



**DERİN ÖĞRENME YÖNTEMLERİ İLE BEYİN
GÖRÜNTÜLERİNDEN NÖROLOJİK BOZUKLUKLARIN
SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

MUHAMMET KUSEY DAHER

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

**MERSİN
OCAK - 2025**

**DERİN ÖĞRENME YÖNTEMLERİ İLE BEYİN
GÖRÜNTÜLERİNDEN NÖROLOJİK BOZUKLUKLARIN
SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

**MUHAMMET KUSEY DAHER
ORCID ID: 0009-0002-4218-5923**

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

**DANIŞMAN
DR. ÖĞR. ÜYESİ MEHMET ACI
ORCID ID: 0000-0002-7245-8673**

**MERSİN
OCAK - 2025**

ÖZET

DERİN ÖĞRENME YÖNTEMLERİ İLE BEYİN GÖRÜNTÜLERİNDEN NÖROLOJİK BOZUKLUKLARIN SINIFLANDIRILMASI

Nörolojik bozukluklar, beyin, omurilik ve sinir sistemini etkileyen, dünya genelinde milyonlarca insanı etkileyen ciddi sağlık sorunları arasında yer almaktadır. Alzheimer hastalığı, Parkinson hastalığı, akut iskemik inme ve beyin tümörleri gibi nörolojik bozukluklar, her biri kendine özgü klinik özellikleriyle tanı ve tedavi açısından büyük zorluklar sunar. Alzheimer hastalığı, hafıza kaybı ve bilişsel gerilemeyle karakterize edilen progresif bir nörodejeneratif hastalık olup, özellikle yaşlı popülasyonlarda demansın en yaygın nedenidir. Parkinson hastalığı ise, motor semptomlar ve bilişsel bozulmalarla ilerleyen, dopamin eksikliği sonucu ortaya çıkan bir hastalıktır ve yaşlı yetişkinlerde yaygındır. Akut iskemik inme, serebral kan akışının ani kesilmesiyle ciddi nörolojik hasara yol açarak engelliliğin önde gelen nedenlerinden biridir. Beyin tümörleri hem birincil hem de ikincil olarak gelişebilen ve önemli morbidite ve mortalite oranlarına sahip ciddi bozukluklardır. Tüm bu bozukluklar, dünya çapında önemli bir halk sağlığı sorunu olarak kabul edilmekte ve özellikle yaşlanan nüfuslar nedeniyle yaygınlıkları giderek artmaktadır. Bu durum, doğru teşhis ve zamanında tedaviye olan ihtiyacı daha da kritik hale getirmektedir. Bu tez çalışmasında, nörolojik bozuklukların erken teşhisi ve doğru sınıflandırılmasına katkıda bulunmak amacıyla yapay zeka ve derin öğrenme yöntemleri kullanılarak bir model geliştirilmiştir. Özellikle beyin manyetik rezonans görüntüleri (MRI) üzerinden nörolojik bozuklukların sınıflandırılmasını amaçlayan bu çalışma, derin evrişimli sinir ağı (CNN) tabanlı CBMDF-Net modeli ile gerçekleştirilmiştir. Tez kapsamında kullanılan veri setleri, Alzheimer, Parkinson, akut iskemik inme ve beyin tümörleri gibi bozuklukların yanı sıra sağlıklı bireylerin beyin MRI görüntülerini de içermektedir. Modelin performansını test etmek için üç farklı deney yapılmıştır. İlk denemede, beş farklı sınıf (Alzheimer hastalığı, Parkinson hastalığı, akut iskemik inme, beyin tümörleri ve sağlıklı bireyler) üzerinde bir sınıflandırma gerçekleştirilmiş ve model %98.82 doğruluk oranına ulaşmıştır. İkinci denemede, nörolojik bozuklukların alt sınıflarını da kapsayan dokuz farklı sınıf kullanılmış ve model %98.31 doğruluk oranı elde etmiştir. Üçüncü denemede, beyin tümörleri ve Alzheimer hastalığı kendi alt grupları üzerinden sınıflandırılmış ve sırasıyla %99.23 ve %99.52 doğruluk oranlarına ulaşmıştır. CBMDF-Net, bozuklukların farklı aşamalarını ve tiplerini ayırt etmek için kapsamlı bir şekilde eğitilmiş olup, görüntü işleme ve derin öğrenme algoritmaları sayesinde karmaşık beyin yapıları ve patolojilerini doğru bir şekilde analiz etmiştir. Bu bağlamda, modelin elde ettiği yüksek doğruluk oranı, nörolojik bozuklukların teşhisinde derin öğrenme tabanlı yaklaşımların ne kadar etkili olabileceğini göstermektedir. Bu çalışma, nörolojik bozuklukların teşhis süreçlerini hızlandırmak, sağlık profesyonellerine klinik karar verme süreçlerinde destek sağlamak ve hastalara erken müdahale imkanı sunmak açısından önemli bir katkı sunmaktadır. CBMDF-Net modeli, klinik uygulamalarda kullanılabilirliği artırma potansiyeline sahip olup, nörodejeneratif ve akut nörolojik bozuklukların teşhisinde yeni bir adım olarak değerlendirilmektedir.

Anahtar Kelimeler: Nörolojik Bozukluklar, Manyetik Rezonans Görüntüleme, Yapay Zeka, Derin Öğrenme, Evrişimli Sinir Ağı.

Danışman: Dr. Öğr. Üyesi Mehmet ACI, Mersin Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Mersin.

ABSTRACT

CLASSIFICATION OF NEUROLOGICAL DISORDERS FROM BRAIN IMAGES USING DEEP LEARNING METHODS

Neurological disorders are serious health issues that affect the brain, spinal cord, and nervous system, impacting millions of people worldwide. Conditions such as Alzheimer's disease, Parkinson's disease, acute ischemic stroke, and brain tumors each present unique clinical characteristics that pose significant challenges for diagnosis and treatment. Alzheimer's disease is a progressive neurodegenerative disorder characterized by memory loss and cognitive decline, and it is the most common cause of dementia in the elderly population. Parkinson's disease is characterized by motor symptoms and cognitive impairments resulting from dopamine deficiency, commonly affecting older adults. Acute ischemic stroke leads to severe neurological damage due to a sudden interruption of cerebral blood flow, making it one of the leading causes of disability. Brain tumors, which can develop both as primary and secondary lesions, represent serious conditions with significant morbidity and mortality rates. All these disorders are recognized as major public health concerns, with their prevalence increasing due to aging populations. This situation heightens the need for accurate diagnosis and timely treatment. In this thesis, a model was developed utilizing artificial intelligence and deep learning methods to contribute to the early diagnosis and accurate classification of neurological disorders. This study aims to classify neurological disorders through brain magnetic resonance imaging (MRI) using a convolutional neural network (CNN)-based model called CBMDF-Net. The datasets employed in this thesis include MRI images of individuals with disorders such as Alzheimer's disease, Parkinson's disease, acute ischemic stroke, and brain tumors, as well as healthy subjects. To evaluate the model's performance, three different experiments were conducted. In the first experiment, a classification was performed on five classes (Alzheimer's disease, Parkinson's disease, acute ischemic stroke, brain tumors, and healthy individuals), achieving an accuracy rate of 98.82%. The second experiment used nine classes, including subtypes of neurological disorders, resulting in an accuracy of 98.31%. In the third experiment, brain tumors and Alzheimer's disease were classified based on their subgroups, attaining accuracy rates of 99.23% and 99.52%, respectively. CBMDF-Net was comprehensively trained to differentiate between various stages and types of disorders, accurately analyzing complex brain structures and pathologies through image processing and deep learning algorithms. In this context, the high accuracy rates achieved by the model demonstrate the effectiveness of deep learning-based approaches in the diagnosis of neurological disorders. This study significantly contributes to expediting the diagnostic processes of neurological disorders, providing support to healthcare professionals in clinical decision-making, and offering early intervention opportunities for patients. The CBMDF-Net model shows potential for increasing applicability in clinical settings, representing a new step in the diagnosis of neurodegenerative and acute neurological disorders.

Keywords: Neurological Disorders, Magnetic Resonance Imaging, Artificial Intelligence, Deep Learning, Convolutional Neural Network.

Advisor: Asst. Prof. Mehmet ACI, Department of Computer Engineering, Mersin University, Mersin.

TEŞEKKÜR

Tez çalışmam süresince bana değerli rehberliği ve destekleriyle yol gösteren, sabrı ve engin bilgisiyle her zaman yanımda olan kıymetli danışmanım Dr. Öğr. Üyesi Abdullah ELEWİ'ye en içten teşekkürlerimi sunarım. Kendisi, araştırma sürecinde karşılaştığım zorlukların üstesinden gelmemde ve bu çalışmayı başarılı bir şekilde tamamlamamda bana sürekli destek olmuş, bilgi ve deneyimlerini cömertçe paylaşarak yolumu aydınlatmıştır. Bilimsel çalışmalara olan derin tutkusuyla bana ilham vermiş ve akademik gelişimime önemli katkılarda bulunmuştur. Kendisi şu anda sağlık sorunları nedeniyle zorlu bir dönemden geçmektedir. En kısa sürede sağlığına kavuşmasını diler, kendisine acil şifalar temenni ederim.

Yeni danışmanım, değerli Dr. Öğr. Üyesi Mehmet ACI'ya de katkılarından dolayı teşekkür etmek isterim. Araştırma sürecinde sağladığı destek, yönlendirmeleri ve sabrı ile çalışmalarımı daha derinlemesine inceleme fırsatı buldum. Onun rehberliği, çalışmamın kalitesini artırmada büyük rol oynamıştır. Kendisiyle çalışmak benim için çok değerli bir deneyim oldu ve bilimsel yolculuğumda önemli bir dönemeçtir.

Ayrıca, lisans eğitimim sırasında bana rehberlik eden değerli hocam Prof. Dr. Mutlu AVCI'ya da tez savunmama katıldığı için teşekkür ederim. Kendisi, akademik yolculuğum boyunca bana önemli katkılarda bulunmuş ve her zaman desteğini esirgememiştir.

Jüri üyelerinden Dr. Öğr. Üyesi Jale BEKTAŞ'a de tez savunmama katılımı ve faydalı önerileriyle sağladığı katkılar için nazik teşekkürlerimi sunarım.

Aileme de sonsuz minnet borçluyum. Onlar, her adımda bana olan inançları ve koşulsuz destekleriyle bu zorlu süreçte en büyük motivasyon kaynağım oldular. Özellikle annemin sabrı, anlayışı ve gösterdiği sevgi için derin teşekkürlerimi sunarım. Onun manevi desteği ve varlığı, bu tezi başarıyla tamamlamamda büyük pay sahibi olmuştur.

İÇİNDEKİLER

	Sayfa
İÇ KAPAK	ii
ONAY	iii
ETİK BEYAN	iv
ÖZET	v
ABSTRACT	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
TABLolar DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
2. GENEL BİLGİLER ve LİTERATÜR TARAMASI	5
2.1. Nörolojik Bozukluklar	5
2.1.1. Akut İskemik İnme	5
2.1.1.1. Akut İskemik İnme Semptomları	6
2.1.1.2. Akut İskemik İnme Tanı Yöntemleri	7
2.1.2. Alzheimer	7
2.1.2.1. Alzheimer Semptomları	9
2.1.2.2. Alzheimer Tanı Yöntemleri	9
2.1.3. Beyin Tümörleri	10
2.1.3.1. Beyin Tümörlerinin Semptomları	12
2.1.3.2. Beyin Tümörlerinin Tanı Yöntemleri	13
2.1.4. Parkinson	13
2.1.4.1. Parkinson Semptomları	15
2.1.4.2. Parkinson Tanı Yöntemleri	15
2.2. Literatür Taraması	16
3. NÖROLOJİK BOZUKLUKLARDA NÖROGÖRÜNTÜLEME TEKNİKLERİ	19
3.1. Manyetik Rezonans Görüntüleme (MRI)	20
3.2. Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI)	21
3.3. Bilgisayarlı Tomografi (CT)	22
3.4. Pozitron Emisyon Tomografisi (PET)	22
4. YAPAY ZEKA	25
4.1. Yapay Sinir Ağları	26
4.2. Derin Öğrenme	27
4.2.1. Derin Sinir Ağları (DNNs)	28
4.2.2. Evrişimsel Sinir Ağları (CNNs)	29
4.2.3. Tekrarlayan Sinir Ağları (RNNs)	30
5. MATERYAL ve YÖNTEM	31
5.1. Veri Setleri	32
5.1.1. Akut İskemik İnme Veri Seti	32
5.1.2. Alzheimer Hastalığı Veri Seti	33
5.1.3. Beyin Tümörleri Veri Seti	33
5.1.4. Parkinson Hastalığı Veri Seti	34
5.2. Ön İşleme Aşaması	34
5.2.1. Görüntülerin Dönüştürülmesi	35
5.2.2. Yatay Simetri (Yansıtma)	35
5.2.3. Yatayda Rastgele Kaydırma	35
5.2.4. Gaussian Dağılımlı Rastgele Gürültü Ekleme	36
5.2.5. Parlaklık ve Kontrast Ayarı	36
5.2.6. Görüntü Boyutlandırma	36
5.2.7. Normalizasyon	37
5.3. Yöntem	37

	Sayfa
5.4. Sınıflandırma Görevleri	41
5.4.1. Nörolojik Bozukluklar ve Sağlıklı Bireylerin Sınıflandırılması	41
5.4.2. Nörolojik Bozuklukların Alt Sınıfları Üzerine Sınıflandırma	41
5.4.3. Alzheimer ve Beyin Tümörlerinin Çoklu Sınıflandırılması	42
6. BULGULAR ve TARTIŞMA	43
6.1. Performans Metrikleri	43
6.1.1. Doğruluk (Accuracy)	43
6.1.2. Kesinlik (Precision)	43
6.1.3. Duyarlılık (Recall)	44
6.1.4. F1 Skoru (F1 Score)	44
6.1.5. ROC Eğrisi ve AUC	44
6.2. Deneysel Analiz	44
6.2.1. Genel Nörolojik Bozukluklar Sınıflandırma Denemesi	45
6.2.2. Nörolojik Bozuklukların Alt Sınıfları Üzerine Sınıflandırma Denemesi	47
6.2.3. Alzheimer ve Beyin Tümörlerinin Çoklu Sınıflandırma Denemesi	50
6.2.3.1. Beyin Tümörleri Analizi	50
6.2.3.2. Alzheimer Analizi	53
6.3. Önceden Eğitilmiş Modellerle Karşılaştırma	56
6.4. CBMDF-Net ile Önceki Çalışmaların Karşılaştırılması	59
7. SONUÇLAR ve ÖNERİLER	61
KAYNAKLAR	63
ÖZGEÇMİŞ	83

TABLolar DİZİNİ

	Sayfa
Tablo 5.1. Önerilen modelin özeti	39-40
Tablo 5.2. Ham ve arttırılmış verilerle eğitim ve test seti dağılımı (1. deneme)	41
Tablo 5.3. Ham ve arttırılmış verilerle eğitim ve test seti dağılımı (2. deneme)	42
Tablo 5.4. Ham ve arttırılmış verilerle eğitim ve test seti dağılımı (3. deneme, beyin tümörleri)	42
Tablo 5.5. Ham ve arttırılmış verilerle eğitim ve test seti dağılımı (3. deneme, Alzheimer)	42
Tablo 6.1. Model performans değerleri (1.deneme)	46
Tablo 6.2. Model performans değerleri (2.deneme)	49
Tablo 6.3. Model performans değerleri (3.deneme, beyin tümörleri)	52
Tablo 6.4. Model performans değerleri (3.deneme, Alzheimer)	55
Tablo 6.5. CBMDF-Net ve önceden eğitilmiş modellerin performans karşılaştırması	56
Tablo 6.6. CBMDF-Net modelinin önceki çalışmalarla performans karşılaştırması	60



ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. En belirgin nörodejeneratif bozuklukların farklı klinik özelliklerinin genel bir bakışı	2
Şekil 2.1. Alzheimer hastalığının farklı evrelerini gösteren beyin görüntüleri	8
Şekil 2.2. Gliom beyindeki görünümü	10
Şekil 2.3. Hipofiz tümörünün beyindeki görünümü	11
Şekil 2.4. Menenjiom beyindeki görünümü	11
Şekil 3.1. Meningioma, glioma ve hipofiz tümörlerine ait aksiyel, koronal ve sagittal düzlemlerde MRI görüntüleri	20
Şekil 3.2. Parkinson hastalarında fonksiyonel manyetik rezonans görüntüleme (fMRI) ile beyin aktivite desenleri	21
Şekil 3.3. Akut iskemik inme tanısında bilgisayarlı tomografi (CT) görüntüsü	22
Şekil 3.4. Alzheimer hastalığı ve hafif bilişsel bozulma ile normal beyin arasındaki metabolik farklılıkları gösteren PET görüntüleri	23
Şekil 4.1. Derin sinir ağı (DNN) mimarisi	28
Şekil 4.2. Evrişimli sinir ağı (CNN) mimarisi	29
Şekil 4.3. Tekrarlayan sinir ağlarının (RNN) yapısı	30
Şekil 5.1. Önerilen yöntemin genel blok diyagramı	31
Şekil 5.2. Akut iskemik inme MRI görüntü örneği	32
Şekil 5.3. Alzheimer hastalığına ait MRI görüntü örnekleri. A) çok hafif demans, b) hafif demans, c) orta dereceli demans, d) demans olmayan	33
Şekil 5.4. Beyin tümörlerine ait MRI görüntü örnekleri. A) gliom, b) hipofiz tümörü, c) menenjiom, d) tümör olmayan	34
Şekil 5.5. Parkinson hastalığına ait MRI görüntü örneği	34
Şekil 5.6. Önerilen modelin mimarisi	37
Şekil 6.1. Önerilen modele ait karışıklık matrisi (1. deneme)	45
Şekil 6.2. Önerilen modelin doğruluk grafiği (1. deneme)	47
Şekil 6.3. Önerilen modelin kayıp grafiği (1. deneme)	47
Şekil 6.4. Önerilen modele ait karışıklık matrisi (2. deneme)	48
Şekil 6.5. Önerilen modelin doğruluk grafiği (2. deneme)	49
Şekil 6.6. Önerilen modelin kayıp grafiği (2. deneme)	50
Şekil 6.7. Önerilen modele ait karışıklık matrisi (3. deneme, beyin tümörleri)	51
Şekil 6.8. Önerilen modelin doğruluk grafiği (3. deneme, beyin tümörleri)	52
Şekil 6.9. Önerilen modelin kayıp grafiği (3. deneme, beyin tümörleri)	53
Şekil 6.10. Önerilen modele ait karışıklık matrisi (3. deneme, Alzheimer)	54
Şekil 6.11. Önerilen modelin doğruluk grafiği (3. deneme, Alzheimer)	55
Şekil 6.12. Önerilen modelin kayıp grafiği (3. deneme, Alzheimer)	56
Şekil 6.13. ResNet50 doğruluk ve kayıp grafikleri	57
Şekil 6.14. InceptionV3 doğruluk ve kayıp grafikleri	57
Şekil 6.15. DenseNet121 doğruluk ve kayıp grafikleri	58
Şekil 6.16. VGG16 doğruluk ve kayıp grafikleri	58
Şekil 6.17. Xception doğruluk ve kayıp grafikleri	59

SİMGELER VE KISALTMALAR

Kısaltma/Simge	Tanım
CBMDF-NET	<u>C</u> onvolutional <u>B</u> atch normalization <u>M</u> ax pooling <u>D</u> ropout <u>F</u> ully connected <u>N</u> ETwork
PLM	Periodic Leg Movement (Periyodik Bacak Hareketi)
REM	Rapid Eye Movement (Hızlı Göz Hareketi)
RBD	REM Sleep Behavior Disorder (REM Uyku Davranış Bozukluğu)
ALS	Amyotrophic Lateral Sclerosis (Amyotrofik Lateral Skleroz)
DL	Deep Learning (Derin Öğrenme)
MRI	Magnetic Resonance Imaging (Manyetik Rezonans Görüntüleme)
fMRI	Functional Magnetic Resonance Imaging (Fonksiyonel Manyetik Rezonans Görüntüleme)
CT	Computed Tomography (Bilgisayarlı Tomografi)
PET	Positron Emission Tomography (Pozitron Emisyon Tomografisi)
CNN	Convolutional Neural Network (Evrışimli Sinir Ağı)
AIS	Acute Ischemic Stroke (Akut İskemik İnme)
AD	Alzheimer's Disease (Alzheimer Hastalığı)
PD	Parkinson's Disease (Parkinson Hastalığı)
tPA	Tissue Plasminogen Activator (Doku Plazminojen Aktivatörü)
DWI	Diffusion Weighted Imaging (Difüzyon Ağırlıklı Görüntüleme)
IoMT	Internet of Medical Things (Tıbbi Nesnelerin İnterneti)
GDS	Global Deterioration Scale (Küresel Bozulma Ölçeği)
MMSE	Mini-Mental State Examination (Mini-Mental Durum Muayenesi)
MCI	Mild Cognitive Impairment (Hafif Bilişsel Bozukluk)
NPS	Neuropsychiatric Symptoms (Nöropsikiyatrik Semptomlar)
GBM	Glioblastoma Multiforme
SVM	Support Vector Machine (Destek Vektör Makinesi)
UPDRS	Unified Parkinson's Disease Rating Scale (Birleşik Parkinson Hastalığı Değerlendirme Ölçeği)
FoG	Freezing of Gait (Yürüyüşte Donma)
CAD	Computer-Aided Diagnosis (Bilgisayar Destekli Tani)
ND	Neurological Disorders (Nörolojik Bozukluklar)
GANs	Generative Adversarial Networks (Çekişmeli Üretici Ağlar)
DNN	Deep Neural Network (Derin Sinir Ağı)
DCNNs	Deep Convolutional Neural Networks (Derin Evrişimli Sinir Ağları)
RMSE	Root Mean Squared Error (kök ortalama kare hatası)
MSE	Mean Squared Error (Ortalama Kare Hatası)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
vGRF	Vertical Ground Reaction Force (Dikey yer Tepki Kuvveti)
BCNN	Bilinear Convolutional Neural Network (Bilineer Evrişimli Sinir Ağı)
UCI	University of California, Irvine
EEG	Electroencephalography (Elektroensefalografi)
MS	Multiple Sclerosis (Multipl Skleroz)
CTA	Computed Tomography Angiography (Bilgisayarlı Tomografi Anjiyografisi)
XPCT	X-ray Phase Contrast Tomography (X-ray Faz Kontrast Tomografisi)
18F-FDG	18F fluorodeoxyglucose (18F Fluorodezoksiglukoz)
AAS	Adaptive Artificial Systems (Yapay Uyarlanabilir Sistemler)
AI	Artificial Intelligence (Yapay Zeka)
ANN	Artificial Neural Network (Yapay Sinir Ağı)
ML	Machine Learning (Makine Öğrenimi)
RNN	Recurrent Neural Network (Tekrarlayan Sinir Ağı)
NiN	Network in Network (Ağ İçinde Ağ)
LSTM	Long Short-Term Memory (Uzun Kısa Süreli Bellek)
SN	Kara Madde (Substantia Nigra)

Kısaltma/Simgesi	Tanım
ResNet	Residual Neural Network (Artık Sinir Ağı)
TP	True Positive (Doğru Pozitif)
TN	True Negative (Doğru Negatif)
FP	False Positive (Yanlış Pozitif)
FN	False Negative (Yanlış Negatif)
ROC	Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
AUC	Area Under the Curve (Eğri altındaki alan)



1. GİRİŞ

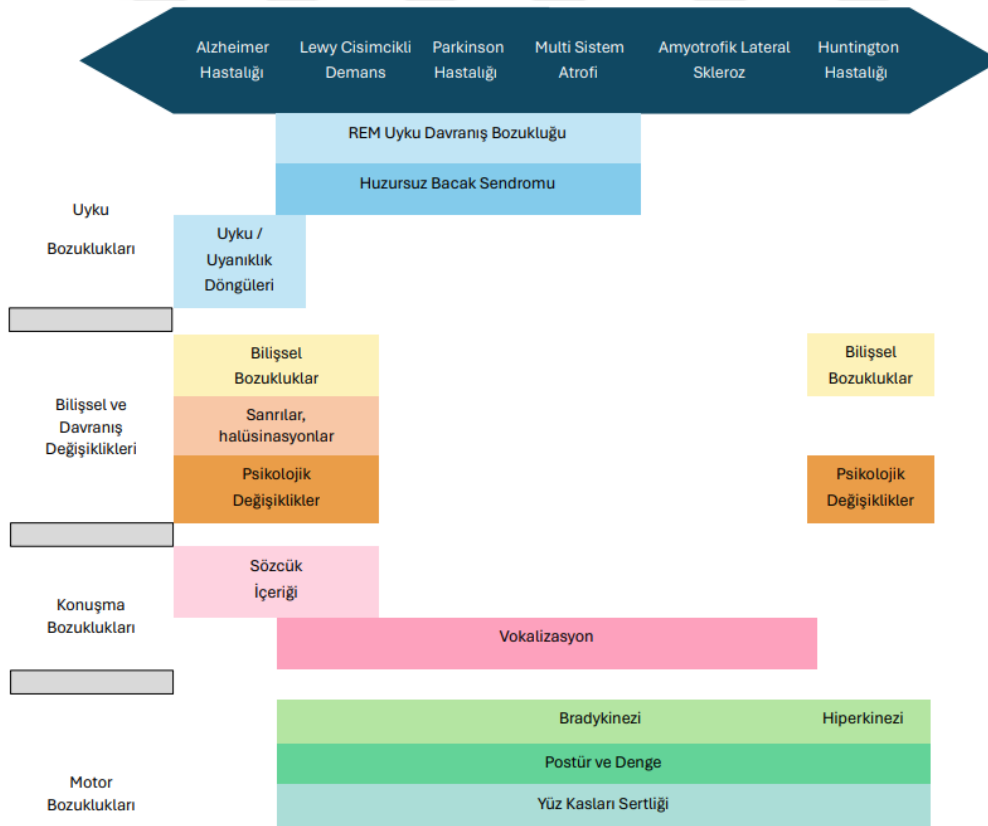
Nörolojik bozukluklar, beyin, omurilik ve sinirleri etkileyen geniş bir yelpazeye sahip olup, dünya genelinde önemli bir halk sağlığı sorunu teşkil etmektedir. Alzheimer, Parkinson, iskemik inme ve beyin tümörleri gibi önemli rahatsızlıklar, her biri tanı ve tedavi açısından farklı zorluklar sunmaktadır. Alzheimer ve Parkinson gibi nörodejeneratif bozukluklar (Moini, vd., 2024; Brakoniecki ve Chung, 2023), iskemik inme gibi damar bozuklukları (Moini, vd., 2024) ve travmatik beyin yaralanmaları (Iorio-Morin, vd., 2023), özellikle yaşlanan nüfuslarla birlikte giderek daha yaygın hale gelmektedir. Küresel etkisi oldukça büyüktür; yaklaşık 1 milyar insanı etkileyen bu bozukluklar, dünya çapındaki ölümlerin %12'sine neden olmakta ve yıllık yaklaşık 6,8 milyon ölüme yol açmaktadır.

Akut iskemik inme, serebral kan akışında ani bir kesinti ile karakterize olup, nörolojik kayıplara yol açmaktadır (Moini, vd., 2024). Engelliliğin önde gelen nedenlerinden biridir ve yaşlanan nüfuslar ile yaşam tarzı değişiklikleri nedeniyle yaygınlığı artmaktadır (Ravindranath, vd., 2023). Alzheimer hastalığı, progresif bilişsel gerileme ile karakterize olup, demansın en yaygın nedenidir (Moini, vd., 2024). Erken tanı için biyomarkerlerin önemi vurgulanmakta ve bu sayede zamanında müdahaleler sağlanabilmektedir (Dias, vd., 2024). Beyin tümörleri, birincil veya ikincil olabilir ve genellikle önemli morbidite ve mortaliteye yol açmaktadır (Brakoniecki ve Chung, 2023). Yönetimleri, cerrahi, radyasyon ve kemoterapi gibi multidisipliner bir yaklaşım gerektirmektedir. Parkinson hastalığı ise, yavaş ilerleyen bir hastalık olup, hareket ve bilişi etkilemekte ve genellikle yaşlı yetişkinlerde görülmektedir (Moini, vd., 2024; Ravindranath, vd., 2023). Hastalığın ilerlemesini yavaşlatmak ve yaşam kalitesini artırmak için nöroprotektif tedaviler üzerinde çalışmalar devam etmektedir (Dias, vd., 2024). Tüm bu bozuklukların anlaşılmasında ve tedavisinde kaydedilen ilerlemeler umut verici olmakla birlikte, nörolojik bozuklukların artan yükü, küresel ölçekte hasta sonuçlarını iyileştirmek için sürekli araştırma ve kaynak tahsisini gerektirmektedir (Winkler, vd., 2024). Bu durum, nörolojik bakımın temel sağlık hizmetlerine entegre edilmesi ve araştırma ile halk sağlığı girişimlerine devam edilmesi ihtiyacını ortaya koymaktadır (Singh, vd., 2010).

Yapay zeka, zihinsel sağlık hizmetlerinde teşhis ve tedavi süreçlerini geliştirmekte potansiyele sahiptir, bu da tıbbi araştırma ve uygulamada yeni bir sınır açmaktadır. Yapay zekanın nöropsikiyatriye entegrasyonu, psikiyatrik bozuklukları anlama, teşhis etme ve tedavi etmede yardımcı olabilir, zihinsel sağlık hizmetlerinin geleceğini şekillendirmeyi vaat etmektedir. "NeuroAI" kavramı, insanlar ve hayvanlar gibi gelişmiş duyu-motor becerilere sahip yapay zeka sistemleri geliştirmeyi amaçlamakta, psikiyatride yapay zeka uygulamalarının kapsamını genişletmektedir. Yapay zeka, nöropsikiyatride sağlık profesyonellerinin yeteneklerini artırarak insan uzmanlığına tamamlayıcı bir araç olarak kullanılabilir. Bununla birlikte, yapay zekanın psikiyatriye entegrasyonu, eğitim verisi kalitesi ve etik konularla ilgili zorlukları da beraberinde getirmektedir. Yapay zekanın avantajlarından

yararlanırken terapi ve bakımda insana odaklı yaklaşımların korunması önemlidir. (Mucci ve Marazziti, 2023)

Makine öğrenimi teknikleri, nörodejeneratif bozuklukların teşhis ve takibi için önemli araçlar haline gelmiştir. Bu teknikler, nörodejenerasyonla ilişkili uyku bozukluklarını, örneğin Periyodik Bacak Hareketi (PLM) veya REM Uyku Davranış Bozukluğu (RBD) gibi, normal uyku desenlerinden otomatik olarak tespit etmekte kullanılmaktadır. Örneğin, Amyotrofik Lateral Skleroz (ALS) gibi bozukluklarda, makine öğrenimi, nörodejeneratif hastalar ile sağlıklı kontrol grupları arasında ayırım yapabilmek için kullanılmaktadır. Parkinson hastalığında ise motor semptomları ve değişmiş hareket paternlerini karakterize etmek amacıyla hesaplamalı yaklaşımlar ve makine öğrenimi yöntemleri kullanılmaktadır. Ayrıca, Parkinson hastalığına bağlı konuşma bozukluklarının analizi için ses analizi alanında makine öğrenimi teknikleri uygulanmaktadır. Makine öğrenimi, sadece bozuklukların varlığını veya yokluğunu sınıflandırmakla kalmayıp, aynı zamanda farklı bozuklukları ve bozuklukların ilerleme aşamalarını ayırt edebilmek için de kullanılmaktadır. Nörodejeneratif bozuklukların takip ve teşhisinde makine öğreniminin kullanımı, otomatik teşhis ve sağlık değerlendirme sistemlerinin geliştirilmesine olanak sağlamıştır (Tautan, vd., 2021). Şekil 1.1, çeşitli nörodejeneratif bozuklukların uyku, bilişsel, konuşma ve motor bozuklukları üzerindeki etkilerini ve bu etkilerin farklı bozukluklara göre değişen boyutlarını göstermektedir.



