

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**DERİN ÖĞRENME YÖNTEMLERİNİ KULLANARAK BEYİN
MR GÖRÜNTÜLERİNDEN OTOMATİK TÜMÖR TESPİTİ**

Necip ÇINAR

Doktora Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

Kuramsal Temeller Bilim Dalı

HAZİRAN 2024

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

DERİN ÖĞRENME YÖNTEMLERİNİ KULLANARAK BEYİN MR
GÖRÜNTÜLERİNDEN OTOMATİK TÜMÖR TESPİTİ

Tez Yazarı
Necip ÇINAR

Danışman
Prof. Dr. Mehmet KAYA

HAZİRAN 2024
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

Başlığı:	Derin Öğrenme Yöntemlerini Kullanarak Beyin MR Görüntülerinden Otomatik Tümör Tespiti
Yazarı:	Necip ÇINAR
İlk Teslim Tarihi:	16.05.2024
Savunma Tarihi:	24.06.2024

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Prof. Dr. Mehmet KAYA Fırat Üniversitesi, Mühendislik Fakültesi	İmza Onayladım
Başkan:	Prof Dr. İbrahim TÜRKOĞLU Fırat Üniversitesi Teknoloji Fakültesi	Onayladım
Üye:	Prof Dr. Taner TUNCER Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Doç. Dr. Muhammed YILDIRIM Malatya Turgut Özal Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi İbrahim Rıza HALLAÇ Alanya Alaaddin Keykubat Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Derin Öğrenme Yöntemlerini Kullanarak Beyin MR Görüntülerinden Otomatik Tümör Tespiti” Başlıklı Doktora Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

24.06.2024

Necip ÇINAR



ÖNSÖZ

Beyin tümörleri erken teşhis edildiğinde tedavi şansı artar. Bu nedenle, otomatik olarak tümörleri tespit etme yeteneği hayat kurtarıcı olabilir. Derin öğrenme yöntemleri, geleneksel yöntemlere kıyasla daha yüksek doğruluk ve hassasiyet sağlayabilir, bu da doğru teşhislerin yapılmasına yardımcı olabilir. Her alanda olduğu gibi, bu alanın da bazı kısıtlar bulunmaktadır. Beyin MR görüntülerinin karmaşıklığı ve çeşitliliği, derin öğrenme modellerinin eğitimini zorlaştırabilir. Veri setinin yetersizliği veya dengesizliği, modelin genelleme yeteneğini etkileyebilir ve yanlış sonuçlara neden olabilir. Bazı nadir tümör tipleri veya belirli koşullar altında tespit edilmesi zor olabilir. Bu alanda çalışmak, sağlık sektörüne değerli katkılarda bulunma ve insan sağlığını iyileştirmek için bir katkı sağlama fırsatı sunmaktadır. Derin öğrenme yöntemlerini uygulama ve geliştirme fırsatı sunarak, yapay zeka ve tıp arasında önemli bir köprü oluşturma olanağı sunmaktadır. Bu alanda çalışmanın bazı zorlukları olsa da, bu alandaki ilerlemelerin insanların yaşam kalitesini artırabileceği düşüncesi, motivasyonumuzu arttıran en önemli faktör olmuştur. Bu tez çalışmasında, beyin MR görüntülerinden otomatik tümör tespiti için daha önce kullanılmamış derin öğrenme yöntemleri kullanılarak yeni bir yaklaşım geliştirilmiştir.

Bu tez çalışması süresince maddi manevi katkılarını esirgemeyen ve tüm bilimsel çalışmalarda zaman gözetmeksizin her an destekçim olan değerli büyüğüm danışman hocam Sayın Prof. Dr. Mehmet Kaya'ya teşekkürlerimi sunarım.

Bu çalışmanın her aşamasında yanımda olan, haklarını asla ödeyemeyeceğim ve bugüne kadar attığım her adımda destekçim olan kıymetli eşim Sercan Çınar, kızım Zehra Beren Çınar ve oğlum Berken Çınar'a teşekkür ederim.

Necip ÇINAR
ELAZIĞ, 2024

İÇİNDEKİLER

ÖNSÖZ.....	iv
İÇİNDEKİLER.....	v
ÖZET.....	vii
ABSTRACT.....	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xi
KISALTMALAR	xii
1. GİRİŞ	1
1.1. Tezin Amacı	18
1.2. Tezin Katkıları.....	18
1.3. Tezin Yapısı.....	20
2. LİTERATÜR TARAMASI.....	9
2.1. Beyin Tümörü Segmentasyonu.....	10
2.2. Beyin Tümörü Sınıflandırma.....	12
3. MATERYAL VE METOT.....	15
3.1. Beyin Tümörü Çeşitleri, Teşhis Yöntemleri ve Görüntüleme Teknikleri.....	15
3.1.1. Beyin Tümörü ve Çeşitleri	16
3.1.2. Görüntüleme Teknikleri	16
3.1.3. Beyin Tümörü Segmentasyonu (Bölütleme)	17
3.1.4. Beyin Tümörü Sınıflandırma.....	18
3.2. Evrişimli Sinir Ağları	19
3.2.1. Girdi Katmanı.....	20
3.2.2. Evrişim Katmanı	21
3.2.3. Havuzlama Katmanı	23
3.2.4. Tamamen Bağlı Katman.....	25
3.2.5. Seyreltme (Dropout) Katmanı	26
3.2.6. Sigmoid Fonksiyonu	27
3.2.7. Rectified Linear Unit (ReLU) Fonksiyonu.....	29
3.2.8. Softmax Fonksiyonu	31
3.2.9. Çıktı Katmanı	32
3.3. Evrişimli Sinir Ağ Mimarileri	33
3.3.1. ResNet	33
3.3.2. VGGNet	35
3.3.3. DenseNet	37
3.3.4. EfficientNet	38
3.3.5. U-Net.....	40
3.4. Kayıp Fonksiyonları	41
3.4.1. Ortalama Kare Hatası (MSE)	42
3.4.2. İkili Çapraz Entropi Kaybı	42
3.4.3. Kategorik Çapraz Entropi Kaybı.....	43
3.4.4. Zar (Dice) Kaybı	44
3.5. Transfer Öğrenme.....	45

4. VERİ SETLERİ, VERİ ÖN İŞLEME VE DEĞERLENDİRME METRİKLERİ .	47
4.1. BraTS 2019 Veri Seti	47
4.2. Kaggle (figshare) Veri Seti	49
4.3. Kaggle (Br35H) Veri Seti	50
4.4. Veri Arttırma.....	51
4.5. Normalizasyon (Normalleştirme).....	52
4.5.1. Minimum-Maksimum Ölçeklendirme	52
4.5.2. Ortalama Normalleştirme	52
4.5.3. Standardizasyon (Z-puan normalizasyonu)	53
4.5.4. Toplu Normalleştirme.....	54
4.6. Değerlendirme Metrikleri	55
5. ÖNERİLEN MODELLER.....	58
5.1. Hibrit DenseNet121-UNet Modeli Kullanarak MR Görüntülerinden Beyin Tümörü Segmentasyonu.	58
5.1.1. Veri Ön İşleme Süreci	60
5.1.2. Önerilen Hibrit DenseNet121-UNet Mimarisi	63
5.1.3. Önerilen DenseNet121-UNet Mimarisinin Avantajları.....	65
5.1.4. Veri Son İşleme Süreci.....	66
5.1.5. Uygulama Detayları	66
5.1.6. Uygulama Sonuçları	67
5.1.7. En Gelişmiş Yöntemlerle Karşılaştırmalar.....	69
5.2. MR Görüntülerini Kullanarak Beyin Tümörü Sınıflandırmasına Yönelik Yeni bir Yaklaşım	70
5.2.1. Ön İşleme Süreci	71
5.2.2. Önerilen Evrişimli Sinir Ağ Mimarisi.....	71
5.2.3. Uygulama Detayları	74
5.2.4. Uygulama Sonuçları.....	75
5.2.5. En Gelişmiş Yöntemlerle Karşılaştırmalar.....	80
5.3. MRI görüntülerini kullanarak beyin tümörü sınıflandırmasına yönelik derin öğrenme modellerinin karşılaştırılması	81
5.3.1. Veri Ön İşleme Süreci	81
5.3.2. Uygulama Detayları	82
5.3.3. Uygulama Sonuçları.....	83
6. SONUÇLAR.....	85
ÖNERİLER	88
KAYNAKLAR.....	89
ÖZGEÇMİŞ	

ÖZET

Derin Öğrenme Yöntemlerini Kullanarak Beyin MR Görüntülerinden Otomatik Tümör Tespiti

Necip ÇINAR

Doktora Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Haziran 2024, Sayfa: xii + 101

Beyin tümörü insan sağlığını ciddi anlamda tehdit eden ve çoğu zaman riskli ameliyatlara tedavi edilebilen bir hastalıktır. Uzmanlar, yüksek çözünürlüklü Manyetik Rezonans (MR) görüntüleriyle beyin tümörünü tespit edebilmektedir. Ancak günümüzde, bir çok araştırmacı derin öğrenme yöntemlerini kullanarak MR görüntülerinden beyin tümör tespitini yapmaktadır. Yapılan çalışmalarda MR veya Bilgisayarlı Tomografi (BT) görüntülerinden beyin tümör tespiti ile ilgili oldukça başarılı sonuçlar elde edilmiştir. Ancak hala bu alanda geliştirilmesi gereken birçok nokta bulunmaktadır. Özellikle tümörlerin yeri, boyutu konusunda başarı oranının istenilen seviyede olmadığı bilinmektedir.

