG sinyali için alfa, beta ve gama bandı frekansını kullanarak, entropi, enerji entropi, teager enerji entropi, spektral entropi, spektral enerji entropi ve spektral teager enerji entropi özniteliklerini çıkarmıştır. Entropi öznitelikleri ve DVM, KNN algoritmaları ile %95'in üzerinde doğrulukla birkaç duygu için değişken sonuçlara ulaşmıştır (127).

Bu doktora tezi kapsamında PH sınıflandırmasında ilk kez kullanılan bir başka öznitelik olan ağırlıklı sembolik karşılıklı bilgi (wSMI), fonksiyonel bağlantı ölçümleri, yani beynin bölgeler arası etkileşimlerini tanımlamak için Imperatori ve arkadaşarı tarafından kullanılmıştır. Fonksiyonel bağlantı ölçümlerinden ağırlıklı faz gecikme endeksi (wPLI) ve wSMI öznitelikleri kullanılarak, uyanıklığın dört aşaması ve REM uykusu arasındaki işlevsel farklılıklar araştırılmıştır. Dört yönlü uyanıklık aşamaları sınıflandırması için, güç ve her iki bağlantı metriğine dayalı özniteliklerin birleştirilmesi, yalnızca güç, wPLI veya wSMI özniteliklerinin doğruluğunu önemli ölçüde arttırdığı görülmüştür (128).

Literatürde pek çok farklı öznitelik yaklaşımı ve farklı türde makine öğrenme yöntemleri kullanılmasına rağmen, PH'lilerin dinamikleri değişiklik gösterdiğinden tek tip bir yöntemin üstünlüğünden şimdiye kadar bahsedilememektedir. Bu alanda çalışmalar sürdüğünden bu doktora tezi kapsamında da yeni tip öznitelikler araştırılması yoluna gidilmiştir. Makine öğrenmesi yöntemleri ile sonuçlar değerlendirilmiştir. Karşılaştırma amacıyla en yaygın kullanılan derin öğrenme yöntemleri ile de denemeler yapılmıştır.

3. GEREÇ ve YÖNTEM


Bu doktora tezi kapsamında üç farklı açık kaynaklı veri seti ile çalışılmıştır. Bu veri setleri; ABD’den Iowa Üniversitesi ve San Diego Üniversitesi, Finlandiya’dan ise Turku Üniversitesi tarafından kaydedilip, internet erişimine açılmıştır (108, 129, 130). Doktora tez çalışmasının amacı olan kognitif bozukluğu olmayan PH’nin erken evre tanısı için EEG verilerine dayalı olarak bir karar verme yöntemi geliştirilmesi için çalışmalar üç farklı açıdan ele alınmıştır. İlk olarak veri ön işleme teknikleri dikkate alınarak, frekans domeni öznitelikleri ilk defa PH’li EEG verilerinden çıkarılmıştır. Özniteliklerin performansları klasik ve modern makine öğrenmesi yöntemleri ile PH ve SK grubunu doğru şekilde ayırdetmek üzere, kanal sayısı, kanal yeri gibi açılardan ayrı ayrı değerlendirilmiş ve sonuçları literatürle karşılaştırmalı olarak sunulmuştur. Ayrıca, literatüre bu tez çalışmasının ürünü olarak yeni öznitelikler sunulmuştur. İkinci olarak, klasik ve modern sınıflandırma yöntemlerine dair bir performans değerlendirmesi sunulmuştur. Son olarak, bu doktora tez çalışmasının özgün yönlerinden biri olarak, EEG verisi ses verisine dönüştürülmüş, yeni tip öznitelikler olan müzik öznitelikleri çıkarılarak sınıflandırma sonuçları değerlendirilmiştir. Ayrıca tez kapsamında, derin öğrenme yöntemi ile de sınıflandırma yapılmış ve sonuçlar, diğer makine öğrenmesi yöntemlerinin sonuçları ile karşılaştırmalı olarak sunulmuştur.

3.1. Kullanılan Veri Setleri


3.1.1. Iowa Veri Seti

Iowa EEG veri seti, Iowa Üniversitesi tarafından kaydedilen halka açık bir veri setidir (108). Veri seti, 14 PH ve 14 SK grubundan oluşan dinlenme durumu EEG kayıtlarını içermektedir. Bu veri setinde yer alan veriler, ilaçlı veya ilaçsız duruma mı ait olduğu açıkça belirtilmemiştir. Literatürden yola çıkılarak bu çalışmada doğrudan PH ON (ilaçlı) durumu olarak değerlendirilmiştir. EEG kayıtları 64 kanallı sinterlenmiş Ag/AgCl elektrotları olan bir Brain Vision sistemi ile gerçekleştirilmiştir. Kayıtların her biri, en az 2 dakika, 500 Hz örnekleme hızında, 0,1 ile 100 Hz frekans aralığında kaydedilmiştir. Referans olarak Pz kanalı kullanılarak çevrimiçi referansla kaydedilmiştir. Veri işleme aşamasında Pz kanalı referans olarak seçildiğinden, bu kanala ait veriler kullanılmamıştır. Iowa veri setine ait 63 kanallı EEG elektrotları önden arkaya doğru sırasıyla ; Fp1, Fz, F3, F7, FT9, FC5, FC1, C3, T7, TP9, CP5, CP1, P3, P7, O1, Oz, O2, P4, P8, TP10, CP6, CP2, Cz, C4, T8, FT10, FC6, FC2, F4, F8, Fp2, AF7, AF3, AFz, F1, F5, FT7, FC3,

C1, C5, TP7, CP3, P1, P5, PO7, PO3, POz, PO4, PO8, P6, P2, CPz, CP4, TP8, C6, C2, FC4, FT8, F6, AF8, AF4, F2, FCz'den oluşmaktadır. Brain Vision sistemine ait elektrot yerleşim düzeni Şekil 5'de yer almaktadır. Şekil 6'da ise SK ve PH'li bireylere ait ham EEG görüntüsü görülmektedir. Burada x eksenini saniye cinsinden kayıt süresini, y eksenini ise elektrot kanallarını göstermektedir.




Şekil 5. Iova veri seti 63 kanal EEG elektrot konumları




Şekil 6. Iova SK ham EEG görüntüsü. (a) Iova PH ham EEG görüntüsü. (b)

3.1.2. San Diego Veri Seti

İkinci veri seti, Kaliforniya'daki San Diego Üniversitesi veri setidir (129). San Diego veri seti, sağ el baskın 15 PH ve 16 SK grubuna ait dinlenme durumu EEG verisidir. Hastaların tümü hafif veya orta şiddette PH'ye sahip olan, ABD'deki Scripps Clinic'ten alınmıştır. Sağlıklı Kontrol grubu yerel gönüllülerden oluşturulmuştur. On beş PH'li grubun tümünün EEG verileri, hem ilaçlı hem de ilaçsız veriler içermektedir. EEG kayıtları, 32 kanallı Biosemi Active Two EEG sistemi ile gerçekleştirilmiştir. Kayıtlar 512 Hz örnekleme frekansında 3 dakika boyunca gerçekleştirilmiştir. San Diego veri setinin elektrot kanalları Fp1, AF3, F7, F3, FC1, FC5, T7, C3, CP1, CP5, P7, P3, Pz, PO3, O1, Oz, O2, PO4, P4, P8, CP6, CP2, C4, T8, FC6, FC2, F4, F8, AF4, Fp2, Fz ve Cz'den oluşmaktadır. Biosemi Active Two EEG sistemine ait elektrot yerleşim düzeni Şekil 7'de yer almaktadır. Şekil 8'de ise SK ve PH'li bireylere ait ham EEG görüntüsü görülmektedir.




Şekil 7. San Diego veri seti 32 kanal EEG elektrot konumları




Şekil 8. San Diego SK ham EEG görüntüsü. **(a)** San Diego PH ham EEG görüntüsü. **(b)**

3.1.3. Turku Veri Seti

Bu veri seti Finlandiya Turku Üniversitesi tarafından kaydedilmiş ve açık kaynaklı olarak kullanıma açılmıştır (130). Turku veri seti, 20 PH ve 20 SK grubundan oluşan toplam 40 hastanın dinlenme durumu EEG kayıtlarını içermektedir. Bu kayıtlarda ilaçlı durumda hem gözler açık hem de gözler kapalı veriler yer almaktadır. Bu doktora tezinde sadece göz açık veri seti kullanılmıştır. EEG kayıtları, 64 kanallı NeurOne Tesla cihazı ile kaydedilmiştir. Örnekleme frekansı 500 Hz'dir. Veriler, iki dakika süresince gözler açık ve iki dakika gözler kapalı kaydedilmiş ve ortalama referans ile referanslanmıştır. Turku veri setinin elektrot kanalları Fp1, Fp2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T7, T8, P7, P8, Fz, Cz, Pz, Iz, FC1, FC2, CP1, CP2, FC5, FC6, CP5, CP6, FT9, FT10, TP9, TP10, F1, F2, C1, C2, P1, P2, AF3, AF4, FC3, FC4, CP3, CP4, PO3, PO4, F5, F6, C5, C6, P5, P6, AF7, AF8, FT7, FT8, TP7, TP8, PO7, PO8, Fpz, CPz, POz, Oz'den oluşmaktadır. NeurOne Tesla EEG sistemine ait elektrot yerleşim düzeni Şekil 9'da yer almaktadır. Şekil 10'da ise SK ve PH'li bireylere ait ham EEG görüntüsü görülmektedir.



Şekil 9. Turku veri seti 64 kanal EEG elektrot konumları



Şekil 10. Turku SK ham EEG görüntüsü. (a) Turku PH ham EEG görüntüsü. (b)

Her üç veri seti PH ve SK grubu yaş ve cinsiyet açısından eşleştirilmiştir. Eğitimleri ve zeka ölçülerinde herhangi bir farklılık bulunmamaktadır. Her üç veri setine ait SK ve PH gruplarının demografik bilgileri karşılaştırmalı olarak Tablo 2’de sunulmuştur. Ayrıca bu üç veri setinin elde edilme yöntemlerine ait unsurlar karşılaştırmalı olarak Tablo 3’de verilmiştir.

Tablo 2. Veri setlerinde yer alan SK ve PH grubunun demografik bilgileri.

	San Diego		Iowa		Turku	
Durum	PH	SK	PH	SK	PH	SK
Sayı	15	16	14	14	20	20
Cinsiyet (kadın/erkek)	8k/7e	9k/7e	8k/6e	8k/6e	11k/9e	12k/8e
Yaş (ortalama yıl $\pm$ SS)	63.2 $\pm$ 8.2	63.5 $\pm$ 9.6	70.5 $\pm$ 8.7	70.5 $\pm$ 8.7	69.8 $\pm$ 7.2	67.8 $\pm$ 6.2
NAART	46.1 $\pm$ 6.3	49.1 $\pm$ 7.1	–	–	-	-
MMSE	28.9 $\pm$ 1.0	29.2 $\pm$ 1.1	–	–	27.8 $\pm$ 1.8	28.2 $\pm$ 1.5
MOCA	–	–	25.9 $\pm$ 2.7	27.2 $\pm$ 1.7	-	-
BPHDÖ	39.2 $\pm$ 9.7 (OFF)/ 32.7 $\pm$ 10.4 (ON)	–	13.4 $\pm$ 6.6	–	28.9 $\pm$ 16.4	5.1 $\pm$ 3.5
Kaç yıldır PH	4.5 $\pm$ 3.5.	–	5.6 $\pm$ 3.2	–	6.4(4.9)	-

NAART, Kuzey Amerika Yetişkin Okuma Testinden Alınan Puanlar; MMSE, Mini Mental Durum Sınavı; MOCA, Montreal Bilişsel Değerlendirme; BPHDÖ, Birleşik Parkinson Hastalığı Derecelendirme Ölçeği (motor). OFF, 12 saat ilaç almamış ve ON, normal zamanında ilacını almış.

Tablo 3. Veri setlerinin ölçüm parametreleri.

Durum (dinlenme durumu)	San Diego veri seti	Iowa veri seti	Turku veri seti
Kullanılan cihaz	Biosemi Active Two EEG sistemi	Brain Vision sistemi	NeurOne Tesla sistemi
Kanal sayısı	32	64	64
Gözler açık/kapalı	Açık	Açık	Açık
Örnekleme hızı	512 Hz	500 Hz	500 Hz
Süre	3 dakika	2 dakika	2 dakika
Referans kanal	Merkezi referans	Pz	Ortalama referans

3.2. Veri Analizi


Elektroensefalografi sinyalleri, beyin fonksiyonlarıyla ilgili çok miktarda bilgi içermektedir. Bu bilgilerin hastalık teşhisinde kullanılması çıplak gözle olmasının yanında, günümüzde modern parametrik yöntemler ve işaret işleme yöntemleri kullanılarak yapılmaktadır. Bu bağlamda, son yıllarda kullanılan yapay zeka ağırlıklı yöntemler ile

hastalık teşhisi giderek daha yüksek doğruluk oranı ile tanımlanabilir duruma gelmiştir (5, 6).

Sinyallerin analiz edilmesi doğrudan sinyalin kendisi veya sinyalin gösteriminin zaman, frekans gibi başka boyutlara taşınmasıyla gerçekleştirilmektedir. Buradaki amaç; sinyalin bilgi kaybına uğratılmadan, bu boyutlardan birisine dönüşümü yapılarak, işlenmemiş haldeki verilerden sağlıklı seçilemeyen anlamlı detay bilgilerine ulaşmaktır. Öncelikle dönüşüm işlemine ihtiyaç duyulur. Herhangi bir sinyalden daha fazla bilgi almak için matematiksel dönüşüm işlemi uygulanmaktadır. Mevcut birçok dönüşüm tekniği farklı tip sinyaller ve amaçlar için kullanılmaktadır. Örnek olarak; Hilbert, Kısa Zamanlı Hızlı Fourier dönüşümü (STFT), Wigner, Radon ve Wavelet dönüşümü gibi (131).

3.2.1. Elektroensefalografi Veri Analizi

Bu bölümde, çok ve tek kanallı EEG sinyalleri kullanılarak SK ve PH'nin analizi ve saptanması için gerçekleştirilen adımlar bulunmaktadır. Şekil 11'de, bu çalışmada izlenen adımlar yer almaktadır. Bu akış şeması, çok ve tek kanallı ham EEG veri setlerinin, kanal seçimi, filtreleme ve segmentleme ile sinyalin ön işlenmesi yapılarak sinyal ayrıştırmasını, öznelik çıkarımını ve PH'nin tanımlanması için sınıflandırmayı göstermektedir.



Şekil 11. Elektroensefalografi verisinin analiz şeması

3.2.1.1. Önışleme Aşamaları

Genel olarak ön işleme, ham verinin daha ileri analizlere uygun ve yorumlanabilir bir formata dönüştürülmesi işlemidir. Bu verilerin, ön işlenmesi genellikle gerçek sinir sinyallerine yaklaşmak için verilerden gürültünün çıkarılması anlamına gelmektedir. Elektroensefalografi verileri için ön işlemenin gerekli olmasının birkaç nedeni vardır. Her şeyden önce kafa derisinden alınan sinyaller, mekansal bilgi kaybaldığından, beyinden kaynaklanan sinyallerin tam olarak doğru bir temsili olmayabilir. İkincisi, EEG verileri, daha zayıf EEG sinyallerini gizleyebilecek çok fazla gürültü içermeye eğilimindedir. Göz kırpması veya kas hareketi gibi artefaktlar, verileri kirletebilir ve resmi bozabilir. Son olarak da ilgili sinir sinyallerini, EEG kayıtları sırasında oluşan rastgele sinirsel aktivitelerden ayırmak gerekmektedir.

Bazen EEG verileri (özellikle yüksek yoğunluklu EEG verileri), doğru bilgi sağlamayan 'kötü' kanallar içerebilir. Bu verilerin saklanması daha sonraki analizleri etkileyeceği için bunları erkenden analizden çıkarmak önemlidir. Kötü kanalları işaretledikten sonra, iyi kanallardan gelen verilere dayanarak kötü kanallara ilişkin verileri enterpolasyona tabi tutmak yaygın bir uygulamadır. Enterpolasyon, mevcut diğer verilere dayanarak eksik verileri doldurmanın bir yoludur.

Mevcut tez çalışmasının veri analizinin tüm aşamaları Python programlama dili ile ve Google Colab ortamında merkezi işlem birimi (CPU) kullanılarak gerçekleştirilmiştir. Python ile EEG verilerinin işlenebilmesi amacıyla mne, numpy, pandas, matplotlib vb. kütüphaneler Google Colab Python ortamında kurulup, yapılandırılmıştır.

Iowa EEG verileri Brain Vision sisteminde kaydedildiği için vhdr uzantılı, San Diego verileri bdf uzantılı ve Turku verileri ise set uzantılı ham EEG dosyaları içermektedir. Bu veriler mne kütüphanesi ile raw nesnesine dönüştürülerek Google Colab ortamına aktarılmıştır. Ön işleme aşamasında, kanal seçimi, filtreleme ve bölütleme yapılmıştır.

Kanal seçimi

Hastalığın tespiti öncelikle hastalara bağlı olduğundan, veri setinde de aynı sayıda SK ve PH sınıf etiketine sahip dengeli veri seti ile çalışılmıştır. Her üç veri seti için de öncelikli olarak sahip oldukları kanalların Iowa 63 (14 SK ve 14 PH), San Diego 32 (16 SK ve 15 PH) ve Turku 64 (20 SK ve 20 PH) kanal verisi kullanılarak analiz yapılmıştır. Daha

sonra her üç veri setinde ortak 31 kanal üzerinden analiz yapılmıştır. Sonrasında sensorimotor kortekse en yakın olan 10 kanalın (FC5, FC1, FC2, FC6, C3, C4, CP5, CP1, CP2, CP6) ve 4 kanalın (FC1, FC2, CP1, CP2) delta, teta, alfa, beta, gama frekans bantlarında kanal ortalamaları alınarak ve yine tek kanal olarak sensorimotor kortekste yer alan ve veri setinde en iyi sonuç üreten motor fonksiyonların ve bilişsel fonksiyonların merkezi olan santral ve frontal bölgeden, sağ ve sol alandan karşılıklı olarak seçilen C3, C4, CP5, CP6, FC1, FC2 kanallarından gelen bilgileri analiz etmek amacıyla bu kanallardan gelen bilgiler alınmış ve kişi başına tek bir veri noktası olarak analiz edilmiştir. Bununla birlikte, beynin ön ve arka bölümlerinin PH’de, fonksiyonlarının değişimini değerlendirmek amacıyla ön ve arkada yer alan ve sağ, sol bölgeden karşılıklı olarak seçilen Fp1, Fp2, O1, O2 elektrot kanalları ayrı ayrı analiz edilerek kullanılmıştır.

Tez kapsamında kanal seçimi, PH’de farklı durumlardaki etkinin incelenmesi için ele alınmıştır. Beynin SK’lı bireylerdeki fonksiyonları ve PH’lilerdeki değişimleri düşünülerek, literatürden referans alınarak Tablo 4’de yer alan kanal seçimleri yapılmıştır (132).


Tablo 4. Analiz yapılan kalan sayıları.

Veri seti	64 kanal ortalaması (Tüm kanal)	63 kanal ortalaması (Tüm kanal)	32 kanal ortalaması (Tüm kanal)	31 kanal ortalaması (Tüm kanal)	18 kanal	10 kanal	6 kanal	4 kanal	Tek kanal
Iova	-	+	-	+	+	+	+	+	+
San Diego	-	-	+	+	-	+	-	+	+
Turku	+	-	-	+	+	+	+	+	+

Fitreleme

İster ses, ister EEG olsun, ister başka bir dijital sinyalin frekanslarına bakarken yapılacak adımlardan biri, belirli frekansları filtrelemektir. Böylece ya bazı frekanslar kaldırılır ya da muhtemelen bazı filtreler kalır. Bu nedenle, artefaktları ortadan kaldırmak amacıyla EEG sinyallerinin uygun şekilde filtrelenmesi gerekmektedir. Çalışma türlerine göre filtreler, alçak geçiren filtreler, yüksek geçiren filtreler, bant geçiren filtreler ve bant

durduran filtreler olmak üzere dört ana başlık altında toplanmaktadır. Filtrenin kullanım amacına göre bu filtreler seçilmektedir. Alçak geçiren filtreler, kesim frekansı olarak belirlenen frekanstan daha düşük olanları geçiren ve daha yüksek frekansların geçmesine engel olan filtrelerdir (133). Yüksek geçiren filtreler, kesim frekansı olarak belirlenen frekans değerinden daha büyük frekanslı sinyalleri geçirir ve daha düşük frekanslı sinyalleri sönümleyerek iletimine engel olurlar (134). Bant geçiren filtreler, istenilen iki frekans aralığındaki frekansları geçiren ve bu aralık dışındaki frekansları engelleyen filtrelerdir. Bant geçiren filtreler alçak ve yüksek geçiren filtrelerin birleşimi olarak da düşünülebilmektedir. Bant durduran filtreler, belirli iki frekans aralığındaki sinyalleri zayıflatırken bu aralık dışında kalan sinyallerin iletimine izin verirler. Filtre türleri Şekil 12’de sunulmuştur.



Şekil 12. Filtre türleri (135)

Bu tez çalışmasında belirlenen problem ele alma sırasına göre önce, ham verilerde kanal seçimi yapılmıştır. Daha sonra birinci senaryoda, ham veriye 0.5 Hz ve 45 Hz arası bant geçiren filtre ve 60 Hz ve 100 Hz’de çentik filtre uygulanarak filtreleme yapılmıştır. İkinci senaryoda, 0.1 Hz ve 120 Hz arası bant geçiren filtre ve 60 Hz ve 100 Hz’de çentik filtre uygulanarak filtreleme yapılmıştır. Iowa ve San Diego veri setleri ABD’ye ait olduğundan 60 Hz şebeke gürültüsü ve Turku veri seti ise Avrupa’ya ait olduğundan 50 Hz şebeke gürültüsü oluşmaktadır. Bu gürültüleri gidermek amacıyla ABD verilerinde 60 Hz ve Avrupa verilerinde 50 Hz çentik filtre uygulanmıştır.

Bölütleme

Bölütleme (Segmentleme), uzun EEG sinyallerinden oluşan zaman serisi doğrusal ve durağan olmaması nedeniyle, sinyal kısa süreli bölümlere ayrılmalıdır. Elde edilen kısa süreli segmentlerin istatistiksel özelliklerinin aynı olması beklenmektedir (136). Bu nedenle, filtrelemeden sonra, bu sinyaller senaryolara göre Hamming pencere yapısı kullanılarak 20 ve 40 saniyelik birbiri ile örtüşmeyen zaman penceresi uzunluğuna bölünmüştür. Bu tek kanal bilgilerinden elde edilen her örnek, her biri birinci senaryoda 20 saniyelik epoklara ve ikinci senaryoda 40 saniyelik epoklar ile daha küçük örneklerle bölünmüştür.

Öznitelik çıkarımı

Öznitelik çıkarma, ham verileri, orijinal veri setindeki bilgileri korurken işlenebilecek sayısal özelliklere dönüştürme işlemidir. Burada bilgi işlemenin karmaşık yapısını azaltmak amacıyla ham verilere boyutsal bir indirgeme yapılarak veri sayısal özniteliklere dönüştürülmektedir. Bu boyutu azaltılmış veri giriş sinyali özniteliklerini doğru bir şekilde tanımlayarak, etkili bir sınıflandırıcının geliştirilmesini sağlayabilmektedir (72, 137, 138). Böylece makine öğrenimini doğrudan ham verilere uygulayarak ulaşılan sonuçlardan, daha iyi sonuçlar elde edilmektedir. Öznitelik oluşturma süreci makine öğrenmesi alanının zorlu yönlerinden birini oluşturmaktadır.

Tez kapsamında öznitelik çıkarımı iki kısımda ele alınmıştır. Öncelikle, doğrudan EEG elektriksel verisi üzerinden frekans domeni öznitelikleri çıkarılmıştır. Burada elde edilen, PSD Delta, PSD Teta, PSD Alfa, PSD Beta, PSD Gama, Spektral Entropi (SE), Median Spektral Frekans (MSF), KAC, wSMI Delta, wSMI Teta, wSMI Alfa, wSMI Beta, wSMI Gama öznitelikleri frekans domeni öznitelikleridir. Ayrıca doktora tezi kapsamında frekans domeni özniteliklerine dayanarak, aritmetik hesaplamalara dayalı olarak yeni öznitelikler de elde edilmiştir.

İkinci olarak öznitelik çıkarımı, EEG işaretlerinin ses işaretlerine dönüştürülerek, bu ses işaretleri üzerinden yapılmıştır. Bu verilerden Ayırık Dalgacık Paket Dönüşümü (DWPT) ve kroma tabanlı öznitelikler çıkarılmıştır.

Güç Spektral Yoğunluğu

Güç Spektral Yoğunluğu, sinyalin, güç içeriğinin frekansa karşı ölçüsü yani sinyalin frekans bandı üzerindeki güç dağılımıdır. Burada, zamanda değişen sinyaller, frekans alanına aktarılır ve sinyalin frekans aralıklarındaki güç dağılımları elde edilir (139, 140). Güç Spektral Yoğunluğunun genliği, sinyali dijitalleştirmek amacıyla kullanılan spektral çözünürlük ile normalize edilmektedir. Birimi V^2/Hz ya da dB (i.e., $10\log_{10}(V^2/Hz)$) olarak kullanılmaktadır.

Fourier dönüşümü kullanılarak rastgele bir sinyalin gücünün farklı frekanslara dağılımı hesaplanmaktadır. Bir sinyalin gücü karesi alınarak hesaplanmaktadır. Fourier dönüşümü olmayan bir sinyalin PSD'si sinyalin oto korelasyon (R(t)) fonksiyonunun Fourier dönüşümü alınarak hesaplanmaktadır. Aşağıda yer alan PSD "Eşitlik 1" ile hesaplanmaktadır.

$$S(f) = \int_{-\infty}^{\infty} R(t)e^{-2\pi ift} dt = F(R(t)) \quad (\text{Eşitlik 1})$$


Bir sinyalin PSD'sini analiz etmek, sinyal işleme için önemli bir temel adımdır. Dönüştürme için, bir sinyal çoklu bireysel sinüsoidal dalgalara ve ayrı frekanslara ayrılmaktadır. Güç Spektral Yoğunluğunun kestirimi için periyodogram yöntemi kullanılmaktadır. Bu yöntemin temeli Fourier dönüşümüne dayanmaktadır. Sinyal; 64, 128 ve 256 gibi çerçevelere segmentlenerek ayrılır ve her bir bölümün Fourier dönüşümünün ortalaması alınarak, güç spektrumu hesaplanmaktadır (139,140). Welch yöntemi, PSD'yi iyileştirilmiş periyodogramların ortalamasını alarak kestirmektedir.

Welch yöntemi uygulanırken ilk olarak N örnek uzunluğundaki veri dizisi birbiri ile örtüşen L adet bölüme ayrılmaktadır. Ayrılan bu her bir bölütün örnek uzunluğu M olan L adet veri bölümü için veri yapısı Welch denklemi "Eşitlik 2" ile hesaplanmaktadır.

$$X_i(n) = x(n + iD) \quad n = 0, 1, \dots, M - 1 \quad i = 0, 1, \dots, L - 1 \quad (\text{Eşitlik 2})$$


Bu fonksiyonda yer alan iD , i. veri dizisinin başlangıç noktasını göstermektedir. Fonksiyonda, $D = M$ olması halinde bölütlerde örtüşme olmamaktadır. Buradaki veri bölütlerinin L sayısı Bartlett PSD kestirimindeki K sayısı ile aynıdır. Örtüşmenin olması için $M > D$ olması gerekmektedir. Burada, $D = M/2$ olması durumunda ise ardışık veri bölütleri arasında %50 örtüşme olmaktadır ve bu durumda $L = 2K$ olarak bulunmaktadır (131, 132). Sonraki aşamalarda kullanılan pencere fonksiyonunun neden olduğu bilgi

kaybını önlemek amacıyla sinyal örtüşecek şekilde bölütleme yapılmaktadır. Genel olarak bölütler arasında örtüşmenin %50 ile %75 arasında olması tavsiye edilir (139, 140). İkinci aşamada ise sinyalin periyodogramını almak amacıyla örtüştürülmüş her bir veri bölütü, uygun bir $w(n)$ pencere fonksiyonu ile pencerelenir. Böylece her veri bölütünün iyileştirilmiş periyodogramının alınması sağlanmış olur. Son aşamada da L adet veri bölütüne ait iyileştirilmiş periyodogramların ortalaması alınır ve N örnek uzunluğundaki işaretin Welch PSD kestirimi bulunmuş olur. Mevcut tüm veri kanalları için PSD tahminleri, spektral yapaylıkları ve bazı durumlarda kötü kanalları kontrol etmek amacıyla uygun bir yol sağlamaktadır. Şekil 13’de Iova SK ve PH grubu verilerinin PSD grafikleri verilmiştir.




Şekil 13. Iova veri seti SK 63 kanal PSD grafikleri. **(a)** Iova veri seti SK PH 63 kanal PSD grafikleri. **(b)**

Şekil 14’de San Diego SK ve PH grubu verilerinin PSD grafikleri verilmiştir.



Şekil 14. San Diego veri seti SK 40 kanal PSD grafikleri. **(a)** San Diego veri seti PH 40 kanal PSD grafikleri. **(b)**

Şekil 15’de Turku SK ve PH grubu verilerinin PSD grafikleri verilmiştir.



Şekil 15. Turku veri seti SK 64 kanal PSD grafikleri. **(a)** Turku veri seti PH 64 kanal PSD grafikleri. **(b)**

Bu tez çalışmasında her elektrot için Welch yöntemi ile PSD'ler hesaplanmıştır. Daha sonra delta (0.5-4 Hz), teta (4-8 Hz), alfa (8-12 Hz), beta (12-30 Hz), gama (30-45 Hz) frekans bantları için sinyal gücü (POW) ve geniş bant (birinci senaryoda; 0,5-45 Hz ve ikinci senaryoda; 0,1-120 Hz) frekans bantları hesaplanmıştır. Bağlı güç (relPOW), her bir frekans bandının değeri, toplam geniş bant gücüne göre yüzde olarak ifade edilerek hesaplanmıştır. Son olarak da, her 20 ve 40 saniye için veri segmentlenerek, epokların ortalaması hesaplanmıştır. Ardından, tüm kanal çiftleri arasındaki medyan bağlantı elde edilerek, tüm elektrotlar için medyan güç hesaplanmış ve sonraki analizlerde kullanılmıştır.

Medyan Spektral Frekans

Medyan Spektral Frekans, sıkıştırılmış olan EEG'deki spektral dizinin güç dağılımının tam orta noktasını temsil etmektedir. Elektroensefalografide bulunan toplam gücün yarısının altında ve üstünde yer alan frekanstır. Ayrıca, toplam gücün yarısı ya da toplam gücün iki eşit parçaya bölünmesidir (139, 140). Aşağıda MSF ifadesi “Eşitlik 3” ile hesaplanmaktadır.

$$\sum_{j=1}^{MDF} P_j = \sum_{j=MDF}^M P_j = 1/2 \sum_{j=1}^M P_j \quad (\text{Eşitlik 3})$$

Kolmogorov Algoritmik Karmaşıklık

Kolmogorov Algoritmik Karmaşıklık, bir s dizisini hesaplayan veya çıktısını veren en kısa programın uzunluğu olarak tanımlanmaktadır. Basitlik ve karmaşıklık kavramlarını formüle eder. Bir s dizisinin, d(s) açıklaması minimum uzunluktaysa (yani en az bit kullanılarak), buna s'nin minimum açıklaması ve d(s) uzunluğu ise s'nin Kolmogorov karmaşıklığıdır ve K(s) ile gösterilir (141). En kısa açıklamanın uzunluğu “Eşitlik 4” ile hesaplanmaktadır.

$$K(x|y) := \min_p \{\ell(p) : U(y, p) = x\} \quad (\text{Eşitlik 4})$$

Burada $\ell(p)$, p'nin bit cinsinden ölçülen uzunluğudur. Bu tanımın U'nun seçiminden bağımsız olduğu, K(x)'in en fazla x'ten bağımsız bir toplamsal sabitle değişmesi anlamında gösterilebilir. Bu değişmezlik teoreminin ifadesi ve kanıtı genellikle algoritmik bilgi teorisinin doğuşu olarak kabul edilmektedir (142-145). Bu, Kolmogorov'un tezi olarak adlandırılabilir.

Spektral Entropi

Verilerin PSD'si Shannon entropisi olarak tanımlanan Spektral Entropi, Shannon entropisine dayalı bir sinyalin spektral güç dağılımının bir ölçüsünü ifade etmektedir (146). Sinyal spektrumunun düzlüğünü ya da karmaşıklığını göstermektedir (147). Aşağıda SE ifadesi “Eşitlik 5” ile hesaplanmaktadır.

$$H(x, f_s) = - \sum_{f=0}^{f_s/2} P(f) \log_2 [P(f)] \quad (\text{Eşitlik 5})$$

Burada P normalize edilmiş PSD ve f_s ise örnekleme frekansıdır.

Ağırlıklı Sembolik Karşılıklı Bilgi

Ağırlıklı Sembolik Karşılıklı Bilgi, iki sinyal arasında doğrusal olmayan bir bilgi paylaşımı endeksinin tahminidir (148). Tau zamanla ayrılabilen sinyalin k örnekleri dikkate alınmaktadır. Bu k örneklerin, büyüklükleri aralarında bulunan sıra ilişkisine bağlı olarak, bir dizi sembol tanımlamaktadır. Bu tanımlanan semboller, sinyallerin zamansal değişimini temsil etmektedir. Ölçü, marjinal olasılık dağılım fonksiyonlarına ve tüm sinyaller için elde edilen sembol dizileri için tahmin edilen ortak olasılık yoğunluk fonksiyonuna dayalı olarak, sinyal segmentlerindeki her elektrot çifti için hesaplanır.

Ağırlıklı Sembolik Karşılıklı Bilgi, her bir sembol çiftinin ortak olasılığını tahmin ederek, dönüştürülmüş her bir EEG sinyal çifti için tahmin edilmektedir. Ortak olasılık matrisi, sinyaller arasındaki sahte korelasyonları azaltmak için ikili ağırlıklarla çarpılmaktadır. Eşsiz bir ortak kaynak tarafından ortaya çıkarılabilen özdeş sembol çiftleri ve tek bir elektrik dipolünün iki tarafını yansıtabilen karşıt semboller için ağırlıklar sıfıra ayarlanmaktadır. Aşağıda wSMI ifadesi “Eşitlik 6” ile hesaplanmaktadır.

$$wSMI(X, Y) = \frac{1}{\log k!} \sum_{x \in X} \sum_{y \in Y} w(x, y) p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (\text{Eşitlik 6})$$

Yukarıdaki formülde, k , sembolik dönüşüm için kullanılan vektörün boyutu, x ve y sırasıyla X ve Y sinyallerinde bulunan tüm semboller, $w(x, y)$ ağırlık matrisi ve $p(x, y)$ X sinyalinde x simgesinin ve Y sinyalinde y simgesinin birlikte ortaya çıkma olasılığının ortak olasılığıdır. Son olarak, $p(x)$ ve $p(y)$, her sinyaldeki bu simgelerin olasılıklarıdır.


