

T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BELİRLİ NÖROPSİKOLOJİK RAHATSIZLIKLARIN YAPAY
ZEKA TEMELLİ SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

FİRUZE DAMLA ERYILMAZ BARAN

DENİZLİ, HAZİRAN - 2024

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**



**BELİRLİ NÖROPSİKOLOJİK RAHATSIZLIKLARIN YAPAY
ZEKA TEMELLİ SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

FİRUZE DAMLA ERYILMAZ BARAN

DENİZLİ, HAZİRAN - 2024

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bilimsel etiğe ve akademik kurallara özenle riayet edildiğini; bu çalışmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etiğe uygun olarak kaynak gösterildiğini ve alıntı yapılan çalışmalara atfedildiğine beyan ederim.

Firuze Damla ERYILMAZ BARAN

ÖZET

**BELİRLİ NÖROPSİKOLOJİK RAHATSIZLIKLARIN YAPAY ZEKA
TEMELLİ SINIFLANDIRILMASI
YÜKSEK LİSANS TEZİ
FİRUZE DAMLA ERYILMAZ BARAN
PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI:DOÇ. DR. MERİÇ ÇETİN)**

DENİZLİ, HAZİRAN - 2024

Yapay Zeka teknolojilerinden medikal alan olmak üzere pek çok alanda yararlanılmaktadır. Bu alanlardan biri de Nöropsikolojik hastalıkların tespiti, teşhisi ve gerekli olması durumunda tedavi edilmesidir. Bu hastalıklar, günlük hayatımızda sıkça karşılaştığımız rahatsızlıklardır. Nöropsikoloji kapsamında pek çok rahatsızlıklar bulunmaktadır. Bu rahatsızlıkların tespit edilememesi durumunda hem bireyin hayati tehlikesi oluşmaktadır hem de çevresi için zorlu bir süreçte sebep olmaktadır. Bu çalışma pek çok nöropsikolojik rahatsızlığı yapay zeka temelli sınıflandıran literatürdeki ilk tez çalışması olma özelliğini bulundurmaktadır. Bu çalışma kapsamında anksiyete bozukluğu, şizofreni bozukluğu, otizm spektrum bozukluğu, depresyon ve demans rahatsızlıklarını içeren beş farklı veri seti kullanılmıştır. Veri setleri üzerinde veri ön işleme, hiperparametre optimizasyonu ile yapay zeka modellerinden faydalanılarak çalışmalar yapılmıştır. Makine öğrenmesi modelleri olarak XGBoost, LightGBM, Rastgele Orman, Destek Vektör Makineleri ve k- En Yakın Komşu kullanılmış ve doğruluk metrikleri üzerinden karşılaştırmalar yapılmıştır. Ayrıca makine öğrenmesi modelleri üzerinde hiperparametre optimizasyonu kullanılarak öncesi ve sonrası karşılaştırmaları da ayrıca yapılmıştır. Veri seti 1 için LightGBM tekniği %96 doğruluk oranı ile en yüksek başarıya sahip iken hiperparametre optimizasyonu sonrasında %97 doğruluk oranı ile SVM öne geçmiş ve en fazla doğruluk oranını vermiştir. Veri seti 3 için %98 doğruluk oranı ile XGBoost ve LightGBM teknikleri başarılı bir sonuç alırken hiperparametre optimizasyonu sonrasında bu oran değişmemiş ve XGBoost en başarılı sonucu vermiştir. Derin öğrenme teknikleri olarak Evrişimsel Sinir Ağları (CNN), Uzun Kısa Süreli Bellek (LSTM) ve Geçitli Yineleme Birimi (GRU) modelleri veri setlerine uygun olarak kurgulanmıştır. Veri seti 2 için LSTM modeli %83 doğruluk oranı sonucunu vermiştir. Veri seti 4 için GRU modeli %93 oranı ile en yüksek doğruluk oranı sonucunu vermiştir. Veri seti 5 için LSTM ve GRU %99 doğruluk oranı ile yüksek bir sonuç vermiştir. Derin öğrenme modelleri sadece doğruluk oranları ile karşılaştırılmayıp öğrenme eğrileri ile de karşılaştırılmıştır. Bu çalışma ile nöropsikolojik rahatsızlıkların yapay zeka ile sınıflandırılabilmenin mümkün olduğunu açıkça gözler önüne sermektedir.

ANAHTAR KELİMELEER: Yapay Zeka, Nöropsikolojik Rahatsızlıklar, Makine Öğrenmesi, Derin Öğrenme, Evrişimsel Sinir Ağları

ABSTRACT

ARTIFICIAL INTELLIGENCE BASED CLASSIFICATION OF SPECIFIC NEUROPSYCHOLOGICAL DISORDERS

MSC THESIS

FİRUZE DAMLA ERYILMAZ BARAN

PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE

COMPUTER ENGINEERING

(SUPERVISOR:ASSOC. PROF. DR. MERİÇ ÇETİN)

DENİZLİ, JUNE 2024

Artificial Intelligence technologies are used in many areas, including the medical field. One of these areas is the detection, diagnosis and, if necessary, treatment of neuropsychological diseases. These diseases are disorders that we frequently encounter in our daily lives. There are many disorders within the scope of neuropsychology. If these disorders are not detected, both the individual's life may be in danger and it causes a difficult process for the environment. This study has the feature of being the first thesis study in the literature that classifies many neuropsychological disorders based on artificial intelligence. Within the scope of this study, five different data sets including anxiety disorder, schizophrenia disorder, autism spectrum disorder, depression and dementia disorders were used. Studies were conducted on the data sets by using data pre-processing, hyperparameter optimization and artificial intelligence models. XGBoost, LightGBM, Random Forest, Support Vector Machines and k- Nearest Neighbor were used as machine learning models and comparisons were made on accuracy metrics. In addition, before and after comparisons were made on machine learning models using hyperparameter optimization. For data set 1, LightGBM technique had the highest success rate with 96% accuracy, while after hyperparameter optimization, SVM came to the forefront with 97% accuracy and gave the highest accuracy rate. For data set 3, XGBoost and LightGBM techniques achieved a successful result with 98% accuracy, while this rate did not change after hyperparameter optimization and XGBoost gave the most successful result. As deep learning techniques, Convolutional Neural Networks (CNN), Long Short-Term Memory (LSTM) and Gated Repetition Unit (GRU) models were designed in accordance with the data sets. For data set 2, LSTM model gave 83% accuracy rate. For data set 4, GRU model gave the highest accuracy rate with 93%. For data set 5, LSTM and GRU gave a high result with 99% accuracy rate. Deep learning models were not only compared with their accuracy rates but also with their learning curves. This study clearly shows that it is possible to classify neuropsychological disorders with artificial intelligence.

KEYWORDS: Artificial Intelligence, Neuropsychological Disorders, Machine Learning, Deep Learning, Convolutional Neural Networks

İÇİNDEKİLER

Sayfa

ÖZET.....	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ.....	vi
TABLO LİSTESİ	vii
KISALTMALAR LİSTESİ.....	viii
ÖNSÖZ.....	ix
1. GİRİŞ.....	1
1.1 Tezin Amacı	1
1.2 Tezin Önemi	1
1.3 Tezin Akışı	2
2. NÖROPSİKOLOJİK RAHATSIZLIKLAR	3
2.1 Nöropsikoloji Nedir?	3
2.2 Nöropsikolojik Rahatsızlıklar.....	4
2.2.1 Anksiyete Bozukluğu (AB)	5
2.2.2 Şizofreni Bozukluğu (ŞB).....	6
2.2.3 Depresyon	7
2.2.4 Otizm Spektrum Bozukluğu (OSB).....	7
2.2.5 Demans	8
2.2.6 Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB)	8
2.2.7 Bipolar Bozukluk (BB).....	9
2.2.8 Alzheimer.....	9
2.3 Tanı.....	10
3. PROBLEM TANIMI	14
3.1 Problem Tanımı	14
3.2 Literatür Taraması	14
3.2.1 Otizm Spektrum Bozukluğu Literatür Taraması	14
3.2.2 Şizofreni Bozukluğu Literatür Taraması	16
3.2.3 Dikkat Eksikliği ve Hiperaktivite Bozukluğu Literatür Taraması.....	19
3.2.4 Bipolar Bozukluk ve Depresyon Literatür Taraması.....	21
3.2.5 Demans ve Alzheimer Literatür Taraması.....	25
3.2.6 Anksiyete Literatür Taraması	28
4. MATERYAL VE YÖNTEM	32
4.1 Yapay Zeka.....	32
4.2 Makine Öğrenmesi	33
4.2.1 Denetimli Öğrenme.....	33
4.2.2 Denetimsiz Öğrenme	34
4.2.3 Yarı Denetimli Öğrenme	36
4.2.4 Pekiştirmeli Öğrenme	36
4.3 Derin Öğrenme	37
4.4 Makine Öğrenmesi Algoritmaları.....	46
4.4.1 XGBoost	46
4.4.2 LightGBM.....	48
4.4.3 k-En Yakın Komşu	49
4.4.4 Rastgele Orman.....	50

4.4.5	Destek Vektör Makineleri.....	51
4.5	Derin Öğrenme Algoritmaları	52
4.5.1	Evrişimsel Sinir Ağları	52
4.5.2	Uzun Kısa Süreli Bellek (LSTM)	53
4.5.3	Geçit Tekrarlayan Birim (GRU)	54
4.6	Değerlendirme Metrikleri	55
4.7	Veri Ön İşleme Süreçleri	59
4.7.1	Gaussian Gürültüsü	60
4.7.2	Fourier Dönüşümü	60
4.7.3	Ayrık Dalgacık Dönüşümü	60
4.7.4	Sürekli Dalgacık Dönüşümü	61
4.7.5	Burg Yöntemi	61
4.8	Hiperparametre Optimizasyonu.....	62
4.9	Google Colaboratory	63
5.	VERİ KÜMELERİ.....	64
5.1	Çevrimiçi Oyuncuların Anksiyete Verileri (Veri Seti 1)	64
5.2	Şizofreni Bozukluğu EEG Veri Seti (Veri Seti 2).....	64
5.3	Otizm Spektrum Bozukluğu Veri Setleri (Veri Seti 3)	64
5.4	İntihar ve Depresyon Tespiti Veri Seti (Veri Seti 4).....	65
5.5	Demans MRI Önışlemesiz Veri Seti (Veri Seti 5)	66
6.	UYGULAMA SONUÇLARI	67
6.1	Veri Seti 1 için Deney Sonuçları	67
6.1.1	XGBoost ve Hiperparametre Optimizasyon Sonuçları.....	71
6.1.2	LightGBM ve Hiperparametre Optimizasyon Sonuçları	73
6.1.3	KNN ve Hiperparametre Optimizasyon Sonuçları	74
6.1.4	RF ve Hiperparametre Optimizasyon Sonuçları	75
6.1.5	SVM ve Hiperparametre Optimizasyon Sonuçları	77
6.1.6	Tüm Deney Sonuçlarının Karşılaştırılması.....	78
6.2	Veri Seti 2 için Deney Sonuçları	79
6.2.1	CNN Modeli Sonuçları	80
6.2.2	LSTM Modeli Sonuçları	84
6.2.3	GRU Modeli Sonuçları	87
6.2.4	Tüm Deney Sonuçlarının Karşılaştırılması.....	90
6.3	Veri Seti 3 için Deney Sonuçları	91
6.3.1	XGBoost ve Hiperparametre Optimizasyon Sonuçları.....	92
6.3.2	LightGBM ve Hiperparametre Optimizasyonu Sonuçları	93
6.3.3	KNN ve Hiperparametre Optimizasyon Sonuçları	94
6.3.4	RF ve Hiperparametre Optimizasyon Sonuçları	95
6.3.5	SVM ve Hiperparametre Optimizasyon Sonuçları	96
6.3.6	Tüm Deney Sonuçlarının Karşılaştırılması.....	97
6.4	Veri Seti 4 için Deney Sonuçları	98
6.4.1	CNN Modeli Sonuçları	98
6.4.2	LSTM Modeli Sonuçları	102
6.4.3	GRU Modeli Sonuçları	105
6.4.4	Tüm Deney Sonuçlarının Karşılaştırması.....	107
6.5	Veri Seti 5 için Deney Sonuçları	108
6.5.1	CNN Modeli Sonuçları	109
6.5.2	LSTM Modeli Sonuçları	112
6.5.3	GRU Modeli Sonuçları	115
6.5.4	Tüm Deney Sonuçlarının Karşılaştırılması.....	118

7. SONUÇ VE DEĞERLENDİRME	120
8. KAYNAKLAR.....	126
9. ÖZGEÇMİŞ.....	134



ŞEKİL LİSTESİ

Sayfa

Şekil 4.1: Denetimli MÖ şeması (Turhost 2021).	34
Şekil 4.2: Denetimsiz MÖ şeması (Turhost 2021).	35
Şekil 6.1: Veri Seti 1'e ait öznelilikler.	67
Şekil 6.2: Veri Seti 1'e ait korelasyon haritası.	69
Şekil 6.3: Veri Seti 1 için etiketlere göre veri sayılarının sütun grafiği.	70
Şekil 6.4: Veri Seti 1'in kümelenme görüntüsü.	70
Şekil 6.5: Veri seti 2 işlem sonrası kanalların frekans değerleri.	79
Şekil 6.6: Veri seti 2 EEG verilerinin gösterimi.	80
Şekil 6.7: Veri seti 2 için CNN modeli şeması.	82
Şekil 6.8: Veri seti 2 için CNN modeline ait karışıklık matrisi.	83
Şekil 6.9: Veri seti 2 için CNN modeline ait öğrenme eğrileri.	84
Şekil 6.10: Veri seti 2 için LSTM modeli şeması.	85
Şekil 6.11: Veri seti 2 için LSTM modeline ait karışıklık matrisi.	86
Şekil 6.12: Veri seti 2 için LSTM modeline ait öğrenme eğrileri.	87
Şekil 6.13: Veri seti 2 için GRU modeli şeması.	88
Şekil 6.14: Veri seti 2 için GRU modeline ait karışıklık matrisi.	89
Şekil 6.15: Veri seti 2 için GRU modeline ait öğrenme eğrileri.	90
Şekil 6.16: Veri seti 4 için CNN modeli şeması.	100
Şekil 6.17: Veri seti 4 için CNN modeli karışıklık matrisi.	101
Şekil 6.18: Veri seti 4 için CNN modeli öğrenme eğrileri.	102
Şekil 6.19: Veri seti 4 için LSTM modeli şeması.	103
Şekil 6.20: Veri seti 4 için LSTM modeli karışıklık matrisi.	104
Şekil 6.21: Veri seti 4 için LSTM modeli öğrenme eğrileri.	104
Şekil 6.22: Veri seti 4 için GRU modeli şeması.	105
Şekil 6.23: Veri seti 4 için GRU modeli karışıklık matrisi.	106
Şekil 6.24: Veri seti 4 için GRU modeli öğrenme eğrileri.	107
Şekil 6.25: Demanslı ve demanssız etiketlenmiş örnek MRI görüntüleri.	109
Şekil 6.26: Veri seti 5 için CNN modeli şeması.	110
Şekil 6.27: Veri seti 5 için CNN modeli karışıklık matrisi.	111
Şekil 6.28: Veri seti 5 için CNN modeli öğrenme eğrileri.	112
Şekil 6.29: Veri seti 5 için LSTM modeli şeması.	113
Şekil 6.30: Veri seti 5 için LSTM modeli karışıklık matrisi.	114
Şekil 6.31: Veri seti 5 için LSTM modeli öğrenme eğrileri.	115
Şekil 6.32: Veri seti 5 için GRU modeli şeması.	116
Şekil 6.33: Veri seti 5 için GRU modeli karışıklık matrisi.	117
Şekil 6.34: Veri seti 5 için GRU modeli öğrenme eğrileri.	118

TABLO LİSTESİ

Sayfa

Tablo 4.1: Karışıklık matrisinin örnek gösterimi	57
Tablo 6.1: Veri Seti 1 için XGBoost modeline ait deney sonuçları	72
Tablo 6.2: Veri Seti 1 için XGBoost modeline ait hiperparametre deney sonuçları	73
Tablo 6.3: Veri seti 1 için LightGBM modeline ait deney sonuçları	73
Tablo 6.4: Veri seti 1 için LightGBM modeline ait hiperparametre deney sonuçları	74
Tablo 6.5: Veri seti 1 için KNN modeline ait deney sonuçları	75
Tablo 6.6: Veri seti 1 için KNN modeline ait hiperparametre deney sonucu ...	75
Tablo 6.7: Veri seti 1 için RF modeline ait deney sonuçları	76
Tablo 6.8: Veri seti 1 için RF modeline ait hiperparametre deney sonuçları ...	76
Tablo 6.9: Veri seti 1 için SVM modeline ait deney sonuçları	77
Tablo 6.10: Veri seti 1 için SVM modeline ait hiperparametre deney sonuçları	78
Tablo 6.11: Veri seti 1 için tüm deneylerin doğruluk sonuçları	79
Tablo 6.12: Veri seti 2 CNN modeline ait deney sonuçları	83
Tablo 6.13: Veri seti 2 için LSTM modeline ait deney sonuçları	86
Tablo 6.14: Veri seti 2 için GRU modeline ait deney sonuçları	89
Tablo 6.15: Veri seti 2 için tüm modellerin doğruluk sonuçları	91
Tablo 6.16: Veri seti 3 için XGBoost modeline ait deney sonuçları	92
Tablo 6.17: Veri seti 3 için XGBoost modeline ait hiperparametre deney sonuçları	92
Tablo 6.18: Veri seti 3 için LightGBM modeline ait deney sonuçları	93
Tablo 6.19: Veri seti 3 için LightGBM modeline ait hiperparametre deney sonuçları	94
Tablo 6.20: Veri seti 3 için KNN modeline ait deney sonuçları	94
Tablo 6.21: Veri seti 3 için KNN modeline ait hiperparametre deney sonuçları ..	95
Tablo 6.22: Veri seti 3 için RF modeline ait deney sonuçları	95
Tablo 6.23: Veri seti 3 için RF modeline ait hiperparametre deney sonuçları	96
Tablo 6.24: Veri seti 3 için RF modeline ait hiperparametre deney sonuçları	96
Tablo 6.25: Veri seti 3 için SVM modeline ait hiperparametre deney sonuçları ..	97
Tablo 6.26: Veri seti 3 için tüm modellerin doğruluk sonuçları	98
Tablo 6.27: Veri seti 4 için CNN modeline ait deney sonuçları	101
Tablo 6.28: Veri seti 4 için LSTM modeline ait deney sonuçları	103
Tablo 6.29: Veri seti 4 için GRU modeline ait deney sonuçları	106
Tablo 6.30: Veri seti 4 için tüm modellerin doğruluk sonuçları	108
Tablo 6.31: Veri seti 5 için CNN modeline ait deney sonuçları	111
Tablo 6.32: Veri seti 5 için LSTM modeline ait deney sonuçları	114
Tablo 6.33: Veri seti 5 için GRU modeline ait deney sonuçları	117
Tablo 6.34: Veri seti 5 için tüm modellerin doğruluk sonuçları	119
Tablo 7.1: MÖ modellerinin karşılaştırma tablosu	124
Tablo 7.2: Derin öğrenme modellerinin karşılaştırma tablosu	124

KISALTMALAR LİSTESİ

NP	:	Nöropsikolojik
AB	:	Anksiyete Bozukluğu
OSB	:	Otizm Spektrum Bozukluğu
DEHB	:	Dikkat Eksikliği ve Hiperaktivite Bozukluğu
DSM	:	Ruhsal Bozuklukların Tanısal ve İstatistiksel El Kitabı
YZ	:	Yapay Zeka
MÖ	:	Makine Öğrenmesi
DÖ	:	Derin Öğrenme
EEG	:	Elektroensefalografi
BB	:	Bipolar Bozukluk
BT	:	Bilgisayarlı Tomografi
MDB	:	Majör Depresif Bozukluk
MRI	:	Manyetik Rezonans Görüntüleme
SVM	:	Destek Vektör Makineleri
DNN	:	Derin Sinir Ağları
DNN-FS	:	Derin Sinir Ağları – Fonksiyonel Bağlantı
CNN	:	Evrişimsel Sinir Ağları
LSTM	:	Uzun-Kısa Süreli Bellek
GRU	:	Geçit Tekrarlayan Birim
RNN	:	Tekrarlayan Sinir Ağları
fMRI	:	Fonksiyonel Manyetik Rezonans Görüntüleme
1D	:	Tek Boyutlu
2D	:	2 Boyutlu
3D	:	3 Boyutlu
LR	:	Lojistik Regresyon
DT	:	Karar Ağacı
RF	:	Rastgele Orman
KNN	:	K-En Yakın Komşu
ANN	:	Yapay Sinir Ağı
FNN	:	İleri Beslemeli Sinir Ağı
AUC	:	Eğri Altındaki Alan
ROC	:	Alıcı Çalışma Özelliği Eğrisi
MAE	:	Ortalama Mutlak Hata
MSE	:	Ortalama Kare Hatası
RMSE	:	Kök Ortalama Kare Hatası
TP	:	Gerçek Pozitif
TN	:	Gerçek Negatif
FP	:	Yanlış Pozitif
FN	:	Yanlış Negatif
CPU	:	Merkezi İşleme Birimi
DWT	:	Ayrık Dalgacık Dönüşümü
CWT	:	Sürekli Dalgacık Dönüşümü

ÖNSÖZ

Bu çalışmanın her aşamasında katkı sağlayan, çalışmayı tamamlamam için güç ve güven veren, desteğini esirgemeyen ve öğrencisi olduğum için gurur duyduğum danışmanım Doç. Dr. Meriç ÇETİN'e tüm içtenliğim ile teşekkürlerimi sunarım.

Beni bugünlere getiren ve bu hayatta her şeyi başarabileceğime beni inandıran sevgili annem Dilek Eryılmaz'a ayrıca teşekkürlerimi sunmak isterim. Beni her zaman en iyi versiyonum olmam için motive eden ve mühendis kelimesinin anlamını öğreten sevgili meslektaşım ve babam Fazıl Ahmet Eryılmaz'a teşekkürlerimi sunarım. Ayrıca eğitim ve öğretim hayatımda çok emeği olan sevgili Şaziment ve Ali Güler'e (anneannem ve dedem) de teşekkür ediyorum.

Bu zorlu yolculukta bana destek olan ve motive eden sevgili eşim Burak Baran'a bu sancılı süreçte beni anlayışla karşıladığı ve yanımda olduğu için ayrıca teşekkür ederim.

1. GİRİŞ

1.1 Tezin Amacı

Bu tezin amacı çeşitli nöropsikolojik (NP) hastalıkların yapay zeka (YZ) ile sınıflandırma yapılabilirliğini test etmek, makine öğrenme (MÖ) algoritmalarının birbirleri ile karşılaştırmasını yapmak, hiperparametre optimizasyonunun performans üzerindeki etkilerini analiz etmek, evrimsel sinir ağlarının (CNN) karşılaştırmasını yapmaktır.

1.2 Tezin Önemi

Günümüzde gelişen teknoloji, tıp ve tıbbi görüntüleme tekniklerinin insan sağlığı üzerinde olumlu dönüşleri olmaktadır. Çarpıcı bir şekilde 19. yüzyılın sonlarından itibaren psikoloji alanının değer kazanmaya başlaması ile günden güne bu alana olan ilgi ve bu alandaki araştırmalar artmaktadır. Psikoloji biliminin öneminin artması ile birlikte psikoloji temelli rahatsızlık türleri de keşfedilmeye başlanmıştır. Bu durum ise psikoloji temelli rahatsızlıkların analiz yöntemlerinin gelişmesine neden olmuştur.

Geçtiğimiz yıllarda YZ'nin ve bu kapsamda geliştirilen algoritmaların tıbbi veriler üzerindeki başarıları araştırılmaktadır. Kanseri ve tümör gibi rahatsızlıklarda YZ algoritmaları sıklıkla kullanılmaktadır. Bu çalışma kapsamında yapılan literatür taramalarında NP bozuklukları üzerine yapılan çalışmaların sınırlı olduğu tespit edilmiştir. Çeşitli NP rahatsızlıkları seçilerek rahatsızlıkların YZ uygunluğu da test edilmiştir.

Farklı veri setleri üzerinde son yıllarda popüler olan MÖ algoritmalarının birbirleri ile karşılaştırılarak performans araştırılması yapılmıştır. MÖ algoritmaları üzerinde hiperparametre optimizasyonu yapılarak parametreler üzerinde optimizasyon yapılmasının gerekliliği araştırılmıştır.

1.3 Tezin Akışı

Bu tez kapsamında ilk bölümde tez kapsamında yapılan çalışmanın öneminden, tezin amacından ve tez akışından bahsedilmiştir. İkinci bölümde NP rahatsızlıklar, anksiyete, şizoreni, depresyon, otizm spektrum bozukluğu, demans, bipolar bozukluk, Alzheimer ve dikkat eksikliği ve hiperaktif bozukluğu rahatsızlıkları ile tanı yöntemleri ile ilgili bilgiler verilmiştir. Üçüncü bölümde problem tanımı ve NP rahatsızlıklar kapsamında olan rahatsızlıkların makine öğrenmesi ve derin öğrenme teknikleri ile yapılmış olan literatürde olan çalışmalar hakkında sonuçları ile birlikte yer verilmiştir. Dördüncü bölümde ise bu çalışma kapsamında kullanılan materyal ve yöntemler bulunmaktadır. Beşinci bölümde tez kapsamında kullanılan 5 adet veri kümesinin detayları bulunmaktadır. Altıncı bölümde veri setleri üzerinde uygulama sonuçları bulunmaktadır. Yedinci bölümde tüm tezin sonuç ve değerlendirme bölümü bulunmaktadır.

2. NÖROPSİKOLOJİK RAHATSIZLIKLAR

2.1 Nöropsikoloji Nedir?

Psikoloji alanıyla ilgili ilk çalışmalar 19. yüzyılın son çeyreğinde başlamıştır. NP kavramının ortaya çıkış temeli olan klinik psikoloji tanımı ve çalışmaları ise 1900'lü yılların başlarında başlamıştır. Dünya savaşlarından sonra kafa travması yaşayan hastalarda davranışsal bozukluklar fark edildiğinde bu bozuklukların sebepleri ile ilgili çalışmalar başlamış ve NP kavramı ortaya çıkmıştır.

NP; beyin fizyolojisi ve fonksiyonlarının kişinin davranışları ile olan ilişkisinin anlaşılması ve nörolojik sebepli bozuklukların neden olabileceği bilişsel etkilerinin tespit edilebilmesi amacı ile çalışmalar yürüten bilim dalıdır. NP; nöroloji ve psikolojinin kesişimi olarak kabul edilmektedir. NP psikolojik süreçler ile beyin yapıları ile sistemleri arasındaki ilişkiyi incelemektedir. Beyin faaliyetlerinin gözlenebilir ve ölçülebilir davranışlardaki çıktısını anlamaya ve açıklamaya çalışmaktadır (Yılmaz 2021).

NP klinik ve deneysel olmak üzere temelde iki dala ayrılmaktadır. Klinik ve deneysel NP arasındaki en önemli ayrım noktası klinik NP anormal üzerinde çalışmalar yapılırken deneysel NP normal üzerinde çalışmalar yapılmasıdır. Klinik NP var olan bir beyin hasarının ya da beyin rahatsızlıklarının, kişinin psikolojisi üzerindeki etkisi inceleniyorken; deneysel NP'de herhangi bir beyin hasarı ya da rahatsızlığı olmayan normal kişilerin farklı ve çeşitli şartlar altında bireylerin psikolojik süreçleri üzerindeki etkisi incelenmektedir.

NP hastalıkların tespitinde ilk başlarda psikologlar tarafından geliştirilen testler kullanılmaktadır. İlk zamanlarda vaka çalışmaları beyin hasarı bulunan hastalar üzerinde yapılmıştır. Bu hastaların davranışlarını, motor becerilerini, dil becerilerini ve kullanımlarını, hafıza ve dikkat gibi davranışlarını ölçecek testler oluşturulmuştur. Tespitlerin ilk yapıldığı aşamalarda psikologlar basit motor hareketleri üzerinden yorum yapmaya elverişli testler üzerinde çalışırken ilerleyen aşamalarda daha farklı, somut veri sunan ve aynı zamanda belirli bir tutarlılık dizini içerisinde tespitini doğruluğunu teyitleyici test arayışı içerisine girmiştir. Bu süreçte teknolojik

gelişmeleri ve özellikle bilgisayar sistemlerinin hastaların motor hareketlerini denetleyebilmesi ve buna uygun raporlama yapabilmesi test güvenilirliğinin ve veri doğruluğunun artmasına sebep olmuştur. 1970 yılında bilgisayar tomografisi (BT) ve 80'lerde manyetik rezonans (MR) nörogörüntüleme tekniklerinin geliştirilmesiyle beyin görüntüleme ve hasarın bölge saptanmasının kolaylaştırılması, NP çalışmaları için büyük avantaj olarak gelecek araştırmaların önünü açmıştır (Çalışkan 2020).

NP çalışma kapsamında biyolojik sebepli davranış bozuklukları; Alzheimer gibi sinir sisteminde yapısal bozukluklara bağlı olarak ortaya çıktığından dolayı nörodejeneratif olarak tanımlanan hastalıklar; depresyon, bipolar bozukluk (BB), anksiyete, dikkat eksikliği, öğrenme bozukluğu veya şizofreni gibi günümüzde popüler olarak ele alınan rahatsızlıklar da NP rahatsızlıklar dahilindedir. Belirtilen bu rahatsızlıkların teşhis edilmesi gerek test yöntemleri gerekse de kişinin içinde olduğu psikolojik durum nedeni ile oldukça güç hale gelmektedir.

Psikiyatri/psikoloji alanlarında başvuran hastaların büyük bir çoğunluğunu oluşturan NP rahatsızlığına sahip kişilerin toplum içerisindeki ve bireysel yaşamının irdelenmesi gereklidir. Bu kapsamda otizm spektrum bozukluğu (OSB) tanısı konulmuş bir bireyin özellikle çocukluk aşamasından itibaren topluma karışması, sosyal yaşam içerisinde kendine yer bulması oldukça zor olması ile birlikte ayrıca erken tanının kritik önemli olduğu bu rahatsızlık için tanı koymak da oldukça güç hale gelmektedir.

2.2 Nöropsikolojik Rahatsızlıklar

Kişinin uzun veya kısa süreli, şiddetli psikolojik bir eyleme maruz kalması sonucunda ya da beyin kimyasındaki biyolojik değişiklikler sebebi ile nörolojik anomalilere yol açmaktadır. Genetik olarak bazı kişilerde bu hastalıklara karşı yatkınlık olabilir ve genetik de belirtilerin başlamasını tetikleyebilir.

Her türlü psikolojik belirti nörolojik hastalıklara eşlik edebilir. Kişide görülen duygu durum değişikliği, iştahta değişiklik, ajitasyon, halüsinasyon, hezeyan, obsesyon ve kompülsiyon, huzursuzluk, uyku bozukluğu, bitkinlik, iştah değişikliği

ve aşırı enerji gibi semptomlar bir NP rahatsızlığın belirtisi olabilir. Fakat bu psikiyatrik belirtiler belirli bir nörolojik hastalığa ait değildir.

Bu çalışma kapsamında anksiyete bozukluğu, şizofreni bozukluğu, otizm bozukluğu, depresyon ve demans hakkında bilimsel çalışma yapılmıştır.

2.2.1 Anksiyete Bozukluğu (AB)

AB, kişinin bedensel ve ruhsal varlığı üzerinde tehlikede hissetmesi sonucu yaşadığı huzursuzluklar korku ve kaygıya neden olmaktadır. Herhangi bir nedeni olmayan ve herhangi bir somut tehlike olmamasına rağmen kişinin yaşadığı bu huzursuzluk ve tedirginlik haline AB adı verilmektedir.

AB olan birey tehdit altında olduğu riskinin yüksek, başa çıkma becerisini ise düşük görmektedir. Kişi ileriki yaşamında karşılaştığı stresli tetikleyici uyarıyı geçmişte yaşadığı durumu, koşullara benzettiğinde yani başa çıkamayacağı bir tehlike şeklinde değerlendirildiğinde AB süreci başlamaktadır (Topçuoğlu 2022).

AB en yaygın ruhsal bozukluklar içerisinde yer almaktadır. Avrupa’da yapılan bir araştırmada son bir yılda 15-54 yaş arasındaki bireylerin %17.2’sinde bu bozukluklardan biri olduğu görülmüştür (Stein ve Hollander 2002). AB boşanma durumu, işsizlik ve gelir düzeyi gibi etkenler sebebi ile ortaya çıkabilmektedir. AB çoğunlukla erken yaşta başlamaktadır. Hayvan fobileri, kan, enjeksiyon, yara fobisi gibi özgül fobiler çocukluktan; sosyal fobi ergenlikten başlamaktadır. AB nadiren tek başına görülmektedir. MDB gibi duygu durum bozukluğu ya da madde veya alkol kullanım bozuklukları AB’e çoğunlukla eşlik etmektedir.

Anksiyete belirtileri olan hastalarda prefrontal ve limbik devrelerin önemli olması nedeniyle anksiyetenin temel özellikleri olan olumsuz işaretlere seçici bir dikkat gösterilmesi ve gelecekteki olumsuz olaylara karşı bir beklenti içinde olunması açıklanabilmektedir. Bu alanların etki ettikleri anksiyete hastalarında farklı tıbbi görüntüleme yöntemleri kullanılmasıyla doğrulanmıştır. Bu alanlardaki nörolojik lezyonlarda anksiyete belirtileri görülebilir (Sevinçok 2007).

2.2.2 Şizofreni Bozukluğu (ŞB)

Şizofreni Bozukluğu toplumda gözlemlenebilen %1 içerisinde görülen sanrı benzeri pozitif bulgular; duygu ve düşüncede sığlaşma ve bunları aktaramama, sosyofobik davranışlar, kendini anlatma ve sohbet azalma gibi negatif bulgular; dikkat, hafıza, yürütücü görevlerde bozulma gibi bilişsel belirtiler ile teşhis edilebilen psikiyatrik bir rahatsızlıktır (Summakoglu 2018).

Şizofrenin ortaya çıkmasında bir çok faktör etkili olabilir. Bunlar arasında; genetik etkenler, beynin morfolojik kimyasal ve fizyolojik değişiklikleri ve endokrin etkenler bulunmaktadır. Hastalığın ortaya çıkmasında belirli bir yaş aralığı, cinsiyet, sosyo ekonomik durum gibi faktörler belirleyici değildir. Her yaş aralığında, hayatın her alanında ortaya çıkabilmektedir. Bu sebeple doğuştan şizofreni belirtileri gözlemlenmese de veya kişinin hayatının büyük çoğunluğu normal geçse de ortaya çıkabilecek bir hastalıktır. Ancak son yıllarda çok geç yaş başlangıçlı şizofreni üzerine yayınlar görülse de hastalığın genellikle gençlik çağına başladığı kabul edilmektedir (Hafner ve diğ. 1998).

Araştırma verilerine göre; frontal lobda küçülme, talamusun algıları süzme ve ayıklama işlevinde bozukluk, prefrontal korteks ve serebellum arasındaki devrelerde bozukluk vardır. Geçmiş araştırmalarla ŞB tanısına sahip kişilerde uyarınların beyne ulaşırken girdi ayarlamasında bir yetersizlik olduğu, bu nedenle beyne çok fazla bilgi iletildiği, ama hastanın bu bilgileri uyum amacıyla ayıklayamadığı ve bütünleştiremediği sonucu çıkarılmıştır. Şizofreni rahatsızlıklarında temelde bir bilgi-işleme kusuru olabileceği görüşü giderek ağırlık kazanmaktadır. Şizofreni bilgi-işleme kuramları başlangıçta daha çok uyarınların süzülmesinde bir bozukluk olduğu varsayımına dayanmaktaydı. Son yıllarda nörofizyolojiye bağlı bilgi işleme kuramları popüler olmaya başlamıştır. Niyetlenme ve harekete geçme işlevleri frontal korteks ile ilgilidir. Son yıllarda "eksiklik sendromu" giderek artan biçimde ilgi çekmektedir (Öztürk 2001).

Hastalığın ortaya çıkmasında özellikle genetik faktörler etkin rol alsada genel itibariyle genetiğin ve çevresel faktörlerin bir arada görüldüğü sınıflandırmaya sahiptir. Burada çevresel faktörlerin olabildiğince kontrol altına alınması ve kişide

bulunan hastalığın şiddetinin azaltılması hedeflenmektedir. Aynı zamanda kişinin psikoterapi görmesi de sağlanarak bir nevi rehabilitasyon gerçekleştirilmektedir.

2.2.3 Depresyon

Hastalık yalnızca genetik veya çevresel faktörler nedeni ile ortaya çıkmamakta her iki unsurun da bir araya gelmesi ile ortaya çıkmaktadır. Son zamanlarda yapılan çalışmalarda da çevresel faktörlerin ve genetik faktörlerin kombinasyonu ile hastalığın ortaya çıktığına dair yaygın görüş oluşmuştur. Yoğun strese maruz kalma, madde bağımlılığı, kişinin hayatında meydana gelen ciddi değişiklikler hastalığın ortaya çıkmasında büyük rol oynamaktadır.

Hastalığın ortaya çıktığı kişilerde öz saygıyı yitirme, yaşama sevincinde eksilme gibi ruhsal değişiklikler gözlemlenebilir. Hastalığın şiddetinin arttığı dönemlerde ise kişilerde intihara yönelme ve intihar düşüncesi de oluşmaktadır. Majör depresyon bozukluğuna (MDB) sahip yetişkin hastaların %2-7'si intihar ile yaşamını kaybetmektedir (Richards ve Ohara 2012).