Bu tez çalışmasında beyin MR görüntülerinden derin öğrenme yöntemleri kullanarak otomatik tümör tespiti için daha önce önerilmemiş beyin tümörü tespitini daha yüksek bir başarı oranı ile tespit eden yeni bir yaklaşım geliştirilmiştir. Bu tez çalışmasında beyin tümör tespiti iki aşamalı bir süreç olarak gerçekleştirilmiştir. İlk aşamada beyin tümörünün yeri ve boyutlarının tespiti için bölütleme (segmentasyon) işlemi yapılmış, ikinci aşamada ise tümör tiplerinin tespiti için sınıflandırma işlemi yapılmıştır.

Bölütleme işlemi için derin öğrenme ağlarından biri olan UNet mimarisi, segmentasyon işlemi için önceden eğitilmiş DenseNet121 mimarisi ile hibrit model olarak kullanılmıştır. Önerilen model, yüksek dereceli ve düşük dereceli glioma tümörlerini içeren BraTS 2019 veri seti ile doğrulanmıştır. Deneysel sonuçlar, modelimizin bu alanda sunulan diğer son teknoloji yöntemlerden daha iyi performans elde ettiğini göstermektedir. Bölütleme işlemi sonucunda, tüm tümör, çekirdek tümör ve genişleyen tümör için sırası ile %95.9, %94.3 ve %89.2 DSC değerleri elde edilmiştir. Beyin MR görüntülerinin sınıflandırılması için 8 katmanlı iyileştirilmiş CNN tabanlı bir ağ tasarlanmıştır. Önerilen yaklaşım, glioma tümörlerini %99,64, menenjiyom tümörlerini %96,53, hipofiz tümörlerini %98,39 doğruluk oranıyla tespit etmiştir.

Anahtar Kelimeler: Derin öğrenme, Tümör bölütleme, Tümör sınıflandırma, Evrimsel sinir ağları, Görüntü işleme

ABSTRACT

Automatic Tumor Detection From Brain MRI Images Using Deep Learning Techniques

Necip ÇINAR

Ph.D. Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

June 2024, Pages: xii + 101

The detection of brain tumors from MRI images is a critical concern for human health and often requires risky surgeries for treatment. Experts can identify brain tumors using high-resolution Magnetic Resonance (MR) imaging. However, nowadays, many researchers are employing deep learning methods to detect brain tumors from MR or Computed Tomography (CT) images. Significant success has been achieved in tumor detection from MR or CT images through these studies. Nevertheless, there are still many areas in this field that need improvement, especially in accurately determining the location and size of tumors.

In this thesis, a new approach has been developed using deep learning methods to automatically detect brain tumors from MRI images with a higher success rate than previously proposed methods. The brain tumor detection process in this thesis is carried out in two stages: in the first stage, segmentation is performed to determine the location and dimensions of the brain tumor, and in the second stage, classification is performed to determine the types of tumors.

For the segmentation process, the UNet architecture, which is one of the deep learning networks, is used as a hybrid model with the pre-trained DenseNet121 architecture. The proposed model has been validated on the BraTS 2019 publicly available brain tumor dataset, which includes high-grade and low-grade glioma tumors. Experimental results demonstrate that our model outperforms other state-of-the-art methods in this field. For the segmentation process, Dice Similarity Coefficient (DSC) values of 95.9%, 94.3%, and 89.2% are obtained for the whole tumor, core tumor, and enhancing tumor, respectively. An 8-layer CNN-based model is designed for the classification of brain MR images. The proposed approach achieves detection accuracies of 99.64% for glioma tumors, 96.53% for meningioma tumors, and 98.39% for pituitary tumors.

Keywords: Deep learning, Tumor segmentation, Tumor classification, Convolutional neural networks, Image processing

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 3.1. Klasik ESA mimarisi.....	20
Şekil 3.2. Evrişim katmanında evrişim işlemi.....	23
Şekil 3.3. Maksimum havuzlama işlemi.....	25
Şekil 3.4. Sigmoid fonksiyonu grafiği.....	29
Şekil 3.5. Negatif ve pozitif girişler için ReLU grafiği.....	30
Şekil 3.6. Softmax fonksiyonu grafiği.....	32
Şekil 3.7. ResNet atlama bağlantıları.....	34
Şekil 3.8. VGGNet mimarisi (Simonyan ve Zisserman).....	36
Şekil 3.9. DenseNet yğün blok mimarisi (Huang ve arkadaşları).....	37
Şekil 3.10. Üç yoğun bloktan oluşan derin bir DenseNet mimarisi (Huang ve arkadaşları).	38
Şekil 3.11. Temel EfficientNet-B0 mimarisi.....	39
Şekil 3.12. U-Net mimarisi (Ronneberger ve arkadaşları).....	40
Şekil 4.1. BraTS 2019 MR görüntülerinin 4 farklı sekans örneği.....	48
Şekil 4.2. Dört farklı sınıfa ait MR görüntüleri.....	49
Şekil 4.3. Tümörlü görüntüler.....	50
Şekil 4.4. Tümörlü olmayan (normal) görüntüler.....	50
Şekil 4.5. DSC formülasyonun gösterimi.....	56
Şekil 4.6. Tümör merkezinin koordinatlarının nasıl elde edildiği gösterilmektedir.	61
Şekil 4.7. MR görüntüsü koordinatlar kullanılarak 64x64 boyutunda parçalara nasıl bölüldüğü gösterilmektedir.	61
Şekil 4.8. Genişliği ve uzunluğu 64'ten büyük, merkez koordinatları belirlenmiş bir görüntü 4 parçaya bölünmüş olarak gösterilir.	62
Şekil 4.9. Hibrit DenseNet121-UNet mimarisinin bir diyagramı gösterilmektedir.	64
Şekil 4.10. Önerilen hibrit DenseNet121-UNet mimarisi.....	65
Şekil 4.11. Tümör parçalarının birleştirilmesi işlemi.....	66
Şekil 4.12. Beyin tümörünün üç bölgesi için Zar Katsayısı (DSC) ve Zar Kaybı (DSC Loss) değerleri gösterilmektedir.	68
Şekil 4.13. Farklı tümör tiplerinin segmentasyon sonuçları gösterilmektedir.	69
Şekil 4.14. Önerilen CNN modelinin mimarisi gösterilmiştir.	72
Şekil 4.15. Kayıp fonksiyonunun eğrisi.....	76
Şekil 4.16. Accuracy fonksiyonunun eğrisi.....	77
Şekil 4.17. Önerilen ESA'nın karışıklık matrisi.....	77

Şekil 4.18. Yanlış pozitif ve yanlış negatif örneği.....	78
Şekil 4.19. MR görüntülerinde kırpma işlemi	82
Şekil 4.20. ResNet101 modelin karışıklık matrisi.....	84



TABLÖLER LİSTESİ

	Sayfa
Tablo 4.1. Önerilen hibrit DenseNet121-UNet mimarimizi doğrulamak için kullanılan metrikler	67
Tablo 4.2. Önerilen hibrit DenseNet121-UNet mimarisinin diğer derin sinir ağları karşılaştırılması	67
Tablo 4.3. Önerilen hibrit DenseNet121-UNet mimarisinin en gelişmiş yöntemlerle karşılaştırılması	70
Tablo 4.4. Modelde kullanılan ve modelin başarısına en fazla etki eden parametreler.....	74
Tablo 4.5. Önerilen modeli doğrulamak için kullanılan performans ölçümleri	75
Tablo 4.6. Önerilen modelin diğer derin öğrenme algoritmaları ile karşılaştırılması	79
Tablo 4.7. Önerilen model ile literatürdeki altı çalışmanın karşılaştırılması	80
Tablo 4.8. Modelde kullanılan ve modelin başarısına en fazla etki eden parametreler.....	82
Tablo 4.9. CNN ağlarını doğruluk değerleri	83

KISALTMALAR

MRI	: Magnetic Resonance Imaging
BT	: Bilgisayarlı Tomografi
ESA	: Evriřimli Sinir Ağları
DSA	: Derin Sinir Ağları
DNN	: Deep Neural Network
BraTS	: Brain Tumor Segmentation
DSC	: Dice Similarity Coefficient
PET	: Pozitron Emisyon Tomografisi
CNN	: Convolutional Neural Networks
IoU	: Intersection of Union
RES	: Residual Extended Skip
WC	: Wide Context
DSÖ	: Dünya Sağlık Örgütü
ReLU	: Rectified Linear Units
RNN	: Recurrent Neural Network
MSE	: Mean Squared Error
GAN	: Generative Adversarial Network