Şekil 1.1. En belirgin nörodejeneratif bozuklukların farklı klinik özelliklerinin genel bir bakışı (Tautan, vd., 2021).

Derin öğrenme (DL), akut iskemik inme, Alzheimer, beyin tümörleri ve Parkinson hastalığı gibi nörolojik bozuklukların tanı ve tedavisinde önemli ilerlemeler sağlamıştır; özellikle manyetik rezonans görüntüleme (MRI) analizi yoluyla bu teknoloji, görüntü yorumlamasını geliştirmekte ve zamanında ve doğru tıbbi müdahaleleri mümkün kılmaktadır. İnme tanısında, derin öğrenme modelleri, bilgisayarlı tomografi (CT) taramalarından MRI sentezleyerek inme tedavisini iyileştirmekte ve lezyonları doğru bir şekilde tasvir eden yüksek kaliteli görüntüler üretmektedir (Wen, vd., 2024). Bu yaklaşım, acil durumlarda MRI'nın sınırlı bulunabilirliği sorununu ele almaktadır. Beyin tümörü tespitinde, evrişimli sinir ağları (CNNs) MRI taramalarından otomatik beyin tümörü tespiti için etkili bir şekilde kullanılmaktadır. Bu modeller, karmaşık desenleri analiz ederek tümör ve tümör olmayan bölgeleri ayırt etmede yüksek doğruluk elde etmektedir (Indumalar, vd., 2024). EfficientNet gibi ileri düzey mimariler, tedavi planlaması için kritik olan sınıflandırma güvenilirliğini daha da artırmaktadır (Agrawal ve Maan, 2024). Alzheimer ve diğer bozukluklarda ise, kapsamlı bir DL sistemi, MRI ve CT görüntülerini analiz ederek Alzheimer da dahil olmak üzere çoklu beyin bozukluklarını tahmin edebilmekte ve bu sistem tanısal raporlar üreterek erken tespiti ve kişiselleştirilmiş tedavi stratejilerini kolaylaştırmaktadır (Vaijyanthimala, vd., 2024). Ancak bu ilerlemelere rağmen, veri çeşitliliği ve model genelleştirmesi konularında zorluklar devam etmekte ve DL uygulamalarını nöroloji alanında optimize etmek için sürekli araştırmalara ihtiyaç duyulmaktadır (Iqbal, vd., 2024).

Bu tezin temel amacı, derin öğrenme tabanlı CBMDF-NET (Convolutional Batch normalization Max pooling Dropout Fully connected NETwork) modeli ile nörolojik bozuklukların erken teşhisi ve sınıflandırılmasındaki etkinliğini değerlendirmektir. Nörolojik bozukluklar, toplum sağlığı üzerinde önemli bir yük oluşturmakta ve bu durum, derin öğrenme algoritmalarının tanı ve tedavi süreçlerine katkısını anlamayı hedeflemektedir. Bu çalışma, sağlık profesyonellerinin ve hastaların derin öğrenme tabanlı sistemlerden nasıl fayda sağlayabileceğini anlamayı, aynı zamanda mevcut teşhis yöntemlerine yönelik olarak bu teknolojilerin klinik uygulanabilirliğini ve etkisini incelemeyi amaçlamaktadır. Bu bağlamda, nörolojik bozuklukların doğru ve hızlı teşhisi için yapay zeka tabanlı yaklaşımların sağladığı avantajlar ve sağlık hizmetlerine entegrasyonu konularına odaklanmaktadır.



2. GENEL BİLGİLER ve LİTERATÜR TARAMASI

2.1. Nörolojik Bozukluklar

Akut iskemik inme (AIS), Alzheimer hastalığı (AD), beyin tümörleri ve Parkinson hastalığı (PD) gibi nörolojik bozukluklar, stres ve çevresel toksinler gibi çeşitli faktörlerden etkilenmektedir. Araştırmalar, stresli yaşam olaylarının bu bozuklukların başlangıç ve ilerleyişini önemli ölçüde etkileyebileceğini göstermektedir. Özellikle Alzheimer hastalığı, teşhise kadar geçen sürenin en uzun olduğu hastalık olarak dikkat çekerken, Parkinson ve inme daha kısa sürede teşhis edilebilmektedir (Domínguez, vd., 2022).

Stresli olayların, Alzheimer, Parkinson ve inme riskini artırdığı tespit edilmiştir, bu da bozuklukların ortaya çıkışında psikolojik bileşenlerin önemini vurgulamaktadır (Domínguez, vd., 2022). Ayrıca, uzun süreli toksik hava kirleticilere maruz kalmanın beyin tümörü görülme sıklığını artırdığı ve Parkinson ile Alzheimer gibi bozuklukların seyrini kötüleştirdiği belirtilmektedir (Nikmanesh, vd., 2022). Beyin tümöründen hayatta kalanlarda, tümörün yeri ve tedavi etkileri gibi faktörler nedeniyle akut iskemik inme riski daha yüksektir, bu yüzden dikkatli bir izleme gerekmektedir (Figuracion, vd., 2021).

Bu bozuklukların tedavisi konusunda umut verici yaklaşımlar arasında, bazı kanser tedavilerinin otofajiyi destekleyerek Alzheimer ve Parkinson hastalığındaki nörodejenerasyonu hafifletebileceği düşünülmektedir (Moussa, 2016). Bu nörolojik bozukluklar ortak risk faktörlerini paylaşırsa da, aralarındaki karmaşık etkileşimler daha etkili önleme ve tedavi stratejileri geliştirmek için daha fazla araştırma yapılmasını gerektirmektedir.

2.1.1. Akut İskemik İnme

Akut iskemik inme (AIS), beyne giden kan akışının aniden kesilmesi sonucu ortaya çıkan ciddi bir tıbbi acil durumdur ve önemli morbidite ile mortaliteye yol açabilir. Zamanında müdahale, bu hastalığın yönetiminde kritik bir rol oynamaktadır. Tedavi stratejilerindeki gelişmeler, hasta sonuçlarını önemli ölçüde iyileştirmiştir; bu da hızlı değerlendirme ve müdahalenin önemini vurgulamaktadır. Geleneksel tedavi yöntemleri arasında intravenöz alteplaz (tPA) ile yapılan trombolitik tedavi, semptomların başlamasından sonraki 4.5 saat içinde en etkili sonuçları vermekte ve iyileşme oranlarını artırmaktadır (Nyström ve Schindler, 2018; Catanese, vd., 2017). Büyük damar tıkanıklıklarında ise intra-arteriyel cihazlar kullanarak yapılan endovasküler tedaviler, özellikle 6 saat içinde başlatıldığında etkili olmaktadır (Catanese, vd., 2017; Khurana, vd., 2019).

İleri görüntüleme teknikleri, CT ve MRI gibi, kurtarılabilir beyin dokusunu tanımlamada önemli bir rol oynamakta ve daha kişiselleştirilmiş tedavi yaklaşımlarına olanak tanımaktadır (Hawkes ve Rabinstein, 2008; Catanese, vd., 2017). Ayrıca, özel inme merkezleri hızlı triyaj ve tedavi

sağlayarak hasta sonuçlarını iyileştirmektedir (Nyström ve Schindler, 2018; Boling ve Keinath, 2018). Ancak, kırsal bölgelerde özel bakıma erişim hala bir sorun teşkil etmekte ve zamanında müdahaleyi kısıtlamaktadır.

Son yıllarda, derin öğrenme, AIS tanı ve yönetiminde devrim niteliğinde bir araç haline gelmiştir. Gelişmiş modeller, infarkt tespiti ve segmentasyonunu iyileştirerek yüksek doğruluk oranları elde etmiştir. Örneğin, nnU-Net modeli DWI sekanslarını kullanarak MRI taramalarından infarktları segmentasyonda 0.810'luk bir Dice skoru elde etmiştir (Kamel, vd., 2024). Derin öğrenmenin Internet of Medical Things (IoMT) ile entegrasyonu, tanı doğruluğunu artırmakta ve EfficientNet modeli, MRI görüntülerinden akut iskemik infarktları tespit etmede %92.31 gibi dikkate değer bir doğruluk oranı elde etmiştir (El-Sheikh, vd., 2024).

Ayrıca, hızlı tespit yöntemleri de gelişmiştir. MSE-VGG modeli gibi yenilikçi yaklaşımlar, EEG sinyallerini kullanarak inme tespitinde %90.17 doğruluk oranı sağlamaktadır (Tong, vd., 2024). Hibrit topluluk modelleri, farklı inme aşamalarındaki sınıflandırma doğruluğunu artırarak daha geniş klinik uygulamalar için potansiyel sunmaktadır (Qasrawi, vd., 2024). Ancak, derin öğrenme teknolojilerinin günlük klinik pratiğe etkili bir şekilde entegre edilmesi için daha fazla araştırma ve doğrulama gerekmektedir.

2.1.1.1. Akut İskemik İnme Semptomları

Akut iskemik inme (AIS), beyinde etkilenen bölgeye bağlı olarak farklı semptomlarla kendini gösterebilir. Bu semptomların erken tespiti, zamanında ve etkili müdahale için büyük önem taşır. Yaygın olarak görülen semptomlar arasında motor bozukluklar yer alır. Hastalarda genellikle vücudun bir tarafında güçsüzlük gelişir. Örneğin, 62 yaşındaki bir erkek hastada sol hemiparezi (yarı felç) gözlenmiştir (Khanal, 2024). Konuşma bozuklukları da sıkça karşılaşılan bir başka durumdur. Dil merkezlerinin etkilenmesi sonucu dizartri (bozuk konuşma) ve afazi (konuşma yetisinin kaybı) gibi semptomlar gelişebilir (Ignacio, vd., 2023). Ayrıca, duyuşsal değişiklikler de yaygın olabilir. Hastalarda parestezi (uyuşma) ve ihmal sendromları gibi duyuşsal bozukluklar görülebilir, özellikle atipik vakalarda bu semptomlar ön plana çıkabilir (Buck, 2024).

Bilişsel bozukluklar da AIS'nin belirtilerinden biridir. Bilinç bulanıklığı veya bilinç kaybı, özellikle posterior dolaşım inmelerinde sıkça görülen belirtilerdir (Ignacio, vd., 2023). Bununla birlikte, semptomlar bazen belirsiz olabilir ve tanıyı zorlaştırabilir. Örneğin, aralıklı güçsüzlük veya baş dönmesi gibi belirtilerle karşılaşılabılır (Buck, 2024; Ignacio, vd., 2023). Ek olarak, COVID-19 hastalarında bağışıklık sisteminin tepkisi sonucu ani inme benzeri nörolojik belirtiler ortaya çıkabilir (Mamatha, 2023). AIS'nin klasik semptomları iyi bilinse de, atipik durumlar ve COVID-19 gibi ek bozuklukların etkisi, tanıda dikkatli değerlendirme ve farkındalığın artırılması gerektiğini ortaya koymaktadır.

2.1.1.2. Akut İskemik İnme Tanı Yöntemleri

Akut iskemik inme (AIS) tanısı, zamanında ve doğru bir şekilde belirlemek için ileri görüntüleme tekniklerine ve yeni teknolojilere dayanır. Ana görüntüleme yöntemleri arasında bilgisayarlı tomografi (CT) ve manyetik rezonans görüntüleme (MRI) bulunmaktadır. MRI, iskemik değişiklikleri tespit etme konusundaki üstün duyarlılığı nedeniyle tercih edilmektedir (Jain, vd., 2024; Kaur, vd., 2023).

CT taramaları, genellikle intrakranial kanamayı tespit etmedeki yüksek duyarlılığı nedeniyle ilk görüntüleme testi olarak kullanılır (Cojocar, 2024). Ancak, diffüzyon ağırlıklı görüntüleme (DWI) MRI, iskemik inme tanısında CT'den daha etkili olup, beyin dokusu hasarını daha erken belirleyerek detaylı bilgiler sunmaktadır (Kaur, vd., 2023; Cojocar, 2024).

Gelişmiş tanı yaklaşımları arasında, derin öğrenme modelleri kullanan otomatik tanı teknikleri öne çıkmaktadır. Örneğin, EfficientNet gibi modeller, MRI görüntü analizinin doğruluğunu artırarak akut iskemik infarktleri tespit etmede yüksek hassasiyet elde etmektedir (El-Sheikh, vd., 2024). Hibrit optimizasyon yöntemleri ise MRI görüntülerindeki lezyon segmentasyonunu iyileştirerek bulguları klinik ölççeklerle ilişkilendirip inme şiddetini değerlendirmeye yardımcı olmaktadır (Geetha, vd., 2024).

Geleneksel görüntüleme yöntemleri hâlâ kritik bir öneme sahipken, yapay zeka ve otomatik tekniklerin entegrasyonu, AIS tanı süreçlerini dönüştürmekte ve potansiyel olarak daha hızlı müdahalelere ve daha iyi hasta sonuçlarına yol açmaktadır. Ancak, acil durumlarda ileri görüntüleme teknolojilerinin erişilebilirliği ve kullanılabilirliği konusunda hâlâ zorluklar bulunmaktadır.

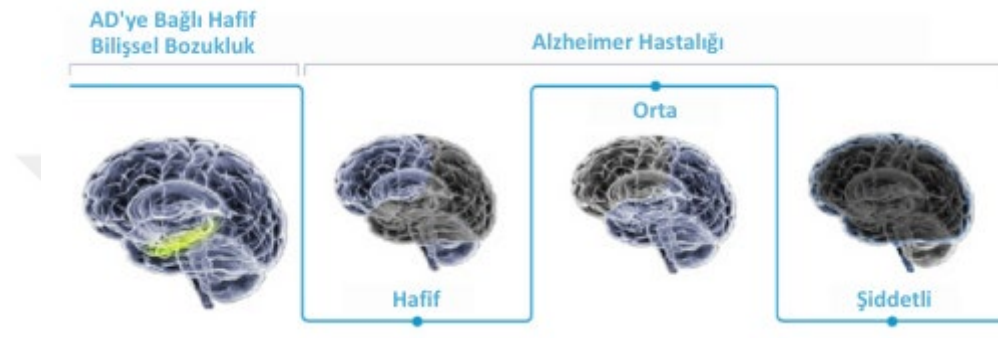
2.1.2. Alzheimer

Alzheimer hastalığı (AD), beyinde amiloid plakları ve nörofibriler yumakların birikmesi sonucu ortaya çıkan, bilişsel gerileme ve hafıza kaybı ile karakterize edilen karmaşık bir nörodejeneratif hastalıktır (Khan, 2016; Husain, vd., 2008). Alzheimer, ilerleyici bir hastalıktır ve her evresi farklı bilişsel ve işlevsel bozukluklarla tanımlanır. Hastalığın teşhisinde kullanılan en yaygın yöntemler arasında Küresel Bozulma Ölçeği (GDS) ve Mini-Mental Durum Muayenesi (MMSE) yer alır. Bu yöntemler, hastalığın şiddetini değerlendirmede önemli bir rol oynar. Alzheimer hastalığının evreleri aşağıdaki gibidir:

- Çok Hafif Evre (GDS Evresi 1): Bireyler genellikle başkaları tarafından fark edilmeyen hafif bilişsel değişiklikler sergileyebilirler. Denge ve yürüme bozuklukları, bu aşamada erken işlevsel gerilemeyi gösterebilir (Gras, vd., 2015).
- Hafif Evre (GDS Evresi 2-3): Bu evrede hastalar belirgin hafıza kaybı yaşar ve karmaşık görevlerde zorluklar çeker. Bilişsel değerlendirmeler, bellek ve dil becerilerinde önemli bozulmalar olduğunu gösterir (Zec, vd., 1992; Kraemer, vd., 1998).

- Orta Evre (GDS Evresi 4-5): Bu aşamada bireyler günlük aktivitelerde daha fazla yardıma ihtiyaç duyar ve kişisel bakımlarını gerçekleştirebilmek için artan bağımlılık gösterirler (Reisberg, vd., 1984).
- Şiddetli Evre (GDS Evresi 6-7): Hastalar iletişim becerilerini kaybeder ve tam zamanlı bakıma ihtiyaç duyarlar. Bu, derin bilişsel ve işlevsel gerilemenin en belirgin olduğu evredir (Reisberg, vd., 1984).

Şekil 2.1, Alzheimer hastalığının evrelerini ve her evrede beyinde meydana gelen bilişsel bozulmaları göstermektedir.



Şekil 2.1. Alzheimer hastalığının farklı evrelerini gösteren beyin görüntüleri (AgeneBio, 2024).

Mevcut tedavi yöntemleri arasında kolinesteraz inhibitörleri ve memantin yer almakta olup, bu ilaçlar yalnızca semptomları hafifletmeyi amaçlamakta, ancak hastalığın ilerlemesini durduramamaktadır (Galimberti ve Scarpini, 2010; Husain, vd., 2008). Yeni terapiler amiloid ve tau patolojilerini hedef alsa da, birçok klinik çalışma belirgin bir etkinlik göstermede başarısız olmuştur (Reiss, vd., 2020). Ayrıca, insan beyninin gelişmiş bilişsel işlevler için uyum sağlamasının Alzheimer'a karşı artan bir hassasiyet yarattığı öne sürülmektedir (Bucfill, vd., 2013).

Son yıllarda derin öğrenme, Alzheimer hastalığının tanı ve sınıflandırılmasında önemli bir rol oynamaya başlamıştır. Gelişmiş sinir ağı mimarileri ile beyin görüntüleme verilerinin analizi, hastalığın erken teşhisini iyileştirmekte ve müdahale süreçlerini daha etkili hale getirmektedir. Örneğin, evrişimli sinir ağları (CNN) kullanılarak yapılan çalışmalarda, Alzheimer hastalığının farklı evrelerini başarılı bir şekilde tespit etmek mümkün olmuştur (Ullah ve Jamjoom, 2023). Veri artırma teknikleri, özellikle CycleGAN gibi yöntemler, bu modellerin performansını daha da geliştirmiştir (Aparna ve Rao, 2023).

Farklı CNN mimarilerini karşılaştıran araştırmalarda, DenseNet ve ResNet gibi yapılar arasında performans farklılıkları olduğu gözlemlenmiştir. DenseNet201 mimarisi bu çalışmalarda yüksek doğruluk oranları sergilemiştir (Muniagurria ve Rowlands, 2023). Ancak, Alzheimer hastalığını diğer yaşa bağlı bilişsel bozukluklardan ayırt etme konusunda bazı zorluklar devam etmektedir, çünkü MRI görüntüleri sıklıkla benzer özellikler taşımaktadır (Sahla, vd., 2023). Ayrıca, derin öğrenme tekniklerinin büyük veri kümelerine olan bağımlılığı ve aşırı öğrenme riskleri, klinik

uygulamalarda güvenilirliği artırmak için dikkat edilmesi gereken başlıca faktörler arasındadır (Sharmili, vd., 2023).

Alzheimer hastalığına dair yapılan çalışmalar ve derin öğrenme teknolojilerinin entegrasyonu, hastalığın tanı süreçlerinde umut verici gelişmeler sunmakla birlikte, bu teknolojilerin klinik uygulamalara etkin bir şekilde dahil edilebilmesi için daha fazla araştırma gerekmektedir. Bu süreçler, bireylerin kişiselleştirilmiş değerlendirme ve müdahale stratejileri ile desteklenmesi gerektiğini vurgulamaktadır.

2.1.2.1. Alzheimer Semptomları

Alzheimer hastalığı (AD), bilişsel ve bilişsel olmayan işlevleri önemli ölçüde etkileyen bir dizi belirti ile kendini göstermektedir. Başlıca belirtiler arasında bellek kaybı, yön bulma güçlüğü ve iletişim zorlukları yer almakta olup, bu belirtiler zamanla giderek kötüleşmektedir. Ayrıca, depresyon, anksiyete, ajitasyon ve isteksizlik gibi nöropsikiyatrik belirtiler (NPS) de yaygındır ve hastaların %97'sine kadarını etkilemektedir (Pless, vd., 2023).

Bellek kaybı, Alzheimer hastalığının erken evrelerinde sık görülen bir belirtidir; bu evrede hastalar genellikle unutuş ve yakın zamandaki olayları hatırlamada zorluk yaşamaktadır (Chorawala, vd., 2024). Yön bulma güçlüğü ise hastaların zaman ve mekan hakkında kafa karışıklığı yaşamasına yol açmakta, bu da bağımlılığın artmasına neden olmaktadır (Chorawala, vd., 2024).

Bilişsel olmayan belirtiler arasında ise depresyon ve anksiyete öne çıkmaktadır. Bu belirtiler sıklıkla bildirilmekte olup, bilişsel gerilemeyi daha da kötüleştirebilmektedir (Warren et al., 2023; Teixeira, vd., 2023). Ajitasyon ve agresyon gibi davranışlar da hastalığın ilerlemesiyle bağlantılıdır ve bu durum, bakım verenler için önemli bir yük oluşturmaktadır (Pless, vd., 2023; Goodwin, vd., 2023).

Fonksiyonel yetkinliklerdeki bozulmalar, hastaların kişisel bakım ve ev işlerini yapmada zorlanmalarına neden olmakta, bu da fonksiyonel becerilerdeki gerilemeyi yansıtmaktadır (Chorawala, vd., 2024). Bilişsel gerilemeye odaklanılsa da, NPS'nin etkisi derindir ve bu durum, bilişsel ve davranışsal semptomları ele alan kapsamlı yönetim stratejilerine duyulan ihtiyacı vurgulamaktadır (Teixeira, vd., 2023).

2.1.2.2. Alzheimer Tanı Yöntemleri

Alzheimer hastalığı (AD) tanısı önemli ölçüde gelişmiş olup, geleneksel yöntemler ile ileri teknolojilerin entegrasyonunu içermektedir. Erken tespit, etkili yönetim için kritik öneme sahip olduğundan, nörogörüntüleme, makine öğrenimi ve biyomarker analizi gibi çeşitli tanı teknikleri ortaya çıkmıştır.

Geleneksel tanı yöntemleri klinik değerlendirmeler ve nöropsikolojik testler, AD tanısında temel oluşturarak bilişsel gerileme ve davranış değişikliklerine odaklanmaktadır (Athira ve Charles, 2024).


İleri nörogörüntüleme teknikleri manyetik rezonans görüntüleme (MRI), AD tanısında önemli bir rol oynamakta olup, yapılan çalışmalar, kortikal kalınlık ve sulkus derinliği gibi özelliklerin AD'yi normal yaşlanmadan ayırt etmede yüksek doğrulukla kullanılabilirliğini göstermektedir (Arabi, vd., 2022). Yapısal MRI'nin klinik ve genetik verilerle entegrasyonu, bazı durumlarda tanısallık hassasiyeti %100'e kadar çıkarmaktadır (Qiang, vd., 2023).

Makine öğrenimi yaklaşımları makine öğrenimi teknikleri, rastgele ormanlar ve derin öğrenme gibi yöntemler, demans ilerlemesini tahmin etmede %98.5 doğruluk oranlarına ulaşarak dikkate değer başarılar göstermiştir (Harshini, vd., 2024; Shukla, vd., 2023). Çok modlu verileri kullanan otomatik sistemler, AD ile hafif bilişsel bozukluk (MCI) arasında ayırt edici olma konusunda karşılaşılan zorlukları aşarak sınıflandırma oranlarını artırmıştır (Shukla, vd., 2023).

Bu gelişmeler, erken tanı için umut verici yollar sunarken, farklı popülasyonlar arasında bu yöntemlerin güvenilirliği ve yorumlanabilirliği konusundaki zorluklar devam etmektedir.

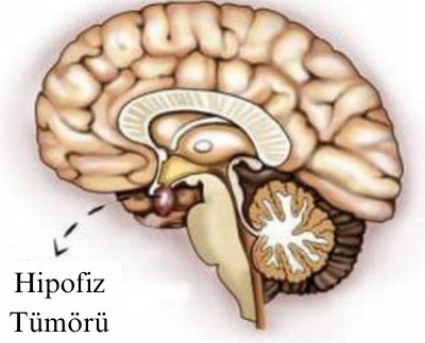
2.1.3. Beyin Tümörleri

Beyin tümörleri, anormal hücre büyümesi ile karakterize edilen, beyin veya çevresindeki dokularda oluşan ve hücre tipi, invazivlik ve malignite gibi çeşitli özelliklere göre 150'den fazla türde sınıflandırılan anormal büyümelerdir (Uysal, 2023). Bu tümörler genellikle iyi huylu veya kötü huylu olabilir; gliomlar, hipofiz tümörleri ve menenjiomlar en yaygın türler arasında yer almaktadır. Şekil 2.2, Şekil 2.3 ve Şekil 2.4 sırasıyla gliom, hipofiz tümörü ve menenjiomun beyindeki lokalizasyonunu ve karakteristik özelliklerini göstermektedir.




Şekil 2.2. Gliom beyindeki görünümü (Pichavél, vd., 2022).

Gliomlar, özellikle glioblastoma multiforme (GBM), erişkinlerde en yaygın ve en agresif tümörlerdir ve multimodal tedavilere rağmen kötü prognozlara yol açmaktadır (Wainwright, vd., 2012).



Şekil 2.3. Hipofiz tümörünün beyindeki görünümü (Pichavel, vd., 2022).

Hipofiz tümörler genellikle iyi huylu olmasına rağmen, konumları nedeniyle önemli hormonal dengesizlikler ve nörolojik belirtiler oluşturabilir (Kaye ve Laws, 2001).



Şekil 2.4. Menenjiom beyindeki görünümü (Pichavel, vd., 2022).

Menenjiomlar, meninkslerden köken alan genellikle yavaş büyüyen tümörlerdir ve önemli bir boyuta ulaşana kadar asemptomatik olabilir (Morantz ve Walsh, 1994). Tümörlerin malignite ve büyüme özelliklerine göre Dünya Sağlık Örgütü tarafından dört dereceye kadar sınıflandırılmaktadır (Arulmani ve Manickam, 2024).

Belirtiler genellikle tümörün konumuna ve çevresindeki beyin yapıları üzerindeki etkisine bağlı olarak nörolojik eksiklikler, nöbetler ve baş ağrıları şeklinde ortaya çıkmaktadır (Chiavazza, vd., 2019). Cerrahi rezeksiyon, erişilebilir tümörler için ilk tedavi seçeneği olarak kabul edilirken (Uysal, 2023), radyoterapi ve kemoterapi, cerrahiden sonra veya cerrahi müdahale yapılamayan tümörlerin büyümesini kontrol etmek için kullanılmaktadır (Pichavel, vd., 2022). Kötü huylu tümörlerin yönetiminde zorluklar devam etmekte ve tedavi direnci önemli bir sorun oluşturmaktadır (Tyler, vd.,

2013). Yeni yöntemler olarak sıvı biyopsiler, tümörden elde edilen biyomarkerlerin vücut sıvılarında analiz edilmesine yönelik araştırmalarda incelenmektedir, bu da tanı ve tedavi izlemine geliştirebilir (Pichaivel, vd., 2022). Tümörlerin doğasına dair mevcut tedavi ve tanı yöntemlerindeki ilerlemelere rağmen, beyin tümörleri önemli bir sağlık sorunu olmaya devam etmektedir.

Son yıllarda, derin öğrenme (DL) yöntemleri, beyin tümörlerinin tanısı ve sınıflandırılmasında önemli bir yenilik olarak öne çıkmıştır. Bu teknikler, tıbbi görüntüleme analizinin doğruluğunu ve verimliliğini artırmakta önemli rol oynamaktadır. Çeşitli çalışmalar, DL modellerinin etkinliğini özellikle MRI verilerinin işlenmesinde vurgulamaktadır. Transfer öğrenme teknikleri kullanarak geliştirilen ResNet50V2 ve Xception gibi modeller, beyin tümörlerini MRI görüntülerinden başarılı bir şekilde sınıflandırabilmektedir (Talukder, vd., 2023). Evrişimli Sinir Ağları (CNN), VGG19 ve ResNet101 gibi yapılarla malign primer ve metastatik beyin tümörlerini ayırt etmede etkili olmuştur; bu bağlamda ResNet101 önemli sonuçlar elde etmiştir (Fauzi, vd., 2023).

MRI dizilimi, sınıflandırma hassasiyetini etkileyen önemli bir faktördür; araştırmalar, T2 dizilimlerinin kötü huylu tümörler için en yüksek hassasiyeti sağladığını göstermektedir (Fauzi, vd., 2023). Ayrıca, EfficientNetV1 gibi hafif modellerin kullanımı, yüksek doğruluğu korurken hesaplama gereksinimlerini azaltma ihtiyacını vurgulamaktadır (Khuntia, vd., 2023). Bununla birlikte, derin öğrenme tekniklerinin geniş veri setlerine ve hesaplama kaynaklarına duyduğu ihtiyaç, bazı zorluklar doğurmaktadır. Gelecek araştırmalar, bu modellerin daha geniş klinik uygulamalara optimize edilmesine odaklanmalıdır.

2.1.3.1. Beyin Tümörlerinin Semptomları

Beyin tümörleri, hastaların yaşam kalitesini önemli ölçüde etkileyen çeşitli semptomlar sunmaktadır. Bu semptomlar, tümörün türüne, konumuna ve bireysel hasta faktörlerine bağlı olarak değişiklik göstermektedir. Bu belirtilerin anlaşılması, erken tanı ve etkili yönetim için kritik öneme sahiptir.

Yaygın semptomlar arasında baş ağrıları, genellikle sürekli ve zamanla kötüleşen baş ağrıları, sık görülen ilk semptomlar arasında yer almaktadır (Kumari ve Jha, 2024). Bulantı ve kusma, artan intrakraniyal basınç nedeniyle ortaya çıkabilir (Kredbová, vd., 2024). Bilişsel ve davranışsal değişiklikler, hastaların bellek sorunları, kişilik değişiklikleri ve ruh hali bozuklukları (depresyon ve anksiyete) gibi sorunlar yaşamasına neden olabilir (Yevtushenko ve Zotov, 2024; Essianda, vd., 2023). Ayrıca, tümörün konumuna bağlı olarak odaklanma sinirsel belirtileri, zayıflık, nöbetler ve duyuusal eksiklikler gibi belirtiler de ortaya çıkabilir (Kuks, vd., 2023).

Çocuklarda ise semptomlar, denge sorunları ve gelişimsel gecikmeler gibi ek belirtiler içerebilir, bu da özel tanı yaklaşımlarına ihtiyaç duyulmasına neden olmaktadır (Kumari ve Jha, 2024). Beyin tümörlerinin semptomları, ciddi temel koşulları gösterebileceği gibi, diğer sağlık sorunlarıyla da

örtüşebilir, bu da tanıyı zorlaştırmaktadır. Bu nedenle, doğru değerlendirme ve tedavi planlaması için multidisipliner bir yaklaşım esastır.