Hastalığın ortaya çıkmasında belirli bir yaş aralığı, cinsiyet, sosyo ekonomik durum gibi faktörler belirleyici değildir. Genel olarak, depresyonun kişide görülme yaşları kişilerin 20'li ve 30'lu yaşlarında görülmektedir. Kadınlarda depresyonun görülme sayısı ekeklere göre iki kat daha fazla görülmektedir (Kessler ve Bromet 2013).

2.2.4 Otizm Spektrum Bozukluğu (OSB)

İlk ortaya çıktığında genetik nedenlerden kaynaklandığı düşünülse de ilerleyen aşamalarda ve çalışmalarda çevresel faktörlerin de etkisi olduğu tespit edilen beynin yapısal işleyişinde gerçekleşen farklılıklardan kaynaklı ortaya çıkan bir hastalıktır. Otizmin tanılanmasında tek belirtiden ziyade birden fazla belirtinin ortaya çıkması ve bu belirtilen belirli bir sistematik içerisinde gözlemlenmesi gereklidir. Genellikle tek bir belirti üzerinden OSB tanısı koymak mümkün olmamaktadır. Zira normal bir gelişim içerisinde olan çocukların da hareket ve davranışları otizm belirtisi olarak

algılanabilmektedir. Bu nedenle tanının doğru olarak konulabilmesi için belirtilerin belirli bir dizin içerisinde ve belirli bir sıklık düzeyinde gerçekleşmesi önem arz etmektedir.

OSB tanısı konulan bireylerin sosyal yaşantı içerisinde kısıtlı ilgi alanları olabileceği gibi ukala tavırlar sergiledikleri, konuşkanlık ve her şeyi ben bilirim tavrı içerisinde oldukları gözlemlenmiştir (Happé 1999). Dolayısıyla otizm tanılama veya farkına varma konusunda oldukça geniş bir kartela içerisinde belirli bir eylem ve davranışları değil, hareketlerin belirli bir dizilim veya sıklığa tabi olup olmadıkları kadar hangi olaylara nasıl tepki verdiği de önemlidir.

2.2.5 Demans

Demans, insan hafızasında ve benzeri zihinsel kabiliyetlerde bozukluğun ortaya çıktığı bir hastalık türüdür. Uygulamada sıklıkla alzheimer ile birlikte anılsa da alzheimer hastalığı, demansın bir türü olmakla birlikte aynı hastalık değildir. Demans hastalığı zihinsel yeteneklerden bir veya birkaçında gerçekleşebilir. Örneğin hasta kişide düşünme yeteneği bozukluğu, karar almada sıkıntılar, konuşma bozukluğu ve hafıza bozukluğu gibi belirtiler görülmektedir. Demansın oluşmasında beyin sinirleri arasında iletişim bozukluğu ve beyin hücrelerinin ölmesi oldukça yaygın görülen nedenlerdir. Demans riskini arttırabilecek diğer etkenlere bağımlılık yapıcı madde kullanımı, şeker hastalığı, yüksek tansiyon veya kolesterol, kilo problemleri bulunmaktadır. Sayılan bu rahatsızlıkların birleşimi yahut kalıtsal faktörler de demansı tetikleyebilir (Erdem 2023).

2.2.6 Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB)

Dikkat eksikliği ve hiperaktivite bozukluğu (DEHB); dikkat bozukluğu, aşırı hareketlilik gibi belirtileri nedeni ile hasta kişinin sosyal, mesleki ve gündelik yaşamını olumsuz etkileyen bir rahatsızlıktır. Rahatsızlık ilk tespit edildiğinde kişinin davranışları ile ilgili bir sorun olarak değerlendirilse de ilerleyen süreçte hastalığın nedeninin nörogelişimsel bir nedene dayalı olduğu tespit edilmiştir.

Rahatsızlık özellikle çocukluk ve ergenlik döneminde görülmekte iken nadiren de ergin kişilerde sonradan ortaya çıkabilmektedir. Erkeklerde görülme sıklığı, kadınlara nazaran daha yüksektir.

2.2.7 Bipolar Bozukluk (BB)

Manik ve depresif periyot olmak üzere gözlemlenebilen ve toplumda sıklığı artmakta olan bir duygu durum bozukluğudur. Periyotların haricinde kişinin normal duygu durumuna geçtiği vakalar da mevcuttur. Hastalığın oluşma riskini %60-80 bandında genetik etmenlerin oluşturduğu düşünülmektedir (Kerner 2014). Hastalığın çevresel ve genetik gözlemlenmesinin haricinde nörolojik nedenlerden dolayı ortaya çıkması da mümkündür. Kişinin inme, travmatik yaralanma, MS gibi hastalıklar geçirmesi halinde de ortaya çıkabilmektedir.

Kişinin çevresinde bulunan kişilerce gözlemlenebilen eylemleri üzerinden yola çıkılarak teşhis başlangıcı aşaması başlamaktadır. Ancak uygulamada BB sahip kişilerin sergilediği davranışların, diğer nörolojik hastalıklar gibi semptom gösterdiği ortadadır. Buna göre kişinin migren hastası mı yoksa BB içerisinde olup olmadığının denetimi tıbbi görüntüleme teknikleri ile ayırt edilebilmektedir. Bu sebeple şu anda ayırıştırıcı tanı yöntemi için kullanılan görüntüleme teknikleri, ileride doğrudan tanımlama noktasında da kullanılabilir. Zira benzer nitelikli klinik çalışmalarında BB'ye sahip bireylerin görüntüleme teknikleri içerisinde ayırt ediciliği ortaya çıkmaya başlamıştır.

2.2.8 Alzheimer

Alzheimer hastalığı yaygın görülen bir demans türüdür. Çoğunlukla uygulamada demans ve alzheimer aynı hastalık gibi anlaşılsa da alzheimer demansın bir alt türüdür. Demansın türü olmasından kaynaklı demans ile benzer özelliklere sahiptir. Dolayısıyla alzheimer hastası olan kişide de birtakım bilişsel bozukluklar ve özellikle hafıza kaybı görülmektedir.

Görüntüleme tekniklerinin teşhis desteği olarak kullanılmasındaki asıl etken hastalığın öncelikle gözlemsel ve davranış testleri ile belirti vermesinden kaynaklanmaktadır. Tanının kesin ve net şekilde tespit edilmesi -yine bu sebepten kaynaklı olarak - görüntüleme tekniklerinin yorumlanması ile gerçekleşir. Erken dönemde belirti gösteren alzheimer hastalarında tedavi süreci ile hastalığın etkileri ve ilerlemesi azaltılabilmektedir.

2.3 Tanı

Farklı NP rahatsızlıklar farklı yöntemler ile tedavi edilmektedir. Bu sebeple de doğru tedavi için doğru bir tanı koymak kritik öneme sahiptir.

NP değerlendirmede klasik testlerin yanı sıra kişinin bilişsel kabiliyet gerektiren günlük yaşam aktivitelerindeki becerilerinin de ölçülmesi daha isabetli bir NP değerlendirme profilinin oluşturulmasında önemlidir (Yağcı 2021).

Psikiyatrik belirtiler, kognitif belirtiler ve altta yatan hastalığın nörolojik belirtileri bir araya gelince hekimler için ayırıcı tanı koymak oldukça zordur. Fiziki ve nörolojik muayene ile psikiyatrik değerlendirme ile beraber NP testlerin uygulanması da tedaviyi şekillendirirken klinisyene yardımcı olmaktadır (Yağcı 2021).

NP bozukluklarda tanı koymak için kullanılan yöntemler biyolojik testler, görüntüleme teknikleri ve özellik gözlemlerdir. Hastalıkların ilk belirtileri gözlemlere dayalı olarak tespit edilebilecek olup belirtilerin artması, sıklaşması veya çeşitlenmesi durumunda biyolojik testlere başvurulmaktadır.

Genel olarak hastalıkların tanınmasında görsel olarak belirtiler analiz edilebilecek olsa da doğrudan teyit verecek biyolojik bir test bulunmamaktadır. Bu nedenle biyolojik testler, hastalığın belirtilerini yorumlamayı kolaylaştırma amacı gütmektedir. Özellikle nörolojik faktörlerin izlenmesi ve MR görüntüleme teknikleri ile belirtiler doğru yorumlanmaya çalışılmakta ve buna göre tanılama işlemi yapılmaktadır. Çalışmamız kapsamında da hem belirtilerin yorumlanması amacı ile hem de nörolojik bulgular ile doğrudan hastalığın tanısını yönelik işaret bulunmaya çalışılmaktadır.

Otizm tanısı koyulmasındaki en önemli etken bireyin davranış şekilleridir (London 2007). DSM-IV-TR’de tanı kitapçığına göre 6 belirti ve üstü otizm tanısı koymaya yeterlidir. Bu belirtiler arasında sosyal iletişim ve etkileşim düzeyinde içeriksel olarak bozukluk, tekralayıcı ve sınırlı davranışlar bulunmaktadır. Örnek belirtiler arasında, sosyal ve duygusal karşılıklılık eksikliği, dilin stereotipik ve yineleyici kullanımı ya da idiosinkratik (kisiye özgü) dil kullanımı ve nesnelerin parçaları ile ısrarlı olarak ilgilenme bulunur. Özellikle benzer yaş gruplarında gözlemlenen sosyal davranışlarda etkili bir esneklik ve azalmanın varlığı halinde tanılama sürecinin başlaması gerekmektedir. Ancak bu şekilde davranışların normal bir sosyolojik eylem mi olduğu yoksa NP bir nedene mi bağlı olduğu tespit edilebilecektir. Çeşitli çalışmalar, kas güçsüzlüğü (hipotoni), kaba motor disfonksiyon (apraksi) ve parmak uçlarında yürüme gibi değişik motor bozukluklara rastlandığını göstermiştir (Ming ve diğ. 2007).

Hastalığın teşhisi doktorla kişinin yüz yüze görüşmesi, psikometrik anketler gibi öznel yöntemlere dayanmaktadır. Mumtaz ve ark. (2017) yürüttüğü çalışmada, EEG sinyalleri incelendiğinde beyindeki bazı bölgelerin sinyallerindeki interhemisferik asimetri sayesinde depresyon teşhisi konulabileceği sonucunu çıkarmışlardır.

Depresyon ve anksiyete ise başlangıç aşamasında gözleme dayalı olarak belirtilerin ortaya çıkmasından sonra tıbbi görüntüleme teknikleri ile desteklenerek tanıya varılmaktadır. Ruhsal Bozuklukların Tanısal ve İstatistiksel El Kitabı’nın beşincisine (DSM 5) göre major depresyon kriterleri; istek ve ilgi azalması, depresif duygudurum, uyku ve iştahta azalma veya artma, psikomotor yavaşlama, suçluluk, konsantrasyon güçlüğü, enerji azalması ve intihar eğilimidir (Kafes 2021).

Şizofrenide ise ilk belirtiler gözleme dayalı olmakla beraber görüntüleme üzerinden beynin ilgili bölgelerinde uyarı akısının kesilmesi ve uyarının yoğunlaşması ile rahatça saptanmaktadır.

Genel olarak hastalıkların tanılanmasında görsel olarak belirtiler analiz edilebilecek olsa da doğrudan teyit verecek biyolojik bir test bulunmamaktadır. Bu nedenle biyolojik testler, hastalığın belirtilerini yorumlamayı kolaylaştırma amacı gütmektedir. Özellikle nörolojik faktörlerin izlenmesi ve MRI teknikleri ile belirtiler

doğru yorumlanmaya çalışılmakta ve buna göre tanılama işlemi yapılmaktadır. Çalışmamız kapsamında da hem belirtilerin yorumlanması amacı ile hem de nörolojik bulgular ile doğrudan hastalığın tanısına yönelik işaret bulunmaya çalışılmaktadır. Zira her hastalık, görsel anlamda belirti vermemektedir.

Demansın belirlenmesine yönelik geleneksel yaklaşımlar öncelikle klinik muayenelere, tıbbi kayıtların analizine ve bilişsel ve NP testlerin uygulanmasına dayanır (Javeed ve diğ. 2024). Demans tanısı için hastalara Mini Mental Test uygulanmaktadır. Mini mental test neticesinde demans izlenimi oluşur ise hastalara daha kapsamlı tetkikler yapılmaktadır. Bu tetkikler arasında psikometrik ve nörolojik değerlendirme, fiziki kontrol ve hasta öyküsünün alınması bulunmaktadır. Mini Mental Test sonrasında, tıbbi görüntüleme teknikleri, EEG, omurilik sıvısı alma işlemleri ve biyokimyasal testler uygulanabilir (Memorial 2023).

Bir nörogelişim bozukluğu olarak, MRI gibi nörogörüntüleme teknolojileri, MÖ algoritmalarıyla birlikte DEHB'de biyobelirteçler olarak giderek daha fazla araştırılmaktadır. DEHB'li çocuklarda, belirli beyin yapılarında genel bir hacim azalması vardır ve sol taraftaki prefrontal korteksteki hacimde orantılı olarak daha büyük bir azalma vardır. DEHB'li bireylerde kontroller ile karşılaştırıldığında arka paryetal kortekste de incelmeye görülmektedir. Prefrontal-striatal-serebellar ve prefrontal-striatal-talamik devrelerdeki diğer beyin yapılarının da DEHB olan ve olmayan kişiler arasında farklılık gösterdiği bulunmuştur.

Hastalık şüphesi bulunan veya belirtiler gösteren kişilerin MRI sonuçları dikkate alınarak beyin yapısı incelenmekte ve buradaki değerlendirme neticesinde dikkat eksikliği ve hiperaktivite bozukluğu tanısı konulmaktadır. Bireyde, beyin yapısının değişmesine bağlı olarak baskı altına alınan bölge, belirtilerin niteliğine göre de ayrıştırmada dikkate alınmaktadır.

DEHB ise tanı yöntem ve araçlarını iki ana kategoriye ayırmak mümkündür. Bunlar; dikkatsizlik ve dürtüselliktir.

Dikkatsizlik, bireyin günlük davranış ve hareketlerinde rahatlıkla gözlemlenebilir. Kişinin basitçe hatalar yapması, uzun süre dikkatini bir olaya verememesi dikkatsizliğin en net ve temel göstergeleridir. Kişilerin uzun süreli dikkat

gerektiren işlerden kaçınması da dikkatini toplayamadığı olarak yorumlanabilir. Görevler veya aktiviteler için gerekli eşyalardan olan kitap, okul malzemeleri, gözlük, çanta gibi ürünleri sıklıkla kaybeder. Günlük aktivitelerini gerçekleştirirken unutkan tavırlar sergilemektedir.

Hiperaktivite yani dürtüsellikte ise kişi sıklıkla elleri veya ayakları ile oynar çoğu zaman çocuk ise etrafta koşuşturur veya tırmanış gibi davranışlar gözlemlenmektedir. Bu durum gençlerde veya yetişkinlerde öznel bir huzursuzluk hissi olarak görülmektedir. Sık sık başkalarının sözünü keser ya da rahatsız etmek de başkaca bir belirti olarak görülmektedir.

Gözlemlenebilen belirtiler haricinde NP tanı yöntemleri ile de hastalığın tanılanması mümkündür. Gözlemlere ek olarak birtakım yöntemler ile hastalığın tanılanması kolaylaşmaktadır. Buna göre NP bulgular içerisinde aşırı motor aktivitesinin gözlemlenmesi, zaman işleme bozukluklarının varlığı, hazzı ertelemekten hoşlanmama ve hedefe karşı çaba göstermede istek ve işlevsizlik tespitleri de DEHB'li bireylerin tespiti için önemli tanı araçlarıdır.

3. PROBLEM TANIMI

3.1 Problem Tanımı

NP bozukluklar, bilişsel, duygusal ve davranışsal işlevleri etkileyen, teşhis ve tedavi açısından karmaşık zorluklar oluşturan geniş bir yelpazedeki durumları kapsamaktadır. Geleneksel tanı yöntemleri sıklıkla subjektif değerlendirmelere dayanır ve bu da sınıflandırma ve prognozda tutarsızlıklara ve yanlışlıklara yol açmaktadır. Ayrıca, bu bozukluklara katkıda bulunan çeşitli faktörlerin karmaşık etkileşimi, kapsamlı bir analiz için çok boyutlu bir yaklaşımı gerektirmektedir. Bu tez, NP bozuklukları analiz etmek için derin öğrenme (DÖ) ve MÖ tekniklerinin gücünden yararlanarak bu zorlukların üstesinden gelmeyi amaçlamaktadır. DÖ ve MÖ kullanılarak tahminleme yapabilmek için Veri Ön İşleme, Özellik Çıkarma ve Seçimi, Model Geliştirme, Tanısal Sınıflandırma, Doğrulama aşamalarına gerek duymaktadır. Bu tez, bu hedefleri ele alarak NP bozuklukların analizinde en son teknolojiyi geliştirmeyi, klinisyenlere erken teşhis, kişiselleştirilmiş tedavi planlaması ve hastaların ilerlemesinin izlenmesinde yardımcı olacak daha doğru ve güvenilir tanı araçları sunmayı amaçlamaktadır.

3.2 Literatür Taraması

NP rahatsızlıklar ile ilgili yapılmış çalışmaların literatür taramaları bu bölümde bulunmaktadır.

3.2.1 Otizm Spektrum Bozukluğu Literatür Taraması

Sen ve diğerleri (2018) OSB üzerine yaptığı çalışmada çok modlu özellik öğrenme ve doğrusal SVM kullanarak yaptığı çalışmada %64.3 başarı elde etmektedir.

Guo ve diğerleri (2017) çalışmasında OSB hastalarının tipik gelişim kontrollerine karşı yüksek boyutlu tüm beyin dinlenme durumu Fonksiyonel Bağlantı modeli sınıflandırması için yeni bir özellik seçme yöntemine sahip bir DNN

geliştirerek %86.36'lık en iyi sınıflandırma doğruluğuna sahip model, 3 gizli katman ve 150 gizli düğüm içeren DNN-FS modeli en iyi performansı göstermektedir.

Dekhil ve diğerleri (2018) OSB üzerine uzamsal aktivasyon alanlarına karşılık gelen zaman akışlarının güç spektral yoğunlukları giriş özellikleri olarak kullanılmış ve bunları yığılmış otomatik kodlayıcıya besler ve ardından olasılıksal SVM kullanarak bir sınıflandırıcı sistem oluşturmaktadırlar. Bu sistem duyarlılık, özgüllük ve dorulukta yaklaşık %90 başarı elde edilmiştir.

Wang ve diğerleri (2019) OSB üzerine Fonksiyonel Bağlantının ilk 1000 özellik seçilerek SVM özyinelemeli özellik eleme algoritması kullanarak, 1000 özellikten yüksek seviyeli gizli ve karmaşık özellikleri çıkarmak için iki gizli katmana sahip yığılmış bir otomatik kodlayıcı eğitilerek daha sonra softmax sınıflandırıcı kullanılarak sınıflandırılma sonucunda %93.59'luk doğruluk elde edilmiştir.

Lakhan ve diğerleri (2023) OSB üzerine yaptıkları çalışmada mevcutta OSB çerçevelerinin sonuçlarını geliştirmek için kapsamlı hizmetlerle birlikte karmaşık ve etkili bir OSB çerçevesi sunmaktadırlar. Multimodal veri kümeleri kullanan çocuklarda OSB tespiti için tasarlanmış Birleşik Öğrenme özellikli CNN-LSTM (FCNN-LSTM) şema önermektedirler. Ayrıca OSB hastalarının verimliliğini artırmak ve daha optimal öğrenme sonuçları elde etmek için çeşitli Nesnelerin İnterneti (IoT) uygulamaları tasarlamışlardır. Simülasyon sonuçları, önerilen çerçevelerinin, mevcut tüm OSB çerçeveleriyle karşılaştırıldığında yaklaşık %99'luk bir OSB tespit doğruluğuna ulaştığını göstermektedir.

Rabbi ve diğerleri (2021) araştırmalarında, sıradan insanlar için uygun olmayan görüntülerden çocuklarda otizm tespitine yönelik YZ algoritmalarından yararlanılmıştır. Çocuklarda OSB sınıflandırmak için Çok Katmanlı Algılayıcı (MLP), RF, Gradient Boosting Machine (GBM), AdaBoost ve CNN olmak üzere beş farklı algoritma kullandılar. Bu algoritmalar arasındaki sınıflandırma performanslarını karşılaştırdıklarında, CNN'de diğer geleneksel MÖ algoritmalarından daha iyi performans gösteren %92,31 ile en yüksek doğruluğu elde edilmiştir. Bu nedenle özellikle çocuklarda OSB'nin tespitinde kullanılabilecek CNN'e dayalı bir tahmin modeli önerilmektedir.

Raj ve Masood (2020) çalışmalarında, OSB sorunlarını tahmin etmek ve analiz etmek için Naive Bayes, SVM, LR, KNN, Sinir Ağı ve CNN kullanılmaktadır. Çeşitli makine öğrenme teknikleri uygulandıktan ve eksik değerler işlendikten sonra, sonuçlar CNN tabanlı tahmin modellerinin Yetişkin, Çocuklar ve Ergenler için Verilerde Otizm Spektrum Bozukluğu Taraması için sırasıyla %99,53, %98,30, %96,88'lik daha yüksek doğrulukla tüm bu veri setlerinde daha iyi çalıştığını güçlü bir şekilde önermektedir.

Asif Mohamed ve diğerleri (2022), transfer öğrenmesi ve flask çerçevesi olan evrişimli sinir ağları ile çalışmaktadırlar. Çalışmalarında Xception modelini kullanmışlardır ve daha önce bu veri seti ile çalışılan diğer derin öğrenme modellerinin değerlendirme metrikleri ile karşılaştırmaları yapılmıştır. Xception modeli 0.93 doğruluk oranı ile sonuç vermektedir.

3.2.2 Şizofreni Bozukluğu Literatür Taraması

Dakka ve diğerleri (2017) Şizofreni ve kontrol sınıflandırması üzerine yaptıkları çalışmada LSTM modeli ile R-CNN modelleri ile SVM doğruluğunu, karşılaştırmışlardır ve LSTM modeli %66.4 test performansı ile en iyi sonucu vermektedir.

Yan ve diğerleri (2019) şizofreni ve kontrol arasındaki sınıflandırma üzerine yaptıkları çalışmada Tekrarlayan Sinir Ağlarının (RNN) zaman dizilerinin dinamik bilgilerini yakalama yeteneğinden hareketle, fMRI bağımsız bileşenlerinin zaman süreçlerini kullanarak sınıflandırmaya olanak tanıyan çok ölçekli bir RNN modeli kullanılmış ve %83.2 doğruluk elde edilmiştir.

Yan ve diğerleri (2017) şizofreni ve kontrol arasındaki sınıflandırma için derin sinir ağı (DNN+LRP) ve katman bazında alaka yayılımı adı verdikleri bir çerçeve hazırlamışlardır ve SVMRFE ile kıyaslamışlardır. Test sonuçlarına göre DNN+LRP %84.8 başarı oranı ile SVMRFE'yi geçmiştir.

Qureshi ve diğerleri (2019) şizofreni ve kontrol arasındaki sınıflandırma üzerine yaptıkları çalışmada 3D-CNN modeli oluşturmuşlardır ve %98 başarı elde

etmişlerdir ve ek olarak iki grup arasındaki fonksiyonel bağlantı farklılıkları, çoklu dinlenme durumu ağlarında istatistiksel olarak analiz etmişlerdir.

Jeng ve diğerleri (2024) şizofreninin nörogelişimsel modelinde, küçük fiziksel anomaliler (MPA'lar), şizofreninin nörogelişimsel belirteçleri olarak kabul edildiğinden dolayı MPA öğelerinin ölçümlerine dayalı olarak şizofreni riskini tahmin etmek ve MPA'ların potansiyel birincil ve etkileşim etkilerini araştırmak için bir MÖ modeli oluşturulmuş ve kullanılmıştır. Çalışmaya 470 şizofreni hastası ve 354 sağlıklı kontrol dahil edilmiştir. Kullanılan modeller klasik istatistiksel model, Lojistik Regresyon (LR) ve MÖ modelleri, Karar Ağacı (DT) ve Rastgele Ormandır (RF). RF'nin şizofreni için en yüksek tahmin gücüne sahip olduğunu bulmuşlardır (Tam eğitim AUC = 0,97 ve 5 kat çapraz doğrulama AUC = 0,75). Ağız bölgesi, yüksek damak, çatık dil, kafatası yüksekliği ve ağız genişliği gibi çeşitli birincil MPA'lar belirlemişlerdir. Etkileşimde ayrıca kafatası yüksekliği ve ağız genişliği, çatık dil ve kafatası yüksekliği, yüksek damak ve kafatası yüksekliği ve yüksek damak ve çatık dilin şizofreni ile anlamlı iki madde etkileşimi gösterdiğini belirlemişlerdir. Yüksek damak, kafatası yüksekliği ve ağız genişliği arasında üç maddelik zayıf bir etkileşim bulunmuştur. Sonuç olarak, iki MÖ yönteminin, MPA'ların birincil ve etkileşim etkilerini kullanarak şizofreni riskini değerlendirmede iyi bir tahmin yeteneği gösterdiği bulunmuştur.

De Miras ve diğerleri (2023) çalışmada, MÖ tekniklerinin şizofreni tanısına yardımcı olup olamayacağını değerlendirilmiş ve dinlenme durumu EEG verilerine dayanarak şizofreninin MÖ sınıflandırıcılarını elde etmek için bir işleme hattı önerilmiştir. EEG verilerinin kayan pencereleri üzerinde iyi bilinen doğrusal ve doğrusal olmayan ölçümleri hesaplanılmış, hastalar ve sağlıklı kontroller arasında daha iyi ayırım yapan ölçümleri seçilmiş ve bunları temel bileşen analizi yoluyla birleştirilmiştir. Bu bileşenler son olarak beş standart MÖ algoritmasında özellik olarak kullanılmıştır: k-en yakın komşular (KNN), LR, DT, RF ve SVM. Çalışma sonucundaki sınıflandırma sonuçlarında: SVM (0,89), RF (0,87), LR (0,86), kNN (0,86) ve DT (0,68). Sonuçlar, dinlenme durumu EEG verileri üzerinde önerilen işleme hattının, standart MÖ algoritmalarının şizofreni hastalarını sağlıklı deneklerden ayırmada çok verimli bir şekilde performans göstermesine olanak tanıyan bir dizi özelliği kolayca hesaplayabildiğini ve seçebildiğini göstermektedir.

Soria ve diğerleri (2023) araştırmasında, EEG sinyallerini analiz etmek için eXtreme Gradient Boosting (XGBoost) algoritmasını temel alan bir MÖ yöntemi önermektedir. Çalışma, önerilen XGBoost tabanlı yaklaşımın performansını diğer dört denetimli MÖ sistemiyle karşılaştırmaktadır. Sonuçlara göre önerilen XGBoost tabanlı yöntem, 0,94 AUC değeri ve 0,94 doğruluk değeriyle karşılaştırılan diğer yöntemleri geride bırakan bir performans sergilemektedir.

Bagherzadeh ve diğerleri (2022) çalışmalarında, çok kanallı EEG sinyallerinde şizofreni tespiti için hibrit derin öğrenme çerçevesi sunmaktadır. İlk olarak, etkili bağlantı matrisi, her bir denek için 19 EEG kanalından gelen beyin bilgi akışı açısından yönlendirilmiş nedensellikleri tahmin eden Transfer Entropi (TE) yöntemine dayalı olarak ölçülür. Daha sonra, TE etkili bağlantı elemanları renklerle temsil edilir ve aynı anda EEG sinyallerinin zaman ve mekansal bilgilerini temsil eden 19×19 bağlantı görüntüsü oluşturulmaktadır. Oluşturulan görüntüler, Transfer Öğrenme (TL) modelleri olarak VGG-16, ResNet50V2, InceptionV3, EfficientNetB0 ve DenseNet121 adlı beş önceden eğitilmiş Evrişimli Sinir Ağları (CNN) modeline beslenmek üzere kullanılır. Son olarak, en ayırt edici uzaysal-zamansal özelliklerin çıkarılması için Uzun Kısa Süreli Bellek (LSTM) modeliyle donatılmış bu TL modellerinden gelen derin özellikler, 14 sağlıklı kontrolden 14 şizofreni hastasını sınıflandırmak için kullanılır. Sonuçlar, önceden eğitilmiş CNN-LSTM modellerinin hibrit çerçevesinin, önceden eğitilmiş CNN modellerinden daha yüksek doğruluk elde ettiğini göstermektedir. En yüksek ortalama doğruluk ve F1 puanı, sırasıyla %99,90 ve %99,93'e eşit 10 katlı çapraz doğrulama yöntemi aracılığıyla EfficientNetB0-LSTM modeli kullanılarak elde edilmiştir. Bu nedenle, EEG sinyallerinden ve önceden eğitilmiş CNN-LSTM modellerinden beyin etkili bağlantı görüntülerinin hibrit çerçevesinin üstün performansı, önerilen yöntemin sağlıklı kontrollerden şizofreni hastalarını tespit etme konusunda oldukça yetenekli olduğunu göstermektedir.

Shoeibi ve diğerleri (2021) çalışmalarında, EEG sinyalleri ile otomatik şizofreni tanısı için çeşitli derin öğrenme tabanlı yöntemler denemektedirler. Sınıflandırma adımı iki farklı yaklaşım ele alınmaktadır. İlki geleneksel makine öğrenme yöntemleri olan SVM, K-En Yakın Komşu, Karar Ağacı, Naive Bayes, RF, İkinci yaklaşım ise LSTM, 1D-CNN ve 1D-CNN-LSTM'dir. En iyi performansı CNN-LSTM modeli %99,25li bir doğruluk yüzdesi ile ulaşmaktadır.

Aslan ve Akın (2022) çalışmalarında, EEG sinyallerinden şizofreniyi otomatik tespit edebilmek için geleneksel makine öğrenmesi algoritmalarından farklı olarak eğitim için gerekli öznitelikleri otomatik olarak çıkarılmaktadır. EEG sinyallerinin zaman-frekans özniteliklerini elde etmek için Sürekli Dalgacık Dönüşümü kullanılmaktadır. VGG-16 kullanılarak bir CNN modeli oluşturulmuştur. Önerdikleri model 0.99 doğruluk sonucu vermektedir.

Grover ve diğerleri (2023) çalışmalarında, EEG aktivitesinden tahmini beyin bağlantı endekslerinin çok modlu bir füzyonuna dayanan yeni ve güvenilir bir şizofreni tanı modeli olan Schizo-Net'i sunmaktadırlar. İlk olarak EEG aktivitesinden istenmeyen artefaktları gidermek için ön işlemden geçer. Sonrasında pencere EEG sinyallerinden altı beyin bağlantı endeksi tahmin edilir ve altı farklı derin öğrenme mimarisi eğitilmektedir. Bu çalışma, şizofreni için çok sayıda beyin bağlantı endeksini ele almakta olan ilk çalışma olma özelliğine sahiptir. Ayrıca, beyin bağlantısında meydana gelen şizofreni ile ilgili değişiklikleri tanımlayan ayrıntılı bir çalışma da gerçekleştirilmektedirler ve hastalığın biyobelirteçlerini belirlemek için bu bağlamda BCI'nin hayati önemini belirtmektedirler. Schizo-Net %99.84 doğruluk oranı ile sonuç vermektedir.

3.2.3 Dikkat Eksikliği ve Hiperaktivite Bozukluğu Literatür Taraması

Zou ve diğerleri (2017) DEHB sınıflandırması üzerine yaptıkları çalışmada MRI özelliklerinin yerel mekansal modellerini araştırmak için 3 boyutlu (3D) bir CNN modeli tasarlamaktadır ve %69.15'lik doğruluğa ulaşılmaktadır.

Riaz ve diğerleri (2018) DEHB sınıflandırması üzerine yaptıkları çalışmada fMRI verilerini sınıflandırmak için DÖ'nin temsili öğrenme yeteneğini kullanan uçtan uca bir model önerilmekte ve önerilen derin FMRI modeli üç aşadan oluşmaktadır: Bir özellik çıkarıcı, bir benzerlik ağı ve bir sınıflandırma ağı. Model girdi olarak fMRI ham zaman serisi sinyallerini almakta ve tahmin edilen etiketleri çıkarmaktadır. Geri yayılım kullanılarak uçtan uca eğitilmektedir. Model %76.6 doğruluk elde etmektedir.

Deshpande ve diğerleri (2015) DEHB sınıflandırması için tam bağlantılı kademeli yapay sinir ağı mimarisi (FCC ANN) ile SVM kıyaslamışlardır. FCC ANN,

kullanılan özelliğe bakılmaksızın doğruluk açısından SVM ile karşılaştırıldığında çok iyi performans göstermektedir ve %90 başarı elde etmektedir. Ayrıca en ayırt edici bağlantısallık özellikleri DEHB'nin patofizyolojisi hakkında bilgi sağlamaktadır ve DEHB'de sol orbitofrontal korteks ve çeşitli serebellar bölgeleri içeren bağlantının azaldığını ve değiştiğini göstermektedir.

Alsharif ve diğerleri (2024) araştırma projesinde, DEHB tanısı konan kişilerden alınan olayla ilgili potansiyel verilerin yanı sıra DEHB olmayan kişilerden oluşan bir kontrol grubunun birleşiminden oluşmaktadır. Bu çalışmada, DEHB hastalarından eğitim amacıyla toplanan veri setini kullanarak DT, RF, SVM ve çok katmanlı algılayıcıya (MLP) dayalı yeni MÖ modelleri sunmaktadır. %91 gibi yüksek bir doğruluk oranına ulaşan SVM bağlamında önemli performans sonuçları görülmektedir. MLP'nin doğruluk oranı %89'dur. Ayrıca RF modeli %87'lik bir doğruluk oranı göstermektedir. Son olarak DT modeli %78'e varan oranda doğru sonuçlar ortaya çıkarmaktadır. Yukarıda belirtilen sonuçlar, DEHB tanısı ve kategorizasyonunda önemli düzeyde doğruluk elde etmede modern hesaplamalı çerçevelerin kullanım yöntemlerinin etkinliğini ve yeteneğini vurgulamaktadır.

Yoo ve diğerleri (2024) çalışmalarında DEHB'deki NP eksiklikleri yansıtan görevlerden MÖ ve göz izleme özelliklerini kullanarak DEHB için bir tarama modeli geliştirmeyi amaçlamaktadırlar. Göz izleme verileri, seçici dikkat, çalışma belleği ve tepki engellemeyi ölçen beş davranışsal görevin performansı sırasında dijital bir cihaz kullanılarak toplanılmaktadır. DEHB için ilgili göz izleme özelliklerini seçmek ve ardından DEHB'yi tipik gelişim göstergeden sınıflandıran optimal bir model oluşturmak için MÖ kullanılmaktadır. Ekstra ağaç ve RF sınıflandırıcılarını birleştiren yumuşak oylama modeli, yalnızca göz izleme özelliklerini kullanarak DEHB'yi belirlemede yüksek doğruluk (%76,3) göstermektedir. Yalnızca göz izleme özelliklerini kullanan modelin Gelişmiş Dikkat Testi veya Stroop testini kullanan modellerle karşılaştırılması, eğri altındaki alanda (AUC) anlamlı bir fark göstermemektedir.

Saurabh ve diğerleri (2024) çalışmalarında, dinlenme durumu fonksiyonel manyetik görüntüleme (rs-fMRI) verilerini dikkate almakta ve 40 deneğin (20 DEHB ve 20 sağlıklı kontrol) vokselle boyutu kan oksijen düzeyine bağlı (BOLD) sinyali aracılığıyla fonksiyonel bağlantısını analiz etmektedirler. Bu BOLD sinyalleri işlevsel

olarak karşılık gelen dinlenme durumu ağlarıyla (RSN) ilgilidir. Çalışmalarında, RSN'nin aktif bölgesi içinde tanımlanan vokseller aracılığıyla DEHB'nin sınıflandırılmasını otomatikleştiren, değiştirilmiş DÖ tabanlı çift yönlü uzun kısa süreli bellek (BLSTM) modeli önermektedirler. Başlangıçta, RSN'nin 28 aktif bölgesini ve 176 zaman damgasına sahip 40 deneğin davranışsal verilerinin zaman serisini göstermektedirler. Deneysel sonuçlar, önerilen modelin %87.5 sınıflandırma doğruluğuna ulaşarak diğer birçok modelden daha iyi performans gösterdiğini göstermektedir.

3.2.4 Bipolar Bozukluk ve Depresyon Literatür Taraması

Kessler ve diğerleri (2016) yaşam boyu MDB olan 1000'den fazla katılımcının sunduğu temel raporları kullanarak daha sonra temel raporlardan 10 ila 12 yıl sonra değerlendirilen sonuçları tahmin etmek için MÖ algoritmalarını kullanılmaktadır. MÖ modeli ile geleneksel LR modelleriyle karşılaştırdılar ve sonuç olarak kroniklik için 0,63 ve diğer sonuçlar için 0,71 ila 0,76 olan AUC ile geleneksel LR modellerinden daha iyi performans göstermektedir.

Rubin-Falcone ve diğerleri (2018) BB ve MDB rahatsızlığına sahip kişilerden elde edilen veriler ile SVM kullanarak bir çalışma yapmışlardır. Test sonuçlarına göre 26 BB hastasının 19'u ve 26 MDB hastasının 20'si, %75 birleştirilmiş doğrulukla doğru şekilde tanımlandı. Sonuçlarına göre manik veya hipomanik bir atak ortaya çıkmadan önce BB öngörmek için bölgesel gri madde hacminin daha fazla araştırılmasını önerilmektedir.