1. GİRİŞ

Beyin tümörü, beyindeki veya merkezi omurilik kanalındaki hücrelerin kitlesi veya anormal büyümesidir. Bu tümörler iyi huylu (kansersiz olmayan) veya kötü huylu (kansersiz) olabilir. Beyin, vücuttaki çeşitli işlevleri kontrol eden hayati bir organdır; dolayısıyla bu alandaki herhangi bir anormal büyüme, önemli sonuçlara yol açabilir[1]. İyi huylu ve kötü huylu olmak üzere iki kategoride sınıflandırılabilir. Genel olarak, iyi huylu tümörler zararlı değildir ve büyümeleri kötü huylu olanlara kıyasla daha uzun sürmektedir. Diğer yanda, kötü huylu tümörler oldukça hızlı büyür ve hasta için hayati tehlike oluştururlar. Çoğu beyin tümörünün kesin nedeni tam olarak anlaşılamamıştır ancak genetik, belirli kimyasallara veya radyasyona maruz kalma ve belirli rahatsızlıkların geçmişi gibi faktörler, bunların gelişimine katkıda bulunabilir[2]. Beyin tümörlerinin bazı yaygın semptomları arasında baş ağrıları, nöbetler, görme değişiklikleri, konuşma veya duyma güçlüğü ve davranış veya kişilik değişiklikleri yer alır.

Beyin tümörlerinin çeşitli türleri vardır ve bunlar konumlarına, hücre kökenlerine ve iyi huylu (kansersiz olmayan) veya kötü huylu (kansersiz) olmalarına göre kategorize edilebilir. İşte bazı yaygın beyin tümörü türleri:

- *Glioma*: Bu tümörler beyindeki destekleyici hücreler olan glial hücrelerden kaynaklanır. Gliomalar en sık görülen primer beyin tümörü türüdür.
- *Meningioma (Menenjiyom)*: Bu tümörler beyni ve omuriliği kaplayan doku katmanları olan meninkilerde gelişir. Menenjiyomların çoğu iyi huyludur.
- *Pituitary (Hipofiz bezi)*: Bu tümörler, beynin tabanında hormon üretimini düzenleyen küçük bir bez olan hipofiz bezinde oluşur.

Her beyin tümörü tipinin farklı özellikler, büyüme oranları ve tedaviye yanıtlar sergileyebileceğini unutmamak önemlidir. Tedavi yaklaşımı tümörün türü, yeri, büyüklüğü ve hastanın genel sağlık durumu gibi faktörlere bağlı olacaktır[3]. Erken teşhis ve doğru teşhis, en uygun tedavi planının belirlenmesi açısından çok önemlidir. Teşhis genellikle manyetik rezonans görüntüleme (MRI) veya bilgisayarlı tomografi (BT) taramaları gibi görüntüleme çalışmalarının yanı sıra tümörün doğasını belirlemek için biyopsi kombinasyonunu içerir. Tedavi seçenekleri tümörün türüne, boyutuna ve konumuna bağlıdır ve cerrahi, radyasyon terapisini, kemoterapiyi veya bu yaklaşımların bir kombinasyonunu içerebilir. Tüm beyin tümörlerinin kansersiz olmadığını ve birçoğunun başarıyla tedavi edilebileceğini unutmamak önemlidir. Ancak teşhis ve tedavi seçenekleri tümörün spesifik özelliklerine bağlı olarak büyük ölçüde değişmektedir.

Manyetik Rezonans Görüntüleme (MRI) beyin tümörleri teşhisinde uzmanlar tarafından en yaygın kullanılan yöntemlerden biridir. MR görüntüleri yüksek çözünürlüklü görüntüler olduğundan hastalıklı dokular kolaylıkla görülebilir ve doku hasarı varsa beyindeki bozulma

tespit edilebilir[4]. MRI görüntülerini işlemek kolaylaştığından ve yıllardır teknolojinin hızla gelişmesiyle birlikte bu görüntüleri kullanarak tümörleri tespit etmek için birçok çalışma gerçekleştirilmiştir. Bu bağlamda kullanılan derin öğrenme teknikleri dikkate değer sonuçlar vermiş ve hastalık teşhisinde popüler hale gelmiştir[5].

Radyologlar hastaların MR görüntülerini manuel olarak inceleyerek tümör olup olmadığını kontrol ederler. Tümörün varlığı tespit edilirse tümörün tipi ve sınırları belirlenir, bir sonraki adımda tümörün tipi belirlenir. Uzmanlar bunu manuel olarak yaptığından bu işlem uzun zaman alır. Yüzlerce hastaya aynı gün MR çektirilmesi nedeniyle, MR raporlarının hazırlanması genellikle belli bir süre sonra yapılır. Bunun nedeni uzmanların bu incelemeleri manuel olarak yapması ve bazı sağlık alanlarında teknolojinin henüz beklenen düzeyde kullanılamamasıdır[6]. Tümörlerin bu şekilde teşhis edilmesi, görüntülerin manuel olarak incelenmesi çok zaman alır ve radyologların hata yapmasına çık bir süreçtir. Teşhis sürecinde yapılacak bir hata yanlış tedavi uygulanması gibi ciddi sorunlara yol açabilmektedir. Bu sorunların üstesinden gelmek için bilgisayar destekli tanıma sistemleri kullanılabilir. Teknolojinin gelişmesiyle birlikte beyin tümörlerinin bilgisayar destekli tanıma sistemleriyle tespitine yönelik birçok çalışma yapılmaktadır. Yapay zekanın her alanda kullanılmaya başlanması ve yüksek kapasiteli bilgisayarların ortaya çıkmasıyla birlikte hastalıkların tanısında teknolojinin kullanımında da büyük bir artış yaşanmıştır[7]. Araştırmacılar yapay zekanın bir alt dalı olan derin öğrenme yöntemlerini kullanarak beyin tümörlerinin teşhisinde büyük başarı elde etti.

Derin öğrenme, model girişinin özelliklerini öğrenmek için birçok metrik fonksiyonun birleşimini kullanır. Son yıllarda yapay sinir ağlarının gelişmesi ve problem çözmedeki başarısı nedeniyle birçok problemin çözümünde kullanılan bir yöntem haline geldi[8]. İnsanların öğrenme şekline benzer şekilde öğrenen sistemler yaratma çabası içinde olan araştırmacılar, derin öğrenmenin altında yatan mimari için insan beyninin yapısından ilham aldı. Bu nedenle derin öğrenmedeki birçok terminoloji nöroloji ile ilgilidir. Nöronların beyinin temel bloklarını oluşturduğu yapıyı benzer bir şekilde derin öğrenme mimarisi doğrusal olmayan fonksiyonların modellenmesine izin veren hesaplama birimi içerir.

Yapay zekâ son zamanlarda özellikle medikal görüntü analizinde olmak üzere birçok alanda çok önemli bir rol oynadı. Beyin tümörünü teşhis etmek için çeşitli yapay zeka teknikleri ile MR görüntülerinden otomatik segmentasyon ve sınıflandırma işlemini yapılmaktadır[9]. Yapay zekâ uygulamaları birçok hastalığın teşhisinde kullanılabildiği gibi, bir uzmanın manuel inceleme sırasında yapabileceği hataların da önüne geçebilmektedir. Bu nedenlerden dolayı MR görüntülerinden beyin tümörlerinin teşhisi ile ilgili literatürde birçok çalışma yapılmaktadır. Bu çalışmalar sonucunda yeni yöntemler geliştirilmekte ve mevcut yöntemlerin başarı oranı

arttırılmaktadır. Bu gelişmeler bilgisayar destekli karar destek sistemlerinin beyin tümörünün tespitinde kullanılmasının önemini göstermektedir. Normal şartlar altında bir uzmanın MR görüntülerinden manuel olarak tümör tespiti yapması yaklaşık 30 dakika sürebilir. Bu sistemler tümör tespitini saniyeler içerisinde daha verimli, hızlı ve doğru bir şekilde yapabilir.

Derin öğrenme ve makine öğrenmesi, yapay zekanın birer alt kümesidir. Makine öğrenmesinde özellik çıkarımı ayrı bir işlem olarak gerçekleşir. Ancak derin öğrenmede özellik çıkarma ayrı bir işlem olarak gerçekleşmez, model aynı zamanda özellik çıkarımını da gerçekleştirir. Makine öğreniminde özellik çıkarmanın başarısızlığı doğrudan modelin başarısını etkiler, çünkü eğer iyi bir özellik çıkarımı yapılmazsa, modelin başarısı düşer. Evrişimsel sinir ağları (ESA) görüntülerin sınıflandırılmasında ve segmentasyonunda yaygın olarak kullanılmaktadır. ESA mimarilerin başarısını arttırmak için, daha fazla katmana sahip derin sinir ağları (DSA) geliştirildi. Derin sinir ağları, ESA ağlarında karşılaşılan dengesiz veri dağılımı ve gradyan azalması gibi problemleri çözmek için geliştirildi. Geliştirilen bu derin sinir ağları, medikal görüntü analizi, yüz tanıma, doğal dil işleme gibi bir çok alanda kullanılmaktadır[10].