2.1.3.2. Beyin Tümörlerinin Tanı Yöntemleri

Beyin tümörlerinin tanısı, çeşitli görüntüleme teknikleri ve hesaplama yöntemleri aracılığıyla önemli ölçüde ilerlemiştir. Anahtar tanı yaklaşımları arasında manyetik rezonans görüntüleme (MRI), ileri nörogörüntüleme teknikleri ve makine öğrenimi algoritmaları yer alır; bu yaklaşımlar, tümör tespitinde doğruluk ve verimliliği artırmaktadır.

Manyetik Rezonans Görüntüleme (MRI) Teknikleri MRI, beyin yapılarının görselleştirilmesinde ana araç olarak kullanılır ve sağlıklı ile tümör etkisi altındaki dokuların ayırt edilmesini sağlar (Hosseini Saber ve Hosseini Saber, 2023). Görüntü kalitesini artırmak ve tümör bölgelerini etkili bir şekilde tanımlamak için ön işleme, segmentasyon ve morfolojik işlemler gibi teknikler uygulanmaktadır (Hosseini Saber ve Hosseini Saber, 2023).

İleri Nörogörüntüleme Fonksiyonel MRI (fMRI) ve difüzyon tensor görüntüleme, cerrahi planlamayı ve ayırıcı tanıyı iyileştirirken, perfüzyon görüntüleme ve spektroskopi, tümör ilerlemesini tedavi ile ilgili değişikliklerden ayırt etmeye yardımcı olmaktadır (Jordan ve Gerstner, 2023).

Makine Öğrenimi Yaklaşımları K-means kümeleme ve Destek Vektör Makineleri (SVM) gibi algoritmalar, otomatik tümör segmentasyonu ve sınıflandırması için kullanılmakta olup yüksek doğruluk oranları elde edilmektedir (Kalaiarasi, vd., 2023; Alsheikhy, vd., 2023). Ayrıca, courtship öğrenme tabanlı su böceği algoritması gibi yenilikçi yöntemler, tanı hızını ve doğruluğunu daha da artırmaktadır (Ren, vd., 2023).

Bu ilerlemelere rağmen, tümörlerin karmaşık yapıları ve hastalar arasındaki varyasyonlar nedeniyle doğru tanıda zorluklar devam etmektedir. Bu tekniklerin rafine edilmesi ve tanı sonuçlarının iyileştirilmesi için sürekli araştırmaların yapılması önemlidir.

2.1.4. Parkinson

Parkinson hastalığı (PD), motor ve motor dışı belirtilerle karakterize edilen yaygın bir nörodejeneratif hastalıktır ve dopaminerjik nöronların kara madde (SN) deki dejenerasyonundan kaynaklanmaktadır. Motor belirtileri iyileştiren tedaviler (örneğin levodopa), hastalığın ilerlemesini durdurmamaktadır. PD araştırma alanında önemli boşluklar bulunmaktadır; özellikle genetik, popülasyon çeşitliliği ve tedavi etkinliği konularında. Mevcut genetik çalışmaların çoğu, Avrupa popülasyonlarına odaklanmakta ve özellikle AfrAbia gibi farklı grupların önemli ölçüde temsil edilmemesi, kişiselleştirilmiş tıp yaklaşımlarını engelleyebilir ve PD etiyojisi hakkında bilgi eksikliğine yol açabilir (Mohamed, 2023). Ayrıca, monojenik ve karmaşık PD vakalarına ilişkin

genetik varyantlarla ilgili tedavi sonuçlarına dair daha kapsamlı verilere ihtiyaç duyulmaktadır (Genç, 2024).

Araştırma kohortları ile gerçek dünya popülasyonları arasında tutarsızlıklar bulunmaktadır. Gerçek dünya ortamlarında hastalar genellikle daha geç teşhis edilmekte ve tedavi almaktadır; bu da araştırma çalışmalarındaki hastalara kıyasla geç kalındığını göstermektedir (Beaulieu-Jones, vd., 2024). Bu durum, hastalığın ilerlemesini ve tedavi yanıtını daha iyi anlamak için gerçek dünya verilerini içeren çalışmalara olan ihtiyacı vurgulamaktadır. Parkinson hastalığındaki yürüme sorunları için mevcut terapiler, örneğin derin beyin stimülasyonu, değişken etkinlik göstermekte ve yenilikçi nöromodülasyon hedeflerine ve hasta seçimi kriterlerine ihtiyaç olduğunu ortaya koymaktadır (Cury et al., 2022). PD, dinlenme tremoru, sertlik, bradikinezi ve postural instabilite gibi motor belirtilerle kendini göstermektedir (Fang, 2023; Balestrino ve Schapira, 2020). Ayrıca, bilişsel gerileme ve ruh hali bozuklukları gibi motor dışı belirtiler de yaşam kalitesini önemli ölçüde etkilemektedir (Albin, 2022).

PD, Avrupa'da her 100.000 bireyden yaklaşık 108–257'sini etkilemektedir ve yaş ile erkek cinsiyeti gibi risk faktörleri bulunmaktadır (Balestrino ve Schapira, 2020). Genetik faktörler, ailevi vakalar üzerinde etkili olup hastalığın mekanizmaları hakkında bilgiler sağlamaktadır (Balestrino ve Schapira, 2020). Levodopa, tedavi temel taşlarından biri olmaya devam etmekte, ancak diskinziye neden olabilmekte ve sınırlamaları bulunmaktadır (Zuber, 2002). Yeni terapiler, nöroprotektion ve PD'nin çok yönlü doğasına hitap etmeye odaklanmaktadır (Albin, 2022). Gelişmelere rağmen, PD'nin karmaşıklığı, daha etkili tedavilerin geliştirilmesi ve patogenezinin anlaşılması için sürekli araştırma gerektirmektedir.

Derin öğrenme, Parkinson hastalığının erken tespiti ve izlenmesinde dönüştürücü bir araç olarak ortaya çıkmıştır. Ses, tıbbi görüntüleme ve yürüme analizi gibi çeşitli veri türlerini kullanarak tanısal doğruluğu ve hasta yönetimini artırmaktadır. Derin öğrenme modelleri, özellikle artık sinir ağları (ResNet), ses verileri kullanarak PD tahmininde %98 doğruluk oranına ulaşmıştır (Maiti, vd., 2024). Jitter ve shimmer gibi akustik özellikler, hastalığın ciddiyetini Birleşik Parkinson hastalığı Değerlendirme Ölçeği (UPDRS) aracılığıyla değerlendirmek için kritik öneme sahiptir. Evreşimli sinir ağları (CNNs), MRI görüntülerinin analizinde etkili bir şekilde kullanılmıştır. Modeller, PD'yi sağlıklı kontrollerden ayırt etmede %97'ye kadar doğruluk oranına ulaşmıştır (Wankar, vd., 2024). Derin öğrenmeyi meta-sezgisel (Metaheuristic) algoritmalarla birleştiren hibrit modeller, bazı durumlarda tanısal doğruluğu %100'e kadar çıkarmıştır (Majhi, vd., 2024).

Yenilikçi giyilebilir cihazlar, derin öğrenme kullanarak yürüyüşte donma (FoG) ataklarını tahmin edebilmekte ve önemli ölçüde yaşam kalitesini artırmaktadır (Ghayvat, vd., 2024). Bu cihazlar, yürüme parametrelerini kullanarak zamanında müdahaleler sağlamakta. Derin öğrenme, PD tanı ve yönetiminde umut verici ilerlemeler sunmakla birlikte, bu teknolojilerin klinik uygulamalara entegrasyonunda ve tüm hastalar için erişilebilirliğin sağlanmasında zorluklar devam etmektedir.

2.1.4.1. Parkinson Semptomları

Parkinson hastalığı (PD), öncelikle motor semptomlarıyla bilinse de, hastaların yaşam kalitesini önemli ölçüde etkileyen motor dışı semptomları da içermektedir. Bu semptomları anlamak, hastalığın etkili bir şekilde yönetimi ve tedavisi için kritik öneme sahiptir.

Parkinson hastalığının karakteristik motor semptomları arasında bradikinezi (hareketlerin yavaşlaması), rijidite (kas sertliği), tremor (titreme) ve postüral instabilite (duruş bozukluğu) bulunmaktadır (Maass ve Reichmann, 2013). Ayrıca, hastalar görsel keskinlikte ve karmaşık görsel işlevlerde sorun yaşayabilir, bu da genel motor fonksiyonları etkileyebilir (Armstrong, 2008).

Motor dışı semptomlar ise depresyon, anksiyete, psikoz ve ilgisizlik gibi nöropsikiyatrik sorunları içerir ve hastaların çoğunluğunu etkileyen yaygın motor dışı semptomlar arasındadır (Aarsland ve Kramberger, 2015). Birçok hasta, uykusuzluk ve huzursuz bacak sendromu gibi uyku bozukluklarından muzdarip olup, bu durum diğer semptomları daha da kötüleştirebilir (Maass ve Reichmann, 2013). Kabızlık ve ortostatik hipotansiyon (ani tansiyon düşmesi) gibi otonom sinir sistemi sorunları da oldukça yaygındır ve genellikle göz ardı edilmektedir (Park ve Stacy, 2011).

Her ne kadar motor semptomlar tanı koymada kritik öneme sahip olsa da, motor dışı semptomlar hastalığın erken dönemlerinde ortaya çıkabilir ve hastalığın ilerlemesi ile yönetimini büyük ölçüde etkileyebilir (Salawu, vd., 2010). Bu semptomların ele alınması, hastaların yaşam kalitesini iyileştirmek için hayati bir rol oynamaktadır.

2.1.4.2. Parkinson Tanı Yöntemleri

Parkinson hastalığının (PD) tanısı, gelişmiş tanı tekniklerinin entegrasyonu ile önemli ölçüde gelişmiştir. Özellikle makine öğrenimi ve görüntü işleme yöntemleri, geleneksel klinik değerlendirmelerin sınırlamalarını aşarak doğruluğu artırmayı ve hastalığın erken tespitini sağlamayı hedeflemektedir.

Makine öğrenimi yaklaşımları, sesli fonasyon analizi gibi yöntemleri içermektedir. Bir çalışmada, makine öğrenimi modellerinin, özellikle destek vektör makinelerinin, Parkinson hastalarını sesli fonasyon analizine dayanarak %58'in üzerinde bir doğrulukla sınıflandırabildiği gösterilmiştir (Wang, vd., 2020). Ayrıca, el yazısı desen tanıma alanında yapılan bir araştırmada, derin öğrenme yöntemleri kullanılarak el yazısı desenlerinin analiziyle Parkinson hastalığını tespit etmede %87 doğruluk elde edilmiştir. Bu yöntem, geleneksel yaklaşımları geride bırakmıştır (Aghzal ve Mourhir, 2020).

Görüntü işleme teknikleri de Parkinson hastalığı tanısında önemli bir rol oynamaktadır. Bilgisayar destekli tanı (CAD) yöntemleri, Parkinson hastalığıyla ilişkili beyin yapılarındaki dopamin azalmasını tespit etmek için kullanılmaktadır. Bu yöntem, daha nesnel bir tanı yaklaşımı sunmaktadır (Valli ve Jiji, 2014).

Bununla birlikte, evrimsel bulanık sınıflandırıcılar gibi yeni yöntemler, dinamik el yazısı verilerini kullanarak Parkinson hastalığının tanısında elde edilen karakteristik örnek noktalarına dayalı olarak bireyleri sınıflandırma işlemi gerçekleştirmektedir (Sarin, vd., 2023).

Bu ileri düzey teknikler umut vaat etse de, farklı popülasyonlar ve klinik ortamlarda standartlaştırılmaları konusunda hâlâ zorluklar mevcuttur. Bu nedenle, daha fazla araştırma ve doğrulama çalışmalarına ihtiyaç duyulmaktadır.

2.2. Literatür Taraması

Bu literatür taraması, nörogörüntüleme derin öğrenme yöntemlerinin uygulanmasını ve çeşitli nörolojik bozuklukların erken teşhisi ile tedavisindeki potansiyelini incelemektedir. Alzheimer, Parkinson, inme ve beyin tümörleri gibi bozuklukların tanı süreçlerinde bu tekniklerin etkinliği vurgulanmakta ve sağlık hizmetlerinde sağladığı yenilikçi yaklaşımlar ele alınmaktadır. Aşağıda, bu alanda gerçekleştirilen önemli çalışmaların özetleri sunulmuştur.

Zhang, vd., (2020) nörogörüntüleme derin öğrenme yöntemlerinin uygulanmasını incelemiştir. Çalışmada, Alzheimer ve Parkinson gibi nörodejeneratif bozuklukların yanı sıra Otizm spektrum bozukluğu ve Şizofreni için bilgisayarlı analiz yöntemleri ele alınmıştır. Yazarlar, derin öğrenme tekniklerinin bilgisayarlı tanıdaki etkinliğini vurgulayarak mevcut çalışmaların sınırlamalarını ve gelecekteki olası araştırma yönlerini tartışmışlardır.

Termine, vd., (2021) derin öğrenme yöntemlerinin nörodejeneratif bozuklukların, özellikle Alzheimer ve Parkinson'un, araştırılmasında çoklu omik, nörogörüntüleme ve elektronik sağlık kayıtları verilerinin entegrasyonu yoluyla erken tanı ve ilaç yeniden değerlendirme stratejilerini geliştirmede potansiyelini incelemiştir. Yazarlar, bu yaklaşımların kişiselleştirilmiş tedaviler ve etkili erken tanı araçları geliştirmedeki önemini vurgulamaktadırlar.

Iqbal, vd., (2024) derin öğrenmenin (DL) nörolojik bozuklukların (ND) teşhis ve tedavisindeki rolünü inceleyerek, multimodal nörogörüntüleme verilerinin analizine odaklanmışlardır. Çalışmada, CNN, LSTM-CNN, GAN ve VGG gibi çeşitli DL modellerinin performansları değerlendirilmiş ve klinik senaryolarda DL'nin etkisi vurgulanmıştır. Yazarlar, DL'nin nörolojik bozuklukların teşhis ve tedavisinde devrim yaratma potansiyelini ortaya koyarak, alanda daha verimli ve erişilebilir DL tekniklerinin geliştirilmesine yönelik yönelimler sunmuşlardır.

Aljarallah, vd., (2023) Akut İskemik İnme (AIS) tespitine yönelik derin öğrenme tabanlı bir model geliştirmişlerdir. Bu model, görüntü kalitesini artırmak amacıyla çekişmeli üretici ağlar (GANs) kullanmakta ve özellik çıkarımı için Yolo V7 tekniklerini uygulamaktadır. Araştırmalarında, 1021 sağlıklı ve 955 hasta T1-ağırlıklı MRI görüntüsünün yanı sıra 1551 sağlıklı ve 950 hasta CT görüntüsünü içeren veri setleri kullanmışlardır. Geliştirilen model, ResNest modelinin ortalama %98.25 doğruluk ve %97.275 F1 skoru ile mevcut yöntemleri aştığını göstermektedir.

Lo, vd., (2021) akut iskemik inme tespiti için derin evrişimli sinir ağları (DCNNs) tabanlı otomatik bir tanı yöntemi önermektedirler. 1254 gri tonlamalı NCCT görüntüsü kullanılarak AlexNet, Inception-v3 ve ResNet-101 modelleri değerlendirilmiş ve transfer öğrenme ile yüksek doğruluk oranları elde edilmiştir. Özellikle AlexNet, %97.12 doğruluk ve %98.11 duyarlılık sağlamıştır, bu da geliştirilen DCNN mimarisinin etkili bir bilgisayara dayalı tanı sistemi sunduğunu göstermektedir.

Yu, vd., (2020) acil servis ortamında inme teşhisini kolaylaştırmak amacıyla çoklu modlu derin öğrenme çerçevesi önermektedirler. Yüz hareketleri ve konuşma güçlükleri üzerinde odaklanan bu yöntem, gerçek acil servis hastaları üzerinde yapılan deneylerde %93.12 duyarlılık ve %79.27 doğruluk oranı elde etmiştir. Bu çerçeve, inme benzeri semptomlar ortaya çıktığında risk altındaki hastaların kendini değerlendirmesine olanak tanımaktadır.

Ullah ve Jamjoom (2023) Alzheimer hastalığı (AD) evrelerini tespit etmek için sıfırdan bir evrişimli sinir ağı (CNN) geliştirmişlerdir. Çalışmada, MRI görüntüleri kullanılarak eğitim sırasında veri artırma teknikleri uygulanmış ve modelin aşırı uyum sorunları aşılmıştır. Önerilen model, Alzheimer'ın dört evresini tespit etmede %99.38 doğruluk oranı ile en yüksek performansı göstermiştir.

Aparna ve Rao (2023) Alzheimer hastalığının çok sınıflı sınıflandırmasını gerçekleştirmek amacıyla iki önceden eğitilmiş derin öğrenme modelinden (DenseNet121 ve MobileNetV2) derin özellikler kullanmaktadır. Çalışmada, veri setinin %70 artırılarak CycleGAN ile yeni görüntüler üretilmiş ve önerilen modellerle %98.82 doğruluk oranı elde edilmiştir.

Muniagurria ve Rowlands (2023) Alzheimer hastalığının teşhisinde çeşitli CNN mimarilerinin etkinliğini karşılaştırmışlardır. VGG, ResNet ve DenseNet modelleri üzerinde yapılan çalışmada, DenseNet201 en yüksek doğruluk oranı olan %86.4'e ulaşmıştır. Transfer öğreniminin model performansını artırdığı belirtilmiştir.

Kiran, vd., (2024) beyin tümörlerinin segmentasyonu için bilineer evrişimli sinir ağı (BCNN) tabanlı yeni bir derin öğrenme yöntemi önermektedirler. Bu model, en yaygın 10 beyin tümörünü segmentleyerek mevcut modelleri aşmıştır. 6.600 MRI görüntüsü üzerinde eğitilen model, %99.40 doğruluk, %99.32 hassasiyet ve %99.45 duyarlılık elde etmiştir.

Abdullah, vd., (2024) beyin tümörlerinin hızlı ve doğru tespiti için yapay zeka tabanlı derin öğrenme yöntemlerini kullanarak MRI görüntülerinden sınıflandırma sürecini iyileştirmişlerdir. Çalışmada, özelleştirilmiş CNN, DeepTumor-Net, VGG-16, ResNet-50 ve Xception modelleri değerlendirilmiştir. "Brain tumors 256×256" veri setinde dört kategoriye ayrılan beyin tümörleri üzerinde, ResNet-50 %92.6 ve VGG-16 %92.1 doğruluk elde etmiştir.

Praveena, vd., (2024) beyin tümörlerini tespit etmek için derin öğrenme tekniklerini, özellikle VGG16 öğrenme algoritmasını ve evrişimli Sinir Ağı (CNN) yöntemlerini kullanan etkili bir sistem önermişlerdir. Bu yöntem, MRI görüntülerindeki karmaşık özellikleri otomatik olarak çıkararak yüksek doğruluk oranları elde etmeyi hedeflemektedir. Deneysel sonuçlar, sistemin erken tümör tespiti ve sonraki tıbbi müdahalelerde değerli bir araç olma potansiyelini göstermektedir.

Naaz, vd., (2022) Parkinson hastalığı'nın ilerlemesini değerlendirmek amacıyla ses verilerini kullanarak Birleşik Parkinson Hastalığı Değerlendirme Ölçeği (UPDRS) tahmini yapmak için derin sinir ağı (DNN) önermişlerdir. Çalışmada, 2 katmanlı ve 3 katmanlı ağlar incelenmiş ve 3 katmanlı ağın motor UPDRS için %97, toplam UPDRS için ise %99.62 doğruluk sağladığı bulunmuştur. Ayrıca, 3 katmanlı modelin ortalama kare hatası (MSE), ortalama mutlak hata (MAE) ve kök ortalama kare hata (RMSE) gibi diğer parametrelerinde de iyileşme gözlemlenmiştir.

Setiawan ve Lin (2021) Parkinson hastalığı (PD) şiddetini sınıflandırmak için derin öğrenme tabanlı bir algoritma geliştirmişlerdir. Dikey yer reaksiyon kuvveti (vGRF) sinyallerini kullanarak, hastaların yürüme bozukluklarından kaynaklanan kuvvet desenlerini analiz etmişlerdir. ResNet-50 ile yapılan değerlendirmede %96.52 doğruluk elde edilmiştir.

Rahman, vd., (2023) Parkinson hastalığı'nın erken aşamalarını tahmin etmek ve sınıflandırmak amacıyla derin öğrenme ve makine öğrenimi yöntemleri geliştirmişlerdir. Çalışmalarında, UCI veri havuzundan elde edilen bir veri setini kullanarak çeşitli sınıflandırma modellerini uygulamışlardır. Sonuç olarak, Extreme Gradient Boosting ile %92.18 doğruluk ve üç katmanlı derin sinir ağı (DNN3) ile %95.41 doğruluk elde edilmiştir.

3. NÖROLOJİK BOZUKLUKLARDA NÖROGÖRÜNTÜLEME TEKNİKLERİ

Nörogörüntüleme teknikleri, beyin fonksiyonu ve patolojisi hakkında anlayışımızı devrim niteliğinde değiştirmiştir; bu teknikler, çeşitli nörolojik ve psikolojik durumları incelemek için önemli bilgiler sunmaktadır. Temel yöntemler arasında Pozitron Emisyon Tomografisi (PET), Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI) ve elektroensefalografi (EEG) yer alır. Her bir yöntem, beyin aktivitesini ve yapısını incelemeye benzersiz avantajlar sunmaktadır. Örneğin, PET, metabolik süreçleri görselleştirmek için radyoizotoplar kullanarak, kanser ve bağımlılık gibi durumların değerlendirilmesinde kritik bir rol oynar (Parvaz, vd., 2011; Rocchi, vd., 2015). PET, glukoz tüketimini ölçerek, tümör karakterizasyonuna ve tedavi yanıtının izlenmesine yardımcı olur (Herholz et al., 2007).

Fonksiyonel MRI, kan akışındaki değişiklikleri tespit ederek beyin aktivitesini ölçer ve bilişsel işlevler ile nörolojik bozukluklar hakkında bilgi verir (Turner & Jones, 2003; Rocchi, vd., 2015). EEG ise, epilepsi ve uyku bozuklukları gibi durumların tanısında kullanılan beyin elektriksel aktivitesinin gerçek zamanlı izlenmesini sağlar (Parvaz, vd., 2011; Turner ve Jones, 2003). Ancak bu tekniklerin beyin fonksiyonu hakkındaki anlayışımızı geliştirmesine rağmen, çözünürlük artırma ve çok modlu görüntüleme yaklaşımlarının entegrasyonu gibi zorluklar devam etmektedir.

Nörogörüntüleme tekniklerindeki araştırma boşluğu, klinik ortamlardaki etkili uygulamalarını engelleyen kritik sınırlamalarla karakterizedir. Gelişmelere rağmen, nörogörüntüleme bulgularının pratik sağlık hizmetlerine dönüştürülmesinde önemli engeller bulunmaktadır. Yüksek maliyetler ve uzmanlık gereksinimleri, nörogörüntülemenin yaygın kullanımını sınırlamaktadır (Dennis, vd., 2023). Ayrıca, mevcut çalışmalar genellikle grup düzeyinde veriler üzerine odaklanmakta, bu da bireysel hasta değişkenliğini yakalayamadığı için kişiselleştirilmiş tedavi yaklaşımlarını sınırlamaktadır (Etkin, 2019).

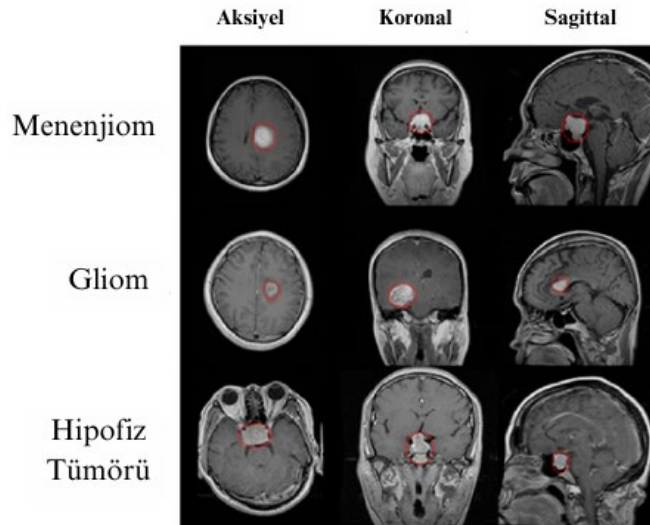
Nörogörüntüleme araştırmalarında coğrafi eşitsizlikler de dikkat çekmektedir; yüksek gelirli ülkelerde yoğunlaşan araştırmalar, düşük ve orta gelirli ülkelerde önemli demografik bilgilerin göz ardı edilmesine neden olmaktadır (Battel, vd., 2021). Metodolojik zorluklar da araştırma alanında sıkça rastlanan bir durumdur; özellikle Williams sendromu gibi durumlarda nörogörüntüleme sonuçlarındaki değişkenlik, daha standartlaştırılmış metodolojilere ve homojen çalışma popülasyonlarına ihtiyaç olduğunu göstermektedir (Thom, vd., 2023). Buna karşın, nörogörüntülemenin psikiyatrik bozuklukları anlama konusundaki potansiyeli umut vericidir ve bu sınırlamaların giderilmesinin klinik relevansı artırabileceği düşünülmektedir (Todeva-Radneva, vd., 2020).

3.1. Manyetik Rezonans Görüntüleme (MRI)

Manyetik Rezonans Görüntüleme (MRI), çeşitli nörolojik bozuklukların tanı ve yönetiminde kritik bir rol oynamaktadır; beyin yapısı ve işlevine dair ayrıntılı bilgiler sunar. MRI, beyaz madde anormalliklerini tespit etmek için tercih edilen görüntüleme yöntemi olup, özellikle multipl skleroz (MS), akut disseminate ensefalomyelit ve leykodistrofiler gibi durumlarda asimetrik ve çok odaklı lezyonları ortaya çıkarmaktadır (Miller, vd., 1990). Gelişmiş MRI teknikleri, difüzyon ağırlıklı görüntüleme ve fonksiyonel MRI gibi yöntemleri içermekte ve beyin perfüzyonu ile doku bütünlüğü hakkında kritik bilgiler sağlamaktadır; bu da karmaşık nörolojik bozuklukların tanısına yardımcı olmaktadır (Rocchi, vd., 2015; Bakshi, 2005).

MRI, tedavi etkinliğini değerlendirmek için klinik denemelerde invaziv olmayan bir araç olarak da işlev görmektedir; özellikle MS ve Alzheimer hastalığında hacimsel ve fonksiyonel görüntüleme, biyomarker olarak kullanılmaktadır (Ciumas, vd., 2008). Hastalık ilerleyişini ve tedaviye yanıtı görselleştirme yeteneği, tedavi stratejilerini önemli ölçüde etkilemekte ve hasta yönetimini optimize etmeye olanak tanımaktadır (Filippi, vd., 2006). MRI, nörolojik tanılama süreçlerinde son derece değerli olmasına rağmen, potansiyel yanlış pozitif sonuçlar ve uzman yorumuna olan ihtiyaç gibi sınırlamaları da bulunmaktadır; bu durum, klinik karar verme süreçlerini etkileyebilmektedir.

Şekil 3.1, meningioma, glioma ve hipofiz tümörlerinin axial, koronal ve sagittal düzlemlerde alınmış MRI görüntülerini ayrıntılı olarak göstermektedir. Her tümör tipi, beyindeki yerleşim ve büyüklüğüne bağlı olarak farklı görüntüleme düzlemlerinde net bir şekilde tanımlanmış ve kırmızı dairelerle vurgulanmıştır. Meningioma genellikle beyin zarlarından kaynaklanırken, glioma beyin dokusundan, hipofiz tümörleri ise hipofiz bezinden kaynaklanarak farklı anatomik bölgelerde farklı etkiler yaratmaktadır. Bu görüntüler, tümörlerin hem yapısal özelliklerini hem de çevresel dokularla olan ilişkisini incelemek için kullanılır.

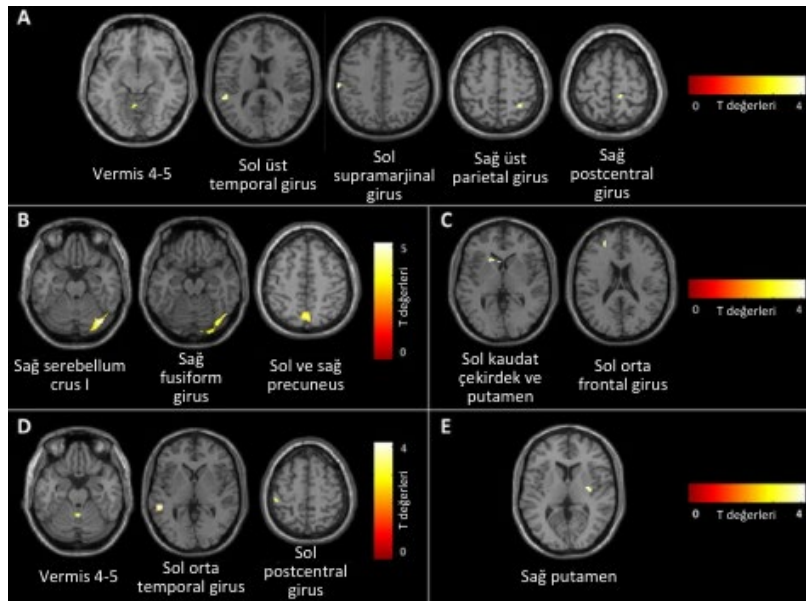


Şekil 3.1. Meningioma, glioma ve hipofiz tümörlerine ait aksiyel, koronal ve sagittal düzlemlerde MRI görüntüleri (Badža ve Barjaktarović, 2020).

3.2. Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI)

Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI), çeşitli nörolojik bozuklukları anlamada ve tanılamada kritik bir araç haline gelmiştir. Beyin aktivitesini ve bağlantılarını değerlendirme yeteneği, Parkinson hastalığı, motor nöron hastalığı ve nöropsikiyatrik bozukluklar gibi durumlarla ilişkili yapısal ve fonksiyonel anormallikler hakkında önemli bilgiler sunmaktadır. Parkinson hastalığında, fMRI, dopamin eksikliklerinin ötesinde işlevsel ağlardaki değişiklikleri ortaya çıkarmış; bu da motor ve nonmotor semptomların anlaşılmasına yardımcı olmuş ve erken tanı ile hastalığın ilerleyişinin izlenmesine katkı sağlamıştır (Niethammer, vd., 2012). Motor nöron hastalığı olan hastalarda yapılan MRI bulguları, Piramidal yol (Piramidal traktus) dejenerasyonuna işaret eden Kortikospinal yol (Tractus Corticospinalis) ile ilişkili belirli sinyal anormalliklerini göstermektedir (Luis, 1990). Nöropsikiyatrik bozukluklar açısından ise, fMRI gibi gelişmiş görüntüleme teknikleri, beyin işlevindeki hastalık-spesifik değişiklikleri tanımlayarak potansiyel erken tanı belirteçleri ve tedavi değerlendirme araçları sunmaktadır (Mueller, vd., 2012). fMRI önemli avantajlar sağlasa da, deneysel tasarım ve veri yorumlamada zorluklar devam etmektedir; özellikle nörolojik bozuklukları olan hastalarda görev seçimi ve veri ön işleme konularına dikkat edilmesi gerekmektedir (Price, vd., 2006).