Guo ve diğerleri (2014) ilaçsız depresyon hastası olan 36 hastadan ve 27 sağlıklı kontrolden dinlenme durumu fMRI verileri toplamışlardır ve sınıflandırma araştırması için yapay sinir ağı algoritması uygulanmıştır. Algoritmanın başarı oranı %90.5'tir. Sonuçlar, beyin ağı metriklerinin MÖ araştırmalarında etkili bir özellik olarak kullanılabileceğini göstermiştir. Deneysel bulgular, istatistiksel anlamlılığın, beyin ağı ölçümlerinin seçiminin etkili bir niceliksel göstergesi olduğunu ve depresyonun klinik tanısına yardımcı olabileceğini göstermektedir.

Gao ve diğerleri (2017) fMRI verilerinden çıkarılan bağımsız bileşenlerin ayırt edici bilgiler taşıdığı ve sınıflandırma için kullanılabileceği kanıtlanmaktadır. Burada, her birey için doğrusal altuzaylar oluşturmak amacıyla birden fazla fMRI bağımsız bileşenlerini kullanan ve sınıflandırıcılar için girdi olarak kullanılan önceki bir yöntemi genişletilmektedir. Farklı konular arasındaki benzerlik matrisi ilk önce ana açının mesafe ölçüsü kullanılarak hesaplanır ve bu daha sonra 37 BB ve 36 MDB arasında SVM sınıflandırması için çekirdek uzayına yansıtılmaktadır. Uygulamada, fMRI'nin en ayırt edici bağımsız bileşen kombinasyonlarını seçmek ve nihai tanıyı çoğunluk oylama mekanizmasıyla belirlemek için 20 bağımsız bileşen üzerinde ileri seçim tekniğini ve iç içe 10 kat çapraz doğrulamayı benisemektedirler. İnsan verilerine ilişkin sonuçlar iyi bir performans elde ettiğini %93 oranında ve esas olarak prefrontal kortekste yer alan BB ve MDB hastalarını ayırt etmek için 5 ayırt edici fMRI bileşenini tanımladığını göstermektedir. Varsayılan mod ağı ve talamus onların ayırıcı tanısı olarak gösterilmektedir.

Wang ve diğerleri (2024) MDB tanısı için yaygın olarak kullanılmakta olan EEG verileri ile çalışmaktadırlar. EEG'nin veri kalitesi ve veri boyutunda bazı zorluklar bulunmaktadır. Bunlar: EEG toplama sırasında büyük miktarda gürültü kaçınılmazlığıdır ve bu da ham EEG'den ayırt edici özelliklerin çıkarılmasını zorlaştırır; Model eğitimi için yeterli ve çeşitli verileri toplamak amacıyla çok sayıda denek gerekmektedir. Her iki zorluk da özellikle DÖ yöntemlerinde aşırı uyum sorununa neden olmaktadır. Çalışmalarında, EEG kullanarak MDB tanısı için difüzyon tabanlı bir DÖ çerçevesi olan DiffMDD'yi önermişlerdir. Özellikle, İleri Yayılma Gürültülü Eğitim Modülünü tasarlayarak modelin sağlamlığını artırmak için gürültüyle alakasız daha fazla özellik çıkartmışlardır. Çalışmada kullanılan iki veri setinden bir tanesi için %94, diğerinden %80 doğruluk elde edilmiştir.

Uyulan ve diğerleri (2021) çalışmalarında MDB için elektroensefalografi (EEG) tabanlı bir tanı modeli, derin CNN yaklaşımıyla birlikte gelişmiş hesaplamalı sinirbilim metodolojisi kullanılarak oluşturmaktadırlar. EEG kayıtları, MDB hastalarını ve sağlıklı kontrolleri ikiye ayırmak amacıyla ResNet-50, MobileNet, Inception-v3 olmak üzere 3 farklı derin CNN yapısı modellenerek analiz edilmektedir. Ayrıca frekans bazlı da bir çalışma yapılmıştır. Çalışma sonuçlarına göre Delta frekansı diğer frekanslara oran ile en fazla doğruluk sonucu çıkarmıştır. Delta frekansı

için en yüksek doğruluk oranını çıkartan model ise ResNet-50 olmuştur. Sol ve sağ beyin üzerinde yapılan testler sonucunda sağ beyin daha fazla doğruluk oranı çıkarmıştır. Sağ beyin için en yüksek doğruluk oranı %92.66 ile MobileNet iken sol beyin için en yüksek doğruluk oranı da %89.33 oranı ile yine MoileNet'tir.

Mikolas ve diğerleri (2024) önceden kayıtlı bir protokolün ardından, yedi çalışma bölgesinden ($N = 276$) kortikal kalınlığını kullanarak bireyleri BB için tahmini risklerine göre sınıflandırmak üzere doğrusal SVM eğitilmiştir. Riski son teknolojiye sahip üç değerlendirme aracını (BPSS-P, BARS, EPIbipolar) kullanarak tahmin edilmiştir. BPSS-P için SVM, 10 kat çapraz doğrulamada Cohen's 0,235 (%95 CI 0,11–0,361) performansa ve %63,1 (%95 CI 55,9–70,3) bir doğruluk elde etmişler.

Metin ve diğerleri (2024) 169 BB ve 45 kontrolün EEG sinyalleri artefaktlardan temizlendi ve iki farklı DL yöntemi kullanılarak işlenmiştir: uzun-kısa süreli bellek (LSTM) ile birleştirilmiş tek boyutlu evrimsel sinir ağı (1D-CNN) ve iki boyutlu evrimsel sinir ağı (2D-CNN) kullanılmaktadır. Ek olarak, BB ve kontrol gruplarından elde edilen Sınıf Aktivasyon Haritaları (CAM'lar), bir görüntüde belirli bir sınıfı belirtmek için ayırt edici bölgeler elde etmek amacıyla kullanılmaktadır. Grup tanımlamaları 2D-CNN yöntemiyle %95,91 genel doğrulukla doğrulanmaktadır; çok yüksek duyarlılık ve daha düşük özgüllük göstermektedir. 1D-CNN + LSTM yönteminden elde edilen genel doğruluk %93'tür. Ayrıca F4, C3, F7 ve F8 elektrot aktivitelerinin BB grubu tespit etmek için baskın özellikler ürettiğini de bulmuşlardır.

Wang ve diğerleri (2024) Bu çalışmada, erken başlangıçlı BB'yi tahmin etmeye yönelik klinik notlar da dahil olmak üzere büyük ölçekli elektronik sağlık kaydı verilerini kullanarak MÖ modelleri geliştirmişlerdir. İki ağaç tabanlı modelin, RF ve hafif gradyanı artırma makinesinin (LGBM) farklı klinik ortamlarda (AUC altındaki alan RF için 0,76-0,88 ve 0,74-0,74-0,74-0,74-0,74-0,74) iyi ayırt edici performans elde ettiğini bulmuşlardır (LGBM için 0,89). Buna ek olarak, büyük ölçüde azaltılmış bir dizi özellik ile karşılaştırılabilir bir performansın elde edilebileceğini göstermişlerdir; bu da model doğruluğundan önemli ölçüde ödün vermeden hesaplama verimliliğine ulaşılabileceğini göstermektedir.

Karthik ve diğerleri (2021) BB ve şizofreninin örtüşen ve örtüşmeyen gen modellerini tanımlamak üzere Sıralamaya dayalı bir Gen Biyobelirteç Tanımlama ve

Sınıflandırma çerçevesi önerilmektedir. Bu deneyin sonucunda örtüşen genler olarak yedi biyobelirteç belirlenmektedir. Ayrıca, örnekleri ayırt etmek için özellik alt kümeleri olarak BB ve şizofreni veri kümesinde 60 ve 68 bilgilendirici gen biyobelirteçleri tanımlanmaktadır. Bozuklukların tanısal doğruluğunu artırmak için örtüşen genler ortadan kaldırılmaktadır. Önerilen sistemin performansı standart mevcut MÖ algoritmaları ile değerlendirilmektedir. Önerilen bu çerçeve, DNN modeliyle BB ve ŞB veri kümesinde %97,01 ve %95,65 doğruluk elde edilmiştir.

Zheng ve diğerleri (2022) çalışmasında, BB olan hastalar için MÖ ve DÖ tekniklerine dayalı, kişiselleştirilmiş bir Valproik asit/sodyum valproat ilaç modeli oluşturmayı amaçlamaktadırlar. Bir özellik alt kümesini seçmek için sıralı ileri seçim algoritması uygulanmıştır ve eksik değerlerin enterpolasyonu için RF kullanılmıştır. Daha sonra XGBoost, LightGBM, CatBoost, RF, GBDT, SVM, LR, ANN ve TabNet kullanan dokuz model karşılaştırılmış ve en iyi performansa sahip bireyselleştirilmiş ilaç modelini oluşturmak için CatBoost seçilmiştir (doğruluk = 0,85, AUC = 0,91), duyarlılık = 0,85 ve özgüllük = 0,83). Son olarak, karışıklık matrisi, günlük 0,5 g VPA dozunu tahmin etmenin %55,56 kesinliğe ve %83,33 geri çağırma oranına sahip olduğunu ve günlük 1 g VPA dozunu tahmin etmenin %95,83 kesinliğe ve %85,19 geri çağırma oranına sahip olduğunu göstermektedir. Sonuç olarak, BB olan hastalar için CatBoost'a dayanan kişiselleştirilmiş VPA ilaç modeli, klinisyenlere en uygun ilaç rejimini önerme konusunda rehberlik sağlayan iyi bir tahmin yeteneğine sahip olduğu belirtilmektedir.

Allayla ve diğerleri (2024) çalışmalarında, büyük veriden anlamlı bir sonuç çıkarmak ve sağlık durumu risklerinin erken tespiti, intihar düşüncelerinin sayısını önleme ve azaltmak için büyük veri mimarisine dayalı yeni bir metodoloji önermektedirler. Ham veriler ön işleminden geçirildikten sonra Naive Bayes, Lojistik Regresyon, LinearSVC, Karar Ağaçları, Rastgele Orman ve MLP kullanılarak sınıflandırılmaktadır. Ayrıca tüm bu modeller özellik çıkarımı olarak Unigram + TF-IDF, Unigram + CV-IDF, Biagram + CV-IDF ve Unigram + Biagram + CV-IDF yöntemleri olmak üzere 4 farklı özellik çıkarım yöntemleri de karşılaştırılmıştır. MLP modeli Unigram + Biagram + CVC-IDF özellik çıkarımı yöntemi ile %93,47 doğruluk oranı sonucu ile en başarılı sonucu vermektedir.

Eswar ve diğerleri (2023) çalışmalarında, depresif gönderilerin özelliklerini analiz etmek için metnin gerçek semantiğini tutarken metnin gömülmesini farklı bir biçime dönüştürerek gizlilik sağlayan bir dönüşüm bloğu geliştirilmiştir. Dönüşüm bloğu, derin öğrenme modellerinin depresyonun dilsel belirteçlerini tanımlamasına olanak tanır ve depresyon tespitinin performansında önemli bir iyileşme sağlar. Dönüşüm bloğu BERT, Bi-LSTM, LSTM, Yığılmış LSTM ve kendi önerdikleri Fourier Dönüşümlü Depresyon Tespiti (FTDD) derin öğrenme modellerine dahil edilmiştir ve sonuçları birbirleri ile karşılaştırılmıştır. En başarılı doğruluk oranı 0.95 oranı ile önerilen FTDD modelidir.

Gupta ve Pirzada (2023) çalışmasında, sosyal medya gönderilerinden analiz yapılarak depresyonu belirlemede yardımcı olacak bir model önermektedirler. Çalışmalarında Küresel Kelime Gösterimi Vektörleri (GLOVE) yerleştirerek bir LSTM modeli önermektedirler. Önerilen yöntem %93 doğruluk elde edilmiştir.

3.2.5 Demans ve Alzheimer Literatür Taraması

Javeed ve diğerleri (2024) demansı tahmin etmek için hastanın elektronik sağlık kayıtlarını kullanan istatistiksel ve MÖ yöntemlerine dayanan hibrit bir teşhis sistemi geliştirmişlerdir. Sınıflandırma için beş farklı MÖ modeline dayalı bir topluluk oylama sınıflandırıcısı geliştirilmiştir: DT, Naive Bayes, LR, SVM ve RF. ML modelinin aşırı uyumu sorununu çözmek için önerilen teşhis sisteminin performansını değerlendirmek amacıyla bir çapraz doğrulama yaklaşımı kullanılmaktadır. Deney sonuçlarına göre, önerilen tanı yöntemi %98,25 ile en iyi doğruluğun yanı sıra %97,44 duyarlılık, %95,744 özgüllüğe ulaşılmaktadır.

Nyholm ve diğerleri (2024) çalışmalarında, MÖ'nin demansı tahmin edip edemeyeceğini ve hangi uyku bozukluğu faktörlerinin demansı etkilediğini incelemeyi amaçlamaktadır. Çalışmada beş MÖ algoritması (gradyan artırma, LR, Gaussian Naive Bayes, RF ve SVM) ve İsveç Ulusal Yaşlanma ve Bakım Çalışması - Blekinge'den İsveç'teki yaşlı nüfusa (60+) ilişkin verileri kullanılmaktadır. Her algoritma, doğruluğu kontrol etmek için Brier skorundan ve demansı etkileyen faktörleri incelemek için özellik öneminden oluşan sonuçları elde etmek için 10 katlı katmanlı çapraz doğrulama kullanılmaktadır. LR, demans ve uyku bozuklukları

arasında bir ilişki bulunmuştur. Ancak çalışmadaki özellikler açısından bu durumun önemsiz olduğunu söylenmiştir. Gradient boosting %92,9 doğruluk oranı, 0,926 f1 skoru, 0,974 ROC AUC ve 0,056 Brier skoru ile en doğru algoritma olduğunu yazmaktadır.

Zhang ve diğerleri (2024) küçük bir dizi mortalite öngörücüsü kullanarak çok faktörlü XGBoost modelleri oluşturmuşlardır ve demans tipine özgü modellerle katmanlı analizler gerçekleştirmişlerdir. Modelleri, 1, 3, 5 ve 10 yıllık eşiklerin tümü için alıcı çalışma karakteristik eğrisinin (ROC) altında 0,82'nin üzerinde bir alana ulaşmaktadır.

Waldo-Benitez ve diğerleri (2024) çalışmada, Alzheimer sınıflandırması için, Açık Erişim Görüntüleme Çalışmaları Serisinde mevcut bir dizi temsili MRI sagittal görüntüden öğrenmek üzere formüle edilen farklı CNN'ler analiz edilmiştir. Demanslı ve yaşları 60 ila 96 arasında olan 64 demanslı denek) ve Alzheimer Hastalığı Nörogörüntüleme Girişimi veri kümeleri. Tüm CNN'ler, 56 ± 4 ortalama doğrulama doğruluğu ile en iyi performansı sergileyen mimari olan VGG-16 varyantı olan son teknoloji MÖ yöntemleriyle karşılaştırılmıştır ve bağımsız çalıştırmalardaki değişkenliği ölçmek için bir önyükleme stratejisiyle değerlendirilmiştir. Bu sonuç, farklı MÖ yöntemleriyle şu ana kadar bildirilen en iyi performansı (< 60) doğrulamıştır. Düşük doğruluk, sorunun ciddiyetini kanıtlar ve OASIS-1 veya ADNI-2 veri kümelerinden önceden işlenmiş ve iyi karakterize edilmiş MRI eksenel görüntüleri ile ulaşılan daha yüksek doğruluk seviyeleriyle (%97'ye kadar) tezat oluşturmuştur. Böylece, Alzheimer sınıflandırması için CNN'leri eğitirken hangi MRI düzleminin dikkate alınması gerektiği konusunda ilginç bir tartışma açılmıştır ve sagittal MRI görüntüleri ile eğitilmiş CNN'lerin performansının iyileştirilmesi için geniş bir alan bırakılmaktadır.

Gajjar ve diğerleri (2024) çalışmasında, Alzheimer ve Parkinson hastalıklarıyla ilgili demans merkezli MRI taramalarına odaklanarak gerçekçi sentetik veriler oluşturmak için en son hesaplama teknolojilerini ve akıllı yöntemleri araştırılmıştır. Araştırma, Üretken Rekabetçi Ağlar (GAN'lar), Değişken Otomatik Kodlayıcılar ve Difüzyon Modellerini inceleyerek bunların sentetik MRI taramaları oluşturmadaki etkinliğini karşılaştırılmıştır. Çalışma aynı zamanda üretken metrikleri doğrulayan bir sınıflandırma çalışmasını da dahil ederek yeni bir yön ortaya

koymaktadır. DÖ mimarisi olan DenseNets, hastalık tespitinde ResNets'e kıyasla üstün performans sergilendi. Her iki modeli de difüzyon modelleri tarafından oluşturulan görüntüler üzerinde eğitmek sonuçları daha da iyileştirilmiştir; DenseNet, Alzheimer ve Parkinson hastalığı tespitinde sırasıyla %80,84 ve %92,42 doğruluk elde edilmiştir.

Ávila-Jiménez ve diğerleri (2024) Alzheimer hastası olup olmadıklarını sınıflandırmak için demans hastalarından alınan klinik verileri kullanan bir DÖ modeli geliştirilmiştir. Model, diğer köklü MÖ teknikleriyle karşılaştırılarak test edilmiştir ve alfa değeri 0,05'ten küçük olan AUC açısından ve %89 doğruluk değeri ile daha iyi sonuçları vermektedir.

Hussain ve Shiren (2023) çalışmalarında MRI görüntülerinden özellik çıkarmak için havza segmentasyonu (Watershed Algoritması) ile zenginleştirilmiş RF, SVM ve CNN algoritmalarını kullanarak demansın dört aşamasını sınıflandırmak için bir yaklaşım önermektedirler. Bu algoritmaların yanısıra Watershed Algoritması kullanılarak modeller tekrar birbirleri ile karşılaştırılmıştır. Havza özelliklerine sahip SVM'nin diğer sınıflandırma yöntemlerini geride bırakarak %96,25'lik etkileyici bir doğruluk elde ettiğini ortaya koymaktadırlar.

Rahman ve diğerleri (2023) çalışmalarında, önerilen bir özellik çıkarma tekniğini içeren bir Makine Öğrenmesi yaklaşımı olan SVM kullanarak demans evrelerini kategorize etmek için MRI görüntüleri kullanmaktadırlar. MRI veri kümesindeki önemli bir sınıf dengesizliğini ele alan SMOTE tekniği, MÖ algoritmalarının uygulanmasından önce veri kümesi dengelemesi için kullanılmaktadır. Önerilen model 0.99 doğruluk sonucu başarısı göstermektedir.

Kaya ve Çetin-Kaya (2024) çalışmalarında demans hastalığının şiddetini sınıflandırmak üzere tasarlanmış CNN mimarilerinde, kıvrım katmanlarının, filtrelerin ve diğer hiperparametrelerin sayısı dahil olmak üzere hiperparametreleri ince ayarlamak için parçacık sürüsü optimizasyonuna dayalı bir algoritma önermektedirler. Önerilen model %99,53 doğruluk oranı ile sonuç vermektedir.

Deshpande ve diğerleri (2024) çalışmalarında, performansı optimize etmek için CNN ve LSTM ile Parçacık Sürüsü Optimizasyonu (PSO) kullanan bir hibrit model geliştirilmiştir. Çalışmada PSO+CNN-LSTM ve CNN-LSTM ve ayrı ayrı

karşılaştırılmaları yapılmaktadır. %98.13 doğruluk oranı ile en yüksek başarıyı PSO + CNN-LSTM hibrit modeli vermektedir.

Yılmaz (2023) çalışmasında, derin öğrenmenin doğru tanı için belirlenmiş standartları karşılama potansiyeline dair kanıt sağlamak için, demans şiddet seviyelerini tahmin etmek için açıklanabilir bir tanısal makine öğrenmesi modeli sunmaktadırlar. KNN ve SVM kullanılmaktadır ve karşılaştırma için CNN modeli kullanılmıştır. CNN modeli %99,9'luk bir doğruluk oranı elde etmektedir. CNN'in tahminlerini yorumlamak ve model şeffaflığını arttırmak için açıklanabilir yapay zeka tekniği SHapley Additive exPlanations (SHAP) kullanılmaktadır. Ayrıca yapay zekanın uygulanması, modelin tahminlerinin demansın iyi bilinen patolojik göstergelerinden etkilendiğini göstermektedir.

3.2.6 Anksiyete Literatür Taraması

Richter ve diğerleri (2024) araştırmasında Etki Alanı Kriterleri (RDoC) yaklaşımına uygun olarak, anksiyete ve depresyon semptomlarının şiddetini tahmin etmede doğrudan bozukluğa özgü ve tanı ötesi bilişsel kalıpları karşılaştırmaktadır. Seçici ve mekansal dikkat, beklenti, yorumlama, hafıza ve bilişsel kontrol önyargılarını hedef alan altı bilgisayarlı bilişsel-davranışsal testten oluşan bir dizi üzerindeki performanslarını analiz etmek için RF regresörleri kullanılmaktadır. Kaygıya özgü benzersiz önyargıların yanı sıra ortak kaygılı-depresif önyargı kalıpları da bulunmaktadır. Bu bilişsel önyargılar, semptom şiddetini tahmin ederken nispeten yüksek uyum oranları sergilemiştir (anket puanları ortak aralığı 0-60, MAE = 6,03, RMSE = 7,53). Yorumlama ve beklenti önyargıları, tüm diğer bireysel önyargıların ötesinde, semptomlarla en yüksek ilişkiyi sergilenmektedir.

Spinrad ve diğerleri (2024) çalışmasında, terapistlerin terapi seanslarında eylem önerileri atama ve gözden geçirme uygulamalarını ve bunun hastaların depresyon ve anksiyete sonuçlarıyla nasıl ilişkili olduğunu incelemektedirler. Genelleştirilmiş Tahmin Denklemleri modellemesini kullanarak, bu ölçüm ile danışanların depresyon ve kaygı puanlarındaki değişiklikler arasındaki ilişkiyi değerlendirilmektedir. Modelleri eylem önerilerini yakalamada %76, bunları incelemede ise %71,1 doğruluk elde edilmektedir. Başlangıçtaki depresyon puanı ile

inceleme yüzdesi arasında anlamlı bir etkileşim tespit edilmiştir ($p = 0,045$). Bu ilişkiye göre düzeltme yapıldığında inceleme yüzdesi, depresyon puanındaki azalmayla pozitif ve anlamlı bir şekilde ilişkilendirilmektedir ($p = 0,032$). Bu, terapideki eylem önerilerinin daha sık gözden geçirilmesinin, depresyon semptomlarında daha fazla iyileşme ile ilişkili olduğunu göstermektedir.

Aldayel ve diğerleri (2024) çalışmasında, EEG tabanlı kaygı tespiti için uygun özellik çıkarma ve MÖ algoritmalarının seçilmesinin önemini vurgulamaktadır. Farklı açıklama/etiketleme, özellik çıkarma ve sınıflandırma algoritmalarını araştırmışlardır. Kaygı durumlarını etiketlemek için Hamilton kaygı derecelendirme ölçeği (HAM-A) ve öz değerlendirme mankeni (SAM) olmak üzere iki ölçüm kullanılmıştır. EEG özellik çıkarımı için ayrık dalgacık dönüşümü (DWT) ve güç spektral yoğunluğunu (PSD) kullanılmıştır. Kaygı tespitinin doğruluğunu artırmak için RF, AdaBoost torbalama ve degrade torbalama gibi topluluk öğrenme yöntemlerini doğrusal diskriminant analizi (LDA), SVM ve k-en yakın dahil olmak üzere geleneksel sınıflandırma algoritmalarıyla karşılaştırmışlardır. Ayrıca farklı etiketleme (SAM ve HAM-A) ve özellik çıkarma algoritmaları (PSD ve DWT) kullanarak sınıflandırıcıların performansını değerlendirmişlerdir. Bulgularımız, HAM-A etiketleme ve DWT tabanlı özelliklerin tüm sınıflandırıcılarda sürekli olarak üstün sonuçlar verdiğini göstermektedir. Spesifik olarak, RF sınıflandırıcı %87,5 ile en yüksek doğruluğu elde edilmiştir ve onu %79 doğrulukla Ada takviyeli torbalama sınıflandırıcı izlemiştir. RF sınıflandırıcı doğruluk, kesinlik ve hatırlama açısından diğer sınıflandırıcılardan daha iyi performans göstermiştir.

Lee ve diğerleri (2024) çalışmalarında komorbid depresyon ve kaygıyı tanımlamak için tüketici düzeyinde bileğe takılan aktivite takip cihazlarından elde edilen zaman serisi aktivite takibi ve uyku verilerini doğrudan girerek uçtan uca DÖ modeli eğitiminin fizibilitesini araştırmışlardır. DÖ modelinin temel yapısı, karışık girdili verileri işleyecek depresyon ve anksiyete için çoklu etikete dayalı sınıflandırma gerçekleştirecek şekilde tasarlanmıştır. Zaman serisi verilerini işlemek için CNN ve uzun kısa süreli hafıza (LSTM) dahil olmak üzere çeşitli DÖ modelleri uygulanmıştır ve hiperparametrelerin performansları karşılaştırılarak model seçimi yapılmıştır. Aktivite izleme verilerine dayanan karma girdili bir DÖ modeli uygulayarak ResNet'te 0,0946 Hamming kayıp puanıyla, depresyon ve anksiyetenin çok etiketli

sınıflandırmasında önemli sonuçlar elde etti. Hiper parametre performansının karşılaştırılması ve CNN, LSTM ve ResNet gibi çeşitli DÖ modellerinin geliştirilmesi, zaman serisi veri işlemenin optimizasyonuna ve anlamlı sonuçların elde edilmesine katkıda bulunmaktadır.

Jacobson ve diğerleri (2021) araştırmalarında, klinik AB semptomlarını bildiren bir örnek üzerinden gelecekteki anksiyete semptomlarını tahmin etmek için akıllı telefon sensörlerinden ve kişiselleştirilmiş DÖ modellerinden yararlanılmıştır. Mevcut tasarım, zaman serileri içindeki zamansal kalıpları birleştirmek için tasarlanmış kişiselleştirilmiş DÖ modellerini ve LSTM modeli kullanılmaktadır. Akıllı telefon sensör verilerini kullanan kişiselleştirilmiş DÖ modelleri, kaygı semptomlarındaki toplam çeşitliliğin çoğunu ($R^2 = 0,748$) ve kişi içi varyasyonun büyük bir kısmını saat bazında (ortalama $R^2 = 0,385$) tahmin edilebildi. Bu sonuçlar, akıllı telefon sensör verilerini kullanan kişiselleştirilmiş DÖ modellerinin gelecekteki AB semptom değişikliklerini doğru bir şekilde tahmin edebildiğini göstermektedir.

Xie ve diğerleri (2020) çalışmasında, EEG tabanlı kaygı ve depresyonun tanınması için beyin ağları ile CNN işlevsel bağlantısını birleştiren yeni bir yaklaşım önerilmektedir. EEG verileri on sağlıklı kontrol ve on anksiyete veya depresyon hastasından oluşan deneklerden toplanmaktadır. Bu sayede %67,67 sınıflandırma doğruluğuna ulaşılmaktadır. Anksiyete ve depresyon hastalarında beyin ağlarının işlevsel bağlantısının ve DÖ teknolojisinin EEG'de uygulanmasının daha fazla araştırılmasının yolunu göstermektedir.

Latubessy ve diğerleri (2024), çalışmasında Ağırlıklı Naive Bayes modelini test etmek için anksiyete oyuncularını veri kümesi kullanılmıştır. Daha sonra aynı veri kümesi kullanılarak Gauss Naive Bayes, Multinomial Naive Bayes ve Kategorik Naive Bayes modelleri ile karşılaştırma yapılmaktadır. Karşılaştırma sonucunda %99.22 doğruluk oranı ile Ağırlıklı Naive Bayes modeli en yüksek oranı vermektedir. Gaussian Naive Bayes %91.13, Kategorik Naive Bayes %91.59 ve Multinomial Naive Bayes %61.10 doğruluk oranı vermektedir.

Gharpure ve diğerleri (2022), çalışmasında oyunların oyuncular üzerindeki kaygı etkisini araştırmak için anksiyete oyuncularını veri kümesi üzerinde C-Destek Vektör Makinesi (SVC) ve Çok Katmanlı Algılayıcı (MLP) modelleri

kullanılmaktadır. MLP 0.881 doğruluk oranı ile SVC'nin 0.878 doğruluk oranından daha yüksek bir sonuç vermektedir.



4. MATERİYAL VE YÖNTEM

4.1 Yapay Zeka

YZ kökleri, Alan Turing ve John McCarthy temelini attığı 20. yüzyılın ortalarına kadar uzanmaktadır. Turing'in "evrensel makine" kavramı ve McCarthy'nin "yapay zeka" terimini türetmesi onlarca yıllık araştırma ve geliştirmenin yolunu açmıştır. İlk YZ sistemleri kural tabanlı yaklaşımlara ve sembolik akıl yürütmeye odaklanmış ve 1970'lerde ve 1980'lerde uzman sistemlerin ve kural tabanlı uzman sistemlerin geliştirilmesiyle sonuçlanmıştır. Ancak hesaplama gücü ve veri kullanılabilirliğindeki sınırlamalar bu dönemde ilerlemeyi engellemiştir.

20. yüzyılın sonlarında MÖ'nin ortaya çıkışı YZ alanında devrim yaratmıştır. Sinir ağları, genetik algoritmalar ve Bayes ağları gibi teknikler, sistemlerin verilerden öğrenmesini ve zaman içinde performanslarını geliştirmesini sağlamıştır. Algoritmalarındaki çığır açıcı gelişmeler, donanımdaki, özellikle de grafik işlem birimlerindeki (GPU'lar) ilerlemelerle birleştiğinde, YZ yeteneklerinin hızla genişlemesini tetiklemiştir. 21. yüzyıl, verilerden üst düzey özellikler çıkarmak için çok katmanlı sinir ağlarını kullanan, MÖ'nin bir alt alanı olan DÖ'nin yükselişine tanık olmuştur. DÖ, YZ yeni boyutlara taşıyarak görüntü tanıma, doğal dil işleme ve diğer karmaşık görevlerde çığır açıcı gelişmelere olanak sağlamıştır.

YZ, tıp alanında teşhis, tedavi ve hasta bakımında devrim yaratan çığır açıcı bir güç olarak ortaya çıkmıştır. Çok miktarda tıbbi veriyi analiz etme ve karmaşık kalıpları ortaya çıkarma yeteneğiyle YZ, klinik karar alma sürecini geliştirme, sonuçları iyileştirme ve sağlık hizmeti sunumunu dönüştürme potansiyeline sahiptir.

YZ tıpta en öne çıkan uygulamalarından biri, büyük veri kümeleri üzerinde eğitilmiş algoritmaların, radyologlara tıbbi görüntüleri daha doğru ve verimli bir şekilde yorumlamada yardımcı olabileceği tanısal görüntülemedir. YZ destekli sistemler, X-ışınları, MRI'lar ve BT taramalarındaki anormallikleri tespit ederek kanser, kardiyovasküler rahatsızlıklar ve nörolojik bozukluklar gibi hastalıkların erken teşhisini kolaylaştırabilir. Üstelik YZ algoritmaları, görüntüleme verilerine dayanarak

hastalığın ilerleyişini ve tedavi yanıtını tahmin edebiliyor ve böylece bireysel hastalara göre kişiselleştirilmiş tedavi planlarına olanak tanımaktadır.

Bilgisayar bilimi ve teknolojisi alanında YZ, insan zekasını simüle edebilen makineler geliştirme isteğini somutlaştıran bir temel kavram olarak durmaktadır. YZ, makinelerin çevrelerini algılamasını, akıl yürütmesini, deneyimlerden öğrenmesini ve özerk kararlar almasını sağlamayı amaçlayan geniş bir teknik ve metodoloji yelpazesini kapsamaktadır. YZ daha geniş kapsamı içinde, MÖ ve DÖ son yıllarda önemli ölçüde dikkat çeken ve dönüştürücü ilerlemeleri katalize eden iki önemli alt alanı temsil etmektedir.

4.2 Makine Öğrenmesi


YZ bir alt kümesi olan MÖ, bilgisayarların açıkça programlanmadan verilerden öğrenmesini sağlayan algoritmaların ve modellerin geliştirilmesine odaklanmaktadır. MÖ, bilgisayarların verilerden öğrenmesine ve açık programlama olmadan tahminlerde bulunmasına veya kararlar almasına olanak tanıyan, bilgisayar bilimlerinde dönüştürücü bir paradigma olarak ortaya çıkmaktadır. MÖ algoritmaları, önceden tanımlanmış kurallara veya talimatlara güvenmek yerine verileri yinelemeli olarak analiz eder, kalıpları belirler ve verilerin temel istatistiksel özelliklerine dayalı olarak tahminler veya kararlar vermektedir. Geleneksel kural tabanlı programlamadan veriye dayalı öğrenmeye yönelik bu paradigma değişimi, görüntü tanıma, doğal dil işleme ve tahmine dayalı analitik dahil olmak üzere çeşitli alanlarda atılımları tetiklemektedir.

MÖ problemlerini çözmek için 4 farklı öğrenme yöntemi ile karşılaşılmaktadır. Bunlar sırasıyla : Denetimli Öğrenme, Denetimsiz Öğrenme, Yarı Denetimli Öğrenme ve Pekiştirmeli Öğrenmedir (Tafralı 2022).

4.2.1 Denetimli Öğrenme

Denetimli öğrenme, algoritmaların tahminlerde bulunmak veya kararlar almak için etiketli verilerden öğrendiği, MÖ temel bir paradigmadır. Denetimli öğrenme

algoritması için etiketli veri kümesi kullanılmaktadır. Denetimli öğrenme algoritması etiketli eğitim verilerinin girdi özelliklerini çıktı verisi ile eşleştirmek için en optimal fonksiyonu bulmak ve en iyi tahmini yapmak için çalışmaktadır. Algoritmanın amacı, sağlanan örneklerle dayanarak girdilerden çıktılara bir eşlemeyi öğrenmek, böylece genelleştirebilmek ve görünmeyen veriler üzerinde tahminler veya kararlar alabilmektir. Denetimli MÖ şeması Şekil 4.1’de bulunmaktadır.



Şekil 4.1: Denetimli MÖ şeması (Turhost 2021).


Denetimli öğrenme çoğunlukla regresyon ve sınıflandırma problemleri için kullanılmaktadır. Regresyon problemlerinde algoritma sürekli değerleri tahmin eder. Örneğin ev fiyatlarını, hisse senedi fiyatlarını veya sıcaklığı tahmin etmek gibi. Sınıflandırma görevlerinde algoritma ayrı etiketleri veya kategorileri tahmin etmektedir. Örneğin, e-postaları spam veya spam değil olarak sınıflandırmak veya görsellere dayalı olarak hayvan türlerini belirlemek gibi.

Regresyon problemleri için sık kullanılan algoritmalar: Doğrusal Regresyon, Polinom Regresyon, Destek Vektör Regresyonu (SVR). Sınıflandırma problemleri için sık kullanılan algoritmalar: LR, DT, KNN, SVM ve Naive Bayes.

4.2.2 Denetimsiz Öğrenme

Denetimsiz öğrenme, MÖ denetimli öğrenmeden farklı bir başka temel paradigmadır. Denetimsiz öğrenmede algoritmanın görevi, etiketlenmemiş verilerdeki

kalıpları veya yapıları bulmaktır. Denetimli öğrenmenin aksine, verilerle ilişkilendirilmiş önceden tanımlanmış etiketler yoktur ve algoritmanın, açık bir rehberlik olmaksızın verilerin temel yapısını veya dağılımını temsil etmeyi öğrenmesi gerekmektedir. Denetimsiz MÖ şeması Şekil 4.2’de bulunmaktadır.



Şekil 4.2: Denetimsiz MÖ şeması (Turhost 2021).

Denetimsiz öğrenmede veriler yorumlanarak aralarında bir ilişki bulunmaktadır (Candan 2021). Kümeleme, boyut azaltma ve anomali tespiti için denetimsiz öğrenme kullanılmaktadır. Denetimsiz öğrenmedeki birincil görevlerden biri, algoritmanın benzer örnekleri özelliklerine veya niteliklerine göre kümeler halinde gruptandığı kümelemedir.

Kümeleme algoritmaları, aynı küme içindeki örneklerin diğer kümelerdekilere göre birbirine daha benzer olmasını sağlayacak şekilde verileri uyumlu gruplara ayırmayı amaçlamaktadır.

Boyut Azaltma: Denetimsiz öğrenmedeki diğer bir yaygın görev, algoritmanın, temel yapıyı veya bilgiyi korurken veri kümesindeki özelliklerin veya değişkenlerin sayısını azalttığı boyut azaltmaktır. Boyut azaltma teknikleri, gereksiz veya ilgisiz özellikleri ortadan kaldırmayı, gürültüyü azaltmayı ve verilerin görselleştirilmesini veya daha fazla analizini kolaylaştırmayı amaçlamaktadır.

Anormallik Tespiti: Denetimsiz öğrenme, algoritmanın verilerdeki normdan veya beklenen modellerden önemli ölçüde sapan örnekleri tanımladığı anormallik veya aykırı değer tespiti için de kullanılabilir. Anormallik tespit teknikleri, hataları, sahtekarlıkları veya yeni olayları gösterebilecek olağandışı veya şüpheli gözlemleri işaretlemeyi amaçlamaktadır.