Beyin tümörlerinin tespitinde derin öğrenme yöntemlerinin kullanılmasının amacı, MR görüntülerinden tümör tespitini otomatikleştirmek, uzmanların yoğunluğunu azaltmak, hastalığın teşhis süresini kısaltmak ve uzmanlar tarafından yapılabilecek olası hataları önlemektir. Bu yöntem iki aşamada gerçekleşir; ilk aşamada tümörün büyüklüğü ve sınırları belirlenir, ikinci aşamada ise bazı özellikleri belirlenen tümörün tipi belirlenir. En yaygın karşılaşılan beyin tümör tipleri, glioma, meningioma (menenjiyom) ve pituitary (hipofiz bezi)'dir[11]. Literatürde beyin MR görüntülerinden tümör tespiti konusunda birçok çalışma yapılmıştır. Bu çalışmalarda çok başarılı sonuçlar elde edilse de hala geliştirilmeye açık birçok nokta bulunmaktadır. Bu çalışmada tümör tespiti süreci iki aşamalı olarak yürütülecektir; ilk aşamada BraTS 2019 veri seti kullanılarak tümör segmentasyon işlemi gerçekleştirilecektir. İkinci aşamada ise Kaggle platformundan indirilen etiketli benchmark veri seti kullanılarak sınıflandırma yapılacaktır.

Tümör segmentasyonunun temel amacı, aktif tümörlü dokuların, nekrotik dokuların ve ödemin bulunduğu tümörlü bölgeleri tespit etmektir. Bu bölgeler normal ve anormal olan dokuların arasındaki farktan tespit edilebilir. Ancak infiltrate glioma tümörlerini tespit etmek zordur, çünkü bulanık sınırlar içerirler[12]. Bu tür tümörlerin tespiti için T1, T1C, T2 ve FLAIR dahil olmak üzere birden fazla MRI sekansı kullanır. İnsan vücudunun farklı dokularını ve yönlerini görselleştirmek için birçok farklı MRI (Manyetik Rezonans Görüntüleme) sekansı kullanılır. Bu sekanslar, dokuların belirli özelliklerini vurgulamak ve teşhis yeteneklerini geliştirmek için uyarlanmıştır. Bu sekanslar, belirli bir klinik durumun spesifik teşhis

ihtiyalarına uyacak şekilde birleřtirilebilir veya deęiřtirilebilir. Dizi seimi, řüphelenilen patoloji, grntlenen blge ve farklı dokular arasında istenen kontrast gibi faktrlere baęlıdır. Bu sekansların her biri ayrı zelliklere sahiptir nk bu sekansların her biri her doku iin benzersiz bir imza oluřturuyor[13]. Son yıllarda derin sinir aęlar, yksek doęruluk elde ederek grnt segmentasyonunda umut verici sonular gsterdi[14]. Bu yntemler bařarılı olmasına raęmen hala beyin tmrlerinin segmentasyonu ile ilgili denenmesi gereken birok mimari bulunmaktadır.

oęu derin ęrenme tabanlı beyin tmr segmentasyonu yaklařımındaki temel sorun, yerel etiketler ve baęımlılıklar zerinde iyi alıřmayan piksel sınıflandırmasını gerekleřtirmesidir[15]. Piksel bazlı sınıflandırmanın temel bir sınırlaması, evreleyen piksellerden gelen bilgilerin kullanılmaması, bu bilgiler, hedef piksellerin sınıfının doęru bir şekilde tanımlanmasına yardımcı olabilir. Literatrde nerilen birok alıřmada tm tmr alanlar yksek Dice Similarity Coefficient (DSC) doęruluęu ile tespit edilmektedir[16]. Ancak nekroz ve geniřleyen tmr alanlarını tespiti ok daha dřk oranlarda yapılmaktadır. Bu alıřmanın temel amalarından biri nekroz ve geniřleyen tmr gibi kk ve sınırları belirsiz blgelerin de tespitinin yksek bir bařarı oranı ile yapılmasıdır.

Bu alıřmanın ilk ařamasında segmentasyon iřlemine gerekleřtirmek iin yama tabanlı hibrit bir DenseNet121-UNet modeli neriyoruz. Bu modeli nermemizin nedeni, beyin tmrnn derin ęrenme yntemleri ile tespitinde yukarıda belirttięimiz zorlukların stesinden gelmektir. Bu alıřmanın iki temel motivasyon kaynaęı bulunmaktadır: Birincisi, verilerin sınıf dengesizlięi probleminin stesinden gelmek, ikincisi ise modelin doęruluęunu arttırmaktır. Bu amala grntleri eęitimden nce (64x64) ebatlarında yamalara blyoruz. Grntleri tmr merkezinin koordinatlarına gre 1, 2 veya 4 paraya blyoruz. Eęitim srecini tamamladıktan sonra yamaları aynı mantıkla birleřtirerek tekrar grntnn ilk halini elde ediyoruz. Literatrde veri dengesizlięi sorununu zmek iin kk yamaların kullanılması yaygındır[17]. DenseNet121-UNet, kodlayıcı ve kod zc arasında atlama baęlantılarını kullanır, bu parametre gncellemelerini stabilize etmeye yardımcı olur. Genellikle daha derin aęlar dięer modellere gre daha fazla zellik yakaladıklarından zellikle grnt iřlemede daha iyi performans gsterirler. DenseNet121-UNet hibrit aęı, modeli daha fazla stabilize ettięi iin ve verimli bir şekilde eęitmeye yardımcı olan kısa bir atlama baęlantısı kullanır[18].

Bu tez alıřmasında MR grntlerinden beyin tmr segmentasyonu iin hibrit bir DenseNet121-UNet mimarisi nerilmektedir. Nekroz ve geniřleyen tmr gibi kk alanların segmentasyonunu kolaylařtırmak iin grntleri n iřleme teknikleriyle normalleřtiriyor ve kırıyoruz. Benzer alıřmalarda DSC doęruluęu nekroz ve geniřleyen tmr alanlarına iliřkin deęerler ok dřktr[19]. Bu alıřmada, bu tr alanların DSC doęruluęunu iyileřtirmeye

odaklanılmıştır. Verimli eğitim ve testleri tanımlayarak BraTS 2019 veri kümesi ile denemeler yapıp elde ettiğimiz sonuçları literatürdeki diğer temel yöntemlerle karşılaştırmaktayız.

Literatürde beyin tümör tespitine yönelik çalışmalar incelendiğinde, bazı çalışmalar tümörün sadece varlığını tespit etmeye yönelik yapılırken, bazı çalışmalar ise tümörün tipini belirlemeye yönelik yapılmaktadır[16]. Bir MR görüntüsünde beyin tümörün var olup olmadığını tespit etmeye yönelik çalışmaların başarı oranı daha çok yüksek. Çünkü MR görüntüsünde bir anormalliği tespit etmek biraz daha kolaydır. Ancak beyin tümörünün glioma, meningioma veya pituitary türlerinden hangisi olduğunu tespit etmek biraz daha zordur. Her bir tümör tipi farklı özelliklere sahiptir, derin öğrenme algoritmalarının bu özellikleri tespit etmesi gerekmektedir. Bu da özellikleri tespit etmek için uygun modellerin ve yaklaşımların kullanılması gerektiğini göstermektedir. Görüntüdeki öznelikleri tespit edecek ve görüntüleri sınıflandıracak bir modelin tasarlanması ile daha yüksek başarı elde etmek mümkündür[20]. Diğer bir sorun da pek çok çalışmada beyin tümörü sınıflandırması için derin sinir ağları kullanılmaktadır. Derin sinir ağlarında katman sayısının artması, azalan gradyan problemini ve darboğaz oluşturur. Az sayıda sınıfın bulunduğu bir sınıflandırma işlemi segmentasyon işlemine daha az karmaşıktır. Böyle durumlarda normal bir CNN ağının modifiye edilmiş hali de çok yüksek bir başarı sağlayabilir[21].

Bu sorunlara çözüm bulmak amacıyla MR görüntüleri kullanılarak beyin tümörü sınıflandırmasına yönelik yeni bir yaklaşım öneriyoruz. Veri ön işleme sürecinde öncelikle veri, one-hot kodlama yöntemiyle ikili koda dönüştürülür, daha sonra ise kırpmaya işlemi gerçekleştirilir. Bu işlem ile görüntüde bulunan, gereksiz, herhangi bir özellik içermeyen bölgelerin görüntüden çıkarılması sağlanır. Kırpmaya işleminden sonra görüntüleri veri artırma tekniği kullanarak çoğaltıyoruz[22]. Görüntüler eğitime hazır hale getirildikten sonra, yeniden tasarladığımız ESA modeli ile eğitimi gerçekleştiriyoruz. Sıfırdan bir modeli tasarlamamızın nedeni, bazı sorunlarla karşılaştığım derin öğrenme modelleri yerine daha basit bir ESA modeli kullanmak, aynı zamanda normal bir ESA modelini değiştirerek daha verimli bir model kullanmaktır.