Şekil 3.2, Parkinson hastalığı bulunan bireylerde fMRI ile elde edilen beyin aktivite modellerini sunmaktadır. Görüntüde, hastalığın etkisiyle farklı beyin bölgelerinde gözlemlenen işlevsel aktivite değişiklikleri ve bu bölgelerdeki yapısal değişimlerin detaylı bir şekilde vurgulandığı görülmektedir. Bu modeller, Parkinson hastalığının patofizyolojik süreçlerini anlamak ve hastalığın ilerleyişini izlemek açısından önemli bilgiler sağlamaktadır.




Şekil 3.2. Parkinson hastalarında fonksiyonel manyetik rezonans görüntüleme (fMRI) ile beyin aktivite desenleri (Piramide, vd., 2020).

3.3. Bilgisayarlı Tomografi (CT)

Bilgisayarlı Tomografi (CT), özellikle acil durumlarda çeşitli nörolojik bozuklukların tanı ve yönetiminde kritik bir rol oynamaktadır. Hemorajik ve iskemik inme arasında hızlı bir şekilde ayırım yapabilme yeteneği, zamanında tedavi için hayati öneme sahiptir ve hasta sonuçlarını önemli ölçüde iyileştirmektedir (Dzialowski, vd., 2022). Akut inme değerlendirmesinde, kontrastsız CT, erken iskemik değişiklikleri tanımlamakta ve tromboliz kararlarına rehberlik etmekte standart bir yöntemdir (Dzialowski, vd., 2022). Beyin damar bozuklukları açısından, CT anjiyografisi (CTA) tıkaçıcı bozuklukların etkili bir şekilde tanı almasına olanak tanır ve büyük trombus yükü olan hastaların yönetiminde yardımcı olmaktadır (Dzialowski, vd., 2022). Gelişmiş görüntüleme teknikleri arasında yer alan X-ray Faz Kontrast Tomografisi (XPCT), merkezi sinir sistemindeki yumuşak dokuların görselleştirilmesini artırarak, Alzheimer ve multipl skleroz gibi nörodejeneratif bozukluklar hakkında geleneksel yöntemlerin kaçırabileceği detayları ortaya çıkarmaktadır (Palermo et al., 2020). CT, genellikle MRI ve PET ile birlikte kullanılarak, nörolojik durumlar hakkında tamamlayıcı bilgiler sunmaktadır (Sima, vd., 2017; Pabla, vd., 2021). Ancak CT, akut senaryolar için değerli olsa da, yumuşak doku kontrastındaki sınırlamaları, kapsamlı nörolojik değerlendirmelerde multimodal bir yaklaşım gerektirmektedir.

Şekil 3.3, akut iskemik inme tanısında kullanılan bilgisayarlı tomografi (CT) görüntüsünü sunmaktadır. Görüntüde, ok ile işaretlenmiş hipodens alan, beyin dokusundaki iskemik bölgeyi belirgin bir şekilde göstermekte olup, bu alanın beyindeki kan akışının azalması nedeniyle oluşan hasarı temsil ettiğini ortaya koymaktadır. Bu hipodens alan, iskemik inmenin acil tanısında önemli bir gösterge olarak kabul edilmektedir.




Şekil 3.3. Akut iskemik inme tanısında bilgisayarlı tomografi (CT) görüntüsü (Potter, vd., 2019).

3.4. Pozitron Emisyon Tomografisi (PET)

Pozitron Emisyon Tomografisi (PET), nörolojik bozuklukların tanı ve yönetiminde kritik bir görüntüleme tekniğidir ve beynin metabolik ve patolojik değişikliklerine dair önemli bilgiler

sunmaktadır. Uygulamaları, Alzheimer hastalığı, multipl skleroz ve nöroinflamasyon gibi durumlarda erken tanıdan hastalık ilerlemesini izlemeye kadar geniş bir yelpazeyi kapsamaktadır. PET görüntülemesi, özellikle 18F-FDG ile, Alzheimer ve frontotemporal demans gibi nörodejeneratif bozukluklarda hipometabolik paternleri tanımlamak için hayati öneme sahiptir (Xie, vd., 2024; Cecchin, vd., 2021). Ayrıca, amiloid ve tau proteinlerini hedef alan yeni izleyiciler, bilişsel bozuklukların daha iyi sınıflandırılmasına olanak tanıyarak tanısal doğruluğu artırmıştır (Cecchin, vd., 2021). Nöroinflamasyonun miktarını belirlemek için giderek daha fazla kullanılan PET, Alzheimer gibi bozukluklarda nöroimmün yanıtı anlamada önemli bir rol oynamaktadır ve bunun tedavi üzerindeki etkilerini araştırmaktadır (Kreisl, vd., 2020). PET-CT, metabolik ve anatomik görüntülemeyi birleştirerek, çeşitli demansların ayırt edilmesine ve hastalık şiddetinin izlenmesine yardımcı olmaktadır (Pabla, vd., 2021). Örneğin, farklı FDG alım paternleri belirli nörolojik durumları gösterebilir (Pabla, vd., 2021). PET görüntülemesi, nörolojik bozuklukların tanısı ve anlaşılmasında önemli avantajlar sağlasa da, klinik uygulamalarının standartlaştırılmasında ve nöroinflamasyon ölçümündeki karmaşıklıkların giderilmesinde zorluklar bulunmaktadır (Kreisl, vd., 2020).

Şekil 3.4, Normal bir beyin ile Hafif Bilişsel Bozulma ve Alzheimer hastalığı olan beyinler arasındaki metabolik farklılıkları net bir şekilde göstermektedir. Normal beyin PET görüntüsünde yaygın kırmızı alanlar sağlıklı glikoz metabolizmasını işaret ederken, Hafif Bilişsel Bozulma ve Alzheimer hastalığında bu metabolik aktivitenin belirgin şekilde azaldığı, özellikle Alzheimer hastalığında ciddi hipometabolik alanların oluştuğu görülmektedir.



Şekil 3.4. Alzheimer hastalığı ve hafif bilişsel bozulma ile normal beyin arasındaki metabolik farklılıkları gösteren PET görüntüleri (Şalçini, 2019).



4. YAPAY ZEKA

Yapay zeka (AI), altmış yılı aşkın bir geçmişe sahip olup, önemli kilometre taşları ve sürekli gelişen araştırma temalarıyla şekillenmiştir. Başlangıçta disiplinler arası çalışmalarla temellenen AI, teorik kavramlardan pratik uygulamalara geçiş yaparak günümüzde birçok alanda etkili bir teknoloji haline gelmiştir. 1950'lerde psikoloji, dilbilim ve bilgisayar bilimlerinin entegrasyonu sonucunda ortaya çıkan AI, bilgi temsili ve akıl yürütme gibi temel yöntemlerin geliştirilmesine öncülük etmiştir (Sokolov, 2019). AI'nin kökeni, eski mitler ve zekaya dair felsefi sorgulamalardan ilham almış, erken dönem literatürde mekanik yardımcıları hayal edilmiştir (Poole ve Mackworth, 2010). Zamanla uzman sistemler, doğal dil işleme ve makine öğrenmesi gibi büyük gelişmeler kaydedilmiş ve bu teknolojiler modern AI uygulamalarının vazgeçilmez bileşenleri olmuştur (Franklin, 2014; Sokolov, 2019). Son on yılda ise özellikle tıp alanında AI teknolojilerinin hızlı yükselişi, tanı süreçlerini ve hasta bakımını büyük ölçüde iyileştirmiştir (Jean, 2020). Günümüzde yumuşak hesaplama, bilişsel hesaplama ve AI'nin etik boyutları gibi konular ön plandadır ve bu alanlarda sorumlu bir geliştirme anlayışının gerekliliği vurgulanmaktadır (Franklin, 2014; Bibel, 2014). AI'nin gelişimindeki nihai hedefler, insan zekasını yalnızca taklit etmekten öte onu geliştirmek üzerinedir (Bibel, 2014). Ancak, veri gizliliği ve algoritma şeffaflığı gibi zorluklar, AI'nin geleceği açısından önemli araştırma konuları olmaya devam etmektedir.

AI'nin özellikle tıp alanındaki entegrasyonu, etkinliğini artırmak ve uygulama alanlarını genişletmek için çözülmesi gereken önemli araştırma boşluklarını da beraberinde getirmektedir. Bu boşluklar genellikle metodolojik yenilikler, doğrulama süreçleri ve etik hususlar etrafında toplanmaktadır. AI'nin tıpta etkin bir şekilde kullanılabilmesi için yeni metodolojilere ihtiyaç duyulmaktadır. Mevcut araştırmalar, önerilen stratejilerin gerçek dünyadaki tıbbi ortamlarda uygulanabilirliğini yeterince deneysel olarak göstermemektedir (Magrez, 1986). Yapay uyarlanabilir sistemlerin (AAS) gelişimi, AI'nin hasta ihtiyaçlarına dinamik olarak uyum sağlayarak karmaşık tıbbi sorunları yönetme potansiyelini göstermektedir, ancak bu alan yeterince araştırılmamıştır (Grossi ve Buscema, 2006). Ayrıca, AI sistemlerinin araştırma ortamından klinik uygulamalara geçişi, doğrulama süreçleriyle ilgili soruları gündeme getirmektedir. Tıbbi uygulamalarda kullanılan sistemlerin, diğer AI uygulamalarından farklı olarak, özel değerlendirme çerçevelerine ihtiyaç duyduğu belirtilmektedir (Oakden-Rayner ve Palmer, 2019). Etik ve politik açılardan ise, AI'nin tıp alanında kullanımıyla ilgili kısa ve uzun vadeli endişelerin ele alınabilmesi için iş birliği yapılması gerektiği konusunda araştırmacılar arasında bir fikir ayrılığı bulunmaktadır (Stix ve Maas, 2021). Bu boşlukların kapatılması, AI'nin sağlık hizmetlerine sorumlu ve etkili bir şekilde entegrasyonunu sağlamak ve yeniliklerin hasta sonuçlarını iyileştirmeye katkı sağlamasını temin etmek açısından kritik öneme sahiptir.

AI, öğrenme, akıl yürütme ve problem çözme gibi insan benzeri bilişsel işlevleri taklit eden makineler aracılığıyla teknoloji dünyasında dönüştürücü bir paradigma sunmaktadır. Bu teknoloji,

çeşitli sektörlerde verimliliği artırmakta ve yenilikleri teşvik etmektedir. AI, entelektüel görevlerin otomasyonu anlamına gelmekte ve makinelere karmaşık senaryolarda uyarlanabilir problem çözme yeteneği kazandırmaktadır (Ashenden, vd., 2021; Zhang, vd., 2021). Sağlık alanında hastalık yönetiminde yardımcı olmak, ulaşımında otonom araçların gelişimini desteklemek gibi çeşitli sektörlerde AI devrim niteliğinde ilerlemeler kaydetmektedir (Panesar, 2019). Ayrıca, bilimsel araştırmalarda yüksek verimli veri analizi aracılığıyla disiplinler arası önemli bulgular sağlamaktadır (Xu, vd., 2021). AI'nin gelişimi devam ettikçe, günlük süreçlere ve endüstrilere daha fazla entegrasyon vaat etmektedir (Tripathi, 2021). Bununla birlikte, AI'nin sağladığı bu önemli gelişmelerin yanında, etik sonuçlar ve iş kaybı gibi endişeler, bu teknolojinin evriminde hala önemli tartışma konuları olmaya devam etmektedir.

4.1. Yapay Sinir Ağları

Yapay sinir ağları (ANN), insan beynindeki biyolojik sinir ağlarından esinlenerek geliştirilmiş hesaplama modelleridir. Bu sistemler, birbirine bağlı ve paralel olarak çalışan nöronlardan oluşur ve karmaşık bilgileri işleyip sınıflandırma gibi görevlerde yüksek başarı sağlar. Sinir ağları, örüntü tanıma ve tahmine dayalı modelleme gibi alanlarda önemli gelişmelerin önünü açmıştır.

Yapay sinir ağları, nöron adı verilen ve girdi sinyallerini toplayarak, işleyip çıkışa dönüştüren birimlerden oluşur (Kruse, vd., 2016; Aggarwal, 2018). Bu nöronlar katmanlar halinde organize olur; tipik olarak giriş, gizli ve çıkış katmanlarından oluşur. Nöronlar arasındaki bağlantı ağırlıkları, geriye yayılım (backpropagation) yöntemi ile ayarlanarak modelin öğrenme süreci gerçekleşir. ANN'ler, bu adaptif öğrenme yetenekleri sayesinde bilgisayarla görü ve doğal dil işleme gibi alanlarda önemli uygulamalara sahiptir (Bisong, 2019). Örneğin, derin öğrenme algoritmaları, kendi kendine giden araçlar ve otomatik konuşma çevirisi gibi teknolojilere olanak tanımaktadır.

Nöronlar, girdileri toplayarak bir eşik fonksiyonuna göre çıkış üretir ve bu süreç, genellikle karmaşık veri işleme için önemli bir rol oynar (Unal, vd., 2013). Bu nöronlar katmanlar halinde organize olup, veriyi daha karmaşık bir şekilde işler (Tino, vd., 2015). ANN'ler, gözetimli ve gözetimsiz öğrenme yaklaşımları ile verilerden öğrenir ve önceden tanımlanmış modellere bağlı kalmaksızın esnek yapılar sunar (Buscema, vd., 2018). Ancak, aşırı öğrenme (overfitting) gibi sorunlar, özellikle gürültülü verilerde karşılaşılan bir problem olarak dikkat çekmektedir ve bu durum dikkatli model seçimi ve eğitim stratejilerinin önemini ortaya koymaktadır (Kubat, 2015).

Yapay sinir ağları, özellikle tıbbi görüntü analizi ve veri sınıflandırma alanında güçlü bir potansiyele sahiptir. Tıbbi görüntülerdeki örüntüleri tanıma ve sınıflandırma konusunda derin öğrenme modelleri önemli başarılarla ulaşmıştır. Bu durum, nöroloji, kardiyoloji ve onkoloji gibi alanlarda teşhis doğruluğunu artırmakta ve büyük veri setlerinin analizini kolaylaştırmaktadır (Suganyadevi, vd., 2021). Ayrıca, ANN'ler klinik karar destek sistemlerinde de geleneksel istatistiksel yöntemlere kıyasla daha üstün performans göstermiştir. Bununla birlikte, bu modellerin rutin klinik uygulamalarda tam

anlamıyla entegrasyonu henüz sınırlıdır ve hasta bakımına doğrudan etkileri nadir olarak görülmektedir (Gant, vd., 2009).

4.2. Derin Öğrenme

Derin öğrenme (DL), makine öğrenimi (ML) ve yapay zekânın (AI) önemli bir alt dalıdır. Yapay sinir ağlarını kullanarak verilerdeki karmaşık desenleri modellemekte ve geleneksel yöntemlere kıyasla üstün performans sergilemektedir (Janiesch, vd., 2021; Sarker, 2021). Bu teknoloji, sağlık, bilgisayarla görme ve doğal dil işleme gibi birçok sektörde kendini göstermiştir.

DL'nin başlıca özelliklerinden biri, insan beynini taklit eden sinir ağı yapısına sahip olmasıdır. Veriyi hiyerarşik olarak işlemek için katmanlar arasındaki düğümlerden faydalanır (Egger, vd., 2021). Ayrıca, büyük veri kümelerinden öğrenme yeteneği sayesinde görüntü tanıma ve metin analitiği gibi alanlarda etkili uygulamalar geliştirilmiştir (Sarker, 2021). Ancak bu modellerin karmaşık yapısı ve genellikle "kara kutu" olarak tanımlanması, geliştirilmesini ve anlaşılmasını zorlaştırmaktadır (Sarker, 2021). Büyük veri setlerine ihtiyaç duyması ve karmaşıklığı, bu teknolojiyi kullananlar için giriş bariyerleri yaratabilir.

Derin öğrenme modellerinin performansı için parametrelerin önemi büyüktür. Son araştırmalar, bu parametrelerin optimizasyonuna yönelik çeşitli stratejiler ortaya koymaktadır. Önemli bulgular, modellerde önemli bir parametre fazlalığı olduğunu ve parametre yönetimi konusunda verimli eğitim yöntemleri ile yenilikçi sıkıştırma tekniklerinin kullanılabilirliğini göstermektedir. Araştırmalar, parametrelerin %95'inden fazlasının doğruluk kaybı olmadan küçük bir ağırlık alt kümesinden tahmin edilebileceğini ortaya koymaktadır. Bu, performanstan ödün vermeden modellerin basitleştirilebileceğini işaret eder (Denil, vd., 2013). Ayrıca, dinamik seyrek yeniden parametreleştirme yöntemi, sıfır olmayan parametreleri yeniden tahsis ederek ağırları daha verimli şekilde eğitmekte ve geleneksel budama yöntemlerinden daha iyi performans sergilemektedir (Mostafa ve Wang, 2019). Büyük parametre setlerinin depolanmasındaki zorlukları çözmek için matris ve tensör ayrıştırma teknikleri kullanılmakta ve bu yöntemler, performansı korurken önemli sıkıştırma sağlamaktadır (He, vd., 2020). Ancak hiperparametre optimizasyonu halen karmaşık bir süreç olup, bu alandaki araştırmaların geliştirilmesi gerekmektedir (Bousquet, vd., 2017).


Derin öğrenme algoritmaları, ileri düzey veri işleme ve öngörülse modelleme yaparak çeşitli alanlarda devrim yaratmıştır. Özellikle, derin sinir ağları (DNNs), evrişimli sinir ağları (CNNs) ve tekrarlayan sinir ağları (RNN) görüntü tanıma, konuşma işleme ve büyük veri analizi gibi uygulamalarda kritik rol oynamaktadır (Pamina ve Beschi, 2019). DNN'ler, dil modelleme ve bilgisayarla görme gibi karmaşık problemleri çözmede başarılıdır (Bisong, 2019). CNN'ler ise görüntü işleme alanında, özellikle nesne tespiti gibi görevlerde uzaysal hiyerarşileri kullanarak doğruluğu artırmaktadır (Pamina ve Beschi, 2019). RNN'ler ise sıralı verilerle çalışmak için ideal olup, zaman serisi tahminleri ve doğal dil işleme uygulamalarında etkilidir (Pamina ve Beschi, 2019). Derin

öğrenmenin pek çok alandaki uygulama ve etkisi dikkate değerdir. Örneğin, derin öğrenmenin pekiştirmeli öğrenme ile entegrasyonu, özellikle karar alma görevlerinde yapay zekâda önemli ilerlemelere yol açmıştır (Ivanov ve D'yakonov, 2019). Ayrıca, yüksek boyutlu stokastik kontrol problemlerinde derin öğrenme, politika yaklaşıkları ve değer fonksiyonu tahmini konularında etkili çözümler sunmaktadır (Huré, vd., 2021). Ancak derin öğrenme algoritmalarının yetenekleri dikkate değer olsa da, büyük veri setlerine ve yüksek hesaplama gücüne olan ihtiyaç, yaygın benimsenmelerinin önünde önemli engeller oluşturmaktadır.

4.2.1. Derin Sinir Ağları (DNNs)

Derin Sinir Ağları (DNNs), makine öğreniminde devrim niteliğinde bir teknoloji olup, bilgisayarla görme, doğal dil işleme gibi çeşitli alanlarda önemli ilerlemelere olanak sağlamaktadır. İnsan beyninden ilham alınarak tasarlanan mimarisi, karmaşık problem çözme yetenekleri ve yüksek performanslı tahminler yapabilme kapasitesi sunmaktadır. Son araştırmalar ışığında DNN'lerle ilgili bazı önemli noktalar şu şekildedir:

DNN'ler, otomatik konuşma çevirisi ve otonom araçlar gibi görevlerde üstün performans sergileyerek çok yönlülüklerini kanıtlamaktadır (Bisong, 2019). Örneğin, iki boyutlu manyetik kayıta, bir DNN tabanlı a posteriori olasılık dedektörü, bit hata oranlarını önemli ölçüde azaltarak geleneksel algoritmalarından daha iyi sonuçlar elde etmiştir (Shen, vd., 2020). Şekil 4.1, bir Derin Sinir Ağı'nın (DNN) mimarisini, giriş katmanından başlayarak gizli katmanlar ve çıkış katmanına kadar olan nöronlar arası bağlantıları göstermektedir.



Şekil 4.1. Derin sinir ağı (DNN) mimarisi (Mohanasundaram, vd., 2019).


DNN'lerin mimarisinde kaydedilen yenilikler arasında "Ağ İçinde Ağ" (NiN) modeli öne çıkmaktadır. Bu model, doğrusal filtreleri çok katmanlı algılayıcılarla değiştirerek sınıflandırma performansını artırmakta, bağlantı yoğunluğunu ve öğrenme verimliliğini geliştirmektedir (Alaeddine ve Jihene, 2021). Ayrıca, "Zaman İçinde Katlanmış DNN" adı verilen yenilikçi bir yaklaşım, DNN'leri geri besleme döngülerine sahip tek bir nörona indirgemekte, böylece karmaşıklığı azaltırken performansı korumaktadır (Stelzer, vd., 2021).

Başarılarına rağmen, DNN'ler genellikle açıklanabilirlikten yoksundur, bu da karar verme süreçlerini netleştirmek için özellik tabanlı ve kendini açıklayan modeller üzerine araştırmaları teşvik etmektedir (Camburu, 2020). DNN'lerin sunduğu olağanüstü yeteneklere rağmen, bu modellerin karmaşıklığı ve opaklığı, onları daha anlaşılır ve verimli hale getirmeye yönelik devam eden araştırmaların gerekliliğini ortaya koymaktadır.

4.2.2. Evrişimsel Sinir Ağları (CNNs)

Evrişimli Sinir Ağları (CNNs), özellikle bilgisayarla görme ve görüntü işleme alanlarında üstün performans gösteren özel bir sinir ağı türüdür. Mimarisi, birden fazla katmandan geçerek otomatik özellik çıkarımı sağlar ve verilerden karmaşık desenleri öğrenme yeteneğini artırır. Son yıllarda CNN'lerdeki yenilikler, performans ve verimliliği çeşitli alanlarda iyileştiren mimari gelişmelere yol açmıştır.

CNN'ler, görüntü sınıflandırma ve segmentasyon gibi görevlerde olağanüstü sonuçlar elde ederek tıbbi görüntüleme ve biyolojik çeşitlilik izleme gibi alanlarda büyük etkiler yaratmıştır (Khan, vd., 2020; Kugunavar ve Prabhakar, 2021). Yoğun Bağlantı (Dense Connectivity) fikrinin tanıtılmasıyla her katman, diğer katmanlara bağlanarak eğitim verimliliği ve doğruluk artırılmış, aynı zamanda kaybolan gradyan sorunları gibi zorluklar da giderilmiştir (Huang, vd., 2022). Şekil 4.2, CNN mimarisinin genel yapısını ve katmanlar arasındaki geçişleri göstermektedir.




Şekil 4.2. Evrişimli sinir ağı (CNN) mimarisi (Mall, vd., 2023).

Ekoloji modellemede de CNN'ler, çevresel mekânsal yapıyı yakalayarak türlerin varlıklarını öngörmeye yüksek doğruluk sağlamıştır (Deneu, vd., 2021). Ayrıca malzeme biliminde de CNN'ler, organik güneş hücreleri için fulleren içermeyen akseptörlerin tasarımında kullanılmakta olup, görüntü işlemenin ötesinde farklı alanlardaki çok yönlülüklerini göstermektedir (Peng, vd., 2022).

CNN'ler birçok alanda devrim yaratmış olmasına rağmen, büyük veri kümeleri ve yüksek hesaplama kaynaklarına olan ihtiyaç gibi bazı zorluklar devam etmektedir; bu da verisi sınırlı ortamlarda erişilebilirlik ve uygulama kısıtlamalarına yol açabilmektedir.

4.2.3. Tekrarlayan Sinir Ađları (RNNs)

Tekrarlayan Sinir Ađları (RNNs), sıralı verileri iřlemek iin tasarlanmış ve zaman iinde gelişen gizli bir durumu koruyan sinir ađları sınıfıdır. Son yıllarda RNN'lerdeki gelişmeler, özellikle karmaşık veri yapılarıyla başa çıkma ve performans artırma konusunda bu ađların yeteneklerini ve uygulama alanlarını genişletmiştir. Şekil, tekrarlayan sinir ađlarının (RNN) temel alıřma prensibini açıklamaktadır. RNN'ler, sıralı verileri iřleyebilme yetenekleri sayesinde özellikle zaman serisi ve dođal dil iřleme gibi alanlarda sıka kullanılır. Ađın her bir hcresinde, önceki adımlardan gelen gizli durum ($h^{(t-1)}$) ve o andaki giriř ($x^{(t)}$) birlikte iřlenerek yeni bir gizli durum ($h^{(t)}$) oluşturulur. Bu gizli durum, hem mevcut ıktı ($o^{(t)}$) üretiminde kullanılır hem de bir sonraki adımdaki hesaplamaa aktarılır. Bylece RNN, önceki adımlardan gelen bilgiyi hatırlayarak gelecekteki adımlarda kullanabilir. Ancak, uzun dizilerde bilgilerin zamanla kaybolma veya zayıflama riski de vardır. Şekil 4.3, bu hesaplamaların zaman iinde nasıl tekrarlanarak ilerlediđini aık bir şekilde gösteriyor ve RNN'lerin ardışık veri iřleme kapasitesini vurguluyor.



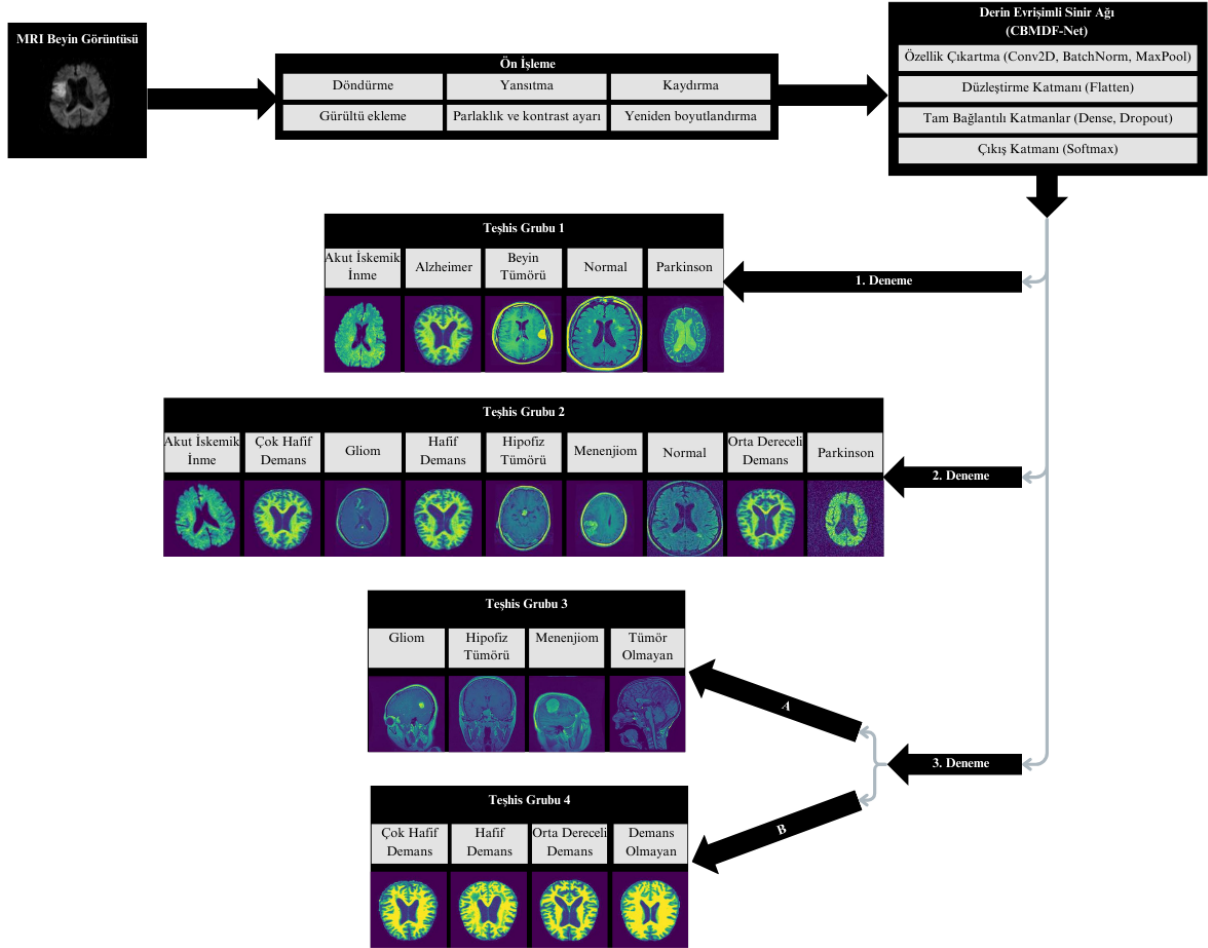
Şekil 4.3. Tekrarlayan sinir ađlarının (RNN) yapısı (Das, vd., 2023).

Symplectic RNN'ler (SRNNs), Hamiltonyen dinamikleri modellemeye odaklanarak, fiziksel sistemlerdeki sayısal zorlukları symplectic entegrasyonu ve optimizasyon teknikleriyle etkili bir şekilde ele almaktadır (Chen et al., 2020). Diđer yandan, Kuaterniyon RNN'ler (QRNNs) ve Kuaterniyon LSTM'ler (QLSTMs), kuaterniyon cebirini kullanarak ok boyutlu giriř özelliklerini yönetmekte ve bu sayede konuşma tanıma gibi görevlerde daha az parametre ile stn performans elde etmektedir (Parcollet, vd., 2018).

Arařtırmalar, özellikle dođal dil iřleme alanında, basit RNN'lerle iliřkili birok problemin kararsız olduđunu ve bu tr problemler iin pratik uygulamalarda sezgisel yaklařımların gerektiđini gstermektedir (Chen, vd., 2018). Lipschitz RNN'ler ise geleneksel RNN mimarilerine kıyasla eřitli görevlerde gelişmiş kararlılık ve performans sađlayarak bir kararlılık analizi erevesi sunmaktadır (Erichson, vd., 2021). RNN'ler nemli yetenekler sergilemiş olmasına rađmen, eđitim zorlukları ve kararlılık sorunları, daha geniş apta uygulanmalarının nndeki nemli engeller olarak kalmaya devam etmektedir.

5. MATERYAL ve YÖNTEM

Bu bölüm, çalışmada kullanılan veri setlerini, önerilen CBMDF-Net modelinin tüm aşamalarını ve uygulanan yöntemleri detaylı olarak açıklamaktadır. Modelin eğitim süreci ve hiperparametre ayarları da burada ele alınmıştır. Şekil 5.1’de sunulan blok diyagramı, CBMDF-Net’in nörolojik hastalıkların sınıflandırılması sürecini üç farklı deneme üzerinden görselleştirmektedir.



Şekil 5.1. Önerilen yöntemin genel blok diyagramı.