Denetimsiz öğrenmenin müşteri segmentasyonu, pazar sepeti analizi, siber güvenlikte anormallik tespiti, görüntü segmentasyonu ve doğal dil işlemede konu modelleme gibi çeşitli alanlarda uygulamaları vardır.

4.2.3 Yarı Denetimli Öğrenme

Yarı denetimli öğrenme, hem denetimli hem de denetimsiz öğrenmenin unsurlarını birleştiren bir MÖ paradigmasıdır. Yarı denetimli öğrenmede algoritma, çok daha büyük bir etiketsiz veri havuzunun yanı sıra az miktarda etiketli veri içeren bir veri kümesi üzerinde eğitilir. Amaç, öğrenme sürecini yönlendirmek için etiketli verilerden yararlanırken aynı zamanda genellemeyi geliştirmek ve verilerin temel yapısını yakalamak için etiketlenmemiş verilerden de yararlanmaktır.

Yarı denetimli öğrenmenin, etiketli verilerin elde edilmesinin az veya pahalı olduğu, ancak büyük miktarda etiketsiz verinin kolaylıkla mevcut olduğu problemlerde uygulanmaktadır. Etiketli örneklerin sınırlı olduğu ancak etiketlenmemiş verilerin bol olduğu metin sınıflandırma, görüntü tanıma ve konuşma tanıma gibi görevlerde yaygın olarak kullanılmaktadır.

Yarı denetimli öğrenme teknikleri, denetimli öğrenmenin verimliliği ile denetimsiz öğrenmenin esnekliği arasında bir uzlaşma sunarak, etiketlenmemiş verilerde mevcut olan bol miktardaki bilgiden yararlanırken sınırlı etiketli verilerden etkili öğrenmeye olanak tanımaktadır. Yarı denetimli öğrenme algoritmaları, her iki paradigmanın unsurlarını birleştirerek çeşitli gerçek dünya uygulamalarında gelişmiş performans ve ölçeklenebilirlik elde edebilir.

4.2.4 Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, bazı kümülatif ödül kavramını en üst düzeye çıkarmak için yazılım araçlarının bir ortamda nasıl eylemde bulunması gerektiğiyle ilgilenen MÖ'nin bir dalıdır. Bir ajanın bir hedefe ulaşmak için çevreyle etkileşime girmeyi öğrendiği davranışçı psikolojiden ilham almaktadır.

Pekiştirmeli öğrenmenin robotik, oyun oynama, otonom araçlar, öneri sistemleri, finans ve sağlık hizmetleri dahil olmak üzere çok çeşitli alanlarda uygulamaları vardır. Ajanları Go, Satranç ve video oyunları gibi karmaşık oyunları oynayacak şekilde eğitmek ve ayrıca otonom araçları ve robotik sistemleri kontrol etmek için başarıyla kullanılmaktadır.

Pekiştirmeli öğrenme, akıllı araçların karmaşık ortamlarla etkileşime girmesi ve deneme yanılma yoluyla en uygun stratejileri öğrenmesi için eğitilmesine yönelik güçlü bir çerçeve sunmaktadır. Güçlendirmeli öğrenme algoritmaları, çevre ile etkileşim yoluyla elde edilen geri bildirimlerden öğrenerek, temsilcilerin zaman içinde karar verme süreçlerini uyarlamalarına ve geliştirmelerine, sonuçta istenen amaç veya hedeflere ulaşmalarına olanak tanımaktadır.

4.3 Derin Öğrenme

DÖ, yapay sinir ağları adı verilen insan beyninin yapısından ve işlevinden ilham alan algoritmalara odaklanan bir YZ alanı olan MÖ'nin bir alt kümesidir. DÖ temel olarak MÖ ve YZ'nin bir karışımıdır. MÖ'e kıyasla daha çok yönlü olduğu, beyin nöronlarından ilham aldığı ve daha doğru modeller oluşturduğu kanıtlandı (Patil ve diğ. 2020). DÖ'yi diğerlerinden ayıran şey, çok katmanlı sinir ağları olan DNN'leri kullanmasıdır. Bu katmanlar, modelin verilerin hiyerarşik temsillerini öğrenmesine olanak tanır ve veriler her katmandan geçerken giderek daha soyut özellikler çıkarmasına olanak tanımaktadır.

DÖ insanların yapması mümkün olmayan karışık işlemleri yüksek doğruluk oranları ile yapabilmektedir. DÖ, çeşitli alanlarda yaygın olarak benimsenmesine ve başarısına katkıda bulunan çeşitli avantajlar sunmaktadır.

DÖ modelleri, birden fazla soyutlama katmanı aracılığıyla verilerin hiyerarşik temsillerini otomatik olarak öğrenmektedir. Bu, açık özellik mühendisliğine ihtiyaç duymadan giriş verilerindeki karmaşık desenleri ve özellikleri yakalamalarına olanak tanımaktadır. DÖ modelleri, görüntü sınıflandırma, konuşma tanıma, doğal dil işleme ve daha fazlasını içeren çok çeşitli görevlerde en son teknoloji performansı göstermektedir. DÖ modellerinin karmaşık örüntüleri öğrenme yetenekleri, onları

özellikle de büyük ve yüksek boyutlu veri kümelerine sahip görevler için oldukça uygun kılmalıdır.

DÖ modelleri, paralel hesaplamadaki gelişmeler ve GPU'lar ve TPU'lar gibi güçlü donanımların kullanılabilirliği sayesinde büyük miktarda veriyi işleyecek şekilde ölçeklenmektedir. Bu ölçeklenebilirlik, DÖ'nin daha önce geleneksel MÖ yöntemleriyle mümkün olmadığı düşünülen görevlerin üstesinden gelmesini sağlamaktadır. DÖ modelleri esnektir ve çeşitli veri ve görev türlerine uyarlanabilmektedir. Görüntüler, metin, ses ve video dahil olmak üzere farklı yöntemleri işleyebilirler ve sınıflandırma, regresyon, kümeleme, üretken modelleme ve pekiştirmeli öğrenme gibi görevlere uygulanabilmektedir.

DÖ modelleri, ara işlem adımlarına dayanmadan ham girdi verilerini doğrudan çıktı tahminleriyle eşleştirdikleri uçtan uca öğrenmeyi gerçekleştirebilmektedir. Bu yaklaşım, model tasarımını basitleştirir ve tüm boru hattını aynı anda optimize ederek daha iyi performansa yol açabilmektedir. Transfer öğrenimi sayesinde, büyük veri kümeleri üzerinde eğitilen DÖ modellerinde ince ayarlar yapılabilir veya daha küçük veri kümeleriyle yeni görevlere uyarlanabilmektedir. Geliştiriciler, başlangıç noktası olarak önceden eğitilmiş modellerden yararlanarak, özellikle etiketli veriler sınırlı olduğunda yeni görevlerde daha hızlı yakınsama ve daha iyi performans elde edebilmektedir.

Fakat DÖ yanında pek çok zorluk getirmektedir. DÖ modelleri, etkili eğitim için büyük miktarda yüksek kaliteli etiketli veri gerektirmektedir. Bu tür veri kümelerinin elde edilmesi ve bunlara açıklama eklenmesi maliyetli ve zaman alıcı olabilmektedir. Ayrıca taraflı veya gürültülü veriler modelin performansını olumsuz yönde etkileyebilmektedir. DÖ modellerinin, özellikle de büyük modellerin eğitimi, güçlü GPU'lar veya TPU'lar ve önemli miktarda bellek dahil olmak üzere önemli hesaplama kaynakları gerektirmektedir. Bu, bu tür kaynaklara erişimi sınırlı olan kişi veya kuruluşlar için bir engel olabilmektedir.

DÖ modelleri, genelleştirilebilir kalıpları öğrenmek yerine eğitim verilerini ezberledikleri aşırı uyum eğilimine sahiptir. Bu sorunu azaltmak için bırakma, düzenlileştirme ve veri artırma gibi teknikler yaygın olarak kullanılmaktadır. DÖ modelleri genellikle "kara kutular" olarak anılır çünkü tahminlerine nasıl ulaştıklarını

anlamak zor olabilmektedir. Yorumlanabilirlik, özellikle kararların önemli sonuçlara yol açtığı uygulamalarda (ör. sağlık hizmetleri, finans) çok önemlidir.

Hassas veriler üzerinde eğitilen DÖ modelleri, özellikle de modeller kötü niyetli aktörlerin erişebileceği ortamlarda kullanılıyorsa, gizlilik ve güvenlik riskleri oluşturabilmektedir. Hem verilerin hem de modelin gizliliğinin ve güvenliğinin sağlanması esastır. DÖ modelleri eğitim verileri üzerinde sıklıkla iyi performans gösterse de, görünmeyen verilere genelleme yapma yetenekleri her zaman garanti edilmemektedir. Modellerin farklı veri kümeleri ve gerçek dünya senaryoları genelinde iyi bir şekilde genelleştirilmesinin sağlanması, pratik kullanımları açısından çok önemlidir.

DÖ, fazla sayıda katmanlı hesaplama modellerinin ve birden fazla sayıda soyutlama düzeyine sahip veri temsillerini öğrenmesine imkan tanımaktadır. DÖ yöntemleri ile doğal dil işleme, görüntü tanıma, konuşma tanıma, nesne algılama gibi diğer birçok alanda en son teknolojiyi önemli ölçüde geliştirmektedir (LeCun ve diğ. 2015).

Genel olarak, DÖ'nin avantajları, onu çok çeşitli gerçek dünya sorunlarının üstesinden gelmek ve YZ ve MÖ'deki ilerlemeleri yönlendirmek için güçlü bir araç haline getirmektedir. DÖ'nin zorluklarının üstesinden gelmek, bilgisayar bilimi, istatistik, matematik ve etik gibi alanlardan araştırmacılar arasında disiplinlerarası işbirliğini gerektirmektedir. Dahası, devam eden araştırma ve inovasyon, DÖ'nin sınırlamalarını ve risklerini azaltırken başarabileceklerinin sınırlarını zorlamak için de gerekmektedir.

DÖ modelleri genellikle bir giriş katmanı, birden fazla gizli katman ve bir çıkış katmanından oluşur. Her katman, giriş verileri üzerinde matematiksel işlemler gerçekleştiren düğümleri (nöronlar) içermektedir. DÖ modelleri, her biri girdi verilerinin işlenmesinde ve istenen çıktının üretilmesinde kendine özgü işlevi olan birden fazla katmandan oluşmaktadır. DÖ mimarilerinde bulunan bazı yaygın katman türleri şunlardır: Giriş katmanı, gizli katmanlar, evrişimli katmanlar, havuzlama katmanları, tekrarlayan katmanlar, tam bağlantılı katmanlar, normalleştirme katmanları, bırakma katmanları ve çıktı katmanı. Bunlar DÖ mimarilerinde kullanılan en yaygın katman türlerinden bazılarıdır. Belirli mimariye ve görev gereksinimlerine

bağlı olarak modelin performansını ve yeteneklerini geliştirmek için ek katmanlar ve varyasyonlar kullanılabilmektedir.

Giriş katmanı, ham giriş verilerinin modele beslendiği sinir ağının ilk katmanıdır. Bu katmandaki her düğüm, giriş verilerinin bir özelliğini veya niteliğini temsil etmektedir. Birincil işlevi, ham girdi verilerini almak ve bunları işlenmek üzere sonraki katmanlara iletmektir. Giriş katmanının özellikleri, işlenen verinin türüne ve sinir ağının mimarisine bağlıdır. DÖ modelinin giriş katmanı ham giriş verileri için giriş noktası görevi görür ve verilerin sinir ağının sonraki katmanları tarafından işlenebilecek bir formatta kodlanmasından sorumludur. Yapısı ve özellikleri, verinin doğasına ve modelin mimarisine bağlı olarak değişmektedir.

DÖ'deki gizli katmanlar, bir sinir ağı mimarisinde giriş katmanından sonra ve çıkış katmanından önce gelen nöron katmanlarıdır. Giriş veya çıkıştan doğrudan gözlemlenemedikleri ve giriş verilerinin bir dizi dönüşüm yoluyla işlenmesinden sorumlu oldukları için "gizli" olarak adlandırılmaktadır. Doğrusal dönüşümler ve ardından aktivasyon fonksiyonları gibi bir dizi matematiksel işlem yoluyla giriş verileri üzerinde dönüşümler gerçekleştirmektedir. DÖ modelinin gizli katmanları, girdi verilerinin hiyerarşik temsillerinin öğrenilmesinde, ilgili özelliklerin çıkarılmasında ve verilerin doğru tahminler yapılmasına veya çıktıların üretilmesine yardımcı olacak bir formata dönüştürülmesinde çok önemli bir rol oynamaktadır. Gizli katmanların sayısı, her katmanın boyutu ve aktivasyon fonksiyonlarının seçimi, belirli bir görev için modelin performansını optimize etmek üzere ayarlanabilen hiper parametrelerdir.

Evrişimli katmanlar özellikle görüntüler gibi ızgara benzeri verileri işlemek için kullanılmaktadır. Bu katmanlar, giriş verilerine filtreler (çekirdek olarak da bilinir) uygular ve filtreleri giriş görüntüsü boyunca evriştirerek özellikler çıkarmaktadır. Evrişimli katmanlar, giriş verilerine evrişim işlemlerini uygulayarak ağın özelliklerin mekansal hiyerarşilerini çıkarmasını sağlamaktadır. Evrişim katmanlarının temel işlemi evrişim işlemidir. Evrişim katmanı, girdi görüntülerinin evrişimini hesaplamak ve temel özellikleri çıkarmak için bir çekirdek filtresi kullanılmaktadır (Purwono ve diğ. 2022). Evrişimsel bir katman, giriş verilerinin küçük bölgelerine (alıcı alan) öğrenilebilir filtreler (çekirdek olarak da bilinir)

uygulamaktadır. Filtre, giriş uzamsal boyutları boyunca kayar (evrilir), giriş değerlerinin ağırlıklı toplamını ve her konumdaki filtre ağırlıklarını hesaplamaktadır.

Evrişimli katmanlar, çıktıları olarak özellik haritaları üretmektedir. Katmandaki her filtre, giriş verilerini evriştirerek ayrı bir özellik haritası oluşturmaktadır. Özellik haritaları, ağ tarafından farklı soyutlama seviyelerinde öğrenilen mekansal kalıpları veya özellikleri temsil etmektedir. Evrişimli katmanların temel özelliklerinden biri ağırlık paylaşımıdır. Aynı filtre, giriş verilerinin farklı uzamsal konumlarına uygulanmaktadır. Bu parametre paylaşımı, ağı çeviriyle değişmeyen özellikleri öğrenmesini sağlar ve eğitilebilir parametrelerin sayısını azaltarak modeli daha verimli ve etkili hale getirmektedir. Çıktı özellik haritalarının uzamsal boyutlarını kontrol etmek için genellikle evrişimden önce giriş verilerine dolgu uygulanmaktadır. Sıfır doldurma, giriş verilerinin çevresine sıfırlar ekleyerek mekansal boyutlarını korur ve ağı görüntü sınırlarındaki özellikleri öğrenmesini sağlamaktadır.

Adım, giriş verileri boyunca evrilirken filtrenin adım boyutunu belirlemektedir. Birden fazla adım, özellik haritalarının aşağı örneklenmesine ve bunların uzamsal boyutlarının azalmasına neden olmaktadır. Adım, çıktı özellik haritalarının uzamsal boyutlarını etkileyen başka bir faktördür. Evrişim işleminden sonra, ReLU (Düzeltilmiş Doğrusal Birim) gibi bir aktivasyon fonksiyonu genellikle çıktı özellik haritalarına eleman bazında uygulanmaktadır. Aktivasyon fonksiyonları ağı doğrusal olmayan bir özellik kazandırarak karmaşık ilişkileri öğrenmesini ve ağı daha anlamlı hale getirmesini sağlamaktadır. Evrişimli katmanlar tipik olarak CNN mimarilerinde bir araya getirilir; her katman, giriş verilerinden giderek daha karmaşık ve soyut özellikler öğrenmektedir. Evrişimsel katmanların, havuzlama katmanlarının ve tamamen bağlantılı katmanların birleşimi, CNN'lerin görüntü sınıflandırma, nesne algılama ve görüntü bölümlleme gibi çeşitli bilgisayarlı görme görevlerinde en son teknolojiye sahip performansa ulaşmasını sağlamaktadır.

Havuzlama katmanları, CNN'lerin önemli bir bileşenidir ve en önemli bilgileri korurken özellik haritalarının uzamsal boyutlarını alt örneklemek için kullanılmaktadır. Komşu bölgelerden gelen bilgileri toplayarak girdi verilerinin mekansal boyutlarını azaltmaktadırlar. Yaygın havuzlama işlemleri maksimum

havuzlamayı ve ortalama havuzlamayı içermektedir. Maksimum havuzlama, havuzlama işleminin en yaygın türüdür.

Maksimum havuzlamada, bir pencere (tipik olarak 2x2 boyutunda) giriş özellik haritası üzerinde kayar ve her pencere içindeki maksimum değer, o bölgeyi temsil edecek şekilde seçilmektedir. Maksimum havuzlama, en göze çarpan özellikleri korurken özellik haritalarının uzamsal boyutlarını etkili bir şekilde azaltmaktadır. Ortalama havuzlama, her penceredeki ortalama değerini hesaplandığı ve ilgili bölgeyi temsil etmek için kullanıldığı başka bir havuzlama işlemi türüdür. Maksimum havuzlamanın aksine, ortalama havuzlama pencere içindeki tüm değerlerin ortalamasını alır; bu da daha düzgün bir alt örnekleme yol açabilir ancak önemli ayrıntıların kaybolmasına neden olabilmektedir. Küresel ortalama havuzlama, tüm mekansal konumlardaki her özellik haritasının ortalama değerini hesaplamaktadır. Özellik haritalarının tüm uzamsal boyutlarını her kanal için tek bir değere indirgemektedir. Küresel ortalama havuzlama genellikle görüntü sınıflandırma gibi görevler için CNN'lerin son katmanlarındaki tamamen bağlı katmanlara alternatif olarak kullanılmaktadır.

Optimum bir fonksiyon için sıklıkla maksimize eden bir kombinasyon kullanılmaktadır. Havuzlama katmanı aynı zamanda aşırı uyumun veya hesaplama ağırlıklarının azaltılmasına da yardımcı olmaktadır (Ke ve diğ. 2018, Purwono ve diğ. 2022).

Havuzlama katmanları, özellik haritalarına uygulanan alt örnekleme miktarını belirleyen, havuzlama penceresinin boyutu (çekirdek boyutu) ve adım gibi parametrelere sahiptir. Daha büyük bir havuzlama penceresi veya daha büyük bir adım, daha agresif alt örneklemeyle sonuçlanır ve özellik haritalarının uzamsal boyutlarını daha büyük ölçüde azaltmaktadır. Katmanları havuzlamanın temel amacı, özellik haritalarının uzamsal boyutlarını azaltmaktır; bu, ağırlık hesaplama karmaşıklığının azaltılmasına ve aşırı uyumun kontrol edilmesine yardımcı olmaktadır. Havuzlama katmanları ayrıca, giriş görüntüsünde biraz farklı bir konumda bir özelliğin varlığı, havuzlama sonrasında aynı özelliğin yakalanmasına neden olacağından, ağırlık bir dereceye kadar çeviri değişmezliği de getirmektedir.

Havuzlama katmanları tipik olarak CNN mimarilerinde evrişimli katmanlar arasına yerleştirilir; her havuzlama katmanı, en önemli özellikleri korurken özellik haritalarının uzamsal boyutlarını aşamalı olarak azaltmaktadır. Havuzlama işlemi ve parametrelerinin seçimi, CNN'nin özel görevine ve mimarisine bağlıdır.

Tekrarlayan katmanlar, RNN'ler ve LSTM ağları ve geçit tekrarlayan birimler (GRU'lar) gibi ilgili mimarilerin önemli bir bileşenidir. Bu katmanlar zaman serisi, metin ve konuşma gibi sıralı verileri işlemek için özel olarak tasarlanmaktadır. Bu katman, modelin verilerdeki zamansal bağımlılıkları yakalamasını sağlamaktadır. Tekrarlayan katmanlar, doğal dil işleme, konuşma tanıma, makine çevirisi, zaman serisi tahmini ve daha fazlasını içeren çeşitli uygulamalarda yaygın olarak kullanılmaktadır. Verilerdeki sıralı kalıpları ve bağımlılıkları yakalamada üstündürler, bu da onları sıralı verileri içeren görevler için çok uygun hale getirmektedir. Tekrarlayan katman mimarisinin seçimi, görevin karmaşıklığı, giriş dizilerinin uzunluğu ve hesaplama kısıtlamaları gibi faktörlere bağlıdır.

Yoğun katmanlar olarak da bilinen tam bağlantılı katmanlar, bir katmandaki her nöronu bir sonraki katmandaki her nörona bağlamaktadır. Yoğun katmanlar olarak da bilinen tamamen bağlı katmanlar, ileri beslemeli sinir ağları (FNN'ler), CNN'ler ve RNN'ler dahil olmak üzere birçok DÖ mimarisinin temel bir bileşenidir. Bu katmanlar, bir katmandaki her nöronu bir sonraki katmandaki her nörona bağlayarak ağındaki verilerdeki karmaşık ilişkileri öğrenmesini sağlamaktadır. Genellikle ağındaki son aşamalarında sınıflandırma veya regresyon gibi görevler için kullanılmaktadır.

Tamamen bağlantılı bir katmanda her nöron, bitişik katmanlardaki her nörona bağlanmaktadır. Tamamen bağlantılı katman, genellikle evrişimsel çıktı katmanı olarak adlandırılmaktadır (Singh ve diğ. 2020). Bu, her giriş özelliğinin (veya önceki katmandaki aktivasyonun) ağırlıklandırıldığı ve tamamen bağlı katmandaki her nöronla birleştirildiği ve bunun sonucunda yoğun bir matris çarpım işlemi gerçekleştiği anlamına gelmektedir. Tamamen bağlı katmanlar, eğitim süreci boyunca öğrenilmesi gereken çok sayıda parametreye sahiptir. Nöronlar arasındaki her bağlantının ilişkili bir ağırlığı vardır ve ayrıca tam bağlantılı katmandaki her nöronla ilişkili bir önyargı terimi de vardır. Tamamen bağlı katmandaki her bir nöron için ağırlıklı girdi ve önyargı toplamı hesaplandıktan sonra, ağı doğrusal olmamayı sağlamak için eleman bazında bir aktivasyon fonksiyonu uygulanmaktadır. Tamamen

bağlı katmanlarda kullanılan yaygın aktivasyon fonksiyonları arasında ReLU (Doğrulanmış Doğrusal Birim), sigmoid ve tanh bulunur. Tamamen bağlı bir katmanın çıkışı, ağız mimarisine bağlı olarak tipik olarak başka bir tamamen bağlı katmana veya bir çıkış katmanına aktarılmaktadır. Sınıflandırma görevlerinde, çıktı katmanı genellikle çok sınıflı sınıflandırma için softmax aktivasyonundan veya ikili sınıflandırma için sigmoid aktivasyonundan oluşmaktadır.

Tamamen bağlantılı katmanlar çok yönlüdür ve temsilleri öğrenmek ve giriş verilerinden tahminler yapmak için çeşitli DÖ mimarilerinde kullanılabilir. Bununla birlikte, aynı zamanda çok sayıda parametre de içerirler ve bu da düzgün şekilde düzenlenmediği takdirde aşırı uyuma yol açabilmektedir.

Normalleştirme katmanları, eğitim sırasında sinir ağlarının kararlılığını ve performansını artırmak için kullanılan, DÖ mimarilerinin önemli bir bileşenidir. Bu katmanlar, nöronların aktivasyonlarını normalleştirerek ağız daha verimli ve etkili bir şekilde öğrenebilmesini sağlamak için tasarlanmaktadır. Toplu normalleştirme gibi normalleştirme katmanları, her katmanın aktivasyonlarını normalleştirerek DNN'lerin eğitimini stabilize etmek ve hızlandırmak için kullanılmaktadır. Katman normalleştirme, toplu normalleştirmeye benzer ancak mini toplu iş düzeyi yerine katman düzeyinde çalışmaktadır. Örnek normalleştirme, her özellik haritasındaki uzamsal boyutlar (yükseklik ve genişlik) boyunca nöronların aktivasyonlarını normalleştirmektedir. Grup normalleştirme, her katmandaki kanalları veya özellikleri gruplara ayırır ve her grup içindeki aktivasyonları bağımsız olarak normalleştirmektedir. Ağırlık normalleştirme, nöron aktivasyonlarını normalleştirmek yerine katmanlar arasındaki bağlantıların ağırlıklarını normalleştirmektedir.

Normalleştirme katmanları, eğitimin kararlılığını geliştirerek, yakınsamayı hızlandırarak ve daha yüksek öğrenme oranlarının kullanılmasını sağlayarak DÖ mimarilerinde kritik bir rol oynamaktadır. Genellikle standart bileşenler olarak sinir ağı mimarilerine entegre edilirler ve farklı alanlar ve görevler genelinde çeşitli DÖ modellerinin başarısına katkıda bulunmaktadırlar.

Bırakma, aşırı uyumu önlemek ve sinir ağlarının genelleme performansını iyileştirmek için DÖ'de yaygın olarak kullanılan bir düzenleme tekniğidir. Bırakma katmanları, eğitim ve çalışma sırasında, katmandaki nöronların bir kısmını rastgele

bırakarak (sıfıra ayarlayarak) ağ mimarisine dahil edilir ve mevcut ileri ve geri geçiş için bunları ağdan etkili bir şekilde çıkarmaktadır. Bırakma katmanları, eğitim sırasında nöronların bir kısmını rastgele bırakarak modelin herhangi bir nörona çok fazla güvenmesini önler ve genelleme performansını artırmaktadır.

Bırakma katmanları, eğitim sırasında bırakılacak nöronların oranını belirleyen, bırakma olasılığını belirleyen tek bir parametre almaktadır. Tipik bırakma olasılıkları 0,2 ile 0,5 arasında değişir; bu, her bir nöronun, her eğitim yinelemesi sırasında %20 ile %50 oranında bırakılma şansına sahip olduğu anlamına gelmektedir.

Bırakma katmanları, özellikle çok sayıda parametreye sahip DÖ modellerinde sinir ağlarını düzenlemek ve aşırı uyumu önlemek için basit ama etkili bir tekniktir. Eğitim sürecine rastgelelik katarak, bırakma, ağın verilerin daha sağlam ve genelleştirilebilir temsillerini öğrenmesini teşvik ederek, görünmeyen örnekler üzerinde performansın artmasına yol açmaktadır.

DÖ modelinin çıktı katmanı, ağ mimarisindeki son katmandır ve işlenmiş girdi verilerine dayanarak istenen çıktının veya tahminlerin üretilmesinden sorumludur. Çıktı katmanının yapısı ve özellikleri, belirli göreve ve işlenen veri türüne bağlıdır; sınıflandırma görevleri genellikle sınıf başına bir düğüme sahiptir ve regresyon görevleri sürekli çıktı için tek bir düğüme sahiptir.

İkili sınıflandırma görevleri için (çıktının iki sınıftan biri olduğu durumlarda), çıktı katmanı tipik olarak sigmoid aktivasyon fonksiyonuna sahip tek bir nörondan oluşmaktadır. Nöronun çıktısı pozitif sınıfın olasılığını temsil etmektedir.

Çok sınıflı sınıflandırma görevleri için (çıktının birden fazla sınıftan biri olduğu durumlarda), çıktı katmanı genellikle softmax aktivasyon fonksiyonuna sahip, her sınıf için bir tane olmak üzere birden fazla nörondan oluşmaktadır. Softmax işlevi, tüm sınıflar üzerindeki olasılık dağılımını hesaplayarak çıktı olasılıklarının toplamının bir olmasını sağlamaktadır.

Regresyon görevleri için (çıktının sürekli bir değer olduğu durumlarda), çıktı katmanı tipik olarak doğrusal aktivasyon fonksiyonuna sahip tek bir nörondan oluşmaktadır. Nöronun çıktısı, hedef değişkenin tahmin edilen değerini temsil etmektedir.

Bazı durumlarda, görevin özel gereksinimlerine göre özel çıktı katmanları tasarlanabilmektedir. Örneğin, CNN'ler kullanan nesne algılama görevlerinde, çıktı katmanı, hem sınıf etiketlerini hem de sınırlayıcı kutu koordinatlarını tahmin etmek için sınıflandırma ve regresyon çıktılarının bir kombinasyonundan oluşabilmektedir.

Çıkış katmanı, model tahminleri ile gerçek hedef değerler arasındaki tutarsızlığı ölçen bir kayıp fonksiyonuyla ilişkilidir. Kayıp fonksiyonunun seçimi göreve ve işlenmekte olan veri türüne bağlıdır (örn. sınıflandırma için çapraz entropi kaybı, regresyon için ortalama kare hata).

Çıktı katmanı, DÖ modelinin nihai tahminlerinin veya çıktılarının belirlenmesinde kritik bir rol oynamaktadır. Yapısı, aktivasyon fonksiyonları ve kayıp fonksiyonları, görevin özel gereksinimlerine göre uyarlanarak modelin girdi verilerinden etkili bir şekilde öğrenmesini ve genelleme yapmasını sağlamaktadır.

4.4 Makine Öğrenmesi Algoritmaları

MÖ, her biri farklı görev ve veri türlerine uygun çok çeşitli algoritmaları kapsamaktadır. En sık kullanılan MÖ algoritmalarından bazıları; doğrusal regresyon, LR, DT, RF'lar, SVM, KNN, naive bayes, kümeleme algoritmaları ve sinir ağlarıdır.

Bunlar, MÖ algoritmalarının yalnızca birkaç örneğidir ve belirli görevlere ve alanlara göre uyarlanmış daha birçok özel algoritma ve teknik vardır. Algoritma seçimi, verinin doğası, problemin karmaşıklığı, modelin istenilen yorumlanabilirliği ve performansı gibi faktörlere bağlıdır.

4.4.1 XGBoost

XGBoost (Extreme Gradient Boosting), özellikle yapılandırılmış/tablolu veriler ve regresyon/sınıflandırma görevlerinde performansı ve ölçeklenebilirliği ile bilinen güçlü ve popüler bir MÖ algoritmasıdır. Topluluk öğrenme kategorisine aittir ve gradyan artırma çerçevesine dayanmaktadır.

XGBoost, birden fazla zayıf tahmini birleştirerek güçlü bir tahmin modeli oluşturan gradyan artırma algoritmasını genişletmektedir. Gradyan artırmada her yeni ağaç, mevcut ağaç topluluğunun yaptığı hataları düzeltmek için eğitilmektedir. XGBoost, bir dizi DT eğitir; burada sonraki her ağaç, önceki topluluğun artıklarını (hatalarını) yakalamaya odaklanmaktadır. Bu yinelemeli süreç, belirli sayıda ağaca ulaşıncaya veya bir durdurma kriteri karşılanıncaya kadar devam etmektedir.

XGBoost, temel öğrencileri olarak bir DT topluluğu kullanılmaktadır. Aşırı uyumu önlemek ve genelleme performansını artırmak için her ağaç genellikle sığdır (düşük derinlik). XGBoost ayrıca aşırı uyumu daha fazla kontrol etmek için küçültme (öğrenme oranı) ve sütun alt örnekleme gibi düzenleme tekniklerini de kullanılmaktadır. XGBoost, gradyan inişini kullanarak türevlenebilir bir kayıp fonksiyonunu (örneğin, regresyon için ortalama kare hata, sınıflandırma için log kaybı) optimize etmektedir. Topluluğun tahminlerine göre kayıp fonksiyonunun gradyanını hesaplar ve model parametrelerini (ağaç yapısı ve yaprak değerleri) kaybı en aza indirecek yönde güncellemektedir.

XGBoost, hız ve ölçeklenebilirlik açısından son derece optimize edilmektedir. Ağaç yapısının birden fazla CPU çekirdeğinde paralelleştirilmesini destekler ve milyonlarca örnek ve özellik içeren büyük veri kümelerini verimli bir şekilde işleyebilmektedir. XGBoost, her bir özelliğin DT’da kullanılma sıklığına ve her bölünmeden kaynaklanan kayıp fonksiyonundaki iyileşmenin büyüklüğüne dayalı olarak özellik önem puanlarını hesaplamaktadır.

XGBoost, sağlamlığı, performansı ve esnekliği nedeniyle MÖ yarışmaları ve gerçek dünya uygulamaları için popüler bir seçim haline gelmiştir. Python, R, Java ve C++ dahil olmak üzere çeşitli programlama dillerinde uygulanır ve scikit-learn ve XGBoost’un yerel uygulaması gibi popüler MÖ kitaplıkları tarafından desteklenmektedir.

XGBoost için önemli parametreler ağaç sayısı, ağaç derinliği, satır oranı, öğrenme katsayısı ve sütun alt örneklemedir. Ağaç sayısı parametresi modeldeki ağaç sayısını belirler ve artırılması model performansını artırırken aşırı uyum sorununa da yol açabilmektedir. Ağaç derinliği parametresi modeldeki apaçların maksimum derinliğini kontrol etmektedir ve değer büyütüldükçe model karmaşılaşır ve aşırı

uyuma sebep olmaktadır. Değerin küçültülmesi ise modeli basitleştirir ve bu da yetersiz öğrenmeye sebep olmaktadır. Satır oranı parametresi ise model içerisindeki her ağacın gözlemlerin oranını kontrol etmektedir. Değerin küçük tutulması karmaşıklığı azaltır ve aşırı uyumun önüne geçmektedir. Öğrenme katsayısı ise öğrenme oranıdır ve optimize edicinin ağırlıklarında güncellemeler yaptığı adım boyutunu kontrol etmektedir. Eta değeri küçük tutulursa daha yavaş ama daha doğru güncellemeler ile sonuç vermektedir. Sütun alt örnekleme parametresi her ağaç için kullanılan özelliklerin oranını kontrol etmektedir. Değer azaldıkça model karmaşıklığı azalır ve aşırı uyumun önüne geçmektedir.

4.4.2 LightGBM

LightGBM (Light Gradient Boosting Machine), Microsoft tarafından geliştirilen yüksek performanslı bir degrade artırma çerçevesidir. Büyük ölçekli veri kümelerinin verimli eğitimi için tasarlanmıştır ve hızı, bellek verimliliği ve doğruluğuyla bilinmektedir. LightGBM, topluluk öğrenme kategorisine aittir ve XGBoost gibi diğer gradyan artırma algoritmalarıyla benzerlikler paylaşmaktadır.

XGBoost gibi LightGBM de, genellikle DT olan birden fazla zayıf öğrencinin tahminlerini birleştirerek güçlü bir tahmin modeli oluşturan gradyan artırma çerçevesine dayanmaktadır. Her yeni ağaç, mevcut topluluğun artıklarını (hatalarını) yakalamaya odaklanarak, bir dizi ağacı eklemeli bir şekilde eğitmektedir. LightGBM'nin temel özelliklerinden biri, DT oluşturmak için yaprak bazında büyüme stratejisidir. Ağacın her seviyesinin genişlik öncelikli olarak genişletildiği geleneksel derinlik odaklı ağaç büyümesinden farklı olarak LightGBM, ağaçları yaprak bazında büyütmektedir. Büyümek için maksimum delta kaybına (kayıp fonksiyonunda iyileşme) sahip yaprağı seçerek, en iyi bölünmeyi daha verimli bir şekilde bulmasına ve ağaçlardaki düğüm sayısını azaltmasına olanak tanımaktadır.

LightGBM, eğitim sürecini hızlandırmak için Gradyan Tabanlı Tek Taraflı Örnekleme tekniğini kullanmaktadır. GOSS, büyük gradyanlara sahip örnekleri (yani, kayıp fonksiyonuna önemli ölçüde katkıda bulunanları) korurken, küçük gradyanlara sahip örnekleri rastgele aşağı doğru örneklemektedir. Bu yaklaşım, modelin doğruluğundan ödün vermeden eğitimin hesaplamalı maliyetini azaltmaya yardımcı

olmaktadır. LightGBM, benzer dağıtımlara sahip birbirini dışlayan özellikleri bir araya toplayan Özel Özellik Paketlemeyi kullanılmaktadır. LightGBM, bu özellikleri bir araya getirerek farklı özellik değerlerinin sayısını azaltır, bu da daha hızlı eğitim ve daha düşük bellek kullanımına yol açmaktadır.

LightGBM, her özellik için en uygun bölme noktalarını bulmak amacıyla histogram tabanlı algoritmalar kullanılmaktadır. Sürekli özellikleri ayırık bölmelere ayırır ve bölme noktalarının etkili bir şekilde hesaplanması için histogramlar oluşturarak en iyi bölmeyi bulmanın hesaplama karmaşıklığını azaltmaktadır. LightGBM, tek seferde kodlamaya gerek kalmadan kategorik özellikler için yerel destek sağlamaktadır. Kategorik özellikler için kategorik bölme ve optimum bölme gibi teknikleri kullanarak daha hızlı eğitim ve daha iyi doğruluk sağlamaktadır. LightGBM, ağaç yapısının paralelleştirilmesini ve GPU hızlandırmayı destekleyerek milyonlarca örnek ve özellik içeren büyük ölçekli veri kümelerini verimli bir şekilde yönetmesine olanak tanımaktadır.