Bu tez çalışmasında MR görüntülerini sınıflandırarak tümör tipini tespit etmek için sıfırdan tasarlanmış bir ESA modelini öneriyoruz. Önerilen model, 6 evrişim ve 2 tam bağlantılı katman olmak üzere toplam 8 katmanlı bir ESA mimarisinden oluşmaktadır. Her evrişim katmanından sonra evrişimi hızlandırmak ve kolaylaştırmak için bir batch normalization (toplu normalleştirme) katmanı eklenmiştir. Modelin aşırı öğrenmesini engellemek için her tam bağlı katmandan sonra bir dropout (bırakma) katmanı eklendi. Sıfırdan bir ESA ağı tasarlamamızın amacı, daha hızlı ve yüksek doğrulukla sınıflandırmayı gerçekleştirebilecek basit ama etkili bir ağ geliştirmektir.

1.1. Tezin Amacı

Bu tezin amacı, beyin MR görüntülerindeki tümörleri otomatik olarak tespit etmek için derin öğrenme yöntemlerini geliştirmek ve uygulamaktır. Bu yöntemler, tümörleri hızlı ve hassas bir şekilde tanımlayarak tıbbi teşhis ve tedavi süreçlerini iyileştirmeyi amaçlamaktadır. Beyin tümörlerinin tespitinde derin öğrenme yöntemlerinin kullanılmasının amacı, MR görüntülerinden tümör tespitini otomatikleştirmek, uzmanların yoğunluğunu azaltmak, hastalığın teşhis süresini kısaltmak ve uzmanlar tarafından yapılabilecek olası hataları önlemektir. Derin öğrenme algoritmaları, büyük miktarda veriyi analiz ederek, belirli desenleri tanımlama ve algılama yeteneğine sahiptir. Beyin taramaları gibi görüntüleme yöntemlerinden elde edilen verileri kullanarak, bu algoritmalar tümörleri belirleme ve sınıflandırma konusunda uzmanlardan daha hassas olabilir. Beyin tümörlerinin erken teşhisi, tedavi ve sağkalım oranlarını önemli ölçüde artırabilir. Derin öğrenme yöntemleri, belirli tümör belirteçlerini veya özelliklerini tanımlamak için öğrenme yeteneğine sahip olduğundan, tümörlerin daha küçük boyutlarda bile tespit edilmesine yardımcı olabilir. Derin öğrenme algoritmaları, doktorlara tümörleri tespit etme ve teşhis etme sürecinde yardımcı olabilir. Özellikle büyük veri kümeleriyle eğitildiklerinde, bu algoritmaların tümör taramaları üzerindeki etkinliği artar. Bu da doktorların daha doğru ve hızlı teşhisler yapmalarına olanak tanır. Derin öğrenme yöntemlerinin beyin tümörlerinin tespitinde kullanılması, teşhis sürecini iyileştirmeye, tedaviye yönelik daha etkili stratejiler geliştirmeye ve sonuçta hastaların sağkalımını artırmaya yardımcı olabilir. Bu tezin amacı çalışmalara katkı sağlamak ve bu alanda yeni yöntemler geliştirerek başarı oranını arttırmaktır.

1.2. Tezin Katkıları

Bu tez çalışmasında, derin öğrenme yöntemlerinin beyin tümörlerini tespit etme konusundaki etkinliği incelenmektedir. Yapılan çalışmaların sonuçları, derin öğrenme algoritmalarının geleneksel teşhis yöntemlerine kıyasla daha yüksek hassasiyet ve doğruluk sağlayıp sağlamadığı araştırılmaktadır. Beyin tümörlerinin tespitinde derin öğrenme yöntemlerinin kullanılmasının amacı, MR görüntülerinden tümör tespitini otomatikleştirmek, uzmanların iş yükünü azaltmak, hastalığın teşhis süresini kısaltmak ve uzmanların yapabileceği hataları önlemektir. Bu süreç iki aşamada gerçekleşir. İlk aşamada beyin MR görüntüsünde bulunan tümörün yeri, büyüklüğü ve sınırları (bölütleme) tespit edilir. İkinci aşamada ise tümörün tipi belirlenir. Beyin tümörleri üç tiptir; glioma, menenjiyom ve hipofiz. Literatürde beyin MR görüntülerinden tümör tespiti üzerine birçok çalışma yapılmıştır. Son yıllarda derin öğrenme yöntemleri yüksek doğruluk elde ederek beyin tümörü tespitinde ümit verici sonuçlar

göstermiştir. Ancak hala geliştirilmesi gereken çok nokta bulunmaktadır.

Güncel yöntemler incelendiğinde beyin MR görüntüsünde tümörün sınıflandırılması işlemini yüksek bir başarı oranı ile yapmalarına rağmen tümör bölütleme işleminde başarı oranı hala düşüktür. Bu sorunun temel nedeni, tümörün olduğu bölgeleri ayırt etmek için çok fazla özelliğin olmaması ve tümör bölgelerini ayıran sınırların belirsiz olması. Ayrıca tam tümör ve genişleyen tümör gibi bölgeler yüksek bir başarı oranı ile tespit edilebiliyorken, çekirdek (nekroz) tümör gibi çok küçük bir alanı kaplayan bölgeyi tespit etme oranı oldukça düşüktür. MR görüntülerinden derin öğrenme yöntemleri kullanarak tümör tespitinde karşılaşılan diğer önemli sorunlardan biride veri setindeki sınıf dengesizliğidir. Örneğin veri setinde glioma, menenjiyom ve hipofiz tümör tiplerini içeren görüntü sayısı eşit olmayabilir. Bu durum, derin öğrenme gibi yöntemlerin performansını olumsuz etkileyebilir, çünkü model, daha fazla örneklenmiş sınıflara karşı daha az örneklenmiş sınıfları tanımakta zorlanabilir. Bu tez çalışmasında bu sorunları aşmak için veri arttırma, hypeparametre iyileştirme ve modelin başarısını ölçen accuracy (doğruluk) ile beraber kesinlik, duyarlılık (recall), F1 puanı gibi sınıf dengesizliğine daha dayanıklı metrikler tercih edilmiştir.

Bu tez çalışmasında MR görüntülerinden derin öğrenme yöntemlerini kullanarak beyin tümörü tespiti iki aşamada gerçekleştirilmektedir. İlk aşamada MR görüntülerinden beyin tümörü segmentasyonu için hibrit bir DenseNet121-UNet mimarisi önerilmektedir. Bu çalışmada BraTS2019 veri seti kullanılmış olup, modelin performansı DSC(Dice Similarity Coefficient) ile ölçülmüştür. Veri seti eğitimden öne ön işleme sürecine tabi tutulmuş ve görüntüler tümörün boyutuna göre yamalara bölünmüştür. Bu şekilde hem eğitim süresinin kısaltılması hem de modelin başarısının arttırılması amaçlanmıştır. Tez çalışmasının ikinci aşamasında sınıflandırma işlemi için sıfırdan bir CNN modeli tasarlanmıştır. Önerilen model, altı evrişim ve iki tamamen bağlantılı katman olmak üzere 8 katmanlı bir CNN ağıdır. Her evrişim katmanından sonra, modeli hızlandırmak ve kolaylaştırmak için bir toplu normalleştirme katmanı eklenmiştir. Modelin aşırı uyumunu önlemek için tamamen bağlı katmanlardan sonra bırakma katmanı kullanıldı. Sıfırdan CNN tabanlı bir ağ tasarlamamanın amacı, sınıflandırma işlemini hızlı ve yüksek doğrulukla gerçekleştirebilen basit ama etkili bir ağ geliştirmektir.

Bu tez çalışmasının temel katkıları aşağıda maddeler halinde açıklanmıştır:

- Segmentasyon işlemi için görüntüleri yamalara ayırarak eğittiğimiz için eğitim süresi normalden çok daha kısa sürmüştür.
- Veri setini veri arttırma tekniklerini kullanarak çoğalttık ve veri ön işleme yaparak sınıf dengesizliği sorununu en aza indirdik.
- Beyin tümörü segmentasyonu için daha önce literatürde önerilmemiş hibrit bir model önerilmiştir.