İlk olarak, ham beyin MRI görüntüleri çeşitli veri artırma teknikleriyle işlenir; döndürme, yansıtma, kaydırma, gürültü ekleme, parlaklık ve kontrast ayarı ile yeniden boyutlandırma gibi ön işleme adımları uygulanır. Bu işlemler, modelin genelleme yeteneğini artırmak ve aşırı öğrenmeyi (overfitting) önlemek amacıyla yapılmaktadır. Ardından, işlenmiş görüntüler üç farklı deneme kapsamında sınıflandırmaya tabi tutulur. Birinci denemede, akut iskemik inme, Alzheimer, beyin tümörleri, Parkinson ve normal olmak üzere beş sınıf üzerinden bir sınıflandırma yapılır. İkinci denemede ise sınıflar genişletilerek akut iskemik inme, çok hafif demans, gliom, hafif demans, hipofiz tümörü, menenjiom, orta dereceli demans, Parkinson ve normal olmak üzere dokuz sınıf üzerinden bir

değerlendirme gerçekleştirilir. Üçüncü denemede, iki farklı teşhis grubu incelenir: Birinci grup beyin tümörleri (gliom, hipofiz tümörü, menenjiom ve tümör olmayan) üzerine odaklanırken, ikinci grup demans alt sınıfları (çok hafif demans, hafif demans, orta dereceli demans ve demans olmayan) arasındaki sınıflandırmaya odaklanmıştır. Her denemede, CBMDF-Net modeli Conv2D, BatchNorm ve MaxPool gibi özellik çıkarma katmanları ile görüntülerin özelliklerini öğrenir, ardından düzleştirme ve tam bağlantılı katmanlar aracılığıyla nihai sınıflandırmayı Softmax katmanı kullanarak gerçekleştirir. Bu yapı, nörolojik hastalıkların doğru bir şekilde teşhis edilmesi için bütüncül ve sistematik bir yaklaşımı ortaya koymaktadır.

5.1. Veri Setleri


Bu çalışmada, nörolojik hastalıkların sınıflandırılması amacıyla dört farklı açık erişimli MRI veri seti kullanılmıştır. Tüm veri setleri, Kaggle platformundan elde edilmiş olup, nörolojik bozuklukları doğru bir şekilde ayırt etmek için farklı kategorilere ayrılmıştır. Her bir veri seti, belirli bir nörolojik hastalığı temsil etmekte ve çalışma kapsamında çeşitli görüntü işleme ve veri artırma teknikleriyle işlenmiştir. Veri setlerinin ayrıntıları aşağıda verilmiştir:

5.1.1. Akut İskemik İnme Veri Seti

Akut İskemik İnme hastalığının teşhisine yönelik olan bu veri seti (TAŞCI, 2022), toplamda 2.010 beyin MRI görüntüsünden oluşmaktadır. Veri seti, beyin inme vakalarının tespitine odaklanmıştır. Görüntüler iki ana gruba ayrılmıştır:

- Eğitim verileri: 1.002 görüntü
- Test verileri: 1.008 görüntü

Bu veri seti yalnızca akut iskemik inme sınıfını temsil etmektedir ve çalışmada sınıflandırma için kullanılan önemli veri kaynaklarından biridir. Aşağıda, bu veri setinden alınan bir örnek beyin MRI görüntüsü gösterilmiştir. Şekil 5.2, akut iskemik inme'yi temsil eden bu görüntü, sınıflandırmada kullanılan önemli verilerden biridir ve CBMDF-Net modelinin sınıflandırma yeteneğini güçlendirmektedir.




Şekil 5.2. Akut iskemik inme MRI görüntü örneği.

5.1.2. Alzheimer Hastalığı Veri Seti

Alzheimer hastalığı teşhisini amaçlayan bu veri seti (Dubey, 2021), toplamda 6.400 beyin MRI görüntüsünden oluşmaktadır ve Alzheimer hastalığının farklı evrelerini sınıflandırmak için dört farklı sınıfa ayrılmıştır:

- Çok hafif demans: 1.792 eğitim, 448 test görüntüsü
- Hafif demans: 717 eğitim, 179 test görüntüsü
- Orta dereceli demans: 52 eğitim, 12 test görüntüsü
- Demans olmayan: 2.560 eğitim, 640 test görüntüsü

Bu veri seti, Alzheimer hastalığının farklı evrelerini (çok hafif, hafif ve orta dereceli demans) ve sağlıklı bireyleri içeren "demans olmayan" sınıfını içerir. Bu nedenle, Alzheimer teşhisinde hassas bir şekilde sınıflandırma yapılmasını sağlamaktadır. Aşağıda, bu veri setine ait beyin MRI görüntülerinin örnekleri verilmiştir. Şekil 5.3, Alzheimer'ın farklı evrelerini ve sağlıklı bireyleri temsil eden bu görüntüler, modelin sınıflandırma doğruluğunu artırmak için kullanılmıştır.



Şekil 5.3. Alzheimer hastalığına ait MRI görüntü örnekleri. A) çok hafif demans, b) hafif demans, c) orta dereceli demans, d) demans olmayan.


5.1.3. Beyin Tümörleri Veri Seti

Beyin tümörlerinin teşhisinde kullanılan bu veri seti (Nickparvar, 2021), toplamda 7.023 beyin MRI görüntüsünden oluşmaktadır ve dört farklı sınıfa ayrılmıştır:

- Gliom: 1.321 eğitim, 300 test görüntüsü
- Hipofiz tümörü: 1.457 eğitim, 300 test görüntüsü
- Menenjiom: 1.339 eğitim, 306 test görüntüsü
- Tümör olmayan: 1.595 eğitim, 405 test görüntüsü

Beyin tümörleri veri seti, gliom, hipofiz tümörü, menenjiom gibi tümör türleri ile birlikte sağlıklı bireyleri içeren "tümör olmayan" sınıfını kapsamaktadır. Bu veri seti, beyin tümörlerinin doğru teşhisini ve sınıflandırılmasını sağlamak için kullanılmıştır. Aşağıda, bu sınıflara ait örnek beyin

MRI görüntüleri verilmiştir. Şekil 5.4, gliom, hipofiz tümörü, menenjiom ve tümör olmayan sınıfları temsil eden bu görüntüler, CBMDF-Net modelinin tümör ve sağlıklı bireyleri doğru sınıflandırmasını sağlamak için kritik öneme sahiptir.




Şekil 5.4. Beyin tümörlerine ait MRI görüntü örnekleri. A) gliom, b) hipofiz tümörü, c) menenjiom, d) tümör olmayan

5.1.4. Parkinson Hastalığı Veri Seti

Parkinson hastalığının teşhisine yönelik olan bu veri seti (Sheriff, 2021), toplamda 221 beyin MRI görüntüsünden oluşmaktadır. Bu veri setinde yer alan görüntüler Parkinson hastalarının teşhisinde kullanılmak üzere iki gruba ayrılmıştır:

- Eğitim verileri: 177 görüntü
- Test verileri: 44 görüntü

Bu veri seti, Parkinson hastalığı sınıfını temsil etmektedir ve diğer veri setleriyle birlikte çalışmanın sınıflandırma görevine önemli katkı sağlamıştır. Aşağıda, Parkinson hastalığını temsil eden bir örnek beyin MRI görüntüsü gösterilmiştir. Şekil 5.5, Parkinson hastalığını temsil eden bu görüntü, modelin Parkinson teşhisindeki doğruluğunu artıran örneklerden biridir.



Şekil 5.5. Parkinson hastalığına ait MRI görüntü örneği.

5.2. Ön İşleme Aşaması

Ön işleme aşaması, bu çalışmada kullanılan derin öğrenme modelinin başarısını doğrudan etkileyen kritik bir adımdır. Ham MRI beyin görüntüleri, doğası gereği çeşitli gürültüler ve farklılıklar

içerebilir; bu nedenle, bu görüntülerin doğru şekilde işlenip modele sunulması büyük önem taşır. Bu süreçte uygulanan veri işleme teknikleri sayesinde hem veri setinin çeşitliliği artırılmış hem de modelin genelleme yeteneği güçlendirilmiştir. Veri artırma ve işleme tekniklerinin yanı sıra, görüntü boyutlandırma gibi işlemler de modelin eğitim sürecinde hızlanma ve tutarlılık sağlamıştır. Ön işleme aşaması, modelin öğrenme sürecine katkı sağlayarak, daha geniş ve temsil gücü yüksek bir veri kümesi ile eğitim yapmasına olanak tanımıştır.

5.2.1. Görüntülerin Dönüştürülmesi

İlk olarak, ham beyin MRI görüntülerinin belirli bir yönlendirmeye bağlı kalmadan işlenebilmesi için çeşitli dönüşüm işlemleri uygulanmıştır. Saat yönünde 90 derece döndürme işlemi, görüntülerin farklı açılardan değerlendirilmesini sağlamıştır. Nörolojik hastalıkların teşhisinde, özellikle beyin anatomisinin çeşitli yönlerden incelenmesi büyük önem taşır. Örneğin, bir tümör veya lezyon farklı açılardan daha belirgin olabilir. Bu nedenle, döndürme işlemi ile veriler farklı perspektiflere taşınmış, böylece modelin her açıdan veri görebilme yeteneği artırılmıştır. Ayrıca, döndürme işlemi veri setinin sayısal olarak genişletilmesine de katkı sağlamıştır, çünkü her bir döndürme işlemi yeni bir veri örneği oluşturmuştur. Böylece, model aynı veriden türetilmiş farklı açılardaki örneklerle daha kapsamlı bir eğitim almıştır.

5.2.2. Yatay Simetri (Yansıtma)

Yansıtma işlemi, görüntülerin yatay ekseninde simetrik bir şekilde aynalanmasını içerir. Bu teknik, görüntü işleme alanında yaygın olarak kullanılan veri artırma yöntemlerinden biridir. Yatay simetri işlemi, beynin her iki yarımküresinde de benzer yapılar bulunabileceğinden, modelin simetrik yapıların tanınmasında başarısını artırır. Aynı zamanda bu işlem, veri setinin çeşitliliğini artırarak modelin veri çeşitliliği ile başa çıkma yeteneğini güçlendirir. Bu sayede, modelin farklı olası senaryolar karşısında dayanıklılığı artırılmış olur. Aynalanan görüntüler, orijinal görüntülerle birlikte modelin eğitimine dahil edilerek, modelin daha fazla veri ile beslenmesi sağlanmıştır.

5.2.3. Yatayda Rastgele Kaydırma

Yatayda rastgele kaydırma işlemi, beyin MRI görüntülerinin yatay ekseninde belirli bir miktarda kaydırılmasıyla gerçekleştirilmiştir. Bu işlem, modelin görüntüdeki nesnelere konumuna bağımlılığını azaltarak, veri setindeki küçük pozisyon değişikliklerine karşı daha sağlam hale getirilmesini sağlamıştır. Örneğin, bir tümör veya lezyonun farklı MRI çekimlerinde hafifçe yer değiştirmesi olasıdır; bu durumda modelin, bu yer değiştirmeyi bir anomali olarak algılamadan doğru teşhis yapabilmesi gerekir. Rastgele kaydırma işlemi, modelin bu tür pozisyonel değişikliklere karşı daha

dayanıklı hale gelmesine yardımcı olur ve öğrenme sürecinde yer değiştirme ile ilişkili hataları azaltır. Bu adım, modelin genel performansını artırarak, gerçek dünyadaki değişken koşullara karşı daha iyi bir performans sergilemesine olanak tanır.

5.2.4. Gaussian Dağılımlı Rastgele Gürültü Ekleme

Veri artırma tekniklerinden biri olan gürültü ekleme işlemi, görüntülerin doğal olmayan gürültülerle zenginleştirilmesi anlamına gelir. Bu çalışmada, Gaussian dağılımlı rastgele gürültü ekleme yöntemi kullanılmıştır. MRI görüntüleri, gerçek dünyada çekim koşullarına ve cihaz hassasiyetine bağlı olarak çeşitli gürültüler içerebilir. Gürültü ekleme işlemi, modelin bu tür doğal gürültülere karşı dayanıklılığını artırmak için gerçekleştirilmiştir. Bu teknik, modelin gerçek dünyadaki veri setlerinde karşılaşılabileceği gürültülü görüntülerde doğru teşhis yapabilme yeteneğini geliştirir. Gaussian dağılımlı gürültü eklenmesi, veri setine daha fazla rastgelelik katarak, modelin öğrenme sürecinde gürültüye dayalı önyargıları ortadan kaldırır ve daha sağlam bir öğrenme sağlar.

5.2.5. Parlaklık ve Kontrast Ayarı

Parlaklık ve kontrast ayarı, MRI görüntülerindeki aydınlatma koşullarını simüle etmek ve modelin bu tür değişken koşullara karşı adaptasyonunu sağlamak amacıyla uygulanmıştır. Farklı aydınlatma koşulları, görüntülerin parlaklığını ve kontrastını etkileyebilir ve bu durum, modelin doğru teşhis yapabilme yeteneğini sınırlayabilir. Bu nedenle, parlaklık ve kontrast ayarı yapılarak modelin, düşük veya yüksek parlaklık koşullarına karşı eğitim alması sağlanmıştır. Bu adım, özellikle hastane ortamlarında farklı cihazlar veya ışıklandırılmalar altında çekilen MRI görüntülerinin standart dışı aydınlatma koşullarına sahip olabileceği göz önünde bulundurularak, modelin genelleme yeteneğini artırmak amacıyla gerçekleştirilmiştir. Parlaklık ve kontrastın artırılması ya da azaltılmasıyla oluşturulan görüntüler, modelin farklı aydınlatma varyasyonlarına karşı sağlamlığını artırmıştır.

5.2.6. Görüntü Boyutlandırma

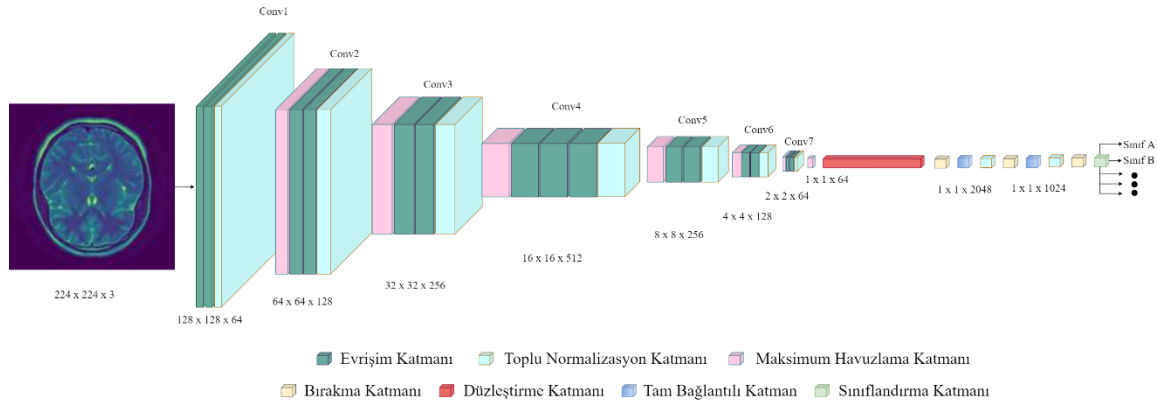
Ön işleme aşamasının bir diğer önemli adımı ise tüm görüntülerin boyutlandırılmasıdır. Modelin eğitimi sırasında, tüm görüntülerin belirli bir boyutta olması gerekmektedir. Bu nedenle, ham MRI görüntüleri belirlenen 224x224 piksel boyutlarına yeniden boyutlandırılmıştır. Bu işlem, görüntülerin modelin giriş formatına uygun hale getirilmesini sağlar. Ayrıca, görüntü boyutlandırma işlemi, modelin eğitim hızını artırarak büyük veri setlerinin işlenmesini kolaylaştırır. Tüm görüntülerin aynı boyutta olması, modelin farklı boyuttaki görüntüler üzerinde eğitilmesini gerektirmediği için hesaplama yükünü de azaltır.

5.2.7. Normalizasyon

Ön işleme aşamasının bir diğer kritik adımı, görüntülerin normalizasyonudur. Görüntüdeki piksellerin değerleri 0 ile 255 arasında değişir ve bu değerlerin 1/255 oranında ölçeklendirilmesi, yani normalizasyon işlemi, modelin daha stabil bir şekilde öğrenmesine katkı sağlar. Bu işlem sayesinde piksellerin değeri 0 ile 1 arasına çekilerek, modelin her pikseli eşit şekilde değerlendirmesi sağlanır. Normalizasyon, görüntülerin farklı parlaklık ve kontrast seviyelerinden kaynaklanan aşırı değişkenliği azaltır, böylece modelin öğrenme süreci hızlanır ve genelleme yeteneği artar.

5.3. Yöntem

Bu tez çalışmasında kullanılan CBMDF-Net modeli, giriş olarak 224×224 piksel boyutunda ve üç renk kanalına (RGB) sahip MRI beyin görüntülerini almaktadır. Modelin bu giriş yapısı, hem detaylı özellik çıkarma işlemleri için yeterli çözünürlüğü sağlamakta hem de eğitim sürecini hızlandırmak amacıyla uygun bir boyutlandırma sunmaktadır. Şekil 5.6, önerilen modelin mimarisinin görselleştirilmiş halini sunmaktadır. Modelin tasarımı, evrişimli sinir ağlarının (CNNs) gücünden faydalanarak, karmaşık özellikleri yakalayabilen derin öğrenme yapılarına dayanmaktadır. Bu mimari, beyin görüntülerindeki ince farkları algılayarak nörolojik hastalıkların doğru bir şekilde sınıflandırılmasını sağlar.



Şekil 5.6. Önerilen modelin mimarisini.

CBMDF-Net modeli, MRI beyin görüntülerindeki nörolojik hastalıkların sınıflandırılması amacıyla özelleştirilmiş bir CNN modelidir. Modelin adındaki kısaltmalar, yapısındaki önemli katman türlerini belirtmektedir: Evrişim (Convolutional), Toplu normalizasyon (Batch normalization), Maksimum havuzlama (Max pooling), Bırakma (Dropout) ve Tam bağlantılı (Fully connected) katmanlar. Modelin temel işleyişi, bu katmanların birbirini tamamlayarak özellik çıkarma ve öğrenme

işlemlerini gerçekleştirmesidir. Her bir katman, görüntüdeki önemli bilgileri belirleyip sonraki katmanlara aktararak modelin daha karmaşık yapısal özellikleri öğrenmesine olanak tanır.

İlk aşamada, evrişim katmanları görüntüden özellikler çıkararak öğrenme sürecini başlatır. Evrişim işlemi, giriş görüntüsüne filtreler (kernels) uygulayarak çeşitli boyutlardaki özelliklerin çıkarılmasını sağlar ve bu işlem aşağıdaki denklemle tanımlanır (Pacal, vd., 2020):

$$S(i,j) = (I * K)(x, y) = \sum_m \sum_n I(i + m, j + n) K(m, n) \quad (5.1)$$

Evrişim işlemi sonrasında, toplu normalizasyon katmanı devreye girer ve modelin öğrenme sürecini hızlandırarak istikrarını artırır. Bu katman, verilerin dağılımını normalleştirerek her katmandaki öğrenmeyi optimize eder. Toplu normalizasyon işlemi şu denklemlerle açıklanır (Ioffe ve Szegedy, 2015):

$$\hat{x}_i = \frac{x_i - \mu_\beta}{\sqrt{\sigma_\beta^2 + \epsilon}} \quad (5.2)$$

$$y_i = \gamma \cdot \hat{x}_i + \beta \quad (5.3)$$

Bu katmanın ardından, modelde uzamsal boyutları küçülterek önemli özellikleri ön plana çıkaran maksimum havuzlama katmanları yer alır. Maksimum havuzlama, daha büyük verilerde önemli bilgileri seçmek amacıyla kullanılır ve görüntünün boyutlarını küçülterek işlem maliyetini düşürür. Bu işlem aşağıdaki denklemle ifade edilir (Zafar, vd., 2022):

$$f_{max}(X) = \max(x_i) \quad (5.4)$$

Modelde yer alan bir diğer önemli bileşen, bırakma katmanıdır. Bu katman, aşırı öğrenmeyi (overfitting) engellemek amacıyla eğitim sırasında belirli nöronları rastgele kapatarak modelin genelleme yeteneğini artırır. Bu süreç, eğitim sırasında maskeli bir nöron kapatma işlemiyle gerçekleştirilir ve test aşamasında belirli bir olasılık oranında yeniden aktive edilir. Bu işlemler aşağıdaki gibi tanımlanır:

- Eğitim aşamasında:

$$Y_{dropout} = X \cdot \text{mask} \quad (5.5)$$

- Test aşamasında:

$$Y_{dropout} = X \cdot \frac{1}{1-p} \quad (5.6)$$

Bu süreçlerden sonra modelin öğrenme süreci, çıkarılan özelliklerin ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılarak etkinleştirilmesiyle devam eder. ReLU aktivasyonu, negatif girdileri sıfıra çekerken pozitif değerleri aynı şekilde bırakır ve modelin daha hızlı öğrenmesini sağlar. Son aşamada ise SoftMax aktivasyon fonksiyonu kullanılarak sınıflandırma gerçekleştirilir. SoftMax, her bir sınıf için olasılık skorları üreterek modelin sonuçları doğru sınıflandırmasını sağlar.

Tablo 5.1. Önerilen modelin özeti.

Katman (Tip)	1. Deneme		2. Deneme		3. Deneme	
	Çıkış Şekli	Parametre Sayısı	Çıkış Şekli	Parametre Sayısı	Çıkış Şekli	Parametre Sayısı
conv2d_1 (Conv2D)	(Yok, 224, 224, 64)	1792	(Yok, 224, 224, 64)	1792	(Yok, 224, 224, 64)	1792
conv2d_2 (Conv2D)	(Yok, 224, 224, 64)	36928	(Yok, 224, 224, 64)	36928	(Yok, 224, 224, 64)	36928
batch_normalization_1	(Yok, 224, 224, 64)	256	(Yok, 224, 224, 64)	256	(Yok, 224, 224, 64)	256
max_pooling2d_1 (MaxPooling2D)	(Yok, 112, 112, 64)	0	(Yok, 112, 112, 64)	0	(Yok, 112, 112, 64)	0
conv2d_3 (Conv2D)	(Yok, 112, 112, 128)	73856	(Yok, 112, 112, 128)	73856	(Yok, 112, 112, 128)	73856
conv2d_4 (Conv2D)	(Yok, 112, 112, 128)	147584	(Yok, 112, 112, 128)	147584	(Yok, 112, 112, 128)	147584
batch_normalization_2	(Yok, 112, 112, 128)	512	(Yok, 112, 112, 128)	512	(Yok, 112, 112, 128)	512
max_pooling2d_2 (MaxPooling2D)	(Yok, 56, 56, 128)	0	(Yok, 56, 56, 128)	0	(Yok, 56, 56, 128)	0
conv2d_5 (Conv2D)	(Yok, 56, 56, 256)	295168	(Yok, 56, 56, 256)	295168	(Yok, 56, 56, 256)	295168
conv2d_6 (Conv2D)	(Yok, 56, 56, 256)	590080	(Yok, 56, 56, 256)	590080	(Yok, 56, 56, 256)	590080
batch_normalization_3	(Yok, 56, 56, 256)	1024	(Yok, 56, 56, 256)	1024	(Yok, 56, 56, 256)	1024
max_pooling2d_3 (MaxPooling2D)	(Yok, 28, 28, 256)	0	(Yok, 28, 28, 256)	0	(Yok, 28, 28, 256)	0
conv2d_7 (Conv2D)	(Yok, 28, 28, 512)	1180160	(Yok, 28, 28, 512)	1180160	(Yok, 28, 28, 512)	1180160
conv2d_8 (Conv2D)	(Yok, 28, 28, 512)	2359808	(Yok, 28, 28, 512)	2359808	(Yok, 28, 28, 512)	2359808
conv2d_9 (Conv2D)	(Yok, 28, 28, 512)	2359808	(Yok, 28, 28, 512)	2359808	(Yok, 28, 28, 512)	2359808
batch_normalization_4	(Yok, 28, 28, 512)	2048	(Yok, 28, 28, 512)	2048	(Yok, 28, 28, 512)	2048
max_pooling2d_4 (MaxPooling2D)	(Yok, 14, 14, 512)	0	(Yok, 14, 14, 512)	0	(Yok, 14, 14, 512)	0

Katman (Tip)	1. Deneme		2. Deneme		3. Deneme	
	Çıkış Şekli	Parametre Sayısı	Çıkış Şekli	Parametre Sayısı	Çıkış Şekli	Parametre Sayısı
conv2d_10 (Conv2D)	(Yok, 14, 14, 256)	1179904	(Yok, 14, 14, 256)	1179904	(Yok, 14, 14, 256)	1179904
conv2d_11 (Conv2D)	(Yok, 14, 14, 256)	590080	(Yok, 14, 14, 256)	590080	(Yok, 14, 14, 256)	590080
batch_normalization_5	(Yok, 14, 14, 256)	1024	(Yok, 14, 14, 256)	1024	(Yok, 14, 14, 256)	1024
max_pooling2d_5 (MaxPooling2D)	(Yok, 7, 7, 256)	0	(Yok, 7, 7, 256)	0	(Yok, 7, 7, 256)	0
conv2d_12 (Conv2D)	(Yok, 7, 7, 128)	295040	(Yok, 7, 7, 128)	295040	(Yok, 7, 7, 128)	295040
conv2d_13 (Conv2D)	(Yok, 7, 7, 128)	147584	(Yok, 7, 7, 128)	147584	(Yok, 7, 7, 128)	147584
batch_normalization_6	(Yok, 7, 7, 128)	512	(Yok, 7, 7, 128)	512	(Yok, 7, 7, 128)	512
max_pooling2d_6 (MaxPooling2D)	(Yok, 3, 3, 128)	0	(Yok, 3, 3, 128)	0	(Yok, 3, 3, 128)	0
conv2d_14 (Conv2D)	(Yok, 3, 3, 64)	73792	(Yok, 3, 3, 64)	73792	(Yok, 3, 3, 64)	73792
conv2d_15 (Conv2D)	(Yok, 3, 3, 64)	36928	(Yok, 3, 3, 64)	36928	(Yok, 3, 3, 64)	36928
batch_normalization_7	(Yok, 3, 3, 64)	256	(Yok, 3, 3, 64)	256	(Yok, 3, 3, 64)	256
max_pooling2d_7 (MaxPooling2D)	(Yok, 1, 1, 64)	0	(Yok, 1, 1, 64)	0	(Yok, 1, 1, 64)	0
flatten_1 (Flatten)	(Yok, 64)	0	(Yok, 64)	0	(Yok, 64)	0
dropout_1 (Dropout)	(Yok, 64)	0	(Yok, 64)	0	(Yok, 64)	0
dense_1 (Dense)	(Yok, 2048)	133120	(Yok, 2048)	133120	(Yok, 2048)	133120
batch_normalization_8	(Yok, 2048)	8192	(Yok, 2048)	8192	(Yok, 2048)	8192
dropout_2 (Dropout)	(Yok, 2048)	0	(Yok, 2048)	0	(Yok, 2048)	0
dense_2 (Dense)	(Yok, 1024)	2098176	(Yok, 1024)	2098176	(Yok, 1024)	2098176
batch_normalization_9	(Yok, 1024)	4096	(Yok, 1024)	4096	(Yok, 1024)	4096
dropout_3 (Dropout)	(Yok, 1024)	0	(Yok, 1024)	0	(Yok, 1024)	0
dense_3 (Dense)	(Yok, 5)	5125	(Yok, 9)	9225	(Yok, 4)	4100

Modelin eğitimi, Adam optimizasyon algoritması ve kategorik çapraz-entropi (categorical cross-entropy) kayıp fonksiyonu ile gerçekleştirilmiştir. Bu optimizasyon algoritması, öğrenme sürecini hızlandıran ve parametre güncellemelerini optimize eden popüler bir tekniktir. Model, 0.0001 öğrenme oranıyla 100 devir boyunca eğitilmiştir. Eğitim süreci sonucunda model, test veri setleri üzerinde gerçekleştirilen farklı denemeler boyunca tutarlı ve yüksek doğruluk oranları elde etmiştir.

CBMDF-Net modeli, toplamda 38 katmandan oluşmakta ve yaklaşık 11.6 milyon parametre barındırmaktadır. Bu kapsamlı yapı, MRI beyin görüntülerinde nörolojik hastalıkları tespit etme

konusunda güçlü ve etkili bir model oluşturmakta, sonuç olarak hastalıkların yüksek doğrulukla sınıflandırılmasını sağlamaktadır.

5.4. Sınıflandırma Görevleri

Bu çalışmada, CBMDF-Net modeli ile nörolojik hastalıkların sınıflandırılmasına yönelik üç farklı deney yapılmış ve her bir deneyde farklı veri alt kategorileri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Deneyler, modelin nörolojik hastalıkları ve sağlıklı bireyleri ayırt edebilme yeteneğini test etmek amacıyla tasarlanmıştır. Her bir denemenin detayları ve kullanılan veri setlerinin büyüklükleri ayrı ayrı açıklanmaktadır.

5.4.1. Nörolojik Bozukluklar ve Sağlıklı Bireylerin Sınıflandırılması

Bu denemede beş sınıf üzerinden sınıflandırma yapılmıştır: akut iskemik inme, Alzheimer (alt grupları olan çok hafif demans, hafif demans ve orta dereceli demans birleştirilmiştir), beyin tümörleri (alt grupları olan gliom, hipofiz tümörü ve menenjiom birleştirilmiştir), Parkinson hastalığı ve sağlıklı bireyler (normal). Normal kategorisi, Alzheimer'ın alt grubu olan demans olmayan ve beyin tümörleri kategorisinin alt grubu olan tümör olmayan sınıflarının birleşiminden oluşturulmuştur. Tablo 5.2'de, 1. denemede kullanılan ham ve arttırılmış veri setlerinin eğitim ve test için ayrıldığı dağılımlar gösterilmiştir.

Tablo 5.2. Ham ve arttırılmış verilerle eğitim ve test seti dağılımı (1. deneme).

Sınıflar	Ham Eğitim	Ham Test	Arttırılmış Eğitim	Arttırılmış Test
Akut iskemik inme	1,002	1,008	38400	5225
Alzheimer	2561	639	38400	5225
Beyin tümörleri	4117	906	38400	5225
Parkinson	177	44	38400	5225
Normal	4,155	1,045	38400	5225

5.4.2. Nörolojik Bozuklukların Alt Sınıfları Üzerine Sınıflandırma

İkinci denemede, daha detaylı bir sınıflandırma yapılmıştır. Bu denemede, nörolojik hastalıkların alt grupları olan akut iskemik inme, çok hafif demans, hafif demans, orta dereceli demans, gliom, hipofiz tümörü, menenjiom, Parkinson hastalığı ve normal (demans olmayan ve tümör olmayan birleştirilmiş sınıflar) olmak üzere toplam dokuz sınıf üzerinden sınıflandırma yapılmıştır. Tablo 5.3'te, 2. denemede kullanılan ham ve arttırılmış veri setlerinin eğitim ve test için ayrıldığı dağılımlar verilmiştir.

Tablo 5.3. Ham ve arttırılmış verilerle eğitim ve test seti dağılımı (2. deneme).

Sınıflar	Ham Eğitim	Ham Test	Arttırılmış Eğitim	Arttırılmış Test
Akut iskemik inme	1,002	1,008	20775	5225
Çok hafif demans	1,792	448	20775	5225
Hafif demans	717	179	20775	5225
Orta dereceli demans	52	12	20775	5225
Gliom	1,321	300	20775	5225
Hipofiz tümörü	1,457	300	20775	5225
Menenjiom	1,339	306	20775	5225
Parkinson	177	44	20775	5225
Normal	4,155	1,045	20775	5225

5.4.3. Alzheimer ve Beyin Tümörlerinin Çoklu Sınıflandırılması

Bu deneme iki farklı analiz üzerinde gerçekleştirilmiştir. İlk analizde, beyin tümörlerinin alt grupları olan gliom, hipofiz tümörü, menenjiom ve tümör olmayan sınıfları üzerinden sınıflandırma yapılmıştır. İkinci analizde ise Alzheimer'ın alt grupları olan çok hafif demans, hafif demans, orta dereceli demans ve demans olmayan sınıfları çoklu sınıflandırma işlemiyle değerlendirilmiştir. Tablo 5.4'te beyin tümörlerinin alt gruplarına ait ham ve arttırılmış veri setleri yer almakta olup, tablo 5.5'te Alzheimer alt sınıfları için veri dağılımı gösterilmiştir.