LightGBM hızı, ölçeklenebilirliği ve doğruluğu nedeniyle hem sektörde hem de akademide popülerlik kazanmıştır. Sınıflandırma, regresyon, sıralama ve öneri sistemleri de dahil olmak üzere çeşitli MÖ görevlerinde yaygın olarak kullanılmaktadır. LightGBM açık kaynaklı bir kitaplık olarak mevcuttur ve Python, R ve C++ dahil olmak üzere çeşitli programlama dillerinde uygulanmaktadır.

4.4.3 k-En Yakın Komşu

KNN algoritması, hem sınıflandırma hem de regresyon görevleri için kullanılan basit ama güçlü bir MÖ algoritmasıdır. Parametrik olmayan ve örnek tabanlı bir öğrenme algoritmasıdır; yani temeldeki veri dağıtımı hakkında açık varsayımlarda bulunmaz ve bunun yerine çıkarım sırasında eğitim veri kümesinin tamamına güvenmektedir.

KNN algoritmasının arkasındaki temel fikir, çoğunluk oylamasına veya özellik uzayındaki en yakın k komşusunun ortalamasına dayalı olarak yeni bir veri noktasının etiketini sınıflandırmak veya tahmin etmektedir. Veri noktalarının "yakınlığını" belirlemek için genellikle Öklid mesafesi, Manhattan mesafesi veya kosinüs benzerliği

gibi bir mesafe ölçümü kullanılmaktadır. Öklid mesafesi en yaygın seçimdir ve çok boyutlu bir uzayda iki nokta arasındaki düz çizgi mesafesini ölçmektedir. Diğer birçok MÖ algoritmasından farklı olarak KNN'nin geleneksel bir eğitim aşaması yoktur. Bunun yerine, eğitim veri kümesinin tamamı bellekte depolanır ve çıkarım, yalnızca veri kümesinin ezberlenmesini içermektedir.

Yeni bir veri noktası için tahminler yapılırken algoritma, yeni nokta ile eğitim veri kümesindeki her nokta arasındaki mesafeyi hesaplamaktadır. Daha sonra bu mesafelere göre en yakın k komşuyu tanımlamaktadır. Sınıflandırma görevleri için algoritma, çoğunluk sınıfı etiketini yeni veri noktasına en yakın k komşu arasında atamaktadır. Eğer $k = 1$ ise algoritma en yakın tek komşunun etiketini atamaktadır. Regresyon görevleri için algoritma, en yakın k komşunun hedef değerlerinin ortalamasını veya ağırlıklı ortalamasını hesaplar ve bu değeri yeni veri noktası için tahmin olarak atamaktadır.

k parametresinin komşu sayısı seçimi KNN'de çok önemli bir hiperparametredir. Daha küçük bir k değeri, daha esnek karar sınırlarına ve potansiyel olarak daha yüksek varyansa yol açarken, daha büyük bir k değeri, daha yumuşak karar sınırlarına ve potansiyel olarak daha yüksek önyargıya neden olmaktadır. Bazı durumlarda, tüm özelliklerin mesafe hesaplamalarına eşit katkıda bulunmasını sağlamak için KNN algoritmasını uygulamadan önce özellikleri normalleştirmek veya ölçeklendirmek önemlidir. Sadeliğine rağmen KNN algoritması, özellikle düşük boyutlu uzaylarda ve karar sınırının oldukça düzensiz olduğu durumlarda şaşırtıcı derecede etkili olabilmektedir. Daha karmaşık modellerle karşılaştırma yapmak için sıklıkla temel veya kıyaslama olarak kullanılan çok yönlü bir algoritmadır.

4.4.4 Rastgele Orman

RF algoritması, hem sınıflandırma hem de regresyon görevleri için kullanılan güçlü bir topluluk öğrenme yöntemidir. Tahmin performansını artırmak ve aşırı uyumu azaltmak için birden fazla DT birleştirmektedir. DT, RF'ların temel yapı taşlarıdır. Topluluktaki her DT, eğitim verilerinin rastgele bir alt kümesi (önyüklemeli örnek) ve özelliklerin rastgele bir alt kümesi (özellik alt örnekleme) üzerinde eğitilmektedir. RF'lar, orijinal veri kümesiyle aynı boyutta birden fazla eğitim veri kümesi oluşturmak

için önyüklemeli örnekleme (değiştirme ile örnekleme) kullanmaktadır. Her DT, bu ön yüklemeli örneklerden biri üzerinde eğitilir ve bu, topluluktaki ağaçlar arasında çeşitliliğe neden olmaktadır.

Önyüklemeli örnekleme ek olarak, RF'lar ayrıca özellik alt örneklemesini de kullanmaktadır. DT'daki her bölmede, bölme için özelliklerin yalnızca rastgele bir alt kümesi dikkate alınmaktadır. Bu rastgelelik, topluluktaki ağaçların ilişkisizleştirilmesine ve genelleme performansının geliştirilmesine yardımcı olmaktadır. Tahminlerde bulunmak için RF'lar, topluluktaki tüm DT'nın tahminlerini bir araya getirmektedir. Sınıflandırma görevleri için topluluk tahmini genellikle çoğunluk oyu (en sık görülen sınıf etiketi) ile belirlenirken, regresyon görevleri için genellikle bireysel ağaç tahminlerinin ortalaması alınmaktadır. RF'lar hem önyargıyı hem de varyansı azaltmada etkilidir. Ek olarak, eğitim sırasında ortaya çıkan rastgelelik, aşırı uyumun önlenmesine yardımcı olur ve önyargıyı azaltmaktadır.

RF'lar, topluluktaki ağaç sayısı, ağaçların maksimum derinliği, bir düğümü bölmek için gereken minimum örnek sayısı ve dikkate alınacak maksimum özellik sayısı dahil olmak üzere performansı optimize etmek için ayarlanabilen çeşitli hiper parametrelere sahiptir.

RF'lar sağlamlıkları, ölçeklenebilirlikleri ve karmaşık ilişkilere sahip yüksek boyutlu verileri işleyebilme yetenekleri nedeniyle pratikte yaygın olarak kullanılmaktadır. Finans, sağlık hizmetleri ve doğal dil işleme gibi çeşitli alanlardaki sınıflandırma ve regresyon görevleri için özellikle uygundur.

4.4.5 Destek Vektör Makineleri

SVM, sınıflandırma, regresyon ve aykırı değer tespit görevleri için kullanılan güçlü bir denetimli öğrenme algoritmasıdır. SVM'ler yüksek boyutlu alanlarda etkilidir ve özellikle boyut sayısının örnek sayısını aştığı durumlar için çok uygundur. En basit haliyle SVM, özellik uzayında farklı sınıflara ait veri noktalarını en iyi şekilde ayıran bir hiperdüzlem oluşturmaktadır. Bu hiperdüzlem, hiperdüzlem ile her sınıftan en yakın veri noktaları (destek vektörleri) arasındaki mesafe olan marjı maksimuma çıkarmak için seçilmektedir. Destek vektörleri, karar sınırına (hiperdüzlem) en yakın

olan veri noktalarıdır. Bunlar, marjı tanımlayan ve karar sınırının konumunu ve yönünü etkileyen kritik veri noktalarıdır.

SVM'ler, marjı en üst düzeye çıkarmak ve sınıflandırma hatalarını en aza indirmek arasındaki dengeyi kontrol etmek için bir düzenleme parametresi (C) kullanılmaktadır. Daha küçük bir C değeri, daha geniş bir marjla sonuçlanır ancak daha fazla sınıflandırma hatasına izin verir; daha büyük bir C değeri ise daha dar bir marja ancak daha az sınıflandırma hatasına yol açmaktadır. SVM'lerdeki optimizasyon problemi, ikinci dereceden bir programlama probleminin çözülmesini içeren ikili formda yeniden formüle edilebilmektedir. Bu ikili formülasyon, sıralı minimum optimizasyon (SMO) gibi optimizasyon algoritmalarını kullanarak SVM'lerin verimli bir şekilde eğitilmesine olanak tanımaktadır.

Çekirdek numarası, SVM'lerin, dönüştürülmüş özellik vektörlerini açıkça hesaplamadan girdi özelliklerini yüksek boyutlu uzaylara örtülü olarak eşlemesini sağlamaktadır. Bu, SVM'lerin doğrusal olmayan karar sınırlarını verimli bir şekilde ele almasına ve yüksek boyutlu alanlarda doğrudan çalışmanın getirdiği hesaplama yükünden kaçınmasına olanak tanımaktadır.

SVM, metin sınıflandırma, görüntü tanıma, biyoenformatik ve finansal tahmin dahil olmak üzere çeşitli uygulamalarda yaygın olarak kullanılmaktadır. Hem doğrusal hem de doğrusal olmayan sınıflandırma görevlerini yerine getirme yetenekleri, sağlamlıkları ve çok yönlülükleriyle birleştiğinde, onları birçok MÖ problemi için popüler bir seçim haline getirmektedir.

4.5 Derin Öğrenme Algoritmaları

4.5.1 Evrimsel Sinir Ağları

DÖ'nin temel mimarisi olan CNN, ham veri üzerinde öğrenerek verinin kendine münhasır özellikleri keşfeder. Veriyi öğrendikten sonra sınıflandırma gibi problemler üzerinde oldukça yüksek performans göstermektedir (Özkan ve Ülker 2017). CNN'ler nesnelerin tanımlanmasında art arda gelen birden çok katmandan

oluşan bir katmanın çıktısı diğer katmanın girdisi olan ileri beslemeli çalışma prensibine dayanan ve genel olarak nesneleri parçalayarak özellik haritalarını çıkararak ağı eğitmesini sağlayan otomatik sistemlerdir (Dinçer ve Özkan 2023). CNN'ler, öncelikli olarak görüntülere odaklanarak, yapılandırılmış ızgara benzeri verileri işlemek için özel olarak tasarlanmış bir DÖ modelleri sınıfıdır. Her biri giriş verilerinden özellikleri çıkarmak ve dönüştürmek için belirli işlemleri gerçekleştiren birden fazla katmandan oluşmaktadırlar. CNN, görüntü sınıflandırma, nesne algılama, görüntü bölümlendirme ve daha fazlası dahil olmak üzere çeşitli bilgisayarlı görme görevlerinde olağanüstü performans göstermektedir. Görsel verilerin hiyerarşik temsillerini otomatik olarak öğrenebilme yetenekleri, onları DÖ alanında vazgeçilmez kılmaktadır. Bu ağı ilk özelliği ileri beslemeli olmasıdır. Diğer özelliği yapay sinir ağı tabanlı olarak geliştirilmiş oluşudur. Son özelliği ise denetimli sinir ağı biçimindeki yapısı olmasıdır (Kırık 2024).

4.5.2 Uzun Kısa Süreli Bellek (LSTM)

RNN'ler, bellekte yönlendirilmiş döngüler içeren ve özellikle sıralı verilerde üstün performans gösteren bir sinir ağıdır. Kaybolan gradyan sorunu nedeniyle, zaman serisi verileri uzun vadeli bağımlılığa sahip olduğunda temel RNN yapısı doğru sonuçtan uzaklaşabilmektedirler. Bu nedenle, kaybolan gradyan problemini azaltmak için LSTM tasarlanmaktadır (Tunç ve Erdem 2024). LSTM, hücre boyunca bilgi akışını kontrol eden geçit mekanizmalarına sahip bellek hücrelerini sunmaktadır. Bu kapılar, bellek hücresinin içine, dışına ve içindeki bilgi akışını düzenleyen bir giriş kapısı, unutma kapısı ve çıkış kapısı içermektedir. Bu, LSTM'lerin sıralı verilerdeki uzun vadeli bağımlılıkları yakalamasına ve sürdürmesine olanak tanımaktadır.

Mimarilerde zaman boyutları arasında bağlam eksiklikleri olması durumunda, devamındaki dizinin tahmin edilmesi oldukça zor olmaktadır (Bengio ve diğ. 1994). LSTM ağları, bilgilerin zaman adımlarında kalıcı olmasını sağlayan tekrarlayan bağlantılara sahiptir. Geleneksel RNN'lerden farklı olarak LSTM birimleri, uzun diziler boyunca bilgi depolayabilen ve alabilen daha karmaşık yinelenen bağlantılar içermektedir.

Bir LSTM ünitesinin temel bileşeni, zaman içinde güncellenebilen ve değiştirilebilen dahili bir durumu (hücre durumu olarak da bilinir) koruyan bellek hücresidir. Bellek hücresi, önceki zaman adımlarından gelen bilgileri saklayan ve mevcut girdiye ve kendi iç dinamiklerine göre seçici olarak güncelleyen bir depolama birimi görevi görmektedir. LSTM'ler, bellek hücresine giren ve çıkan bilgi akışını kontrol etmek için kapı adı verilen özel yapıları kullanılmaktadır. Bir LSTM ünitesinde üç ana kapı türü vardır: Unutma kapısı, giriş kapısı ve çıkış kapısı. Unutma kapısı; önceki hücre durumundan hangi bilgilerin atılması veya unutulması gerektiğini belirlemektedir. Giriş kapısı; Mevcut girişten hangi yeni bilginin hücre durumuna eklenmesi gerektiğini belirlemektedir. Çıkış kapısı; hücre durumundan hangi bilginin bir sonraki zaman adımına çıkışı gerektiğini belirlemektedir.

LSTM'ler, kapılardan bilgi akışını kontrol etmek ve her zaman adımında hücre durumu ve çıktı değerlerini düzenlemek için sigmoid fonksiyonu ve hiperbolik tanjant (tanh) fonksiyonu gibi aktivasyon fonksiyonlarını kullanılmaktadır. Yıllar geçtikçe, belirli zorlukların üstesinden gelmek veya farklı uygulamalardaki performansı artırmak için temel LSTM mimarisinin çeşitli varyantları ve uzantıları önerilmektedir. Örnekler arasında GRU'lar, Gözetleme Deliği Bağlantıları ve Dikkat Mekanizmaları yer almaktadır.

LSTM ağları, birçok DÖ mimarisinde, özellikle sıralı veri işlemeyi içeren görevlerde temel bir yapı taşı haline gelmektedir. Uzun vadeli bağımlılıkları yakalama ve bilgileri genişletilmiş diziler üzerinde saklama yetenekleri, onları doğal dil işleme, zaman serisi analizi ve ötesindeki çok çeşitli uygulamalar için çok uygun hale getirmektedir.

4.5.3 Geçit Tekrarlayan Birim (GRU)

GRU, giriş ve unutma kapılarını tek bir güncelleme kapısında birleştirerek LSTM mimarisini basitleştiren başka bir tekrarlayan katman türüdür. GRU ayrıca geçmiş gizli durumun geçerli zaman adımındaki hesaplamayı ne ölçüde etkilediğini kontrol eden bir sıfırlama kapısı da sunmaktadır. GRU'lar, LSTM'lerden hesaplama açısından daha verimlidir ve aynı zamanda uzun vadeli bağımlılıkları yakalama yeteneğini korumaktadır. GRU'nun arkasındaki temel fikir, her zaman adımında ağırlık

gizli durumunu seçici olarak güncellemek için geçit mekanizmalarını kullanmaktadır. Geçit mekanizmaları, ağıın içine ve dışına bilgi akışını kontrol etmek için kullanılmaktadır (Tunç ve Erdem 2024).

Geleneksel LSTM'ler gibi GRU'lar da bilginin sıralı verilerde zaman adımlarında kalıcı olmasını sağlayan tekrarlayan bağlantılara sahiptir. Her zaman adımında, bir GRU birimi önceki zaman adımlarından bilgileri yakalayan ve ağıın belleği olarak görev yapan gizli bir durum vektörünü korumaktadır. Bu gizli durum, yeni giriş işlendiğinde dinamik olarak güncellenmektedir. GRU'lar, mevcut girişten ve önceki gizli durumdan gelen bilgi akışını kontrol eden bir güncelleme kapısı içermektedir. Güncelleme kapısı, önceki gizli durumun ne kadarının korunması gerektiğine ve yeni girdinin ne kadarının güncellenmiş gizli duruma entegre edilmesi gerektiğine karar vermektedir. Güncelleme kapısına ek olarak, GRU'lar ayrıca bir sıfırlama kapısı içermektedir. Sıfırlama kapısı, yeni gizli durumun hesaplanmasında geçmiş bilgilerin ne kadarının unutulması veya sıfırlanması gerektiğini belirlemektedir.

GRU'lardaki geçit mekanizması, LSTM'lere benzer şekilde bilgileri zaman içinde seçici olarak güncellemelerine ve saklamalarına olanak tanımaktadır. Ancak GRU'lar, LSTM'lere kıyasla daha az parametreyle daha basit bir mimariye sahiptir. GRU'lar, LSTM'lere benzer şekilde, zaman içinde geri yayılım kullanılarak eğitilmektedir. Eğitim sırasında, gradyanlar tüm giriş dizisi boyunca yayılır ve kayıp fonksiyonunu en aza indirmek için ağı parametrelerinde güncellemeler yapılmaktadır.

GRU'lar, doğal dil işleme, konuşma tanıma ve zaman serisi analizi dahil olmak üzere çeşitli sıra modelleme görevlerindeki basitlikleri, verimlilikleri ve rekabetçi performansları nedeniyle son yıllarda popülerlik kazanmaktadır. Sıralı verilerdeki uzun vadeli bağımlılıkları yakalama yeteneğini korurken LSTM'lere göre daha akıcı bir alternatif sunmaktadırlar.

4.6 Değerlendirme Metrikleri

Bir sistemin veya modelin performansının değerlendirilmesi MÖ veri bilimi ve mühendislik gibi alanlarda çok önemlidir. Değerlendirme metrikleri, modelinizin veya

sisteminizin amaçlanan görevi yerine getirme konusunda ne kadar iyi performans gösterdiğini ölçmeye yardımcı olmaktadır. Veri bilimi alanında değerlendirme ölçümleri, modellerin ve sistemlerin geliştirilmesine ve iyileştirilmesine rehberlik eden pusula görevi görmektedir. Bu ölçümler, algoritmaların performansına ilişkin ölçülebilir bilgiler sunarak karar verme süreçlerine yardımcı olur ve iyileştirmeleri teşvik etmektedir.

Değerlendirme metrikleri, MÖ, istatistik ve mühendislik dahil olmak üzere çeşitli alanlardaki modellerin etkinliğini değerlendirmek için vazgeçilmez araçlardır. Performansı ölçmek için standartlaştırılmış bir çerçeve sağlar, farklı yaklaşımlar arasında karşılaştırma yapılmasına olanak tanır ve bilinçli karar almayı kolaylaştırmaktadır. Değerlendirme metriklerinin türleri vardır ve bunlar sınıflandırma ve regresyon metrikleridir. Sınıflandırma metrikleri içerisinde; doğruluk, hassasiyet ve geri çağırma, F1 skoru, karışıklık matrisi bulunmaktadır. Regresyon metrikleri içerisinde; ortalama mutlak hata (MAE), ortalama karesel hata, ortalama karekök hata ve r-kare'dir.

Değerlendirme metriklerini seçerken, problem alanının belirli özelliklerini ve analizin hedeflerini dikkate almak çok önemlidir. Örneğin, yanlış pozitiflerin veya yanlış negatiflerin farklı maliyetler taşıdığı senaryolarda kesinlik ve geri çağırma, model performansına ilişkin değerli bilgiler sunmaktadır. Benzer şekilde, regresyon görevlerinde MAE ve RMSE gibi ölçümler, tahmin doğruluğuna ilişkin incelikli bir anlayış sağlamaktadır.

Ayrıca değerlendirme metrikleri model seçiminde, hiper parametre ayarlamasında ve performans optimizasyonunda önemli bir rol oynamaktadır. Veri bilimcileri, uygun ölçümleri kullanarak modelleri sistematik olarak değerlendirerek en etkili yaklaşımları belirleyebilir ve metodolojilerini yinelemeli olarak geliştirebilmektedirler. Değerlendirme metrikleri veriye dayalı karar vermenin temel taşı olarak hizmet eder ve uygulayıcılara modellerin performansını titizlikle ve sistematik bir şekilde ölçme yetkisi vermektedir. Veri bilimcileri, belirli görevlere ve alanlara göre uyarlanmış çeşitli ölçümlerden yararlanarak eyleme geçirilebilir içgörüler elde edebilir, inovasyonu teşvik edebilir ve sonuçta veriye dayalı çözümlerin tüm potansiyelini ortaya çıkarabilmektedir.

Karışıklık Matrisi, sınıflandırma performansının ayrıntılı bir analizini kolaylaştıran, gerçek sınıflara karşı modelin tahminlerinin tablo şeklinde temsilidir. Sınıf sayısına göre matrisin satır ve sütun sayıları artar. Karışıklık matrisinin temelinde Gerçek Pozitif (True positive, TP), Gerçek Negatif (True negative, TN), Yanlış Pozitif (False positive, FP) ve Yanlış Negatiftir (False Negative, FN). TP, modelin pozitif sınıfı doğru tahmin etmektedir. Örneğin, bir hastalığı olan bireye doğru tanı konulması durumudur. TN, modelin negatif sınıfı doğru tahmin etmektedir. FP, modelin negatif sınıfı yanlış tahmin etmektedir. FN, modelin pozitif sınıfı tahmin etmesi gerekirken negatif sınıfı tahmin ettiği durumdur. Örneğin yanlış tanı olarak sağlıklı denilen bir bireyin aslında hastalığı olması durumudur.

Tablo 4.1: Karışıklık matrisinin örnek gösterimi

TP-Gerçek Pozitif	FN-Yanlış Negatif
FP-Yanlış Pozitif	TN-Gerçek Negatif

Doğruluk, modelin yaptığı toplam tahminler arasında doğru tahminlerin oranıdır.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Hassasiyet, tüm olumlu tahminler arasındaki TP tahminlerin oranını ölçerken, hatırlama, tüm TP tahminler arasındaki TP tahminlerin oranını ölçmektedir.

$$Hassasiyet = \frac{TP}{TP + FP} \quad (2)$$

Duyarlılık, tüm doğru tahminler arasındaki TP tahminlerin oranını ölçmektedir.

$$Duyarluluk = \frac{TP}{TP + FN} \quad (3)$$

F1-Skor, hassasiyet ve duyarlılığın harmonik ortalamasıdır. F1-Skor model performansının dengeli bir değerlendirmesini sağlamaktadır.

$$F1\ Skor = \frac{2 * Hassasiyet * Duyarluluk}{Hassasiyet + Duyarluluk} \quad (4)$$

ROC, bir ikili sınıflandırıcı sistemin ayırım eşiği değişikçe teşhis yeteneğini gösteren grafiksel bir çizimdir. ROC AUC, olası tüm sınıflandırma eşiklerinde performansın toplu bir ölçüsünü sağlamaktadır. MAE, regresyon görevlerinde yaygın olarak kullanılan bir ölçümdür. Tahmin edilen değerler ile gerçek değerler arasındaki ortalama mutlak farkları hesaplamaktadır. Ortalama Karesel Hata (MSE), MAE'ye benzer şekilde MSE, regresyon görevleri için başka bir ölçümdür. Tahmin edilen ve gerçekleşen değerler arasındaki hataların karelerinin ortalamasını hesaplamaktadır. Ortalama Kare Hatanın Kökü (RMSE), MSE'nin kareköküdür. Hedef değişkenle aynı birimde yorumlanabilir bir ölçüm vermektedir. R-kare (R^2), verilerin uygun regresyon çizgisine ne kadar yakın olduğunun istatistiksel bir ölçüsüdür. Bağımlı değişkendeki varyansın bağımsız değişkenlerden tahmin edilebilen oranını göstermektedir. Çapraz Doğrulama Puanları, MÖ'de modelin performansının görünmeyen veriler üzerinde değerlendirilmesi önemlidir. Çapraz doğrulama, istatistiksel analiz sonuçlarının bağımsız bir veri setine nasıl genelleştirileceğini değerlendirmek için kullanılan bir tekniktir.

Öğrenme eğrileri, bir görevin veya sürecin yeterliliğinin zaman içinde deneyim ve pratikle nasıl geliştiğini gösteren grafiksel gösterimlerdir. Geniş anlamda, öğrenme ve deneyim arasındaki ilişkiyi temsil ederek eğitim, üretim, iş ve MÖ de dahil olmak üzere çeşitli alanlardaki ilerlemenin ve verimliliğin ölçülmesine yardımcı olmaktadır. Öğrenme eğrilerinden 3 adet sonuç çıkarılmaktadır ve bunlar aşırı öğrenme, yeterli uyum ve yetersiz uyum. Aşırı öğrenme, doğrulama eğrisinin eğitim verisinden daha yüksek çıkması sonucunda gözlemleyebileceğimiz durumdur. Bu da modelin sonuçları ezberlediğini ve sadece o veriler üzerinde başarı elde edebileceğini göstermektedir. Aşırı uyum sorununu değişken azaltarak, daha fazla veri ekleyerek ya da erken durdurma ile engellenebilmektedir. Yetersiz uyum, validasyon eğrisi ve eğitim verisinin birebir aynı veya çok yakın gitmesi sonucunda gözlemlenmektedir.

Bu sorun verilerin çok çeşitli olduğu ve modelin öğrenemediği durumlarda gözlemlenmektedir. Yeterli uyum ise validasyon eğrisinin eğitim eğrisinden bir miktar fazlı ve sağlıklı bir fark çıktığı durumlarda görülmektedir.

4.7 Veri Ön İşleme Süreçleri

Veri normalleştirme, bir veri kümesinin özelliklerini standart bir ölçeğe dönüştürmek için kullanılan bir ön işleme tekniğidir. Amaç, özellikleri, MÖ algoritmalarının performansını ve yakınsamasını artırabilecek benzer bir aralığa veya dağılıma getirmektedir. Normalleştirme, farklı ölçeklere veya birimlere sahip özelliklerle uğraşırken özellikle önemlidir çünkü daha büyük büyüklüğü nedeniyle herhangi bir özelliğin öğrenme sürecine hakim olmamasını sağlamaktadır.

MÖ’de temel bir ön işleme tekniği olan veri normalleştirme, model performansını ve yakınsamayı geliştirmek için girdi özelliklerinin standartlaştırılmasında ve ölçeklendirilmesinde önemli bir rol oynamaktadır. Tutarlı ve etkili model eğitimi sağlamak için normalleştirme gerekli olsa da, bunun değerlendirme ölçümleri üzerindeki etkisini anlamak da aynı derecede önemlidir. Veri normalleştirme, giriş özelliklerini ortak bir ölçeğe dönüştürmeyi, böylece özellik heterojenliğiyle ilgili sorunları azaltmayı ve MÖ modellerinin yorumlanabilirliğini ve yakınsamasını geliştirmeyi amaçlamaktadır. Değerlendirme ölçümleri, farklı normalleştirme teknikleri genelinde model performansını ölçmek ve en uygun ön işleme stratejilerinin seçimine rehberlik etmek için kıstas görevi görmektedir. Uygulayıcılar, modelleri çeşitli ölçümler kullanarak sistematik olarak değerlendirerek normalleştirme yöntemlerinin etkinliği ve bunların model genellemesi üzerindeki etkisi hakkında fikir sahibi olmaktadır.

Verinin dağılımı bazı algoritmaların çalışmasını etkileyen önemli bir faktördür. Verilerin baskınlığını azaltmak için bazı yöntemler bulunmaktadır. Normalizasyon ve standardizasyon bu yöntemlerden bazılarıdır. MinMax Ölçeklemede veri 0 ile 1 aralığında değer almaktadır. Burada dağılım, verinin dağılımı ile benzerdir. ‘Outlier’ adı verilen durum ise dışarıda kalan verilere karşı gelişen hassasiyet durumudur. Bu sebeple de değerlerin fazla olması performansın da iyi olacağı anlamına gelmemektedir (Merter 2020).

4.7.1 Gaussian Gürültüsü

Sinyal işleme, istatistik ve MÖ alanlarında gürültü önemli bir rol oynamaktadır. Çeşitli gürültü türleri arasında Gauss gürültüsü en yaygın ve önemli olanlardan biridir. Normal gürültü olarak da bilinen Gauss gürültüsü, olasılık dağılımıyla karakterize edilen bir tür istatistiksel gürültüdür.

Gauss gürültüsü ortalama etrafında simetriktir; değerlerinin çoğu ortalama etrafında kümelenir ve uç noktalara doğru incelmektedir. Bu, onu çeşitli istatistiksel ve sinyal işleme uygulamalarında faydalı kılmaktadır. Gauss gürültüsü, sensörler ve iletim hatalarından dolayı görüntülerde yaygındır. Gauss gürültüsünü anlamak, gürültü azaltma algoritmalarının geliştirilmesine ve görüntü kalitesinin iyileştirilmesine yardımcı olmaktadır.

4.7.2 Fourier Dönüşümü

Fourier dönüşümü, fonksiyonları veya sinyalleri frekans bileşenleri açısından analiz etmek ve temsil etmek için kullanılan temel bir matematiksel araçtır. Karmaşık bir sinyali, değişen frekanslara ve genliklere sahip daha basit sinüzoidal dalgalardan oluşan bir spektruma ayırmaya olanak tanımaktadır.

Fourier dönüşümü ses, radyo ve diğer sinyalleri analiz etmek için kullanılır ve frekans bileşenlerini tanımlamamıza ve gürültüyü filtrelememize olanak tanımaktadır. Görüntü analizinde Fourier dönüşümü kenar algılama, görüntü sıkıştırma ve filtreleme gibi görevlerde yardımcı olmaktadır. Fourier dönüşümü teknikleri, MÖ uygulamaları için verilerdeki özellikleri çıkarmak ve kalıpları analiz etmek için kullanılabilir.

4.7.3 Ayırık Dalgacık Dönüşümü

DWT, bir sinyali birden fazla bileşene ayrıştırarak çoklu çözünürlüklü analize olanak tanıyan bir sinyal işleme tekniğidir. Görüntü işleme, sinyal sıkıştırma ve değişen ayrıntı seviyelerinin kritik olduğu diğer uygulamalarda yaygın olarak

kullanılmaktadır. Sinyalleri sinüzoidlere ayırıştıran Fourier dönüşümünün aksine DWT, özellikle durağan olmayan sinyaller için daha esnek bir gösterim sunan dalgacıkları kullanmaktadır.

DWT, sinyalin ayrıntılı ve yaklaşık bileşenlerini çıkarmak için tipik olarak yüksek geçişli ve alçak geçişli filtreler kullanan bir dizi filtre bankası aracılığıyla çalışmaktadır. Bu filtreler, farklı ayrıntı düzeylerini yakalamak için yinelemeli olarak uygulanarak DWT'nin çoklu çözünürlüklü analiz elde etmesine olanak tanımaktadır.

4.7.4 Sürekli Dalgacık Dönüşümü

Sürekli Dalgacık Dönüşümü (CWT), farklı ölçekler ve frekanslardaki sinyallerin ayrıntılı analizine olanak tanıyan güçlü bir sinyal işleme tekniğidir. Dalgacık kavramını sürekli zamanlı sinyallere kadar genişleterek sinyallerin ayrıştırılması ve analiz edilmesi için kapsamlı bir çerçeve sunmaktadır. CWT, sürekli bir sinyali bir dizi ölçeklendirilmiş ve çevrilmiş dalgacıklara ayrıştırmak zaman-frekans gösterimi sağlayan matematiksel bir işlemdir. Sinüsoidleri kullanan sinyalleri temsil eden Fourier Dönüşümünün aksine, CWT, sonlu enerji ve yerelleştirilmiş destekle salınan işlevler olan dalgacıkları kullanılmaktadır.

4.7.5 Burg Yöntemi

Burg yöntemi, sinyal işlemede spektral tahmin için popüler bir tekniktir. Kısa veri setleriyle bile yüksek çözünürlüklü güç spektral yoğunluğu tahminleri üretme yeteneğiyle bilinmektedir. Burg yöntemi, bir sinyalin güç spektral yoğunluğunu tahmin etmek için otoregresif modellere dayanan bir spektral tahmin tekniğidir. Otoregresif model, bir sinyalin önceki değerleri artı beyaz gürültü teriminin doğrusal bir kombinasyonu olarak temsil edilebileceğini varsaymaktadır.

4.8 Hiperparametre Optimizasyonu

MÖ modeli geliştirmenin ayrılmaz bir parçası olan hiperparametre optimizasyonu, algoritmaların davranışını ve performansını yöneten parametrelere ince ayar yapılmasını içermektedir. Uygulayıcılar geniş hiperparametreler yelpazesinde gezinirken, sağlam değerlendirme ölçümleri, en uygun konfigürasyonların seçimine rehberlik ederek yol gösterici olarak hizmet etmektedir.

Hiperparametre optimizasyonu, model karmaşıklığı ile performans arasında hassas bir denge kurmaya çalışarak, aşırı uyumdan kaçınırken görünmeyen verileri iyi şekilde genelleştiren yapılandırmalar aramaktadır. Değerlendirme metrikleri, farklı parametre ayarlarında model performansının niceliksel ölçümlerini sağlayarak bu çabada çok önemli bir rol oynamaktadır. Uygulayıcılar, modelleri çeşitli ölçümler kullanarak sistematik olarak değerlendirerek güçlü, zayıf yönleri ve geliştirilecek alanları hakkında fikir sahibi olmaktadır.

Izgara araması, önceden tanımlanmış bir hiperparametre kombinasyonları ızgarasını sistematik olarak araştırır ve her konfigürasyonu belirtilen değerlendirme metriklerini kullanarak değerlendirmektedir. Izgara araması, hiperparametre alanını kapsamlı bir şekilde arayarak, seçilen ölçümlere göre model performansını en üst düzeye çıkaran en uygun yapılandırmayı tanımlamaktadır.

Rastgele arama, hiperparametre kombinasyonlarını kapsamlı bir şekilde araştıran ızgara aramanın aksine, rastgele arama, hiperparametre alanından rastgele yapılandırmaları örneklemektedir. Rastgele arama, ızgara aramasından daha az hesaplama yoğunluğuna sahip olsa da, yüksek performanslı konfigürasyonları etkili bir şekilde tanımlamak için rastgele örnekleme ilkelerinden yararlanmaktadır.

Hiperparametre optimizasyonunda değerlendirme metriklerinin seçiminin, modelin iyileştirilmesi ve performansı üzerinde derin etkileri vardır. Doğruluk, sınıflandırma görevleri için ortak bir ölçüm olmaya devam ederken, hassasiyet, geri çağırma, F1-skor ve ROC AUC gibi diğer ölçümler, özellikle dengesiz veya asimetrik olarak maliyete duyarlı alanlarda model performansına ilişkin daha incelikli değerlendirmeler sunmaktadır. Regresyon görevlerinde, ortalama kare hata (MSE), MAE ve R-kare gibi ölçümler, tahmin doğruluğu ve model uyumu hakkında bilgi

sağlamaktadır. Hiperparametre optimizasyonu, MÖ modeli geliştirmede, optimum yapılandırmaların seçiminin performansı ve genelleme yeteneğini önemli ölçüde etkileyebileceği önemli bir aşamayı temsil etmektedir. Sağlam değerlendirme ölçümleri pusula görevi görerek uygulayıcılara hiperparametre uzayında rehberlik eder ve üstün modellere giden yolu aydınlatmaktadır. Uygulayıcılar, çeşitli değerlendirme metriklerinden ve metodolojilerinden yararlanarak, model ayarlama alanında güvenle gezinebilir, MÖ uygulamalarında yenilikçiliği ve mükemmelliği teşvik edebilmektedir.

4.9 Google Colaboratory

Google'ın herkese sağlamış olduğu açık kaynaklı bir hizmetidir. Google Colab sayesinde, yeterli kaynağı olmayan kişilere araştırma ve geliştirme yapabilmeleri için GPU ve TPU hizmeti sağlamaktadır. Python diline izin vermektedir. Bu çalışma kapsamında Google Colab ve Python dili kullanılmıştır.

5. VERİ KÜMELERİ

5.1 Çevrimiçi Oyuncuların Anksiyete Verileri (Veri Seti 1)

Veri setinin içeriğinde, dünya çapındaki oyuncular arasında yapılan bir anketin parçası olarak toplanan verilerden oluşmaktadır. Ankette, psikologların genellikle kaygıya yatkın, sosyal fobisi olan ve yaşam doyumunu az olan veya hiç olmayan kişilere sorduğu sorular sorulmuştur. Anket, psikolojik çalışmanın bir parçası olarak sorulan 14250 adet hastaya sorulmuş olan çeşitli sorulardan oluşmaktadır. Orijinal veriler Marian Sauter ve Dejan Draschkow tarafından derlenmiştir (Agrawal 2020). Veri seti, ankette sorulan her soruya karşılık gelen 55 sütundan oluşmaktadır. Sütunların çoğu, GAD (Genel Anksiyete Bozukluğu), SWL (Yaşamdan Doyum) ve SPIN (Sosyal Fobi Envanteri) puanları gibi psikolojide kullanılan farklı puanlama kriterlerine karşılık gelmektedir. İnsanların nerede doğdukları ve neden çevrimiçi oyunlar oynadıkları vb. hakkında birkaç genel soru vardır.

5.2 Şizofreni Bozukluğu EEG Veri Seti (Veri Seti 2)

Bu veri seti içerisinde açık erişimli olmak üzere 14 adet ŞB hastasından ve 14 sağlıklı kontrolden elde edilmiş EEG sinyalleri bulunmaktadır. Deneklerinin 15 dakika süre boyunca gözleri kapalı olarak EEG sinyalleri kaydedilmiştir. Veriler, 19 EEG kanalıyla standart 10-20 EEG montajı kullanılarak 250 Hz örnekleme frekansı ile elde edilmiştir. Bu kanallar Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, 01, 02'dir. Şizofreni grubundaki deneklere Uluslararası Hastalık Sınıflandırması ICD10 kriterlerine (kategori F20.0) göre paranoid şizofreni tanısı konulmuş ve Polonya'nın Varşova kentindeki Psikiyatri ve Nöroloji Enstitüsü'ne yatırılmıştır (Olejarczyk ve Jernajczyk 2017).