- Tam tümör, genişleyen tümör ve çekirdek tümör bölgeleri literatürdeki benzer çalışmalara göre, daha yüksek bir başarı oranı ile tespit edilmiştir.
- MR görüntüleri kullanarak beyin tümörünün sınıflandırılması için sıfırdan CNN tabanlı bir model tasarlandı.
- Beyin tümörünün sınıflandırılması için önerilen modelin hiper parametreleri iyileştirilerek performansı arttırılmıştır.
- Beyin tümörünün sınıflandırılması literatürdeki benzer çalışmalara göre oldukça yüksek bir başarı oranı ile gerçekleştirilmiştir.

1.3. Tezin Yapısı

Bu tez çalışmasının 2. Bölümünde literatür taraması yer almaktadır. Mevcut literatürdeki bilgileri, benzer çalışmaları ve ilgili araştırmaları kapsayan bir bölümdür. Bu bölümde, tümör segmentasyonu ve tümör sınıflandırması ile ilgili çalışmalar ayrı başlıklar altında incelenmiştir. Çalışmanın 3. Bölümünde, araştırma tasarımını, veri toplama yöntemlerini ve analiz tekniklerini açıklayan materyal ve metot yer almaktadır. Bu bölümde araştırmanın nasıl yapıldığı bu çalışmada kullanılan derin öğrenme yöntemleri detaylı bir şekilde açıklanmıştır. Bölüm 4'te bu tez çalışmasında kullanılan veri setleri ile ilgili bilgiler bulunmaktadır. Ayrıca veri önleme sürecinde kullanılan teknikler ve performans değerlendirme metrikleri hakkında özet bilgilere yer verilmiştir. 5. Bölümde, bu tez çalışmasında geliştirilen veya önerilen modeller detaylı olarak açıklanmıştır. Bu modellerin geliştirilme süreçleri, veri ön işleme adımları, kullanılan parametreler, değerlendirme metrikleri ve uygulamaların sonuçları bu bölümde anlatılmıştır. Çalışmanın 6. Bölümünde tez sürecinde yapılan tüm çalışmaların genel sonuçlarına yer verilmiştir. Bu bölümde araştırmanın ana sonuçları özetlenmiş ve çalışmanın genel önemini vurgulanmıştır.

2. LİTERATÜR TARAMASI

Beyin tümörlerini tespit etmek için manyetik rezonans görüntüleme (MRI) ve bilgisayarlı tomografi (CT) gibi görüntüleme teknikleri, derin öğrenme yöntemleri ile kullanılarak birçok çalışma yapılmıştır. Radyologlar tarafından yapılan beyin tümör tespiti genel olarak iki aşamadan oluşmaktadır; birinci aşamada tümörün yeri, büyüklüğü, boyutları belirlenir, daha sonra ikinci aşamada ise tümörün türü belirlenir. Ancak literatür incelendiğinde yapılan çalışmalarda bu sürecin baz alındığı söylenemez. Bazı çalışmalarda tümör segmentasyonu (tümörün yeri, boyutlarının belirlenmesi) yapılırken, bazı çalışmalarda tümör tiplerinin sınıflandırma işlemi yapılmaktadır[16]. Bazı çalışmalarda ise sadece tümör var veya tümör yok şeklinde ikili sınıflandırma işlemi yapılmaktadır. Tümör tespitini uçtan uca yapan çalışmalar literatürde pek bulunmamaktadır. Bu nedenle literatür taraması yaparken çalışmaları ayrı başlıklar altında incelemenin daha doğru olacağına karar verildi.

Beyin tümörü tespiti ve sınıflandırması için kullanılan MRI (Manyetik Rezonans Görüntüleme), CT (Bilgisayarlı Tomografi), PET (Pozitron Emisyon Tomografisi) ve diğerleri gibi çeşitli tıbbi görüntüleme yöntemlerine ilişkin mevcut literatürü taradık. Her yöntemin güçlü yönlerini ve sınırlamalarını anlamak, uygun veri kaynaklarını ve özelliklerini seçmek için çok önemlidir. Bu nedenle farklı tıbbi görüntüleme teknikleri kullanılan çalışmaları inceledik. Ayrıca beyin tümörü sınıflandırması için tıbbi görüntülere uygulanan farklı özellik çıkarma yöntemleri araştırıldı. Bu, doku analizi, şekil tanımlayıcılar ve yoğunluğa dayalı özellikler gibi geleneksel tekniklerin yanı sıra derin öğrenme tabanlı özellik çıkarma gibi daha gelişmiş yöntemleri içermektedir. Tıbbi görüntü analizi için özel olarak tasarlanmış derin öğrenme mimarilerindeki son gelişmeler keşfedilmeye çalışıldı. U-Net, SegNet ve 3D CNN'ler gibi beyin tümörü segmentasyonu ve sınıflandırma görevleri için özel olarak tasarlanmış mimariler incelenip ve bunların geleneksel yöntemlerle karşılaştırıldığında performanslarını gözlemlendi.

Derin öğrenme modellerinde başarıyı arttırmanın en önemli etkenlerinden biri de veri arttırma yöntemleridir[23]. Model genellemesini ve sağlamlığını geliştirmek için tıbbi görüntüleme verilerini artırma teknikleri araştırıldı. Eğitim veri setinin çeşitliliğini arttırmak için döndürme, ölçekleme, çevirme ve elastik dönüşümler gibi veri büyütme yöntemleri yaygın olarak kullanılmaktadır. Literatürde yapılan çalışmalarda kullanılan veri arttırma tekniklerini detaylı bir şekilde araştırıldı. Literatür taramasının en önemli konularından biri de eğitilen modellerin başarısını değerlendirmek için kullanılan metriklerdir. Segmentasyon ve sınıflandırma görevleri için duyarlılık, özgüllük, doğruluk, ROC eğrisi altındaki alan (AUC) ve Zar benzerlik katsayısı (DSC) dahil olmak üzere derin öğrenme algoritmalarının değerlendirilmesinde kullanılan standart performans değerlendirme ölçümleri incelendi. Son olarak dengesiz veri kümelerinin işlenmesi, derin öğrenme modellerinin yorumlana bilirliliği,

klirik iş akışlarıyla entegrasyon ve kaynakların kısıtlı olduđu ortamlarda devreye alma gibi beyin tümörü tespitindeki zorlukları ve açık araştırma soruları belirlendi. Bu zorlukların üstesinden gelmek için yapılan bu tez çalışmasında kullanılan yöntemler araştırıldı.

2.1. Beyin Tümörü Segmentasyonu

Son zamanlarda MR görüntülerin beyin tümör tespiti için birçok segmentasyon mimarisi önerilmiştir. Konum, görünüm, boyut ve yoğunluk dağılımındaki çok çeşitlilik nedeniyle, otomatik ve kesin beyin tümörü segmentasyonu zorlu bir iştir. Huang ve arkadaşları bu sorunu çözmek için bilgisayar destekli uyarlanabilir bir iyileştirilmiş sinir ağına dayalı beyin tümörü segmentasyon sistemi (GammaNet) önermişlerdir. Geleneksel gama düzeltmesinden ilham alan bir yoğunluğun değişmezliğini gerçekleştirmek ve önemli bölgelere odaklanmak için bu modeli önermişlerdir. Deneysel sonuçlar Dice Similarity Coefficient (DSC), Sensitivity ve Intersection of Union (IoU) değerlerinin sırası ile %85,8, %87,8 ve %80,31 olduğunu göstermektedir[24]. Makine öğrenimi ve derin öğrenmenin kapsamı da bazı araştırmacılar tarafından beyin tümörü segmentasyonu alanında araştırılmaktadır. Elde edilen sonuçlar da cesaret verici ve gelecek çalışmalar açısından motive edicidir. Kısıtlı veri setlerinin olması aynı zamanda derin öğrenme segmentasyonundaki zorluklardan biridir. Tripathi ve arkadaşları, tümör segmentasyonu için OKM, yani Otsu K-megansa metodlarının birlikte kullanılmasını öneren bir çalışma yapmışlardır. Bu çalışmada T2 ve FLAIR MR sekanslarını kullanmışlardır. Önerilen yöntemin nihai çıktısı, genişleyen tümör, nekroz, genişlemeyen tümör ve ödemi içeren bölümlerin segmente edilmiş halidir. Önerilen algoritma, eğitim ve büyük boyutlu veritabanları içermediğinden sağlam ve etkili bir sonuç elde edilmiştir[12].