Tablo 5.4. Ham ve arttırılmış verilerle eğitim ve test seti dağılımı (3. deneme, beyin tümörleri).

Sınıflar	Ham Eğitim	Ham Test	Arttırılmış Eğitim	Arttırılmış Test
Gliom	1,321	300	7975	2025
Hipofiz tümörü	1,457	300	7975	2025
Menenjiom	1,339	306	7975	2025
Tümör olmayan	1,595	405	7975	2025

Tablo 5.5. Ham ve arttırılmış verilerle eğitim ve test seti dağılımı (3. deneme, Alzheimer).

Sınıflar	Ham Eğitim	Ham Test	Arttırılmış Eğitim	Arttırılmış Test
Çok hafif demans	1,792	448	32000	3200
Hafif demans	717	179	32000	3200
Orta dereceli demans	52	12	32000	3200
Demans olmayan	2,560	640	32000	3200

6. BULGULAR ve TARTIŞMA

Bu tez çalışmasında, derin öğrenme tabanlı bir model olan CBMDF-Net'in nörolojik hastalıkların sınıflandırılmasındaki performansı, dört farklı MRI veri seti kullanılarak kapsamlı bir şekilde değerlendirilmiştir. Bu veri setleri, Akut İskemik İnme, Alzheimer hastalığı, Beyin Tümörleri ve Parkinson hastalığı gibi çeşitli nörolojik bozuklukları içermektedir ve Kaggle platformundan elde edilmiştir. Deneyler, NVIDIA GeForce GTX 1660 Ti GPU ve 16 GB DDR4 RAM ile donatılmış bir bilgisayar üzerinde gerçekleştirilmiştir. Eğitim sürecinde Python tabanlı Keres kütüphanesi kullanılmış ve optimizasyon amacıyla 'Adam' algoritması tercih edilmiştir. Kayıp fonksiyonu olarak çok sınıflı çapraz entropi seçilmiştir. Modelin performansı doğruluk, kesinlik, duyarlılık ve F1 skoru gibi yaygın kullanılan metrikler üzerinden değerlendirilmiştir.

6.1. Performans Metrikleri

Performans metrikleri, bir modelin başarısını değerlendirmek için kullanılan önemli araçlardır. Bu metrikler, sınıflandırma problemlerinde modelin doğruluğunu, güvenilirliğini ve etkinliğini ölçmek için kullanılır. Aşağıda, derin öğrenme tabanlı CBMDF-Net modelinin performansını değerlendirmek için kullanılan başlıca metrikler detaylandırılmıştır.

6.1.1. Doğruluk (Accuracy)

Doğruluk, doğru sınıflandırılan örneklerin toplam örneklere oranını ifade eder. Aşağıdaki formül ile hesaplanır:

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (6.1)$$

Doğru pozitif (TP), modelin doğru bir şekilde pozitif olarak sınıflandırdığı örnek sayısını ifade ederken, doğru negatif (TN), modelin yanlış bir şekilde negatif olarak sınıflandırdığı örnek sayısını belirtir. Yanlış pozitif (FP), modelin yanlış bir şekilde pozitif olarak sınıflandırdığı örneklerin sayısını gösterirken, yanlış negatif (FN), modelin yanlış bir şekilde negatif olarak sınıflandırdığı örnek sayısını ifade eder. Bu dört metrik, bir modelin sınıflandırma performansını değerlendirmek için kritik öneme sahiptir ve modelin başarı düzeyini anlamak için bir arada kullanılır.

6.1.2. Kesinlik (Precision)

Kesinlik, modelin pozitif olarak sınıflandırdığı örneklerden ne kadarının gerçekten pozitif olduğunu gösterir. Aşağıdaki formül ile hesaplanır:

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (6.2)$$

Bu metrik, yanlış pozitif oranını azaltmak ve modelin pozitif tahminlerinin güvenilirliğini artırmak için önemlidir.

6.1.3. Duyarlılık (Recall)

Duyarlılık, gerçek pozitif örneklerin ne kadarının model tarafından doğru bir şekilde sınıflandırıldığını gösterir. Hesaplama şu şekildedir:

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (6.3)$$

Duyarlılık, modelin pozitif örnekleri tespit etme yeteneğini ölçer ve genellikle 'hastalık tespiti' gibi durumlarda önemlidir.

6.1.4. F1 Skoru (F1 Score)

F1 skoru, kesinlik ve duyarlılığı birleştirerek tek bir performans metriği sağlar. Aşağıdaki formül ile hesaplanır:

$$\text{F1 skoru} = 2 \cdot \frac{\text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (6.4)$$

F1 skoru, dengesiz veri setlerinde modelin genel performansını daha iyi bir şekilde temsil eder.

6.1.5. ROC Eğrisi ve AUC

Alıcı işletim karakteristiği (ROC) eğrisi, modelin farklı eşik değerlerinde pozitif ve negatif sınıflandırma oranlarını gösterir. Eğrinin altındaki alan (AUC), bu eğrinin altındaki alanı temsil eder ve modelin genel sınıflandırma performansını ölçmek için kullanılır. AUC değeri 0 ile 1 arasında değişir; 1 mükemmel bir modeli, 0.5 ise rastgele tahminleri temsil eder.


6.2. Deneysel Analiz

Bu çalışmada, MRI beyin görüntülerini kullanarak nörolojik hastalıkların sınıflandırılmasında önerilen CBMDF-Net modelinin performansı üç farklı deneme ile değerlendirilmiştir. Denemeler, genel nörolojik bozuklukların sınıflandırılması, alt sınıfların detaylı olarak incelenmesi ve Alzheimer

ile beyin tümörlerinin çoklu sınıflandırılması üzerine odaklanmıştır. Her bir deneme, belirli hastalık gruplarının sınıflandırılması için modelin etkinliğini ve doğruluğunu incelemek amacıyla farklı veri setleri üzerinde gerçekleştirilmiştir. Aşağıda her bir denemenin ayrıntıları sunulmuştur.

6.2.1. Genel Nörolojik Bozukluklar Sınıflandırma Denemesi

Bu deneyde, modelimiz beş sınıf üzerinden sınıflandırma gerçekleştirmiştir: akut iskemik inme, Alzheimer, beyin tümörleri, Parkinson hastalığı ve sağlıklı bireyler. Modelin bu sınıflandırmayı yapabilmesi için kullanılan veri setleri, her bir sınıf için yeterli sayıda örnek içermekte olup, bu durum modelin genelleme yeteneğini artırmaktadır. Test veri seti üzerinde elde edilen %98.82 doğruluk oranı, modelin sınıflandırma görevini yüksek bir başarıyla yerine getirdiğini göstermektedir. Bu yüksek doğruluk, modelin, özellikle nörolojik bozuklukların ve sağlıklı bireylerin ayırt edilmesinde etkili bir şekilde çalıştığını ortaya koymaktadır.



Şekil 6.1. Önerilen modele ait karışıklık matrisi (1. deneme)

Şekil 6.1'de görüldüğü üzere, CBMDF-Net modelinin sınıflandırma performansı kapsamlı bir şekilde analiz edilmiştir. Model, akut iskemik inme sınıfında 5,100 vakayı doğru sınıflandırırken, 11 Alzheimer, 30 normal ve 84 Parkinson vakasını yanlış sınıflandırmıştır. Alzheimer sınıfında 5,174


vaka doğru sınıflandırılmış ve sadece 51 vaka normal olarak yanlış tanımlanmıştır. Beyin tümörleri için 5,215 vaka doğru sınıflandırılmış, yanlış sınıflamalar arasında 5 akut iskemik inme, 2 Alzheimer ve 3 normal vaka yer almıştır. Normal sınıfında model 5,177 vakayı doğru tanımlamış, ancak 44 Alzheimer ve 4 Parkinson vakasını yanlış sınıflandırmıştır. Parkinson sınıfında ise 5,152 vaka doğru tespit edilmiş, 2 akut iskemik inme ve 71 normal vaka yanlış sınıflanmıştır. Bu sonuçlar, CBMDF-Net modelinin nörolojik hastalıkları ve sağlıklı bireyleri ayırt etme konusunda yüksek bir başarıya sahip olduğunu göstermektedir.

Tablo 6.1, önerilen CBMDF-Net modelinin genel nörolojik bozuklukların üzerine yapılan sınıflandırma denemesinde elde ettiği genel performansı sunmaktadır. Performans tablosuna göre, modelin genel doğruluk oranı %99, kesinlik oranı %99, duyarlılık oranı %99 ve F1 skoru %99 olarak belirlenmiştir. Bu sonuçlar, modelin nörolojik bozuklukları doğru bir şekilde sınıflandırma konusunda yüksek bir başarı gösterdiğini ortaya koymaktadır.


Tablo 6.1. Model performans değerleri (1.deneme)

Sınıf	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
Akut iskemik inme	0.98	1.00	0.98	0.99
Alzheimer	0.99	0.99	0.99	0.99
Beyin tümörleri	1.00	1.00	1.00	1.00
Normal	0.99	0.97	0.99	0.98
Parkinson	0.99	0.98	0.99	0.98
Makro Ortalama	0.99	0.99	0.99	0.99
Ağırlıklı Ortalama	0.99	0.99	0.99	0.99

Şekil 6.2'deki doğruluk eğrileri, CBMDF-Net modelinin genel nörolojik bozuklukları sınıflandırma denemesinde eğitim ve test süreçlerindeki doğruluk seviyesinin zamanla nasıl geliştiğini göstermektedir. Şekil 6.3'teki kayıp eğrileri, modelin eğitim ve test verilerindeki kayıpların zamanla nasıl değiştiğini göstermektedir. Eğitim kaybı eğrisinin hızlı bir şekilde azaldığı ve stabil bir seviyeye ulaştığı, test kaybının ise daha dalgalı bir seyir izlediği, ancak genel olarak düşük seviyelerde kaldığı gözlemlenmektedir. Özellikle test kaybında 80. devirden sonra belirgin bir artış görülse de, modelin performansı genel olarak etkileyici düzeydedir. Modelin eğri altındaki alan (AUC) değeri %99.69 ve kayıp oranı %8.46 olarak hesaplanmıştır. Bu sonuçlar, modelin nörolojik hastalıkların sınıflandırılmasında yüksek doğruluk ve güvenilirlik sunduğunu göstermektedir.



Şekil 6.2. Önerilen modelin doğruluk grafiği (1. deneme)




Şekil 6.3. Önerilen modelin kayıp grafiği (1. deneme)

6.2.2. Nörolojik Bozuklukların Alt Sınıfları Üzerine Sınıflandırma Denemesi

Bu deneyde, daha önce yalnızca genel nörolojik bozukluklar dikkate alınırken, şimdi çok daha spesifik alt gruplar olan çok hafif demans, hafif demans, orta dereceli demans, gliom, hipofiz tümörü ve menenjiom ile birlikte akut iskemik inme, Parkinson hastalığı ve normal sınıfları üzerinde detaylı bir sınıflandırma gerçekleştirilmiştir. Bu yaklaşım, modelin karmaşık ve çeşitli veri setleri üzerindeki etkinliğini test etmek amacıyla uygulanmıştır. Alt sınıfların eklenmesi, modelin daha ince ayrımlar yapabilmesini sağlarken, bu ayrımların klinik önemini de vurgulamaktadır. Modelin %98.31 doğruluk

oranına ulaşması, sınıflandırma yeteneğinin yüksek olduğunu gösterirken, aynı zamanda daha karmaşık sınıflandırma sorunlarını çözme yeteneğinin de bir göstergesidir.



Şekil 6.4. Önerilen modele ait karışıklık matrisi (2. deneme)

Şekil 6.4'te görüldüğü üzere, CBMDF-Net modelinin performansı, çeşitli nörolojik hastalıkların sınıflandırılması konusunda etkileyici bir başarı sergilemiştir. Akut iskemik inme, çok hafif demans, gliom, hafif demans, hipofiz tümörü, menenjiom, orta dereceli demans ve Parkinson gibi hastalıklarda model yüksek doğruluk oranlarına ulaşmıştır. Örneğin, akut iskemik inme vakalarında model 5,132 vakayı doğru sınıflandırmış, yalnızca birkaçını yanlış etiketlemiştir. Benzer şekilde, orta dereceli demans ve Parkinson hastalıkları neredeyse hatasız sınıflandırılmıştır. Model, demans ve tümör gibi nörolojik bozukluklarda da yüksek başarı oranları sergileyerek, sağlıklı beyin durumunu tanımda %99'dan fazla doğruluk sağlamıştır. Genel olarak, model özellikle akut iskemik inme, orta dereceli demans ve Parkinson hastalıklarını doğru bir şekilde ayırt etmekte güçlü performans gösterirken, diğer nörolojik hastalıkları da büyük ölçüde başarılı bir şekilde sınıflandırmıştır.


Tablo 6.2, nörolojik bozuklukların alt sınıfları üzerine yapılan sınıflandırma denemesinde önerilen CBMDF-Net modelinin genel performansını sunmaktadır. Performans tablosuna göre,

modelin alt sınıfları ayırt etme yeteneği oldukça yüksektir; genel doğruluk oranı %98, genel kesinlik oranı %98, genel duyarlılık oranı %98 ve genel F1 skoru %98 olarak belirlenmiştir. Bu sonuçlar, modelin alt sınıfları doğru bir şekilde sınıflandırmada oldukça başarılı olduğunu göstermektedir.


Tablo 6.2. Model performans değerleri (2.deneme)

Sınıf	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
Akut iskemik inme	0.98	0.99	0.98	0.98
Çok hafif demans	0.96	0.98	0.96	0.97
Gliom	0.96	1.00	0.96	0.98
Hafif demans	0.98	0.99	0.98	0.99
Hipofiz tümörü	1.00	0.99	1.00	0.99
Menenjiom	0.98	0.97	0.98	0.98
Normal	1.00	0.94	1.00	0.97
Orta dereceli demans	1.00	1.00	1.00	1.00
Parkinson	0.99	0.99	0.99	0.99
Makro Ortalama	0.98	0.98	0.98	0.98
Ağırlıklı Ortalama	0.98	0.98	0.98	0.98

Şekil 6.5'teki doğruluk eğrileri, nörolojik bozuklukların alt sınıfları üzerine yapılan sınıflandırma denemesinde CBMDF-Net modelinin eğitim ve test süreçlerindeki doğruluk seviyesinin zamanla nasıl geliştiğini göstermektedir. Şekil 6.6'daki kayıp eğrileri ise, modelin eğitim ve test verilerindeki kayıpların zamanla azalarak stabil hale geldiğini ortaya koymaktadır. Ayrıca, AUC değeri %99.53 ve kayıp oranı %11.17 olarak hesaplanmıştır. Bu bulgular, modelin alt sınıfları sınıflandırmada güvenilirliği ve doğruluğu hakkında önemli veriler sunmaktadır.



Şekil 6.5. Önerilen modelin doğruluk grafiği (2. deneme)



Şekil 6.6. Önerilen modelin kayıp grafiği (2. deneme)


6.2.3. Alzheimer ve Beyin Tümörlerinin Çoklu Sınıflandırma Denemesi

Bu deney, beyin tümörleri ve Alzheimer hastalığının farklı alt gruplarını sınıflandırmak amacıyla iki ayrı analiz kapsamında gerçekleştirilmiştir. İlk analiz, beyin tümörlerini alt gruplarına ayırarak (gliom, hipofiz tümörü, menenjiom ve tümör olmayan) bu grupların sınıflandırılmasını hedeflemiş, ikinci analiz ise Alzheimer hastalığının evreleri (çok hafif demans, hafif demans, orta dereceli demans ve demans olmayan) arasında sınıflandırma yapmayı amaçlamıştır. Her iki analiz de, yalnızca hastalığın genel teşhisini yapmakla kalmayıp, hastalığın farklı alt gruplarını doğru bir şekilde ayırt edebilme becerisini değerlendirerek, tanının hassasiyetini artırmayı amaçlamaktadır. Bu tür bir detaylı sınıflandırma, klinik açıdan büyük önem taşır, zira her bir hastalık evresinin veya alt grubunun, tedavi süreci ve hastanın prognozu üzerinde farklı etkileri bulunmaktadır. Dolayısıyla, doğru sınıflandırma, hastalığın evresine veya türüne uygun tedavi yaklaşımlarını belirlemek açısından kritik bir rol oynamaktadır.

6.2.3.1. Beyin Tümörleri Analizi

Beyin tümörlerinin sınıflandırılması amacıyla yapılan analiz, modelin gliom, hipofiz tümörü, menenjiom ve tümör olmayan gruplar arasında doğru sınıflandırma yapma yeteneğini değerlendirmiştir. Analiz sonucunda elde edilen %99.23 doğruluk oranı, modelin beyin tümörlerini ayırt etme konusundaki üstün başarısını açıkça ortaya koymaktadır. Bu yüksek doğruluk oranı, modelin tümör türleri arasındaki ince farkları doğru bir şekilde tespit edebildiğini göstermektedir. Beyin tümörlerinin farklı alt gruplarının sınıflandırılması, doğru tedavi planlarının belirlenmesi

açısından önemlidir. Örneğin, gliom ve menenjiom gibi farklı tümör türleri hem biyolojik yapı hem de tedaviye verdikleri yanıtlar bakımından büyük farklılıklar göstermektedir. Dolayısıyla, bu alt grupları doğru bir şekilde ayırt edebilmek hem cerrahi müdahale planlarının hem de medikal tedavi yaklaşımlarının hastaya özgü olarak belirlenmesini mümkün kılmaktadır. Modelin elde ettiği yüksek başarı, klinik uygulamalarda beyin tümörlerinin doğru teşhisine katkı sağlayacak potansiyelde olduğunu göstermektedir.



Şekil 6.7. Önerilen modele ait karışıklık matrisi (3. deneme, beyin tümörleri)

Şekil 6.7'de görüldüğü üzere, CBMDF-Net modelinin beyin tümörlerinin alt gruplarını sınıflandırma performansı dikkat çekici bir başarı göstermiştir. Gliom sınıfında model, 1,993 vakayı doğru sınıflandırmış, ancak 2 hipofiz tümörü ve 30 menenjiom vakayı yanlış sınıflandırmıştır. Hipofiz tümörü sınıfında ise model 2,012 vakayı doğru bir şekilde sınıflandırmış, ancak 2 gliom, 8 menenjiom ve 3 tümör olmayan vakada hatalar yapmıştır. Menenjiom sınıfında, 2,008 vaka doğru sınıflandırılmış olup, 8 gliom, 5 hipofiz tümörü ve 4 tümör olmayan vaka yanlış sınıflandırılmıştır. Tümör olmayan sınıfında ise model, tüm vakaları (%100 doğrulukla) doğru şekilde tespit etmiştir ve bu sınıfta hiç yanlış sınıflandırma yapmamıştır. Bu sonuçlar, CBMDF-Net'in beyin tümörlerinin alt gruplarını ayırt etme konusunda oldukça başarılı olduğunu ve özellikle tümör olmayan vakaları %100 doğrulukla tespit ederek modelin yüksek hassasiyetini ortaya koyduğunu göstermektedir.

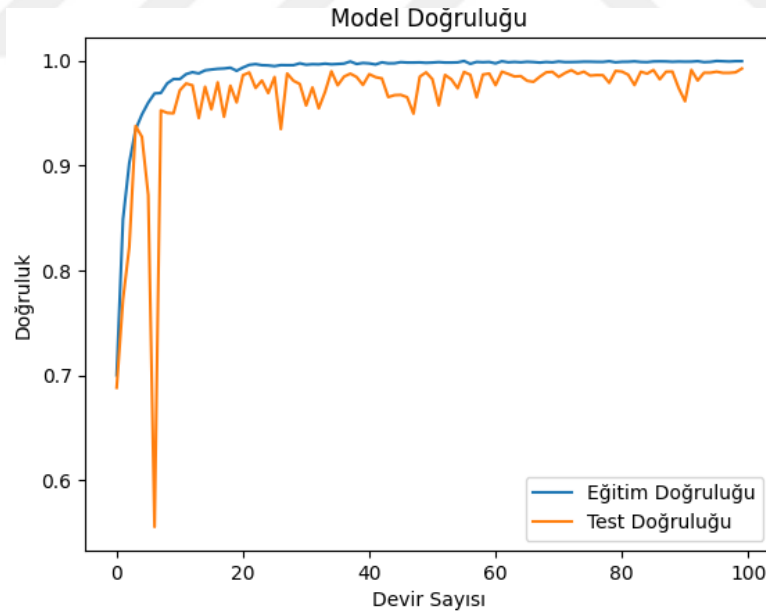
Tablo 6.3, beyin tümörlerinin alt gruplarına yönelik yapılan sınıflandırma deneyinde CBMDF-Net modelinin genel performansını sunmaktadır. Performans tablosuna göre, modelin beyin tümörlerinin alt sınıflarını ayırt etme yeteneği oldukça yüksektir; genel doğruluk oranı %99, genel kesinlik oranı %99, genel duyarlılık oranı %99 ve genel F1 skoru %99 olarak elde edilmiştir. Bu

sonuçlar, CBMDF-Net modelinin beyin tümörlerinin alt gruplarını doğru bir şekilde sınıflandırmada son derece başarılı olduğunu, özellikle her bir sınıfı yüksek hassasiyet ve doğrulukla ayırt edebildiğini göstermektedir.


Tablo 6.3. Model performans değerleri (3.deneme, beyin tümörleri)

Sınıf	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
Gliom	0.98	1.00	0.98	0.99
Hipofiz tümörü	0.99	1.00	0.99	1.00
Menenjiom	0.99	0.98	0.99	0.99
Tümör olmayan	1.00	1.00	1.00	1.00
Makro Ortalama	0.99	0.99	0.99	0.99
Ağırlıklı Ortalama	0.99	0.99	0.99	0.99

Şekil 6.8'deki doğruluk eğrileri, beyin tümörlerinin alt sınıfları üzerine yapılan sınıflandırma denemesinde CBMDF-Net modelinin eğitim ve test süreçlerindeki doğruluk seviyesinin zamanla nasıl geliştiğini göstermektedir. Şekil 6.9'daki kayıp eğrileri ise, modelin eğitim ve test verilerindeki kayıpların zamanla azalarak stabil hale geldiğini ortaya koymaktadır. Modelin AUC değeri %99.65 ve kayıp oranı %4.89 olarak hesaplanmıştır. Bu sonuçlar, modelin beyin tümörlerinin alt sınıflarını yüksek doğruluk ve güvenilirlikle sınıflandırabildiğini net bir şekilde ortaya koymaktadır.




Şekil 6.8. Önerilen modelin doğruluk grafiği (3. deneme, beyin tümörleri)



Şekil 6.9. Önerilen modelin kayıp grafiği (3. deneme, beyin tümörleri)

6.2.3.2. Alzheimer Analizi

Alzheimer hastalığının alt evrelerinin sınıflandırılmasına yönelik yapılan analizde model, çok hafif demans, hafif demans, orta dereceli demans ve demans olmayan sınıfları başarıyla ayırt edebilmiştir. Bu sınıflandırma sonucunda elde edilen %99.52 doğruluk oranı, modelin Alzheimer hastalığının evrelerini yüksek bir hassasiyetle tanıyabildiğini göstermektedir. Alzheimer hastalığının farklı evrelerinin doğru bir şekilde sınıflandırılması, hastalığın ilerleyişini daha iyi anlamak ve uygun tedavi yaklaşımlarını geliştirmek açısından kritik önem taşımaktadır. Çok hafif demans evresinde olan bir hasta, erken tanı sayesinde daha uzun süre bağımsız yaşamını sürdürebilirken, orta dereceli demans evresindeki bir hasta için daha yoğun bir bakım ve müdahale gerekebilir. Dolayısıyla, modelin bu evreleri doğru bir şekilde ayırt etmesi, klinik süreçlerdeki karar mekanizmalarının etkinliğini artırabilir. Modelin elde ettiği yüksek doğruluk oranı, özellikle Alzheimer hastalığının erken evrelerinde doğru teşhis yapılmasının hastalığın ilerleyişini yavaşlatmaya yönelik tedavi süreçlerinde önemli bir katkı sağlayabileceğini göstermektedir. Bu doğrultuda, CBMDF-Net modelinin Alzheimer hastalığının farklı evrelerini başarılı bir şekilde ayırt etme becerisi, klinik uygulamalarda hastalığın yönetimi açısından büyük bir potansiyel sunmaktadır.



Şekil 6.10. Önerilen modele ait karışıklık matrisi (3. deneme, Alzheimer)

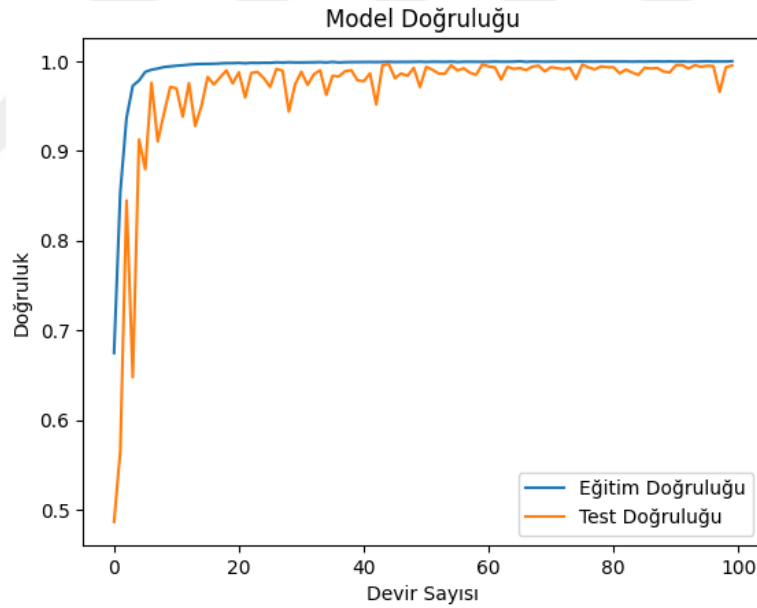
Çalışmada, Şekil 6.10'da görüldüğü üzere, Alzheimer hastalığının evrelerine yönelik yapılan sınıflandırma deneyinde CBMDF-Net modelinin performansı oldukça yüksektir. Model, çok hafif demans evresinde 3,168 vakayı doğru şekilde sınıflandırmış; ancak 5 hafif demans ve 27 demans olmayan vakayı yanlış tanımlamıştır. Demans olmayan sınıfta ise model, 3,192 vakayı doğru sınıflandırırken, 6 çok hafif demans ve 2 hafif demans vakasını yanlış tanımlamıştır. Hafif demans evresinde model, 3,178 vakayı doğru sınıflandırmış, fakat 17 çok hafif demans ve 5 demans olmayan vakayı yanlış tanımlamıştır. Orta dereceli demans evresinde ise model, %100 doğrulukla 3,200 vakayı doğru bir şekilde tanımlamış ve hiçbir yanlış sınıflandırma yapmamıştır. Bu sonuçlar, CBMDF-Net modelinin Alzheimer hastalığının evrelerini yüksek doğrulukla ayırt etme yeteneğine sahip olduğunu göstermektedir.


Tablo 6.4, Alzheimer hastalığının evrelerine yönelik yapılan sınıflandırma deneyinde CBMDF-Net modelinin genel performansını sunmaktadır. Performans tablosuna göre, modelin Alzheimer hastalığının evrelerini ayırt etme yeteneği oldukça yüksektir; genel doğruluk oranı %100, genel kesinlik oranı %100, genel duyarlılık oranı %100 ve genel F1 skoru %100 olarak elde edilmiştir. Bu sonuçlar, CBMDF-Net modelinin Alzheimer hastalığının evrelerini doğru bir şekilde sınıflandırmada son derece başarılı olduğunu, her bir evreyi yüksek hassasiyet ve doğrulukla ayırt edebildiğini göstermektedir.

Tablo 6.4. Model performans değerleri (3.deneme, Alzheimer)

Sınıf	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
Çok hafif demans	0.99	0.99	0.99	0.99
Demans olmayan	1.00	0.99	1.00	0.99
Hafif demans	0.99	1.00	0.99	1.00
Orta dereceli demans	1.00	1.00	1.00	1.00
Makro Ortalama	1.00	1.00	1.00	1.00
Ağırlıklı Ortalama	1.00	1.00	1.00	1.00

Şekil 6.11'deki doğruluk eğrileri, Alzheimer hastalığının evreleri üzerine yapılan sınıflandırma denemesinde CBMDF-Net modelinin eğitim ve test süreçlerindeki doğruluk seviyesinin zamanla nasıl geliştiğini göstermektedir. Şekil 6.12'deki kayıp eğrileri, modelin eğitim ve test verilerindeki kayıpların zamanla nasıl değiştiğini göstermektedir. Eğitim kaybı eğrisinin hızlı bir şekilde azaldığı ve belirli bir noktadan sonra stabil hale geldiği gözlemlenmektedir. Test kaybı ise daha dalgalı bir seyir izlemekte, ancak genel olarak düşük seviyelerde kalmaktadır. Ayrıca, AUC değeri %99.89 ve kayıp oranı %2.57 olarak hesaplanmıştır. Bu bulgular, modelin Alzheimer hastalığının evrelerini sınıflandırmada yüksek doğruluk ve güvenilirlik sunduğunu açıkça ortaya koymaktadır.

**Şekil 6.11.** Önerilen modelin doğruluk grafiği (3. deneme, Alzheimer)



Şekil 6.12. Önerilen modelin kayıp grafiği (3. deneme, Alzheimer)

6.3. Önceden Eğitilmiş Modellerle Karşılaştırma

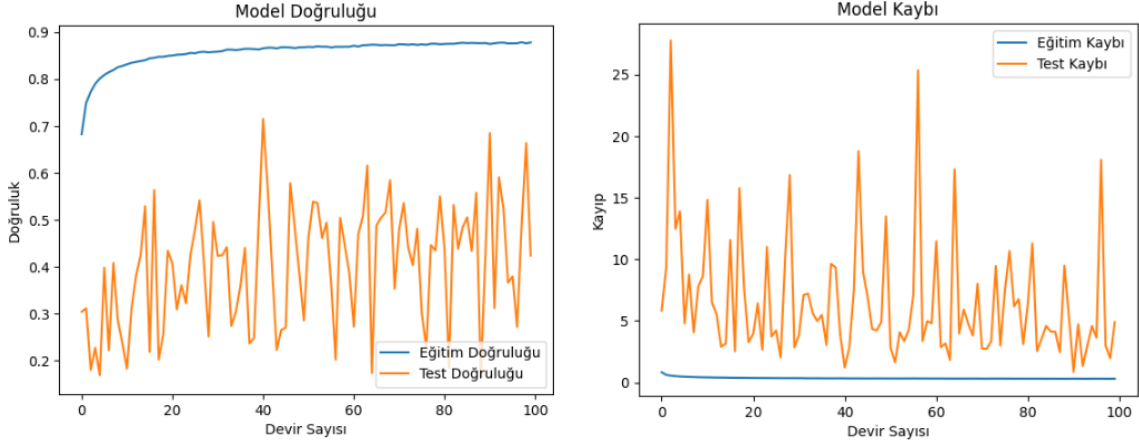
CBMDF-Net modelinin performansı, yaygın olarak kullanılan ve çeşitli görüntü işleme görevlerinde başarı sağlamış önceden eğitilmiş derin öğrenme modelleri ile karşılaştırılmıştır. Bu karşılaştırma, modelin nörolojik hastalıkların sınıflandırılmasındaki üstünlüğünü ve klinik uygulamalar açısından taşıdığı potansiyeli değerlendirmek amacıyla yapılmıştır. Karşılaştırılan modeller arasında VGG16, ResNet50, InceptionV3, Xception ve DenseNet121 bulunmaktadır. Bu modellerin performansı genellikle genel amaçlı görüntü sınıflandırma görevlerinde güçlü sonuçlar elde etmiştir; ancak nörolojik hastalıkların sınıflandırılmasında elde edilen performanslar birbirinden farklılık göstermektedir. Tablo 6.5, CBMDF-Net modelinin bu önceden eğitilmiş modeller ile karşılaştırmalı performansını göstermektedir.