5.3 Otizm Spektrum Bozukluğu Veri Setleri (Veri Seti 3)

OSB için seçilen üç veri setinin ilki çocuklarda OSB gelişiminde rol oynayan faktörleri içermektedir. Aşağıdaki özelliklerden oluşmaktadır: A10 OSB Bölümü,

Sosyal Duyarlılık Ölçeği, Yaş Yılı, Qchat_10_Score, Konuşma Gecikmesi/Dil Bozukluğu, Öğrenme bozukluğu, Genetik Bozukluklar, Depresyon, Küresel gelişimsel gecikme/zihinsel yetersizlik, Sosyal/Davranışsal Sorunlar, Çocukluk Çağı Otizm Derecelendirme Ölçeği, AB, Cinsiyet, Etnik Köken, Sarılık, OSB'li Aile Hafızası ve Çeşitli Bilgiler (Larxel 2020). Buradaki veriler çocuklarda OSB'nin özelliklerini taşıyan farklı miktar ve faktörlerden oluşmaktadır. Toplamda 1986 adet kayıt bulunmaktadır. Otizm Araştırmaları: Arkansas Üniversitesi Bilgisayar Bilimleri Bölümü'nden hastalık durumlarını analiz etmek ve önceden tahmin etmek amacıyla derlenmiştir.

İkinci veri seti, küçük çocuklarda otizmi taramak için Dr Fadi Fayez Thabtah tarafından ASDTests adlı bir mobil uygulama kullanılarak geliştirilmiştir. Bu veri setinde, davranış bilimindeki kontrollerden OSB vakalarını tespit etmede etkili olduğu kanıtlanmış on davranışsal özelliği (Q-Chat-10) artı diğer bireysel özellikleri kaydedilmiştir (Thabtah 2017). Veri setindeki kayıt sayısı 1054 ve sınıf değişken sayısı 18'dir (Thabtah 2018).

Üçüncü veri seti, başvuru formunu dolduran 700'den fazla ergen ve yetişkinin anket sonuçlarından oluşmaktadır. Kişinin otizm tanısı alıp almadığını gösteren etiketler mevcut olup, MÖ modellerinin otizm olasılığını tahmin etmesine olanak tanıyarak sağlık profesyonellerinin kaynaklarını önceliklendirmesine olanak tanımaktadır (Thabtah 2017).

5.4 İntihar ve Depresyon Tespiti Veri Seti (Veri Seti 4)

Veri kümesi, Reddit platformunun "SuicideWatch" ve "depresyon" alt dizilerindeki gönderilerin bir koleksiyonudur. Gönderiler Pushshift API kullanılarak toplanmıştır. 16 Aralık 2008'den (yaratılma) 2 Ocak 2021'e kadar "SuicideWatch"a gönderilen tüm gönderiler toplanırken, "depresyon" gönderileri 1 Ocak 2009'dan 2 Ocak 2021'e kadar toplanmıştır. SuicideWatch'tan toplanan tüm gönderiler toplanmıştır. İntihar olarak etiketlenirken, depresyon alt dizisinden toplanan gönderiler depresyon olarak etiketlenir. İntihar içermeyen gönderiler gençlerden toplanmaktadır (Komati 2021). Bu çalışmada sadece depresyon verileri kullanılmıştır.

5.5 Demans MRI Önışlemesiz Veri Seti (Veri Seti 5)

Veri setinde veriler çeşitli web sitelerinden/hastanelerden/kamuya açık depolardan toplanmıştır. Veri Seti, Önceden İşlenmiş MRI Görüntülerinden oluşmaktadır. Tüm resimler 128 x 128 piksel olarak yeniden boyutlandırılmıştır. Veri Seti toplam 6400 MRI görüntüsünden oluşmaktadır. Veri Kümesinin dört görüntü sınıfı vardır. Sınıf – 1, Hafif Demanslı (896 resim); Sınıf – 2, Orta Derecede Demans (64 resim); Sınıf – 3, Demanssız (3200 resim); Sınıf – 4, Çok Hafif Demanslı (2240 resim) resim bulunmaktadır (Kumar ve Shastri 2022).



6. UYGULAMA SONUÇLARI

6.1 Veri Seti 1 için Deney Sonuçları


Veri seti içerisinde 53 kolon ve 13461 satırdan oluşmaktadır. Veri seti içerisindeki kolonların özellikleri Şekil 6.1’de gösterilmiştir. Count kolonu, satırlardaki verilerin adetini göstermektedir. Mean kolonu, satırlardaki verilerin ortalamasını gösterilmiştir. Std kolonu ise satırlardaki verilerin standart sapmasını gösterilmiştir. 12081 adet veri kullanılmıştır. Bu verilerden 9664 adeti eğitim için kullanılırken, 2417 adeti test için kullanılmıştır.

	count	mean	std
GAD1	13464.0	0.860963	0.926542
GAD2	13464.0	0.673351	0.915724
GAD3	13464.0	0.965761	0.982776
GAD4	13464.0	0.724079	0.921971
GAD5	13464.0	0.488042	0.837014
GAD6	13464.0	0.911022	0.931168
GAD7	13464.0	0.588755	0.894408
SWL1	13464.0	3.720440	1.736264
SWL2	13464.0	4.602050	1.696276
SWL3	13464.0	4.345440	1.809430
SWL4	13464.0	3.762032	1.818136
SWL5	13464.0	3.358883	1.916319
Hours	13434.0	22.247357	70.284502
highestleague	0.0	NaN	NaN
streams	13364.0	11.233538	78.549209
SPIN1	13340.0	0.856897	0.907351
SPIN2	13310.0	1.210969	1.144054
SPIN3	13324.0	1.095392	1.164982
SPIN4	13305.0	1.682976	1.229730
SPIN5	13298.0	1.248985	1.221828
SPIN6	13308.0	1.348287	1.279251
SPIN7	13326.0	1.050503	1.221171
SPIN8	13320.0	1.405030	1.372777
SPIN9	13306.0	1.567338	1.383539
SPIN10	13304.0	0.917769	1.125849
SPIN11	13277.0	1.827446	1.488372
SPIN12	13296.0	0.892148	1.158235
SPIN13	13277.0	0.538827	0.944180
SPIN14	13308.0	1.252405	1.207463
SPIN15	13317.0	1.411054	1.349874
SPIN16	13317.0	0.620635	0.961853
SPIN17	13289.0	0.935962	1.180456
Narcissism	13441.0	2.027677	1.061842
Age	13464.0	20.930407	3.300897
GAD_T	13464.0	5.211973	4.713267
SWL_T	13464.0	19.788844	7.229243
SPIN_T	12814.0	19.848525	13.467493

Şekil 6.1: Veri seti 1’e ait öznitelikler.

Verilerin incelemesi yapıldıktan sonra Hours ve streams kolonları birleştirilip 115 saatten fazla ve 0 saat oynayan oyuncuların verileri çıkartılmıştır. GADE sütunu için boş gelen satırlar, en çok tekrar eden veri ile doldurulmuştur. Streams kolonundaki eksik değerler streams kolonunun ortalama değeri ile doldurulmuştur. Hours kolonundaki eksik değerler hours kolonunun ortalama değeri ile doldurulmuştur. League kolonundaki eğerler küçük harfe döndürüldü ve boşluklar silinmiştir. League kolonu için veri standardizasyonu yapılmıştır. Birthplace ve Birthplace_ISO3 sütunları silinmiştir. Çoğu kolon için eksik veya az olan değerler en çok tekrar eden değer ile doldurulmuştur. Residence ve accept sütunları kaldırılmıştır.






Şekil 6.2: Veri seti 1'e ait korelasyon haritası.


Verilerin birbirleri ile olan ilişkisini gösteren korelasyon haritası ise Şekil 6.2'de bulunmuştur. Haritadaki koyu renkler pozitif değerdir ve yüksek korelasyon olduğunu gösterirken, açık renkler negatif değer alır ve aradaki ilişkinin düşük olduğunu göstermektedir. Korelasyon haritası verilerin arasındaki ilişkiyi daha hızlı tespit etmemizi sağlamaktadır. 0,8 tam korelasyonu, 0,4 negatif korelasyonu ve 0 değeri ise hiç korelasyon olmadığını belirtmektedir. Haritayı incelediğimizde GAD_T değeri ile GAD1, GAD2, GAD3, GAD4, GAD5, GAD6 ve GAD7 değerleri arasında yüksek korelasyon olduğunu; SWL_T değeri ile ise SWL1, SWL2, SWL3, SWL4, ve

SWL5 değerleri arasında yüksek korelasyon olduğunu; SPIN_T değeri ile SPIN değerleri arasında yüksek korelasyon olduğunu gözlemlenebilmektedir.

Normalizasyon aşamasında Hours, streams, Age, GAD_T, SWL_T ve SPIN_T kolonları için MinMaxScaler fonksiyonu kullanılmıştır. GAD_T, SWL_T, SPIN_T, Hours ve streams kolonları kullanılarak ve korelasyon haritasından yararlanarak 5 adet etiket seçilmiştir. 5 farklı gruba kümelendirerek veri incelemelerine devam edildiğinde Şekil 6.3 ve Şekil 6.4'teki grafikler ortaya çıkmaktadır.



Şekil 6.3: Veri seti 1 için etiketlere göre veri sayılarının sütun grafiği.



Şekil 6.4: Veri seti 1'in kümelenme görüntüsü.

Verilerin dengede olup olmadığını kontrol etmek adına 5 adet etiket içerisindeki veri sayılarına bakılmıştır. 1 numaralı etikette 1662 adet veri, 2 numaralı etikette 1987 adet veri, 3 numaralı etikette 1124 adet veri, 4 numaralı etikette 2783 adet veri ve 5 numaralı etikette 2659 adet veri bulunmaktadır. Etiketlere göre GAD_T, SWL_T, SPIN_T, Hours ve streams kolonları ile olan ilişkilerine tek tek bakıldığında aşağıdaki maddeler yorumlanmaktadır.

- L0; İzlemek yerine oyun oynamayı tercih etmektedir ve hayattan memnun ama sosyal fobisi yüksektir.
- L1; Hayattan memnundur ve yalnız ya da insanlar ile oyun oynamak herhangi bir sorun değildir yani sosyal fobisi bulunmamaktadır.
- L2; Hayattan memnundur fakat sosyal fobisi yüksektir.
- L3; Anksiyetesi yüksektir ve bu sebeple de hayattan hiç memnun değildir.
- L4; Hayattan pek memnun değildir, anksiyetesi vardır ve sosyal fobisi de vardır.

Etiketlenmiş veri seti eğitim ile test olmak üzere X_{train} , X_{test} , y_{train} ve y_{test} olarak 0.8 oranında rastgele ayrıştırılmıştır.

6.1.1 XGBoost ve Hiperparametre Optimizasyon Sonuçları

Veri seti üzerinde XGBoost MÖ algoritması kullanılmıştır. Model hazırlanırken bazı parametreler sabit verilmiştir. Ağaç sayısı 200, derinlik değeri 200, öğrenme katsayısı 0.1, satır oranı 0.7 ve sütun alt örnekleme değeri 0.8 verilmiştir. Bu eğitim sonucunda L0 etiketi için 0.94 hassasiyet, 0.93 duyarlılık, 0.93 f1-skoru ile diğer etiketlere göre ortalama sonuç vermektedir. L1 etiketi diğer etiketler arasında tüm metrik sonuçları ile en yüksek oranda sonuç vermektedir. 0.96 duyarlılık, 0.97 duyarlılık ve 0.97 f1-skor sonuç vermektedir. L4 etiketi L1 etiketinden sonra en yüksek hassasiyet oranı olan 0.95 sonuç vermektedir. L3 etiketi L1 etiketinden sonra en yüksek duyarlılık ve f1-skoru oranları olan 0.96 ve 0.95 oranları ile sonuç vermektedir. Model genel olarak 0.94 doğruluk oranı ile sonuçlanmıştır. Tüm sonuçlar Tablo 6.1'de görülmektedir.

Tablo 6.1: Veri seti 1 için XGBoost modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.94	0.93	0.93
1	0.96	0.97	0.97
2	0.94	0.89	0.91
3	0.90	0.96	0.93
4	0.95	0.95	0.95

Daha sonrasında hiperparametre optimizasyonu yapılmıştır. Parametre optimizasyonu için Izgara Arama (GridSearch) fonksiyonu kullanılmıştır. Ağaç derinliği değer aralığı 3'ten 9'a kadar; öğrenme katsayı değerleri 0.01 ile 0.1 aralığı; satır oranı aralığı 0.5 ile 1 arasında; ağaç sayısı değerleri 100, 200 ve 250 ve sütun alt örnekleme değerleri 0.7, 0.8, 0.9 ve 1 vermektedir. Izgara arama sonucunda en iyi sonuçlar sütun alt örnekleme değeri 1, öğrenme katsayısı 0.09, ağaç derinliği 4, ağaç sayısı 250, satır oranı 0.6 olarak sonuç vermektedir. En iyi parametreler ile kurgulanan deneyin sonuçları Tablo 6.2'de bulunmaktadır. Bu eğitim sonucunda L0 etiketi için 0.98 hassasiyet, 0.98 duyarlılık, 0.98 f1-skoru ile diğer etiketlere göre ortalama sonuç vermektedir. L0 etiketi diğer etiketler arasında tüm metrik sonuçları ile en yüksek oranda sonuç vermektedir. Hiperparametre optimizasyonu öncesinde L1 en başarılı sonuçları verirken hiperparametre optimizasyonu sonucunda L0 olmaktadır. Duyarlılık için L0'dan sonra en iyi sonuçları L1 ve L3 vermektedir. F1-Skoru için ise L0'dan sonra L3 etiketi 0.97 oranı ile sonuç vermektedir. Hiperparametre optimizasyonu öncesinde doğruluk oranı 0.94 iken, hiperparametre optimizasyonu sonra doğruluk oranı 0.96 olmaktadır.

Tablo 6.2: Veri seti 1 için XGBoost modeline ait hiperparametre deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.98	0.98	0.98
1	0.94	0.97	0.96
2	0.96	0.96	0.96
3	0.96	0.97	0.97
4	0.96	0.92	0.94

6.1.2 LightGBM ve Hiperparametre Optimizasyon Sonuçları

Veri seti üzerinde LightGBM MÖ algoritması kullanılmıştır. Algoritma varsayılan parametreler ile kullanılmıştır. Sütun alt örnekleme parametresinin değeri 1.0, öğrenme katsayısı 0.1, minimum örnek ağırlığı 20, yapak sayısı 31 olarak varsayılan değerlerdir. LightGBM algoritması çalışma sonrası eğitim sonucu 0.96 sonucunu vermektedir. Algoritmanın test sonuçları ise Tablo 6.3'te bulunmaktadır. L0 etiketi 0.98 oranı ile hassasiyet, 0.98 oranı ile duyarlılık ve 0.98 oranı ile f1-skor metrikleri arasında en yüksek sonuçlara sahiptir. Hassasiyet metriğinde L0'dan sonra L2 ve L3 değerleri 0.96 oranları ile takip etmektedir. Modelin doğruluk sonucu 0.96 başarı elde etmektedir.

Tablo 6.3: Veri seti 1 için LightGBM modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.98	0.98	0.98
1	0.93	0.98	0.96
2	0.96	0.94	0.95
3	0.96	0.97	0.96
4	0.94	0.92	0.93

Hiperparametre optimizasyonu için parametre uzayı için ağaç derinlik değerleri 3, 4 ve 9; öğrenme katsayısı aralığı 0.01 ile 0.1 arası; satır oranı aralığı 0.5 ile 0.9; yaprak sayısı değerleri 150, 160, 170, 1500 ve 1600; yapraktaki minimum veri

sayısı değerleri 110, 120, 140 ve 150; ağaç sayısı değerleri 130, 140, 150, 190 ve 200 olarak seçilmiştir. Parametre optimizasyonu için Izgara arama fonksiyonu kullanılmıştır. Izgara arama sonucu en başarılı parametre sonuçları öğrenme kaysatısı değeri 0.1, ağaç derinliği değeri 4, yapraktaki minimum veri sayısı 150, ağaç sayısı değeri 220, yaprak sayısı değeri 1200, satır oranı değeri 0.1 sonucu çıkmaktadır. Hiperparametre optimizasyon sonucunda çıkan en iyi parametre sonuçları ile deney tekrar kurulduğunda Tablo 6.4'teki sonuçlar çıkmaktadır. Model doğruluğu parametre optimizasyonu öncesi doğruluk ile aynı olup 0.96'dır.

Tablo 6.4: Veri seti 1 için LightGBM modeline ait hiperparametre deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.98	0.98	0.98
1	0.94	0.98	0.96
2	0.98	0.94	0.96
3	0.95	0.98	0.97
4	0.95	0.92	0.93

6.1.3 KNN ve Hiperparametre Optimizasyon Sonuçları

Veri seti üzerinde KNN MÖ algoritması kullanılmıştır. Algoritma için komşu sayısı parametresi 3 olarak seçilmiştir. Diğer parametreler varsayılan olarak algoritmanın içerisinde bulunmaktadır. KNN metrik sonuçları Tablo 6.5'te bulunmaktadır. Deney sonucu 0.65 doğruluk sonucu ile düşük bir sonuç çıkarmıştır. L1, 0.86 sonucu ile hassasiyet metriğinde ve 0.77 F1-skoru ile en yüksek başarıyı elde etmiştir. L3, 0.85 ile duyarlılık alanında en yüksek sonuca ulaşmıştır.

Tablo 6.5: Veri seti 1 için KNN modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.60	0.57	0.59
1	0.86	0.69	0.77
2	0.41	0.62	0.49
3	0.53	0.85	0.65
4	0.65	0.61	0.63

Parametre uzayı olarak sadece komşu sayısı parametresi 1 ile 31 arasında değer aralığı verilmiştir. Bu aralıkta en iyi parametreler komşu sayısı parametresi için 20 olmuştur. Deney tekrar kurulduğunda komşu sayısı değeri 20 ile değiştirildi ve deney tekrar çalıştırılmıştır. Deney sonuçları Tablo 6.6'da verilmiştir. Sadece tek bir parametre değiştirilmesine rağmen yeni deneyin doğruluk oranı 0.65'ten 0.72'e çıkmıştır. L0 hassasiyet oranı 0.95'e çıkarken L1'in hassasiyet oranı 0.58'e düşmüştür. Duyarlılık metriğinde ise L1 etiketi 0.92'e çıkarak en yüksek değere sahiptir. L0, f1-skor değeri 0.83 ile diğer etiketler arasında en yüksek değere sahiptir.

Tablo 6.6: Veri seti 1 için KNN modeline ait hiperparametre deney sonucu

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.95	0.74	0.83
1	0.58	0.92	0.71
2	0.62	0.68	0.65
3	0.80	0.67	0.73
4	0.39	0.76	0.52

6.1.4 RF ve Hiperparametre Optimizasyon Sonuçları

Veri seti üzerinde RF MÖ algoritması kullanılmıştır. Algoritma için ağaç sayısı parametre değeri 1000, rastgele sayı oluşturucu 44 ve ağaç derinliği değeri ise 8 olarak seçilmiştir. Geri kalan parametreler varsayılan olarak gelmektedir. RF modelinin test sonuçları Tablo 6.7'de bulunmaktadır. Deneyin test doğruluğu ise 0.82 sonucunu

vermiştir. L1; 0.89 ile en yüksek kesinlik metrik, 0.87 ile f1-skor değerlerine sahiptir. L3, 0.96 ile en yüksek duyarlılık değerine sahiptir.

Tablo 6.7: Veri seti 1 için RF modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.81	0.80	0.80
1	0.89	0.86	0.87
2	0.72	0.77	0.75
3	0.76	0.96	0.85
4	0.83	0.78	0.81

Hiperparametre optimizasyonu için parametre uzayı için ağaç derinliği 10 ile 110 arasında; özellik sayıları 2 ve 3; yaprak örnek sayısı 1 ile 11 arasında, minimum örnek sayısı aralığı 1 ile 15 arasında ve ağaç sayısı değerleri 500 ile 1000 arasında seçilmiştir. Parametre uzayında, uzay geniş seçildiği için Izgara Arama algoritması yerine Rastgele Arama (RandomizedSearchCV) algoritması kullanılmıştır. Rastgele Arama algoritması sonucunda en iyi parametreler ağaç sayısı değeri 800, minimum örnek sayısı 6, minimum yaprak sayısı 1, özellik sayısı 3, maksimum derinliği 110 olarak sonuçlanmıştır. Rastgele arama sonucunda çıkan en iyi parametreler modele verilmiştir. Yeni parametreler ile çalışan model sonuçları Tablo 6.8’de verilmiştir. Parametre optimizasyonu ile yapılan deneyin test sonuçlarının doğruluk oranı 0.87’e artmıştır. En fazla artış L0 etiketinde gerçekleşmiştir. Hassasiyet metriğinde en yüksek oran L0 etiketindedir. Duyarlılık metriğinde en yüksek oran L1 etiketindedir. L3 etiketinin duyarlılık oranı parametre optimizasyonuna göre düşüş yaşanmıştır.

Tablo 6.8: Veri seti 1 için RF modeline ait hiperparametre deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.94	0.87	0.91
1	0.82	0.88	0.85
2	0.83	0.82	0.83
3	0.86	0.87	0.86
4	0.86	0.93	0.89

6.1.5 SVM ve Hiperparametre Optimizasyon Sonuçları

Veri seti üzerinde SVM MÖ algoritması kullanılmıştır. Algoritma için SVM'nin varsayılan parametreleri kullanılmıştır. SVM modeli ile yapılan deney sonuçları Tablo 6.9'da bulunmaktadır. Deney sonucunda doğruluk oranı 0.76 sonucu çıkmıştır. Hassasiyet oranı olarak en başarılı sonucu L1 etiketi vermiştir. Duyarlılık metriğinin oranı ise en yüksek 0.91 oranı ile L3 etiketidir. Fakat duyarlılık metriği yüksek bir oran iken hassasiyet oranı oldukça düşüktür ve FN sayısının FP oranından daha az olduğu sonucu çıkarılabilmektedir. L1 etiketi, f1-skoru için diğer etiketler arasında en yüksek orana sahiptir.

Tablo 6.9: Veri seti 1 için SVM modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.73	0.73	0.73
1	0.88	0.82	0.85
2	0.62	0.72	0.67
3	0.67	0.91	0.77
4	0.79	0.71	0.75

SVM için hiperparametre uzayı için seçilen parametreler C değerleri 0.1, 1 ve 10; çekirdek türleri lineer, rbf ve poli; düğüm skoru değerleri 0.1 ve 1 olarak seçildi. Izgara arama algoritması kullanılarak en iyi değerler seçilmiştir. Izgara arama algoritması sonucunda en iyi parametre değerleri C değeri 10, düğüm skoru 0.1, çekirdek ise lineer olarak sonuç vermiştir. En iyi hiperparametre değerleri SVM modeline eklendi ve model tekrar çalıştırılmıştır. Modelin test sonuçları Tablo 6.10'da bulunmaktadır. Standart SVM modeli ile alınan doğruluk sonucu 0.76 iken yeni deney sonucu 0.97 ile üstün bir artış ve doğruluk puanı elde etmiştir. Tüm etiketler de hassasiyet, duyarlılık ve f1-skor metrik değerlerinde yüksek bir artış görülmüştür. Etiketler arasında en yüksek artık L0 etiketi için gerçekleşmiştir.

Tablo 6.10: Veri seti 1 için SVM modeline ait hiperparametre deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.98	0.98	0.98
1	0.94	0.96	0.95
2	0.95	0.96	0.96
3	0.97	0.97	0.97
4	0.97	0.95	0.96

6.1.6 Tüm Deney Sonuçlarının Karşılaştırılması

İlk veri seti için tüm deneylerin MÖ teknikleri ile karşılaştırma tablosu Tablo 6.11’de bulunmaktadır. Tabloda, XGBoost, LightGBM, KNN, RF ve SVM MÖ algoritmalarının standart parametreler ile alınan sonuçları ile hiperparametre optimizasyonu yapıldıktan sonra çıkan en iyi parametreler kullanılarak hazırlanan modeller ile alınan sonuçlar bulunmaktadır.

Standart algoritma ile yapılan deneylerin en başarılı sonuç LightGBM ile alınmıştır. Hiperparametre optimizasyonu sonrasında ise en büyük fark 0.76’dan 0.97’e yükselerek SVM’de olmuştur. Ayrıca SVM diğer modeller ile de karşılaştırıldığında en yüksek doğruluk oranını vermiştir. LightGBM için standart ve hiperparametre optimizasyonu doğruluk sonucu arasında herhangi bir fark görülmemiştir.

Ayrıca bu veriseti ile literatürde yapılan çalışmalar ile doğruluk oranı karşılaştırmaları da Tablo 6.11’de bulunmaktadır. Diğer çalışmalar ile tez kapsamında yapılan modeller arasında en başarılı doğruluk sonucunu 0.99 sonucu ile Ağırlıklı Naive Bayes vermektedir. Gharpure ve diğerlerinin (2022) çalışmasında MLP ve SVC karşılaştırmalarında MLP 0.88 ile daha başarılı bir sonuç vermektedir. Fakat tez kapsamında yapılan çalışmada hiperparametre optimizasyonu yapıldıktan sonraki model performansları Gharpure’nin çalışmalarından daha başarılı sonuçlar elde edildiği görülmektedir.

Tablo 6.11: Veri seti 1 için tüm deneylerin doğruluk sonuçları

<i>Model</i>	Standart	Hiperparametre
<i>XGBoost</i>	0.94	0.96
<i>LightGBM</i>	0.96	0.96
<i>KNN</i>	0.65	0.72
<i>Rastgele Orman</i>	0.82	0.87
<i>SVM</i>	0.76	0.97
<i>Ağırlıklı Naive Bayes (Latubessy ve diğ. 2024)</i>	0.99	
<i>Gaussian Naive Bayes (Latubessy ve diğ. 2024)</i>	0.91	
<i>Kategorik Naive Bayes (Latubessy ve diğ. 2024)</i>	0.91	
<i>Multinomial Naive Bayes (Latubessy ve diğ. 2024)</i>	0.61	
<i>SVC (Gharpure ve diğ. 2022)</i>	0.87	
<i>MLP (Gharpure ve diğ. 2022)</i>	0.88	

6.2 Veri Seti 2 için Deney Sonuçları

Veri seti içerisinde 15 kontrol grubunun 15 adet şizofreni hastalarının edf formatında eeg sinyalleri bulunmaktadır. Veriler 19 adet EEG kanalı, 1.00 Hz yüksek geçirgen ve 45.00 Hz alçak geçirgen frekanstan oluşmaktadır.


İlk olarak edf dosyalarının kanal referansları hesaplandı ve gürültüyü azaltmak için hesaplanan referans değeri her kanaldan çıkartılmıştır. İşlemden sonra kanalların frekans değerleri Şekil 6.5’te görülmektedir.

healthy_df.head()																			
	Fp2	F8	T4	T6	O2	Fp1	F7	T3	T5	O1	F4	C4	P4	F3	C3	P3	Fz	Cz	Pz
0	5.417520	2.052663	-0.722774	-10.059695	-24.959618	4.984881	6.772007	7.741116	3.781279	-17.532765	6.478505	2.209278	-6.136842	7.197948	6.367251	-0.612816	6.141798	10.286918	-9.406656
1	2.956190	0.249148	-0.068053	-9.665873	-27.122031	5.617645	7.019227	7.188226	4.962001	-15.597937	5.463867	2.281802	-5.553940	7.882831	6.604726	0.075235	6.325823	10.801766	-8.620652
2	0.291552	-1.432313	0.129960	-7.774743	-25.669193	4.118035	5.821529	6.781807	6.780256	-11.704540	3.307222	2.452698	-4.515427	7.201619	5.774153	0.587431	4.736945	9.706610	-6.593598
3	-1.223277	-2.246108	2.123059	-5.139397	-21.517579	0.844842	3.630629	6.325727	0.352933	-7.398015	0.719092	2.660682	-2.720603	5.593118	0.483254	1.903082	7.477395	-4.133148	h01
4	-1.170055	-2.343491	4.064603	-2.694850	-15.987052	-2.701084	1.435816	5.271372	0.584072	-4.011532	-1.295362	2.846806	-0.087046	3.763834	2.540576	-0.494230	-0.912148	5.015486	-1.825776

schizo_df.head()																			
	Fp2	F8	T4	T6	O2	Fp1	F7	T3	T5	O1	F4	C4	P4	F3	C3	P3	Fz	Cz	Pz
0	-7.330050	0.584119	-1.477679	9.722291	13.916273	-1.683342	4.043875	7.847657	14.363363	12.070614	-10.759373	-6.037262	-2.522359	-2.228997	-1.572304	-0.434662	-9.463202	-10.075182	-8.963879
1	-7.623678	-0.538772	-0.777046	10.428657	13.790679	-4.187495	3.378698	8.544270	15.621131	13.301221	-10.794320	-6.257408	-2.801830	-2.534343	-1.227131	0.671649	-9.280330	-9.821807	-9.792345
2	-6.668268	-0.485381	1.175887	11.071763	12.349929	-5.213441	3.033988	8.058004	14.668209	12.385921	-9.734054	-6.008243	-3.238105	-2.462736	-1.265476	0.953095	-8.501430	-9.247147	-10.872515
3	-4.837835	0.777183	3.107475	11.362611	9.533124	-4.007706	3.035459	6.828077	12.031951	9.577549	-7.945623	-5.380127	-3.829507	-1.653996	-1.243008	0.461321	-7.173519	-8.460243	-12.183286
4	-2.916846	2.408481	4.052032	10.761743	6.108216	-1.313793	3.182462	5.352157	8.664198	5.749640	-6.020817	-4.396006	-4.234257	-0.292242	-0.734225	-0.290287	-5.447177	-7.396022	-13.137259

Şekil 6.5: Veri seti 2 işlem sonrası kanalların frekans değerleri.

Verilerin grafiğe dönüştürülmüş görüntüsü Şekil 6.6’da bulunmaktadır. Grafiği görselleştirmek için chart_studio kütüphanesi kullanılmıştır.



Şekil 6.6: Veri seti 2 EEG verilerinin gösterimi.


EEG verilerinin özelliklerini çıkarımı için sırasıyla Fourier dönüşümü, DWT, CWT ve Burg yöntemleri kullanılarak yeni diziler oluşturulmuştur. Daha sonrasında CNN, LSTM ve GRU modelleri tasarlandı ve deneyler yapılmıştır. Her bir modelin en iyi sonucu için pek çok kez katman artırılıp azaltıldı veya parametre değerleri değiştirilmiştir. Burada paylaşılan modeller en iyi sonuçlara sahip olan modellerdir.

6.2.1 CNN Modeli Sonuçları

CNN modeli için ilk iki katmanda 1D evrişim katmanı seçilmiştir. Filtre sayısı 16, çekirdek sayısı 2 seçilmiştir. Aktivasyon fonksiyonu olarak Relu kullanılmıştır. Üçüncü katman olarak 1D havuzlama katmanı seçildi ve havuz ölçüsü 2 olarak seçilmiştir. Ezberlemeyi engellemek için dördüncü katmanda bırakma katmanı kullanılmıştır. Daha sonrasındaki 4 katmanda aynı şekilde tekrar edildi ve filtre sayısı

32'e çıkarılmıştır. Modelin son katmanında iki kategori seçimi olacağı için aktivasyon fonksiyonu olarak sigmoid seçildi. Modelin çizim grafiği Şekil 6.7'de bulunmaktadır.






Şekil 6.7: Veri seti 2 için CNN modeli şeması.

Modelin öğrenme oranı 0.01 seçilmiştir. Modelin eğitim aşamasında aşırı öğrenmeyi engellemek için modelin kontrol noktası değerleri kaydedilmiştir. Adım sayısı 100 seçilmiştir. Modelin eğitim sonuçları Tablo 6.12’de görülmektedir.

Tablo 6.12: Veri seti 2 CNN modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.74	0.94	0.83
1	0.92	0.68	0.78


Modelin doğruluk oranı 0.81 sonucunu vermiştir. 0 etiketi sağlıklı kontrol grubunu, 1 etiketi ise şizofreni etiketini temsil etmektedir. Hassasiyet metriğinde şizofreni etiketli veriler 0.88 oranında daha başarılı sonuç vermiştir. Duyarlılık metriğinde ise 0.91 oranı ile kontrol grubu daha yüksek bir başarı göstermektedir. F1-skoru için de yine kontrol grubu daha yüksek bir başarı göstermektedir.



Şekil 6.8: Veri seti 2 için CNN modeline ait karışıklık matrisi.

Karışıklık matrisi Şekil 6.8’de bulunmaktadır. 1706 adet veri TP, 1273 adet veri ise TN başarı ile tahmin etmiştir. Şekil 6.9’de öğrenme eğrileri grafikleri


bulunmaktadır. İyi bir uyum için modelin kaybı eğitim veri setinden neredeyse her zaman daha düşük olmalıdır. İlk grafikte 20. adıma kadar iyi bir uyum gözlemlenirken 20. adımdan sonra aşırı uyum sorunun başladığını görülmektedir.



Şekil 6.9: Veri seti 2 için CNN modeline ait öğrenme eğrileri.

6.2.2 LSTM Modeli Sonuçları

LSTM modeli için ilk üç katmanda 1D zaman dağıtık evrişim katmanı seçilmiştir. Filtre sayısı 16, çekirdek sayısı 2 seçilmiştir. Aktivasyon fonksiyonu olarak Relu kullanılmıştır. Ezberlemeyi engellemek için dördüncü katmanda bırakma katmanı kullanılmıştır. Beşinci katmanda zaman dağıtık havuzlama katmanı kullanılmıştır. Altıncı katmanda ise zaman dağıtık düzleştirme katmanı kullanılmıştır. Yedinci ve sekizinci katmanlarda LSTM katmanı kullanılmıştır. Dokuzuncu katmanda tekrar bırakma katmanı kullanılmıştır. Onuncu katmanda düzleştirme katmanı kullanılmıştır. Çıkış katmanında ikili kategori olduğu için sigmoid aktivasyon fonksiyonu kullanılmıştır. LSTM modelinin şeması Şekil 6.10'da görülmektedir.




Şekil 6.10: Veri seti 2 için LSTM modeli şeması.

Modelin eğitim adım sayısı 100 seçildi ve öğrenme oranı 0.01. Modelin eğitim sonuçları Tablo 6.13'te bulunmaktadır.

Tablo 6.13: Veri seti 2 için LSTM modeline ait deney sonuçları


<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.78	0.89	0.83
1	0.88	0.76	0.82

Eğitim doğruluk oranı 0.83 sonucunu vermiştir. Şizofren rahatsızlığının hassasiyet oranı 0.86 ile kontrol grubundan daha yüksek çıkmaktadır. Duyarlılık metriği için ise kontrol grubu 0.86 oran ile daha yüksek sonuç vermektedir. F1-Skoru için heriki grup da eşit sonuç vermiştir.



Şekil 6.11: Veri seti 2 için LSTM modeline ait karışıklık matrisi.


Karışıklık matrisi Şekil 6.11'de bulunmaktadır. 1623 adet veri TP, 1427 adet veri ise TN başarı ile tahmin etmiştir. Şekil 6.12'de LSTM modeli için öğrenme eğri grafikleri bulunmaktadır. LSTM modeli için 22. adıma kadar iyi bir uyum gözlemlenirken daha sonraki adımlar için aşırı uyum gözlemlenmektedir.



Şekil 6.12: Veri seti 2 için LSTM modeline ait öğrenme eğrileri.

6.2.3 GRU Modeli Sonuçları

GRU modeli için ilk katmanda 600 birimlik GRU katmanı kullanılmıştır. İkinci katmanda bırakma katmanı kullanılmıştır. Üçüncü katmanda 300 birimlik GRU katmanı kullanılmıştır. Dördüncü katmanda aşırı ezberlemeyi engellemek için bırakma katmanı kullanılmıştır. Beşinci katmanda düzleştirme katmanı kullanılmıştır. Ara katmanlardan sonra son katmanda sigmoid aktivasyonu kullanılmıştır. GRU modelinin şeması Şekil 6.13'te bulunmaktadır.




Şekil 6.13: Veri seti 2 için GRU modeli şeması.

Tablo 6.14: Veri seti 2 için GRU modeline ait deney sonuçları


<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.80	0.86	0.83
1	0.86	0.79	0.82

Modelin eğitim sonuçları Tablo 6.14’te bulunmaktadır. Eğitim sonucunda doğruluk oranı 0.82 çıkmıştır. Tüm kategoriler için duyarlılık, hassasiyet ve f1-skor oranlarında eşit sonuçlar vermektedirler.



Şekil 6.14: Veri seti 2 için GRU modeline ait karışıklık matrisi.

Modelin karışıklık matrisi Şekil 6.14’te bulunmaktadır. 1566 adet veri TP, 1483 adet veri ise TN başarı ile tahmin etmiştir. Modelin öğrenme eğrisi grafiği Şekil 6.15’te bulunmaktadır. Grafik incelendiğinde, eğitim kaybı için iyileşme gösteren bir öğrenme eğrisi ve doğrulama kaybı için iyileşme gösteren bir öğrenme eğrisi gözlemlenmek ile beraber aşırı öğrenme gözlemlenmektedir.



Şekil 6.15: Veri seti 2 için GRU modeline ait öğrenme eğrileri.