Ağırlıklı Sembolik Karşılıklı Bilgi, tüm EEG kanallarındaki X ve Y zaman serileri önce ayırık sembol dizilerine dönüştürülmüştür. Semboller, önceden tanımlanmış belirli

sayıda ardışık zaman noktasının genliklerindeki eğilimlere göre kodlanmaktadır. Analizlerde, k kerneli 3 olarak seçilmiş ve her bir elektrotun medyan değeri hesaplanmıştır. Bu çalışmada wSMI parametreleri, wSMI Delta, wSMI Teta, wSMI Alfa, wSMI Beta, wSMI Gama öznitelikleri hesaplanırken sırasıyla, $\tau = 64$, $\tau = 32$, $\tau = 16$, $\tau = 8$, $\tau=4$ ve $k = 3$ olarak seçilmiştir.

Bu ayrıştırılmış EEG sinyallerinin alt bantlarının PSD'leri üzerinden MSF, KAC, SE, wSMI'ye ait wSMI Delta, wSMI Teta, wSMI Alfa, wSMI Beta, wSMI Gama öznitelikleri hesaplanmıştır.

3.2.2. Ses Verisine Dönüştürülen Elektroensefalografi Veri Analizi

EEG verisinin, ses verisine dönüştürülmesi, ön işleme aşamaları, ses verisinden müzik özniteliklerinin çıkarılması, makine öğrenme yöntemleriyle sınıflandırma aşamaları Şekil 16'da yer almaktadır.



Şekil 16. Ses verisinin analiz şeması


3.2.2.1. Ön işleme

Öncelikle her üç veri grubuna ait ham EEG verileri Google Colab ortamına aktarılmıştır. Ham Iowa EEG verileri vhdr uzantılı, San Diego EEG verileri bdf uzantılı ve Turku EEG verileri set uzantılı olduğundan, hepsi önce csv uzantılı dosyalara dönüştürülmüştür. Ardından csv uzantılı dosyalar da, tsv uzantılı dosyalara dönüştürülmüş ve bu dosyalar sonrasında, waw uzantılı ses dosyalarına dönüştürülmüştür. Daha sonra, üç veri setinde de ortak olan 31 kanal seçimi yapılmış ve sonra verilere 0,5-45 Hz frekansında bant geçiş filtresi ve 60 ve 100 Hz’de çentik filtre, Turku veri setinde ise 50 ve 100 Hz’de çentik filtre uygulanmıştır. Son olarak 20 saniye bölümlerle epoklama yapılmıştır (149). Python librose kütüphanesi kullanılarak müzik öznitelikleri çıkarılmıştır.

Ses dosyasına dönüştürülme aşamalarında, beyin dalgaları doğrudan ses dalgalarına çevrilemeyeceğinden, öncelikle EEG elektrotlarının voltaj değerleri hesaplanmıştır. Voltaj değeri, belirli bir sesin başlangıçtaki yüksekliğini kontrol eden genlik değerleridir. Bu voltaj değerleri, farklı duygulara ve beyin süreçlerine bağlı olarak beyin aktivitesi ile ilişkilidir. Ses dalgası bir genlik ve bir frekans (ve bir faz) ile ifade edilir. Beyin dalga frekansları olan delta, teta, alfa, beta, gama, bantlarının frekansları oldukça düşük olduğundan doğrudan ses dalgasına çevirisi 100 Hz’in altındaki frekanslara yol açmaktadır. Bu nedenle, daha seçkin bir ses elde etmek için bu frekanslar katmanlanmıştır. Bir EEG dosyası yürütülürken genlik ve frekanslar rastgele seçilmiştir. Bu nedenle dosyanın her çalıştırılışında, yeni ve benzersiz bir ses oluşmaktadır. Dönüştürme işleminde ilk olarak beyin dalgalarının frekans aralıklarına göre ses katmanları belirlenmiştir. Her bir beyin dalgası için bir ses katmanı oluşturuldu. Bu katmanlar, belirli bir frekans aralığını temsil etmektedir. Delta beyin dalgası 0-4 Hz frekansı için birinci ses katmanı $f_1 = 3$, Teta beyin dalgası 4-8 Hz frekansı için ikinci ses katmanı $f_2 = 7$, Alfa beyin dalgası 8-12 Hz frekansı için üçüncü ses katmanı $f_3 = 12$, Beta beyin dalgası 12-30 Hz frekansı için dördüncü ses katmanı $f_4 = 29$, Gama beyin dalgası 30-45 Hz ve üstü frekans aralığında olması nedeniyle beşinci ses katmanı için $f_5 = 69$ olarak belirlenmiştir. Sonrasında her bir ses katmanı için rastgele genlik ve frekans değerleri belirlenmiştir. Burada ilk olarak, EEG sinyalinde her bir beyin dalgası için belirlenen frekans aralıklarında rastgele bir genlik ve frekans seçilmiştir. Bu seçim, beyin aktivitesi ile ilişkilendirilmektedir. Daha sonra genlik ve frekanslar numaralandırılmıştır. Burada seçilen genlik ve frekans değerleri numaralandırılarak bir sözlük oluşturulmaktadır. Yani, her bir genlik ve frekans değeri bir

numara ile ilişkilendirilmiştir. Bu sayede, belirlenen genlik ve frekanslar daha sonra ses sinyali oluşturmak için kullanılmaktadır. Burada, birinci ses katmanı için bu değer $f_1=3$ 'tür. Genlik değerleri de sıfır ile 211 arasında oluşturulan sözlükten rastgele seçilerek, genlik değerleri arasında çeşitlilik sağlanmaktadır. Daha sonra temel frekanslar oluşturulur. Her bir temel frekans için bir ve 10 arasında tam sayılar kullanılarak daha yüksek modlar oluşturulur. Örneğin, temel frekans üç ise, bir katı 3 Hz, iki katı 6 Hz, üç katı 9 Hz vb. olacak şekilde daha yüksek modlar oluşturulur. Bu modlar, temel frekansın harmonikleri olarak adlandırılır ve ses sinyalinin daha zengin ve kompleks bir yapısını oluştururlar. Sonrasında ses sinyali oluşur. Bu aşamada her bir ses katmanı için, numaralandırılmış genlikler ve frekanslar kullanılarak rastgele bir ses sinyali oluşmaktadır. Bu işlem, belirlenen sayıda katman boyunca tekrarlanır ve her katman için ayrı ayrı rastgele genlik ve frekans değerleri belirlenir. Bu katmanların sayısı, belirlenen beş beyin dalgası frekansı kadardır. Bulunan değerler bir listeye kaydedilir. Sonrasında her katmandaki ses sinyalleri toplanarak tek bir ses sinyali elde edilir. Tüm katmanlar için belirlenen rastgele genlik ve frekans değerleri, her bir katmanın genlik ve frekans değerlerinin toplamını oluşturmak için birleştirilir. Daha sonra elde edilen ses sinyali, 44 100 Hz örnekleme oranına ve 10 saniyelik periyotlara dönüştürülmüştür. Periyot başına düşen sayı hesaplandıktan sonra elde edilen ses sinyali wav dosyası olarak kaydedilir. Bu ses sinyali, beyin aktivitesi ile ilişkilendirilen farklı ve benzersiz sesleri temsil etmektedir. Bu süreç, her çalıştırıldığında farklı genlik ve frekans değerleri seçilerek benzersiz sesler oluşmaktadır (149).


Şekil 17'de SK ve PH grubundan birer kişiye ait EEG verilerinin, wav uzantılı ses temsilleri sunulmuştur. Burada x eksenini saniye olarak zamanı ve y eksenini genlik değerini göstermektedir.



Şekil 17. SK grubu bir kişiye ait wav uzantılı ses temsili. **(a)** PH grubu bir kişiye ait wav uzantılı ses temsili. **(b)**


Ses dosyasının Müzikal Enstrüman Dijital Arayüzü temsilleri

Müzikal Enstrüman Dijital Arayüzü (MIDI), bilgisayarlar, sentezleyiciler ve diğer elektronik müzik enstrümanları gibi dijital cihazlar arasında müzik bilgisinin iletimini sağlayan bir standart protokoldür. Bu arayüz, müzik üretiminde, performansında ve eğitiminde yaygın olarak kullanılmaktadır. Bu MIDI verisi, bir notanın perdesini, süresini ve dinamiklerini gibi bir performansın çeşitli yönlerini kontrol eden mesajları içermektedir (150). Sesin müzik temsillerine ait görseller şekil 18’de yer almaktadır.



Şekil 18. Nota müzik temsili. **(a)** Ses temsili. **(b)** Bir bilgisayar tarafından ayrıştırılabilecek açık müzikal anlamı olan varlıklara dayalı tanımlama. **(c)** (Müller'den, 150)

Notaların müzik temsilinin piyano klavyesinde perde karşılığı Şekil 19'da yer almaktadır.



Şekil 19. Piyano klavyesi ve notaların müzik temsili. **(a)** Nota temsili **(b)** (Müller'den, 150)

Ses verisine ait öznitelik çıkarımı

Ayrık Dalgacık Paket Dönüşümü

Ayrık Dalgacık Paket Dönüşümü, öznitelik çıkarma tekniği olarak kullanılmaktadır. Bir sinyali, sinyalin frekans ve zaman özniteliklerini temsil eden bir dizi dalgacık katsayısına ayıran ayrık dalgacık dönüşümünün (DWT) bir genellemesidir. Bu dönüşüm ise her seviyede hem yaklaşım hem de detay katsayılarının ayrıştırılmasına izin vererek DWT'yi genişletmektedir. Böylece sinyal daha esnek ve verimli bir şekilde temsil edilir. Bu nedenle DWPT daha çok tercih edilmektedir (151). Bu doktora tezinde Daubechies dört dalgacığı kullanılmıştır.

Kroma tabanlı öznitelikler

Müzikal perde algısının döngüsel sarmal temsilde kroma kavramı kullanılmaktadır. Kroma özniteliği, bir müzik perdesinin rengini ifade eden, kroma adı verilen oktavdan bağımsız bir değer ve perdenin hangi oktavda olduğunu gösteren bir perde yüksekliği olarak ayrıştırılabilen bir perde sınıfı niteliğidir (152). Kroma vektörü ise sinyalde her bir perde sınıfının $\{C, C\#, D, D\#, E, \dots, B\}$ ne kadar enerji içerdiğini gösteren tipik olarak 12 elemanlı bir öznitelik vektörüdür. İnsanların perde algısı, iki perdenin bir veya birkaç oktav (bizim ölçeğimizde bir oktav 12 perdenin mesafesi olarak tanımlanır) farklı olması durumunda renk açısından benzer olarak algılanması (benzer armonik rol oynaması) anlamında periyodiktir. Örneğin, $p = 60$ ve $p = 72$ perdeleri bir oktav aralıklıdır. Yine, $p = 57$ ve $p = 71$ perdeleri iki oktav aralıklıdır. Bir perde, ton yüksekliği ve kroma olarak adlandırılan iki bileşene ayrılabilir. Ton yüksekliği oktav sayısını, kroma ise ilgili perde yazım özniteliğini ifade etmektedir (153).

Bir oktav kadar farklı olan perdeleri tanımlayan kroma özellikleri, tını içindeki değişimlere karşı yüksek derecede sağlamlık gösterir ve armoninin müzikal yönüyle yakından ilişkilidir. Kroma özniteliklerinin müzik verilerini işlemek ve analiz etmek için iyi bilinen bir araç olmasının nedeni budur. Örneğin, temelde her akor tanıma prosedürü bir çeşit kroma sunumuna dayanmaktadır. Ayrıca, kroma öznitelikleri müzik hizalama ve senkronizasyonun yanı sıra ses yapısı analizi gibi görevler için de fiili standart haline gelmiştir (154).

Harmonik perde sınıfı profilleri, bir akor tanıma sistemi olan perde sınıfı profiline dayalı olarak bir bilgisayar programının ses sinyalinden çıkardığı bir grup özniteliktir (155).

Müzikte, kroma özniteliği veya kromagram terimi on iki farklı perde sınıfıyla yakından ilgilidir. Perde sınıfı profilleri olarak da adlandırılan kroma tabanlı öznitelikler, perdeleri anlamlı bir şekilde kategorize edilebilen ve akordu eşit ölçeğe yakın olan müziği analiz etmek için kullanılan güçlü bir araçtır. Kroma öznitelikleri, kısa süreli bir ses penceresinin armonik içeriğini (örneğin: anahtarlar, akorlar) temsil etmeyi amaçlamaktadır. Öznitelik vektörü, Kroma Normalize Enerji İstatistikleri (CENS), STFT, Sabit Q Dönüşümü (CQT), Değişken Q Dönüşümü (VQT) kullanılarak büyüklük spektrumundan çıkarılmaktadır (149).

Kroma Normalize Enerji İstatistikleri

Kroma bantlarındaki enerji dağılımları üzerinde kısa süreli istatistikleri göz önünde bulundurarak daha ileri bir soyutlama derecesi ekleyerek, ölçeklenebilir ve sağlam bir ses öznitelikleri ailesi oluşturan CENS öznitelikleri elde edilmektedir. Bu özniteliklerin hesaplanmasında, logaritmik olarak seçilen eşiklere dayalı bir niceleme uygulanmaktadır (156).

Kısa Zamanlı Fourier Dönüşümü

Kısa zamanlı Fourier dönüşümü, zamana bağlı değişen bir sinüzoidal sinyalin yerel bölümlerinin frekansını ve fazını bulmakta kullanılan bir tür Fourier dönüşümüdür.

$$X_{STFT}[m, n] = \sum_{k=0}^{L-1} x[k]g[k-m]e^{-j2\pi nk/L}$$

$$x[k] = \sum_m \sum_n X_{STFT}[m, n] g[k-m]e^{j2\pi nk/L} \quad (\text{Eşitlik 7})$$

Burada $x[k]$ bir sinyali belirtir ve $g[k]$ bir L noktası pencere fonksiyonunu belirtmektedir. Eşitlik 7'den , $x[k]$ 'nin STFT'si, $x[k]g[k-m]$ ürününün Fourier dönüşümü olarak yorumlanabilir (139, 140).

Sabit Q Dönüşümü

Sabit Q Dönüşümü, bir veri serisini frekans alanına dönüştürmektedir. Fourier dönüşümü gibi sabit Q dönüşümü de bir filtre bankasıdır. Ancak, ilkinin aksine geometrik aralıklı merkez frekanslara sahiptir. CQT bir dalgacık dönüşümü olarak görülebilmektedir (157).

Değişken Q Dönüşümü

Değişken Q Dönüşümü, sinyal analizi ve sıkıştırma için matematiksel bir teknik olan CQT'nin bir varyasyonudur. Bu dönüşüm, frekans çözünürlüğü ile zaman çözünürlüğü arasındaki dengeyi belirleyen Q kalite faktörünün ayarlanmasına olanak tanımaktadır. Bu dönüşüm, müzik veya konuşma gibi değişen spektral özelliklere sahip sinyalleri analiz etmek için yararlı olabilmektedir. Bu dönüşüm uygulamalarından bazıları, ses segmentasyonu, perde tespiti, başlangıç tespiti, akor tanıma ve müzik transkripsiyonudur (158).

Ses verisinden 266 öznelik çıkarılmıştır. Ses verisinden çıkarılan özneliklerin tamamını; Spektral Merkez, Spektral Bant Genişliği, Spektral Rolloff, Spektral Düzlük, Spektral Kontrast, Kök Ortalama Kare, Sıfır Geçiş Oranı, Zamansal Merkez, Perde, Tempo, Tempo Zamanları, Ritim Senkronizasyonu, Kromagram Maksimum, Kromagram Minimum, Kromagram Aralığı, Kromagram Ortalaması, Kromagram Varyansı, Kromagram Basıklığı, Kromagram Çarpıklığı, Kaplanmış Kromagram Maksimum, Kaplanmış Kromagram Minimum, Kaplanmış Kromagram Aralığı, Kaplanmış Kromagram Ortalaması, Kaplanmış Kromagram Varyansı, Kaplanmış Kromagram Basıklığı, Kaplanmış Kromagram Çarpıklığı ve Mel Frekans Kepstrum Katsayıları ikinci ve üçüncü dereceden ayrı ayrı olarak birden başlayarak 20'ye kadar, Ton Ağı birden başlayarak altıya kadar, Kroma CQT ve Delta Kroma CQT birden başlayarak 12'ye kadar, Kroma STFT ve Delta Kroma STFT birden başlayarak 12'ye kadar, Kroma CENS ve Delta Kroma CENS birden başlayarak 12'ye kadar, Kroma VQT ve Delta Kroma VQT birden başlayarak 12'ye kadar içerecek şekilde oluşturmaktadır. Kroma tabanlı özneliklerde ve Mel Spektral Katsayılarında da ikinci ve üçüncü dereceden delta hesaplanarak kroma tabanlı delta öznelikleri ayrı ayrı öznelik olarak hesaplanmıştır.

Bu özneliklerin 208 tanesi kroma tabanlı özneliklerdir. Bu özneliklerden, RO algoritması kullanılarak öznelik seçimi yapılmıştır. Kroma tabanlı öznelikler üç veri setinde de yüksek sonuç vermesi nedeniyle, sınıflandırmada kroma tabanlı öznelikler kullanılmıştır. Sınıflandırmada kullanılan öznelikler, Delta Kroma STFT Standart Sapması 7 (ikinci dereceden), Kroma CENS 8 (ikinci dereceden), Kroma CENS 2 (üçüncü dereceden), Kroma CQT 2 (ikinci dereceden), Delta Kroma VQT Standart Sapması 5 (ikinci dereceden), Delta Kroma CQT Standart Sapması 2 (üçüncü dereceden), Delta Kroma STFT Standart Sapması 3 (üçüncü dereceden), Delta Kroma CENS Standart

Sapması 8 (üçüncü dereceden), Delta Kroma CENS Standart Sapması 5 (üçüncü dereceden), Delta Kroma VQT Standart Sapması 11 (üçüncü dereceden), Delta Kroma CENS Standart Sapması 8 (ikinci dereceden), Delta Kroma VQT Standart Sapması 1 (üçüncü dereceden) öznitelikleri kullanılmıştır.

3.3. Makine Öğrenmesi Algoritmaları

Makine öğrenmesi algoritmaları, 1950'lerde ortaya çıkmıştır. İnsanların karmaşık veri kümelerini keşfetmesi, analiz etmesi ve bunları gerçek hayatla bağdaştırmasına yardımcı olan kod parçacıklarıdır. Hesaplamalı istatistik ile yakından ilişkili ve karar verme yetisi üzerine uzmanlaşmıştır. Genel olarak hesaplama süreçlerinde kural tabanlı algoritmalar kullanılmaktadır. Çok fazla sayıdaki giriş değerleri için her birinin sahip olduğu özellik fonksiyonlarını gözleyerek ait oldukları sınıfları tahmin etmektedirler. Makine öğrenme yöntemleri hastalık teşhisi, medikal uygulamalar, beyin bilgisayar arayüzleri gibi uygulamalarda sinyal örüntülerinin tanınması amacıyla kullanılmaktadır (159, 160).

Makine öğrenme yöntemleri verinin yapısına bağlı olarak denetimsiz, denetimli ve takviyeli öğrenme olarak üçe ayrılır (160, 161). Bunlardan ilki, hedef girdilere karşı hiçbir çıktı verisinin olmadığı, veri içerisindeki grupların belirlenmeye çalışıldığı denetimsiz öğrenmedir. İkincisi ise, örnek girişlere karşı istenen çıkışların verildiği denetimli ya da danışmanlı öğrenmedir. Bu konuda pek çok yaklaşım ve algoritma geliştirilmiştir. Denetimli öğrenmede, girdilerden bilgi çıkarımı elde edebilmek için bu girdilerin etiketlenmesi gerekmektedir. Denetimli öğrenmede en çok kullanılan tekniklerden biri sınıflandırmadır. Sınıflandırmada, her bir girdiye verilen etiket bu girdinin ait olduğu sınıfı temsil etmektedir (159, 160). Veri setinden bilgi çıkarımı yapabilmek amacıyla farklı sınıflandırıcılar kullanılmaktadır. Sınıflandırıcıların performansı bir veri setinden diğerine değişebilmektedir. Bu sebeple, bir veri setinde en iyi performansı elde edecek sınıflandırıcıyı tespit etmek amacıyla birden fazla sınıflandırıcının performansını test etmek gerekebilmektedir. Bu çalışmanın analizi için yararlanılan tüm makine öğrenme algoritmaları denetimli öğrenme algoritmalarından oluşmaktadır.

Ayrıca, çalışma içerisinde faydalanan tüm makine öğrenme algoritmalarında, alışlagelmiş eğitim yöntemlerine göre (örneğin: %75 eğitim verisi, %25 test verisi) çok daha iyi ve daha güvenilir sonuçlar sağladığı için ve genel doğruluğu değerlendirmek için k katmanlı çapraz doğrulama tekniği kullanılmıştır.

Bu teknik ile toplam veri seti, yaklaşık olarak eşit olacak şekilde k sayıda parçaya ayrılmaktadır. Makine öğrenme yapıları k kez eğitilir ve test edilir. Her seferinde test edilecek veri bölümü k parçalarının içerisinde alınır ve geri kalan tüm veriler makine öğrenme yapısının eğitimi için kullanılmaktadır. Bu doğrultuda k sayıda farklı test ve eğitim sonuçları oluşmaktadır. Bu sonuçların ortalaması, makine öğrenme yapıları için test sonuçlarını vermektedir (159, 160). Bu tez çalışmasında dokuz farklı makine öğrenmesi yöntemi kullanılmıştır. Kullanılan makine öğrenmesi yaklaşımlarından sırasıyla bahsedilmiştir.

3.3.1. Kategorik Arttırma Algoritması

Kategorik Arttırma Algoritması, Yandex tarafından önerilen ve heterojen verilerle iyi başa çıkma yeteneğine sahip olduğu gösterilen GB ve KA algoritmalarından türetilmiş yeni bir topluluk öğrenme yöntemidir (161). Ayrıca CatBoost, temel tahminçiler olarak dengeli olan unutkan ağaçlar kullanmaktadır. Böylece aşırı öğrenme sorunlarının üstesinden gelmektedir. Genel olarak diğer topluluk öğrenme algoritmalarına göre üstün sınıflandırma performansı sergilemektedir.

3.3.2. Aşırı Gradyan Arttırma Algoritması

Aşırı Gradyan Arttırma Algoritması, GB algoritmasının çeşitli düzenlemeler ile optimum hale getirilerek, yüksek performanslı olarak elde edilen bir şeklidir. Tianqi Chen ve Carlos Guestrin'in 2016 yılında yayınladıkları, "XGBoost: A Scalable Tree Boosting System" adlı makale ile sınıflandırma sistemine girmiştir (162). Yüksek tahmin gücüne sahip, aşırı öğrenmenin önüne geçebilen, boş verileri yönetebilen ve bütün bunları hızlı yapabilen bir algoritmadır. Karar ağacına dayalı algoritmalar arasında en iyi performans gösteren algoritma olduğu ifade edilmektedir. Gradient Boosting algoritmasına çalışma şekli olarak oldukça benzer olan XGBoost'ta ilk adım ilk tahmini yapmaktır. Yapılan tahmin, sonraki adımlarda yapılacak işlemler ile yakınsayarak, doğru sonuca ulaşılacağı için herhangi bir sayı olabilmektedir. Hataları tahminleyen ağaçların kurulması, ağaçlar için benzerlik ve kazanç skorlarının hesaplanması, budama ve model çıktılarının elde edilmesi ile ilk ağaç tamamlanmaktadır (163).

3.3.3. K En Yakın Komşu Algoritması

Makine öğrenme yöntemlerinden bir diğeri K En Yakın Komşu Algoritması, sınıflandırma ve regresyon için kullanılan bir denetimli öğrenme algoritmasıdır. Bu

algoritma ile yeni noktaya en yakın noktalar aranmakta olup, k bilinmeyen noktanın en yakın komşularının miktarını göstermektedir. Sınıflandırıcının sonuçları tahmin etmek amacıyla genellikle bir tek sayı olarak algoritmanın k miktarı seçilmektedir. Hem sınıflandırma ve hem de regresyon için girdi, özellik alanında k en yakın eğitim örneklerinden oluşmaktadır. Bu yöntemde, çıktı sınıf üyeliğidir. Bir nesne, komşularının çoğunluk oyu ile sınıflandırılmaktadır. Bir nesne, en yakın komşuları arasında en yaygın olan sınıfa verilmektedir. Eğer $k = 3$ ise, nesne basit olarak ona en yakın komşusunun sınıfına atanmaktadır (164). Bu yöntemde, k değerinin seçimi ve komşular arasındaki uzaklığı hesaplanması sonuç açısından çok önemlidir.

Yöntem, Öklit mesafesi “Eşitlik 8” de verilen bir ifade ile hesaplanmaktadır.

$$L_2(X, Y) = \sqrt{\sum_{i=1}^n (|x_i - y_i|)^2} \quad (\text{Eşitlik 8})$$

3.3.4. Gradyan Arttırma Algoritması


Boosting, zayıf öğrencileri güçlü öğrenciye dönüştüren bir yöntemdir. Bunu iterasyonlar ile aşamalı yapmaktadır. Diğer Boosting algoritmaları ile arasındaki fark genellikle zayıf öğrencilerin eksikliğini tamamlama şeklidir. Gradyan Arttırma (Gradient Boosting) Algoritmasında öncelikle ilk yaprak oluşturulmaktadır. Ardından tahmin hataları dikkate alınarak yeni ağaçlar oluşturulmaktadır. Bu durum, karar verilen ağaç sayısına veya modelde daha fazla gelişme olmayıncaya dek devam etmektedir (165).

3.3.5. Destek Vektör Makineleri

Destek Vektör Makineleri, ilk olarak 1992 yılında Vapnik tarafından önerilmiş bir denetimli öğrenme yöntemidir (166). Bu yöntem, bilim adamlarınca zaman içerisinde geliştirilmiştir. Sınıflandırma ve doğrusal olmayan fonksiyon yaklaşımı problemlerinde oldukça başarılı ve yaygın olarak kullanılmaktadır. Günümüzde DVM’ler ses, yüz, nesne, yazı vb. örüntü tanıma, fonksiyon tahmini, mühendislik, genetik, bilgi güvenliği, zaman serilerinin tahmini, biyoenformatik vb. birçok alanda başarı ile uygulanan bir yöntemdir. Bu makine öğrenme yöntemi, başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması için ortaya atılmıştır. Ancak zamanla, matematiksel alt yapısı geliştirilerek doğrusal olmayan ve çok sınıflı verilerin sınıflandırılması için genelleştirilmiştir. Bu yöntem temelde üç ana bileşenden oluşur. Bu ana bileşenleri istatistiksel öğrenme teorisi, optimizasyon algoritması ve çekirdek fonksiyonlarıdır (166, 167).


Destek Vektör Makineleri, ikili sınıflandırma problemlerinde oldukça önemli başarılar elde eden bir yöntemdir. Aşağıda yer alan şekilde gösterildiği gibi iki farklı veri sınıfını ayırmak için birden fazla doğrunun çizilme ihtimali bulunmaktadır. En uygun ayırıcı doğru belirlenirken, veri sınıflarına eşit ve maksimum mesafede olanı tespit edilmektedir. Marjin olarak isimlendirilen bu maksimum mesafe oluşturulurken, veri sınıflarına ait örnekler içerisinde ayırıcı doğruya en yakın örnekler kullanılmaktadır. Bu örnekler destek vektörleri olarak adlandırılmaktadır. Çok boyutlu uzayda doğruların yerini hiperdüzlemler almaktadır (166, 167). Bu yöntemde iki veri sınıfını ayıran hiperdüzlemler, sınıflandırılacak verinin durumuna göre iki ayrı bölümde incelenebilmektedir. Bunlar; doğrusal DVM ve doğrusal olmayan DVM olarak adlandırılmaktadır.

Doğrusal DVM’de iki sınıf arasındaki veriler tek bir hiper düzlem ile ayrılmaktadır. Şekil 20’de doğrusal ayrılma durumu sunulmuştur.



Şekil 20. Doğrusal ayrılma durumu (Kotsiantis’den, 168)

Gerçek dünyada problemlerinde verilerin çoğu doğrusal bir hiperdüzlemle ayrılamamaktadır. Bu durumda DVM girdi uzayını daha üst boyutlu uzaya taşımaktadır. Burada sınıflar, birbirinden doğrusal bir karar sınırı ile doğrusal olarak ayrılabilir. Şekil 21’de doğrusal ayrılama durumu sunulmuştur.



Şekil 21. Doğrusal ayrılamama durumu (Fletcher’den, 169)

3.3.6. Lojistik Regresyon


Lojistik Regresyon, ikili lojistik model veya logit model, bir problem için oranların logaritmasını alarak problemin iki alternatif arasından gerçekleşme olasılığını modelleyen istatistiksel bir yaklaşımdır. Bir ya da daha fazla bağımsız değişkenin doğrusal bir kombinasyonunu oluşturmaktadır (170, 171). Bu yöntemde, bağımsız değişkenler ile iki ya da çok sınıflı kategorik bağımlı değişken arasındaki ilişkinin tanımlanması amacıyla matematiksel modelleme yapılmaktadır (170, 171). Bağımsız değişkenlerin tamamı sürekli olduğunda lojistik model “Eşitlik 9” da verilen bir ifade ile hesaplanmaktadır.

$$\ln \frac{\Pr(x_1, \dots, x_p)}{1 - \Pr(x_1, \dots, x_p)} = \beta_0 + \sum_{j=1}^k \beta_j x_{ij} \quad (\text{Eşitlik 9})$$

3.3.7. Karar Ağacı Algoritması

Karar Ağacı algoritması, giriş verilerinin ait oldukları sınıfların tanımlanabilmesi için oluşturulmuş bir karar mekanizması olarak tanımlanan denetimli öğrenme algoritmalarıdır. Ağacın her düğümü, ya bir sınıf ismini belirtir ya da düğümdeki test verilerine ait mümkün olan çıkışlara göre örnek uzayını bölerek özel bir test bölümü meydana getirmektedir. Bölünerek oluşturulan her bir alt küme yeni bir alt ağaç tarafından çözülecek olan yeni bir alt sınıflandırma problemine karşılık gelmektedir. Başka bir deyişle, KA yönetim organizasyonunda yaprak olarak adlandırılan düğümler (sonuç düğümü) sınıf ismini barındırmaktadır. Yaprak düğümü olmayan noktalar (karar düğümü), yeni bir özellik barındırmaktadır. Bu özelliklerin mümkün olan her bir değeri için tıpkı ağacın dalları gibi dallara ayrılarak başka bir karar ağacı oluşturulmaktadır. Karar ağacı

algoritması sınıflandırma problemlerinde böl ve yönet tekniğine dayanmaktadır (172). Karar ağaçlarının çalışma işleyişi, hastalık tanısı üzerine kurgulanmış basit bir örnek ile aşağıdaki gibi ifade edilmektedir (173). Şekil 22’de KA’nın çalışma işleyişi sunulmuştur



Şekil 22. Çalışma işleyişi (Taşkın’dan, 173)

Bu örnek incelendiğinde;

EĞER Bademcik Şişmesi = Var ise SONRA Tanı = Boğaz Enfeksiyonu

EĞER Bademcik Şişmesi = Yok ve Ateş = Var ise SONRA Tanı = Soğuk Algınlığı

EĞER Bademcik Şişmesi = Yok ve Ateş = Yok ise SONRA Tanı = Sağlıklı

Bademcik şişmesinin olduğu ilk durumda KA’nın yaprağı oluşturulmaktadır. Oluşturulan sonuç tanı olarak ortaya konmaktadır. Bademcik şişmesinin olmadığı durumlarda ise yeni bir alt ağaç oluşturularak, KA’nın dallanması gerçekleştirilmiş olur. Karar ağacı algoritmalarının temeli otomatik etkileşim algılayıcı yöntemi olarak adlandırılan ilk modelleme ile başlamıştır. Daha sonra çeşitli yöntemler geliştirilmiş olup, Quinlan tarafından geliştirilen ID3 (Iterative Dichotomiser 3) ve C4.5 yöntemleri literatürde çokça kullanılan ve hala popüler olan KA yöntemleridir (174). Bu yapılar evet ve hayır mantığında çalışmaktadır. Ağacın yayılması, entropi hesabına dayandırarak sağlanmaktadır. Her bir adımda, bilgi için en düşük entropiye sahip sonuçlar seçilmektedir.

3.3.8. Naive Bayes Algoritması

Naive Bayes, ismini İngiliz matematikçi Thomas Bayes’ten almaktadır. Bu denetimli bir öğrenme yöntemi olup, Bayes teoreminin bağımsızlık önermesiyle basitleştirilmiş durumudur. Bayes teoremi “Eşitlik 10” da verilen bir ifade ile hesaplanmaktadır.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (\text{Eşitlik 10})$$

$P(A|B)$; B olayı gerçekleştiğinde A olayının olma olasılığı

$P(B|A)$; A olayı gerçekleştiğinde B olayının olma olasılığı

$P(A)$ ve $P(B)$; A ve B olaylarının önsel olasılıklarını göstermektedir.

Burada yer alan önsel olasılık Bayes teoreminine öznellik katmaktadır (164).

3.3.9. Rastgele Orman Algoritması

Rastgele Orman algoritması, denetimli sınıflandırma algoritmasından biridir. Karar ağacı tabanlıdır. Regresyon ve sınıflandırma için kullanılmaktadır. Bu yöntem, birden çok KA üretmektedir. Sınıflandırma yapılması esnasında sınıflandırma performansını yükseltmeyi amaçlamaktadır. Bu yöntemde, birbirinden bağımsız şekilde çalışan bir sürü KA bir araya gelerek, yaptıkları puanlama sonucu en yüksek puanlı ağaç seçilmektedir. Ağaç sayısının artmasına bağlı olarak kesin olarak bir sonuca ulaşma yüzdesi yükselmektedir. Karar ağaçlarından ayrılan tarafı, RO'da kök düğümünü bulma ve kök düğümlerini bölünmesi rastgele yapılmaktadır (175).

Kullanılan makine öğrenme yöntemlerinin yaygın kullanılan parametreleri Tablo 5'de yer almaktadır.