Klasik segmentasyon yöntemleri uygulanırken bazı sınırlamalar, beyindeki homojen olmayan yoğunluk, karmaşık fizyolojik yapı ve doku sınırlarının bulanık olması gibi sorunlar genellikle tatmin edici olmayan sonuçlara yol açar. Lei ve arkadaşları bu sorunu çözmek için bu sorunları çözmek için MR görüntülerinde beyin tümörü segmentasyonu seyrek kısıtlı seviye seti yöntemi ile gerçekleştirmektedir. Bu yöntem ile beyin tümör görüntülerinden yararlanılarak beyin tümörlerinin şeklinin ortak özelliklerini ortaya çıkaran seyrek bir görüntü oluşturulur. Önerilen yöntem kullanılarak BraTS 2017 veri seti ile ortalama %96,20 doğruluk değeri elde edilmektedir[25]. Barzegar ve Jamzad [5] etiketi birleştiren yarı denetimli olasılıksal grafik tabanlı yöntem parametrik bir grafik üzerinde yayılma ve yama tabanlı segmentasyon için bir öneride bulunuyor. Önerilen yaklaşımı değerlendirmek için düşük ve yüksek dereceli glioma tümörleri dahil olmak üzere kamuya açık BraTS veri kümelerine uygulanmıştır. Deneysel sonuçlar, önerilen metodun doğru segmentasyon sonuçlarına sahip olduğunu göstermektedir[26]. Glioma, düzensiz şekli ve bulanık sınırları nedeniyle tanısı en zor beyin

tümörlerinden biridir. Glioma beyin tümörlerinin otomatik segmentasyonu, yapılarındaki önemli farklılıklar nedeniyle zorlu bir problemdir. Aglahari ve arkadaşları, beyin tümörlerinin MRI görüntülerinden otomatik olarak segmentasyonu için geliştirilmiş UNet tabanlı mimariler kullanan bir yaklaşım önermişlerdir. Önerilen modelin mimarisi hem yerel özelliklerden hem de küresel özelliklerden aynı anda yararlanıyor. Ayrıca, orijinal UNet'ten farklı olarak, önerdikleri mimari daha az parametreye sahiptir. Önerilen model BraTS'2018 veri seti ile değerlendirilerek iyi sonuçlar vermiş ve hesaplama maliyeti diğer yöntemlere göre daha düşük çıkmıştır[27].

Beyin tümörlerinin doğru otomatik segmentasyonu hem hayatta kalma olasılığını artırır hem de tedavi sürecini daha hızlı ve verimli hale getirir. Evrişimli Sinir Ağları, sağlık alanında görüntü değerlendirmeleri için popüler bir otomatik yaklaşımdır. ESA, klasik makine öğrenimi algoritmalarına karşı daha iyi sonuçlar sağlayabilir. Ahmad ve arkadaşları, birden fazla beyin MRI etiketinden gelen bağlamsal bilgileri birleştirmek için farklı bir yaklaşım sunmuşlardır. Beyin tümörü segmentasyonunun sorunlarını çözmek için, popüler 3D U-Net mimarisi üzerinde artık yoğun bağlantıları ile evrişim katmanının çoklu hızlarının birleşiminden oluşan farklı bir strateji uygulamışlardır. Önerilen yaklaşımlarını eğitmek ve doğrulamak için BraTS 2019'un farklı veri kümelerini kullanmışlardır[28]. Son zamanlarda yapılan araştırmalarda, beyin tümörü alt bölgelerinin segmentasyon performansını artırmak için çeşitli sinir ağı tabanlı mimariler önermektedir. Rehman ve arkadaşları, beyin tümörü segmentasyonu araştırmalarına katkıda bulunmak için bir 2 boyutlu görüntü segmentasyon yöntemi olan BU-Net'i önermektedir. Temel U-Net mimarisinde özelleştirilmiş kayıp fonksiyonuyla birlikte artık genişletilmiş atlama (RES) (Residual extended skip ve geniş bağlam (WC) wide context kullanılır. Özelleştirmeler, geçerli alıcı alanı artırarak daha çeşitli özelliklerin bulunmasına katkıda bulunur[29]. Derin sinir ağların popüleritesi tıbbi görüntü konusunda araştırmacıların dikkatini çekmektedir. Derin sinir ağları beyin tümörlerinin segmentasyonunda çok başarılı sonuçlar göstermektedir[30]. Kodlayıcı ve kod çözücünden oluşan UNet mimarisi, tıbbi görüntü işleme alanındaki performansından dolayı popülerlik kazanmıştır. Derin sinir ağları, ağırlıkları olan büyük veri setleri ile önceden eğitildiğinde performans önemli ölçüde artar[31].

BraTS 2019 veri seti analiz edildiğinde, tüm etiketlerin aynı sayıda olmadığı görülmektedir. Örneğin, tüm MR görüntülerinde genişleyen tümör yoktur ve bu diğer tüm MR görüntü sınıfları için de geçerlidir. Bu durum yaygın olarak görülen sınıf dengesizliği sorununun ortaya çıkmasına neden olur. Benzer şekilde MR görüntülerindeki tüm tümör görüntülerinin alanlarının boyutu da farklıdır. Bazı tümör alanları daha büyüktür (tam tümör gibi), diğerleri tümör tiplerinin (nekroz, genişleyen tümör gibi) kapladığı alan ise daha küçüktür daha büyüktür. Böyle durumlarda tüm tümör tiplerinde aynı başarıyı yakalamak zor olabilir, bazı tümör

tiplerinin segmentasyonu yüksek başarı oranı ile gerçekleştirilirken, nekroz gibi küçük bir alan kaplayan tümör tiplerinin segmentasyonu daha zordur. Her ne kadar literatürde bu konuda bir çok çalışma yapılmış olsa da, hala nekroz ve genişleyen tümör alanlarının segmentasyonu ile ilgili iyileştirilmesi gereken noktalar bulunmaktadır[32].

2.2. Beyin Tümörü Sınıflandırma

Beyin tümörü sınıflandırmasına yönelik araştırmalar, tıbbi görüntü işleme ve derin öğrenme alanında önemli bir ilgi alanı olmuştur. Literatürde beyin tümörü sınıflandırma ile ilgili birçok çalışma bulunmaktadır. Bazı çalışmalar yalnızca tümörün varlığını tespit etmeye odaklanırken bazılarında ise tümörün türü ve sınırları da belirlenmeye çalışmıştır. Birkaç yıl öncesine kadar ağırlıklı olarak makine öğrenimi yöntemleri kullanılırken günümüzde daha çok derin öğrenme algoritmaları kullanılmaktadır. Makine öğrenmesi yöntemleriyle belli bir noktaya kadar başarılı sonuçlar elde edildi. Daha sonra yapay sinir ağlarının gelişmesiyle görüntü sınıflandırılmasında evrimsel sinir ağları kullanılmaya başlandı. ESA ağları makine öğrenimi yöntemleri ile karşılaştırıldığında başarı oranının ciddi oranda yükseldiği görüldü. Günümüzde ESA tabanlı modeller beyin tümörü tespiti ile ilgili birçok çalışmada kullanılmaktadır. Bazı araştırmacılar normal CNN ağlarını değiştirerek modeli kullanmayı tercih ederken bazı araştırmacılar ise derin sinir ağlarını kullanmayı tercih etmektedir. Hepsinin ortak hedefi beyin tümörü tespitinde başarı oranını daha yükseklerle çıkarmaktır.

ESA, görüntü işleme için en yaygın kullanılan derin öğrenme algoritmalarından biridir. Khan ve arkadaşları, beyin MR görüntülerini sınıflandırmak için ESA ağını kullandı. Sıfırdan oluşturdukları CNN ağını, sadece MR görüntülerinde tümör olup olmadığını göstermek için transfer öğrenme yöntemiyle eğittikleri VGG16, ResNet50 ve InceptionV3 modellerini kullandılar. Her ne kadar çalışmanın sonuçları küçük bir veri seti ile test edilmiş olsa da geliştirdikleri model ile yüksek bir başarı oranı elde ettiler. Önerdikleri yaklaşım %100 Accuracy, diğer ESA modelleri ise sırasıyla VGG16 %96, ResNet50 %89 ve Inceptionv3 %75 Accuracy oranı göstermiştir[33]. Sajjad ve arkadaşları, beyin tümörü türlerini tespit etmek için bir ESA ağını değiştirdi ve transfer öğrenme yöntemiyle eğitti. Görüntüleri eğitmeden önce veri artırma uygulayarak çoğalttılar. Daha sonra hem çoğaltılmış veriler hem de ham veriler ile model eğitildi ve sonuçları karşılaştırıldı. Verileri artırmadan önce meningioma, glioma ve pituitary tümör tipleri için sınıflandırma Accuracy değerleri sırasıyla %90.22, %93.12 ve %89.08 olarak gerçekleşmiştir. Veri artırma tekniği uygulanan veri seti ile model eğitilince meningioma, glioma ve pituitary için sırasıyla %94, %96.14 ve %93.21 Accuracy oranları elde edilmiştir[34]. Sonuçlar veri artırma tekniklerinin doğru uygulandığında modelin başarısını olumlu yönde etkilediğini göstermektedir.