6.2.4 Tüm Deney Sonuçlarının Karşılaştırılması

İkinci veri seti için tüm deneylerin CNN ile hazırlanmış modellerin karşılaştırma tablosu Tablo 6.15'te bulunmaktadır. Tabloda, CNN, LSTM ve GRU modelleri ile alınan sonuçlar bulunmaktadır. Modeller ile yapılan deneyler arasında doğruluk oranı karşılaştırmasında en başarılı sonuç LSTM ve GRU modellerinde görülmektedir. Öğrenme eğrilerini karşılaştırdığımızda ise her üç modelde de aşırı öğrenme gözlemlenmektedir.

Literatürdeki bu veri seti ile yapılan çalışmalar ile karşılaştırma yapılabilmesi adına Tablo 6.15'e doğruluk sonuçları eklenilmiştir. Tablo incelendiğinde CNN-LSTM modellerinin CNN modellerine göre daha başarılı sonuç verdiği görülmektedir. Ayrıca öz nitelik çıkarım çalışmalarının önemli bir fark yarattığı Shoeibi'nin çalışmalarında görülmektedir. EfficientNet ve DenseNet gibi önceden eğitilmiş modeller ile çalışılırken modellere LSTM eklendiği zaman yine doğruluk sonuçlarının ve model başarısının arttığı gözlemlenmektedir.

Tablo 6.15: Veri seti 2 için tüm modellerin doğruluk sonuçları

<i>Model</i>	Doğruluk Oranları
<i>CNN</i>	0.81
<i>LSTM</i>	0.83
<i>GRU</i>	0.82
<i>EfficientNetBO (Bagherzadeh ve diğ. 2022)</i>	0.94
<i>DenseNet121 (Bagherzadeh ve diğ. 2022)</i>	0.96
<i>EfficientNetBO-LSTM (Bagherzadeh ve diğ. 2022)</i>	0.99
<i>DenseNet121-LSTM (Bagherzadeh ve diğ. 2022)</i>	0.99
<i>DT (Shoeibi ve diğ. 2021)</i>	0.64
<i>SVM (Shoeibi ve diğ. 2021)</i>	0.62
<i>CNN-LSTM 1D ReLU + z-Score+L2 (Shoeibi ve diğ. 2021)</i>	0.98
<i>CNN-LSTM 2D ReLU + z-Score+L2 (Shoeibi ve diğ. 2021)</i>	0.99
<i>CNN-LSTM 1D ReLU + z-Score (Shoeibi ve diğ. 2021)</i>	0.93
<i>CNN-LSTM 2D ReLU + z-Score (Shoeibi ve diğ. 2021)</i>	0.94
<i>VGG16-CNN (Aslan ve Akin 2022)</i>	0.99
<i>DNN (Grover ve diğ. 2023)</i>	0.99

6.3 Veri Seti 3 için Deney Sonuçları

Deneylerde veri setini kullanabilmek için üç veri setinin de benzer kolonları ve özellikler tespit edilmiştir. Üç veri seti için de benzer kolonlar; A1, A2, A3, A4, A5, A6, A7, A8, A9, A10, Yaş, Cinsiyet, Etnik, Ailede Otizm Tanısı, Testi Tamamlayan ve OSB Tanısı. Tüm bu benzer kolonlar ile birlikte tüm veri setleri birleştirildiğinde 3473 satır ve 17 adet kolon bulunmaktadır. Daha sonra kolonların içerisindeki veriler normalizasyon için incelenmiştir.

Aynı anlama gelen farklı şekilde yazılmış tüm veriler düzenlenmiştir. 0-10 yaş arası çocuk, 11-15 yaş arası ergen, 16-24yaş arası genç ve 25 yaş üstü yetişkin olmak üzere veriler 4 gruba ayrılmıştır.

6.3.1 XGBoost ve Hiperparametre Optimizasyon Sonuçları

Model hazırlanırken bazı parametreler sabit olarak verilmiştir. Ağaç sayısı 200, maksimum derinlik değeri 7, öğrenme katsayısı 0.1, satır oranı 0.7, sütun alt örnekleme değeri 0.8 verilmiştir.

Eğitim sonucunda 0 etiketi kontrol grubunu, 1 etiketi otizm tanı etiketini temsil etmektedir. Tablo 6.16’ta deney sonuçları görülmektedir. Kesinlik ve F1-skor metriklerinde 1.0 ve 0.99 oranları ile otizm tanı etiketi daha başarılı sonuç vermiştir. Duyarlılık metriğinde ise 0.99 oranı ile kontrol grubu etiketi daha başarılı sonuç vermiştir. Deneyin doğruluk oranı ise 0.98 ile yüksek bir başarı göstermiştir.

Tablo 6.16: Veri seti 3 için XGBoost modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.97	0.99	0.98
1	1	0.98	0.99

Hiperparametre optimizasyonu yapılmıştır. Parametre uzayı için ağaç derinliği 3 ile 9 arasında; öğrenme katsayıları 0.01 ile 0.1 arasında; satır oranı aralığı 0.5 ile 1; ağaç sayısı değerleri 100, 200 ve 250; sütun alt örnekleme değerleri 0.7 ile 1 arasında verilmiştir. Izgara Arama fonksiyonu kullanılmıştır. Fonksiyon sonucunda başarılı parametreler ağaç sayısı değeri 200, ağaç derinliği değeri 8, öğrenme katsayısı 0.1, satır oranı 0.7, sütun alt örnekleme değeri 0.8 çıkmıştır.

En iyi parametreler ile deney tekrar çalıştırıldığı Tablo 6.17’deki sonuçlar çıkmıştır. Hiperparametre optimizasyonu sonrasındaki sonuçlar ile öncesindeki sonuçlar birebir aynı çıkmıştır. Doğruluk oranı da 0.98 oranında sonuç vermiştir.

Tablo 6.17: Veri seti 3 için XGBoost modeline ait hiperparametre deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.97	0.99	0.98
1	1	0.98	0.99

6.3.2 LightGBM ve Hiperparametre Optimizasyonu Sonuçları

Veri seti üzerinde LightGBM MÖ algoritması kullanılmıştır. Algoritmanın varsayılan parametreleri kullanılmıştır.

LightGBM algoritması çalışma sonrası eğitim sonuçları Tablo 6.18’de verilmiştir. Eğitim sonucunda 0.98 doğruluk sonucu vermiştir. Kontrol grubunun etiketi Hayır, otizm tanısı grubunun etiketi ise Evet’tir. Kesinlik metriği 0.99 oranı ile otizm tanısı daha yüksek bir sonuç vermiştir. Duyarlılık metriğinde ise kontrol grubu daha yüksek bir sonuç vermiştir. F1-skorunda ise her iki etiket de 0.98 sonuç ile aynı sonucu vermiştir.

Tablo 6.18: Veri seti 3 için LightGBM modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.97	0.99	0.98
1	0.99	0.97	0.98

Hiperparametre optimizasyonu için seçilen parametreler ve değerleri: ağaç derinliği -2, -3, 2 ve 3; öğrenme katsayısı 0.01 ile 0.1; satır oran aralığı 0.9 ve 1; yaprak sayısı değerleri 150 ile 1600 arasında; yapraktaki minimum veri sayısı 110 ile 150; ağaç sayısı aralığı 90 ile 130 arasında verilmiştir. En iyi parametreyi bulmak için Izgara Arama fonksiyonu kullanılmıştır. En iyi parametreler öğrenme katsayısı 0.8, ağaç derinliği -2, yapraktaki minimum değer sayısı 150, ağaç sayısı değeri 130, yaprak sayısı değeri 150 ve satır oranı değeri 0.9 olarak çıkmıştır.

Hiperparametre optimizasyonu sonrasında en iyi parametreler ile deney tekrar kurulduğunda Tablo 6.19’daki sonuçlar çıkmaktadır. Deney sonucunda 0.98 doğruluk oranı vermiştir. Kesinlik ve f1-skor metrikleri hem evet hem de hayır etiketinde 0.98 oran vermiştir. Duyarlılık metriği ise şizofreni için 0.98 oranını vermiştir. Doğruluk sonuçları hiperparametre optimizasyonu öncesi ve sonrasında aynı oranı vermiştir.

Tablo 6.19: Veri seti 3 için LightGBM modeline ait hiperparametre deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.98	0.97	0.98
1	0.98	0.98	0.98

6.3.3 KNN ve Hiperparametre Optimizasyon Sonuçları

KNN MÖ algoritması veri seti üzerinde kullanılmıştır. Algoritmanın varsayılan parametreleri kullanılmıştır.

KNN MÖ algoritması ile yapılan deney sonucu Tablo 6.20’de bulunmaktadır. Deneyin doğruluk oranı 0.92 sonucunu vermiştir. Otizm grubu için kesinlik ve f1-skor metrikleri sırasıyla 0.94 ve 0.93 oranları ile daha yüksek bir sonuç vermiştir. Duyarlılık metriği ise 0.93 oranı ile kontrol grubu daha yüksek oran vermiştir.

Tablo 6.20: Veri seti 3 için KNN modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.89	0.93	0.91
1	0.94	0.91	0.93

Hiperparametre optimizasyonu, Izgara Arama fonksiyonu kullanılarak yapılmıştır. Parametre uzayı için sadece komşu sayısı parametresi kullanılmıştır. Değer aralığı 1 ile 31 değerleri arasında verilmiştir. En iyi parametre değeri de 5 çıkmıştır. Bu parametre değeri KNN MÖ algoritmasına eklenmiştir ve deney tekrar çalıştırılmıştır. Deney sonuçları Tablo 6.21’de verilmektedir. Deney sonucuna göre 0.92 doğruluk oranı ile sonuçlanmıştır. Kontrol grubu için iyileşme gözlemlenirken otizm grubu için sadece duyarlılık oranında bir iyileşme gözlemlenmektedir.

Tablo 6.21: Veri seti 3 için KNN modeline ait hiperparametre deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.89	0.93	0.91
1	0.94	0.91	0.93

6.3.4 RF ve Hiperparametre Optimizasyon Sonuçları

Veri seti üzerinde RF MÖ algoritması kullanılmıştır. Parametre olarak ağaç derinliği değeri 10 ve satgele sayı oluşturucu 0 olarak seçilmiştir. Geri kalan parametreler varsayılan parametrelerdir.

Seçilen parametreler ile deney sonucu Tablo 6.22’de bulunmaktadır. Deney sonucuna göre model 0.97 sonucunu elde etmiştir. Kesinlik ve f1-skor metrik sonuçları 0.98 oranı ile şizofreni grubu daha yüksek bir sonuç elde etmiştir. Kontrol grubu ise duyarlılık metriği ile 0.98 oranı ile daha yüksek bir başarı elde etmiştir.

Tablo 6.22: Veri seti 3 için RF modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.96	0.98	0.97
1	0.98	0.97	0.98

Hiperparametre optimizasyonu için parametre uzayı Şekil 60’daki gibidir. En iyi parametreyi bulabilmek için Rastgele Arama fonksiyonu kullanılmıştır. Fonksiyon sonucunda en iyi parametre değerleri ağaç sayısı 300, minimum örnek sayısı 6, yapraktaki minimum örnek sayısı 1, özellik sayısı 2, ağaç derinliği 90 olarak sonuç vermiştir.

En iyi parametre değeri ile model tekrar kurgulanıp çalıştırıldığında test sonuçları Tablo 6.23’te bulunmaktadır. Deneyin doğruluk oranı 0.98 sonucunu vermiştir. Şizofreni grubu kesinlik ve f1-skor metrik oranları sırasıyla 0.99 ve 0.98 oranları ile kontrol grubundan daha yüksektir. Kontrol grubu ise duyarlılık metriğinde 0.99 oranı ile şizofreni grubundan daha yüksek sonuç elde etmiştir.

Tablo 6.23: Veri seti 3 için RF modeline ait hiperparametre deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.96	0.99	0.97
1	0.99	0.97	0.98

6.3.5 SVM ve Hiperparametre Optimizasyon Sonuçları

Veri seti üzerinde SVM MÖ algoritması kullanılmıştır. Algoritma için SVM'nin varsayılan parametre değerleri kullanılmıştır.

SVM modeli ile yapılan deney sonuçları Tablo 6.24'te bulunmaktadır. Deneyin doğruluk sonucu 0.85 sonucunu vermiştir. Kontrol grubu kesinlik metriğinde 0.88 sonucunu elde etmiştir. Şizoreni grubu ise duyarlılık ve f1-skor metriklerinde sırasıyla 0.89 ve 0.85 oranlarında daha yüksek başarı elde etmiştir.

Tablo 6.24: Veri seti 3 için SVM modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.88	0.80	0.84
1	0.82	0.89	0.85

Hiperparametre optimizasyonu için Izgara Arama fonksiyonu kullanılmıştır. Izgara Arama sonucunda en iyi parametreler sırasıyla C değeri 10, düğüm skoru değeri 0.1 ve çekirdek ise poli olarak sonuç vermiştir.

Izgara arama sonucunda en iyi parametreler ile yapılan deney sonuçları Tablo 6.25'te bulunmaktadır. Deneyin doğruluk oranı 0.97 olarak sonuç vermiştir. Şizofreni grubu kesinlik metriğinde 0.98 oranını vermiştir. Duyarlılık metriğinde ise kontrol grubu 0.98 oranı ile daha başarılı olmuştur. F1-skor metriğinde ise 0.97 oranı ile iki grup da eşit sonuç vermiştir.

Tablo 6.25: Veri seti 3 için SVM modeline ait hiperparametre deney sonuçları

<i>Etiketler</i>	<i>Kesinlik</i>	<i>Duyarlılık</i>	<i>F1-Skor</i>
0	0.95	0.98	0.97
1	0.98	0.96	0.97

6.3.6 Tüm Deney Sonuçlarının Karşılaştırılması

OSB veri seti için tüm deneylerin MÖ teknikleri ile karşılaştırma tablosu Tablo 6.2d'da bulunmaktadır. Tabloda XGBoost, LightGM, KNN, RF ve SVM MÖ algoritmalarının hiperparametre optimizasyonu öncesi ve sonrası deneylerinin doğruluk metriğinin sonuçları bulunmaktadır.

Hiperparametre optimizasyonu XGBoost, LightGBM ve KNN modellerinin sonuçlarında herhangi bir iyileştirme gerçekleşmemiştir. Hiperparametre optimizasyonunda en etkili farkı SVM modelinde görülmektedir. Hiperparametre optimizasyonu öncesinde yapılan deneylerde en başarılı sonuçları 0.98 oranında XGBoost ve LightGBM modelleri vermiştir. Hiperparametre optimizasyonu sonrasında XGBoost, LightGBM ve RF modelleri 0.98 oranı ile eşit ve en yüksek sonuçları vermiştir.

Aynı veri seti ile literatürde yapılan bazı çalışmalar karşılaştırma için Tablo 6.26'a eklenmiştir. Raj ve Masood (2020) çalışmalarında SVM ve CNN ile 1.0 doğruluk oranı ile oldukça yüksek bir sonuç elde etmişlerdir. Asif Mohamed'in Xception ile yaptığı çalışma ise 0.93 oranı ile her ne kadar iyi bir oran elde etse de bu çalışmadaki hiperparemetre oprimizasyonu yapılan modellerin pek çoğunu geçememektedir.

Tablo 6.26: Veri seti 3 için tüm modellerin doğruluk sonuçları

<i>Model</i>	Standart	Hiperparametre
<i>XGBoost</i>	0.98	0.98
<i>LightGBM</i>	0.98	0.98
<i>KNN</i>	0.92	0.92
<i>Rastgele Orman</i>	0.97	0.98
<i>SVM</i>	0.85	0.97
<i>Naive Bayes (Raj ve Masood 2020)</i>	0.96	
<i>SVM (Raj ve Masood 2020)</i>	1.0	
<i>CNN (Raj ve Masood 2020)</i>	1.0	
<i>KNN (Raj ve Masood 2020)</i>	0.96	
<i>Xception (Asif Mohamed ve diğ. 2022)</i>	0.93	

6.4 Veri Seti 4 için Deney Sonuçları


Veri seti içerisinde 2 adet kolon bulunmaktadır. Kolonlardan birinde cümleler diğesinde ise depresyon ve depresyon olmayan etiketler bulunmaktadır. Cümleler tokenlar haline getirilerek bölünmüştür. Daha sonrasında psikolojik duruma etkisi olmayan kelimelerden bir liste oluşturulmuş ve bunlar veri setinden çıkarılmıştır. Daha sonrasında tüm kelimeler küçük harfe çevrilmiş, eposta bilgileri, noktalama işaretleri ve özel harfler çıkarılmıştır. Daha sonrasında 10000 benzersiz kelime seçilmiştir. Veri seti eğitim ve test olmak üzere 0.3 oranı ile rastgele bölünmüştür.

6.4.1 CNN Modeli Sonuçları

CNN modeli için ilk katmanda gömme katmanı kullanılmıştır. Bu katmanda giriş boyutu (10000) için kelime sayısı, çıkış boyutu gömme boyutu (100) kullanılmıştır. İkinci katman olarak 1D konvülasyon katmanı kullanılmıştır. Filtre sayısı 16 çekirdek sayısı ise 5 ve aktivasyon fonksiyonu olarak relu kullanılmıştır. Üçüncü katman olarak 1D havuzlama seçildi. Dört, beş, altı ve yedinci katmanlar ikinci ve üçüncü katmanların tekrarıdır. Sekizinci katmanda düzleştirme katmanı

kullanılmıştır. Dokuz, on ve onbirinci katmanda yoğun katman kullanılmıştır. Onbirinci katman aynı zamanda çıkış katmanıdır ve aktivasyon katmanı olarak softmax aktivasyon fonksiyonu kullanılmıştır. Modelin şeması Şekil 6.16'da bulunmaktadır.






Şekil 6.16: Veri seti 4 için CNN modeli şeması.

Modelin adım sayısı 25 olarak seçilmiştir. Modelin eğitim aşamasında aşırı öğrenmeyi engellemek için modelin kontrol noktası değerleri kaydedilmiştir. Eğitim sırasında 11. adımda eğitim durmuştur. Eğitim aşamasında 0 etiketi intihar eğilimi olmayanları, 1 etiketi ise intihar eğilimi olanları temsil etmektedir. Modelin eğitim sonuçları Tablo 6.27’de görülmektedir. Modelin doğruluk oranı 0.90 sonucunu vermiştir. 0 etiketli veriler kesinlik metriğinde 0.92 sonucunu vermiştir. 1 etiketli verilerde duyarlılık oranı 0.92 ile 0 etiketinden daha yüksek oran vermiştir. F1-skor ise 1 etiketi 0.91 ile daha yüksek sonucu vermiştir.

Tablo 6.27: Veri seti 4 için CNN modeline ait deney sonuçları


<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.92	0.89	0.90
1	0.89	0.92	0.91

Karışıklık matrisi Şekil 6.17’de bulunmaktadır. 13282 adet veri TP, 13835 veriyi ise TN ile tahmin etmiştir.



Şekil 6.17: Veri seti 4 için CNN modeli karışıklık matrisi.


Şekil 6.18’te öğrenme eğrileri bulunmaktadır. Öğrenme eğrilerini incelendiğinde modelin aşırı uyum gösterdiğini ve sadece eğitim verilerini ezberlediği görülmektedir. Ya da diğer sebep veri kümesinde 10000 adet benzersiz kelimeden oluştuğu için eğitim veri kümesi ile doğrulama veri kümesi farklı özelliklere sahip olduğu için de bu şekilde gerçekleşmiş olma ihtimali bulunmaktadır.



Şekil 6.18: Veri seti 4 için CNN modeli öğrenme eğrileri.

6.4.2 LSTM Modeli Sonuçları

LSTM modeli için ilk katmanda gömülü katman bulunmaktadır. Giriş katman boyutu kelime sayısıdır. İkinci katmanda bırakma katmanı kullanılmıştır. Üçüncü katmanda LSTM katmanı 32 adet filtre kullanılmıştır. Dördüncü katmanda ise ezberlemeyi engellemek için bırakma katmanı kullanılmıştır. Beşinci katmanda ise havuzlama katmanı kullanılmıştır. Son katman ise çıkış katmanıdır ve aktivasyon fonksiyonu olarak softmax kullanılmıştır. LSTM modelinin şeması Şekil 6.19’da görülmektedir.




Şekil 6.19: Veri seti 4 için LSTM modeli şeması.

Deney sonuçları Tablo 6.28’de, karışıklık matrisi ise Şekil 6.20’de bulunmaktadır. Modelin doğruluk oranı 0.90 oranı ile sonuç vermiştir. 0.91 oranı ile 0 etiketinin kesinlik sonucu daha yüksek çıkmıştır. 0.91 oranı 1 etiketinin duyarlılık oranı daha yüksek çıkmıştır. 0.90 oranı ile 1 etiketi F1-Skorda daha yüksek sonuç vermiştir.


Tablo 6.28: Veri seti 4 için LSTM modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.91	0.88	0.89
1	0.88	0.91	0.90



Şekil 6.20: Veri seti 4 için LSTM modeli karışıklık matrisi.


Öğrenme eğrileri Şekil 6.21’de bulunmaktadır. Öğrenme eğrilerine baktığımızda herhangi bir aşırı öğrenme olmadan uyumlu bir şekilde öğrendiği söylenebilmektedir.



Şekil 6.21: Veri seti 4 için LSTM modeli öğrenme eğrileri.

6.4.3 GRU Modeli Sonuçları

GRU modeli için ilk katmanda gömülü katman kullanılmıştır. İkinci katmanda bırakma katmanı kullanılmıştır. Üçüncü katmanda 100 birimlik GRU katmanı kullanılmıştır. Dördüncü katmanda 0.2 oranı ile bırakma katmanı kullanılmıştır. Beşinci katmanda 100 birimlik GRU kullanılmıştır. Son katmanda ise softmax aktivasyon fonksiyonu kullanılmıştır. GRU modelinin şeması Şekil 6.22’de bulunmaktadır.




Şekil 6.22: Veri seti 4 için GRU modeli şeması.

GRU modeli deney sonuçları Tablo 6.29’da, karışıklık matrisi Şekil 6.23’te bulunmaktadır. Deney sonucuna göre deneyin doğruluk oranı 0.93 oranındadır. İki etiket için de f1-skor metrik sonucu 0.93 oranı ile eşittir. 0 etiketinin kesinlik metrik sonucu 0.94 oranıdır. Duyarlılık metrik oranı 0.95 oranı ile 0 etiketinde daha yüksektir.


Tablo 6.29: Veri seti 4 için GRU modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.94	0.91	0.93
1	0.91	0.95	0.93



Şekil 6.23: Veri seti 4 için GRU modeli karışıklık matrisi.

Öğrenme eğri grafikleri Şekil 6.24’te bulunmaktadır. Öğrenme eğri grafikleri incelendiğinde aşırı öğrenme olmadan çalıştırmayı durduğunu ve 10. adımdan sonra grafiği sabitlediği görülmektedir.



Şekil 6.24: Veri seti 4 için GRU modeli öğrenme eğrileri.

6.4.4 Tüm Deney Sonuçlarının Karşılaştırması

Dördüncü veri seti için tüm deneylerin CNN ile hazırlanmış modellerinin karşılaştırma tablosu Tablo 6.30'da bulunmaktadır. Tabloda CNN, LSTM ve GRU modelleri ile alınan sonuçlar bulunmaktadır. Modeller ile yapılan deneyler arasında doğruluk oranı karşılaştırmasında en başarılı sonuç GRU modelinde alınmıştır. Fakat öğrenme eğrileri incelendiğinde aslında en başarılı modelin LSTM olduğunu söylenebilmektedir.


Literatürdeki diğer çalışmalar ile karşılaştırılabilmesi için Tablo 6.30'da bu veri seti ile yapılan diğer çalışmaların doğruluk sonuçları eklenmiştir. Allayla ve diğerleri (2024) makine öğrenmesi modelleri ile yaptıkları çalışmada ekledikleri özellik çıkarımları ile bu tez kapsamında hazırlanan GRU modeli ile aynı sonucu vermektedir. Eswar ve diğerleri (2023) çalışmalarında kendilerinin geliştirdikleri FTDD modeli 0.95 doğruluk oranı ile en başarılı doğruluk sonucunu vermektedir. Bu doğruluk sonucu Fourier Dönüşümünün bu veri seti üzerindeki önemini göstermektedir. Gupta ve Pirzada (2023) önerdikleri GLOVE – LSTM modeli 0.93 doğruluk oranı ile bu tezde önerilmekte olan GRU modeli ile aynı doğruluk sonucunu vermektedir.

Tablo 6.30: Veri seti 4 için tüm modellerin doğruluk sonuçları

<i>Model</i>	Doğruluk Oranları
<i>CNN</i>	0.90
<i>LSTM</i>	0.90
<i>GRU</i>	0.93
<i>NB (Unigram + Biagram + CV-IDF) (Allayla ve diğ. 2024)</i>	0.90
<i>LR (Unigram + Biagram + CV-IDF) (Allayla ve diğ. 2024)</i>	0.92
<i>DT (Unigram + Biagram + CV-IDF) (Allayla ve diğ. 2024)</i>	0.86
<i>RF (Unigram + Biagram + CV-IDF) (Allayla ve diğ. 2024)</i>	0.85
<i>MLP (Unigram + CV-IDF) (Allayla ve diğ. 2024)</i>	0.93
<i>MLP (Biagram + CV-IDF) (Allayla ve diğ. 2024)</i>	0.88
<i>MLP (Unigram + Biagram + CV-IDF) (Allayla ve diğ. 2024)</i>	0.93
<i>Bert (Eswar ve diğ. 2023)</i>	0.87
<i>Bert + LSTM (Eswar ve diğ. 2023)</i>	0.89
<i>LSTM (Eswar ve diğ. 2023)</i>	0.93
<i>FTDD (Eswar ve diğ. 2023)</i>	0.95
<i>GLOVE + LSTM (Gupta ve Pirzada 2023)</i>	0.93

6.5 Veri Seti 5 için Deney Sonuçları


Veri seti içerisinde önceden işlenmiş, 128x128 piksel olarak boyutlandırılmış 6400 adet MRI görüntüsü bulunmaktadır. 896 adet hafif demanslı, 64 adet orta derecede demans, 3200 adet demanssız ve 2240 adet çok hafif demanslı MRI görüntüsü bulunmaktadır. Veri seti projede hafif demanslı, orta derecede demanslı ve çok hafif demanslı görüntüler birleştirilerek toplamda 3200 adet veri demanslı olarak; demanssız veriler de demanssız olarak etiketlenerek kullanılmıştır. Örnek veri görseli Şekil 6.25'te bulunmaktadır. Görüntüler 1/255 oranında yeniden ölçeklendirilerek veri normalizasyon işlemi yapılmıştır.



Şekil 6.25: Demanslı ve demanssız etiketlenmiş örnek MRI görüntüleri.

6.5.1 CNN Modeli Sonuçları

CNN modeli için giriş katmanı normalizasyon katmanı olarak kullanılarak önce verilere Gaussian gürültüsü 0.15 oranı ile gürültü giderilmiştir. İkinci katmanda 2D konvolüsyonel katmanı filtre sayısı 32 olarak çekirdek boyutu 3x3 matris, aktivasyon katmanında relu kullanılmıştır. Üçüncü katmanda yığın normaliasyon katmanı kullanılmıştır. Dördüncü katmanda 2x2 matrisinde havuzlama katmanı kullanılmıştır. İkinci, üçüncü ve dördüncü katmanlar 3 kez daha tekrar ederek kullanılmıştır. On dördüncü katmanda düzleştirme katmanı kullanılmıştır. Çıkış katmanında softmax aktivasyon fonksiyonu kullanılmıştır. Modelin eğitim esnasında adım sayısı 40 olarak seçilmiştir. CNN modelinin şeması 6.26'da bulunmaktadır.




Şekil 6.26: Veri seti 5 için CNN modeli şeması.

Modelin eğitim sonuçları Tablo 6.31’de bulunmaktadır. 1 etiketi demanslı, 0 etiketi demanssız verilerin etiketidir. Modelin doğruluk oranı 0.98 sonucunu vermiştir. İki etiket için de tüm kesinlik, doğruluk ve F1-skor sonuçları aynı çıkmıştır. Deneyin karışıklık matrisi Şekil 6.27’de gösterilmektedir.


Tablo 6.31: Veri seti 5 için CNN modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.98	0.98	0.98
1	0.98	0.98	0.98



Şekil 6.27: Veri seti 5 için CNN modeli karışıklık matrisi.


Deneyin öğrenme eğri grafikleri Şekil 6.28’de bulunmaktadır. Öğrenme grafiği incelendiğinde hem eğitim verileri hem de doğrulama verileri için adım sayısı arttıkça doğruluk değerinin arttığı görülmektedir. Adım sayısı arttıkça her iki eğrinin de arasındaki farkın azalmakta olduğu görülmektedir. Bu sebeple de hem eğitim verilerinin de hem de doğrulama eğrilerinin uyumlu bir şekilde öğrendiği söylenebilmektedir. Grafikte doğrulama verilerinin eğrilerinde dalgalanmalar görülmediği için de doğrulama sonuçlarının güvenilirliğini arttırmaktadır.



Şekil 6.28: Veri seti 5 için CNN modeli öğrenme eğrileri.

6.5.2 LSTM Modeli Sonuçları

LSTM modeli için giriş katmanını normalizasyon katmanını olarak kullanılarak önce verilere Gaussian gürültüsü 0.15 oranı ile gürültü giderilmiştir. İkinci ve üçüncü katmanda 1D zaman dağıtık evrişim katmanını seçilmiştir. Her iki katmanda da filtre sayısı 16, çekirdek sayısı 2 ve aktivasyon fonksiyonu relu olarak seçilmiştir. Dördüncü katmanda 0.2 oranı ile bırakma katmanını kullanılmıştır. Beşinci ve altıncı katmanında zaman dağıtık havuzlama ve düzleştirme katmanını kullanılmıştır. Yedinci katmanda LSTM katmanını kullanılmıştır. Çıkış katmanında softmax aktivasyon fonksiyonu kullanılmıştır. Modelin şeması Şekil 6.29'da bulunmaktadır. Adım sayısı 40 seçildi fakat aşırı öğrenmeyi engellemek için modelin kontrol noktası değerleri kaydedilmiştir.




Şekil 6.29: Veri seti 5 için LSTM modeli şeması.

Modelin eğitim sonuçları Tablo 6.32’de, karışıklık matrisi Şekil 6.30’da bulunmaktadır. Deney 0.99 doğruluk sonucunu vermiştir. Tüm etiketler için kesinlik, duyarlılık ve F1-skor değerleri 0.99 sonucu ile aynı sonucu vermiştir.


Tablo 6.32: Veri seti 5 için LSTM modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.99	0.99	0.99
1	0.99	0.99	0.99



Şekil 6.30: Veri seti 5 için LSTM modeli karışıklık matrisi.


Öğrenme eğrileri grafikleri Şekil 6.31’de bulunmaktadır. Öğrenme grafiği incelendiğinde hem eğitim verileri hem de doğrulama verileri için adım sayısı arttıkça doğruluk değerinin arttığı görülmektedir. Adım sayısı arttıkça her iki eğrinin de arasındaki farkın azalmakta olduğu görülmektedir. Modelin iyi öğrendiği sonucu çıkarılmaktadır.



Şekil 6.31: Veri seti 5 için LSTM modeli öğrenme eğrileri.

6.5.3 GRU Modeli Sonuçları

GRU modeli için giriş katmanı normalizasyon katmanı olarak kullanılarak önce verilere Gaussian gürültüsü 0.15 oranı ile gürültü giderilmiştir. İkinci katmanda verinin boyutunu GRU katmanına hazırlamak için şekillendirme katmanı kullanılmıştır. Üçüncü katmanda 600 birimlik GRU kullanılmıştır. Dördüncü katmanda bırakma katmanı kullanılmıştır. Beşinci katmanda 300 birimlik GRU katmanı kullanılmıştır. Altıncı katmanda bırakma katmanı kullanılmıştır. Yedinci katmanda düzleştirme katmanı kullanılmıştır. Son katmanda softmax aktivasyon fonksiyonu kullanılmıştır. GRU modelinin şeması Şekil 6.32’de bulunmaktadır.




Şekil 6.32: Veri seti 5 için GRU modeli şeması.

Deneyin eğitim sonuçları Tablo 6.33'te, karışıklık matrisi ise Şekil 6.33'te bulunmaktadır. Modelin doğruluk oranı 0.99 sonucunu vermiştir. Kesinlik metriği için 1 etiketli veriler 0.99 oranı ile daha yüksek bir sonuç vermiştir. 0 etiketi duyarlılık metriğinde 0.99 ile daha yüksek sonuç elde etmiştir. F1-skor metriği her iki etiket için de 0.99 oranı ile aynı sonucu vermiştir.


Tablo 6.33: Veri seti 5 için GRU modeline ait deney sonuçları

<i>Etiketler</i>	Kesinlik	Duyarlılık	F1-Skor
0	0.98	0.99	0.99
1	0.99	0.98	0.99



Şekil 6.33: Veri seti 5 için GRU modeli karışıklık matrisi.

Modelin öğrenme eğrileri grafikleri Şekil 6.34'te bulunmaktadır. Öğrenme grafiklerinde hem eğitim verileri hem de doğrulama verileri için adım sayısı arttıkça doğruluk değerinin arttığı ve çok yakın ilerledikleri görülmektedir. 27. Adımdan sonra grafikteki dalgalanmaların azalması modele olan güveni arttırmaktadır.



Şekil 6.34: Veri seti 5 için GRU modeli öğrenme eğrileri.

6.5.4 Tüm Deney Sonuçlarının Karşılaştırılması

Demans veri seti için tüm deneyler CNN kullanılmıştır. Modellerin doğruluk değerlerinin karşılaştırması Tablo 6.34'te bulunmaktadır. Tabloda CNN, LSTM ve GRU modelleri bulunmaktadır. Modeller arasında en başarılı doğruluk sonuçları 0.99 ile LSTM ve GRU modelleridir. Öğrenme eğrileri incelendiğinde LSTM modelinin öğrenme aşamasında daha az dalgalanma gösterdiği için GRU modeline göre daha güvenilir olduğu söylenebilmektedir.

Bu veri seti ile yapılan literatürdeki diğer çalışmaların doğruluk sonuçları Tablo 6.34'te bulunmaktadır. Hussain ve Shiren (2023) çalışmalarına bakıldığında Watershed algoritmasının SVM doğruluk oranını 0.80'den 0.96'a arttırmış ve CNN'i geçmiştir. Fakat bu tezde hazırlanan CNN modeli, Hussain ve Shiren'in (2023) hazırlamış olduğu CNN modelinin doğruluk oranını geçmiştir. Rahman ve diğerleri (2023) sınıf dengesizliği tekniği ile SVM modeli kullanılarak 0.99 doğruluk oranı elde edilmiştir ve sınıf dengesizliğinin giderilmesinin bu veri seti üzerinde önemli bir katkısı olduğunu göstermektedir. Kaya ve Çetin-Kaya (2024) tasarladıkları Lightweight CNN isimli hiperparametre ince ayarı yapılan model ile 0.99 başarı oranı elde edilmiştir ve hiperparametre ayarının model doğruluk sonucu için önemini göstermektedir. Deshpande ve diğerleri (2024) parçacık sürüsü optimizasyonu ekleyerek ve eklemedikleri versiyonlar ile karşılaştırmalar yapıldığında parçacık sürüsü optimizasyonunun model başarısını arttırdığı görülmektedir. Parçacık sürüsü optimizasyonlu CNN-LSTM hibrit modeli 0.98 doğruluk oranı ile başarısını

yükseltmiştir fakat bu tezde tasarlanan LSTM modeli 0.99 oranı ile daha yüksek bir sonuç elde etmektedir. Yılmaz (2023) çalışmasında tasarladığı CNN modelinde 0.99 doğruluk oranı elde etmektedir fakat aynı zamanda KNN ve SVM modelleri de 0.99 oranı elde edilmiştir.

Tablo 6.34: Veri seti 5 için tüm modellerin doğruluk sonuçları

Model	Doğruluk Oranları
<i>CNN</i>	0.98
<i>LSTM</i>	0.99
<i>GRU</i>	0.99
<i>RF (Hussain ve Shiren 2023)</i>	0.91
<i>SVM (Hussain ve Shiren 2023)</i>	0.80
<i>WS + SVM (Hussain ve Shiren 2023)</i>	0.96
<i>CNN (Hussain ve Shiren 2023)</i>	0.93
<i>SMOTE + SVM (Rahman ve diğ. 2023)</i>	0.99
<i>Lightweight CNN (Kaya ve Çetin-Kaya 2024)</i>	0.99
<i>CNN (Deshpande ve diğ.2024)</i>	0.92
<i>LSTM (Deshpande ve diğ.2024)</i>	0.91
<i>CNN-LSTM (Deshpande ve diğ.2024)</i>	0.93
<i>PSO + CNN (Deshpande ve diğ.2024)</i>	0.96
<i>PSO + LSTM (Deshpande ve diğ.2024)</i>	0.94
<i>PSO + CNN-LSTM (Deshpande ve diğ.2024)</i>	0.98
<i>KNN (Yılmaz 2023)</i>	0.99
<i>SVM (Yılmaz 2023)</i>	0.99
<i>CNN (Yılmaz 2023)</i>	0.99

7. SONUÇ VE DEĞERLENDİRME

Bu tez çalışması, NP rahatsızlıkların YZ teknolojisi ile tespit edilebilirliğini göstermek, doktorların daha hızlı, kolay ve güvenilir teşhis koyabilmelerini sağlamak amacıyla yazılmıştır. Çalışma içerisinde 5 farklı NP rahatsızlık ile ilgili veri setleri kullanılmıştır. Çalışmada kullanılan veriler rahatsızlıklara bağlı olarak çeşitli uluslararası kaynaklardan alınmıştır. Çalışmada tıbbi görüntüler de kullanılmıştır.