Tablo 5. Makine öğrenme yöntemlerinde kullanılan parametreler ve yaygın seçilen değerleri.

Makine Öğrenme Yöntemleri	Parametreler	Değerleri
CatBoost	Derinlik	4, 6, 8
	Öğrenme oranı	0.01, 0.05, 0.1
	Tekrar sayısı	100, 200, 300, 800
XGBoost	Maksimum derinlik	4, 6, 8
	Öğrenme oranı	0.01, 0.05, 0.1
	Estimatör sayısı	100, 200, 300
GB	Maksimum derinlik	4, 6, 8
	Öğrenme oranı	0.01, 0.05, 0.1
	Estimatör sayısı	100, 200, 300
KNN	Komşu sayısı	3, 5, 7
	Ağırlıklar	uniform, distance
	P	1,2
DVM	C:	0.1, 1, 10
	Kernel	linear, rbf
LR	C	0.1, 1, 10
	Çözümleyici	liblinear, saga
KA	Maksimum derinlik	4, 6, 8
	Minimum örnekleme bölünmesi	2, 4, 6
RO	Estimatör sayısı	100, 200, 300
	Maksimum derinlik	4, 6, 8
	En küçük örnek bölme	2, 4, 6
	Bölme kriteri	gini, entropi

3.3.10. Derin Öğrenme Yöntemleri

Veriler, birbirini takip eden katmanlarda işlenirken gittikçe artan bir şekilde daha kullanışlı sonuçlar elde edilen makine öğrenme yöntemlerinin bir alt alanını oluşturmaktadır. Modeldeki oluşturulan katman sayısı ne kadar çok ise model o kadar derindir. Modern derin öğrenme modelleri, onlarca ya da yüzlerce birbirini takip eden

katmandan meydana gelmektedir. Diğer makine öğrenme algoritmaları genelde bir veya iki katmandan oluşmaktadır. Bu katmanlı gösterim, sinir ağı olarak isimlendirilen ve birbirini takip eden katmanları olan model sayesinde öğrenmektedir. Kullanılan yöntemler denetimli, yarı denetimli ya da denetimsiz olabilmektedir (176-178).

Derin sinir ağları, derin inanç ağları, derin takviyeli öğrenme, tekrarlayan sinir ağları, evrişimli sinir ağları ve dönüştürücüler gibi derin öğrenme mimarileri, bilgisayarlı görü, konuşma tanıma, doğal dil işleme, biyoinformatik, ilaç tasarımı, tıbbi görüntü analizi, iklim bilimi, malzeme denetimi ve masa oyunu programları gibi alanlara uygulanmış ve burada insan uzman performansıyla karşılaştırılabilir ve bazı durumlarda onu aşan sonuçlara ulaşılmıştır (178, 179).

3.3.10.1. Tekrarlayan Sinir Ağı

Tekrarlayan sinir ağı, katmanlar arasındaki bilgi akışının yönü ile karakterize olan iki geniş yapay sinir ağı türünden biridir. Tek yönlü ileri beslemeli sinir ağının aksine, çift yönlü bir yapay sinir ağıdır. Bu da bazı düğümlerden gelen çıktının aynı düğümlere sonraki girdiyi etkilemesine izin vermektedir. Rastgele girdi dizilerini işlemek için dahili hafıza kullanma yetenekleri bulunmaktadır (179).

3.3.10.2. Uzun Kısa Süreli Bellek

Uzun kısa süreli bellek ağı, geleneksel RNN'lerde mevcut olan kaybolan gradyan problemiyle başa çıkmayı amaçlayan tekrarlayan bir sinir ağıdır. Boşluk uzunluğuna karşı göreceli duyarsızlığı diğer RNN'lere, gizli markov modellerine ve diğer dizi öğrenme yöntemlerine göre avantajıdır. Bu yöntem için binlerce zaman adımı sürebilen kısa süreli bir bellek, dolayısıyla uzun kısa süreli bellek sağlamayı amaçlamaktadır (177).

3.3.10.3. Çok Katmanlı Algılayıcı

Çok katmanlı algılayıcı, ileri beslemeli yapay sinir ağının bir türüdür. Bir MLP en az üç düğüm katmanından oluşmaktadır. Bu modelde bir giriş katmanı, bir gizli katman ve bir çıkış katmanı bulunmaktadır. Giriş düğümleri dışındaki her düğüm, doğrusal olmayan bir aktivasyon fonksiyonu kullanan bir nöronudur. Bu yöntem, eğitim için geri yayılım adı verilen denetimli bir öğrenme tekniğini kullanmaktadır. Çoklu katmanları ve doğrusal olmayan aktivasyonu, MLP'yi doğrusal bir algılayıcıdan ayırmaktadır. Doğrusal olarak ayıramayan verileri ayırt edebilmektedir (180).

3.4. Sınıflandırma Modellerinin Performans Değerlendirmesi

3.4.1. Karışıklık Matrisi

Karışıklık Matrisi, makine öğrenimi sınıflandırma probleminde bir performans ölçümüdür. Tahmin edilen ve gerçek değerlerin dört farklı kombinasyonundan oluşan bir tablodur. Bu Matris, sistemler tarafından yapılan tahminlere ve belirli bir veri örneğinin gerçek sınıfına dayalı iki veya daha fazla sınıfı karşılaştırarak sınıflandırma kurallarını temsil etmek için en sezgisel yolu sağlamaktadır. Bununla birlikte, tek başına bir performans ölçütü değildir. Ancak, dört önemli sonuca dayanmaktadır. Bunlar, Gerçek Pozitifler (GP), Yanlış Pozitifler (YP), Gerçek Negatifler (GN) ve Yanlış Negatifler (YN)'dir (181, 182). Karışıklık matrisi Tablo 6'da sunulmuştur.

Gerçek Pozitifler, doğru etiketlenen örnek sayısını temsil etmektedir. Tahmin gerçek sınıfla eşleşmektedir. Doğru pozitif tahminlerdir (181, 182). Gerçek Negatifler, gerçek sınıfla eşleşen ama negatif olarak kabul edilen doğru tahminlere sahip veri örnekleridir (181, 182). Yanlış Pozitifler, tahmin ile gerçek sınıfı arasında bir eşleşme olmayan örneklerdir. Sistemin yanlış tahmininden ettiği veri örnekleridir (181, 182). Yanlış Negatifler, yanlışlıkla başka bir sınıf olarak etiketlenen, sistemin negatif olarak tahmin ettiği ama aslında pozitif olan veri örnekleridir (181, 182).

Tablo 6. Karışıklık matrisi

Tahmin		
Gerçek	GN	YP
	YN	GP

Yukarıdaki terimler ile hesaplayabileceğimiz bazı metrikler bulunmaktadır.

3.4.2. Doğruluk

Doğru olarak sınıflandırılan örneklerin yüzdesini ifade etmektedir. Sınıflandırma problemlerinin doğruluğu, toplam örnekler ve yapılan tahminler üzerinden model

tarafından doğru tahmin edilen veri örneklerinin sayısını veya yüzdesini temsil etmektedir (181, 182). Doğruluk, “Eşitlik 11” ile verilen bir formül kullanılarak hesaplanmaktadır.

$$\text{Doğruluk} = \frac{GP+GN}{GP+YP+GN+YN} \quad (\text{Eşitlik 11})$$

3.4.3. Duyarlılık

Duyarlılık ya da hassasiyet, pozitif olarak tahmin etmemiz gereken işlemlerin ne kadarını pozitif olarak tahmin ettiğimizi, yani gerçekten pozitif olarak tahmin edilen pozitif vakaların sayısını göstermektedir. Gerçek pozitiflerin ne kadarının doğru bir şekilde tanımlandığını göstermektedir (181, 182). Duyarlılık, “Eşitlik 12” ile verilen bir formül kullanılarak hesaplanmaktadır.

$$\text{Duyarlılık} = \frac{GP}{GP+YN} \quad (\text{Eşitlik 12})$$

3.4.4. Kesinlik

Pozitif olarak tahmin ettiğimiz değerlerin gerçekten kaç tanesinin pozitif olduğunu göstermektedir. Gerçek pozitif ve doğru sınıflandırılmış örnek (GP) ile dikkate alınan tüm pozitif örnekler (GP + YP) arasındaki karşılaştırmaya dayanmaktadır (181, 182). Kesinlik, “Eşitlik 13” ile verilen bir formül kullanılarak hesaplanmaktadır.

$$\text{Kesinlik} = \frac{GP}{GP+YP} \quad (\text{Eşitlik 13})$$

3.4.5. F1 Skor

Kesinlik ve duyarlılığın harmonik ortalamasını gösteren bir metriktir. Maksimum olarak bir sayısına, yani mükemmel kesinlik ve duyarlılığa ve yine minimum sıfıra sahip olabilmektedir. Genel olarak, sınıflandırma modelinin kesinliğinin ve sağlamlığının bir ölçüsüdür. Oluşturulan iki modeli düşük kesinlik ve yüksek duyarlılık ile karşılaştırmak çok güçtür ya da tam tersi de mümkün olabilmektedir. Bu nedenle iki modeli kıyaslanabilir hale getirmek için F1 skoru kullanılmaktadır (181, 182). F1 Skor, “Eşitlik 14” ile verilen bir formül kullanılarak hesaplanmaktadır.

$$\text{F1_Skor} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (\text{Eşitlik 14})$$

3.4.6. Eğri Altındaki Alan ve Alıcı İşlem Karakteristiği

Eğri Altındaki Alan (AUC) eğrisi ve Alıcı İşlem Karakteristiği (ROC) çeşitli eşik ayarlarında sınıflandırma problemi için bir performans ölçü metriğidir. Bununla birlikte ROC bir olasılık eğrisidir ve AUC ayrılabilirliğin derecesini veya ölçüsünü temsil etmektedir. Bu metrikler, eğrinin altında kalan alanı oluşturmaktadır. Modellerin, sınıflar arasında ne kadar ayırt edici olduğunu göstermektedir. Eğri altındaki alanın artması, modelin tahmin gücünün yüksek olduğunu göstermektedir. Alıcı İşlem Karakteristiği, bir modelin genel doğruluğunu gösteren bir tahmin metriğidir. Bir model ele alındığında, eğri dört ana frekans ve bir kesme değeri ile temsil edilmektedir. Bu koşullar, olayları veya olay olmayanları tahmin etme, gerçek sonuç ve tahminlerle eşleşip eşleşmediği ile ilgili dört senaryoyu kapsar. Grafiğin kendisinde x eksen, 1-özgüllüğü ve y eksen de duyarlılığı temsil etmektedir. Eğri, kesme noktalarının bir sonucunu göstermektedir (181, 182). Bu metrik, “Eşitlik 15” ile verilen bir formül kullanılarak hesaplanmaktadır.

$$AUC = \frac{1}{2} \left(\frac{GP}{GP+YN} + \frac{GN}{GN+YP} \right) \quad (\text{Eşitlik 15})$$

3.4.7. Gerçek Pozitif Oran

Gerçek Pozitif Oran (GPO), tüm pozitif veri noktalarına göre pozitif olarak kabul edilen, pozitif veri noktalarının oranına karşılık gelmektedir (181, 182). Bu metrik, “Eşitlik 16” ile verilen bir formül kullanılarak hesaplanmaktadır.

$$TPR = \frac{GP}{YN+GP} \quad (\text{Eşitlik 16})$$

3.4.8. Yanlış Pozitif Oran

Yanlış Pozitif Oran (YPO), tüm negatif veri noktalarına göre yanlışlıkla pozitif olarak kabul edilen, negatif veri noktalarının oranına karşılık gelmektedir. Bu metrik, “Eşitlik 17” ile verilen bir formül kullanılarak hesaplanmaktadır.

$$FPR = \frac{YP}{YP+GN} \quad (\text{Eşitlik 17})$$

Pozitifleri doğru bir şekilde tanımlamak bizim için önemliyse, daha yüksek hassasiyetli bir model seçmeliyiz. Bununla birlikte, negatifleri doğru bir şekilde tanımlamak daha önemliyse, ölçüm metriği olarak özgüllüğü seçmeliyiz (181, 182).

3.4.9. Cohen Kappa Değeri

Gözlenen doğruluk ile beklenen doğruluğu karşılaştırarak sınıflandırma değerleri ile doğruluk değerleri arasındaki benzerliği ölçmektedir (181, 182). Genel olarak Kappa istatistiği, $k = 1$ mükemmel uyumu, $k = 0$ şans eseri beklenenden daha kötü uyumu, $k < 0$ ise şanstan daha kötü uyumu göstermektedir. Bu metrik, “Eşitlik 18” ile verilen bir formül kullanılarak hesaplanmaktadır.

$$\text{Kappa katsayısı} = \frac{2x(GP \times GN - YN \times YP)}{(GP + YP) \times (YP + GN) + (GP + YN) \times (YN + GN)} \quad (\text{Eşitlik 18})$$

3.5. Klinik Karar Destek Sistemleri

Günümüzde tıp biliminde, hasta kayıtları, hasta tanı yöntemleri, araştırmalar, yeni ilaçlar gibi tıbbi verinin artışı, bu bilgilerin doğru ve uygun yönetimi ve ortaya çıkan seçenekler arasında doğru karar verebilmek için karar desteğine ihtiyaç duyulmaktadır (183). Klinik karar destek sistemleri, sağlık hizmetlerinin iyileştirilmesine yardımcı olacak bilgi ve öneriler üretilmesine sağlayacak hasta verilerini bir bilgi tabanına bağlar ve bu ihtiyaç duyulan karar desteğine yardımcı olur (184-186).

4. BULGULAR

Doktora tezinin bu bölümünde, yapılan çalışmalar kısmında planlanan problem ve ele alış şekillerine dayalı elde edilen çıktılar sunulmuştur. Doktora tezinde tez çalışmasında ele alınan veri işleme düzeni Tablo 7’ de ve kullanılan öz nitelikler Tablo 8’de sunulmuştur.

Tablo 7. Tez çalışmasında ele alınan veri işleme düzeni.

Iowa Veri Seti	San Diego Veri Seti	Turku Veri Seti
63 Kanal Ortalamaları	32 Kanal Ortalamaları	64 Kanal Ortalamaları
6 adet Tek Kanal (C3, C4, FC1, FC2, CP5, CP6)_ Senaryo 1 (0.5-45 Hz bant geçiren filtre ve 20 sn bölütleme) ve Senaryo 2 (0.1-120 Hz bant geçiren filtre ve 40 sn bölütleme)	6 adet Tek Kanal (C3, C4, FC1, FC2, CP5, CP6)_ Senaryo 1 (0.5-45 Hz bant geçiren filtre ve 20 sn bölütleme) ve Senaryo 2 (0.1-120 Hz bant geçiren filtre ve 40 sn bölütleme)	6 adet Tek Kanal (C3, C4, FC1, FC2, CP5, CP6)_ Senaryo 1 (0.5-45 Hz bant geçiren filtre ve 20 sn bölütleme) ve Senaryo 2 (0.1-120 Hz bant geçiren filtre ve 40 sn bölütleme)
Ön ve Arka Lob 4 Tek Kanal (Fp1, Fp2, O1, O2) Senaryo 1 (0.5-45 Hz bant geçiren filtre ve 20 sn bölütleme) ve Senaryo 2 (0.1-120 Hz bant geçiren filtre ve 40 sn bölütleme)	Ön ve Arka Lob 4 Tek Kanal (Fp1, Fp2, O1, O2) Senaryo 1 (0.5-45 Hz bant geçiren filtre ve 20 sn bölütleme) ve Senaryo 2 (0.1-120 Hz bant geçiren filtre ve 40 sn bölütleme)	Ön ve Arka Lob 4 Tek Kanal (Fp1, Fp2, O1, O2) Senaryo 1 (0.5-45 Hz bant geçiren filtre ve 20 sn bölütleme) ve Senaryo 2 (0.1-120 Hz bant geçiren filtre ve 40 sn bölütleme)
Merkezi ve Frontal 10 Adet Kanalın Ortalamasının (FC5, FC1, FC2, FC6, C3, C4, CP5, CP1, CP2, CP6) 5 Alt Bandı (0.1-4 Hz, 4-8 Hz, 8-12 Hz, 12-30 Hz, 30-45 Hz)	Merkezi ve Frontal 10 Adet Kanalın Ortalamasının (FC5, FC1, FC2, FC6, C3, C4, CP5, CP1, CP2, CP6) 5 Alt Bandı (0.1-4 Hz, 4-8 Hz, 8-12 Hz, 12-30 Hz, 30-45 Hz)	Merkezi ve Frontal 10 Adet Kanalın Ortalamasının (FC5, FC1, FC2, FC6, C3, C4, CP5, CP1, CP2, CP6) 5 Alt Bandı (0.1-4 Hz, 4-8 Hz, 8-12 Hz, 12-30 Hz, 30-45 Hz)
4 Adet Merkezi Kanalın Ortalamasının (FC1, FC2, CP1, CP2) 5 Alt Bandı (0.1-4 Hz, 4-8 Hz, 8-12 Hz, 12-30 Hz, 30-45 Hz)	4 Adet Merkezi Kanalın Ortalamasının (FC1, FC2, CP1, CP2) 5 Alt Bandı (0.1-4 Hz, 4-8 Hz, 8-12 Hz, 12-30 Hz, 30-45 Hz)	4 Adet Merkezi Kanalın Ortalamasının (FC1, FC2, CP1, CP2) 5 Alt Bandı (0.1-4 Hz, 4-8 Hz, 8-12 Hz, 12-30 Hz, 30-45 Hz)
6 Merkezi Kanal Ortalamaları (C1, C2, C3, C4, C5, C6)	(Bu Veri Setinde 6 Merkezi Kanal Ortalamaları ve 18 Merkezi Kanal Ortalamaları yok)	6 Merkezi Kanal Ortalamaları (C1, C2, C3, C4, C5, C6)
18 Merkezi Kanal Ortalamaları (FC1, FC2, FC3, FC4, FC5, FC6, C1, C2, C3, C4, C5, C6, CP1, CP2, CP3, CP4, CP5, CP6)		18 Merkezi Kanal Ortalamaları (FC1, FC2, FC3, FC4, FC5, FC6, C1, C2, C3, C4, C5, C6, CP1, CP2, CP3, CP4, CP5, CP6)


Tablo 8. Çalışmada kullanılan ve önerilen öznitelikler.

Spektral öznitelikler	Doktora tezinde önerilen öznitelikler	Sese dönüştürülen EEG verisinden çıkarılan kroma öznitelikleri
PSD Delta	1. Öznitelik = $\frac{wSMI\ Teta}{wSMI\ Delta}$	Kroma1
PSD Teta	2. Öznitelik = $\frac{PSD\ Delta}{MSF}$	Kroma2
PSD Alfa	3. Öznitelik = $\frac{1}{SE}$	Kroma3
PSD Beta	4. Öznitelik = $\frac{KAC}{SE}$	Kroma4
PSD Gama	5. Öznitelik = $\frac{KAC}{SE}$	
MSF	5. Öznitelik = $\sqrt{\left(\frac{PSD\ Delta}{PSD\ Beta} \times \frac{PSD\ Delta}{PSD\ Alfa}\right)}$	
KAC		Kroma61...
SE		
wSMI Delta		
wSMI Teta		
wSMI Alfa		
wSMI Beta		
wSMI Gama		

4.1. Elektroensefalografi Verisine Dayalı Kullanılan Özniteliklerin Ayırdediciliği


Bu bölümde gözler açık ve dinlenme durumunda kaydedilen PH ve SK'dan elde edilen EEG sinyallerinin Welch yöntemi ile çıkarılan PSD öznitelikleri olan PSD Delta, PSD Teta, PSD Alfa, PSD Beta, PSD Gama öznitelikleri ve bu PSD özniteliklerinin üzerinden hesaplanan SE, MSF, KAC, wSMI Delta, wSMI Teta, wSMI Alfa, wSMI Beta, wSMI Gama öznitelikleri kullanılarak bu çalışma yapılmıştır.

Kullanılan on üç özniteliğin, üç veri setinde PH ve SK'deki karşılaştırılmaları görsel olarak Şekil 23'den başlayarak, Şekil 43'e kadar yer almaktadır. Kırmızı nokta PH'yi ve mavi nokta ise SK'yi göstermekte olup, öznitelikler değerlendirildiğinde EEG'de PH ve SK'nın farklılaştığı görülmektedir.




Şekil 23. Iova PSD Delta özniteliği PH ve SK karşılaştırması. **(a)** Iova PSD Teta özniteliği PH ve SK karşılaştırması. **(b)**

Burada PSD Teta öznitelik değerleri, iki grup için belirgin fark oluştururken, PSD Delta özniteliklerine ait sayısal değerler iki grup için yakın olsalar da, küçük bir fark oluşturmaktadır.




Şekil 24. Iova PSD Alfa özniteliği PH ve SK karşılaştırması. **(a)** Iova PSD Beta özniteliği PH ve SK karşılaştırması. **(b)**

Burada PSD Alfa öznitelik değerleri ve PSD Beta öznitelik değerleri, iki grup için belirgin fark oluşturmaktadır.




Şekil 25. Iova PSD Gama özniteliği PH ve SK karşılaştırması. **(a)** Iova SE özniteliği PH ve SK karşılaştırması. **(b)**

Burada PSD Gama öznitelik ve SE öznitelik değerleri, iki grup için belirgin fark oluşturmaktadır.




Şekil 26. Iova MSF özniteliği PH ve SK karşılaştırması. **(a)** Iova KAC özniteliği PH ve SK karşılaştırması. **(b)**

Burada MSF öznitelik değerleri, iki grup için belirgin fark oluştururken, KAC özniteliklerinin sayısal değerlerinden belirgin fark anlaşılamamaktadır.




Şekil 27. Iova wSMI Delta özniteliği PH ve SK karşılaştırması. **(a)** Iova wSMI Teta özniteliği_PH ve SK karşılaştırması. **(b)**

Burada wSMI Delta ve wSMI Teta özniteliklerinin sayısal değerleri fark oluşturmaktadır.




Şekil 28. Iova wSMI Alfa özniteliği PH ve SK karşılaştırması. **(a)** Iova wSMI Beta özniteliği_PH ve SK karşılaştırması. **(b)**

Burada wSMI Alfa öznitelik değerleri, iki grup için fark oluştururken, wSMI Beta iki grup için belirgin fark oluşturmamaktadır.




Şekil 29. Iova wSMI Gama özniteliği PH ve SK karşılaştırması

Burada wSMI Gama öznitelik değerleri, iki grup için belirgin fark oluşturmaktadır.




Şekil 30. San Diego PSD Delta özniteliği PH ve SK karşılaştırması. **(a)** San Diego PSD Teta özniteliği PH ve SK karşılaştırması. **(b)**

San Diego veri setinde PSD Delta ve PSD Teta öznitelik değerleri, iki grup için de belirgin fark oluşturmamaktadır.




Şekil 31. San Diego PSD Alfa özneliği PH ve SK karşılaştırması. **(a)** San Diego PSD Beta özneliği PH ve SK karşılaştırması. **(b)**

Burada PSD Alfa ve PSD Beta öznelik değerleri, iki grup için de belirgin fark oluşturmamaktadır.




Şekil 32. San Diego PSD Gama özneliği PH ve SK karşılaştırması. **(a)** San Diego SE özneliği PH ve SK karşılaştırması. **(b)**

Burada PSD Gama ve SE öznelik değerleri, iki grup için de belirgin fark oluşturmamaktadır.




Şekil 33. San Diego MSF özniteliği PH ve SK karşılaştırması. **(a)** San Diego KAC özniteliği PH ve SK karşılaştırması. **(b)**

Burada MSF ve KAC öznitelik değerleri, iki grup için de belirgin fark oluşturmamaktadır.




Şekil 34. San Diego wSMI Delta özniteliği PH ve SK karşılaştırması. **(a)** San Diego wSMI Teta özniteliği PH ve SK karşılaştırması. **(b)**

Burada wSMI Delta ve wSMI Teta öznitelik değerleri, iki grup için de belirgin fark oluşturmamaktadır.




Şekil 35. San Diego wSMI Alfa özniteliği PH ve SK karşılaştırması. **(a)** San Diego wSMI Beta özniteliği PH ve SK karşılaştırması. **(b)**

Burada wSMI Alfa iki grup için farklı olurken, wSMI Beta öznitelik değerleri, iki grup için belirgin fark oluşturmamaktadır.




Şekil 36. San Diego wSMI Gama özniteliği PH ve SK karşılaştırması




Şekil 37. Turku PSD Delta özniteliği PH ve SK karşılaştırması. **(a)** Turku PSD Teta özniteliği PH ve SK karşılaştırması. **(b)**

Turku veri setinde SK ve PH gruplarının PSD Delta ve PSD Teta değerlerinin birbirine çok yakın çıktığı görülmektedir. Bu nedenle seçilen özniteliklerin ayırt ediciliğinin düşük olacağı açıktır.




Şekil 38. Turku PSD Alfa özniteliği PH ve SK karşılaştırması. **(a)** Turku PSD Beta özniteliği PH ve SK karşılaştırması. **(b)**

Burada PSD Alfa ve PSD Beta öznitelik değerleri, iki grup için de belirgin fark oluşturmamaktadır.




Şekil 39. Turku PSD Gama özniteliği PH ve SK karşılaştırması. **(a)** Turku SE özniteliği PH ve SK karşılaştırması. **(b)**


Burada PSD Gama iki grup için belirgin fark oluşturmamakla birlikte, SE öznitelik değerleri, iki grup için farklı çıkmaktadır.




Şekil 40. Turku MSF özniteliği PH ve SK karşılaştırması. (a) Turku KAC özniteliği_PH ve SK karşılaştırması. (b)



Şekil 41. Turku wSMI Delta özniteliği PH ve SK karşılaştırması. (a) Turku wSMI Teta özniteliği_PH ve SK karşılaştırması. (b)




Şekil 42. Turku wSMI Alfa özniteliği PH ve SK karşılaştırması. (a) Turku wSMI Beta özniteliği_PH ve SK karşılaştırması. (b)




Şekil 43. Turku PH ve SK wSMI Gama özniteliği karşılaştırması

4.2. Tez Çalışmasında Önerilen Özniteliklerin Karşılaştırılması


Kullanılan 13 öznitelik üzerinden çıkarılan, Tablo 8’de doktora tezinde önerilen öznitelik sütununda yer alan beş yeni özniteliğin, üç veri setinde PH ve SK’deki karşılaştırmaları görsel olarak Şekil 44’den başlayarak, Şekil 52’ye kadar yer almaktadır. Kırmızı nokta PH’yi ve mavi nokta ise SK’yi göstermekte olup, öznitelikler değerlendirildiğinde EEG’de, PH ve SK’nin farklılaştığı görülmektedir.




Şekil 44. Iowa birinci özniteliği PH ve SK karşılaştırması




Şekil 45. Iova ikinci özniteliği PH ve SK karşılaştırması. (a) Iova üçüncü özniteliği PH ve SK karşılaştırması. (b)




Şekil 46. Iova dördüncü özniteliği PH ve SK karşılaştırması. (a) Iova beşinci özniteliği PH ve SK karşılaştırması. (b)




Şekil 47. San Diego birinci özniteliği PH ve SK karşılaştırması




Şekil 48. San Diego ikinci özniteliği PH ve SK karşılaştırması. **(a)** San Diego üçüncü özniteliği PH ve SK karşılaştırması. **(b)**




Şekil 49. San Diego dördüncü özniteliği PH ve SK karşılaştırması. **(a)** San Diego beşinci özniteliği PH ve SK karşılaştırması. **(b)**



Şekil 50. Turku birinci özniteliği PH ve SK karşılaştırması



Şekil 51. Turku ikinci özneliği PH ve SK karşılaştırması. **(a)** Turku üçüncü özneliği PH ve SK karşılaştırması. **(b)**



Şekil 52. Turku dördüncü özneliği PH ve SK karşılaştırması. **(a)** Turku beşinci özneliği PH ve SK karşılaştırması. **(b)**

4.3. Kanal Sayılarına Göre Sınıflandırma Sonuçları

Kullanılan üç veri setinin ölçüm cihazları farklı olduğundan, EEG elektrotlarına ait kanal sayıları da farklıdır. Tezin bu bölümünde, her üç veri seti arasında analiz sonuçlarının doğru şekilde karşılaştırmasının yapılabilmesi amacıyla ortak kanallar seçilmiştir. Seçilen bu kanallara göre işlem adımları Tablo 7’de sunulmuştur. Bulgular başlığı Tablo 7’ye göre devam ettirilmiştir.

4.3.1. Veri Setlerinin Ortak 31 Kanalına Göre Sonuçlar

Bu bölümde gözler açık, dinlenme durumunda kaydedilen, üç farklı veri setinde ortak olan 31 kanal seçilerek öznelilik çıkarılmış ve sınıflandırma yapılmıştır. Bu kanallar; Fp1, AF3, F7, F3, FC1, FC5, T7, C3, CP1, O1, Oz, O2, CP5, P3, P7, PO3, PO4, P4, P8, CP6, CP2, C4, T8, FC6, FC2, F4, F8, AF4, Fp2, Fz, Cz’den oluşmaktadır. Burada 20 saniyelik epoklama yapılmış, 0.5-45 Hz bant geçiren filtre ve 60 ve 100 Hz’de çentik filtre


uygulanmıştır. Bu sınıflandırmada PSD Delta, PSD Teta, PSD Alfa, PSD Beta, PSD Gama, SE, MSF, KAC, wSMI Delta, wSMI Teta, wSMI Alfa, wSMI Beta, wSMI Gama özniteliklerinden oluşan 13 öznitelik kullanılmıştır.

4.3.1.1. Iowa Veri Seti 31 Kanal Sonuçları


Tablo 9’da Iowa veri setinin tüm kafa geneli 31 kanalına ait verilerinin kullanılan dokuz makine öğrenmesi yöntemiyle elde edilen ortalama sınıflandırma sonuçları sunulmuştur. Tabloda modelin eğitim süresi, test süresi, doğruluk, duyarlılık, kesinlik, F1 skoru, Cohen Kappa Değeri yer almaktadır. On katlı çapraz doğrulama sonuçları ve standart sapmaları verilmiştir. Burada en yüksek sınıflandırma doğruluğuna (%85.00) XGBoost algoritması ile ulaşılmıştır. İkinci en yüksek sınıflandırma başarısı CatBoost (%83.33) ile elde edilmiştir. DVM ve LR’nin sınıflandırma başarımları oldukça düşüktür. Şekil 53’de ortalama ROC ve AUC, Şekil 54’de ise sınıflandırıcılara ait karışıklık matrisleri yer almaktadır. Karışıklık matrisinde en yüksek sınıflandırma sonucunun elde edildiği XGBoost algoritması ile 14 PH’nin 12’si doğru ve ikisi yanlış, 14 SK’nın 12’si doğru ve ikisi yanlış sınıflandırılmıştır.

Tablo 9. Iowa veri seti 31 kanal ortalaması 10 katlı çapraz doğrulama sonuçları.

Model	Eğitim Süresi (s)	Test Süresi (s)	Doğruluk	Duyarlılık	Kesinlik	F1 Skoru	Cohen’nin Kappa Değeri
CatBoost	0.17 (+/- 0.04)	0.01 (+/- 0.00)	0.83 (+/- 0.16)	0.82 (+/- 0.19)	0.79 (+/- 0.25)	0.78 (+/- 0.23)	0.62 (+/- 0.40)
XGBoost	0.23 (+/- 0.17)	0.03 (+/- 0.01)	0.85 (+/- 0.18)	0.87 (+/- 0.16)	0.85 (+/- 0.22)	0.83 (+/- 0.22)	0.72 (+/- 0.36)
KNN	0.00(+/- 0.00)	0.01 (+/- 0.00)	0.58 (+/- 0.29)	0.57 (+/- 0.29)	0.48(+/- 0.34)	0.49 (+/- 0.31)	0.13 (+/- 0.58)
GB	0.07 (+/- 0.00)	0.01 (+/- 0.00)	0.71 (+/- 0.21)	0.67 (+/- 0.25)	0.60 (+/- 0.31)	0.61 (+/- 0.28)	0.33(+/- 0.49)
DVM	0.00(+/- 0.00)	0.01 (+/- 0.00)	0.46 (+/- 0.26)	0.50 (+/- 0.27)	0.38 (+/- 0.31)	0.39 (+/- 0.27)	-0.02 (+/- 0.53)
LR	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.46 (+/- 0.26)	0.55 (+/- 0.26)	0.41 (+/- 0.33)	0.42 (+/- 0.28)	0.07 (+/- 0.51)
KA	0.00 (+/- 0.00)	0.00 (+/- 0.00)	0.68 (+/- 0.18)	0.65 (+/- 0.22)	0.57 (+/- 0.28)	0.57 (+/- 0.25)	0.27 (+/- 0.44)
NB	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.75 (+/- 0.27)	0.72 (+/- 0.30)	0.68 (+/- 0.34)	0.69 (+/- 0.32)	0.44 (+/- 0.61)
RO	0.27 (+/- 0.00)	0.02 (+/- 0.00)	0.63 (+/- 0.37)	0.62 (+/- 0.39)	0.60 (+/- 0.39)	0.59 (+/- 0.39)	0.25 (+/- 0.74)



Şekil 53. Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri




Şekil 54. Farklı sınıflandırıcıların karışıklık matrisleri

4.3.1.2. San Diego Veri Seti 31 Kanal Sonuçları


Tablo 10’da San Diego veri setinin tüm kafa geneli 31 kanalına ait verilerinin kullanılan dokuz makine öğrenmesi yöntemiyle elde edilen ortalama sınıflandırma sonuçları sunulmuştur. Tabloda modelin eğitim süresi, test süresi, doğruluk, duyarlılık, kesinlik, F1 skoru, Cohen’in Kappa değeri yer almaktadır. Tabloya göre en yüksek sınıflandırma doğruluğuna CatBoost algoritması ile (%64.17) ulaşılmıştır. San Diego veri setinin sınıflandırma başarımlarının, Iova veri setininkilerden düşük olduğu görülmektedir. Şekil 55’de ortalama ROC ve AUC, Şekil 56’da ise sınıflandırıcıların karışıklık matrisleri yer almaktadır. Karışıklık matrisinde en yüksek sınıflandırma sonucunun elde edildiği CatBoost algoritması ile 15 PH’linin 10’u doğru ve beşi yanlış, 16 SK’lının 10’u doğru ve altısı yanlış sınıflandırılmıştır.

Tablo 10. San Diego veri seti 31 kanal ortalaması 10 katlı çapraz doğrulama sonuçları.