Tablo 6.5. CBMDF-Net ve önceden eğitilmiş modellerin performans karşılaştırması

Metod	Doğruluk	Kesinlik	Duarlılık	F1 Skoru
CBMDF-Net	99%	99%	99%	99%
VGG16	89%	89%	89%	89%
ResNet50	42%	73%	42%	38%
InceptionV3	82%	82%	82%	82%
Xception	79%	84%	79%	79%
DenseNet121	82%	85%	82%	83%


CBMDF-Net, doğruluk, kesinlik, duyarlılık ve F1 skoru metriklerinde diğer tüm modelleri geride bırakarak %99 oranlarına ulaşmıştır. Özellikle ResNet50 gibi bazı modellerin nörolojik hastalıkları sınıflandırma konusunda belirgin bir şekilde düşük performans sergilediği görülmektedir. Bu düşük performans, modelin daha geniş ve karmaşık veri setlerinde genelleme yeteneğinin sınırlı

olduğunu göstermektedir. ResNet50'nin %42 gibi düşük bir doğruluk oranı ile sınıflandırma yapması, nörolojik hastalıkların sınıflandırılması gibi spesifik ve ince ayar gerektiren bir görevde başarılı olamadığını açıkça ortaya koymaktadır. Şekil 6.13'te, ResNet50 modelinin doğruluk ve kayıp grafikleri sunulmuş olup, bu grafikler modelin sınıflandırma performansını ve eğitim sürecindeki kayıplarını detaylandırmaktadır.




Şekil 6.13. ResNet50 doğruluk ve kayıp grafikleri

Öte yandan, InceptionV3 ve DenseNet121 modelleri, nörolojik hastalıkların sınıflandırılmasında makul sonuçlar elde etmiş olsa da, CBMDF-Net modelinin sağladığı %98 doğruluk oranına ulaşamamıştır. Bu durum, CBMDF-Net'in bu alanda daha derin özellikler çıkarabilme yeteneği ve daha optimize edilmiş bir model yapısına sahip olduğunu göstermektedir. InceptionV3 ve DenseNet121 modelleri %82 doğruluk oranı ile güçlü performans sergilerken, CBMDF-Net'in %98 doğruluk oranı, modelin nörolojik hastalıkları tanıma ve sınıflandırma konusunda çok daha başarılı olduğunu ortaya koymaktadır. Şekil 6.14 ve Şekil 6.15'te, sırasıyla InceptionV3 ve DenseNet121 modellerinin doğruluk ve kayıp grafiklerine yer verilmiş olup, bu grafikler her iki modelin nörolojik bozuklukların sınıflandırma performansını detaylandırmaktadır.




Şekil 6.14. InceptionV3 doğruluk ve kayıp grafikleri




Şekil 6.15. DenseNet121 doğruluk ve kayıp grafikleri

VGG16 ve Xception modelleri ise sırasıyla %89 ve %79 doğruluk oranlarına sahip olup, CBMDF-Net'in performansının gerisinde kalmıştır. VGG16'nın daha derin modellerden daha iyi performans sergilemesi, klasik CNN tabanlı yaklaşımların hala belirli sınıflandırma görevlerinde rekabetçi olabileceğini gösterirken, Xception gibi daha karmaşık modellerin düşük performansı, bu modellerin nörolojik veriler üzerindeki performansını artırmak için daha fazla optimizasyon gerektiğini ortaya koymaktadır. Şekil 6.16 ve Şekil 6.17'de, VGG16 ve Xception modellerinin sınıflandırma doğruluğu ile kayıp değerleri zaman içindeki değişimini göstermektedir.



Şekil 6.16. VGG16 doğruluk ve kayıp grafikleri



Şekil 6.17. Xception doğruluk ve kayıp grafikleri

CBMDF-Net'in tüm bu modellerle kıyaslandığında açık ara üstün performans sergilemesi, modelin nörolojik hastalıkların sınıflandırılmasında son derece etkili olduğunu ve bu tür spesifik sınıflandırma görevlerinde önemli bir potansiyele sahip olduğunu göstermektedir. Bu başarı, CBMDF-Net'in hastalıkların erken teşhisi ve klinik uygulamalar açısından kullanılabilirliğini daha da güçlendirmektedir.

6.4. CBMDF-Net ile Önceki Çalışmaların Karşılaştırılması

Bu bölümde, çalışmada geliştirilen CBMDF-Net modeli ile önceki nörolojik hastalık sınıflandırma çalışmaları arasında detaylı bir karşılaştırma yapılacaktır. Bu karşılaştırma, hedeflenen hastalıklar, kullanılan yöntemler ve elde edilen doğruluk oranları üzerinden değerlendirilecektir.

Tablo 6.6'da sunulan karşılaştırmalı analiz, nörolojik bozuklukların tanısında kullanılan derin öğrenme modellerine ilişkin kapsamlı bir bakış açısı sunmakta ve çeşitli modeller ile bunların başarı oranlarını ortaya koymaktadır. Önceki araştırmalar Alzheimer hastalığı, beyin tümörleri ve akut iskemik inme gibi hastalıkların sınıflandırılmasında kayda değer doğruluk oranları göstermiş olsa da, mevcut modellerde bazı sınırlamalar gözlemlenmiştir. Çoğu çalışma, genellikle belirli hastalıklara veya sınırlı veri kümelerine odaklanmakta ve bu modellerin birden fazla nörolojik bozukluğu genelleme yetenekleri sınırlı kalmaktadır. Bu çalışmada geliştirilen CBMDF-Net modeli ise, bu eksiklikleri gidererek daha geniş bir bozukluk yelpazesini içeren, veri dengeleme ve modelin sağlamlığını artırmak için ileri düzey ön işleme ve veri artırma teknikleri uygulayan bir yaklaşım benimsemektedir. Bu bütüncül yaklaşım, yalnızca belirli bozukluklara odaklanan ve farklı nörolojik durumları tek bir çerçeve içinde ayırt etmenin karmaşıklıklarını göz ardı eden diğer modellerden ayrılmaktadır. Ayrıca, CBMDF-Net'in hem daha genel hem de daha spesifik kategorilerdeki sınıflandırma görevlerinde elde ettiği başarı, modelin uyarlanabilirliğini vurgulamakta ve nörogörüntüleme uygulamalarında daha çok yönlü bir araç haline gelmesini sağlamaktadır. Bu katkılar

sayesinde, CBMDF-Net nörolojik bozuklukların sınıflandırılmasında üstün bir çözüm olarak öne çıkmakta ve klinik uygulamalarda tanısallık doğruluğun artırılmasına yönelik potansiyel sunmaktadır.

Tablo 6.6. CBMDF-Net modelinin önceki çalışmalarla performans karşılaştırması

Referans	Hedef Hastalık	Metod	Doğruluk
Kiran, vd., (2024)	Beyin tümörü	Binary CNN	99.40%
Abdullah, vd., (2024)	Beyin tümörü	Özel CNN, DeepTumor-Net, VGG-16, ResNet-50, Xception	En iyi: ResNet-50 (92.6%)
Praveena, vd., (2024)	Beyin tümörü	VGG16, CNN	Yüksek doğruluk
Ullah ve Jamjoom (2023)	Alzheimer	CNN	99.38%
Aparna ve Rao (2023)	Alzheimer	DenseNet121, MobileNetV2, CycleGAN	98.82%
Muniagurria ve Rowlands (2023)	Alzheimer	VGG, ResNet, DenseNet201 (Transfer Learning)	En iyi: DenseNet201 (86.4%)
Aljarallah, vd., (2023)	Akut iskemik inme	ResNest, GAN, YOLO-V7	MRI: 98.25%, CT: 98.65%
Rahman, vd., (2023)	Parkinson	XGBoost, AdaBoost, LightGBM, CatBoost, RF, Ridge, 3 katman DNN	En iyi: 3 katmanlı DNN (95.41%)
Naaz, vd., (2022)	Parkinson	2 katmanlı ve 3 katmanlı Derin Sinir Ağları (DNN)	En iyi: 3 katmanlı DNN (99.62%)
Setiawan ve Lin (2021)	Parkinson	ResNet-50	96.52%
Lo, vd., (2021)	Akut iskemik inme	AlexNet, Inception-v3, ResNet-101	AlexNet: 97.12%
Yu, vd., (2020)	İnme belirtileri (acil durumda teşhis)	Multimodal Öğrenme	Derin 79.27%
Bu Çalışma	Deney 1: akut iskemik inme, Alzheimer hastalığı, beyin tümörleri, Parkinson hastalığı, sağlıklı bireyler	CBMDF-Net	98.82%
	Deney 2: nörolojik bozuklukların alt kategorileri (9 sınıf)		98.31%
	Deney 3: Alzheimer hastalığı (4 sınıf) ve beyin tümörleri (4 sınıf)		99.52% (Alzheimer hastalığı), 99.23% (beyin tümörleri)

7. SONUÇLAR ve ÖNERİLER

Bu tezde geliştirilen CBMDF-Net modeli, nörolojik bozuklukların sınıflandırılmasında yüksek başarı sergilemiştir. Üç farklı deney üzerinden test edilen modelin her bir sınıflandırma görevi için elde ettiği sonuçlar, modelin gücünü ve esnekliğini ortaya koymuştur.

İlk denemede, beş farklı sınıf (Alzheimer hastalığı, Parkinson hastalığı, akut iskemik inme, beyin tümörleri ve sağlıklı bireyler) üzerinde bir sınıflandırma gerçekleştirilmiştir. Model, bu deneyde %98.82 doğruluk oranına ulaşmıştır. Sağlıklı bireylerin yanı sıra dört ana nörolojik bozukluğun tespiti, özellikle klinik ortamlarda yaygın olarak karşılaşılan bu hastalıkların doğru teşhis edilmesinde önemli bir başarı olarak kabul edilebilir. İkinci denemede, nörolojik bozuklukların daha detaylı alt grupları dikkate alınmıştır. Bu deneyde toplam dokuz sınıf kullanılmıştır: akut iskemik inme, çok hafif demans, hafif demans, orta dereceli demans, gliom, hipofiz tümörü, menenjiom, Parkinson hastalığı ve normal (sağlıklı bireyler). Alt grupların da dahil edildiği bu deney, modelin daha ince ayrımlar yapabilme kabiliyetini test etmek amacıyla gerçekleştirilmiştir ve model, bu daha karmaşık sınıflandırma görevinde %98.31 doğruluk oranına ulaşmıştır. Bu sonuç, modelin yalnızca ana hastalıkları değil, bu hastalıkların alt tiplerini de doğru bir şekilde ayırt edebilme kapasitesine sahip olduğunu göstermektedir. Üçüncü ve son denemede ise, beyin tümörleri ve Alzheimer hastalığı ayrı ayrı kendi alt grupları üzerinden çoklu sınıflandırma işlemleri gerçekleştirilmiştir. Beyin tümörleri için gliom, hipofiz tümörü, menenjiom ve tümör olmayan olmak üzere dört sınıfta çoklu sınıflandırma yapılmış ve %99.23 doğruluk oranına ulaşılmıştır. Alzheimer hastalığı için ise çok hafif demans, hafif demans, orta dereceli demans ve demans olmayan dikkate alınmış ve model %99.52 doğruluk oranına ulaşmıştır. Bu sonuçlar, modelin karmaşık beyin patolojilerini ve bu patolojilere ait alt grupları başarıyla ayırt edebilme kabiliyetini ortaya koymuştur.

Bu yüksek başarı oranları, özellikle veri dengeleme ve veri artırma tekniklerinin kullanımı sayesinde elde edilmiştir. Veri dengesizliklerini gidermek için uygulanan teknikler, her bir sınıfta daha dengeli tahminler yapılmasını sağlamış ve modelin genelleme yeteneğini artırmıştır. Görüntü işleme teknikleri ise veri çeşitliliğini artırarak sınırlı veri setlerinde bile yüksek doğruluk oranları elde edilmesine olanak tanımıştır.

CBMDF-Net modeli ayrıca VGG16, ResNet50, InceptionV3, Xception ve DenseNet121 gibi yaygın olarak kullanılan önceden eğitilmiş modellerle karşılaştırılmıştır. Bu süreçte, CBMDF-Net %99 doğruluk oranına ulaşırken, diğer modellerin performansları %42-89 aralığında kalmıştır. Bu fark, CBMDF-Net'in nörolojik bozuklukları tespit etmede daha üstün bir model olduğunu açıkça ortaya koymaktadır.

CBMDF-Net modelinin klinik uygulamalara entegrasyonu, nörolojik bozuklukların erken teşhisini hızlandırabilir ve sağlık profesyonellerine teşhis süreçlerinde destek sağlayabilir. Gelecekte yapılacak çalışmalar, modelin daha geniş ve farklı demografik gruplarda test edilerek genelleme kapasitesinin artırılmasına odaklanabilir. Ayrıca, yalnızca MRI görüntüleri değil, CT ve PET gibi

diğer tıbbi görüntüleme tekniklerinin de kullanılması, modelin çoklu tıbbi görüntüleme verilerini kullanarak teşhis yeteneğini genişletebilir. Bunun yanı sıra, nörolojik bozuklukların ilerleyici yapısı göz önüne alındığında, zaman serisi verilerinin kullanılması hastalıkların ilerleyişini izlemek ve daha dinamik bir teşhis modeli geliştirmek açısından önemli bir katkı sağlayacaktır. Özellikle Alzheimer ve Parkinson gibi ilerleyici hastalıkların erken evrelerinde teşhis edilmesi için bu tür zaman bazlı analizlerin entegre edilmesi, modelin tanı süreçlerine olan katkısını artırabilir.



KAYNAKLAR

Aarsland, D., & Kramberger, M. G. (2015). "Neuropsychiatric Symptoms in Parkinson's Disease." *Journal of Parkinson's Disease*, Vol. 5, No. 3, pp. 659-667.

Abdullah, F., Jamil, A., Alazzawi, E. M., & Hameed, A. A. (2024). "Exploring Deep Learning-based Approaches for Brain Tumor Diagnosis from MRI Images." *2024 IEEE 3rd International Conference on Computing and Machine Intelligence (ICMI)*, Mt Pleasant, MI, USA.

Aggarwal, C. C. (2018). "An Introduction to Neural Networks." *Neural Networks and Deep Learning*, Springer, Cham, pp. 1-52.

Aghzal, M., & Mourhir, A. (2020). "Early Diagnosis of Parkinson's Disease Based on Handwritten Patterns Using Deep Learning." *Proceedings of the 2020 Fourth International Conference on Intelligent Computing in Data Sciences (ICDS)*, Fez, Morocco.

Agrawal, A., & Maan, V. (2024). "Brain Tumor Classification of MRI Scans using Deep Learning Techniques." *2024 International Conference on Communication, Computer Sciences and Engineering (IC3SE)*, Gautam Buddha Nagar, India.

Alaeddine, H., & Jihene, M. (2021). "Deep network in network." *Neural Computing and Applications*, Vol. 33, pp. 1453-1465.

Albin, R. L. (2022). *Parkinson Disease*, Contemporary Neurology Series, Oxford University Press, Oxford, UK.

Aljarallah, N. A., Dutta, A. K., Sait, A. R. W., Alanaz, A. K. M., & Absi, R. (2023). "Building an Acute Ischemic Stroke Identification Model Using a Deep Learning Technique." *Journal of Disability Research*, King Salman Centre for Disability Research, Vol. 2, No. 1, pp. 35-46.

Alsheikhy, A. A., Azzahrani, A. S., Alzahrani, A. K., & Shawly, T. (2023). "An Effective Diagnosis System for Brain Tumor Detection and Classification." *Computer Systems Science and Engineering*, Vol. 46, No. 2, pp. 2021-2037.

Aparna, M., & Rao, B. S. (2023). "A Novel Automated Deep Learning Approach for Alzheimer's Disease Classification." *IAES International Journal of Artificial Intelligence (IJ-AI)*, Vol. 12, No. 1, pp. 451-458.

Arabi, E. M., Ahmed, K. S., & Mohra, A. S. (2022). "Advanced Diagnostic Technique for Alzheimer's Disease Using MRI Top-Ranked Volume and Surface-Based Features." *Journal of Biomedical Physics and Engineering*, Vol. 12, No. 6, pp. 569-582.

Armstrong, R. A. (2008). "Visual Signs and Symptoms of Parkinson's Disease." *Clinical and Experimental Optometry*, Vol. 91, No. 2, pp. 129-138.

Arulmani, D., & Manickam, R. (2024). "Brain Tumors." *Journal of Student Research*, Vol. 13, No. 2.

Ashenden, S. K., Bartosik, A., Agapow, P.-M., & Semenova, E. (2021). "Introduction to Artificial Intelligence and Machine Learning." *The Era of Artificial Intelligence, Machine Learning, and Data Science in the Pharmaceutical Industry*, Academic Press, pp. 15-26.

Athira, R. S., & Charles, J. (2024). "Alzheimer's Disease Diagnosis - A Critical Appraisal of Technique." *2024 1st International Conference on Trends in Engineering Systems and Technologies (ICTEST)*, Kochi, India.

Badža, M. M., & Barjaktarović, M. Č. (2020). "Classification of Brain Tumors from MRI Images Using a Convolutional Neural Network." *Applied Sciences*, Vol. 10, No. 6.

Bakshi, R. (2005). "Magnetic Resonance Imaging Advances in Multiple Sclerosis." *Journal of Neuroimaging*, Vol. 15, No. 4, pp. 5S-9S.

Balestrino, R., & Schapira, A. H. V. (2020). "Parkinson Disease." *European Journal of Neurology*, Vol. 27, No. 1, pp. 27-42.

Battel, L., Cunegatto, F., Viduani, A., Fisher, H. L., Kohrt, B. A., Mondelli, V., Swartz, J. R., & Kieling, C. (2021). "Mind the Brain Gap: The Worldwide Distribution of Neuroimaging Research on Adolescent Depression." *NeuroImage*, Vol. 231.

Beaulieu-Jones, B. K., Frau, F., Bozzi, S., Chandross, K. J., Peterschmitt, M. J., Cohen, C., Coulovrat, C., Kumar, D., Kruger, M. J., Lipnick, S. L., Fitzsimmons, L., Kohane, I. S., & Scherzer, C. R. (2024). "Disease Progression Strikingly Differs in Research and Real-World Parkinson's Populations." *npj Parkinson's Disease*, Vol. 10.

Bibel, W. (2014). "Artificial Intelligence in a Historical Perspective." *AI Communications*, Vol. 27, No. 1, pp. 87-102.

Bisong, E. (2019). "What Is Deep Learning." *Building Machine Learning and Deep Learning Models on Google Cloud Platform*, Apress, Berkeley, CA, pp. 327-329.

Boling, B., & Keinath, K. (2018). "Acute Ischemic Stroke." *AACN Advanced Critical Care, Symposium: Neurocritical Care*, Vol. 29, No. 2, pp. 152–162.

Bousquet, O., Gelly, S., Kurach, K., Teytaud, O., & Vincent, D. (2017). "Critical hyper-parameters: No random, no cry." *arXiv*.

Brakoniecki, K. & Chung, K. W. (2023). "Neurologic Disorders." *Advanced Anesthesia Review*, Oxford Academic.

Buck, M. (2024). "An Atypical Presentation of Ischemic Stroke in a Middle-Aged Adult." *Advanced Emergency Nursing Journal*, Vol. 46, No. 3, pp. 207-216.

Bufill, E., Blesa, R., & Augustí, J. (2013). "Alzheimer's Disease: An Evolutionary Approach." *J Anthropol Sci*, Vol. 91, pp. 135-157.

Buscema, P. M., Massini, G., Breda, M., Lodwick, W. A., Newman, F., & Asadi-Zeydabadi, M. (2018). "Artificial Neural Networks." *Artificial Adaptive Systems Using Auto Contractive Maps, Studies in Systems, Decision and Control*, Springer, Cham, pp. 11-35.

Camburu, O.-M. (2020). "Explaining deep neural networks." *arXiv*.

Catanese, L., Tarsia, J., & Fisher, M. (2017). "Acute Ischemic Stroke Therapy Overview." *Circulation Research*, American Heart Association, Inc., Vol. 120, No. 3, pp. 541-558.

Cecchin, D., Garibotto, V., Law, I., & Goffin, K. (2021). "PET Imaging in Neurodegeneration and Neuro-Oncology: Variants and Pitfalls." *Seminars in Nuclear Medicine*, Vol. 51, No. 5, pp. 408-418.

Chen, Z., Zhang, J., Arjovsky, M., & Bottou, L. (2020). "Symplectic Recurrent Neural Networks." *arXiv*.

Chiavazza, C., Franchino, F., & Rudà, R. (2019). "Clinical Concepts of Brain Tumors." *Neurorehabilitation in Neuro-Oncology*, Springer, Cham, pp. 37–51.

Chorawala, M. R., Shah, A. C., Pandya, A. J., Kothari, N. R., & Prajapati, B. G. (2024). "Symptoms and Conventional Treatments of Alzheimer's Disease." *Alzheimer's Disease and Advanced Drug Delivery Strategies*, Elsevier, pp. 213-234.

Ciomas, C., Montavont, A., & Ryvlin, P. (2008). "Magnetic Resonance Imaging in Clinical Trials." *Current Opinion in Neurology*, Vol. 21, No. 4, pp. 431-436.

Cojocar, L. (2024). "Acute Ischemic Stroke." *The Brain of the Critically Ill Pregnant Woman, Critical Care in Obstetrics*, pp. 223-235.

Cury, R. G., Pavese, N., Aziz, T. Z., Kraus, J. K., & Moro, E. (2022). "Gaps and Roadmap of Novel Neuromodulation Targets for Treatment of Gait in Parkinson's Disease." *npj Parkinson's Disease*, Vol. 8, No. 1.

Das, S., Tariq, A., Santos, T., Kantareddy, S. S., Banerjee, I. (2023). "Recurrent Neural Networks (RNNs): Architectures, Training Tricks, and Introduction to Influential Research." *Machine Learning for Brain Disorders, Neuromethods*, Vol. 197, Humana, New York, pp. 117-138. NY.

Deneu, B., Servajean, M., Bonnet, P., Botella, C., Munoz, F., & Joly, A. (2021). "Convolutional neural networks improve species distribution modelling by capturing the spatial structure of the environment." *PLOS Computational Biology*, Vol. 17, No. 4.

Denil, M., Shakibi, B., Dinh, L., Ranzato, M. A., & de Freitas, N. (2013). "Predicting Parameters in Deep Learning." *Neural Information Processing Systems*.

Dennis, E. L., Keleher, F., Tate, D. F., & Wilde, E. A. (2023). "The Role of Neuroimaging in Evolving TBI Research and Clinical Practice." *medRxiv*.

Dias, R. I. R., Alves de Carvalho, M. J., Figueiredo de Lucena, W., Lucena Salviano, J., Rodrigues Soares, J. R., Pinheiro Sampaio Feitosa, G., de Oliveira Costa, D. W., Henriques da Fonseca Araújo, N., Rayanne Barbosa dos Santos Torres, C., & Prazeres de Lemos Segundo, R. (2024). "Research on neurological diseases, such as Alzheimer's, Parkinson's, and multiple sclerosis." *V Seven International Multidisciplinary Congress*.

Domínguez, R. O., Marschoff, E., Oudkerk, L. M., de la Ossa Angulo, L. E., Pérez, S. V., Bianchi, G., Repetto, M. G., & Serra, J. A. (2022). "Neurological disorders in an elderly cohort that experienced past stressful events: a retrospective-prospective study." *Current Aging Science*, Vol. 15, No. 2, pp. 163-171.

Dubey, S. (2021). Alzheimer's dataset (4 class of images). 29 Ağustos 2024 tarihinde <https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images/> adresinden erişildi.

Dzialowski, I., Puetz, V., Parsons, M., Bivard, A., & von Kummer, R. (2022). "Computed Tomography-Based Evaluation of Cerebrovascular Disease." *Stroke (Seventh Edition): Pathophysiology, Diagnosis, and Management*, Elsevier, pp. 660-675.

Egger, J., Pepe, A., Gsaxner, C., Jin, Y., Li, J., & Kern, R. (2021). "Deep learning—a first meta-survey of selected reviews across scientific disciplines, their commonalities, challenges and research impact." *PeerJ Computer Science*, Vol. 7.

El-Sheikh, M. A., Bayoumy, A., Ahmed, N., El-Deeb, A., Rabea, F. I., Nawar, A. A., Khattap, M. G., Hassan, H. G. E. M. A., Mostafa, M., Ibrahim, N., Ramadan, R. M., Hassan, Y. R., Khaled, M., Maher, A., Abd Elaziz, M., & Ibrahim, A. G. (2024). "Enhancing Acute Ischemic Stroke Diagnosis Using IoMT and Deep Learning Technologies." 2024 International Telecommunications Conference (ITC-Egypt), Cairo, Egypt.

Erichson, N. B., Azencot, O., Queiruga, A. F., Hodgkinson, L., & Mahoney, M. W. (2021). "Lipschitz Recurrent Neural Networks." arXiv.

Essianda, V., Indrasari, A. D., Widyastuti, P., Syahla, T., & Rohadi, R. (2023). "Brain Tumor: Molecular Biology, Pathophysiology, and Clinical Symptoms." *Jurnal Biologi Tropis*, Vol. 23, No. 4.

Etkin, A. (2019). "A Reckoning and Research Agenda for Neuroimaging in Psychiatry." *American Journal of Psychiatry*, Vol. 176, No. 7, pp. 507-511.

Fang, J. Y. (2023). "Parkinson Disease." *Primer on the Autonomic Nervous System (4th ed.)*, Academic Press, pp. 549-552.

Fauzi, A., Yueniwati, Y., Naba, A., & Rahayu, R. F. (2023). "Performance of Deep Learning in Classifying Malignant Primary and Metastatic Brain Tumors Using Different MRI Sequences: A Medical Analysis Study." *Journal of X-Ray Science and Technology*, Vol. 31, No. 5, pp. 893–914.

Figuracion, K. C. F., Jung, W., & Martha, S. R. (2021). "Ischemic Stroke Risk Among Adult Brain Tumor Survivors: Evidence to Guide Practice." *Journal of Neuroscience Nursing*, Vol. 53, No. 5, pp. 202-207.

Filippi, M., DeStefano, N., Dousset, V., & McGowan, J. C. (2006). "MR Imaging in White Matter Diseases of the Brain and Spinal Cord." *AJNR Am J Neuroradiol*, Vol. 27, No. 8.

Franklin, S. (2014). "History, Motivations, and Core Themes." *The Cambridge Handbook of Artificial Intelligence*, Cambridge University Press, pp. 15-33.

Galimberti, D., & Scarpini, E. (2010). "Treatment of Alzheimer's Disease: Symptomatic and Disease-Modifying Approaches." *Current Aging Science*, Vol. 3, No. 1, pp. 46-56.

Gant, V., Rodway, S., & Wyatt, J. (2009). "Artificial neural networks: practical considerations for clinical application." *Clinical Applications of Artificial Neural Networks*, Cambridge University Press, pp. 329-356.

Geetha, R., Priya, E., & Sivakumar, K. (2024). "Automated Diagnosis of Acute Cerebral Ischemic Stroke Lesions from Diffusion-Weighted Magnetic Resonance Images in Assessment with Modified Rankin Scale." *Journal of Intelligent & Fuzzy Systems*, Pre-press, pp. 1-19.

Genç, G. (2024). "Genetic Research and Its Contribution to the Treatment in Parkinson's Disease." *Deep Brain Stimulation*, Vol. 4, pp. 47-49.

Ghayvat, H., Awais, M., Geddam, R., Khan, M. A., Nkenyereye, L., Fortino, G., & Dev, K. (2024). "AiCarePWP: Deep Learning-Based Novel Research for Freezing of Gait Forecasting in Parkinson." *Computer Methods and Programs in Biomedicine*, Vol. 254.

Goodwin, G. J., Moeller, S., Nguyen, A., & John, S. (2023). "Network Analysis of Neuropsychiatric Symptoms in Alzheimer's Disease." *Journal of the International Neuropsychological Society*, Vol. 29, pp. 517-518.

Gras, L. Z., Kanaan, S. F., McDowd, J. M., Colgrove, Y. M., Burns, J., & Pohl, P. S. (2015). "Balance and Gait of Adults With Very Mild Alzheimer Disease." *Journal of Geriatric Physical Therapy*, Vol. 38, No. 1, pp. 1-7.

Grossi, E., & Buscema, M. (2006). "Artificial Intelligence and Outcome Research." *Drug Development Research*, Vol. 67, No. 3, pp. 227-244.

Harshini, V., Sweatha, S. M., Senthil Shunmugam, K., & Saraswathi Meena, R. (2024). "Alzheimer's Diagnosis: Harnessing Machine Learning and Deep Learning for Enhanced Prediction and Understanding." *Artificial Intelligence Transformations for Healthcare Applications: Medical Diagnosis, Treatment, and Patient Care*.

Hawkes, M. A., & Rabinstein, A. A. (2020). "Acute Ischemic Stroke." *Neurological Emergencies*, Springer, Cham, pp. 171–188.

He, S., Li, Z., Tang, Y., Liao, Z., Li, F., & Lim, S.-J. (2020). "Parameters compressing in deep learning." *CMC*, Vol. 62, No. 1, pp. 321-336.

Herholz, K., Coope, D., & Jackson, A. (2007). "Metabolic and Molecular Imaging in Neuro-Oncology." *The Lancet Neurology*, Vol. 6, No. 8, pp. 711–724.

Hosseini Saber, B. N., & Hosseini Saber, R. N. (2023). "Diagnosis of Brain Tumor Using MRI Techniques." *2023 Fifth International Conference on Electrical, Computer and Communication Technologies (ICECCT)*, Erode, India.

Huang, G., Liu, Z., Pleiss, G., van der Maaten, L., & Weinberger, K. Q. (2022). "Convolutional Networks with Dense Connectivity." *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 44, No. 12, pp. 8704-8716.

Huré, C., Pham, H., Bachouch, A., & Langrené, N. (2021). "Deep Neural Networks Algorithms for Stochastic Control Problems on Finite Horizon: Convergence Analysis." *SIAM Journal on Numerical Analysis*, Vol. 59, No. 1.

Husain, M. M., Trevino, K., Siddique, H., & McClintock, S. M. (2008). "Present and Prospective Clinical Therapeutic Regimens for Alzheimer's Disease." *Neuropsychiatric Disease and Treatment*, Vol. 4, No. 4, pp. 765–777.