YZ algoritmaları ile modeller hazırlanmadan önce veri, modele uygun hale getirilmelidir. Kullanılan veri setine göre verinin hazırlanması, çeşitli grafik yöntemleri kullanılarak verilerin eliminasyondan geçirilmesi modelin öğrenmesini kolaylaştırmaktadır. Ya da kümeleme teknikleri, çok fazla kolonlu ve etiketlenmesi zor olan veri setlerinde nasıl etiketleyeceğimize karar vermede yardımcı olmaktadır. Sinyal içeren veri setleri için dalgacık dönüşümleri kullanılması veriyi daha kullanılabilir hale getirmektedir. Aynı anlama gelen fakat farklı şekilde yazılmış olan verilerin düzeltilmesi de modelin öğrenmesi için pozitif etki yaratmaktadır. Bu çalışmada MÖ modellerinin kullanıldığı iki veri seti üzerinde varsayılan parametre değerleri ile hiperparametre optimizasyonu sonucu çıkan en iyi parametre değerleri karşılaştırmaları yapılmış ve optimizasyonun etkisi gözlemlenmiştir. Üç veri seti üzerinde ise DÖ modellerinden olan CNN, LSTM ve GRU modelleri veri setlerine göre kurgulanmış ve birbirleri ile karşılaştırmaları yapılmıştır.

İlk veri setinde, veri setini nitelikli ve modele uygun hale getirmek için korelasyon ısı haritasından, veri normalizasyonundan ve kümelemeden yararlanılmıştır. MÖ modelleri ise olan XGBoost, LightGBM, KNN, RF ve SVM seçilerek birbirleri arasındaki doğruluk değerlerine göre karşılaştırmalar yapılmıştır. Aynı zamanda hiperparametre optimizasyonunun etkisinin gözlemlenebilmesi için aynı modeller üzerinde hiperparametre optimizasyonu yapılarak çıkan en iyi parametreler ile modeller tekrar kurgulanmış ve eğitilmiştir. Hiperparametre optimizasyonu öncesi SVM %76 doğruluk oranı ile oldukça geride çıkmıştır. Çıkan sonuç ise doğruluk metriği açısından hiperparametre optimizasyonunun modeller üzerinde olumlu bir etkisi olduğunu göstermiştir. Varsayılan parametreler ile yapılan deney sonucunda en iyi model %96 oranı ile LightGBM iken hiperparametre optimizasyonu sonrasında %97 oranı ile SVM öne geçmiştir. Literatürde bu veri seti

ile yapılan diğer çalışmalar ile karşılaştırma yaptığımızda ise Latubessy ve diğerleri (2024) Ağırlıklı Naive Bayes ile 0.99 oranı ile bu tez kapsamında alınan sonuçlardan daha başarılı bir sonuç almaktadır fakat diğer Naive Bayes çalışmaları bu tez kapsamında alınan en başarılı doğruluk sonuçlarından daha yüksek değildir. Gharpure ve diğerler (2022) yapmış olduğu çalışmada SVC ve MLP makine öğrenmesi modelleri bu tez kapsamında yapılan deney sonuçlarından daha yüksek değildir.

İkinci veri setindeki EEG sinyallerinden gürültü azaltılmış olup dalgacık dönüşümleri uygulanmıştır. Bu veri setindeki temel amaç DÖ modellerinin (CNN, LSTM ve GRU) karşılaştırılmasıdır. Doğruluk sonuçlarına bakıldığında GRU %83 oranı ile en iyi sonucu vermiştir. Bu da EEG sinyalleri için GRU gibi daha karmaşık modellerin CNN'e göre daha başarılı olduğunu göstermekte ve şizofreni rahatsızlığının YZ yöntemleri ile tespit edilebileceğine dair umut vermektedir. Öğrenme eğrileri incelendiğinde üç model için de öğrenme eğrisi adım sayısı arttıkça dalgalanmalar yaşanarak güvenilirliği azaltmaktadır. Doğruluma eğrisinin, öğrenme eğrisinden düşük olması ise modellerin yeterince öğrenememesidir. Bunun sebebinin verinin yetersizliğinden kaynaklanabileceği ya da öz nitelik çıkarımının yetersiz olduğu düşünülmektedir. Literatürde bu veri ile yapılan diğer çalışmalar incelendiğinde öz nitelik çıkarımının özellikle üzerinde duran Shoeibi ve diğerleri (2021) hazırlamış oldukları CNN-LSTM 2D ReLU + z-Score + L2 hibrit modelleri 0.99 oranı ile oldukça yüksek bir sonuç elde etmektedirler. Bu da bu tez kapsamında bu veri setinde öğrenme grafiklerindeki doğrulama eğrisinin öğrenme eğrisinden düşük olmasının sebebinin yeterli öz nitelik çıkarımı yapılmadığı sonucu daha ağır basmaktadır. Ayrıca önceden eğitilmiş model kullanan DenseNet121 (Bagherzadeh ve diğerleri 2022) veya VGG16-CNN (Aslan ve Akın 2022) modellerinin de sırası ile 0.96 ve 0.99 doğruluk oranı vermeleri, bu tez kapsamında hazırlanan modellerin de yetersiz kaldığını düşündürmektedir.

Üçüncü veri seti ise 3 farklı veri setinin birbirlerine uygun şekilde birleştirilmesi sonucunda oluşmuştur. Verilerin kullanılabilir olması için ortak kolonlar seçilmiştir. Ankete dayalı veri setleri için MÖ teknikleri daha uygun olduğu için bu modeller kullanılmıştır. İlk veri setinde olduğu gibi aynı 5 model hiperparametre optimizasyonu öncesi ve sonrası olarak birbirleri ile karşılaştırılmıştır. Bu veri seti için kullanılan modeller için genelleme yaparsak yüksek doğruluk oranları

ile sonuç vermiştir. Bu sebeple de hiperparametre optimizasyonu sonrasında SVM hariç ciddi bir fark gözlemlenememiştir. Bu da yüksek doğruluk oranına sahip modellerde karşılaşılması olağan bir durumdur. SVM modeli %85 oranından %97 oranına yükselmiştir. Hiperparametre optimizasyonu öncesi en başarılı modeller XGBoost ve LightGBM olmuştur. Literatürde bu veri setleri ile yapılan çalışmalar incelendiğinde Raj ve Masood (2020) kullanmış oldukları SVM ve CNN modelleri ile 1.0 doğruluk oranı ile oldukça yüksek doğruluk oranı elde ederken KNN modeli ile 0.96 oranı elde edilmiştir ve bu tez kapsamında hiperparametre optimizasyonuna rağmen 0.92 doğruluk oranı elde edilmiştir. Bu da bu tez için seçilen parametre uzayının yeterince kapsamlı olmadığı sonucunu çıkarmaktadır.

Dördüncü veri setinde, kurulan cümlelerden depresyonun ilerlemesi sonucunda karşılaşılan ve hayati tehlikeye sebep olan intihar eğiliminin tespit edilip edilemeyeceği DÖ modelleri ile sınıflandırılmıştır. Cümleler önce tokenlar haline getirilmiş, daha sonrasında anlam ifade etmeyen kelimeler veri setinden çıkarılmış, modele uygun hale getirmek için vektörler haline getirilmiştir. Çok fazla kelime olduğu için kelimeler 10000 adet ile sınırlandırılmıştır. Modeller veriye uygun şekilde kurgulanmıştır. CNN, LSTM ve GRU modelleri tasarlanmıştır. Doğruluk metrikleri karşılaştırıldığında en başarılı sonucu %93 oranı ile GRU modeli vermiştir. Fakat öğrenme eğrileri incelendiğinde her ne kadar en yüksek doğruluk oranına sahip olmasa da LSTM daha güvenilir bir şekilde öğrendiği görülmektedir. Güvenilirlik açısından LSTM'in daha başarılı ve tercih edilebilir olduğu söylenebilir. Bu veri seti ile literatürde yapılan diğer çalışmalar incelendiğinde Eswar ve diğerleri (2023) Fourier Dönüşümlü hibrit bir model önermektedirler ve 0.95 doğruluk oranı sonucu elde edilmiştir ve kelimeler üzerinde Fourier dönüşümünün ne kadar etkili olabileceğini gözler önüne sermektedir. Allayla ve diğerlerinin (2024) makine öğrenmesi modellerinin iyi bir öz nitelik çıkarımı ile derin öğrenme modelleri ile yapılan çalışmalar kadar başarılı olduğu sonucunu göstermektedir.

Beşinci veri seti ise toplamda 6400 adet ön işleminden geçmiş demans rahatsızlığına sahip olan ve olmayan olacak şekilde etiketlenmiş MRI görüntüsünden oluşmaktadır. Görüntüler üzerine sadece yeniden ölçeklendirme ve modeller kurgulanırken giriş katmanlarına görüntülerdeki gürültüyü giderecek algoritma eklenmiştir. Bu deneyde CNN, LSTM ve GRU DÖ modelleri veriye uygun şekilde

hazırlanmış ve karşılaştırılmıştır. Doğruluk oranına göre karşılaştırma yapıldığında en yüksek doğruluk oranına sahip olan modeller %99 oranları ile LSTM ve GRU modelleridir. Bu kadar yüksek bir başarı oranı aşırı öğrenme tereddütü yaşatmaktadır. Bu sebeple de öğrenme eğrileri incelenmiştir. Öğrenme eğrileri incelendiğinde de anlaşılmaktadır ki aşırı öğrenme görülmemektedir. Hem LSTM hem de GRU benzer öğrenme eğrileri göstermektedir. Görseller ile çalışılırken LSTM ya da GRU modelleri önerilebilir. Bu veri seti ile literatürde yapılan çalışmalar incelendiğinde Hussain ve Shiren (2023) makine öğrenmesi modellerini denemiştir ve kullandıkları Watershed algoritması ile SVM modeli 0.96 doğruluk oranı ile yüksek bir başarı elde etmektedirler. Kaya ve Çetin-Kaya (2024) tasarladıkları basit CNN yapısı ile sadece hiperparametre ince ayarı yapılarak modelin 0.99 oranı ile bu tez kapsamında hazırlanan CNN modelinden daha yüksek sonuç elde edilmiştir. Fakat Deshpande ve diğerlerinin (2024) yaptıkları çalışmada kullandıkları CNN, LSTM ve CNN+LSTM modelleri bu tez kapsamında hazırlanan modellerden daha düşük doğruluk oranı vermektedir. Ayrıca parçacık sürüsü optimizasyonu ekleyerek hazırladıkları CNN ve LSTM modelleri de yine bu tez kapsamında hazırlanan modellerden daha düşük sonuç verirken CNN-LSTM modeli 0.98 oranı ile bu tez kapsamında hazırlanan CNN ile aynı sonucu vermektedir fakat LSTM ve GRU modelleri daha iyi sonuç vermektedir.

Bu tez çalışmasında kullanılan MÖ modelleri olan XGBoost, LightGBM, KNN, RF ve SVM modellerinin doğruluk oranları ile hiperparametre öncesi ve sonrası karşılaştırma sonuçları Tablo 7.1'de bulunmaktadır. DÖ modelleri olan ve bu çalışmada kullanılan CNN, LSTM ve GRU modellerinin doğruluk oranları ile karşılaştırılmaları Tablo 7.2'de bulunmaktadır.

MÖ modelleri ile çalışılırken hiperparametre optimizasyonu yapılmadan önce LightGBM her iki veri setinde de yüksek bir doğruluk oranı ile başarı elde etmiştir. Hiperparametre optimizasyonu RF, KNN ve SVM modellerinde yüksek bir artışa sebep olmuştur. Bu modeller ile çalışılırken hiperparametre optimizasyonu yapılarak daha yüksek doğruluk oranı ile başarı elde edilebilir olduğundan önerilebilir.

Tablo 7.1: MÖ modellerinin karşılaştırma tablosu

	Veri Seti 1	Veri Seti 3
XGBoost	0.94	0.98
XGBoost Hiperparametre	0.96	0.98
LightGBM	0.96	0.98
LightGBM Hiperparametre	0.96	0.97
KNN	0.65	0.92
KNN Hiperparametre	0.72	0.93
Rastgele Orman	0.82	0.97
Rastgele Orman Hiperparametre	0.87	0.97
SVM	0.76	0.85
SVM Hiperparametre	0.97	0.97

DÖ modelleri ile çalışırken farklı doğruluk oranları sebebi ile veri setinin önemi gözler önüne serilmiştir. Tüm veri setleri doğruluk sonuçlarına göre incelendiğinde CNN'e nazaran LSTM ve GRU yöntemlerinde daha başarılı sonuçlar elde edilmiştir. DÖ modelleri daha karmaşık yapıya sahip olduğu için görüntü verileri ile çalışırken DÖ modelleri tercih edilmesi özellikle de standart CNN yerine LSTM ya da GRU önerilebilir. 10000 farklı kelimenin ortak özelliklerini de GRU modelinin daha başarılı bir şekilde öğrendiğini ve ayırt edebildiği sonucunu çıkarabiliriz. EEG sinyalleri için ise diğer modellere göre LSTM'in daha başarılı olmasını beklerken GRU ile aynı sonucu vermesi LSTM kadar GRU modelinin de tercih edilebilirliğini arttırmaktadır.

Tablo 7.2: Derin öğrenme modellerinin karşılaştırma tablosu

	Veri Seti 2	Veri Seti 4	Veri Seti 5
CNN	0.81	0.90	0.98
LSTM	0.83	0.90	0.99
GRU	0.82	0.93	0.99

Sonuç olarak bu tez çalışması çeşitli NP rahatsızlıklar için çeşitli YZ tekniklerinin kullanılabilir olduğu ispatlanmıştır. Yapay zeka tekniklerinin daha hızlı ve doğru tanımlar koyması ile erken müdahale ve kişiselleştirilmiş tedavi planları

gerçekleştirilebilir. Aynı zamanda, yapay zeka tabanlı araçlar, nöropsikolojik rahatsızlıklara sahip bireylerin özel ihtiyaçlarına göre rehabilitasyon programları sunarak bireysel gelişimlerini destekleyebilir. Bu çalışma bazı nöropsikolojik rahatsızlıkları yapay zeka temelli sınıflandıran ilk tez çalışması özelliği ile literatüre önemli bir katkısı olacak ve gelecekte daha yeni teknikler ve daha çeşitli nöropsikolojik rahatsızlıklar ile çalışılarak gelecekteki çalışmalara ışık olacak niteliktedir.



8. KAYNAKLAR

Agrawal, D., “Online Gaming Anxiety Data [online]”, (9 January 2024), <https://www.kaggle.com/datasets/divyansh22/online-gaming-anxiety-data/data>, (2020).

Allayla, M. A., and Ayvaz, S., “A Big Data Analytics System for Predicting Suicidal Ideation in Real-Time Based on Social Media Streaming Data”, arXiv preprint arXiv:2404.12394, (2024).

Aldayel, M., and Al-Nafjan, A., “A comprehensive exploration of machine learning techniques for EEG-based anxiety detection”, PeerJ Computer Science, 10, e1829, (2024).

Alsharif, N., Al-Adhaileh, M. H., and Al-Yaari, M., “Accurate Identification of Attention-deficit/Hyperactivity Disorder Using Machine Learning Approaches”, Journal of Disability Research, 3(1), 20230053, (2024).

Asif Mohamed, H. B., Khan, M. S., and Mohan, K. G., “Early Detection Of Autism Spectrum Disorder Using Enhanced Deep-Convolutional Neural Network (Ed-Cnn) Models”, Journal of Pharmaceutical Negative Results, 7801-7805, (2022).

Aslan, Z., and Akin, M., “A deep learning approach in automated detection of schizophrenia using scalogram images of EEG signals”, Physical and Engineering Sciences in Medicine, 45(1), 83-96, (2022).

Ávila-Jiménez, J. L., Cantón-Habas, V., del Pilar Carrera-González, M., Rich-Ruiz, M., and Ventura, S., “A deep learning model for Alzheimer’s disease diagnosis based on patient clinical records”, Computers in Biology and Medicine, 169, 107814, (2024).

Bagherzadeh, S., Shahabi, M. S., and Shalbaf, A., “Detection of schizophrenia using hybrid of deep learning and brain effective connectivity image from electroencephalogram signal”, Computers in Biology and Medicine, 146, 105570, (2022).

Bengio, Y., Simard, P., and Frasconi, P., “Learning long-term dependencies with gradient descent is difficult”, IEEE transactions on neural networks, 5(2), 157-166, (1994).

Candan, H., “Adım Adım Makine Öğrenmesi Bölüm3: Denetimsiz Öğrenme Nedir? [online]”, (12 Mart 2024), <https://medium.com/machine-learning-t%C3%BCrkiye/ad%C4%B1m-ad%C4%B1m-makine-%C3%B6%C4%9Frenmesi-b%C3%B6l%C3%BCm-3-denetimsiz-%C3%B6%C4%9Frenme-nedir-f890ada49a40>, (26 Aralık 2021).

Merter Dereli, S., “Veri Hazırlığının Vazgeçilmezi: Özellik Ölçeklendirme [online]”, (16 Mart 2024), <https://www.veribilimiokulu.com/veri-hazirliginin-vazgecilmezi-ozellik-olceklendirme/>, (7 Ocak 2020).

Çalışkan, A., “Nöropsikoloji-101: Başlangıç [online]”,(4 Mart 2024), <https://blogauraxis.wordpress.com/2020/12/21/noropsikoloji-101-baslangic/>, (2020).

Dakka, J., Bashivan, P., Gheiratmand, M., Rish, I., Jha, S., and Greiner, R., “Learning Neural Markers of Schizophrenia Disorder Using Recurrent Neural Networks”, arXiv, preprint arXiv:1712.00512, (2017).

Dekhil, O., Hajjdiab, H., Shalaby, A., Ali, M. T., Ayinde, B., Switala, A. and El-Baz, A. , “Using Resting State Functional MRI To Build A Personalized Autism Diagnosis System”, PloS One, 13(10), e0206351, (2018).

Deshpande, G., Wang, P., Rangaprakash, D., and Wilamowski, B., “Fully Connected Cascade Artificial Neural Network Architecture for Attention Deficit Hyperactivity Disorder Classification from Functional Magnetic Resonance Imaging Data”, IEEE transactions on cybernetics, 45(12), 2668-2679, (2015).

Dinçer, Y., and Özkan, İ. N. İ. K., “ÇEVRESEL SESLERİN EVRİŞİMSEL SİNİR AĞLARI İLE SINIFLANDIRILMASI”, Konya Journal of Engineering Sciences, 11(2), 468-490, (2023).

De Miras, J. R., Ibáñez-Molina, A. J., Soriano, M. F., and Iglesias-Parro, S., “Schizophrenia Classification Using Machine Learning on Resting State EEG Signal”, Biomedical Signal Processing and Control, 79, 104233, (2023).

Deshpande, P., Dhabliya, R., Khubalkar, D., Upadhye, P. A., Wagh, K. A., and Khetani, V., “Alzheimer Disease Progression Forecasting: Empowering Models Through hybrid of CNN and LSTM with PSO Op-Timization”, In 2024 International Conference on Emerging Smart Computing and Informatics (ESCI) (pp. 1-5), IEEE, (2024, March).

Erdem, M., “Demans Nedir? Belirtileri Nelerdir? Tedavisi Nasıldır? [online]”, (6 Mart 2024), <https://www.erdempsikiyatri.com/demans-nedir>, (2023).

Eswar, T., Varshini, U. S. S., Kumar, V., Srinivas, M., and Krishna, P. R., “FTDD: Representation Learning using Fourier Transformations for Depression Detection in Social Media Content”, In 2023 IEEE 20th India Council International Conference (INDICON), (pp. 1317-1322), IEEE, (2023).

Thabtah, F. , “Autism screening data for toddlers [online]”, (7 January 2024), <https://www.kaggle.com/datasets/fabdelja/autism-screening-for-toddlers>, (2018).

Gao, S., Osuch, E. A., Wammes, M., Théberge, J., Jiang, T. Z., Calhoun, V. D., and Sui, J. , “Discriminating bipolar disorder from major depression based on kernel SVM using functional independent components”, In 2017 IEEE 27th international workshop on machine learning for signal processing (MLSP) (pp. 1-6). IEEE, (2017).

Gajjar, P., Garg, M., Desai, S., Chhinkaniwala, H., Sanghvi, H. A., Patel, R. H., and Pandya, A. S., “An Empirical Analysis of Diffusion, Autoencoders, and Adversarial Deep Learning Models for Predicting Dementia Using High-Fidelity MRI”, IEEE Access, (2024).

Gharpure, N., and Gharpure, N., “Linking Mental Health and Gaming Using C-Support Vectors and Multilayer Perceptrons”, In 2022 4th International Conference on Circuits, Control, Communication and Computing,(I4C), (pp. 18-24), IEEE, (2022).

Grover, N., Chharia, A., Upadhyay, R., and Longo, L., “Schizo-Net: A novel Schizophrenia Diagnosis framework using late fusion multimodal deep learning on Electroencephalogram-based Brain connectivity indices”, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 31, 464-473, (2023).

Guo, H., Cheng, C., Cao, X., Xiang, J., Chen, J., and Zhang, K., “Resting-state functional connectivity abnormalities in first-onset unmedicated depression”, Neural regeneration research, 9(2), 153-163, (2014).

Guo, X., Dominick, K. C., Minai, A. A., Li, H., Erickson, C. A., and Lu, L. J., “Diagnosing Autism Spectrum Disorder from Brain Resting-State Functional Connectivity Patterns Using A Deep Neural Network with A Novel Feature Selection Method”, Frontiers in Neuroscience, 11, 460, (2017).

Gupta, A., and Pirzada, U. S. M., “LSTM Network for Suicide Detection”, In 2023 5th Biennial International Conference on Nascent Technologies in Engineering (ICNTE), (pp. 1-5). IEEE, (2023).

Happé, F., “Understanding Assets and Deficits in Autism: Why success is more interesting than failure”, The Psychologist, 12(11), 540–546, (1999).

Häfner, H., an der Heiden, W., Behrens, S., Gattaz, W. F., Hambrecht, M., Löffler, W. and Stein, A. “Causes and Consequences of the Gender Difference in Age at Onset of Schizophrenia”, Schizophrenia Bulletin, 24(1), 99-113, (1998).

Hussain, M. G., and Shiren, Y., “Identifying Alzheimer Disease Dementia Levels Using Machine Learning Methods”, arXiv preprint arXiv:2311.01428, (2023).

Javeed, A., Anderberg, P., Ghazi, A. N., Noor, A., Elmståhl, S., and Berglund, J. S., “Breaking Barriers: a Statistical and Machine Learning-based Hybrid System for Predicting Dementia”, Frontiers in Bioengineering and Biotechnology, 11, 1336255, (2024).

Jeng, S. L., Tu, M. J., Lin, C. W., Lin, J. J., Tseng, H. H., Jang, F. L., and Lin, S. H., “Machine Learning for Prediction of Schizophrenia Based on Identifying the Primary and Interaction Effects of Minor Physical Anomalies”, Journal of Psychiatric Research, (2024).

Kafes, A. Y., “Depresyon ve Anksiyete Bozuklukları Üzerine Bir Bakış”, Humanistic Perspective, 3(1), 186-194, (2021).

Karthik, S., and Sudha, M., “Predicting bipolar disorder and schizophrenia based on non-overlapping genetic phenotypes using deep neural network”, Evolutionary Intelligence, 14(2), 619-634, (2021).

Kaya, M., and Çetin-Kaya, Y., “A Novel Deep Learning Architecture Optimization for Multiclass Classification of Alzheimer’s Disease Level”, IEEE Access, (2024).

Ke, Q., Liu, J., Bennamoun, M., An, S., Sohel, F., and Boussaid, F., “Computer vision for human–machine interaction”, In Computer vision for assistive healthcare (pp. 127-145). Academic Press, (2018).

Kessler, R. C. and Bromet, E. J., “The Epidemiology of Depression Across Cultures”. Annual Review of Public Health, 34, 119-138, (2013).

Kessler, R. C., van Loo, H. M., Wardenaar, K. J., Bossarte, R. M., Brenner, L. A., Cai, T., and Zaslavsky, A. M., “Testing a machine-learning algorithm to predict the persistence and severity of major depressive disorder from baseline self-reports”, Molecular psychiatry, 21(10), 1366-1371, (2016).

Kerner, B., “Genetics of Bipolar Disorder”, The Application of Clinical Genetics, 33-42, (2014).

Kırık, C., “Derin öğrenme üzerine yapılmış uluslararası yayınların bibliyometrik analizi”, (2024).

Komati N., “Suicide and Depression Detection [online]”, (11 January 2024), <https://www.kaggle.com/datasets/nikhileswarkomati/suicide-watch>, (2021).

Kumar, S., Shastri, S., “Alzheimer MRI Preprocessed Dataset [online]”, (11 January 2024), <https://www.kaggle.com/datasets/sachinkumar413/alzheimer-mri-dataset/data>, (2022).

Lakhan, A., Mohammed, M. A., Abdulkareem, K. H., Hamouda, H., and Alyahya, S., “Autism Spectrum Disorder Detection Framework for Children Based on Federated Learning Integrated CNN-LSTM”, Computers in Biology and Medicine, 166, 107539, (2023).

Latubessy, A., Wardoyo, R., Musdholifah, A., and Kusrohmaniah, S., “Fine tuning attribute weighted naïve Bayes model for detecting anxiety disorder levels of online gamers”, International Journal of Electrical and Computer Engineering (2088-8708), 14(3), (2024).

LeCun, Y., Bengio, Y., and Hinton, G., “Deep learning”, Nature, 521(7553), 436-444, (2015).

Lee, T. R., Kim, G. H., and Choi, M. T., “Geriatric depression and anxiety screening via deep learning using activity tracking and sleep data”, International Journal of Geriatric Psychiatry, 39(2), e6071, (2024).

London, E., “The Role of the Neurobiologist in Redefining the Diagnosis of Autism”, Brain Pathology, 17(4), 408-411, (2007).

Madhuri, U. L., “ASD children traits [online]”, (13 January 2024), <https://www.kaggle.com/datasets/uppulumadhuri/dataset>, (2022).

Metin, B., Uyulan, Ç., Ergüzel, T. T., Farhad, S., Çifçi, E., Türk, Ö., and Tarhan, N., “The deep learning method differentiates patients with bipolar disorder from controls with high accuracy using EEG data”, *Clinical EEG and Neuroscience*, 55(2), 167-175, (2024).

Mikolas, P., Marxen, M., Riedel, P., Bröckel, K., Martini, J., Huth, F., and Pfennig, A., “Prediction of estimated risk for bipolar disorder using machine learning and structural MRI features”, *Psychological Medicine*, 54(2), 278-288, (2024).

Ming, X., Brimacombe, M., and Wagner, G. C. “Prevalence of Motor Impairment in Autism Spectrum Disorders”, *Brain and Development*, 29(9), 565-570, (2007).

Mumtaz, W., Xia, L., Ali, S. S. A., Yasin, M. A. M., Hussain, M., and Malik, A. S., “Electroencephalogram (EEG)-Based Computer-Aided Technique to Diagnose Major Depressive Disorder (MDD)”, *Biomedical Signal Processing and Control*, 31, 108-115, (2017).

Nyholm, J., Ghazi, A. N., Ghazi, S. N., and Berglund, J. S., “Prediction of dementia based on older adults’ sleep disturbances using machine learning”, *Computers in Biology and Medicine*, 108126, (2024).

Özkan, İ. N. İ. K., and Ülker, E., “Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri”, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104, (2017).

Öztürk, M. O., *Ruh Sağlığı ve Bozuklukları*, (Yenilenmiş 8. Basım). Ankara: Nobel Tıp Kitabevleri, (2001).

Qureshi, M. N. I., Oh, J., and Lee, B., “3D-CNN Based Discrimination of Schizophrenia Using Resting-State Fmri”, *Artificial Intelligence in Medicine*, 98, 10-17, (2019).

Olejarczyk, E., and Jernajczyk, W., “EEG in schizophrenia”, *RepOD*, (2017).

Patil, T., Pandey, S., and Visrani, K., “A review on basic deep learning technologies and applications”, *Data Science and Intelligent Applications: Proceedings of ICDSIA 2020*, 565-573, (2020).

Purwono, P., Ma'arif, A., Rahmانيar, W., Fathurrahman, H. I. K., Frisky, A. Z. K., and ul Haq, Q. M., “Understanding of convolutional neural network (cnn): A review”, *International Journal of Robotics and Control Systems*, 2(4), 739-748, (2022).

Rabbi, M. F., Hasan, S. M., Champa, A. I., and Zaman, M. A., “A convolutional neural network model for early-stage detection of autism spectrum disorder”, In *2021 international conference on information and communication technology for sustainable development (icict4sd)* (pp. 110-114). IEEE, (2021).

Raj, S., and Masood, S., “Analysis and detection of autism spectrum disorder using machine learning techniques”, *Procedia Computer Science*, 167, 994-1004, (2020).

Rahman, S. R., Chakraborty, A., Islam, M. R., Islam, T., and Al Mamun, M., “A Machine Learning Algorithm to Detect Alzheimer’s Disease Using MRI Images”, In *2023 6th International Conference on Electrical Information and Communication Technology (EICT)* (pp. 1-6), IEEE, (2023, December).

Riaz, A., Asad, M., Al Arif, S. M. R., Alonso, E., Dima, D., Corr, P., and Slabaugh, G., “Deep fMRI: AN End-to-End Deep Network for Classification of fMRI Data”, In *2018 IEEE 15th International Symposium on Biomedical Imaging*, 1419-1422, (2018).

Richards, C. S. and O'Hara, M. W., *The Oxford Handbook of Depression and Comorbidity*, United States of America: Oxford University Press, (2014).

Sacks, O., *An anthropologist on Mars: Seven paradoxical tales*, Vintage, (2012).

Richter, T., Stahi, S., Mirovsky, G., Hel-Or, H., and Okon-Singer, H., “Disorder-specific versus transdiagnostic cognitive mechanisms in anxiety and depression: Machine-learning-based prediction of symptom severity”, *Journal of Affective Disorders*, 354, 473-482, (2024).

Rubin-Falcone, H., Zanderigo, F., Thapa-Chhetry, B., Lan, M., Miller, J. M., Sublette, M. E., and Mann, J. J., “Pattern recognition of magnetic resonance imaging-based gray matter volume measurements classifies bipolar disorder and major depressive disorder”, *Journal of affective disorders*, 227, 498-505, (2018).

Saurabh, S., and Gupta, P. K., “Deep learning-based modified bidirectional LSTM network for classification of ADHD disorder”, *Arabian Journal for Science and Engineering*, 49(3), 3009-3026, (2024).

Sen, B., Borle, N. C., Greiner, R., and Brown, M. R., “A General Prediction Model for The Detection of ADHD and Autism Using Structural and Functional MRI”, *PloS One*, 13(4), e0194856, (2018).

Sevinçok, L., “Yaygın Anksiyete Bozukluğunun Nörobiyolojisi”, *Klinik Psikiyatri*, 10(5), 3-12, (2007).

Singh, S. A., Meitei, T. G., and Majumder, S., “Short PCG classification based on deep learning”, In *Deep learning techniques for biomedical and health informatics* (pp. 141-164). Academic Press, (2020).

Shoeibi, A., Sadeghi, D., Moridian, P., Ghassemi, N., Heras, J., Alizadehsani, R., and Gorriz, J. M., “Automatic diagnosis of schizophrenia in EEG signals using CNN-LSTM models”, *Frontiers in neuroinformatics*, 15, 777977, (2021).

Soria, C., Arroyo, Y., Torres, A. M., Redondo, M. Á., Basar, C., and Mateo, J., “Method for Classifying Schizophrenia Patients Based on Machine Learning. *Journal of Clinical Medicine*”, 12(13), 4375, (2023).

Spinrad, A., Taylor, C. B., Ruzek, J. I., Jefroykin, S., Friedlander, T., Feleke, I., and Sadeh-Sharvit, S., "Action recommendations review in community-based therapy and depression and anxiety outcomes: a machine learning approach", BMC psychiatry, 24(1), (2024).

Summakoglu, D. and Ertugrul, B. "Şizofreni ve Tedavisi", Lectio Scientific, 2(1), 43-61, (2018).

Stein, D. J., Williams, D.R., "Cultural and social aspects of anxiety disorders.", Textbook of anxiety disorders, 463-474, (2002).

Tabtah, F., "Autism Spectrum Disorder Screening: Machine Learning Adaptation and DSM-5 Fulfillment", Proceedings of the 1st International Conference on Medical and Health Informatics 2017, pp.1-6. Taichung City, Taiwan, (2017).

Tafralı, S., "Makine Öğrenmesi [online]", (12 Mart 2024), <https://medium.com/machine-learning-t%C3%BCrkiye/makine-ogrenmesi-7cfbb3d859db>, (4 Aralık 2022).

Thabtah, F., "Machine Learning in Autistic Spectrum Disorder Behavioural Research: A Review", To Appear in Informatics for Health and Social Care Journal, (2017).

Topçuoğlu, V., "Anksiyete Bozuklukları", Istanbul Kent University J Health Sciences, 1(1), 38-40, (2022).

Tunç, T., and Erdem, H., "Lityum iyon batarya için dikkat mekanizmalı geçitli tekrarlayan birim (GRU) sinir ağını temel alan sağlık durumu (SOH) tahmini", Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 13(2), 639-647, (2024).

Uyulan, C., Ergüzel, T. T., Unubol, H., Cebi, M., Sayar, G. H., Nezhad Asad, M., and Tarhan, N., "Major depressive disorder classification based on different convolutional neural network models: Deep learning approach", Clinical EEG and neuroscience, 52(1), 38-51, (2021).

Waldo-Benítez, G., Padierna, L. C., Ceron, P., and Sosa, M. A., "Dementia classification from magnetic resonance images by machine learning", Neural Computing and Applications, 36(6), 2653-2664, (2024).

Wang, B., Sheu, Y. H., Lee, H., Mealer, R. G., Castro, V. M., and Smoller, J. W., "Machine Learning Models for the Prediction of Early-Onset Bipolar Using Electronic Health Records", medRxiv, 2024-02, (2024).

Wang, C., Xiao, Z., Wang, B., and Wu, J., "Identification of Autism Based on SVM-RFE and Stacked Sparse Auto-Encoder", Ieee Access, 7, 118030-118036, (2019).

Wang, Y., Zhao, S., Jiang, H., Li, S., Luo, B., Li, T., and Pan, G., "DiffMDD: A Diffusion-based Deep Learning Framework for MDD Diagnosis Using EEG", IEEE Transactions on Neural Systems and Rehabilitation Engineering, (2024).

Xie, Y., Yang, B., Lu, X., Zheng, M., Fan, C., Bi, X., and Li, Y., “Anxiety and depression diagnosis method based on brain networks and convolutional neural networks”, In 2020 42nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (1503-1506). IEEE, (2020).

Yağcı, İ., “Nöropsikoloji ve Bozuklukları Nelerdir? [online]”, (7 Mart 2024), <https://dergipsikopol.com/noropsikoloji-ve-bozukluklari-nelerdir/>, (2021).

Yan, W., Calhoun, V., Song, M., Cui, Y., Yan, H., Liu, S., and Sui, J., “Discriminating Schizophrenia Using Recurrent Neural Network Applied on Time Courses of Multi-site fMRI Data”, EBioMedicine, 47, 543-552, (2019).

Yan, W., Plis, S., Calhoun, V. D., Liu, S., Jiang, R., Jiang, T. Z., and Sui, J., “Discriminating schizophrenia from normal controls using resting state functional network connectivity: A deep neural network and layer-wise relevance propagation method”, In 2017 IEEE 27th international workshop on machine learning for signal processing (MLSP) ,pp. 1-6, IEEE, (2017).

Yılmaz, H., “Nöropsikoloji’ye Uzanan Yol [online]”,(4 Mart 2024), <https://noropsikoloji.org/noropsikolojiye-uzanan-yol/>, (2021).

Yoo, J. H., Kang, C., Lim, J. S., Wang, B., Choi, C. H., Hwang, H., and Kim, J. W., “Development of an innovative approach using portable eye tracking to assist ADHD screening: a machine learning study”, Frontiers in Psychiatry, 15, 1337595, (2024).

Zhang, J., Song, L., Miller, Z., Chan, K. C., and Huang, K. L., “Machine learning models identify predictive features of patient mortality across dementia types”, Communications Medicine, 4(1), 23, (2024).

Zheng, P., Yu, Z., Mo, L., Zhang, Y., Lyu, C., Yu, Y., and Li, Y., “An individualized medication model of sodium valproate for patients with bipolar disorder based on machine learning and deep learning techniques”, Frontiers in Pharmacology, 13, 890221, (2022).

Zou, L., Zheng, J., Miao, C., Mckeown, M. J., and Wang, Z. J., “3D CNN Based Automatic Diagnosis of Attention Deficit Hyperactivity Disorder Using Functional and Structural MRI”, IEEE Access, 5, 23626-23636, (2017).

“Demans (Bunama) Nedir? Demans Belirtileri Nelerdir? [online]”, (8 Mart 2024), <https://www.memorial.com.tr/hastaliklar/demans-nedir-demans-hastaligi-belirtileri>, (28 Ağustos 2023).

“Makine Öğrenmesi (Machine Learning) Nedir? [online]”, (12 Mart 2024), <https://www.turhost.com/blog/makine-ogrenmesi-machine-learning-nedir/>, (26 Kasım 2021).