Model	Eğitim Süresi (s)	Test Süresi (s)	Doğruluk	Duyarlılık	Kesinlik	F1 Skoru	Cohen’in Kappa Değeri
CatBoost	0.41 (+/- 0.01)	0.01 (+/- 0.00)	0.64 (+/- 0.34)	0.67 (+/- 0.33)	0.61 (+/- 0.39)	0.61 (+/- 0.37)	0.36 (+/- 0.63)
XGBoost	0.03 (+/- 0.00)	0.01 (+/- 0.00)	0.60 (+/- 0.29)	0.62 (+/- 0.27)	0.53 (+/- 0.35)	0.53 (+/- 0.31)	0.25 (+/- 0.50)
KNN	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.59 (+/- 0.25)	0.57 (+/- 0.27)	0.50 (+/- 0.32)	0.50 (+/- 0.29)	0.13 (+/- 0.53)
GB	0.23 (+/- 0.01)	0.01 (+/- 0.00)	0.50 (+/- 0.40)	0.52 (+/- 0.41)	0.50 (+/- 0.42)	0.49 (+/- 0.41)	0.10 (+/- 0.74)
DVM	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.58 (+/- 0.29)	0.60 (+/- 0.30)	0.52 (+/- 0.34)	0.52 (+/- 0.31)	0.19 (+/- 0.54)
LR	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.54 (+/- 0.27)	0.62 (+/- 0.23)	0.46 (+/- 0.35)	0.49 (+/- 0.30)	0.24 (+/- 0.45)
KA	0.00 (+/- 0.00)	0.00 (+/- 0.00)	0.44 (+/- 0.37)	0.42 (+/- 0.37)	0.38 (+/- 0.38)	0.38 (+/- 0.37)	-0.09 (+/- 0.67)
NB	0.00 (+/- 0.00)	0.00 (+/- 0.00)	0.50 (+/- 0.34)	0.52 (+/- 0.36)	0.50 (+/- 0.38)	0.48 (+/- 0.35)	0.07 (+/- 0.65)
RO	0.17 (+/- 0.04)	0.02 (+/- 0.00)	0.50 (+/- 0.37)	0.52 (+/- 0.37)	0.48 (+/- 0.40)	0.47 (+/- 0.37)	0.09 (+/- 0.66)



Şekil 55. Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri




Şekil 56. Farklı sınıflandırıcıların karışıklık matrisleri

4.3.1.3. Turku Veri Seti 31 Kanal Sonuçları


Tablo 11’de Turku veri setinin tüm kafa geneli 31 kanalına ait verilerinin kullanılan dokuz makine öğrenmesi yöntemiyle elde edilen ortalama sınıflandırma sonuçları sunulmuştur. Tabloda modelin eğitim süresi, test süresi, doğruluk, duyarlılık, kesinlik, F1 skoru, Cohen’in Kappa değeri yer almaktadır. Burada diğer sınıflandırıcılara göre XGBoost algoritması ile en yüksek sınıflandırma doğruluğuna (%75.00) ulaşılmıştır. İkinci en iyi sınıflandırma başarımı CatBoost algoritması ile (%72.5) elde edilmiştir. En düşük sınıflandırma doğrulukları ise NB ve LR algoritmaları ile elde edilmiştir. Şekil 57’de ortalama ROC ve AUC, Şekil 58’de ise sınıflandırıcıların karışıklık matrisleri yer almaktadır. Karışıklık matrisinde en yüksek sınıflandırma sonucunun elde edildiği XGBoost algoritması ile 20 PH’linin 15’i doğru ve beşi yanlış, 20 SK’lının 15’i doğru ve beşi yanlış sınıflandırılmıştır.

Tablo 11. Turku veri seti 31 kanal ortalaması 10 katlı çapraz doğrulama sonuçları.

Model	Eğitim Süresi (s)	Test Süresi (s)	Doğruluk	Duyarlılık	Kesinlik	F1 Skoru	Cohen’in Kappa Değeri
CatBoost	0.51 (+/- 0.14)	0.01 (+/- 0.00)	0.72 (+/- 0.13)	0.72 (+/- 0.13)	0.78 (+/- 0.15)	0.71 (+/- 0.13)	0.45 (+/- 0.26)
XGBoost	0.04 (+/- 0.00)	0.01 (+/- 0.00)	0.75 (+/- 0.19)	0.75 (+/- 0.19)	0.78 (+/- 0.19)	0.74 (+/- 0.19)	0.50 (+/- 0.38)
KNN	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.67 (+/- 0.25)	0.67 (+/- 0.25)	0.65 (+/- 0.29)	0.65 (+/- 0.27)	0.35 (+/- 0.50)
GB	0.15 (+/- 0.00)	0.00 (+/- 0.00)	0.70 (+/- 0.26)	0.70 (+/- 0.26)	0.71 (+/- 0.30)	0.68 (+/- 0.28)	0.40 (+/- 0.53)
DVM	0.00 (+/- 0.00)	0.00 (+/- 0.00)	0.67 (+/- 0.25)	0.67 (+/- 0.25)	0.63 (+/- 0.32)	0.63 (+/- 0.28)	0.35 (+/- 0.50)
LR	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.60 (+/- 0.27)	0.60 (+/- 0.27)	0.60 (+/- 0.33)	0.57 (+/- 0.29)	0.20 (+/- 0.55)
KA	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.62 (+/- 0.32)	0.62 (+/- 0.32)	0.61 (+/- 0.37)	0.60 (+/- 0.34)	0.25 (+/- 0.64)
NB	0.00 (+/- 0.00)	0.00 (+/- 0.00)	0.50 (+/- 0.22)	0.50 (+/- 0.22)	0.41 (+/- 0.29)	0.42 (+/- 0.23)	0.00 (+/- 0.44)
RO	0.13 (+/- 0.00)	0.02 (+/- 0.00)	0.65 (+/- 0.22)	0.65 (+/- 0.22)	0.68 (+/- 0.28)	0.63 (+/- 0.24)	0.30 (+/- 0.45)



Şekil 57. Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri




Şekil 58. Farklı sınıflandırıcıların karışıklık matrisleri

4.4. Tek Kanala Dayalı Sınıflandırma Sonuçları

Parkinson hastalığında, erken tanı oluşturacak EEG bulgularının kanal bazlı araştırılmasını yapmak amacıyla, santral ve frontal bölgeden seçilen spesifik kanalların (C3, C4, FC1, FC2, CP5, CP6) sınıflandırma performansları değerlendirilmiştir. Bu kanalların seçilme nedeni, PH'ye ait ilk bulguların genellikle motor performanstaki değişimle ilişkilendiriliyor oluşudur. Ayrıca yine frontal ve oksipital bölge işaretlerinde değişiklik oluşturup oluşturmadığını görmek amacıyla, Fp1, Fp2, O1, O2 elektrot kanallarının sınıflandırma performansları da karşılaştırılmıştır. Burada sırasıyla sensorimotor kortekste sağ ve sol bölgede karşılıklı olarak yer alan kanalların fonksiyonlarının, SK ve PH'deki değişimlerini izlemek ve günlük yaşamda daha kolay veri elde etmek amacıyla tek kanal sınıflandırma başarıları araştırılmıştır. Bu analiz aşamasında verilerin ön işlemeyle ilgili bir araştırma da gerçekleştirilmiştir. Bu nedenle sınıflandırma işlemi aynı kanallar üzerinden iki senaryoya göre gerçekleştirilmiştir. Birinci senaryoda, ön işleme adımları veriyi 20 saniyelik epoklara bölerek, onun üzerinden 0.5-45 Hz bant geçiren filtre ve 60 ve 100 Hz'de çentik filtre uygulanmış ve daha sonra seçilen öznitelikler çıkartılmıştır. İkinci senaryoda 40 saniyelik epoklama yapılmış, 0.1-120 Hz bant geçiren filtre ve 60 ve 100 Hz'de çentik filtre uygulanmıştır. Turku veri setinde, Avrupa şebeke gürültüsü 50 Hz olması nedeniyle 50 ve 100 Hz çentik filtre uygulanmıştır.

4.4.1. Iova Veri Seti Sensorimotor Korteks Tek Kanal Sonuçları

Iova veri setinin C3, C4, FC1, FC2, CP5, CP6 kanallarına ait SK ve PH'li'lerin PSD'leri Şekil 59'da yer almaktadır. Burada x ekseni frekans, y ekseni PSD'yi göstermektedir. Ayrıca, PH'li grup bordo renk ve SK'lı grup siyah renk olarak görülmektedir. Grupların PSD genlik değerlerinin birbiriyle örtüşmediği de görülmektedir. Bu farklılık sınıflandırma sonuçlarına da yansımaktadır.




Şekil 59. Iova C3 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(a)** Iova C4 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(b)** Iova FC1 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(c)** Iova FC2 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(d)** Iova CP5 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(e)** Iova CP6 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(f)**

Iova veri seti birinci senaryo sınıflandırma sonuçları Tablo 12’de on katlı çapraz doğrulama sonuçları ve standart sapmaları ile verilmiştir. Burada diğer sınıflandırıcılara göre CatBoost ve XGBoost algoritması ile en yüksek sınıflandırma doğruluğuna (%88.33) ulaşılmıştır. Burada NB ve LR algoritmaları ile en düşük sınıflandırma sonuçları elde edilmiştir. Şekil 60’da en yüksek değerin elde edildiği CatBoost, XGbosst, KNN ve LR’ye ait doğruluk sonuçları kanal bazında karşılaştırmalı olarak sunulmuştur.

Tablo 12. Iova veri seti birinci senaryo tek kanal doğruluk sonuçları.

Model	C3	C4	FC1	FC2	CP5	CP6
CatBoost	0.88 (+/- 0.18)	0.71 (+/- 0.21)	0.71 (+/- 0.21)	0.75 (+/- 0.22)	0.78 (+/- 0.27)	0.71 (+/- 0.21)
XGBoost	0.88 (+/- 0.18)	0.71 (+/- 0.21)	0.81 (+/- 0.18)	0.81 (+/- 0.18)	0.78 (+/- 0.23)	0.783(+/- 0.18)
KNN	0.66 (+/- 0.33)	0.63 (+/- 0.27)	0.65 (+/- 0.26)	0.53 (+/- 0.33)	0.63 (+/- 0.31)	0.68 (+/- 0.24)
GB	0.51 (+/- 0.26)	0.61 (+/- 0.18)	0.50 (+/- 0.25)	0.61 (+/- 0.31)	0.55 (+/- 0.29)	0.583(+/- 0.29)
DVM	0.55 (+/- 0.21)	0.61 (+/- 0.23)	0.40 (+/- 0.24)	0.26 (+/- 0.13)	0.70 (+/- 0.34)	0.65 (+/- 0.21)
LR	0.43 (+/- 0.26)	0.63 (+/- 0.31)	0.41 (+/- 0.20)	0.36 (+/- 0.06)	0.70 (+/- 0.31)	0.65(+/- 0.26)
KA	0.65 (+/- 0.30)	0.56 (+/- 0.33)	0.53 (+/- 0.20)	0.58 (+/- 0.32)	0.45 (+/- 0.33)	0.65 (+/- 0.21)
NB	0.35 (+/- 0.21)	0.46 (+/- 0.33)	0.43 (+/- 0.33)	0.45 (+/- 0.39)	0.60 (+/- 0.32)	0.45 (+/- 0.29)


**Şekil 60.** Iova veri seti birinci senaryo sınıflandırma sonuçları

Iova veri seti ikinci senaryo doğruluk sonuçları ve standart sapmaları Tablo 13’de verilmiştir. Burada en yüksek sınıflandırma doğruluğuna C3 kanalında (%96.67) CatBoost algoritması ile ulaşılmıştır. Ayrıca, Şekil 61’de en yüksek değerin elde edildiği CatBoost,

XGBoost, KNN ve LR'ye ait doğruluk sonuçları kanal bazında karşılaştırmalı olarak sunulmuştur.

Tablo 13. Iova veri seti ikinci senaryo tek kanal tek kanal doğruluk sonuçları.


Model	C3	C4	FC1	FC2	CP5	CP6
CatBoost	0.96 (+/- 0.10)	0.71 (+/- 0.21)	0.73 (+/- 0.20)	0.76 (+/- 0.26)	0.75 (+/- 0.27)	0.65 (+/- 0.30)
XGBoost	0.88 (+/- 0.18)	0.75 (+/- 0.22)	0.75 (+/- 0.22)	0.81 (+/- 0.18)	0.71 (+/- 0.25)	0.70 (+/- 0.26)
KNN	0.70 (+/- 0.22)	0.63 (+/- 0.34)	0.63 (+/- 0.27)	0.60 (+/- 0.23)	0.65 (+/- 0.21)	0.75 (+/- 0.22)
GB	0.56 (+/- 0.13)	0.53 (+/- 0.33)	0.65 (+/- 0.26)	0.50 (+/- 0.37)	0.55 (+/- 0.29)	0.60 (+/- 0.32)
DVM	0.58 (+/- 0.25)	0.63 (+/- 0.34)	0.66 (+/- 0.29)	0.63 (+/- 0.31)	0.70 (+/- 0.31)	0.55 (+/- 0.33)
LR	0.48 (+/- 0.26)	0.60 (+/- 0.32)	0.63 (+/- 0.31)	0.56 (+/- 0.30)	0.70 (+/- 0.31)	0.61 (+/- 0.27)
KA	0.56 (+/- 0.20)	0.53 (+/- 0.33)	0.73 (+/- 0.24)	0.41 (+/- 0.25)	0.55 (+/- 0.33)	0.60 (+/- 0.32)
NB	0.45 (+/- 0.21)	0.46 (+/- 0.30)	0.46 (+/- 0.33)	0.53 (+/- 0.30)	0.60 (+/- 0.29)	0.48 (+/- 0.21)



Şekil 61. Iova veri seti ikinci senaryo sınıflandırma sonuçları

4.4.2. San Diego Veri Seti Sensorimotor Korteks Tek Kanal Sonuçları

San Diego veri setinin C3, C4, FC1, FC2, CP5, CP6 kanallarına ait SK ve PH'lilerin PSD grafikleri Şekil 62'de yer almaktadır. Burada x eksen frekans, y eksen PSD'yi göstermektedir. Ayrıca, PH'li grup bordo renk ve SK'lı grup siyah renk olarak görülmektedir. Burada da Iova veri setinde olduğu gibi SK ve PH gruplarının PSD genliklerinin örtüşmediği, dolayısıyla iki veri setinin birbirinden farklı olduğu görülmektedir.




Şekil 62. San Diego C3 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(a)** San Diego C4 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(b)** San Diego FC1 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(c)** San Diego FC2 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(d)** San Diego CP5 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(e)** San Diego CP6 kanalı SK ve PH grubu bir kişiye ait PSD görünütüsü. **(f)**

San Diego veri seti birinci senaryoya ait sınıflandırma sonuçları ve standart sapmaları Tablo 14'de verilmiştir. Burada da Iova veri setinde olduğu gibi en yüksek

sınıflandırma doğruluğuna (%84.17) CatBoost algoritması ile ulaşılmıştır. Şekil 63’de en yüksek değerin elde edildiği CatBoost, XGBoost, KNN ve LR’ye ait doğruluk sonuçları kanal bazında karşılaştırmalı olarak sunulmuştur.

Tablo 14. San Diego veri seti birinci senaryo tek kanal doğruluk sonuçları.

Model	C3	C4	FC1	FC2	CP5	CP6
CatBoost	0.84 (+/- 0.16)	0.70 (+/- 0.27)	0.64 (+/- 0.18)	0.60 (+/- 0.29)	0.64 (+/- 0.23)	0.61 (+/- 0.18)
XGBoost	0.70 (+/- 0.23)	0.70 (+/- 0.27)	0.54 (+/- 0.27)	0.51 (+/- 0.26)	0.60 (+/- 0.20)	0.55 (+/- 0.25)
KNN	0.77 (+/- 0.21)	0.59 (+/- 0.21)	0.47 (+/- 0.22)	0.75 (+/- 0.22)	0.65 (+/- 0.21)	0.51 (+/- 0.21)
GB	0.65 (+/- 0.26)	0.60 (+/- 0.32)	0.38 (+/- 0.27)	0.62 (+/- 0.24)	0.50 (+/- 0.17)	0.52 (+/- 0.22)
DVM	0.38 (+/- 0.18)	0.58 (+/- 0.25)	0.38 (+/- 0.18)	0.31 (+/- 0.11)	0.38 (+/- 0.18)	0.55 (+/- 0.25)
LR	0.51 (+/- 0.15)	0.60 (+/- 0.25)	0.38 (+/- 0.10)	0.48 (+/- 0.15)	0.51 (+/- 0.15)	0.57 (+/- 0.26)
KA	0.61 (+/- 0.23)	0.57 (+/- 0.30)	0.25 (+/- 0.19)	0.69 (+/- 0.28)	0.50 (+/- 0.17)	0.45 (+/- 0.27)
NB	0.58 (+/- 0.25)	0.58 (+/- 0.29)	0.35 (+/- 0.15)	0.60 (+/- 0.20)	0.45 (+/- 0.22)	0.61 (+/- 0.27)




Şekil 63. San Diego veri seti birinci senaryo sınıflandırma sonuçları

San Diego veri seti ikinci senaryo sınıflandırma sonuçları ve standart sapmaları Tablo 15’de verilmiştir. Burada diğer sınıflandırıcılara göre CatBoost algoritması ile en yüksek sınıflandırma doğruluğuna (%77.50) C3 kanalında ulaşılmıştır. Ayrıca, Şekil 64’de en başarılı sınıflandırıcıların kanal bazlı karşılaştırması yer almaktadır.

Tablo 15. San Diego veri seti ikinci senaryo tek kanal doğruluk sonuçları.


Model	C3	C4	FC1	FC2	CP5	CP6
CatBoost	0.77 (+/- 0.21)	0.70 (+/- 0.23)	0.60 (+/- 0.20)	0.67 (+/- 0.25)	0.64 (+/- 0.27)	0.61 (+/- 0.27)
XGBoost	0.70 (+/- 0.17)	0.63 (+/- 0.27)	0.51 (+/- 0.21)	0.65 (+/- 0.30)	0.64 (+/- 0.23)	0.65 (+/- 0.30)
KNN	0.55 (+/- 0.21)	0.57 (+/- 0.30)	0.64 (+/- 0.23)	0.58 (+/- 0.32)	0.60 (+/- 0.20)	0.58 (+/- 0.29)
GB	0.45 (+/- 0.21)	0.57 (+/- 0.26)	0.54 (+/- 0.27)	0.58 (+/- 0.25)	0.55 (+/- 0.26)	0.39 (+/- 0.13)
DVM	0.38 (+/- 0.10)	0.48 (+/- 0.21)	0.35 (+/- 0.15)	0.31 (+/- 0.11)	0.38 (+/- 0.23)	0.44 (+/- 0.22)
LR	0.51 (+/- 0.15)	0.51 (+/- 0.15)	0.38 (+/- 0.10)	0.51 (+/- 0.15)	0.51 (+/- 0.15)	0.51 (+/- 0.15)
KA	0.51 (+/- 0.15)	0.54 (+/- 0.27)	0.57 (+/- 0.26)	0.55 (+/- 0.34)	0.59 (+/- 0.25)	0.35 (+/- 0.23)
NB	0.40 (+/- 0.25)	0.48 (+/- 0.30)	0.35 (+/- 0.21)	0.36 (+/- 0.27)	0.45 (+/- 0.21)	0.37 (+/- 0.24)



Şekil 64. San Diego veri seti ikinci senaryo sınıflandırma sonuçları

4.4.3. Turku Veri Seti Sensorimotor Korteks Tek Kanal Sonuçları

Turku veri setinin C3, C4, FC1, FC2, CP5, CP6 kanallarına ait SK ve PH'lilerin PSD grafikleri Şekil 65'de yer almaktadır. Burada x eksen frekans, y eksen PSD'yi göstermektedir. Ayrıca, PH'li grup bordo renk ve SK'lı grup siyah renk olarak görülmektedir. Burada da Iova ve San Diego veri setlerinde olduğu gibi SK ve PH gruplarının PSD genliklerinin örtüşmediği, dolayısıyla iki veri setinin birbirinden farklı olduğu görülmektedir.




Şekil 65. Turku C3 kanalı SK ve PH grubu bir kişiye ait PSD görüntüsü. **(a)** Turku C4 kanalı SK ve PH grubu bir kişiye ait PSD görüntüsü. **(b)** Turku FC1 kanalı SK ve PH grubu bir kişiye ait PSD görüntüsü. **(c)** Turku FC2 kanalı SK ve PH grubu bir kişiye ait PSD görüntüsü. **(d)** Turku CP5 kanalı SK ve PH grubu bir kişiye ait PSD görüntüsü. **(e)** Turku CP6 kanalı SK ve PH grubu bir kişiye ait PSD görüntüsü. **(f)**

Turku veri seti, birinci senaryo sınıflandırma doğruluğu ve standart sapmaları Tablo 16’da verilmiştir. Burada en yüksek sınıflandırma doğruluğuna (%77.50) KNN algoritması ile CP5 kanalında ulaşılmıştır. İkinci en yüksek sonuç (%75) XGBoost algoritması ile FC1 kanalında elde edilmiştir. Ayrıca, Şekil 66’da en başarılı sınıflandırıcıların kanal bazlı karşılaştırması da yer almaktadır.

Tablo 16. Turku veri seti birinci senaryo tek kanal doğruluk sonuçları.

Model	C3	C4	FC1	FC2	CP5	CP6
CatBoost	0.65 (+/- 0.20)	0.55 (+/- 0.18)	0.67 (+/- 0.16)	0.57 (+/- 0.11)	0.57 (+/- 0.27)	0.67 (+/- 0.25)
XGBoost	0.57 (+/- 0.25)	0.62 (+/- 0.27)	0.75 (+/- 0.19)	0.42 (+/- 0.22)	0.62 (+/- 0.23)	0.72 (+/- 0.30)
KNN	0.62 (+/- 0.16)	0.62 (+/- 0.20)	0.67 (+/- 0.25)	0.55 (+/- 0.29)	0.77 (+/- 0.17)	0.57 (+/- 0.25)
GB	0.50 (+/- 0.22)	0.65 (+/- 0.27)	0.70 (+/- 0.24)	0.60 (+/- 0.16)	0.62 (+/- 0.27)	0.52 (+/- 0.17)
DVM	0.70 (+/- 0.15)	0.62 (+/- 0.23)	0.67 (+/- 0.19)	0.50 (+/- 0.11)	0.42 (+/- 0.16)	0.57 (+/- 0.22)
LR	0.62 (+/- 0.23)	0.62 (+/- 0.23)	0.65 (+/- 0.20)	0.47 (+/- 0.07)	0.50 (+/- 0.00)	0.55 (+/- 0.15)
KA	0.52 (+/- 0.17)	0.62 (+/- 0.27)	0.67 (+/- 0.22)	0.55 (+/- 0.21)	0.65 (+/- 0.20)	0.50 (+/- 0.15)
NB	0.65 (+/- 0.22)	0.62 (+/- 0.20)	0.65 (+/- 0.20)	0.57 (+/- 0.22)	0.55 (+/- 0.24)	0.55 (+/- 0.24)




Şekil 66. Turku veri seti birinci senaryo sınıflandırma sonuçları

Turku veri seti ikinci senaryo sınıflandırma sonuçları Tablo 17’de verilmiştir. Burada diğer sınıflandırıcılara göre CatBoost ve KNN algoritmaları ile en yüksek sınıflandırma doğruluğuna (%72.50) FC1 kanalında ulaşılmıştır. Ayrıca Şekil 67’de en başarılı sınıflandırıcıların kanal bazlı karşılaştırması da yer almaktadır.

Tablo 17. Turku veri seti ikinci senaryo tek kanal doğruluk sonuçları.

Model	C3	C4	FC1	FC2	CP5	CP6
CatBoost	0.70 (+/- 0.15)	0.65 (+/- 0.22)	0.72 (+/- 0.17)	0.55 (+/- 0.18)	0.57 (+/- 0.19)	0.70 (+/- 0.24)
XGBoost	0.62 (+/- 0.20)	0.60 (+/- 0.12)	0.70 (+/- 0.18)	0.50 (+/- 0.22)	0.50 (+/- 0.25)	0.62 (+/- 0.32)
KNN	0.70 (+/- 0.15)	0.70 (+/- 0.24)	0.72 (+/- 0.17)	0.57 (+/- 0.22)	0.57 (+/- 0.16)	0.55 (+/- 0.15)
GB	0.57 (+/- 0.25)	0.60 (+/- 0.27)	0.65 (+/- 0.16)	0.55 (+/- 0.18)	0.52 (+/- 0.20)	0.60 (+/- 0.16)
DVM	0.62 (+/- 0.23)	0.70 (+/- 0.24)	0.65 (+/- 0.22)	0.55 (+/- 0.10)	0.52 (+/- 0.13)	0.57 (+/- 0.19)
LR	0.62 (+/- 0.23)	0.65 (+/- 0.22)	0.65 (+/- 0.20)	0.47 (+/- 0.07)	0.47 (+/- 0.07)	0.55 (+/- 0.15)
KA	0.57 (+/- 0.22)	0.65 (+/- 0.22)	0.57 (+/- 0.16)	0.50 (+/- 0.19)	0.55 (+/- 0.21)	0.60 (+/- 0.20)
NB	0.60 (+/- 0.12)	0.65 (+/- 0.20)	0.62 (+/- 0.25)	0.60 (+/- 0.22)	0.52 (+/- 0.13)	0.55 (+/- 0.18)



Şekil 67. Turku veri seti ikinci senaryo sınıflandırma sonuçları


Burada beynin ön bölgesi olan frontal bölgede sağ ve sol bölümde yer alan Fp1 ve Fp2 kanalı ile oksipital bölge yani beynin arka bölümünde sağ ve sol alanda yer alan O1 ve O2 kanallarının SK ve PH grubunda elektriksel potansiyel farkı olup olmadığına dair değerlendirme yapılmıştır.

4.4.4. Frontal ve Oksipital Bölge Tek Kanal Sonuçları

Tablo 18’de, Iova veri seti birinci senaryo sekiz sınıflandırıcı için doğruluk sonuçları ve standart sapmaları verilmiştir. Burada XGBoost algoritması ile en yüksek sınıflandırma doğruluğuna (%85.00) frontal bölgenin sağında yer alan Fp2 kanalı ile ulaşılmıştır. Ayrıca, Şekil 68’de sınıflandırıcıların kanal bazlı karşılaştırılması da verilmiştir.

Tablo 18. Iova veri seti birinci senaryo frontal ve oksipital kanallar doğruluk sonuçları.

Model	Fp1	Fp2	O1	O2
CatBoost	0.63 (+/- 0.26)	0.83 (+/- 0.21)	0.71 (+/- 0.33)	0.75 (+/- 0.17)
XGBoost	0.73 (+/- 0.23)	0.85 (+/- 0.18)	0.71 (+/- 0.33)	0.63 (+/- 0.30)
KNN	0.71 (+/- 0.29)	0.56 (+/- 0.29)	0.71 (+/- 0.25)	0.53 (+/- 0.37)
GB	0.63 (+/- 0.26)	0.68 (+/- 0.24)	0.60 (+/- 0.23)	0.55 (+/- 0.25)
DVM	0.78 (+/- 0.27)	0.71 (+/- 0.21)	0.63 (+/- 0.31)	0.65 (+/- 0.30)
LR	0.75 (+/- 0.27)	0.68 (+/- 0.24)	0.66 (+/- 0.33)	0.61 (+/- 0.31)
KA	0.60 (+/- 0.23)	0.60 (+/- 0.23)	0.75 (+/- 0.27)	0.51 (+/- 0.21)
NB	0.65 (+/- 0.30)	0.61 (+/- 0.27)	0.63 (+/- 0.31)	0.45 (+/- 0.31)




Şekil 68. Iova veri seti birinci senaryo frontal ve oksipital kanal bazlı karşılaştırması

Tablo 19’da Iova veri seti ikinci senaryo sekiz sınıflandırıcı için doğruluk sonuçları ve standart sapmaları verilmiştir. Burada, diğer sınıflandırıcılara göre KNN algoritması ile en yüksek sınıflandırma doğruluğuna (%78.33) beynin oksipital bölgesinde yer alan O1 kanalında ulaşılmıştır. Ayrıca, Şekil 69’da ikinci senaryo en başarılı sınıflandırıcıların frontal ve oksipital kanal bazlı karşılaştırması verilmiştir. Beynin frontal bölümünün sağında yer alan Fp2 ve solunda yer alan Fp1 arasında sınıflandırma doğruluğunun farklı çıkması, elektriksel potansiyellerin farklı olduğunu düşündürmektedir. Aynı şekilde, beynin oksipital bölgesinin sağında yer alan O2 kanalı ile solunda yer alan O1 kanalı arasında da benzer farklılığın olduğu görülmektedir.

Tablo 19. Iova veri seti ikinci senaryo frontal ve oksipital kanallar doğruluk sonuçları.

Model	Fp1	Fp2	O1	O2
CatBoost	0.61 (+/- 0.23)	0.75 (+/- 0.17)	0.73 (+/- 0.38)	0.70 (+/- 0.22)
XGBoost	0.66 (+/- 0.19)	0.63 (+/- 0.16)	0.75 (+/- 0.34)	0.63 (+/- 0.30)
KNN	0.58 (+/- 0.25)	0.63 (+/- 0.16)	0.78 (+/- 0.23)	0.40 (+/- 0.32)
GB	0.53 (+/- 0.33)	0.43 (+/- 0.24)	0.65 (+/- 0.26)	0.50 (+/- 0.29)
DVM	0.71 (+/- 0.25)	0.71 (+/- 0.21)	0.66 (+/- 0.29)	0.55 (+/- 0.29)
LR	0.68 (+/- 0.28)	0.61 (+/- 0.23)	0.56 (+/- 0.24)	0.58 (+/- 0.29)
KA	0.58 (+/- 0.29)	0.41 (+/- 0.29)	0.58 (+/- 0.35)	0.45 (+/- 0.33)
NB	0.56 (+/- 0.24)	0.50 (+/- 0.29)	0.60 (+/- 0.32)	0.41 (+/- 0.32)




Şekil 69. Iova veri seti ikinci senaryo frontal ve oksipital kanal bazlı karşılaştırması

San Diego veri seti birinci senaryo frontal ve oksipital kanallar doğruluk sonuçları Tablo 20’de verilmiştir. Burada en yüksek sınıflandırma doğruluğuna (%75.00) frontal bölgenin solunda yer alan Fp1 kanalı ile CatBoost algoritması ile ulaşılmıştır. Ayrıca, Şekil 70’de en başarılı sınıflandırıcıların kanal bazlı karşılaştırması da yer almaktadır.

Tablo 20. San Diego veri seti birinci senaryo frontal ve oksipital kanallar doğruluk sonuçları.

Model	Fp1	Fp2	O1	O2
CatBoost	0.75 (+/- 0.17)	0.55 (+/- 0.22)	0.68 (+/- 0.18)	0.58 (+/- 0.20)
XGBoost	0.70 (+/- 0.17)	0.55 (+/- 0.22)	0.65 (+/- 0.22)	0.48 (+/- 0.21)
KNN	0.54 (+/- 0.17)	0.60 (+/- 0.20)	0.51 (+/- 0.30)	0.54 (+/- 0.31)
GB	0.50 (+/- 0.34)	0.51 (+/- 0.33)	0.39 (+/- 0.29)	0.45 (+/- 0.25)
DVM	0.41 (+/- 0.20)	0.51 (+/- 0.26)	0.55 (+/- 0.15)	0.41 (+/- 0.13)
LR	0.48 (+/- 0.15)	0.45 (+/- 0.21)	0.38 (+/- 0.18)	0.51 (+/- 0.15)
KA	0.54 (+/- 0.34)	0.45 (+/- 0.29)	0.42 (+/- 0.33)	0.54 (+/- 0.34)
NB	0.61 (+/- 0.27)	0.48 (+/- 0.21)	0.55 (+/- 0.26)	0.31 (+/- 0.24)




Şekil 70. San Diego veri seti birinci senaryo frontal ve oksipital kanal bazlı karşılaştırması

Tablo 21’de San Diego veri seti ikinci senaryo frontal ve oksipital kanal doğruluk sonuçları ve standart sapmaları verilmiştir. Burada, CatBoost ve XGBoost algoritmaları ile en yüksek sınıflandırma doğruluğuna (%70.83) beynin oksipital yani arka sağ bölgede yer alan O2 kanalında ulaşılmıştır. Ayrıca, Şekil 71’de sınıflandırıcıların frontal ve oksipital kanal bazlı karşılaştırılması da sunulmuştur. Beynin frontal bölümünün sağında yer alan Fp2 ve solunda yer alan Fp1 kanalları arasında sınıflandırma doğruluğunun farklı çıkması, elektriksel potansiyellerin farklı olduğunu düşündürmektedir. Beyin oksipital bölgesinin

sağında yer alan O2 kanalı ile solunda yer alan O1 kanalı arasında da doğruluk değerlerinin farklı olması elektriksel potansiyellerin farklı olduğunu düşündürmektedir.

Tablo 21. San Diego veri seti ikinci senaryo frontal ve oksipital kanalların doğruluk sonuçları.

Model	Fp1	Fp2	O1	O2
CatBoost	0.54 (+/- 0.27)	0.58 (+/- 0.20)	0.63 (+/- 0.23)	0.70 (+/- 0.17)
XGBoost	0.60 (+/- 0.25)	0.55 (+/- 0.22)	0.64 (+/- 0.23)	0.70 (+/- 0.17)
KNN	0.54 (+/- 0.22)	0.58 (+/- 0.25)	0.60 (+/- 0.20)	0.54 (+/- 0.17)
GB	0.51 (+/- 0.21)	0.60 (+/- 0.20)	0.54 (+/- 0.22)	0.48 (+/- 0.33)
DVM	0.48 (+/- 0.26)	0.40 (+/- 0.25)	0.29 (+/- 0.10)	0.41 (+/- 0.20)
LR	0.51 (+/- 0.15)	0.51 (+/- 0.15)	0.51 (+/- 0.15)	0.48 (+/- 0.15)
KA	0.65 (+/- 0.21)	0.54 (+/- 0.22)	0.57 (+/- 0.21)	0.51 (+/- 0.33)
NB	0.51 (+/- 0.26)	0.35 (+/- 0.21)	0.31 (+/- 0.28)	0.61 (+/- 0.27)




Şekil 71. San Diego veri seti ikinci senaryo frontal ve oksipital kanal bazlı karşılaştırması

Tablo 22’de, Turku veri seti birinci senaryo frontal oksipital kanallar için doğrulama sonuçları ve standart sapmaları verilmiştir. Burada, GB algoritması ile en yüksek sınıflandırma doğruluğuna (%70.00) frontal bölgenin sağında yer alan Fp2 kanalı ile ulaşılmıştır. Ayrıca, Şekil 72’de dört sınıflandırıcıya, ön ve arka dört kanala ait grafikte 10 katlı çapraz doğrulama sınıflandırma doğruluk sonucu da yer almaktadır.