Ignacio, K. H. D., Kim, D., Te, J. T., & Demchuk, A. (2023). "Teaching NeuroImage: Rapidly Changing Symptoms With Multistep Migration of Clot in the Posterior Circulation After Tenecteplase for Acute Ischemic Stroke." *Neurology*, Vol. 101, No. 24.

Indumalar, S., Sathik Raja, M., & Reshma, R. (2024). "Brain Tumor Detection from MRI Image using Deep Learning." *International Journal of Innovative Research*.

Iorio-Morin, C., Villeneuve, S. A., Masson-Côté, L., & Mathieu, D. (2023). "Neurological Disorders: Radiation Therapy of Benign Diseases." *Medical Radiology*, Springer, Cham, pp. 181–190.

Iqbal, M. S., Heyat, M. B., Parveen, S., Hayat, M. A., Roshanzamir, M., Alizadehsani, R., Akhtar, F., Sayeed, E., Hussain, S., Hussein, H. S., & Sawan, M. (2024). "Progress and trends in neurological disorders research based on deep learning." *Computerized Medical Imaging and Graphics*, Elsevier, Vol. 116.

Ivanov, S., & D'yakonov, A. (2019). "Modern Deep Reinforcement Learning Algorithms." arXiv.

Jain, M., Patil, D., Gupta, S., & Mahajan, S. (2024). "Advancement in Diagnostic and Therapeutic Techniques for Ischemic Stroke." *Integrating Metaheuristics in Computer Vision for Real-World Optimization Problems*.

Janiesch, C., Zschech, P., & Heinrich, K. (2021). "Machine learning and deep learning." *Electronic Markets*, Vol. 31, No. 3, pp. 685-695.

Jean, A. (2020). "A Brief History of Artificial Intelligence." *M S-Medecine Sciences*, Vol. 36, No. 11, pp. 1059-1067.

Jordan, J. T., & Gerstner, E. R. (2023). "Imaging of Brain Tumors." *CONTINUUM: Lifelong Learning in Neurology*, Vol. 29, No. 1, pp. 171-193.

Kalaiaarasi, K., Sindhuja, N., & Islam, S. M. N. (2023). "Diagnosing the Abnormalities in Brain Tumors with the Technique of K-Means Clustering with Knowledge Acquisition." *2023 International Conference on Advancement in Computation & Computer Technologies (InCACCT)*, Gharuan, India.

Kamel, P., Kanhere, A., Kulkarni, P., Khalid, M., Steger, R., Bodanapally, U., Gandhi, D., Parekh, V., & Yi, P. H. (2024). "Optimizing Acute Stroke Segmentation on MRI Using Deep Learning: Self-Configuring Neural Networks Provide High Performance Using Only DWI Sequences." *Journal of Imaging Informatics in Medicine*.

Kaur, D., Bansal, R. P., & Uppal, A. (2023). "A Comparative Analysis of Diagnostic Imaging in Acute Ischaemic Stroke." *Chettinad Health City Medical Journal*, Vol. 12, No. 2.

Kaye, A. H., & Laws, E. R. (2001). *Brain Tumors: An Encyclopedic Approach*. Churchill Livingstone, London, UK.

Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2020). "A survey of the recent architectures of deep convolutional neural networks." *Artificial Intelligence Review*, Vol. 53, pp. 5455-5516.

Khan, T. K. (2016). "Clinical Diagnosis of Alzheimer's Disease." *Biomarkers in Alzheimer's Disease*, Academic Press, pp. 27-48.

Khanal, D. R. (2024). "Acute Ischemic Stroke." *Case-based Approach to Common Neurological Disorders*, Springer, Singapore, pp. 71–78.

Khuntia, M., Sahu, P. K., & Devi, S. (2023). "Deep Learning Approaches for Brain Tumor Diagnosis Using Fused Layer Accelerator." *Journal of Computer Science*, Vol. 19, No. 2, pp. 188-202.

Khurana, D., Das, B., & Bhatia, R. (2019). "Acute Ischaemic Stroke." *Emergencies in Neurology*, In Springer, Singapore, pp. 215-238.

Kiran, L., Zeb, A., Rehman, Q. N. U., Rahman, T., Khan, M. S., Ahmad, S., Irfan, M., Naeem, M., Huda, S., & Mahmoud, H. A. (2024). "An Enhanced Pattern Detection and Segmentation of Brain Tumors in MRI Images Using Deep Learning Technique." *Frontiers in Computational Neuroscience*, Vol. 18.

Kraemer, H. C., Taylor, J. L., Tinklenberg, J. R., & Yesavage, J. A. (1998). "The Stages of Alzheimer's Disease: A Reappraisal." *Dementia and Geriatric Cognitive Disorders*, Vol. 9, No. 6, pp. 299–308.

Kredbová, B., Klát, J., Špaček, R., & Šimetka, O. (2024). "Brain Tumors in Pregnancy, Symptoms, Diagnosis, and Our Cases." *European Journal of Obstetrics and Gynecology and Reproductive Biology*, Vol. 293.

Kreisl, W. C., Kim, M.-J., Coughlin, J. M., Henter, I. D., Owen, D. R., & Innis, R. B. (2020). "PET Imaging of Neuroinflammation in Neurological Disorders." *The Lancet Neurology*, Vol. 19, No. 11, pp. 940-950.

Kruse, R., Borgelt, C., Braune, C., Mostaghim, S., & Steinbrecher, M. (2016). "Introduction to Neural Networks." *Computational Intelligence, Texts in Computer Science*, Springer, London, pp. 9-13.

Kubat, M. (2015). "Artificial Neural Networks." *An Introduction to Machine Learning*, Springer, Cham, pp. 91-111.

Kugunavar, S., & Prabhakar, C. J. (2021). "Convolutional neural networks for the diagnosis and prognosis of the coronavirus disease pandemic." *Visual Computing for Industry, Biomedicine, and Art*, Vol. 4.

Kuks, J. B. M., Snoek, J. W., Jacobs, B., & Martins Jarnalo, C. O. (2023). "Neurological Tumours and Neurological Complications of Cancer and Cancer Treatment." *Textbook of Clinical Neurology*, Bohn Stafleu van Loghum.

Kumari, K., & Jha, A. M. (2024). "Brain Tumors in Pediatric Patients." *International Journal of Trends in OncoScience*, Vol. 2, No. 3, pp. 14-22.

Ioffe, S., & Szegedy, C. (2015). "Batch normalization: Accelerating deep network training by reducing internal covariate shift." *Machine Learning, Computer Science*.

Lo, C.-M., Hung, P.-H., & Lin, D.-T. (2021). "Rapid Assessment of Acute Ischemic Stroke by Computed Tomography Using Deep Convolutional Neural Networks." *Journal of Digital Imaging*, Vol. 34, No. 3, pp. 637-646.

Luis, M. L., Hormigo, A., Mauricio, C., Alves, M. M., & Serrao, R. (1990). "Magnetic Resonance Imaging in Motor Neuron Disease." *Journal of Neurology*, Vol. 237, No. 8, pp. 471-474.

Maass, A., & Reichmann, H. (2013). "Sleep and Non-Motor Symptoms in Parkinson's Disease." *Journal of Neural Transmission*, Vol. 120, pp. 565-569.

Magrez, P. (1986). "Artificial Intelligence in Medicine." *Rev Med Brux*, Vol. 7, No. 3, pp. 153-161.

Maiti, S., Sen, S., Manna, S., Kole, A., Mondal, R., & Chatterjee, B. (2024). "Deep Learning-Based Prediction and Monitoring of Parkinson's Disease Using Voice Data." *Research Square*.

Majhi, B., Kashyap, A., Mohanty, S. S., Dash, S., Mallik, S., Li, A., & Zhao, Z. (2024). "An Improved Method for Diagnosis of Parkinson's Disease Using Deep Learning Models Enhanced with Metaheuristic Algorithm." *BMC Medical Imaging*, Vol. 24.

Mall, P. K., Singh, P. K., Srivastav, S., Narayan, V., Paprzycki, M., Jaworska, T., & Ganzha, M. (2023). "A comprehensive review of deep neural networks for medical image processing: Recent developments and future opportunities." *Healthcare Analytics*, Vol. 4.

Mamatha, T. R. (2023). "Acute Ischemic Stroke in Covid-19." *Current Innovations in Disease and Health Research*, Vol. 2, pp. 86-93.

MCI Due to AD, the Symptomatic, Pre-Dementia Phase of Alzheimer's, Results from Hippocampal Overactivity. <https://agenebio.com/pipeline/about-amci-and-alzheimers-dementia/> [Accessed 25 Sep 2024].

Miller, D. H., Robb, S. A., Ormerod, I. E. C., Pohl, K. R. E., MacManus, D. G., Kendall, B., Moseley, I. F., & McDonald, W. I. (1990). "Magnetic Resonance Imaging of Inflammatory and Demyelinating White-Matter Diseases of Childhood." *Developmental Medicine & Child Neurology*, Vol. 32, No. 2, pp. 97–107.

Mohamed, W. (2023). "Parkinson's Genetics Research on Underrepresented AfrAbia Populations: Current State and Future Prospects." *American Journal of Neurodegenerative Diseases*, Vol. 12, No. 2, pp. 23-41.

Mohanasundaram, R., Malhotra, A. S., Arun, R., & Periasamy, P. S. (2019). "Deep Learning and Semi-Supervised and Transfer Learning Algorithms for Medical Imaging.", *Deep Learning and Parallel Computing Environment for Bioengineering Systems*, Academic Press, pp. 139-151.

Moini, J., LoGalbo, A., & Ahangari, R. (2024). "Neurological disorders: Foundations of the Mind, Brain, and Behavioral Relationships." *Understanding Physiological Psychology*, Academic Press, Elsevier, pp. 241-267.

Morantz, R. A., & Walsh, J. W. (1994). *Brain Tumors: A Comprehensive Text. Neurological Disease and Therapy*, CRC Press, Boca Raton, Florida, USA.

Mostafa, H., & Wang, X. (2019). "Parameter efficient training of deep convolutional neural networks by dynamic sparse reparameterization." Proceedings of the 36th International Conference on Machine Learning, Long Beach, California, PMLR 97, arXiv.

Moussa, C. (2016). "Could cancer drugs be repurposed for use in Parkinson's and Alzheimer's?" Expert Review of Neurotherapeutics, Vol. 16, No. 12, pp. 1335-1336.

Mucci, F., & Marazziti, D. (2023). "Artificial Intelligence in Neuropsychiatry: a potential beacon in an ocean of uncertainty?" Clinical Neuropsychiatry, Vol. 20, No. 6, pp. 467-469.

Mueller, S., Keeser, D., Reiser, M. F., Teipel, S. J., & Meindl, T. (2012). "Functional and Structural MR Imaging in Neuropsychiatric Disorders, Part 1: Imaging Techniques and Their Application in Mild Cognitive Impairment and Alzheimer Disease." American Journal of Neuroradiology, Vol. 33, No. 10, pp. 1845-1850.

Muniagurria, T. P., & Rowlands, S. (2023). "Alzheimer's Disease MRI Identification, Recognition, & Evaluation-Deep Learning." Research Square, Vol. 1.

Naaz, S., Hussain, A., & Siddiqui, F. (2022). "Prediction of Parkinson's Disease Using Deep Learning in TensorFlow." International Journal of Bioinformatics and Computational Biology, Vol. 11, No. 1.

Nickparvar, M. (2021). Brain Tumor MRI Dataset. 29 Ağustos 2024 tarihinde <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset/data/> adresinden erişildi.

Niethammer, M., Feigin, A., & Eidelberg, D. (2012). "Functional Neuroimaging in Parkinson's Disease." Cold Spring Harbor Perspectives in Medicine, Vol. 2, No. 5.

Nikmanesh, Y., Mohammadi, M. J., Yousefi, H., Mansourimoghadam, S., & Taherian, M. (2022). "The effect of long-term exposure to toxic air pollutants on the increased risk of malignant brain tumors." Reviews on Environmental Health.

Nyström, K., & Schindler, J. (2018). "Acute Ischemic Stroke." Neurocritical Care for the Advanced Practice Clinician, Springer, Cham, pp. 93-115.

Oakden-Rayner, L., & Palmer, L. J. (2019). "Artificial Intelligence in Medicine: Validation and Study Design." Artificial Intelligence in Medical Imaging, Springer, Cham, pp. 83-104.

Pabla, H. S., Gokulakrishnan, P. R., Murali, A., & Venkata Sai, P. M. (2021). "Role of PET-CT in Aiding Diagnosis of Various Neurological Conditions – A Case Series." *Journal of Evolution of Medical and Dental Sciences*, Vol. 10, No. 7, pp. 440-446.

Pacal, I., Karaboga, D., Basturk, A., Akay, B., & Nalbantoglu, U. (2020). "A comprehensive review of deep learning in colon cancer." *Computers in Biology and Medicine*, Elsevier, Vol. 126.

Palermo, F., Pieroni, N., Maugeri, L., Begani Provinciali, G., Sanna, A., Massimi, L., Catalano, M., Olbinado, M. P., Bukreeva, I., Fratini, M., Uccelli, A., Gigli, G., Kerlero de Rosbo, N., Balducci, C., & Cedola, A. (2020). "X-ray Phase Contrast Tomography Serves Preclinical Investigation of Neurodegenerative Diseases." *Frontiers in Neuroscience*, Vol. 14.

Pamina, J., & Beschi, R. J. (2019). "Survey on deep learning algorithms." *International Journal of Emerging Technology and Innovative Engineering*, Vol. 5, No. 1.

Panesar, A. (2019). "What Is Artificial Intelligence, Machine Learning and AI for Healthcare." Apress, Berkeley, CA, pp. 1-18.

Parcollet, T., Ravanelli, M., Morchid, M., Linarès, G., Trabelsi, C., De Mori, R., & Bengio, Y. (2018). "Quaternion Recurrent Neural Networks." arXiv.

Park, A., & Stacy, M. (2011). "Dopamine-Induced Nonmotor Symptoms of Parkinson's Disease." *Parkinson's Disease*.

Parvaz, M. A., Alia-Klein, N., Woicik, P. A., Volkow, N. D., & Goldstein, R. Z. (2011). "Neuroimaging for Drug Addiction and Related Behaviors." *Reviews in the Neurosciences*, Vol. 22, No. 6, pp. 609-624.

Peng, S.-P., Yang, X.-Y., & Zhao, Y. (2022). "Convolutional neural networks for the design and analysis of nonfullerene acceptors." *Computational and Data-Driven Chemistry Using Artificial Intelligence: Fundamentals, Methods, and Applications*, Elsevier, pp. 231-256.

Pichaivel, M., Anbumani, G., Theivendren, P., & Gopal, M. (2022). "An Overview of Brain Tumor." *Brain Tumors*, IntechOpen.

Piramide, N., Agosta, F., Sarasso, E., Canu, E., Volontè, M., & Filippi, M. (2020). "Brain Activity During Lower Limb Movements in Parkinson's Disease Patients with and without Freezing of Gait." *Journal of Neurology*, Vol. 267.

Pless, A., Ware, D., Saggi, S., Rehman, H., Morgan, J., & Wang, Q. (2023). "Understanding Neuropsychiatric Symptoms in Alzheimer's Disease: Challenges and Advances in Diagnosis and Treatment." *Front. Neurosci.*, Vol. 17.

Poole, D., & Mackworth, A. K. (2010). "Artificial Intelligence: Artificial Intelligence and Agents." *Artificial Intelligence: Foundations of Computational Agents*, Cambridge University Press, pp. 3-42.

Potter, C. A., Vagal, A. S., Goyal, M., Nunez, D. B., Leslie-Mazwi, T. M., & Lev, M. H. (2019). "CT for Treatment Selection in Acute Ischemic Stroke: A Code Stroke Primer." *RadioGraphics*, Vol. 39, No. 6.

Praveena, M. R., Abinaya, K., Gowthami, E., Lakshmidhevi, E., & Yashodha, G. (2024). "Brain Neoplasm Identification Using Deep Learning." *International Journal of Scientific Research in Engineering and Management*, Vol. 8, No. 9.

Price, C. J., Crinion, J., & Friston, K. J. (2006). "Design and Analysis of fMRI Studies with Neurologically Impaired Patients." *Clinical Potential of Brain Mapping Using MRI. Journal of Magnetic Resonance Imaging*, Vol. 23, No. 6, pp. 816-826.

Qasrawi, R., Qdaih, I., Daraghme, O., Thwib, S., Vicuna Polo, S., Atari, S., & Abu Al-Halawa, D. (2024). "Hybrid Ensemble Deep Learning Model for Advancing Ischemic Brain Stroke Detection and Classification in Clinical Application." *J Imaging*, Vol. 10, No. 7.

Qiang, Y.-R., Zhang, S.-W., Li, J.-N., Li, Y., Zhou, Q.-Y., & Alzheimer's Disease Neuroimaging Initiative. (2023). "Diagnosis of Alzheimer's Disease by Joining Dual Attention CNN and MLP Based on Structural MRIs, Clinical and Genetic Data." *Artificial Intelligence in Medicine*, Elsevier, Vol. 145.

Rahman, S., Hasan, M., Sarkar, A. K., & Khan, F. (2023). "Classification of Parkinson's Disease Using Speech Signal with Machine Learning and Deep Learning Approaches." *European Journal of Electrical Engineering and Computer Science*, Vol. 7, No. 2.

Ravindranath, V., Menesgere, A. L., & Wallin, M. T. (2023). "Burden of neurological disease." *Neurobiology of Brain Disorders (Second Edition), Biological Basis of Neurological and Psychiatric Disorders*, Elsevier, pp. 1047-1064.

Reisberg, B., Ferris, S. H., Anand, R., de Leon, M. J., Schneck, M. K., Buttinger, C., & Borenstein, J. (1984). "Functional Staging of Dementia of the Alzheimer Type." *First Colloquium in Biological Sciences*, Vol. 435, No. 1, pp. 481-483.

Reiss, A. B., Glass, A. D., & Stecker, M. M. (2020). "Alzheimer's Disease: Many Failed Trials, So Where Do We Go from Here?" *Journal of Investigative Medicine*, Vol. 68, No. 6.

Ren, W., Hasanzade Bashkandi, A., Afshar Jahanshahi, J., AlHamad, A. Q. M., Javaheri, D., & Mohammadi, M. (2023). "Brain Tumor Diagnosis Using a Step-by-Step Methodology Based on Courtship Learning-Based Water Strider Algorithm." *Biomedical Signal Processing and Control*, Elsevier, Vol. 83.

Rocchi, L., Nicolini, F., & Politis, M. (2015). "Recent Imaging Advances in Neurology." *Journal of Neurology*, Vol. 262, No. 9, pp. 2182–2194.

Sahla, F. K. V., Surya, C. R., Adharsh, S., & Krishnan, S. P. (2023). "Alzheimer Disease Prediction Using Deep Learning." *International Research Journal of Modernization in Engineering Technology and Science*, Vol. 5, No. 4.

Salawu, F. K., Danburam, A., & Olokoba, A. B. (2010). "Non-Motor Symptoms of Parkinson's Disease: Diagnosis and Management." *Nigerian Journal of Medicine*, Vol. 19, No. 2, pp. 126-131.

Şalçini, C. (2019). Alzheimer Hastalığı Tanısında Amiloid PET Görüntüleme. 27 Eylül 2024 tarihinde <http://www.celalsalcini.com/index.php/2019/11/06/alzheimer-hastaligi-tanisinda-amiloid-pet-goruntuleme/> adresinden erişildi.

Sarin, K., Bardamova, M., Svetlakov, M., Koryshev, N., Ostapenko, R., Hodashinskaya, A., & Hodashinsky, I. (2023). "A Three-Stage Fuzzy Classifier Method for Parkinson's Disease Diagnosis Using Dynamic Handwriting Analysis." *Decision Analytics Journal*, Vol. 8.

Sarker, I. H. (2021). "Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions." *SN Computer Science*, Vol. 2, No. 6.

Setiawan, F., & Lin, C.-W. (2021). "Implementation of a Deep Learning Algorithm Based on Vertical Ground Reaction Force Time-Frequency Features for the Detection and Severity Classification of Parkinson's Disease." *Sensors*, Vol. 21, No. 15.

Sharmili, K. C., Suja, G. P., Pandian, E., Ala Walid, Md. A., Arunachalam, S., & Babu, G. C. (2023). "An Effective Diagnosis of Alzheimer's Disease with the Use of Deep Learning Based CNN Model." 2023 7th International Conference on Intelligent Computing and Control Systems (ICICCS), Madurai, India.

Shen, J., Aboutaleb, A., Sivakumar, K., Belzer, B. J., Chan, K. S., & James, A. (2020). "Deep Neural Network a Posteriori Probability Detector for Two-Dimensional Magnetic Recording." *IEEE Transactions on Magnetics*, Vol. 56, No. 6.

Sheriff, I. (2021). parkinsons_brain_mri_dataset. 29 Ağustos 2024 tarihinde <https://www.kaggle.com/datasets/irfansheriff/parkinsons-brain-mri-dataset/> adresinden erişildi.

Shukla, A., Tiwari, R., & Tiwari, S. (2023). "Review on Alzheimer Disease Detection Methods: Automatic Pipelines and Machine Learning Techniques." *Sci*, Vol. 5, No. 1, Article 13.

Sima, D. M., Loeckx, D., Smeets, D., Jain, S., Parizel, P. M., & Van Hecke, W. (2017). "Use Case I: Imaging Biomarkers in Neurological Disease. Focus on Multiple Sclerosis." *Imaging Biomarkers*, Springer, Cham, pp. 169-180.

Singh, J., Banji, D., Manjulatha, B., & Babitha, S. (2010). "Neurological disorders: An overview." *Pharmacologyonline*, Vol. 1, pp. 602-612.

Sokolov, I. A. (2019). "Theory and Practice of Application of Artificial Intelligence Methods." *Herald of the Russian Academy of Sciences*, Vol. 89, No. 2, pp. 115-119.

Stelzer, F., Stelzer, F., Stelzer, F., Röhm, A., Vicente, R., Fischer, I., & Yanchuk, S. (2021). "Deep neural networks using a single neuron: folded-in-time architecture using feedback-modulated delay loops." *Nature Communications*, Vol. 12.

Stix, C., & Maas, M. M. (2021). "Bridging the Gap: The Case for an 'Incompletely Theorized Agreement' on AI Policy." *AI and Ethics*, Vol. 1, No. 3, pp. 261-271.

Suganyadevi, S., Seethalakshmi, V., & Balasamy, K. (2021). "A review on deep learning in medical image analysis." *International Journal of Multimedia Information Retrieval*, Vol. 11, pp. 19-38.

Talukder, M. A., Islam, M. M., Uddin, M. A., Akhter, A., Pramanik, M. A. J., Aryal, S., Almoyad, M. A. A., & Hasan, K. F. (2023). "An Efficient Deep Learning Model to Categorize Brain Tumor Using Reconstruction and Fine-Tuning." *Expert Systems with Applications*, Vol. 230.

TAŞCI, B. (2022). Acute Ischemic Stroke MRI. 29 Ağustos 2024 tarihinde <https://www.kaggle.com/datasets/buraktaci/mri-stroke/> adresinden erişildi.

Tautan, A. M., Ionescu, B., & Santarnecchi, E. (2021). "Artificial intelligence in neurodegenerative diseases: A review of available tools with a focus on machine learning techniques." *Artificial Intelligence in Medicine*, Vol. 117.

Teixeira, A. L., Rocha, N. P., & Gatchel, J. (2023). "Behavioral or Neuropsychiatric Symptoms of Alzheimer's Disease: From Psychopathology to Pharmacological Management." *Arq Neuropsiquiatr*, Vol. 81, No. 12, pp. 1152-1162.

Termine, A., Fabrizio, C., Strafella, C., Caputo, V., Petrosini, L., Caltagirone, C., & Giardina, E. (2021). "Multi-Layer Picture of Neurodegenerative Diseases: Lessons from the Use of Big Data through Artificial Intelligence." *Journal of Personalized Medicine*, Vol. 11, No. 4.

Thom, R. P., Canales, C., Tresvalles, M., McDougale, C. J., Hooker, J., Chen, Y.-C., & Zürcher, N. R. (2023). "Neuroimaging Research in Williams Syndrome: Beginning to Bridge the Gap with Clinical Care." *Neuroscience & Biobehavioral Reviews*, Vol. 153.

Tino, P., Benuskova, L., & Sperduti, A. (2015). "Artificial Neural Network Models." *Springer Handbook of Computational Intelligence*, Springer Handbooks, Springer, Berlin, Heidelberg, pp. 455-471.

Todeva-Radneva, A., Paunova, R., Kandilarova, S., & Stoyanov, D. (2020). "The Value of Neuroimaging Techniques in the Translation and Transdiagnostic Validation of Psychiatric Diagnoses - Selective Review." *Current Topics in Medicine*, Vol. 20, No. 7, pp. 540-553.

Tong, W., Yue, W., Chen, F., Shi, W., Zhang, L., & Wan, J. (2024). "MSE-VGG: A Novel Deep Learning Approach Based on EEG for Rapid Ischemic Stroke Detection." *Sensors*, Vol. 24, No. 13.

Tripathi, S. (2021). "Artificial Intelligence: A Brief Review." *Analyzing Future Applications of AI, Sensors, and Robotics in Society*, IGI Global, pp. 1-16.

Turner, R., & Jones, T. (2003). "Techniques for Imaging Neuroscience." *British Medical Bulletin*, Vol. 65, No. 1, pp. 3–20.

Tyler, B. M., Pradilla, G., Hadelsberg, U., Bow, H., Suk, I., & Brem, H. (2013). "Treatment of Brain Tumors." *Focal Controlled Drug Delivery, Advances in Delivery Science and Technology*, Springer, Boston, MA, pp. 169–194.

Ullah, Z., & Jamjoom, M. (2023). "A Deep Learning for Alzheimer's Stages Detection Using Brain Images." *Computers, Materials & Continua*, Vol. 74, No. 1, pp. 1457-1473.

Unal, M., Ak, A., Topuz, V., & Erdal, H. (2013). "Artificial Neural Networks." *Optimization of PID Controllers Using Ant Colony and Genetic Algorithm*, Springer, Berlin, Heidelberg, pp. 5-17.

Uysal, S. (2023). "Brain Neoplasms." *Functional Neuroanatomy and Clinical Neuroscience: Foundations for Understanding Disorders of Cognition and Behavior*, pp. 270-278.

Vaijayanthimala, J., Gopiga, S., Harrish, M., Krishnapriya, S., & Mano Ranjitha, R. (2024). "Multiple Brain Disease Prediction with Diagnostic Report Using Deep Learning." *International Journal of Scientific Research in Engineering and Management*, Vol. 8, No. 9.

Valli, A., & Wiselin Jiji, G. (2014). "Parkinson's Disease Diagnosis Using Image Processing Techniques: A Survey." *International Journal of Computer Science & Applications (IJCSA)*, Vol. 4, No. 6, pp. 57-67.

Wainwright, D. A., Nigam, P., Thaci, B., Dey, M., & Lesniak, M. S. (2012). "Recent Developments on Immunotherapy for Brain Cancer." *Expert Opinion on Emerging Drugs*, Vol. 17, No. 2, pp. 181-202.

Wang, M., Ge, W., Apthorp, D., & Suominen, H. (2020). "Robust Feature Engineering for Parkinson Disease Diagnosis: New Machine Learning Techniques." *JMIR Publications*, Vol. 5, No. 1.

Wankar, B. R., Kshirsagar, N. V., Jadhav, A. V., Bawane, S. R., & Koshti, S. M. (2024). "Innovative Deep Learning Approach for Parkinson's Disease Prediction: Leveraging Convolutional Neural

Networks for Early Detection.” EAI Endorsed Transactions on Pervasive Health and Technology, Vol. 10.

Warren, S. L., Abo Hamza, E., Tindle, R., Reid, E., Whitfield, P., Doumit, A., & Moustafa, A. A. (2023). “Common Neuropsychiatric Symptoms in Alzheimer’s Disease, Mild Cognitive Impairment, and Subjective Memory Complaints: A Unified Framework.” *Current Alzheimer Research*, Vol. 20, No. 7, pp. 459-470.

Wen, G., McNaughton, J., Chong, B., Shim, V., Fernandez, J., Holdsworth, S., & Wang, A. (2023). “Synthesising MRIs from CTs to Improve Stroke Treatment Using Deep Learning.” 2023 ISMRM & ISMRT Annual Meeting & Exhibition.

Winkler, A. S., Gupta, S., Patel, V., Bhebhe, A., Fleury, A., Aukrust, C. G., Duah, T., Welte, T. M., Chakraborty, S., & Park, K. B. (2024). “Global brain health—the time to act is now.” *The Lancet Global Health*, Vol. 12, No. 5.

Xie, L., Zhao, J., Li, Y., & Bai, J. (2024). “PET Brain Imaging in Neurological Disorders.” *Physics of Life Reviews*, Elsevier, pp. 100-111.

Xu, Y., Liu, X., Cao, X., Huang, C., Liu, E., Qian, S., Liu, X., Wu, Y., Dong, F., Qiu, C.-W., Qiu, J., Hua, K., Su, W., Wu, J., Xu, H., Han, Y., Fu, C., Yin, Z., Liu, M., Roepman, R., Dietmann, S., Virta, M., Kengara, F., Zhang, Z., Zhang, L., Zhao, T., Dai, J., Yang, J., Lan, L., Luo, M., Liu, Z., An, T., Zhang, B., He, X., Cong, S., Liu, X., Zhang, W., Lewis, J. P., Tiedje, J. M., Wang, Q., An, Z., Wang, F., Zhang, L., Huang, T., Lu, C., Cai, Z., Wang, F., & Zhang, J. B. (2021). “Artificial Intelligence: A Powerful Paradigm for Scientific Research.” *The Innovation*, Vol. 2, No. 4.

Yevtushenko, N. Yu., & Zotov, O. S. (2024). “Mental Disorders as Symptoms of Brain Tumors: A Literature Review.” *Practical Oncology*, Vol. 7, No. 1.

Yu, M., Cai, T., Huang, X., Wong, K. K., Volpi, J., Wang, J. Z., & Wong, S. T. C. (2020). “Toward Rapid Stroke Diagnosis with Multimodal Deep Learning.” *Medical Image Computing and Computer Assisted Intervention – MICCAI 2020, Lecture Notes in Computer Science*, Springer, Cham, Vol. 12263, pp. 616-626.

Zafar, A., Aamir, M., Mohd Nawi, N., Arshad, A., Riaz, S., Alruban, A., Kumar Dutta, A., & Almotairi, S. (2022). “A comparison of pooling methods for convolutional neural networks.” *Appl. Sci.*, Vol. 12, No. 17.

Zec, R. F., Landreth, E. S., Vicari, S. K., Belman, J., Feldman, E., Andrise, A., Robbs, R., Becker, R., & Kumar, V. (1992). "Alzheimer Disease Assessment Scale: A Subtest Analysis." *Alzheimer Disease & Associated Disorders*, Vol. 6, No. 3, pp. 164-181.

Zhang, L., Pan, Y., Wu, X., & Skibniewski, M. J. (2021). "Introduction to Artificial Intelligence." *Artificial Intelligence in Construction Engineering and Management, Lecture Notes in Civil Engineering*, Springer, Singapore, pp. 1-15.

Zhang, L., Wang, M., Liu, M., & Zhang, D. (2020). "A Survey on Deep Learning for Neuroimaging-Based Brain Disorder Analysis." *Frontiers in Neuroscience*, Vol. 14.

Zuber, M. (2002). "Enfermedad de Parkinson." *EMC - Tratado de Medicina*, Elsevier, Vol. 6, No. 1, pp. 1-5.