Tablo 22. Turku veri seti birinci senaryo frontal ve oksipital kanal doğruluk sonuçları.

Model	Fp1	Fp2	O1	O2
CatBoost	0.65 (+/- 0.30)	0.67 (+/- 0.22)	0.65 (+/- 0.25)	0.57 (+/- 0.16)
XGBoost	0.57 (+/- 0.16)	0.67 (+/- 0.19)	0.60 (+/- 0.25)	0.62 (+/- 0.20)
KNN	0.65 (+/- 0.27)	0.57 (+/- 0.16)	0.62 (+/- 0.27)	0.55 (+/- 0.33)
GB	0.60 (+/- 0.12)	0.70 (+/- 0.18)	0.62 (+/- 0.23)	0.45 (+/- 0.10)
DVM	0.50 (+/- 0.29)	0.50 (+/- 0.19)	0.62 (+/- 0.30)	0.62 (+/- 0.20)
LR	0.50 (+/- 0.00)	0.52 (+/- 0.07)	0.60 (+/- 0.27)	0.60 (+/- 0.22)
KA	0.57 (+/- 0.16)	0.62 (+/- 0.27)	0.57 (+/- 0.22)	0.45 (+/- 0.15)
NB	0.45 (+/- 0.24)	0.52 (+/- 0.28)	0.65 (+/- 0.27)	0.55 (+/- 0.21)




Şekil 72. Turku veri seti birinci senaryo frontal ve oksipital kanal bazlı karşılaştırması

Tablo 23’de Turku veri seti ikinci senaryo frontal ve oksipital kanal verilerine göre sınıflandırma sonuçları ve standart sapmaları verilmiştir. En yüksek sınıflandırma doğruluğuna (%70.00) CatBoost algoritması ile beynin oksipital yani arka sağ bölgede yer alan O2 kanalında ulaşılmıştır. Şekil 73’de, frontal ve oksipital kanal verilerine göre sınıflandırma algoritmaları karşılaştırmalı olarak da sunulmuştur.

Tablo 23. Turku veri seti ikinci senaryo frontal ve oksipital kanal doğruluk sonuçları.

Model	Fp1	Fp2	O1	O2
CatBoost	0.65 (+/- 0.27)	0.60 (+/- 0.20)	0.67 (+/- 0.31)	0.70 (+/- 0.15)
XGBoost	0.62 (+/- 0.27)	0.47 (+/- 0.13)	0.62 (+/- 0.23)	0.57 (+/- 0.25)
KNN	0.67 (+/- 0.16)	0.60 (+/- 0.22)	0.60 (+/- 0.12)	0.65 (+/- 0.25)
GB	0.60 (+/- 0.20)	0.60 (+/- 0.22)	0.65 (+/- 0.25)	0.60 (+/- 0.25)
DVM	0.55 (+/- 0.26)	0.57 (+/- 0.25)	0.62 (+/- 0.20)	0.57 (+/- 0.11)
LR	0.50 (+/- 0.00)	0.55 (+/- 0.10)	0.60 (+/- 0.27)	0.60 (+/- 0.16)
KA	0.57 (+/- 0.22)	0.62 (+/- 0.25)	0.60 (+/- 0.22)	0.60 (+/- 0.27)
NB	0.47 (+/- 0.20)	0.52 (+/- 0.23)	0.57 (+/- 0.25)	0.62 (+/- 0.12)




Şekil 73. Turku veri seti ikinci senaryo frontal ve oksipital kanal bazlı karşılaştırması

4.5. Veri Setlerinin Elektroensefalografi Alt Bantlarına Göre Sınıflandırılması


Doktora tez çalışmasının bu kısmında, veri analizi için frekans bölgesi üzerinden bir sınıflandırma yapılmıştır. Veri seti 40 saniyelik epoklarla bölümlendirilmiştir. Öncelikle her üç veri setinde de yer alan FC5, FC1, FC2, FC6, C3, C4, CP5, CP1, CP2, CP6'dan oluşan 10 adet merkezi kanalın verileri EEG'nin alt bantları olarak tanımlanan 0.1-4 Hz Delta, 4-8 Hz Teta, 8-12 Hz Alfa, 12-30 Hz Beta ve 30-45 Hz Gama frekans bandına göre bölünerek, PSD'leri hesaplanmış, öznitelikleri çıkarılmış ve son olarak sınıflandırma sonuçları değerlendirilmiştir. Ayrıca burada, 0.1-120 Hz tüm frekans bandına

da bakılmıştır. Şekil 74’de, seçilen 10 adet kanalın elektrobaşıklıkta yer alan yerleşim düzeni görülmektedir.



Şekil 74. Seçilen merkezi kanalların yerleşim düzeni


Iova veri setinin SK ve PH’ler için seçilen 10 kanal ortalamalarından hesaplanan bağıl PSD değerleri Şekil 75’de yer almaktadır. Her iki grup için tüm frekans aralıklarında PSD genliklerinin farklı olduğu görülmektedir. Bu fark bize, PH için merkezi elektrotlarda elektriksel potansiyellerin değiştiğini düşündürmektedir. Tablo 24’de, Iova veri setine ait 10 kanalın ortalaması sonucu elde edilen sınıflandırma sonuçları ve standart sapmaları verilmiştir. Burada en yüksek sınıflandırma doğruluğuna (%91.67), CatBoost algoritması ile 8-12 Hz yani alfa frekansında ulaşılmıştır. Şekil 76’da, alt frekans bantlarına göre en başarılı sınıflandırma algoritmalarının karşılaştırması sunulmuştur.




Şekil 75. Iova veri seti 10 kanalın bağıl PSD dağılımları

Tablo 24. Iova veri setine ait 10 kanal alt bant doğruluk sonuçları.

Model	0.1-4 Hz	4-8 Hz	8-12 Hz	12-30 Hz	30-45 Hz	0.1-120 Hz
CatBoost	0.88 (+/- 0.18)	0.85 (+/- 0.18)	0.91 (+/- 0.17)	0.81 (+/- 0.18)	0.68 (+/- 0.32)	0.81 (+/- 0.24)
XGBoost	0.78 (+/- 0.18)	0.73 (+/- 0.23)	0.81 (+/- 0.18)	0.81 (+/- 0.18)	0.56 (+/- 0.29)	0.76 (+/- 0.24)
KNN	0.81 (+/- 0.18)	0.83 (+/- 0.22)	0.75 (+/- 0.22)	0.68 (+/- 0.24)	0.68 (+/- 0.32)	0.65 (+/- 0.26)
GB	0.75 (+/- 0.22)	0.75 (+/- 0.22)	0.75 (+/- 0.22)	0.68 (+/- 0.24)	0.51 (+/- 0.30)	0.61 (+/- 0.35)
DVM	0.80 (+/- 0.22)	0.80 (+/- 0.16)	0.68 (+/- 0.24)	0.41 (+/- 0.20)	0.36 (+/- 0.06)	0.66 (+/- 0.29)
LR	0.70 (+/- 0.23)	0.83 (+/- 0.22)	0.71 (+/- 0.21)	0.41 (+/- 0.20)	0.41 (+/- 0.20)	0.63 (+/- 0.31)
KA	0.71 (+/- 0.21)	0.71 (+/- 0.21)	0.75 (+/- 0.22)	0.71 (+/- 0.29)	0.55 (+/- 0.29)	0.60 (+/- 0.31)
NB	0.70 (+/- 0.34)	0.85 (+/- 0.24)	0.83 (+/- 0.16)	0.75 (+/- 0.22)	0.56 (+/- 0.33)	0.70 (+/- 0.34)

**Şekil 76.** Iova veri seti EEG alt bantları 10 kanal sınıflandırma sonuçları


San Diego veri seti için aynı şekilde alt bant düzenlemesi yapıldıktan sonra analiz gerçekleştirilmiştir. Şekil 77’de, seçilen 10 kanala ait bağıl PSD grafikleri yer almaktadır. Grafiklerden, SK ve PH gruplarının bağıl PSD değerlerinin farklı olduğu görülmektedir. Buna bağlı olarak elde edilen, sınıflandırma sonuçları Tablo 25’de verilmiştir. San Diego veri setinde en yüksek sınıflandırma doğruluğuna XGBoost algoritması ile 0.1-120 Hz frekansında (%75.00) ulaşılmıştır. Burada CatBoost ile (%70), 8-12 Hz alfa frekansında gözlenmiştir. Ayrıca, Şekil 78’de alt frekans bantlarında dört sınıflandırıcıya, 10 kanala ait grafikte, 10 katlı çapraz doğrulama sınıflandırma doğruluk sonucu da yer almaktadır.




Şekil 77. San Diego veri seti 10 kanalın bağıl PSD dağılımları

Tablo 25. San Diego veri seti 10 kanal alt bant doğruluk sonuçları.

Model	0.1-4 Hz	4-8 Hz	8-12 Hz	12-30 Hz	30-45 Hz	0.1-120 Hz
CatBoost	0.58 (+/- 0.29)	0.63 (+/- 0.27)	0.70 (+/- 0.27)	0.56 (+/- 0.33)	0.50 (+/- 0.23)	0.65 (+/- 0.30)
XGBoost	0.45 (+/- 0.27)	0.66 (+/- 0.25)	0.48 (+/- 0.21)	0.60 (+/- 0.29)	0.50 (+/- 0.31)	0.75 (+/- 0.30)
KNN	0.57 (+/- 0.30)	0.63 (+/- 0.17)	0.58 (+/- 0.35)	0.45 (+/- 0.25)	0.61 (+/- 0.27)	0.65 (+/- 0.26)
GB	0.57 (+/- 0.30)	0.58 (+/- 0.20)	0.51 (+/- 0.26)	0.64 (+/- 0.18)	0.66 (+/- 0.21)	0.68 (+/- 0.32)
DVM	0.48 (+/- 0.15)	0.54 (+/- 0.17)	0.45 (+/- 0.15)	0.51 (+/- 0.21)	0.35 (+/- 0.05)	0.48 (+/- 0.26)
LR	0.54 (+/- 0.22)	0.55 (+/- 0.25)	0.48 (+/- 0.21)	0.51 (+/- 0.15)	0.41 (+/- 0.13)	0.51 (+/- 0.15)
KA	0.51 (+/- 0.21)	0.57 (+/- 0.26)	0.55 (+/- 0.25)	0.64 (+/- 0.18)	0.53 (+/- 0.22)	0.68 (+/- 0.32)
NB	0.54 (+/- 0.22)	0.64 (+/- 0.31)	0.56 (+/- 0.33)	0.57 (+/- 0.26)	0.57 (+/- 0.30)	0.51 (+/- 0.26)

**Şekil 78.** San Diego veri seti EEG alt bantları 10 kanal sınıflandırma sonuçları


Turku veri setinin Şekil 79’da verilen bağıl PSD grafikleri incelendiğinde, SK ve PH çıktılarının delta bandı haricinde yakın değerler aldığı gözlenmektedir. Bu değerlendirmeye göre de, Tablo 26’da verilen 10 kanalın ortalamasına göre hesaplanan doğruluk sonuçlarının Iowa ve San Diego sonuçlarına göre düşük olduğu görülmektedir. Burada diğer sınıflandırıcılara göre GB ve KA algoritması ile en yüksek sınıflandırma doğruluğuna 0-45 Hz frekansında (%82.50) ulaşılmıştır. Ayrıca, Şekil 80’de alt frekans bandlarında dört sınıflandırıcıya ve 10 kanala ait grafikte 10 katlı çapraz doğrulama sınıflandırma doğruluk sonucu da yer almaktadır.



Şekil 79. Turku veri seti 10 kanalın bağıl PSD dağılımları


Tablo 26. Turku veri seti 10 kanal alt bant doğruluk sonuçları.

Model	0.1-4 Hz	4-8 Hz	8-12 Hz	12-30 Hz	30-45 Hz	0.1-120 Hz
CatBoost	0.72 (+/- 0.23)	0.67 (+/- 0.16)	0.62 (+/- 0.25)	0.65 (+/- 0.20)	0.47 (+/- 0.17)	0.80(+/- 0.10)
XGBoost	0.60 (+/- 0.20)	0.52 (+/- 0.23)	0.62 (+/- 0.20)	0.62 (+/- 0.16)	0.47 (+/- 0.30)	0.77 (+/- 0.17)
KNN	0.55 (+/- 0.18)	0.62 (+/- 0.23)	0.52 (+/- 0.23)	0.65 (+/- 0.25)	0.40 (+/- 0.16)	0.65 (+/- 0.20)
GB	0.50 (+/- 0.27)	0.62 (+/- 0.27)	0.42 (+/- 0.27)	0.65 (+/- 0.27)	0.45 (+/- 0.24)	0.82 (+/- 0.16)
DVM	0.57 (+/- 0.16)	0.67 (+/- 0.22)	0.50 (+/- 0.22)	0.60 (+/- 0.16)	0.42 (+/- 0.11)	0.65 (+/- 0.20)
LR	0.60 (+/- 0.22)	0.70 (+/- 0.15)	0.50 (+/- 0.00)	0.57 (+/- 0.16)	0.50 (+/- 0.25)	0.62 (+/- 0.16)
KA	0.57 (+/- 0.27)	0.50 (+/- 0.27)	0.40 (+/- 0.27)	0.60 (+/- 0.25)	0.37 (+/- 0.23)	0.82 (+/- 0.19)
NB	0.47 (+/- 0.17)	0.47 (+/- 0.13)	0.42 (+/- 0.16)	0.60 (+/- 0.20)	0.45 (+/- 0.15)	0.55 (+/- 0.24)

**Şekil 80.** Turku veri seti EEG alt bantları 10 kanal sınıflandırma sonuçları

Bu bölümde kanal sayısı 10 adetten, dörde indirilerek, az kanal verisi ile sınıflandırma doğruluklarının ne oranda değiştiği araştırılmıştır. Her üç veri setinde de yer alan FC1, FC2, CP1, CP2'den oluşan dört merkezi kanalın beş frekans bandına (0.1-4 Hz, 4-8 Hz, 8-12 Hz, 12-30 Hz, 30-45 Hz) göre sonuçları değerlendirilmiştir. Burada, alt bant

sınırlarına göre geçiş filtresi uygulanmıştır. Veri seti 40 saniyelik epoklarla bölümlendirilmiştir. Şekil 81’de dört kanalın yerleri görülmektedir.



Şekil 81. Seçilen dört merkezi kanalın yerleşim düzeni

Tablo 27’de, Iova veri setine ait dört merkezi kanalın ortalaması ve sekiz sınıflandırıcının doğruluk sonuçları ve standart sapmaları verilmiştir. Burada diğer sınıflandırıcılara göre KNN, DVM, LR algoritmaları ile en yüksek sınıflandırma doğruluğuna 4-8 Hz alfa frekansında (%83.33) ulaşmıştır.

Tablo 27. Iova veri seti dört merkezi kanal alt bant doğruluk sonuçları.

Model	0.1-4 Hz	4-8 Hz	8-12 Hz	12-30 Hz	30-45 Hz
CatBoost	0.71 (+/- 0.21)	0.75 (+/- 0.27)	0.73 (+/- 0.23)	0.65 (+/- 0.26)	0.53 (+/- 0.29)
XGBoost	0.60 (+/- 0.28)	0.75 (+/- 0.27)	0.70 (+/- 0.26)	0.61 (+/- 0.31)	0.56 (+/- 0.20)
KNN	0.68 (+/- 0.24)	0.83 (+/- 0.22)	0.78 (+/- 0.18)	0.60 (+/- 0.24)	0.60 (+/- 0.31)
GB	0.50 (+/- 0.25)	0.76 (+/- 0.26)	0.51 (+/- 0.33)	0.46 (+/- 0.25)	0.36 (+/- 0.31)
DVM	0.63 (+/- 0.23)	0.83 (+/- 0.22)	0.61 (+/- 0.23)	0.41 (+/- 0.20)	0.36 (+/- 0.06)
LR	0.65 (+/- 0.15)	0.83 (+/- 0.22)	0.68 (+/- 0.18)	0.41 (+/- 0.20)	0.41 (+/- 0.20)
KA	0.50 (+/- 0.21)	0.73 (+/- 0.24)	0.63 (+/- 0.22)	0.53 (+/- 0.33)	0.36 (+/- 0.31)
NB	0.66 (+/- 0.24)	0.71 (+/- 0.25)	0.70 (+/- 0.22)	0.66 (+/- 0.19)	0.65 (+/- 0.33)

San Diego veri setine ait dört kanalın ortalaması Tablo 28’de verilmiştir. En yüksek sınıflandırma doğruluğuna (%70.33) KNN algoritması ile 4-8 Hz yani teta frekansında ulaşılmıştır.

Tablo 28. San Diego veri seti dört merkezi kanal alt bant doğruluk sonuçları.

Model	0.1-4 Hz	4-8 Hz	8-12 Hz	12-30 Hz	30-45 Hz
CatBoost	0.52 (+/- 0.34)	0.70 (+/- 0.23)	0.68 (+/- 0.18)	0.67 (+/- 0.15)	0.61 (+/- 0.31)
XGBoost	0.42 (+/- 0.39)	0.57 (+/- 0.26)	0.58 (+/- 0.13)	0.57 (+/- 0.21)	0.55 (+/- 0.33)
KNN	0.64 (+/- 0.23)	0.60 (+/- 0.25)	0.70 (+/- 0.34)	0.61 (+/- 0.27)	0.60 (+/- 0.32)
GB	0.37 (+/- 0.24)	0.45 (+/- 0.27)	0.54 (+/- 0.31)	0.48 (+/- 0.33)	0.43 (+/- 0.30)
DVM	0.51 (+/- 0.15)	0.48 (+/- 0.15)	0.48 (+/- 0.21)	0.57 (+/- 0.21)	0.41 (+/- 0.20)
LR	0.51 (+/- 0.21)	0.51 (+/- 0.15)	0.45 (+/- 0.15)	0.51 (+/- 0.15)	0.51 (+/- 0.21)
KA	0.44 (+/- 0.30)	0.42 (+/- 0.26)	0.54 (+/- 0.34)	0.41 (+/- 0.25)	0.40 (+/- 0.32)
NB	0.55 (+/- 0.25)	0.55 (+/- 0.29)	0.47 (+/- 0.22)	0.47 (+/- 0.22)	0.48 (+/- 0.26)

Turku veri setine ait dört merkezi kanalın ortalaması ve sekiz sınıflandırıcıya ait modelin doğruluk sonuçlarının yer aldığı 10 katlı çapraz doğrulama sonuçları ve standart sapmaları Tablo 29’da verilmiştir. Burada diğer sınıflandırıcılara göre CatBoost ve XGBoost algoritması ile en yüksek sınıflandırma doğruluğuna (%80.00) 4-8 Hz yani teta frekansında ulaşılmıştır.

Tablo 29. Turku veri seti dört merkezi kanal alt bant doğruluk sonuçları.


Model	0-4 Hz	4-8 Hz	8-12 Hz	12-30 Hz	30-45 Hz
CatBoost	0.70 (+/- 0.21)	0.80 (+/- 0.18)	0.57 (+/- 0.16)	0.67 (+/- 0.32)	0.45 (+/- 0.18)
XGBoost	0.62 (+/- 0.27)	0.80 (+/- 0.18)	0.47 (+/- 0.20)	0.70 (+/- 0.24)	0.50 (+/- 0.25)
KNN	0.57 (+/- 0.22)	0.72 (+/- 0.26)	0.47 (+/- 0.17)	0.60 (+/- 0.20)	0.60 (+/- 0.20)
GB	0.50 (+/- 0.25)	0.75 (+/- 0.27)	0.45 (+/- 0.15)	0.57 (+/- 0.22)	0.52 (+/- 0.17)
DVM	0.57 (+/- 0.16)	0.62 (+/- 0.20)	0.42 (+/- 0.19)	0.65 (+/- 0.20)	0.47 (+/- 0.17)
LR	0.60 (+/- 0.16)	0.65 (+/- 0.25)	0.50 (+/- 0.00)	0.60 (+/- 0.16)	0.60 (+/- 0.16)
KA	0.45 (+/- 0.33)	0.67 (+/- 0.25)	0.57 (+/- 0.19)	0.52 (+/- 0.17)	0.50 (+/- 0.19)
NB	0.50 (+/- 0.15)	0.50 (+/- 0.15)	0.45 (+/- 0.15)	0.60 (+/- 0.20)	0.50 (+/- 0.11)

4.6. Diğer En Yüksek Alt Bant Sonuçları

Bu bölümde C1, C2, C3, C4, C5, C6 merkezi kanal verileri ve MSF, KAC, wSMI Alfa, PSD Alfa, ve SE'den oluşan beş öznitelik kullanılarak sınıflandırma sonuçları EEG alt bantlarına göre araştırılmış ve en başarılı bant sonuçları karşılaştırmalı olarak sunulmuştur. Verilere 60 ve 100 Hz'de çentik filtre uygulanmıştır. Veri seti 40 saniyelik epoklarla bölümlendirilmiştir.

4.6.1. Merkezi Kanal Elektroensefalografi Alt Bant Sonuçları

Iova veri seti altı kanalın (C1, C2, C3, C4, C5, C6) ortalamasına bakılmıştır. Şekil 82'de altı kanalın yerleşimi görülmektedir. Seçilen altı kanalın ortalamasına göre CatBoost algoritması ile en yüksek sınıflandırma doğruluğuna (%100.00) 8-12 Hz alfa frekansında ulaşılmıştır (Tablo 30).



Şekil 82. Seçilen altı merkezi kanalın yerleşim düzeni

Tablo 30. Iova veri seti altı merkezi kanal alt bant doğruluk sonuçları.

Model	Eğitim Süresi (s)	Test Süresi (s)	Doğruluk	Duyarlılık	Kesinlik	F1 Skor	Cohen'nin Kappa Değeri
CatBoost	0.27 (+/- 0.00)	0.01 (+/- 0.00)	1.00 (+/- 0.00)	1.00 (+/- 0.00)	1.00 (+/- 0.00)	1.00 (+/- 0.00)	1.00 (+/- 0.00)
XGBoost	0.02 (+/- 0.00)	0.01 (+/- 0.00)	0.90 (+/- 0.15)	0.85 (+/- 0.22)	0.80 (+/- 0.30)	0.82 (+/- 0.27)	0.70 (+/- 0.45)
KNN	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.75 (+/- 0.22)	0.75 (+/- 0.25)	0.70 (+/- 0.30)	0.69 (+/- 0.28)	0.47 (+/- 0.50)
GB	0.06 (+/- 0.00)	0.01 (+/- 0.00)	0.83 (+/- 0.16)	0.82 (+/- 0.19)	0.79 (+/- 0.25)	0.78 (+/- 0.23)	0.62 (+/- 0.40)
DVM	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.71 (+/- 0.21)	0.72 (+/- 0.23)	0.68 (+/- 0.28)	0.66 (+/- 0.26)	0.41 (+/- 0.47)
LR	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.71 (+/- 0.21)	0.75 (+/- 0.22)	0.72 (+/- 0.26)	0.69 (+/- 0.24)	0.45 (+/- 0.45)
KA	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.80 (+/- 0.16)	0.77 (+/- 0.20)	0.72 (+/- 0.27)	0.72 (+/- 0.25)	0.52 (+/- 0.42)
NB	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.90 (+/- 0.15)	0.90 (+/- 0.16)	0.88 (+/- 0.20)	0.87 (+/- 0.20)	0.78 (+/- 0.35)

Turku veri seti ile yapılan aynı analiz adımlarına göre elde edilen sonuçlar Tablo 31'de sunulmuştur. Burada 50 ve 100 Hz'de çentik filtre uygulanmıştır. Burada en yüksek sınıflandırma doğruluğuna (%85.00) CatBoost algoritması ile 4-8 Hz teta frekansında ulaşılmıştır.

Tablo 31. Turku veri seti altı merkezi kanal alt bant doğruluk sonuçları.


Model	Eğitim Süresi (s)	Test Süresi (s)	Doğruluk	Duyarlılık	Kesinlik	F1 Skor	Cohen'nin Kappa Değeri
CatBoost	0.24 (+/- 0.00)	0.01 (+/- 0.00)	0.85(+/- 0.16)	0.85(+/- 0.16)	0.85 (+/- 0.21)	0.82 (+/- 0.2070)	0.70(+/- 0.33)
XGBoost	0.03 (+/- 0.00)	0.01 (+/- 0.00)	0.80 (+/- 0.21)	0.80 (+/- 0.21)	0.83 (+/- 0.23)	0.78 (+/- 0.23)	0.60 (+/- 0.43)
KNN	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.70 (+/- 0.21)	0.70 (+/- 0.21)	0.68 (+/- 0.30)	0.65 (+/- 0.26)	0.40 (+/- 0.43)
GB	0.15 (+/- 0.02)	0.01 (+/- 0.00)	0.57 (+/- 0.22)	0.57 (+/- 0.22)	0.60 (+/- 0.30)	0.55 (+/- 0.23)	0.15 (+/- 0.45)
DVM	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.70 (+/- 0.15)	0.70 (+/- 0.15)	0.67 (+/- 0.28)	0.64 (+/- 0.21)	0.40 (+/- 0.30)
LR	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.70 (+/- 0.15)	0.70 (+/- 0.15)	0.67 (+/- 0.28)	0.64 (+/- 0.21)	0.40 (+/- 0.30)
KA	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.57 (+/- 0.25)	0.57 (+/- 0.25)	0.55 (+/- 0.32)	0.53 (+/- 0.27)	0.15 (+/- 0.50)
NB	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.70 (+/- 0.15)	0.70 (+/- 0.15)	0.72 (+/- 0.21)	0.67 (+/- 0.17)	0.40 (+/- 0.30)

Ayrıca Iowa veri seti 4-8 Hz'de 18 merkezi kanal (FC1, FC2, FC3, FC4, FC5, FC6, C1, C2, C3, C4, C5, C6, CP1, CP2, CP3, CP4, CP5, CP6) ortalamasına bakılmıştır. Burada 60 ve 100 Hz'de çentik filtre uygulanmıştır. Veri seti 40 saniyelik epoklarla bölümlendirilmiştir. Burada diğer sınıflandırıcılara göre CatBoost algoritması ile en yüksek sınıflandırma doğruluğuna (%100.00) ulaşılmıştır.

4.7. Veri Setlerinin Kanal Sayılarına Göre Karşılaştırılması


Tez çalışmasının bu bölümünde, kullanılan kanal sayısının sınıflandırma performansındaki değişime katkısını görmek üzere denenmiş olan farklı kanal sayısı performansları, veri setlerinin kendi içerisinde ve değişik veri setleri arasında karşılaştırmalı olarak sunulmuştur.

Iowa veri seti için 63, 31, 18, 10, altı, dört ve tek kanal için analizler yapılmıştır. En yüksek sınıflandırma doğruluğunun elde edildiği dört algoritmaya göre sonuçlar Şekil 83'de yer almaktadır. Burada 63 kanalda en yüksek %80, 31 kanalda %83, 18 kanalda %100, 10 kanalda %92, altı kanalda %100, dört kanalda %83, tek kanalda %97 doğruluk sonuçlarına ulaşılmıştır.



Şekil 83. Iova veri seti kanal sayılarına göre sınıflandırma sonuçları


San Diego veri seti için 32, 31, 10, dört ve tek kanal için analizler yapılmıştır. En yüksek sınıflandırma doğruluğunun elde edildiği dört algoritmaya göre sonuçlar Şekil 84’de yer almaktadır. Burada 32 kanalda en yüksek %68, 31 kanalda %64, 10 kanalda %75, dört kanalda %71, tek kanalda %84 doğruluk sonuçlarına ulaşılmıştır.



Şekil 84. San Diego veri seti kanal sayılarına göre sınıflandırma sonuçları

Turku veri seti için 64, 31, 18, 10, altı, dört ve tek kanal için analizler yapılmıştır. En yüksek sınıflandırma doğruluğunun elde edildiği dört algoritmaya göre sonuçlar Şekil 85’de yer almaktadır. Burada 64 kanalda en yüksek %78, 31 kanalda %75, 18 kanalda

%70, 10 kanalda %80, altı kanalda %85, dört kanalda %80, tek kanalda %78 doğruluk sonuçlarına ulaşılmıştır.



Şekil 85. Turku veri seti kanal sayılarına göre sınıflandırma sonuçları

Üç veri setine ait kanal sayıları ve en yüksek doğruluk oranları Tablo 32’de yer almaktadır. Tablodaki verilere göre, en yüksek sınıflandırma performansının Iova veri setinin 18 kanal ve altı merkezi kanal sonuçlarından elde edildiği görülmektedir. Tek kanal kullanımında da %96.67’lik sınıflandırma başarısına ulaşılmıştır. San Diego ve Turku veri setlerinin sınıflandırma performansları daha düşük olmakla birlikte tek kanal kullanımında San Diego veri seti ile %84.17 ve Turku veri seti ile %77.5’lik doğruluk elde edilmiştir.

Tablo 32. Farklı veri setlerindeki kanal sayısı performansı.


Veri setleri	64 kanal ort (Tüm kanal)	63 kanal ort (Tüm kanal)	32 kanal ort (Tüm kanal)	31 kanal ortalaması (Tüm kanal)	18 kanal	10 kanal	6 kanal	4 kanal	Tek kanal
Iova	-	0.83 (+/- 0.16)	-	0.85 (+/- 0.18)	1.00 (+/- 0.00)	0.91 (+/- 0.17)	1.00 (+/- 0.00)	0.83 (+/- 0.22)	0.96 (+/- 0.10)
San Diego	-	-	0.67 (+/- 0.29)	0.64 (+/- 0.34)	-	0.70 (+/- 0.27)	-	0.70 (+/- 0.34)	0.84 (+/- 0.16)
Turku	0.77 (+/- 0.20)	-	-	0.80 (+/- 0.10)	0.70 (+/- 0.18)	0.77 (+/- 0.13)	0.85 (+/- 0.16)	0.80 (+/- 0.18)	0.77 (+/- 0.17)

4.8. Üç Veri Setinde C3 Kanalının Birinci ve İkinci Senaryoya Göre Sonuçları

Literatürde C3 kanalının motor görevlerden sorumlu bölgeyi içermesi nedeniyle PH'deki motor işlev kayıplarıyla ilgili olabileceğinden özel olarak ele alınmıştır. Seçilen üç veri setinde C3 kanalı sonuçları Tablo 33'de ayrıntılı olarak yer almaktadır. Şekil 86'da da grafik olarak sunulmuştur. Iova veri setinde C3 kanalı birinci senaryoda %88 doğruluk, ikinci senaryoda %96.67 doğruluk sonucuna ulaşmıştır. San Diego veri seti C3 kanalı birinci senaryoda %84.17 doğruluk, ikinci senaryoda %77.50 doğruluk sonucuna ulaşmıştır. Turku veri seti C3 kanalı birinci senaryoda %65 doğruluk, ikinci senaryoda %70 doğruluk sonucuna ulaşmıştır.

Tablo 33. Üç veri setinde C3 kanalı yedi özniteliğe ait karşılaştırmalı sınıflandırma sonuçları.

Model (CatBoost)	Eğitim Süresi (s)	Test Süresi (s)	Doğruluk	Duyarlılık	Kesinlik	F1 Skor	Cohen'nin Kappa Değeri
Iova Senaryo 1	0.11 (+/- 0.02)	0.01 (+/- 0.00)	0.88 (+/- 0.18)	0.87 (+/- 0.20)	0.83 (+/- 0.28)	0.84 (+/- 0.25)	0.74 (+/- 0.41)
Iova Senaryo 2	0.20 (+/- 0.00)	0.00 (+/- 0.00)	0.96 (+/- 0.10)	0.95 (+/- 0.15)	0.93 (+/- 0.20)	0.94 (+/- 0.18)	0.90 (+/- 0.30)
San Diego Senaryo 1	0.16 (+/- 0.01)	0.01 (+/- 0.00)	0.84 (+/- 0.16)	0.87 (+/- 0.12)	0.88 (+/- 0.11)	0.84 (+/- 0.16)	0.71 (+/- 0.29)
San Diego Senaryo 2	0.11 (+/- 0.02)	0.01 (+/- 0.00)	0.77 (+/- 0.21)	0.77 (+/- 0.23)	0.76 (+/- 0.26)	0.73 (+/- 0.25)	0.52 (+/- 0.47)
Turku Senaryo 1	0.21 (+/- 0.00)	0.01 (+/- 0.00)	0.65 (+/- 0.20)	0.65 (+/- 0.20)	0.65 (+/- 0.26)	0.62 (+/- 0.22)	0.30 (+/- 0.40)
Turku Senaryo 2	0.11 (+/- 0.00)	0.01 (+/- 0.00)	0.70 (+/- 0.15)	0.70 (+/- 0.15)	0.72 (+/- 0.21)	0.67 (+/- 0.17)	0.40 (+/- 0.30)



Şekil 86. Senaryolara göre en yüksek C3 kanalı için sınıflandırma sonuçları

4.9. Tez Çalışmasında Önerilen Yeni Öznitelik Sınıflandırma Sonuçları

Bu çalışmada da kullanılan KAC, MSF, SE, wSMI öznitelikleri biyolojik işaretlerin ayırt edilmesinde etkili parametrelerdir. Bu doktora tez çalışmasında EEG alt bantlarına bu öznitelikler uygulanarak kullanılmıştır. Bununla birlikte, Tablo 8'de önerilen öznitelik

sütununda yer alan öznitelikler, beş yeni öznitelik olarak önerilmiştir. Tablo 34’de görüleceği üzere birinci, ikinci ve dördüncü öznitelik de her üç veri setinde doğruluk sonucunu yükseltmiştir. Iova ve Turku veri setlerinde beşinci öznitelik doğruluk sonucunu yükseltmiştir. Sadece Iova veri setinde üçüncü öznitelik doğruluk sonucunu yükseltmiştir. Yeni özniteliklerin doğruluk sonuçları tek başına değerlendirildiğinde ise Iova veri setinde CatBoost algoritması ile birinci öznitelik ile %73.33, ikinci öznitelik ile %73.33, üçüncü öznitelik ile %56.67, dördüncü öznitelik ile %58.33, beşinci öznitelik ile %75.00 doğruluk sonucu elde edilmiştir. San Diego veri setinde CatBoost algoritması ile birinci öznitelik ile %70.83, ikinci öznitelik ile %33.33, üçüncü öznitelik ile %59.17, dördüncü öznitelik ile %61.67, beşinci öznitelik ile %41.67 doğruluk sonucu elde edilmiştir. Turku veri setinde CatBoost algoritması ile birinci öznitelik ile %57.50, ikinci öznitelik ile %62.50, üçüncü öznitelik ile %67.50, dördüncü öznitelik ile %75.00, beşinci öznitelik ile %45.00 doğruluk sonucu elde edilmiştir.

Yeni özniteliklerin kanal sayısına, kanal konumlarına, veri setlerine bağlı olarak sınıflandırma doğruluk performansları değişmektedir. Iova veri seti 31 kanalda, dördüncü öznitelik ve CatBoost algoritması ile %58.33, 18 merkezi kanalda ise dördüncü öznitelik ile %93.33 doğruluk elde edilmiştir. Yine 31 kanalda üçüncü öznitelik ve CatBoost algoritması ile %56.67 ve 18 merkezi kanalda ise üçüncü öznitelik ile %80.00 doğruluk sonucu elde edilmiştir.

Her üç veri setinde ortak 31 kanal kullanılarak, yeni öznitelikler eklenmiş, eklenmemiş, yeni öznitelikler tek başına olarak sınıflandırma performanslarına bakılmış ve sonuçlar karşılaştırmalı olarak Tablo 34’de sunulmuştur. Sınıflandırma doğruluk sonuçları değerlendirildiğinde, veri setlerine bağlı olarak performansı yüksettikleri görülmektedir. Öznitelikler tek başlarına üç veri setinde de yüksek doğruluk sonuçları vermiştir.

Tablo 34. Yeni özniteliklerin CatBoost algoritması ile karşılaştırmalı doğruluk sonuçları.

Öznitelikler	Iova	San Diego	Turku
31 kanal ve 12 öznitelik (Temel durum)	0.76 (+/- 0.15)	0.64 (+/- 0.34)	0.70(+/-0.21)
Temel durum + 1. öznitelik	0.88 (+/- 0.18)	0.67 (+/- 0.33)	0.72(+/-0.17)
Temel durum + 2. Öznitelik	0.80 (+/- 0.16)	0.64 (+/- 0.38)	0.70(+/-0.21)
Temel durum + 3. Öznitelik	0.78 (+/- 0.18)	0.67 (+/- 0.36)	0.72(+/-0.17)
Temel durum + 4. Öznitelik	0.80 (+/- 0.22)	0.68 (+/- 0.35)	0.72(+/-0.23)
Temel durum + 5. Öznitelik	0.86 (+/- 0.16)	0.60 (+/- 0.39)	0.72(+/-0.23)
1. öznitelik	0.73 (+/- 0.32)	0.70 (+/- 0.23)	0.57(+/-0.29)
2. öznitelik	0.56 (+/- 0.33)	0.59 (+/- 0.21)	0.67(+/-0.22)
3. öznitelik	0.58 (+/- 0.32)	0.61 (+/- 0.23)	0.75(+/-0.15)
4. öznitelik	0.73 (+/- 0.32)	0.33 (+/- 0.33)	0.62(+/-0.16)
5. öznitelik	0.75 (+/- 0.22)	0.41 (+/- 0.20)	0.45(+/-0.21)

4.10. Ses Verisine Dönüştürülen Elektroensefalografi Verisinin Analizi

Bu bölümde üç farklı veri setinde ortak olan 31 kanal verisi üzerinden gidilmiştir. Bu kanallar; Fp1, AF3, F7, F3, FC1, FC5, T7, C3, CP1, O1, Oz, O2, CP5, P3, P7, PO3, PO4, P4, P8, CP6, CP2, C4, T8, FC6, FC2, F4, F8, AF4, Fp2, Fz, Cz'den oluşmaktadır. Burada 20 saniyelik epoklama yapılmış, 0.5-45 Hz bant geçiren filtre ve veri tipine göre 50 Hz veya 60 Hz ve 100 Hz'de çentik filtre uygulanmıştır. Daha sonra DWPT ile öznitelik çıkarımı yapılmış ve istenilen sınıflandırma sonucuna ulaşamayında DWPT uygulanmış veri üzerinden müzik öznitelikleri çıkarılma yoluna gidilmiştir.

4.10.1. Ses Veri Setlerinde Öznitelik Çıkarımı ve Sınıflandırma Sonuçları

Ses veri setlerinde ilk olarak DWPT dönüşümü uygulanarak öznitelikler çıkarılmıştır. Her bir dosya için DWPT ile en iyi 20 katsayı seçilmiş, seçilen katsayılar üzerinden istatistiksel öznitelikler ortalama, standart sapma, maksimum değer, minimum değer ve enerji değerleri hesaplanmıştır. Buradan elde edilen 80 adet öznitelik içerisinde RO algoritması ile öznitelik seçimi yapılmış ve en yüksek doğruluk veren öznitelikler ile


sınıflandırma yapılmıştır. Bu dönüşüm yapılarak çıkarılan öznitelikler ile elde edilen sınıflandırma doğrulukları; Iova veri seti için %75, San Diego veri seti için %78, Turku veri seti için %77.50 olarak hesaplanmıştır.

4.10.2. Müzik Öznitelikleri Çıkarımı ve Sınıflandırma Sonuçları

Burada DWPT uygulanmış ses verisi üzerinden müzik özniteliği çıkarılmıştır. Bu öznitelikler; Spektral Merkez, Spektral Bant Genişliği, Spektral Rolloff, Spektral Düzlük, Spektral Kontrast, Kök Ortalama Kare, Sıfır Geçiş Oranı, Zamansal Merkez, Perde, Tempo, Tempo Zamanları, Ritim Senkronizasyonu, Kromagram Maksimum, Kromagram Minimum, Kromagram Aralığı, Kromagram Ortalaması, Kromagram Varyansı, Kromagram Basıklığı, Kromagram Çarpıklığı, Kaplanmış Kromagram Maksimum, Kaplanmış Kromagram Minumum, Kaplanmış Kromagram Aralığı, Kaplanmış Kromagram Ortalaması, Kaplanmış Kromagram Varyansı, Kaplanmış Kromagram Basıklığı, Kaplanmış Kromagram Çarpıklığı ve Mel Frekansı Kepstrum Katsayıları ikinci ve üçüncü dereceden ayrı ayrı olarak birden başlayarak 20'ye kadar, Ton Ağı birden başlayarak altıya kadar, Kroma CQT ve Delta Kroma CQT birden başlayarak 12'ye kadar, Kroma STFT ve Delta Kroma STFT birden başlayarak 12'ye kadar, Kroma CENS ve Delta Kroma CENS birden başlayarak 12'ye kadar, Kroma VQT ve Delta Kroma VQT birden başlayarak 12'ye kadar içerecek şekilde oluşturmaktadır. Kroma tabanlı özniteliklerde ve Mel Spektral Katsayılarında da ikinci ve üçüncü dereceden delta hesaplanarak kroma tabanlı delta öznitelikleri ayrı ayrı öznitelik olarak hesaplanarak, 266 öznitelik çıkarılmıştır. Bu özniteliklerin RO algoritması ile ağırlıklandırması hesaplanmıştır. En yüksek ağırlıklar kroma tabanlı özniteliklerde yer almaktadır. Bu nedenle analize 208 adet olan ve kendi içerisinde RO algoritması ile öznitelik seçimi yapılarak en yüksek sonucu veren kroma tabanlı öznitelikler kullanılmıştır. Sınıflandırmada kullanılan öznitelikler Delta Kroma STFT Standart Sapması 7 (ikinci dereceden), Kroma CENS 8 (ikinci dereceden), Kroma CENS 2 (üçüncü dereceden), Kroma CQT 2 (ikinci dereceden), Delta Kroma VQT Standart Sapması 5 (ikinci dereceden), Delta Kroma CQT Standart Sapması 2 (üçüncü dereceden), Delta Kroma STFT Standart Sapması 3 (üçüncü dereceden), Delta Kroma CENS Standart Sapması 8 (üçüncü dereceden), Delta Kroma CENS Standart Sapması 5 (üçüncü dereceden), Delta Kroma VQT Standart Sapması 11 (üçüncü dereceden), Delta Kroma CENS Standart Sapması 8 (ikinci dereceden), Delta Kroma VQT Standart Sapması 1 (üçüncü dereceden) kroma tabanlı özniteliklerinden oluşmaktadır.

4.10.2.1. Iova Veri Seti Müzik Öznitelikleri Çıkarılması ve Sınıflandırma Sonuçları


Iova veri seti SK ve PH'li birer kişiye ait ortalama CENS Şekil 87'de verilmiştir. Tablo 35'de Iova veri seti 10 katlı çapraz doğrulama sonuçları ve standart sapmaları verilmiştir. Tabloda 31 kanal ve dokuz sınıflandırıcıya ait modelin eğitim süresi, test süresi ile Doğruluk, Duyarlılık, Kesinlik, F1 skoru, Cohen'nin Kappa Değeri, ROC ve AUC metrikleri yer almaktadır. Ses verileri ile de en yüksek sınıflandırma doğruluğuna (%96.67) CatBoost algoritması ile ulaşılmıştır. Şekil 88'de ortalama ROC ve AUC, Şekil 89'da dokuz sınıflandırıcıya ait karışıklık matrisleri yer almaktadır. Karışıklık matrisinde en yüksek sınıflandırma sonucunun elde edildiği CatBoost algoritması ile 14 PH'linin 13'ü doğru ve biri yanlış, 14 SK'linin 14'ü doğru ve sıfırı yanlış sınıflandırılmıştır.




Şekil 87. Iova SK kroma ortalaması. (a) Iova PH kroma ortalaması. (b)

Tablo 35. Iowa veri setine ait ses öznitelikleri ile sınıflandırma sonuçları.

Model	Eğitim Süresi (s)	Test Süresi (s)	Doğruluk	Duyarlılık	Kesinlik	F1 Skor	Cohen'nin Kappa Değeri
CatBoost	0.08 (+/- 0.00)	0.01 (+/- 0.00)	0.96 (+/- 0.10)	0.95 (+/- 0.15)	0.93 (+/- 0.20)	0.94 (+/- 0.18)	0.90 (+/- 0.30)
XGBoost	0.02 (+/- 0.00)	0.01 (+/- 0.00)	0.73 (+/- 0.29)	0.77 (+/- 0.28)	0.77 (+/- 0.28)	0.73 (+/- 0.29)	0.52 (+/- 0.52)
KNN	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.63 (+/- 0.31)	0.67 (+/- 0.31)	0.64 (+/- 0.34)	0.61 (+/- 0.33)	0.31 (+/- 0.62)
GB	0.19 (+/- 0.01)	0.01 (+/- 0.00)	0.76 (+/- 0.21)	0.80 (+/- 0.21)	0.80 (+/- 0.21)	0.75 (+/- 0.23)	0.55 (+/- 0.45)
DVM	0.01 (+/- 0.01)	0.01 (+/- 0.00)	0.61 (+/- 0.23)	0.65 (+/- 0.20)	0.49 (+/- 0.32)	0.52 (+/- 0.28)	0.28 (+/- 0.39)
LR	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.51 (+/- 0.30)	0.57 (+/- 0.29)	0.45 (+/- 0.36)	0.46 (+/- 0.32)	0.15 (+/- 0.54)
KA	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.80 (+/- 0.22)	0.82 (+/- 0.22)	0.82 (+/- 0.22)	0.79 (+/- 0.23)	0.61 (+/- 0.46)
NB	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.83 (+/- 0.2236)	0.87 (+/- 0.16)	0.84 (+/- 0.25)	0.82 (+/- 0.24)	0.72 (+/- 0.36)
RO	0.28 (+/- 0.00)	0.03 (+/- 0.00)	0.80 (+/- 0.26)	0.82 (+/- 0.25)	0.79 (+/- 0.30)	0.78 (+/- 0.29)	0.63 (+/- 0.51)


**Şekil 88.** Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri



Şekil 89. Farklı sınıflandırıcıların karışıklık matrisleri

4.10.2.2. San Diego Veri Seti Müzik Öznitelikleri Çıkarılması ve Sınıflandırma Sonuçları


San Diego veri seti SK ve PH'li birer kişiye ait ortalama CENS Şekil 90'da verilmiştir. Tablo 36'da San Diego veri seti 31 kanala ve dokuz sınıflandırıcıya ait modelin eğitim süresi, test süresi, Doğruluk, Duyarlılık, Kesinlik, F1 skoru, Cohen'nin Kappa Değeri, ROC ve AUC metriklerinin yer aldığı 10 katlı çapraz doğrulama sonuçları ve standart sapmaları verilmiştir. Burada en yüksek sınıflandırma doğruluğuna (%90.83) CatBoost algoritması ile ulaşılmıştır. Şekil 91'de ortalama ROC ve AUC, Şekil 92'de dokuz sınıflandırıcıya ait karışıklık matrisleri yer almaktadır. Karışıklık matrisinde en yüksek sınıflandırma sonucunun elde edildiği CatBoost algoritması ile 15 PH'linin 13'ü doğru ve ikisi yanlış, 16 SK'lının 15'i doğru ve biri yanlış sınıflandırılmıştır.




Şekil 90. San Diego SK kroma ortalaması. **(a)** San Diego PH kroma ortalaması. **(b)**

Tablo 36. San Diego veri setine ait ses öznelikleri ile sınıflandırma sonuçları.

Model	Eğitim Süresi (s)	Test Süresi (s)	Doğruluk	Duyarlılık	Kesinlik	F1 Skor	Cohen'nin Kappa Değeri
CatBoost	0.23 (+/- 0.00)	0.01 (+/- 0.00)	0.90 (+/- 0.14)	0.92 (+/- 0.11)	0.93 (+/- 0.10)	0.90 (+/- 0.14)	0.83 (+/- 0.26)
XGBoost	0.02 (+/- 0.00)	0.01 (+/- 0.00)	0.78 (+/- 0.23)	0.77 (+/- 0.26)	0.75 (+/- 0.28)	0.74 (+/- 0.27)	0.53 (+/- 0.52)
KNN	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.70 (+/- 0.17)	0.72 (+/- 0.20)	0.70 (+/- 0.23)	0.66 (+/- 0.21)	0.39 (+/- 0.41)
GB	0.19 (+/- 0.00)	0.01 (+/- 0.00)	0.68 (+/- 0.28)	0.67 (+/- 0.31)	0.67 (+/- 0.31)	0.65 (+/- 0.31)	0.33 (+/- 0.63)
DVM	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.70 (+/- 0.17)	0.72 (+/- 0.20)	0.70 (+/- 0.23)	0.66 (+/- 0.21)	0.39 (+/- 0.41)
LR	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.70 (+/- 0.17)	0.72 (+/- 0.20)	0.70 (+/- 0.23)	0.66 (+/- 0.21)	0.39 (+/- 0.41)
KA	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.75 (+/- 0.27)	0.75 (+/- 0.27)	0.70 (+/- 0.33)	0.70 (+/- 0.31)	0.49 (+/- 0.54)
NB	0.00 (+/- 0.00)	0.00 (+/- 0.00)	0.71 (+/- 0.15)	0.70 (+/- 0.18)	0.65 (+/- 0.24)	0.63 (+/- 0.21)	0.36 (+/- 0.36)
RO	0.14 (+/- 0.00)	0.02 (+/- 0.00)	0.74 (+/- 0.19)	0.72 (+/- 0.23)	0.70 (+/- 0.27)	0.67 (+/- 0.25)	0.42 (+/- 0.47)




Şekil 91. Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri



Şekil 92. Farklı sınıflandırıcıların karışıklık matrisleri

4.10.2.3. Turku Veri Seti Müzik Öznitelikleri Çıkarılması ve Sınıflandırma Sonuçları


Turku veri seti SK ve PH'li birer kişiye ait ortalama CENS Şekil 93'de verilmiştir. Tablo 37'de Iowa veri seti 10 katlı çapraz doğrulama sonuçları ve standart sapmaları verilmiştir. Tabloda 31 kanal ve dokuz sınıflandırıcıya ait modelin eğitim süresi, test süresi, Doğruluk, Duyarlılık, Kesinlik, F1 skoru, Cohen'nin Kappa Değeri, ROC ve AUC metrikleri yer almaktadır. En yüksek sınıflandırma doğruluğuna (%87.50) CatBoost algoritması ile ulaşılmıştır. Şekil 94'de ortalama ROC ve AUC, Şekil 95'de dokuz sınıflandırıcıya ait karışıklık matrisleri yer almaktadır. Karışıklık matrisinde en yüksek sınıflandırma sonucunun elde edildiği CatBoost algoritması ile 20 PH'linin 17'si doğru ve üçü yanlış, 20 SK'linin 18'i doğru ve ikisi yanlış sınıflandırılmıştır.




Şekil 93. Turku SK kroma ortalaması. (a) Turku PH kroma ortalaması. (b)

Tablo 37. Turku veri setine ait ses öz nitelikleri sınıflandırma sonuçları.

Model	Eğitim Süresi (s)	Test Süresi (s)	Doğruluk	Duyarlılık	Kesinlik	F1 Skor	Cohen'nin Kappa Değeri
CatBoost	0.55 (+/- 0.15)	0.01 (+/- 0.00)	0.87 (+/- 0.16)	0.87 (+/- 0.1677)	0.87 (+/- 0.22)	0.85 (+/- 0.21)	0.75 (+/- 0.33)
XGBoost	0.02 (+/- 0.00)	0.01 (+/- 0.00)	0.80 (+/- 0.21)	0.80 (+/- 0.21)	0.76 (+/- 0.29)	0.76 (+/- 0.26)	0.60 (+/- 0.43)
KNN	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.62 (+/- 0.16)	0.62 (+/- 0.16)	0.66 (+/- 0.22)	0.61 (+/- 0.17)	0.25 (+/- 0.33)
GB	0.21 (+/- 0.00)	0.01 (+/- 0.00)	0.75 (+/- 0.15)	0.75 (+/- 0.15)	0.77 (+/- 0.21)	0.72 (+/- 0.18)	0.50 (+/- 0.31)
DVM	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.65 (+/- 0.27)	0.65 (+/- 0.27)	0.62 (+/- 0.33)	0.62 (+/- 0.30)	0.30 (+/- 0.55)
LR	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.65 (+/- 0.27)	0.65 (+/- 0.27)	0.65 (+/- 0.31)	0.63 (+/- 0.29)	0.30 (+/- 0.5568)
KA	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.75 (+/- 0.11)	0.75 (+/- 0.11)	0.81 (+/- 0.11)	0.73 (+/- 0.11)	0.50 (+/- 0.22)
NB	0.00 (+/- 0.00)	0.01 (+/- 0.00)	0.75 (+/- 0.11)	0.75 (+/- 0.11)	0.79 (+/- 0.18)	0.72 (+/- 0.15)	0.50 (+/- 0.22)
RO	0.40 (+/- 0.08)	0.03 (+/- 0.00)	0.80 (+/- 0.15)	0.80 (+/- 0.15)	0.82 (+/- 0.20)	0.77 (+/- 0.18)	0.60 (+/- 0.30)

**Şekil 94.** Farklı sınıflandırıcılar için ortalama ROC ve AUC metrikleri




Şekil 95. Farklı sınıflandırıcıların karışıklık matrisleri

Daha sonra ses verisinden çıkarılan DWPT öznelikleri ve DWPT uygulanmış veri üzerinden çıkarılan müzik öznelikleri ile sınıflandırma performas karşılaştırması yapılmıştır. Karşılaştırma sonuçları Tablo 38’de yer almaktadır. Burada görüleceği üzere sadece DWPT ile elde edilen sınıflandırma doğruluk sonuçlarına kıyasla DWPT uygulanmış veri üzerinden çıkarılan müzik öznelikleri ile yapılan sınıflandırma doğruluk sonuçlarının yükseldiği görülmektedir. Bu dönüşüm yapılmış veri üzerinden çıkarılan müzik öznelikleri ile Iova veri seti için en yüksek sınıflandırma sonucu %96.67, San Diego veri seti için en yüksek sınıflandırma sonucu %90.83, Turku veri seti ile en yüksek sınıflandırma sonucu %87.50 olarak bulunmuştur.

Tablo 38. Ses verisi üzerinden çıkarılan özniteliklerin sınıflandırma sonuçlarının karşılaştırılması.

Veri setleri	DWPT	DWPT+müzik Öznitelikleri
Iova	0.75 (+/-0.22)	0.96 (+/- 0.10)
San Diego	0.78 (+/-0.18)	0.90 (+/- 0.14)
Turku	0.77(+/- 0.17)	0.87 (+/- 0.16)

Son olarak standart EEG işaretlerinden elde edilen sınıflandırma performansı ve EEG verisinin ses verisine dönüştürülmesiyle elde edilen müzik özniteliklerinin sınıflandırma performansı kıyaslanmıştır. Her üç veri seti için 31 kanal sonuçları karşılaştırıldığında; Iova EEG veri seti için en yüksek sınıflandırma doğruluğu XGBoost ile %75 ve müzik özniteliklerinde CatBoost ile %97, San Diego EEG veri seti için en yüksek CatBoost ve XGBoost ile %72 ve müzik özniteliklerinde en yüksek CatBoost ile %91, Turku EEG veri seti için en yüksek CatBoost ve XGBoost ile %75 ve müzik özniteliklerinde en yüksek CatBoost ile %88 doğruluk değerlerine ulaşılmıştır. Karşılaştırmalı sonuçlar Şekil 96’da yer almaktadır.



Şekil 96. Üç veri seti 31 kanal için en yüksek EEG ve müzik özniteliklerinin karşılaştırmalı sınıflandırma sonuçları

4.11. Frontal ve Oksipital Kanalların Öznitelik Değerlendirmesi

Tablo 39’da, frontal ve oksipital kanal alt bantlarının sınıflandırma sonuçlarına baktığımızda sekiz öznitelik ile sol frontal bölgede yer alan Fp1 kanalında PSD Alfa özniteliği olmadığında doğruluk sonucu yüksek çıkmaktadır. Burada PSD Alfa özniteliği olduğunda doğruluk sonucu düşük çıkmaktadır. Yine PSD Delta olmadığında doğruluk sonucu düşük çıkmaktadır. Burada PSD Delta olduğunda doğruluk sonucu yüksek çıkmaktadır. Sol oksipital bölgede yer alan O1 kanalında ise PSD Alfa özniteliği olmadığında doğruluk sonucu düşük çıkmaktadır. Bununla birlikte, PSD Alfa özniteliği olduğunda doğruluk sonucu yüksek çıkmaktadır. Yine PSD Delta olmadığında doğruluk sonucu yüksek çıkmaktadır. Buna karşın, PSD Delta olduğunda doğruluk sonucu düşük çıkmaktadır.

Tablo 39. Fp1 ve O1 kanalı PSD Delta ve PSD Alfa öznitelik değerlendirme.

Kanallar	PSD Alfa yok	PSD Alfa var	PSD Delta yok	PSD Delta var
Fp1	0.63 (+/-0.26)	0.60 (+/-0.28)	0.43 (+/-0.20)	0.60 (+/- 0.18)
O1	0.75(+/- 0.30)	0.76 (+/- 0.39)	0.76 (+/- 0.39)	0.73 (+/- 0.38)

4.12. Derin Öğrenme Algoritması Sınıflandırma Sonuçları

Bu doktora tez çalışmasında, derin öğrenme algoritmaları da denenmiştir. Veri boyutu küçük olduğundan, derin öğrenme için elverişli olmasa da, literatürle karşılaştırabilmek ve güncel sınıflandırma algoritmalarını öğrenmek ve geliştirmekte olan yöntemlerden geri kalmamak amacıyla bu tezde derin öğrenme kullanılmıştır. Sınıflandırma için RNN ve LSTM yöntemleri denenmiştir. Burada, RNN ve LSTM modelleri hibrit olarak, basit RNN ve LSTM katmanları içeren birer katlı model oluşturulmuştur. Aktivasyon fonksiyonları olarak Relu ve çıkış fonksiyonu olarak da Sigmoid seçilmiştir. Modelde, Adam Optimizer ve Binary Cross Entropy kayıp fonksiyonu kullanılmıştır. Eğitim tur sayısı 100 olarak belirlenmiş ve sıfır ve bir arasında ölçeklenmiştir. Sonrasında on katlı çapraz doğrulama yapılmıştır.

Burada MLP yapay sinir ağı modeli için aktivasyon fonksiyonları olarak Relu ve çıkış fonksiyonu olarak da Sigmoid kullanılmıştır. Regularization oranı 0.001 olarak alınmıştır. Eğitim tur sayısı 100 olarak belirlenmiştir.

Tablo 40’da derin öğrenme yöntemi ile üç veri seti için ortak olan 31 kanala ait sonuçlar yer almaktadır. Veri setlerinin boyutunun küçük olması nedeniyle derin öğrenmeden istenilen sonuca ulaşamamıştır.

Tablo 40. Derin öğrenme 31 kanal doğruluk sonuçları.

Veri setleri	RNN-LSTM	MLP
Iova	0.60	0.65
San Diego	0.54	0.60
Turku	0.53	0.68

4.13. Veri Setlerinin Karşılaştırmalı Literatür Sonuçları

Tablo 41. Iova veri seti literatür sonuçları.

Yapılan çalışma	Veri seti (gözler açık)	Öznitelik analizi	Makine ve derin öğrenme teknikleri	Sınıflandırma	Doğruluk
Anjum ve ark. (110)	Iova	Doğrusal tahmini kodlama	Hiper düzlemler	PH ve SK	%85.7
Lee ve ark. (170)	Iova	Hjorth parametreleri	GB	PH ve SK	%89.3
Lina Qiu ve ark. (124)	Iova	Faz kilitli değer ve Güç Spektral Yoğunluğu	MCNN	PH ve SK	%99.75
Hanife Goker (120)	Iova	PSD öznitelik vektörleri (49 öznitelik)	BiLSTM	PH ve SK	%97.92
Mehmet Fatih Karakas ve ark. (121)	Iova	Gri düzey eş-oluşum matrisi öznitelikleri	DVM	PH ve SK	%85.7
Önerilen çalışma	Iova	Yedi PSD öznitelik ve tek kanal	CatBoost	PH ve SK	%96.67
Önerilen çalışma	Iova	4-8 Hz, dört PSD özniteliği ve 18 kanal	CatBoost	PH ve SK	%100
Önerilen çalışma	Iova	8-12 Hz, 11 PSD özniteliği ve altı kanal	CatBoost	PH ve SK	%100
Önerilen çalışma	Iova	DWPT+üç müzik öznitelik ve 31 kanal	CatBoost	PH ve SK	%96.67
Önerilen çalışma	Iova	KAC/SE oranı	CatBoost	PH ve SK	%93

Tablo 42. San Diego veri seti literatür sonuçları.

Yapılan çalışma	Veri seti (gözler açık)	Öznitelik analizi	Makine ve derin öğrenme teknikleri	Sınıflandırma	Doğruluk
Khare ve ark.(112)	San Diego	Ayarlanabilir Q dalgacık dönüşümü	En küçük kareler DVM	PH ve SK	%97.65
Khare ve ark.(113)	San Diego	Wigner-ville dağılımına dayalı spektrogram üretimi	CNN 2D	PH ve SK	%100
Loh ve ark. (114)	San Diego	Gabor dönüşümü	CNN 2D	PH ve SK	%92.60
Barua ve ark. (115)	San Diego	Yeni aspirin deseni, istatistiksel momentler ve maksimum mutlak havuzlama	KNN	PH ve SK	%100
Shaban ve ark. (118)	San Diego	Sürekli dalgacık dönüşümü	CNN 2D	PH ve SK	%99.8
Lina Qiu ve ark. (124)	San Diego	Faz kilitli değer ve PSD	MCNN	PH ve SK	%98.27
Chawla ve ark. (122)	San Diego	Esnek analitik dalgacık dönüşümü ve 6 entropi özniteliği	KNN	PH ve SK	%95.85
Önerilen çalışma	San Diego	Yedi EEG PSD öznitelik ve tek kanal	CatBoost	PH ve SK	%84.17
Önerilen çalışma	San Diego	DWPT+üç müzik öznitelik ve 31 kanal	CatBoost	PH ve SK	%90.83

Tablo 43. Turku veri seti literatür sonuçları.

Yapılan çalışma	Veri seti (gözler açık)	Öznitelik analizi	Makine ve derin öğrenme teknikleri	Sınıflandırma	Doğruluk
Henry Railo ve ark. (130)	Turku	Bütçe tabanlı arama algoritması ve 10 kanal	LR	PH ve SK	%77.80
Mehmet Fatih Karakas ve ark (121)	Turku	Gri düzey eş-oluşum matrisi öznitelikleri	DVM	PH ve SK	%63.25
Ilkka Suuronen ve ark. (119)	Turku ile beraber toplam 3 veri seti	Özel bütçe tabanlı arama algoritması ve beş kanal	LR	PH ve SK	%76.00
Önerilen çalışma	Turku	Sekiz PSD özniteliği ve tek kanal (FC1)	CatBoost, KNN	PH ve SK	%75.00
Önerilen çalışma	Turku	Sekiz PSD özniteliği ve tek kanal (CP5)	KNN	PH ve SK	%77.50
Önerilen çalışma	Turku	0,1-4 Hz, beş PSD özniteliği ve altı kanal	CatBoost	PH ve SK	%85.00
Önerilen çalışma	Turku	0,1-4 Hz, beş PSD Özniteliği ve altı kanal	CatBoost	PH ve SK	%80.00
Önerilen çalışma	Turku	DWPT+üç müzik özniteliği ve 31 kanal	CatBoost	PH ve SK	%87.50

5. TARTIŞMA

Bu doktora tez çalışmasında, PH’de dinlenme durumunda EEG’de oluşan beyin dalgalarının değişimleri tespit edilerek, erken dönemde hastalığın daha spesifik şekilde belirlenmesi ve teşhis edilmesi, hastalığın ilerlemesinin yavaşlatılması, gereksiz zaman kaybının önlenmesi ve hastalık ilerlemesinden kaynaklanan bakıma yönelik maliyetlerin ve gereksiz test maliyetlerinin düşürülmesi planlanmıştır. Bu nedenle yapılması planlanan bu çalışmada, EEG’ye ilişkin parametreler makine öğrenmesi yöntemleri kullanılarak elde edilmiş ve PH tanısında hekimlerin kullanabileceği akıllı bir klinik karar destek sistemi geliştirilmesi amaçlanmıştır.

Öncelikli olarak EEG verisine ön işleme yapıldıktan sonra tüm veri setleri için, farklı durumları ve beyin bölgelerini içerecek şekilde kanal bazlı değerlendirme yapılmıştır. Veri işleme düzeni Tablo 7’de gösterilmiştir. Dördüncü bölümde ele alınan ‘4.1. EEG Verisine Dayalı Kullanılan Özniteliklerin Ayırdediciliği’ başlığı altında seçilen özniteliklerin ayırt etme performansları karşılaştırmalı olarak sunulmuştur. Seçilen özniteliklerin birbirlerine yakın değerler taşıyıp taşımadığını görebilmek için, kendi aralarında ikişerli dağılımı Şekil 23’den itibaren, Şekil 43’e kadar sunulmuştur. Bu grafikler incelendiğinde, PSD Delta, PSD Teta, PSD Alfa, PSD Beta, PSD Gama öznitelikleri ve bu PSD özniteliklerinin üzerinden hesaplanan SE, MSF, KAC, wSMI Delta, wSMI Teta, wSMI Alfa, wSMI Beta, wSMI Gama öznitelikleri seçilen durumlarda çoğu için ayırt edici olmuştur. Bununla birlikte, KAC, wSMI Beta, wSMI Delta, wSMI Teta, wSMI Alfa tek başlarına çok seçici olmadıkları da görülmektedir. Bu özniteliklerin birlikte kullanımı sınıflandırma başarısını artırmaktadır.

Daha sonra ‘Bölüm 4.3. Kanal Sayılarına Göre Sınıflandırma Sonuçları’ kısmında, hızlı ve esnek çalışabilen karar destek sistemini genelleştirebilmek amacıyla üç veri setinde ortak olan 31 kanal, sağ ve sol bölgede karşılıklı olarak altı sensorimotor bölgede yer alan kanal (C3, C4, FC1, FC2, CP5, CP6) ve beynin frontal ve oksipital bölgesinde yer alan dört kanal (Fp1, Fp2, O1, O2) tek tek iki senaryo halinde, sensorimotor bölgede yer alan 10 adet kanalın ortalaması (FC5, FC1, FC2, FC6, C3, C4, CP5, CP1, CP2, CP6) beş alt bant olarak ve yine dört adet sensorimotor bölgede yer alan kanalların ortalaması (FC1, FC2, CP1, CP2) beş alt bant olarak bakılmıştır. Sonrasında Iova ve Turku’da veri setlerinde ortak olan ve San Diego veri setinde yer almayan sensorimotor bölgedeki kanalların sınıflandırma performanslarına bakılmıştır. Genel olarak CatBoost, XGBoost,

KNN, GB, DVM, LR, KA, NB, RO olmak üzere sınıflandırma algoritmaları ve Doğruluk, Duyarlılık, Kesinlik, Cohen'nin Kappa Değeri, ROC ve AUC olmak üzere altı adet değerlendirme metriği kullanılmıştır.

Her üç veri seti için farklı kanal sayılarında performans değerlendirmesi Şekil 83'den, Şekil 85'e kadar verilmiştir. Buna göre verilen, üç veri setinin tüm kanalları olan Iova 63 kanal, San Diego 32 kanal, Turku 64 kanal sınıflandırma sonuçlarına göre, en yüksek başarımla Iova veri setinde %80.00 doğruluk değeri ile CatBoost algoritması ile elde edilmiştir. San Diego veri setinde CatBoost ve GB ile %67.50 doğruluk sonucu elde edilmiştir. Turku veri setinde KNN ile %77.50 doğruluk sonucu elde edilmiştir. Üç verisetinde ortak olan 31 kanal sonuçlarına göre en yüksek sonuçlar, Iova veri setinde CatBoost ile %83.33 ve XGBoost ile %85.00, San Diego'da CatBoost ile %64.17 ve XGBoost ile %60.83, Turku'da CatBoost ile %72.50 ve XGBoost ile %75.00 doğruluk elde edilmiştir.

Tablo 13'den, 17'ye kadar incelendiğinde, ön işleme performansının değerlendirildiği sensorimotor bölge tek kanal sonuçlarına göre, en yüksek sınıflandırma doğruluğu Iova veri setinin ikinci senaryosu ile C3 kanalında CatBoost algoritması ile %96.67, birinci senaryosu ile de yine C3 kanalında CatBoost ve XGBoost algoritmaları ile %88.33 değerinde elde edilmiştir. San Diego veri setinin birinci senaryosu ile C3 kanalında CatBoost ile %84.17, ikinci senaryosu ile ise yine CatBoost algoritması ile %77.50 doğruluk sonucu elde edilmiştir. Turku veri setinin birinci senaryosunda CP5 kanalında KNN ile %77.50, ikinci senaryosunda ise FC1 kanalında CatBoost ve KNN ile %72.50 doğruluk sonucu elde edilmiştir. Bununla birlikte, C3 kanalı sonuçları her iki senaryoda da KNN ile %70.00, doğruluk ile ikinci sırada yer almaktadır. Literatürde C3 kanalının PH'de yüksek sınıflandırma doğruluğuna ulaştığını gösteren çalışmalar yapılmıştır (187, 188). Ayrıca, bu çalışmada FC1 kanalında elde edilen yüksek sınıflandırma başarısı durumu literatürdeki PH'de, FC1 ve CP5 kanalının yüksek sınıflandırma doğruluğu ile benzerdir (118). Çalışmamızda sensörimotor bölgedeki kanallarda ve özellikle C3 kanalında sınıflandırma sonuçları yüksek çıkmıştır. Bu sonuç da literatürle uyumlu olarak PH'de motor bölgenin etkilendiğini düşündürmektedir.

Tablo 18'den, Tablo 23'e kadar incelendiğinde, ön işleme performansının değerlendirildiği frontal ve oksipital bölge kanal sonuçlarına göre, Iova veri seti birinci senaryo ile Fp2 kanalında XGBoost ile %85.00, Fp1 kanalında DVM ile %78.33, O1

kanalında KA ile %75.00, O2 kanalında CatBoost ile %75.00 doğruluk sonuçları elde edilmiştir. İkinci senaryoda O1 kanalında KNN ile %78.33, Fp2 kanalında CatBoost ile %75.00, Fp1 kanalında DVM ile %71.67, O2 kanalında CatBoost ile %70.00 doğruluk sonucu elde edilmiştir. San Diego veri seti birinci senaryoda Fp1 kanalında CatBoost ile %75.00, O1 kanalında CatBoost ile %68.33, Fp2 kanalında KNN ile %60.83, O2 kanalında CatBoost ile %58.33 doğruluk sonucu elde edilmiştir. İkinci senaryoda O2 kanalında CatBoost ve XGBoost ile %70.83, Fp1 kanalında KA ile %65.00, O1 kanalında XGBoost ile %64.17, Fp2 kanalında GB ile %60.83 doğruluk sonucu elde edilmiştir. Turku veri seti birinci senaryoda en yüksek tek kanal sonuçları, Fp2 kanalında GB ile %70.00, Fp1 kanalında KNN ile %65.00, O1 kanalında CatBoost ve NB ile %65.00, O2 kanalında XGBoost ve DVM ile %62.50 doğruluk sonucu elde edilmiştir. İkinci senaryoda en yüksek O2 kanalında XGBoost ile %70.00, Fp1 kanalında KNN ile %67.50, O1 kanalında CatBoost ile %67.50, Fp2 kanalında CatBoost, KNN ve GB ile %60.00 doğruluk sonucu elde edilmiştir.

Frontal ve oksipital bölgede Iowa ve San Diego veri setlerinde ikinci senaryo sonuçları daha yüksektir. Turku veri setinde çoğu kanalda ikinci senaryo sonuçları yüksek çıkmıştır. Tüm veri setlerinde kanallara göre değişiklikler izlenmiş birinci senaryoda yüksek çıkan kanal, ikinci senaryoda düşük çıkmış ve tam tersi de olmuştur. Birinci senaryoda frontal ve oksipital bölgede sınıflandırma doğruluk sonuçlarına göre Iowa ve Turku veri setlerinde sırasıyla Fp2, Fp1, O1, O2 kanalları yer almıştır. İkinci senaryoda San Diego ve Turku veri setinde sırasıyla O2, Fp1, O1, Fp2 kanalları en yüksek çıkmıştır. Üç veri setinde de Fp1 ve Fp2, O1 ve O2 kanal sonuçları karşılıklı bölgede olmaları nedeniyle fonksiyonel açıdan değerlendirildiğinde sağ ve sol bölgede farklılıkların olduğu sınıflandırma sonuçlarından görülmektedir. Dinlenme durumu EEG’inde, PH’de Fp1 ve Fp2 kanallarının yüksek sınıflandırma doğruluğu verdiği belirtilmiştir (118). Literatürle uyumlu olarak bu çalışmada da Fp1 ve Fp2 kanallarında yüksek sınıflandırma doğruluğu elde edilmiştir.

Çalışmanın başında belirtildiği üzere, birinci ve ikinci senaryo bant geçiren filtrenin aralıklarının ve segmentleme sürelerinin değiştirilmesini içermektedir. Böylece, ön işlemeden kaynaklanan farklılıklar değerlendirilmiştir. Literatürle uyumlu olarak, EEG verilerinde ön işleme farklılıklarının da sınıflandırma doğruluk sonuçlarını etkilediği görülmüştür (5). Yine literatürle uyumlu olarak, bant geçiren filtrenin üst bant frekansının

değiştirilmesi ve öznitellik çıkarımı için aralık uzunluğunun (segmentleme süresi) değiştirilmesi doğruluk sonuçlarını değiştirmiştir (187).

Tablo 39'a göre frontal ve oksipital bölgeye frekans bazlı bakıldığında Fp1 kanalında PSD Alfa özniteliği başarı sonucunu düşürürken, PSD Delta özniteliği başarı sonucunu yükseltmektedir. Oksipital bölgede yer alan O1 kanalında PSD Alfa özniteliği başarı sonucunu yükseltmektedir. PSD Delta özniteliği ise başarı sonucunu düşürmektedir. Frontal ve oksipital bölgeye göre PSD Alfa ve PSD Delta ters orantı göstermektedir. Bu sonuçlar değerlendirildiğinde alfa ve delta frekansında ön ve arka bölgede PH ve SK'ya göre değişim olduğu görülmektedir. Bu da PH'de beynin bölgelerine göre de frekanslarda değişim olduğunu düşündürmektedir. Bununla birlikte, frontal bölgede alfa bandının daha az etkilendiğini ya da etkilenmediğini ama delta bandının daha fazla etkilendiğini düşündürmektedir. Oksipital bölgede ise alfa bandının daha fazla etkilendiğini ama delta bandının daha az etkilendiğini ya da etkilenmediğini düşündürmektedir. Literatürde yapılan bir çalışmada, PH'de delta frekans aralığındaki salınım tepkileri incelenmiş, PH'lilerde delta duyuşal uyarılmış osilasyonlarını ve olaya bağılı osilasyonlarının yanıtları SK'lılara kıyasla anlamlı derecede düşük bulunmuştur. Olaya bağılı osilasyon yanıtları tüm frontal, merkezi ve parietal bölgelerde azaldığı tespit edilmiştir (189). Yapılan başka bir çalışmada ise PH'de, SK'lılara göre posterior elektrot lokasyonlarında yüksek alfa aktivitesi ile korele bulunmuştur (190).

Iova ve Turku veri setinde ortak olan fakat San Diego veri setinde olmayan merkezi 18 kanalın ve merkezi altı kanalın alt bantlarına da bakılmıştır. Burada delta bandında, teta ve alfa bandında CatBoost ile yüksek sonuçlar elde edilmiştir. Tablo 30'da görüldüğü gibi Iova'da altı sensorimotor kanalda alfa frekansında CatBoost algoritması ile %100 doğruluk sonucu elde edilmiştir. Ayrıca, 18 sensorimotor kanalda teta frekansında CatBoost algoritması ile %100 doğruluk sonucu elde edilmiştir. Turku veri setinde Tablo 31'de görüldüğü gibi altı sensorimotor kanalda teta frekansında CatBoost algoritması ile %85.00 doğruluk sonucuna ulaşılmıştır. Veri setlerini kendi içinde değerlendirildiğinde en yüksek doğruluk sonuçları bu kanallarda elde edilmiştir.

Şekil 96 incelendiğinde, EEG spektral öznitelikleri ile ortak 31 kanalda Iova %85.00, San Diego %64.17 Turku'da %75.00 doğruluk elde edildiği görülür. Müzik öznitelikleri ile 31 kanalda Iova 96.67, San Diego %90.83, Turku %87.50 sınıflandırma doğruluğuna ulaşılmıştır. Ortak 31 kanal bazında değerlendirildiğinde müzik

özniteliklerinin sınıflandırma sonuçlarının EEG özniteliklerinin sonuçlarına göre daha yüksek olduğu görülmektedir.

Çalışma sonuçlarını kullanılan sınıflandırma algoritmaları (CatBoost, XGBoost, KNN, GB, DVM, LR, KA, NB) açısından değerlendirildiğinde en yüksek sınıflandırma sonuçları genel olarak Gradyan Toplama tabanlı CatBoost ile sonrasında sırasıyla XGBoost, KNN, GB ve DVM ile elde edilmiştir. CatBoost, belirli bir özneliğin belirli bir değeri yerine tek bir özneliğin modele katkısına odaklanmayı kolaylaştırarak analizi yapar. Diğer en yüksek sonuç veren model olan XGBoost ise bir grup algoritmayı aynı anda ve paralel olarak eğitir, ardından ağırlıkları ayarlar ve bütünü doğruluğunu artırmak için toplu olarak hepsine geri beslenir. Her algoritma birden fazla CPU veya GPU'da ayrı ayrı eğitilir, bu da eğitim süresini azaltır ve performansı artırır.

Sınıflandırma esnasında eğitim ve test süresine de bakılmıştır. Çalışma sonuçları Tablo 9'da yer alan 31 kanal test süreleri açısından değerlendirildiğinde, CatBoost ile 0.0136, XGBoost ile 0.0157, KNN ile 0.0114, GB ile 0.0121, DVM ile 0.0168, LR ile 0.0144, KA ile 0.0162, NB ile 0.0154 saniye olduğu görülmektedir. En düşük KNN, sonrasında GB ve üçüncü sırada da CatBoost algoritması yer almaktadır. Burada KNN ile CatBoost algoritması arasında 0.0022 saniyelik çok düşük düzeyde bir fark vardır. Sınıflandırma performansı en yüksek olan algoritmanın CatBoost algoritması olması ve işlem süresinin kısa olması, CatBoost algoritmasının kullanışlılığını öne çıkarmaktadır.

Öznitelik bazında değerlendirildiğinde EEG verisinde SE, KAC, wSMI öznitelikleri yüksek sonuçlar vermiştir. Iova veri seti 18 merkezi kanal 4-8 Hz frekansında %100 doğruluk sonucuna ulaşılmıştır. Burada SE ve KAC özneliğinin birbirine SE/KAC oranı ile CatBoost algoritması kullanılarak, Iova verisi teta bandı 18 kanalda %93.00 doğruluk sonucuna ulaşılmıştır. Diğerlerinde de genel olarak yüksek sonuçlara ulaşılmıştır. Parkinson hastalarında istirahat EEG veya MEG ile yapılan çalışmada SK'lilere kıyasla istatistiki olarak genel bir karmaşıklık kaybına uğradığı görülmüştür (191, 192). Sınıflandırmada kullanılan karmaşıklık öznitelikleri (KAC) de bu sonucu desteklemektedir. Literatür araştırmasına dayanarak wSMI özneliğinin PH sınıflandırmasında ilk kez bu çalışma ile kullanılmıştır. Ayrıca, SE ve KAC öznitelikleri de dinlenme durumunda EEG'den PH sınıflandırması çalışmasında ilk kez kullanılmıştır.

Ayrıca, bu çalışmada Tablo 8'de önerilen öznitelikler sütununda görüleceği üzere beş yeni öznitelik önerilmiştir. Her üç veri setinde ortak 31 kanal üzerinde yeni öznitelikler

eklenmiş, eklenmemiş ve yeni özniteliklerin tek başına olarak sınıflandırma sonuçları karşılaştırmalı olarak Tablo 34’de yer almaktadır. Bu tabloda görüleceği üzere yeni önerilen birinci öznitelik, ikinci öznitelik, dördüncü öznitelik her üç veri setinde de doğruluk sonucunu yükseltmiştir. Iova ve Turku veri setlerinde beşinci öznitelik doğruluk sonucunu yükseltmiştir. Sadece Iova veri setinde üçüncü öznitelik doğruluk sonucunu yükseltmiştir. Yeni önerilen öznitelikler başarıyı yükseltmektedir. Kullanılan özniteliklere, yeni öznitelikler ayrı ayrı eklendiğinde en yüksek elde edilen doğruluk sonucundan daha iyi sonuçlara ulaşılmıştır. Bu nedenle, bu özniteliklerin literatüre katkısı olacağı düşünülmektedir.

Yeni öznitelikler, doğruluk sonucu tek başına değerlendirildiğinde Tablo 34’de görüleceği üzere, Iova veri setinde CatBoost algoritması ile birinci öznitelik ile %73.33, ikinci öznitelik ile %73.33, üçüncü öznitelik ile %56.67, dördüncü öznitelik ile %58.33, beşinci öznitelik ile %75.00 doğruluk sonucu elde edilmiştir. San Diego veri setinde CatBoost algoritması ile birinci öznitelik ile %70.83, ikinci öznitelik ile %33.33, üçüncü öznitelik ile %59.17, dördüncü öznitelik ile %61.67, beşinci öznitelik ile %41.67 doğruluk sonucu elde edilmiştir. Turku veri setinde CatBoost algoritması ile birinci öznitelik ile %57.50, ikinci öznitelik ile %62.50, üçüncü öznitelik ile %67.50, dördüncü öznitelik ile %75.00, beşinci öznitelik ile %45.00 doğruluk sonucu elde edilmiştir. Bununla birlikte, yeni öznitelikler de kanal sayısına, kanal konumuna, veri setlerine bağlı olarak sınıflandırma doğruluk performansları değişmektedir. Iova veri seti 31 kanalda dördüncü öznitelik ve CatBoost algoritması ile %58.33 ve 18 merkezi kanalda ise dördüncü öznitelik ile %93.33 elde edilmiştir. Yine 31 kanalda üçüncü öznitelik ve CatBoost algoritması ile %56.67 ve 18 merkezi kanalda ise üçüncü öznitelik ile %80.00 doğruluk sonucu elde edilmiştir. Sınıflandırma doğruluk sonuçları veri setlerine bağlı olarak yükselmektedir. Öznitelikler tek başlarına üç veri setinde de yüksek doğruluk sonuçları vermiştir.

Literatürde EEG’den PH tespiti çalışmalarında genellikle doğruluk metriği kullanılmaktadır (5). PH tespitine yönelik yapılan çoğu çalışmada çapraz doğrulama kullanılmadığı ve çapraz doğrulama kullanılmasının sonuçların güvenilirliği açısından desteklendiği belirtilmektedir (6). Bu çalışmada 10 katlı çapraz doğrulama yapılmış, doğruluk, kesinlik, duyarlılık, F1 skoru, Cohen’nin Kappa Değeri ve ROC ve AUC performans kriterleri dikkate alınmıştır. Bu da yaklaşımın sağlamlığını ve performansının güvenilirliğini göstermektedir.

EEG verisinin sınıflandırma performansı ayrıca elektriksel verilerin ses verisine dönüştürülmesi ile ele alınmıştır. Parkinson literatüründe ilk kez denenen bu yöntemle, bilimsel çalışmalara katkı sunulması amaçlanmıştır. Her üç veri setinde ortak olan 31 kanala ait EEG verileri, ses verilerine dönüştürülmüştür. Dönüştürülen PH verisine yine literatürde ilk kez DWPT yöntemi uygulanarak öznelik çıkarımı yapılmıştır. Tablo 38’de görüldüğü gibi ortak 31 kanalda Iowa veri seti için %75.00, San Diego veri seti için %78.33, Turku veri seti için %77.50 doğruluk sonuçları elde edilmiştir. Elde edilen sınıflandırma doğrulukları düşük olduğundan, performansı artırmak amacıyla geliştirme yoluna gidilmiştir. Bu amaçla, DWPT yapılmış veri üzerinden 266 adet müzik öznelikleri çıkarılmıştır. Bu 266 özneliğe RO algoritmasıyla öznelik seçimi yapılmış ve kroma tabanlı özneliklerin üç veri setinde de daha yüksek sonuç verdiği görülerek çalışmada kroma öznelikleri kullanılmıştır. Iowa veri setinde Delta Kroma STFT Standart Sapması 7 (ikinci dereceden), 1/ Kroma STFT 10 (ikinci dereceden), Kroma CENS 8 (ikinci dereceden) öznelikleri kullanılmıştır. San Diego Kroma CENS 2 (üçüncü dereceden), Kroma CQT 2 (ikinci dereceden), Delta Kroma VQT Standart Sapması 5 (ikinci dereceden), Delta Kroma CQT Standart Sapması 2 (üçüncü dereceden) öznelikleri kullanılmıştır. Turku veri setinde Delta Kroma STFT Standart Sapması 3 (üçüncü dereceden), Delta Kroma CENS Standart Sapması 8 (üçüncü dereceden), Delta Kroma CENS Standart Sapması 5 (üçüncü dereceden), Delta Kroma VQT Standart Sapması 11 (üçüncü dereceden), Delta Kroma CENS Standart Sapması 8 (ikinci dereceden), Delta Kroma VQT Standart Sapması 1 (üçüncü dereceden) kroma tabanlı müzik öznelikleri seçilmiştir. Tablo 35’den, 37’ye kadar görüleceği üzere, bu öznelikler ile Iowa veri setinde CatBoost ile %96.67, San Diego veri setinde CatBoost ile %90.83, Turku veri setinde CatBoost ile %87.50 doğruluk sonuçları elde edilmiştir. Müzik özneliklerinin kullanımı ile yalnızca DWPT özneliklerinin kullanımından daha yüksek sınıflandırma doğruluğu elde edilmiştir. Bu sonuçlar Şekil 96’da görüleceği üzere, ortak 31 kanal üzerinden EEG spektral öznelikleri kullanımı ile elde edilen sınıflandırma başarımlarından daha yüksektir. Dolayısıyla, EEG verisinin ses verisine dönüştürülmesi ve bu veriler üzerinden çıkarılan müzik özneliklerinin PH’de kullanımı ile literatüre katkı sağlanacağı düşünülmektedir.

Bu doktora tez çalışmasında makine öğrenmesi yöntemlerinin kullanımının yanında, derin öğrenme yöntemleri de son yıllarda çok önem kazandığı için karşılaştırma amacıyla kullanılmıştır. Tablo 40’da görüldüğü gibi derin öğrenme algoritması da ortak 31

kanal için uygulanmıştır. Derin öğrenme yöntemlerinden RNN + LSTM hibrit ve MLP algoritmaları denenmiştir. Burada RNN+LSTM ile Iova veri setinde %60, San Diego veri setinde %54, Turku veri setinde %53 ve MLP ile Iova veri setinde %65, San Diego veri setinde %60, Turku veri setinde %68 doğruluk sonuçları elde edilmiştir. Bu sonuçların geleneksel makine öğrenme yöntemlerine göre ve literatürde aynı veri setleri ile derin öğrenme yöntem sonuçlarına göre daha düşük olduğu görülmektedir. Bu düşük başarının temel nedeni olarak veri sayısının küçük olması gösterilebilir. Ayrıca, literatürde genellikle veriler görüntü işleme teknikleri ile sınıflandırılmıştır. Bunun yanında farklı bölütleme tekniklerinin kullanılması da başarıyı artırıcı etkenlerdendir.

Bu doktora tez çalışmasının literatürdeki benzerleri ile olan karşılaştırması Tablo 41-43'de sunulmuştur. Tablo 41'de görüldüğü üzere ilk olarak Iova veri kümesi ve New Mecixo veri kümesini kullanarak spektral özelliklere sahip EEG zaman serilerinin PH tespiti için doğrusal tahmin kodlamalı bir EEG algoritması geliştirmiş ve sınıflandırmada %85.7 doğruluk elde edilmiştir (110). Hjorth parametresi ve GB algoritması kullanarak %89,3 doğrulukla bir PH tahmin yöntemi önermişlerdir (116). Burada 63 kanal sonuçlarının doğruluk oranlarına bakıldığında, doktora çalışmasının literatürdeki sonuçlara kıyasla daha yüksek sınıflandırma doğruluk oranlarına ulaştığı görülmektedir. Faz kilitli değer ve PSD ile derin öğrenme algoritması olan modifiye CNN (MCNN)'nin kullanıldığı ve 63 kanallı çalışmada %99,75 sonuç elde edilmiştir (124). Aynı veri seti ile yapılan başka bir çalışmada 63 kanal, 49 PSD öznitelik vektörü ve bir derin öğrenme modeli olan çift yönlü uzun kısa süreli bellek (BiLSTM) ile %97,92 doğruluk elde edilmiştir (120). Öte yandan, bu tez çalışmasında sadece C3 kanalında yedi öznitelik ve geleneksel makine öğrenmesi yöntemi olan CatBoost algoritması ile ortalama %96,67 sınıflandırma doğruluk sonucuna ulaşılmıştır. Derin öğrenmenin daha büyük bir veri seti gerektirmesi ve daha uzun işlem süresi alması gerçek hayatta kullanımını zorlaştırmaktadır. Holo Hilbert Spektral Analizi ile F8 (FM 4-8 Hz ve AM 2-4 Hz), FZ (FM 128-256 Hz ve AM 1-2 Hz) ve C3'ü (FM 32-64 Hz ve AM 8-16 Hz) en öncelikli üç öznitelik olarak seçmiş ve torba sınıflandırma algoritması ile sınıflandırmada %81 ile en yüksek ortalama doğruluğu elde etmiştir (188). Holo Hilbert Spektral Analizinin özellikle F8, FZ ve C3 elektrotlarında PH'nin SK'lılardan ayırt edilmesini sağladığı bildirilmiştir.

San Diego veri setini kullanan literatürdeki çalışmalar Tablo 42'de verilmiştir. Ayarlanabilir Q dalgacık dönüşümünün öznitelik çıkarım algoritmasının ve En küçük

kareler DVM sınıflandırma algoritmasının kullanıldığı çalışmada %97.65 doğruluk elde edilmiştir (112). Yine aynı grup Wigner-Ville dağılımına dayalı spektrogram üretimi öznelik çıkarımı ve CNN 2D algoritması ile %100 sonuç elde etmiştir (111). Başka bir çalışmada aynı veri seti ile Gabor dönüşümü ve CNN 2D ile %92.60 doğruluk elde edilmiştir (114). Bir başka çalışmada, yeni aspirin deseni, istatistiksel momentler ve maksimum mutlak havuzlama öznelik çıkarımı ve KNN algoritması ile %100 doğruluk elde edilmiştir (115). Sürekli dalgacık dönüşümü öznelik çıkarımı ve CNN 2D algoritması ile %99.8 doğruluk sonucu elde edilmiştir (200). Faz kilitli değer ve PSD öznelik çıkarımı ve MCNN sınıflandırma algoritması ile %98.27 doğruluk elde edilmiştir (116). Esnek analitik dalgacık dönüşümü yapılarak altı entropi özneliği ve KNN algoritması ile %95.85 doğruluk değerine ulaşmıştır (122). Bu doktora çalışmasında San Diego veri seti için en yüksek doğruluk değerine müzik öznelikleri ile % 90 doğruluk ile ulaşılmıştır.

Turku veri setinin Tablo 43'de görülen sonuçlarına göre, sınıflandırma başarıları diğer iki veri setine oranla düşüktür. Bütçe tabanlı arama algoritması ve 10 kanal LR sınıflandırma yöntemiyle %77.80 doğruluk elde edilmiştir (130). Yine aynı veri seti ile Gri düzey eş oluşum matrisi öznelikleri ve DVM yöntemi ile %63.25 doğruluk elde edilmiştir (121). Yine başka bir çalışma ile Bütçe tabanlı arama algoritması, beş kanal ve LR ile %76.00 doğruluk sonucuna ulaşmıştır (119). Bu doktora çalışmasında müzik öznelikleri kullanılarak CatBoost algoritması ile %87.50 değeri ile literatürle kıyaslandığında en yüksek sonuca ulaşılmıştır.

6. SONUÇ ve ÖNERİLER

Bu çalışmanın yukarıdaki tartışma ve en son tekniklerle karşılaştırılması neticesinde, önerilen yaklaşımların, çok ve tek kanallı EEG sinyalleri kullanılarak gerçek zamanlı olarak, SK ve PH'lilerin doğru ve hızlı bir şekilde tespit edilmesine yönelik uygun modeller olduğu sonucuna güçlü bir şekilde ulaşılmaktadır. Literatürle karşılaştırıldığında başarılı sınıflandırma sonuçları elde edilmiştir. Bu çalışmada önerilen yeni yaklaşımlarla, kullanılan öznitelik, yeni sunulan öznitelik, EEG'nin ses verisi üzerinden değerlendirilmesi, literatüre katkı sağlamaktadır.

Yıllar içinde PH konusunda pek çok ilerleme kaydedilmiş ve uzman sistemlerin tıpta teşhis uygulanmasına ilişkin çeşitli yöntemler gösterilmiş olmasına rağmen, hala bilinmezler çoktur. Dolayısıyla bu da, PH tanısının iyileştirilmesine ve sürekli yatırım yapılmasını motive eder. Bu gelişmeler umut vaad ettiğinden, Makine Öğrenimi ve Veri Madenciliği tekniklerinin uygulanması yoluyla PH analizi ve erken teşhis için sonuçlar üreten sağlık hizmetleri teknolojisine ekstra yatırım yapılmasını teşvik etmektedir.

Bu çalışmada önerilen metodolojinin, EEG'den PH teşhisinde yüksek bir tespit oranı elde etmesine rağmen, hala çeşitli sınırlamaları vardır. Bu çalışmada hazır alınan üç farklı veri setinin de boyutları küçüktür. Genelleme yapabilmek ve klinik kullanımda standardize edilebilmesi açısından, önerilen algoritmaların daha fazla örneklem sayısı içeren çalışmalarla ve farklı bölgesel veri kümeleriyle test edilerek PH tespitindeki sağlamlığı artırılmalıdır. Sonuç olarak, bu çalışma sonunda genel olarak tatmin edici sonuçlar alınmış olmasının yanı sıra, PH çalışması için genelleştirilebilecek ve somutlaştırılacak birden fazla yöntem olduğu da ortadadır.

Çalışmanın özel olarak sonuçları aşağıdaki maddeler ile sıralanabilir:

1. Bu çalışmada PH, SK grubu iyi bir sınıflandırma oranı ile ayrılmıştır. Kanal bazlı sınıflandırma sonuçları EEG spektral öznitelikleri ile değerlendirildiğinde, Iova 63 kanalda CatBoost ile %80.00, San Diego 32 kanalda CatBoost ile %67.50, Turku 64 kanalda KNN ile %77.50, ortak 31 kanalda Iova XGBoost ile %85.00, San Diego CatBoost ile %64.17 Turku'da XGBoost ile %75.00 sınıflandırma doğruluk sonuçları elde edilmiştir. En yüksek tek kanal sonuçları, Iova tek kanal en yüksek CatBoost ile %96.67, San Diego tek kanal en yüksek

CatBoost ile %84.17, Turku tek kanal en yüksek KNN ile %77.50 sınıflandırma doğruluk sonuçları elde edilmiştir.

2. Bu çalışmada en yüksek sınıflandırma sonucuna C3 kanalında ulaşılmıştır. Bu da frontal ve oksipital bölgeye göre sensorimotor bölgede daha fazla fonksiyonel değişim olduğunu düşündürmektedir.
3. Üç veri setinin dört merkezi kanal ortalamasında teta bandında yüksek sınıflandırma sonuçları elde edilmiştir. Sonrasında veri setlerinde büyük oranda alfa ve delta bandında değişim olduğu görülmüştür.
4. Alt bant sonuçları ise Iova veri setinde altı sensorimotor kanal CatBoost ile (C1, C2, C3, C4, C5, C6) alfa ve 18 sensorimotor kanal CatBoost ile (FC1, FC2, FC3, FC4, FC5, FC6, C1, C2, C3, C4, C5, C6, CP1, CP2, CP3, CP4, CP5, CP6) teta bandında %100, Turku veri setinde teta bandı altı sensorimotor kanal CatBoost ile %85 sınıflandırma doğruluk sonucu ile kendi içinde en yüksek sonuçlara ulaşılmıştır.
5. Bu çalışmada EEG verisi spektral özniteliklerinden beş yeni öznitelik önerilmiştir.
6. EEG spektral özniteliklerinden wSMI öznitelikleri ilk defa PH teşhisinde kullanılmıştır.
7. Dinlenme durumu EEG verisinden elde edilen KAC ve SE öznitelikleri ilk defa PH teşhisinde kullanılmıştır.
8. Literatürde PH'de ilk kez EEG verisi, ses verisine dönüştürülerek, kroma tabanlı müzik öznitelikleri çıkarılarak sınıflandırma yapılmıştır.

9. Ses verisi üzerinden kroma tabanlı müzik öznitelikleri ile Iova'da CatBoost ile %96.67, San Diego'da CatBoost ile %90.83, Turku'da CatBoost ile %87.50 doğruluk sonucu elde edilmiştir.

10. Literatürde PH'de, DWPT ilk kez uygulanmıştır.

11. CatBoost algoritmasının genel olarak diğer kullanılan makine öğrenme yöntemlerine göre hem kısa hesaplama süresi hem de analiz sonucu olarak yüksek doğruluk verdiği görülmektedir.

12. Bu çalışma sonucunda Iova ve Turku veri setlerinde hem EEG hem de ses üzerinden literatürdekinden daha yüksek doğruluk sonuçları elde edilmiştir.

Geliştirilen sınıflandırma modelleriyle EEG verilerinden PH'yi tespit etmek için umut verici bir yaklaşım sunulmuştur. Bu model sayesinde nörologlar PH'yi erken evrelerinde daha doğru ve etkili bir şekilde tespit edebilirler. Gelecekte, Teletıp, Bulut ve Nesnelerin İnterneti (IoT) bilişim teknolojisindeki ilerlemelerle, bu yaklaşımın PH'nin önlenmesi ve tespiti için gerçek zamanlı bir akıllı sağlık izleme yöntemi olarak geliştirilebileceği açıktır. Araştırma, gelişmiş bir EEG cihazı ile birkaç veya tek elektrot aracılığıyla EEG sinyallerini tespit edebilir ve bu kayıtları uzaktaki nörologlara ileterek hastaların uzaktan sağlık takibini sağlayabilir. Bununla birlikte, AH, epilepsi, otizm, şizofreni vb. dahil olmak üzere diğer hastalıkları tespit etmek için de kullanılabilir.

Çalışmanın daha geniş kitleler üzerinden veri alınarak denenmesi ve aynı zamanda ulusal veri seti oluşturulmasına katkı sağlanması ileriki çalışmalar için önerilebilir. Yeni çıkan sınıflandırma algoritmaları ve öznitelik yöntemlerinin denenmesi bundan sonraki araştırmacılar için önerilebilir. Bu çalışma sonucunda kazanılan deneyim sayesinde ulusal anlamda PH araştırma ortaklıkları kurulabilir.

7. KAYNAKLAR

1. Parkinson's UK (2023). What is Parkinson's. <http://www.parkinsons.org.uk/about-parkinsons/what-is-parkinsons.aspx>. [Eriřim tarihi 9 Aralık 2023].
2. Parkinson's Foundation (2023). Statistics. <https://www.parkinson.org/understanding-parkinsons/statistics>. [Eriřim tarihi 9 Aralık 2023].
3. Acıbadem (2021). Parkinson Hastalığı. <https://www.acibadem.com.tr/ilgi-alani/parkinson-hastaligi/>. [Eriřim tarihi 9 Aralık 2023].
4. Braak H, Del Tredici K, Bratzke H, Hamm-Clement J, Sandmann-Keil D, Rüb U (2002). Staging of the intracerebral inclusion body pathology associated with idiopathic Parkinson's disease (preclinical and clinical stages). *Journal of neurology* 249: 1-5.
5. Maitin AM, Garcia Tejedor AJ, Munoz JPR (2020). Machine Learning Approaches for Detecting Parkinson's Disease from EEG Analysis: A Systematic Review. *Applied Sciences* 10(23): 8662.
6. Maitin AM, Romero Munoz JP, Garcia Tejedor AJ (2022). Survey of machine learning techniques in the analysis of EEG signals for Parkinson's disease: A systematic review. *Applied Sciences* 12(14): 6967.
7. World Health Organization (2022). <https://www.who.int/news/item/14-06-2022-launch-of-who-s-parkinson-disease-technical-brief>. [Eriřim tarihi 9 Aralık 2023].
8. Parkinson J (2002). An essay on the shaking palsy. *The Journal of Neuropsychiatry and Clinical Neurosciences* 14: 223-36.
9. Parkinson J (1817). *Essay on the shaking palsy* London: Sherwood, Nealy and Jones.
10. Wirdefeldt K, Adami HO, Cole P, Trichopoulos D, Mandel J (2011). Epidemiology and etiology of Parkinson's disease: a review of the evidence. *European journal of epidemiology* 26: 1-58.
11. Pringsheim TM, Jette N, Frolkis A, Steeves TDL (2014). The incidence of Parkinson's disease: A systematic review and meta-analysis of studies from 2001 to 2011. *Movement Disord* 29: 548-548.

12. Pringsheim T, Jette N, Frolkis A, Steeves TD (2014). The prevalence of Parkinson's disease: a systematic review and meta-analysis. *Movement disorders* 29(13): 1583-1590.
13. Khan NL, Thomas B (2004). Parkinson's disease clinical features, pathophysiology and genetics. *Hospital Pharmacist* 11: 9-15.
14. De Lau LM, Breteler MM (2006). Epidemiology of Parkinson's disease. *The Lancet Neurology* 5(6): 525-535.
15. Jankovic J (2007). Pathophysiology and assessment of parkinsonian symptoms and signs. In: Pahwa R, Lyons K, Koller WC, eds. 3. Baskı. *Handbook of Parkinson's disease*. Taylor and Francis Group LLC, New York 79-104.
16. Mahlknecht P, Krismer F, Poewe W, Seppi K (2017). Meta-analysis of dorsolateral nigral hyperintensity on magnetic resonance imaging as a marker for Parkinson's disease. *Movement Disorders* 32(4): 619-623.
17. Kalia LV, Lang AE (2015). Parkinson's Disease. *Lancet* 386: 896-912.
18. Jankovic J (2005). Progression of Parkinson disease: are we making progress in charting the course?. *Archives of neurology* 62(3): 351-352.
19. Beitz JM (2014). Parkinson's disease: a review. *Frontiers in bioscience (Scholar edition)* 6: 65-74.
20. RD A (1997). Victor M, Ropper AH. *Principles of neurology*. New York: McGraw Hill 1: 128-1129.
21. Koller WC (1984). Sensory symptoms in Parkinson's disease. *Neurology* 34(7): 957-957.
22. Bromberg MB (2003). Consensus. *Supplements to Clinical Neurophysiology* 55(40): 335-338.
23. Ozansoy M, Başak AN (2004). Parkinson hastalığının genetiği ve nörodejenerasyonun moleküler biyolojisi. *Parkinson Hastalığı Hareket Bozuklukları Dergisi* 7: 109-120.
24. Waters CH (2000). *Parkinson Hastalığının Tanısı ve Tedavisi*. Çev: Büyükkal B, Turgut yayıncılık ve Tic. A.Ş. İstanbul.

25. Tarsy D (2005). Diagnostic criteria for Parkinson's Disease. *Parkinson's Disease*. Taylor and Francis Boks. Florida, 569-576.
26. Uitti RJ, Baba Y, Wszolek ZK, Putzke DJ (2005). Defining the Parkinson's disease phenotype: initial symptoms and baseline characteristics in a clinical cohort. *Parkinsonism and related disorders* 11(3): 139-145.
27. Nagatsu T, Sawada M (2005). Inflammatory process in Parkinson's disease: role for cytokines. *Current pharmaceutical design* 11(8): 999-1016.
28. Hirsch EC, Hunot S (2009). Neuroinflammation in Parkinson's disease: a target for neuroprotection?. *The Lancet Neurology* 8(4): 382-397.
29. Martin WE, Loewenson RB, Resch JA, Baker AB (1973). Parkinson's disease: Clinical analysis of 100 patients. *Neurology* 23(8): 783-783.
30. Hughes AJ, Daniel SE, Blankson S (1993). Sdney Multicenter Study of Parkinson's disease. *Arch Neurol* 50: 140-148.
31. Hughes AJ, Daniel SE, Kilford L, Lees AJ (1992). Accuracy of clinical diagnosis of idiopathic Parkinson's disease: a clinico-pathological study of 100 cases. *Journal of neurology, neurosurgery and psychiatry* 55(3): 181-184.
32. Dewey JR, RB (2000). Clinical features of Parkinson's disease. In *Parkinson's disease and movement disorders: Diagnosis and treatment guidelines for the practicing physician*. NJ: Humana Press, Totowa 71-84.
33. Shahed J, Jankovic J (2007). Motor symptoms in Parkinson's disease. *Handbook of clinical neurology* 83: 329-342.
34. Paulson HL, Stern MB (2004). Clinical manifestations of parkinson's disease. Ed: Watts RL, Koller WC *Movement Disorders Neurologic Principles and Practice* 14: 233-245.
35. Kızıltan G (2008). Parkinson Hastalığının Harekete İlişkin Belirti ve Bulguları. *Türkiye Klinikleri J Neural-Special Topics* 1(4): 23-30.
36. Shahed J, Jankovic J (2007). Motor symptoms in Parkinson's disease. *Handbook of clinical neurology* 83: 329-342.

37. Ross GW, Petrovitch H, Abbott RD, Nelson J, Markesbery W, Davis D, White LR (2004). Parkinsonian signs and substantia nigra neuron density in decedents elders without PD. *Annals of Neurology: Official Journal of the American Neurological Association and the Child Neurology Society* 56(4): 532-539.
38. Raming LA, Gould WJ (1986). Speech characteristic in Parkinson's disease. *Neurol Consult* 4: 1-8.
39. Broussolle E, Krack P, Thobois S, Xie-Brustolin J, Pollak P, Goetz CG (2007). Contribution of Jules Froment to the study of parkinsonian rigidity. *Movement disorders* 22(7): 909-914.
40. Çakmur R (2003). Parkinson hastalığının epidemiyolojisi ve klinik özellikleri. *Türkiye klinikleri Nöroloji Dergisi* 1(3): 15-17.
41. Jankovic J (2003). Pathophysiology and clinical assessment of parkinsonian symptoms and signs. *Neurological disease and therapy* 59: 71-108.
42. Hoehn MM, Yahr MD (1967). Parkinsonism: onset, progression, and mortality. *Neurology* 17(5): 427-427.
43. Apaydın H (1999). Alfa-Sinüklein hastalıkları. *Parkinson Hastalığı ve Hareket bozuklukları dergisi* 2(1): 23-30.
44. Braak H, Del Tredici K, Rüb U, De Vos RA, Steur ENJ, Braak E (2003). Staging of brain pathology related to sporadic Parkinson's disease. *Neurobiology of aging* 24(2): 197-211.
45. Poewe W (2007). Dysautonomia and cognitive dysfunction in Parkinson's disease. *Movement disorders: official journal of the Movement Disorder Society* 22(17): 374-378.
46. Hou JGG, Lai EC (2007). Non-motor symptoms of Parkinson's disease. *International Journal of Gerontology* 1(2): 53-64.
47. Weiner WJ, Shulman LM, Lang AE (2013). *Parkinson's disease: A complete guide for patients and families*. JHU Press.
48. Tran J, Anastacio H, Bardy C (2020). Genetic predispositions of Parkinson's disease revealed in patient-derived brain cells. *NPJ Parkinson's disease* 6(1): 8.

49. Liou HH, Tsai MC, Chen CJ, Jeng JS, Chang YC, Chen SY, Chen RC (1997). Environmental risk factors and Parkinson's disease: a case-control study in Taiwan. *Neurology* 48(6): 1583-1588.
50. Pınar L (2010). Sinir ve Kas Fizyolojisi Temel Bilgileri. (Yedinci Baskı). Türkiye: Ankara, Efil Yayınevi, 13-33.
51. Sung VW, Nicholas AP (2013). Nonmotor symptoms in Parkinson's disease: expanding the view of Parkinson's disease beyond a pure motor, pure dopaminergic problem. *Neurologic Clinics* 31(3): 1-16.
52. Dudman JT, Krakauer JW (2016). The basal ganglia: from motor commands to the control of vigor. *Current Opinion in Neurobiology* 37: 158-166.
53. Danafoundation(2023).BasalGangliaAnatomy.<http://www.dana.org/news/brainwork/detail.aspx?id=6028>. [Erişim tarihi 9 Aralık 2023].
54. Bhidayasiri R, Martinez-Martin P (2017). Clinical assessments in Parkinson's disease: scales and monitoring. *International review of neurobiology* 132: 129-182.
55. Ramdhani RA, Khojandi A, Shylo O, Kopell BH (2018). Optimizing clinical assessments in Parkinson's disease through the use of wearable sensors and data driven modeling. *Frontiers in computational neuroscience* 12: 72.
56. Leung H, Mok V (2005). Parkinson's disease: aetiology, diagnosis, and management. *Hong Kong Medical Journal* 11(6): 476.
57. Hoehn MM, Yahr MD (1967). Parkinsonism: onset, progression, and mortality. *Neurology* 17(5): 427-427.
58. Movement Disorder Society Task Force on Rating Scales for Parkinson's Disease (2003). The unified Parkinson's disease rating scale (UPDRS): status and recommendations. *Movement Disorders* 18(7): 738-750.
59. Selekler K, Cangöz B, Uluç S (2010). Montreal bilişsel değerlendirme ölçeği (MOBİD)'nin hafif bilişsel bozukluk ve alzheimer hastalarını ayırt edebilme gücünün incelenmesi. *Türk Geriatri Dergisi* 13(3): 166-171.
60. Sivaranjini S, Sujatha CM (2020). Deep learning based diagnosis of Parkinson's disease using convolutional neural network. *Multimedia tools and applications* 79: 15467-15479.

61. Zhang J (2022). Mining imaging and clinical data with machine learning approaches for the diagnosis and early detection of Parkinson's disease. *NPJ Parkinson's disease* 8(1): 13.
62. Mabrouk R, Chikhaoui B, Bentabet L (2018). Machine learning based classification using clinical and DaTSCAN SPECT imaging features: A study on Parkinson's disease and SWEDD. *IEEE Transactions on Radiation and Plasma Medical Sciences* 3(2): 170-177.
63. Shiiba T, Arimura Y, Nagano M, Takahashi T, Takaki A (2020). Improvement of classification performance of Parkinson's disease using shape features for machine learning on dopamine transporter single photon emission computed tomography. *PLoS One* 15(1): e0228289.
64. Lin CH, Li CH, Yang KC, Lin FJ, Wu CC, Chieh JJ, Chiu MJ (2019). Blood NfL: a biomarker for disease severity and progression in Parkinson disease. *Neurology* 93(11): e1104-e1111.
65. Kim R, Kim HJ, Kim A, Jang M, Kim A, Kim Y, Jeon B (2018). Peripheral blood inflammatory markers in early Parkinson's disease. *Journal of Clinical Neuroscience* 58: 30-33.
66. Merck Manual (Professional Version) (2023). Secondary and Atypical Parkinsonism. <https://www.merckmanuals.com/professional/neurologic-disorders/movement-and-cerebellar-disorders/secondary-and-atypical-parkinsonism?query=secondary%20and%20atypical%20parkinsonism>. [Erişim tarihi 9 Aralık 2023].
67. El Sayed ESK, Eissa A, Nofal S, Elmorsy E (2018). Parkinson's Disease: A Review about Pathogenesis, Treatment and Experimental Models. *Journal of Advanced Pharmacy Research* 2(3): 142-161.
68. Olanow CW, Brin MF, Obeso JA (2000). The role of deep brain stimulation as a surgical treatment for Parkinson's disease. *Neurology* 55(12 Suppl 6): 60-6.
69. Benabid AL (2003). Deep brain stimulation for Parkinson's disease. *Current opinion in neurobiology* 13(6): 696-706.

70. Berg D (2007). Ultrasound in the (premotor) diagnosis of Parkinson's disease. *Parkinsonism and related disorders* 13: 429-433.
71. Teplan M (2002). Fundamentals of EEG measurement. *Measurement science review* 2(2): 1-11.
72. Gursel Ozmen N (2010). Beyin Bilgisayar Arayüzü Tasarımı için Farklı Zihinsel Aktiviteler Esnasında Oluşan EEG İşaretlerinin Analiz Edilmesi ve Sınıflandırılması. Doktora tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon
73. Sanei S, Chambers JA (2013). EEG signal processing. John Wiley and Sons
74. Abhang PA, Gawali BW, Mehrotra SC (2016). Technological basics of EEG recording and operation of apparatus. *Introduction to EEG-and Speech-Based Emotion Recognition*, 19-50.
75. Gazzaniga MS (1994). Cognitive electrophysiology. Springer Science, Business Media. United States of America
76. Gastaut HJ, Bert J (1954). EEG changes during cinematographic presentation (Moving picture activation of the EEG). *Electroencephalography and clinical neurophysiology* 6: 433-444.
77. Steriade M, Amzica F, Contreras D (1996). Synchronization of fast (30-40 Hz) spontaneous cortical rhythms during brain activation. *Journal of Neuroscience* 16(1): 392-417.
78. Fisch BJ (1998). Spehlmann'ın EEG el kitabı. Turgut Yayıncılık ve Ticaret AŞ., İstanbul
79. Babiloni C, Del Percio C, Lizio R, Noce G, Cordone S, Lopez S, De Pandis MF (2017). Abnormalities of cortical neural synchronization mechanisms in subjects with mild cognitive impairment due to Alzheimer's and Parkinson's diseases: an EEG study. *Journal of Alzheimer's Disease* 59(1): 339-358.
80. Babiloni C, Lizio R, Marzano N, Capotosto P, Soricelli A, Triggiani AI, Del Percio C (2016). Brain neural synchronization and functional coupling in Alzheimer's disease as revealed by resting state EEG rhythms. *International Journal of Psychophysiology* 103: 88-102.

81. Railo H, Suuronen I, Kaasinen V, Murtojarvi M, Pahikkala T, Airola A (2020). Resting state EEG as a biomarker of Parkinson's disease: Influence of measurement conditions. *BioRxiv* 2020-05.
82. Merck Manual (Professional Version) 2023. Parkinson Disease. <https://www.merckmanuals.com/professional/neurologic-disorders/movement-and-cerebellar-disorders/parkinson-disease>. [Erişim tarihi 9 Aralık 2023].
83. Singh K, Malhotra J (2021). Deep learning based smart health monitoring for automated prediction of epileptic seizures using spectral analysis of scalp EEG. *Physical and engineering sciences in medicine* 44(4): 1161-1173.
84. Krishnan S, Athavale Y (2018). Trends in biomedical signal feature extraction. *Biomedical Signal Processing and Control* 43: 41-63.
85. Borowska M (2015). Entropy-based algorithms in the analysis of biomedical signals. *Studies in Logic, Grammar and Rhetoric* 43(1): 21-32.
86. Yi GS, Wang J, Deng B, Wei XL (2017). Complexity of resting-state EEG activity in the patients with early-stage Parkinson's disease. *Cognitive Neurodynamics* 11: 147-160.
87. Klimesch W (1999). EEG alpha and theta oscillations reflect cognitive and memory performance: a review and analysis. *Brain research reviews* 29(2-3): 169-195.
88. Wang Q, Meng L, Pang J, Zhu X, Ming D (2020). Characterization of EEG data revealing relationships with cognitive and motor symptoms in Parkinson's disease: a systematic review. *Frontiers in Aging Neuroscience* 12: 587396.
89. De Hemptinne C, Ryapolova-Webb ES, Air EL, Garcia PA, Miller KJ, Ojemann JG, Starr PA (2013). Exaggerated phase–amplitude coupling in the primary motor cortex in Parkinson disease. *Proceedings of the National Academy of Sciences* 110(12): 4780-4785.
90. Swann NC, de Hemptinne C, Aron AR, Ostrem JL, Knight RT, and Starr PA (2015). Elevated synchrony in Parkinson disease detected with electroencephalography. *Annals of Neurology* 78(5): 742-750.

91. Soikkeli R, Partanen J, Soininen H, Paakkönen A, Riekkinen Sr P (1991). Slowing of EEG in Parkinson's disease. *Electroencephalography and Clinical Neurophysiology* 79(3): 159-165.
92. Neufeld MY, Blumen S, Aitkin I, Parmet Y, Korczyn AD (1994). EEG frequency analysis in demented and nondemented parkinsonian patients. *Dementia and Geriatric Cognitive Disorders* 5(1): 23-28.
93. Pezard L, Jech R, Ruzicka E (2001). Investigation of non-linear properties of multichannel EEG in the early stages of Parkinson's disease. *Clinical Neurophysiology* 112(1): 38-45.
94. Bosboom JLW, Stoffers D, Stam CJ, Van Dijk BW, Verbunt J, Berendse HW, and Wolters EC (2006). Resting state oscillatory brain dynamics in Parkinson's disease: an MEG study. *Clinical Neurophysiology* 117(11): 2521-2531.
95. Mei J, Desrosiers C, Frasnelli J (2021). Machine learning for the diagnosis of Parkinson's disease: a review of literature. *Frontiers in Aging Neuroscience* 13: 633752.
96. Singh A, Richardson SP, Narayanan N, Cavanagh JF (2018). Mid-frontal theta activity is diminished during cognitive control in Parkinson's disease. *Neuropsychologia* 117: 113-122.
97. Cavanagh JF, Kumar P, Mueller AA, Richardson SP, and Mueen A (2018). Diminished EEG habituation to novel events effectively classifies Parkinson's patients. *Clinical Neurophysiology* 129(2): 409-418.
98. Koch M, Geraedts V, Wang H, Tannemaat M, Back T (2019). Automated Machine Learning for EEG-Based Classification of Parkinson's Disease Patients. In 2019 IEEE International Conference on Big Data(Big Data) 4845-4852. IEEE.
99. Betrouni N, Delval A, Chaton L, Defebvre L, Duits A, Moonen A, Dujardin K (2019). Electroencephalography-based machine learning for cognitive profiling in Parkinson's disease: Preliminary results. *Movement Disorders* 34(2): 210-217.
100. Boon LI, Hillebrand A, Potters WV, de Bie RM, Prent N, Bot M, Berendse HW (2020). Motor effects of deep brain stimulation correlate with increased functional

connectivity in Parkinson's disease: An MEG study. *NeuroImage: Clinical* 26: 102225.

101. Channa A, Cramariuc O, Memon M, Popescu N, Mammone N, Ruggeri G (2022). Parkinson's disease resting tremor severity classification using machine learning with resampling techniques. *Frontiers in Neuroscience* 16: 955464.
102. Güntekin B, Hanoğlu L, Güner D, Yılmaz NH, Çadırcı F, Mantar N, Başar E (2018). Cognitive impairment in Parkinson's disease is reflected with gradual decrease of EEG delta responses during auditory discrimination. *Frontiers in psychology* 9: 170.
103. Maharramova A (2019). Kognitif bozukluğu olmayan Parkinson hastalığı olgularında boylamsal istirahat EEG incelemesi. Uzmanlık tezi, Dokuz Eylül Üniversitesi Tıp Fakültesi, Nöroloji Anabilim Dalı, İzmir
104. Mantar N (2016). Kognitif bozukluğu olan ve olmayan Parkinson hastalarında alfa ve beta EEG osilasyonlarının incelenmesi. Yüksek lisans tezi, İstanbul Medipol Üniversitesi Sağlık Bilimleri Enstitüsü, Sinirbilim Anabilim Dalı, İstanbul
105. Çadırcı F (2016). Parkinson hastalığında bilişsel bozulmanın seyrinde görsel algısal işlevler ve olaya ilişkin EEG koherans analizi ile ilişkisi. Yüksek lisans tezi, İstanbul Medipol Üniversitesi Sağlık Bilimleri Enstitüsü, Sinirbilim Anabilim Dalı, İstanbul
106. Chaturvedi M, Hatz F, Gschwandtner U, Bogaarts JG, Meyer A, Fuhr P, Roth V (2017). Quantitative EEG (QEEG) measures differentiate Parkinson's disease (PD) patients from healthy controls (HC). *Frontiers in Aging Neuroscience* 9: 3.
107. Ly QT, Handojoseno AA, Gilat M, Chai R, Martens KAE, Georgiades M, Nguyen HT (2017). Detection of turning freeze in Parkinson's disease based on S-transform decomposition of EEG signals. In 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) 3044-3047. IEEE.
108. Yuvaraj R, Rajendra Acharya U, Hagiwara Y (2018). A novel Parkinson's Disease Diagnosis Index using higher-order spectra features in EEG signals. *Neural Computing and Applications* 30: 1225-1235
109. Betrouni N, Delval A, Chaton L, Defebvre L, Duits A, Moonen A, Dujardin K (2019). Electroencephalography-based machine learning for cognitive profiling in Parkinson's disease: Preliminary results. *Movement Disorders* 34(2): 210-217.

110. Anjum MF, Dasgupta S, Mudumbai R, Singh A, Cavanagh JF, Narayanan NS (2020). Linear predictive coding distinguishes spectral EEG features of Parkinson's disease. *Parkinsonism and Related Disorders* 79: 79-85.
111. De Oliveira APS, de Santana MA, Andrade MKS, Gomes JC, Rodrigues MC, dos Santos WP (2020). Early diagnosis of Parkinson's disease using EEG, machine learning and partial directed coherence. *Research on Biomedical Engineering* 36(3): 311-331.
112. Khare SK, Bajaj V, Acharya UR (2021). Detection of Parkinson's disease using automated tunable Q wavelet transform technique with EEG signals. *Biocybernetics and Biomedical Engineering* 41(2): 679-689.
113. Khare SK, Bajaj V, Acharya UR (2021). PDCNNNet: An automatic framework for the detection of Parkinson's disease using EEG signals. *IEEE Sensors Journal* 21(15): 17017-17024.
114. Loh HW, Ooi CP, Palmer E, Barua PD, Dogan S, Tuncer T, Acharya UR (2021). GaborPDNet: Gabor transformation and deep neural network for Parkinson's disease detection using EEG signals. *Electronics* 10(14): 1740.
115. Barua PD, Dogan S, Tuncer T, Baygin M, Acharya UR (2021). Novel automated PD detection system using aspirin pattern with EEG signals. *Computers in Biology and Medicine* 137: 104841.
116. Lee SB, Kim YJ, Hwang S, Son H, Lee SK, Park KI, Kim YG (2022). Predicting Parkinson's disease using gradient boosting decision tree models with electroencephalography signals. *Parkinsonism and Related Disorders* 95: 77-85.
117. Aljalal M, Aldosari SA, AlSharabi K, Abdurraqueeb AM, Alturki FA (2022). Parkinson's disease detection from resting-state EEG signals using common spatial pattern, entropy, and machine learning techniques. *Diagnostics* 12(5): 1033.
118. Shaban M, Amara AW (2022). Resting-state electroencephalography based deep-learning for the detection of Parkinson's disease. *Plos one* 17(2): e0263159.
119. Suuronen I, Airola A, Pahikkala T, Murtojarvi M, Kaasinen V, Railo H (2023). Budget-based classification of Parkinson's disease from resting-state EEG. *IEEE Journal of Biomedical and Health Informatics*.

120. Göker H (2023). Automatic detection of Parkinson's disease from power spectral density of electroencephalography (EEG) signals using deep learning model. *Physical and Engineering Sciences in Medicine* 1-12.
121. Karakaş MF, Latifoğlu F (2023). Distinguishing Parkinson's Disease with GLCM Features from the Hankelization of EEG Signals. *Diagnostics* 13(10): 1769.
122. Chawla P, Rana SB, Kaur H, Singh K, Yuvaraj R, Murugappan M (2023). A decision support system for automated diagnosis of Parkinson's disease from EEG using FAWT and entropy features. *Biomedical Signal Processing and Control* 79: 104116.
123. Oh SL, Hagiwara Y, Raghavendra U, Yuvaraj R, Arunkumar N, Murugappan M, Acharya UR (2020). A deep learning approach for Parkinson's disease diagnosis from EEG signals. *Neural Computing and Applications* 32: 10927-10933.
124. Qiu L, Li J, Pan J (2022). Parkinson's disease detection based on multi-pattern analysis and multi-scale convolutional neural networks. *Frontiers in Neuroscience* 16: 957181.
125. Akar SA, Kara S, Latifoğlu F, Bilgiç V (2016). Analysis of the complexity measures in the EEG of schizophrenia patients. *International Journal of Neural Systems* 26(02): 1650008.
126. Vicnesh J, Hagiwara Y (2019). Accurate detection of seizure using nonlinear parameters extracted from EEG signals. *Journal of Mechanics in Medicine and Biology* 19(01): 1940004.
127. KN R, Subramaniam K (2018). Analysis of Emotional States in Parkinson's Disease using Entropy, Energy-Entropy and Teager Energy-Entropy Features. *Indian Journal of Public Health Research and Development* 9(10).
128. Imperatori LS, Cataldi J, Betta M, Ricciardi E, Ince RA, Siclari F, Bernardi G (2021). Cross-participant prediction of vigilance stages through the combined use of wPLI and wSMI EEG functional connectivity metrics. *Sleep* 44(5): 247.
129. Rockhill AP, Jackson N, George J, Aron A, Swann NC (2021). UC San Diego Resting State EEG Data from Patients with Parkinson's Disease. *OpenNeuro*. doi, 10.

130. Railo H, Suuronen I, Kaasinen V, Murtojarvi M, Pahikkala T, Airola A (2020). Resting state EEG as a biomarker of Parkinson's disease: Influence of measurement conditions. *BioRxiv* 2020-05.
131. Da Silva FL (1999). EEG analysis: theory and practice. *Electroencephalography: basic principles, clinical applications and related fields*: 1125-1159.
132. Maurer K, Dierks T (2012). *Atlas of brain mapping: topographic mapping of EEG and evoked potentials*. Springer Science and Business Media.
133. Davis WA, Agarwal K (2003). *Radio frequency circuit design*. John Wiley and Sons.
134. Lacanette K (1991). Find filter settling time with ease. *Electronic design* 39(12): 101-102.
135. Siemens(2023).IntroductiontoFilters.<https://community.sw.siemens.com/s/article/introduction-to-filters-fir-versus-iir>. [Erişim tarihi 9 Aralık 2023].
136. Singh K, Malhotra J (2021). Deep learning based smart health monitoring for automated prediction of epileptic seizures using spectral analysis of scalp EEG. *Physical and engineering sciences in medicine* 44(4): 1161-1173.
137. Krishnan S, Athavale Y (2018). Trends in biomedical signal feature extraction. *Biomedical Signal Processing and Control* 43: 41-63.
138. Borowska M (2015). Entropy-based algorithms in the analysis of biomedical signals. *Studies in Logic, Grammar and Rhetoric* 43(1): 21-32.
139. Semmlow JL (2004). *Biosignal and Biomedical Matlab-Based Applications*. Marcel Dekker, New Jersey
140. Proakis JG, Rader CM, Ling F (1992). CL Nikias *Advanced Digital Signal Processing*.
141. Kolmogorov Karmaşıklığı(2023).Kolmogorovcomplexity.https://en.wikipedia.org/wiki/Kolmogorov_complexity. [Erişim tarihi 9 Aralık 2023].
142. Kolmogorov AN (1965). Three approaches to the quantitative definition of information. *Problems of information transmission* 1(1): 1-7.
143. Solomonoff RJ (1964). A formal theory of inductive inference. Part I. *Information and control* 7(1): 1-22.

144. Solomonoff RJ (1964). A formal theory of inductive inference. Part II. Information and control 7(2): 224-254.
145. Chaitin GJ (1969). On the length of programs for computing finite binary sequences: statistical considerations. Journal of the ACM (JACM) 16(1): 145-159.
146. Helakari H, Kananen J, Huotari N, Raitamaa L, Tuovinen T, Borchardt V, Ansakorpi H (2019). Spectral entropy indicates electrophysiological and hemodynamic changes in drug-resistant epilepsy–A multimodal MREG study. NeuroImage: Clinical 22: 101763.
147. Vakkuri A, Yli-Hankala A, Talja P, Mustola S, Tolvanen-Laakso H, Sampson T, Viertio-Oja H (2004). Time-frequency balanced spectral entropy as a measure of anesthetic drug effect in central nervous system during sevoflurane, propofol, and thiopental anesthesia. Acta Anaesthesiologica Scandinavica 48(2): 145-153.
148. Sitt JD, King JR, El Karoui I, Rohaut B, Faugeras F, Gramfort A, Naccache L (2014). Large scale screening of neural signatures of consciousness in patients in a vegetative or minimally conscious state. Brain 137(8): 2258-2270.
149. Github (2023). EEG-Sound-Synthesis. https://github.com/emergnce/EEG-Sound-Synthesis/blob/main/eeg_sound_synthesis_code.py. [Erişim tarihi 9 Aralık 2023].
150. Müller M. (2015). Fundamentals of music processing: Audio, analysis, algorithms, applications (Vol. 5). Springer, Cham
151. Wikipedia(2023).Waveletpacketdecomposition.https://en.wikipedia.org/wiki/Wavelet_packet_decomposition. [Erişim tarihi 9 Aralık 2023].
152. Wikipedia (2023). Chroma. <https://en.wikipedia.org/wiki/Chroma>. [Erişim tarihi 9 Aralık 2023].
153. Randall RB (1987). Frequency analysis. Naerum (DK): Bruel and Kjaer. [Erişim tarihi 9 Aralık 2023].
154. Wikipedia(2023).Chromafeature.https://en.wikipedia.org/wiki/Chroma_feature. [Erişim tarihi 9 Aralık 2023].
155. Wikipedia(2023).Harmonicpitchclassprofiles.https://en.wikipedia.org/wiki/Harmonic_pitch_class_profiles. [Erişim tarihi 9 Aralık 2023].

156. Medium(2023).MusicInformationRetrieval. 2/music-information-retrieval-8a3facacf88e. [Erişim tarihi 9 Aralık 2023].
157. Blankertz B (2001). The constant Q transform. URL [http://doc. ml. tu-berlin. de/bbci/material/publications/Bla_constQ. pdf](http://doc.ml.tu-berlin.de/bbci/material/publications/Bla_constQ.pdf).
158. Wikipedia(2023).ConstantQtransform.https://en.wikipedia.org/wiki/Constant-Q_transform. [Erişim tarihi 9 Aralık 2023].
159. Lison P (2015). An introduction to machine learning, Language Technology Group (LTG) 1: 35.
160. Alpaydın, E (2011). Introduction of machine learning second edition. The MIT Press, USA
161. Prokhorenkova L, Gusev G, Vorobev A, Dorogush AV, Gulin A (2018). CatBoost: unbiased boosting with categorical features. Advances in neural information processing systems 31.
162. Chen T, Guestrin C (2016). Xgboost: A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining 785-794.
163. Towardsdatascience(2022).XGBoostAlgorithm.<https://towardsdatascience.com/https-medium-com-vishalorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d>. [Erişim tarihi 9 Aralık 2023].
164. Wikipedia (2023). K-nearest neighbors algorithm. https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm. [Erişim tarihi 9 Aralık 2023].
165. Wikipedia(2023).Gradientboosting.https://en.wikipedia.org/wiki/Gradient_boosting#:~:text=Gradient%20boosting%20is%20a%20machine,are%20typically%20simple%20decision%20trees. [Erişim tarihi 9 Aralık 2023].
166. Vapnik V (2013). The nature of statistical learning theory. Springer science and business media.
167. Burges CJ (1998). A tutorial on support vector machines for pattern recognition. Data mining and knowledge discovery 2(2): 121-167.

168. Kotsiantis SB (2007). Supervised Machine Learning: A Review of Classification Techniques. IOS Press, Amsterdam : 3-24
169. Fletcher T (2009). Support vector machines explained. Tutorial paper 1-19.
170. Menard SW (2010). Logistic regression: From introductory to advanced concepts and applications. Sage.
171. Kleinbaum GD (1994). A Self-learning Text Logistic Regression. Springer, Atlanta
172. Utgoff PE (1998). Decision trees. University of Massachusetts, Amherst: 1-4.
173. Taşkın GGEVÇ (2005). Veri madenciliğinde karar ağaçları ve bir satış analizi uygulaması. Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi 6(2): 221-239.
174. Ross Quinlan J (1993). C4. 5: programs for machine learning. Mach. Learn 16(3): 235-240.
175. Genuer R, Poggi JM, Genuer R, Poggi JM (2020). Random forests (pp. 33-55). Springer International Publishing, USA
176. LeCun Y, Bengio Y, Hinton G (2015). Deep learning. nature 521(7553): 436-444.
177. Chollet F (2021). Deep learning with Python. Simon and Schuster, USA
178. Charu CA (2018). Neural networks and deep learning: a textbook. Springer, New York
179. Goodfellow I, Bengio Y, Courville A (2016). Deep learning. MIT press, USA
180. Patterson J, Gibson A (2017). Deep learning: A practitioner's approach. O'Reilly Media Inc, USA
181. Alpar R (2018). Uygulamalı istatistik ve geçerlilik güvenirlik: Spor, sağlık ve eğitim bilimlerinden örneklerle. Detay Yayıncılık, Ankara
182. Gürsakal N (2018). Makine Öğrenmesi. Dora, Bursa
183. Persidis A, Persidis A (1991). Medical Expert Systems: An Overview. Journal of Management in Medicine 5(3): 27-34.

184. Sim I, Gorman P, Greenes RA, Haynes RB, Kaplan B, Lehmann H, Tang PC (2001). Clinical decision support systems for the practice of evidence-based medicine. *Journal of the American Medical Informatics Association* 8(6): 527-534.
185. Osheroff JA, Teich JM, Middleton B, Steen EB, Wright A, Detmer DE (2007). A roadmap for national action on clinical decision support. *Journal of the American medical informatics association* 14(2): 141-145.
186. Shortliffe EH (1987). Computer programs to support clinical decision making. *Jama* 258(1): 61-66.
187. Smrdel A (2022). Use of common spatial patterns for early detection of Parkinson's disease. *Scientific Reports* 12(1): 18793.
188. Chang KH, French IT, Liang WK, Lo YS, Wang YR, Cheng ML, Juan CH (2022). Evaluating the different stages of Parkinson's disease using electroencephalography with Holo-Hilbert spectral analysis. *Frontiers in Aging Neuroscience* 14: 832637.
189. Emek Savaş DD, Özmüş G, Güntekin B, Dönmez Çolakoğlu B, Çakmur R, Başar E, Yener GG (2017). Decrease of delta oscillatory responses in cognitively normal Parkinson's disease. *Clinical EEG and Neuroscience* 48(5): 355-364.
190. Yılmaz NH, Çalışoğlu P, Güntekin B, Hanoğlu L (2020). Correlation between alpha activity and neuropsychometric tests in Parkinson's disease. *Neuroscience Letters* 738: 135346.
191. Gomez C, Olde Dubbelink KT, Stam CJ, Abasolo D, Berendse HW, Hornero R (2011). Complexity analysis of resting-state MEG activity in early-stage Parkinson's disease patients. *Annals of Biomedical Engineering* 39: 2935-2944.
192. Yi GS, Wang J, Deng B, Wei XL (2017). Complexity of resting-state EEG activity in the patients with early-stage Parkinson's disease. *Cognitive Neurodynamics* 11: 147-160.

BİLDİRİLER

1. Turhan K, Baki N, Kurt B, Kılıç A (2017). Koroner Bypass Yapılan Olgularda Postoperatif Dönemde Gelişen Atrial Fibrilasyon Gelişme Riski İçin Karar Ağacı Yöntemi Kullanılarak Bir Tahmin Modeli Önerisi. Tıp Bilişiminde Yenilikler Sempozyumu (pp.10). Ankara, Turkey
2. Baki N, Kılıç A, Turhan K, Özkan E (2017). Koroner Arter Hastalıklarının Tahmininde Kullanılan Risk Faktörlerinde Veri Madenciliği Sınıflandırma Yöntemlerinin Karşılaştırılması. Uluslararası Katılımlı X. Tıp Bilişimi Kongresi (pp.50). Antalya, Turkey.
3. Keskin S, Baki N, Turhan K, Kurt B, Buluk Kuzu M, Keskin DD (2018). Kadınlarda HPV Gelişme Riski İçin Bir Tahmin Model Önerisi. XX. Ulusal ve III. Uluslararası Biyoistatistik Kongresi (pp.30). Gaziantep, Turkey.
4. Baki N, Esnafoğlu E, Turhan K, Gündoğan C (2019). Erken Çocukluk Döneminde Otizm Spektrum Bozukluğu Teşhisine Yönelik bir Tahmin Model Önerisi. 12. Ulusal Tıp Bilişimi Kongresi (pp.28) Ankara, Turkey.
5. Baki N, Keskin S, Gürsel Özmen N (2021). Preeklampsinin Erken Teşhisine Yönelik Bir Tahmin Modeli Önerisi. 13. Tıp Bilişimi Kongresi (pp.159). Çevrimiçi, Turkey.
6. Baki N, Gürsel Özmen N (2022, October). An Early Diagnosis Approach for Parkinson Patients Without Cognitive Disorder from EEG Data. In 2022 Medical Technologies Congress (TIPTEKNO) (pp. 1-4). IEEE.
7. Baki N, Gürsel Özmen N (2023). Analysis of EEG Activity of Parkinson's Disease Patients by Means of Kolmogorov Algorithmic Complexity. 14. Tıp Bilişimi Kongresi (pp.182-187). İzmir, Turkey.