Arbane ve arkadaşları beyin MR görüntülerinden tümör tespiti üzerine yaptıkları çalışmada ResNet, Xception, MobilNetV2 modellerini transfer öğrenmesi yöntemi kullanarak eğitmişlerdir. Çalışma sonucunda en yüksek Accuracy değeri MobilNetV2 modeli ile elde edildi. Bu çalışmada beyin tümörü tespiti %98,24 Accuracy oranı ile gerçekleştirildi[35]. Abbood ve arkadaşları 3000 MR görüntüsü üzerinde yaptıkları çalışmada 4 tane farklı derin öğrenme modellerinden elde ettikleri sonuçları karşılaştırmışlardır. Yaptıkları bu çalışmada, AlexNet, VGG16, GoogleNet ve ResNet50 modellerini kullanmışlardır. Bu çalışmada en yüksek doğruluk ResNet50 ile %95,8 elde edilmiştir[36]. Saleh ve arkadaşları aynı veri seti ile önceden eğitilmiş beş ESA modelini kullandı: Xception, ResNet50, InceptionV3, VGG16 ve MobileNet. F1 skorları sırasıyla %98.75, %98.50, %98.00, %97.50 ve %97.25 olarak belirlendi. En yüksek doğruluk değeri Xception modeli ile elde edildi[37]. Yapılan başka bir çalışmada, MR görüntülerinden beyin tümörü teşhisi için ResNet50 iyileştirildi. Elde edilen sonuçlar, AlexNet, Resnet50, Densenet201, InceptionV3 ve GoogleNet modelleri ile karşılaştırıldı. Araştırma sonucunda en yüksek Accuracy değeri, ResNet modelini iyileştirilmiş hali ile elde edilmiştir[38].

Çınar ve Yıldırım, ResNet50 modelini değiştirerek MR görüntülerinden beyin tümörü teşhisi için eğitti. İyileştirdikleri bu modelden elde ettikleri sonuçları diğer derin öğrenme modelleri, AlexNet, Resnet50, Densenet201, InceptionV3 ve GoogleNet ile karşılaştırdılar. Araştırma sonucunda en yüksek doğruluk değeri önerilen yöntemle elde edildi[39]. Toğaçar ve arkadaşları, BrainMRNet adında yeni bir ESA mimarisi önermektedir. Önerdikleri mimari, artık ağ ve hiper sütun tekniği kullanan dikkat modülü tabanlı bir yaklaşımdır. Yaptıkları çalışmada, ilk aşamada görüntüleri veri artırma teknikleri kullanarak çoğalttılar. Daha sonra veri ön işleme süreci ile eğitime hazır hale getirdikleri görüntüler ile önerdikleri ESA mimarisini eğittiler. Çalışma sonucunda önerilen model ile %96.05 doğruluk oranı elde etmişlerdir. Sonuçlarını önceden eğitilmiş AlexNet, GoogleNet ve VGG16 ile karşılaştırdılar[40]. Swati ve arkadaşları, diğer çalışmalardan farklı olarak daha büyük verilerle çalışmışlardır. Transfer öğrenmeye dayalı blok bazında ince ayar stratejisi kullanarak önceden eğitilmiş derin ESA modelini kullanmayı önermişlerdir. Önerilen yöntem minimum düzeyde ön işleme tabi tutuldu ve beş kat çaprazlama altında ortalama %94,82 doğruluk elde edildi. Elde ettikleri diğer derin öğrenme modelleri ile de karşılaştırarak elde ettikleri doğruluk oranının başarısını göstermişlerdir[6].

Ayadi ve arkadaşları yaptıkları çalışmada üç beyin tipini (glioma, meningioma ve pituitary) sınıflandırmayı amaçlamışlardır. Önerilen modelleri, MRI kalitesini iyileştirmek için ve ayırt edici bir özellik seti oluşturmak normalleştirmeyi, yoğun hızlandırılmış sağlam özellikleri ve gradyan yaklaşımlarının histogramını kullanır. Çalışma sonucunda %90.27 doğruluk oranı elde ettiler. Pei ve arkadaşları yeni bir ESA modeli geliştirdi ve MR görüntüleri

ile eğitti. Önerilen yaklaşım iki aşamadan oluşmaktadır. İlk aşamada farklı veri işleme tekniklerini kullanarak veri ön işleme sürecini gerçekleştirmişlerdir. İkinci aşamada eğitim için hazırlanan görseller modele girdi olarak verilmiştir. Glioma, meningioma ve pituitary tümör tiplerini sınıflandırdıkları çalışmada ortalama %94.39 doğruluk oranına ulaşmışlardır[41]. Ghosal ve arkadaşları, MR görüntülerinden beyin tümörü sınıflandırması için görüntü örneklerinin CNN tabanlı bir Sıkıştırma ve Uyarılma ResNet modeline aktarıldığı otomatik bir yaklaşım önermektedir. İlk olarak modeli görüntüde veri artırma olmadan eğittiler. Daha sonra verileri artırarak modeli tekrar eğittiler. Veri artırmadan önce ortalama %89,93 doğruluk elde ettiler. Sonrasında veri artırmayla ortalama %93,83 doğruluk elde ettiler. Her tümör tipi için glioma, meningioma ve pituitary için sırasıyla, %98.67, %91.81 ve %91.03 doğruluk oranları elde etmişlerdir[42].



3. MATERYAL VE METOT

MR görüntüleri kullanılarak beyin tümörü tespiti üzerine tez yazmak hem ilgili tıbbi görüntüleme tekniklerinin hem de analiz için kullanılan hesaplamalı yöntemlerin kapsamlı bir şekilde anlaşılmasını gerektirir. Tez çalışmasında "Materyal ve Metot" bölümü, araştırmanın temelini oluşturur ve çalışmanın yöntemini, kullanılan veri kaynaklarını ve analiz tekniklerini açıklar. Bu bölüm, tezimizde kullanacağımız materyal ve metodolojiye ilişkin detaylı bilgiler içermektedir. Bu bölüm, MR görüntüleri kullanılarak beyin tümörü tespitinde kullanılan materyaller, veriler ve metodolojiler hakkında yapılandırılmış bir genel bakış sunmaktadır.

3.1. Beyin Tümörü Çeşitleri, Teşhis Yöntemleri ve Görüntüleme Teknikleri

Bu tez çalışmasında en yaygın görülen glioma, meningioma ve pituitary histolojik tümörleri inceleyeceğiz. Gliomalar, glial hücrelerden kaynaklanır ve astrositomları, oligodendrogliomaları, ependimomaları ve glioblastomaları içerir. Meningioma beyni ve omuriliği kaplayan koruyucu zarlar olan meninkslerden kaynaklanır. Pituitary beynin tabanında yer alan hipofiz bezinden kaynaklanır. Tümörler genellikle saldırganlıklarına ve yayılma olasılıklarına (malignite) göre derecelendirilir. Dünya Sağlık Örgütü (DSÖ) sınıflandırma sistemi, tümörleri 1'den 4'e kadar derecelendirir; daha yüksek dereceler, daha tümörün daha tehlikeli olduğunu gösterir[2]. Derece I ve II tümörler genellikle düşük dereceli veya iyi huylu olarak kabul edilir. Derece III ve IV tümörler yüksek dereceli veya kötü huyludur; derece IV glioblastoma en agresif ve en ölümcül beyin tümörlerinden biridir. Beyin tümörlerinin sınıflandırılmasını anlamak, doğru tanı, prognozun belirlenmesi ve tedavi planlaması için gereklidir. Her beyin tümörü türü, ameliyat, radyasyon terapisi, kemoterapi, hedefe yönelik tedavi veya bu yöntemlerin bir kombinasyonu dahil olmak üzere farklı yönetim yaklaşımları gerektirebilir.

Beyin tümörlerinin teşhisi, klinik belirtiler, fizik muayene bulguları ve görüntüleme çalışmaları kullanılarak yapılır. Hastanın nörolojik durumu, doktor tarafından değerlendirilir. Nörolojik muayene, beyin fonksiyonlarının ve sinir sistemi işlevlerinin değerlendirilmesini içerir. Manyetik rezonans görüntüleme (MRG) ve bilgisayarlı tomografi (BT) en yaygın kullanılan görüntüleme yöntemleridir[43]. MRG, beyin dokusunun detaylı bir görüntüsünü sağlar ve tümörlerin lokasyonunu, büyüklüğünü ve karakteristiklerini belirlemeye yardımcı olur. BT, beyin tümörlerinin büyüklüğünü, şeklini ve kafatası kemiklerinde herhangi bir değişikliği görselleştirmek için kullanılır. Teşhis yöntemleri, birlikte veya ayrı ayrı kullanılarak, beyin tümörlerinin doğru bir şekilde tanımlanmasına ve sınıflandırılmasına yardımcı olur. Tanı, hastanın semptomlarına, tümörün büyüklüğüne, konumuna ve diğer faktörlere bağlı olarak

belirlenir.

Manyetik rezonans görüntüleme, manyetik alanlar ve radyo dalgaları kullanarak detaylı görüntüler elde etmek için kullanılan bir tıbbi görüntüleme tekniğidir. Beyin tümörlerinin teşhisi ve karakterizasyonunda yaygın olarak kullanılır. Farklı MRG sekansları, tümörlerin morfolojisini, kanama varlığını, nekroz ve ödem gibi karakteristik özellikleri değerlendirmeye yardımcı olur[44]. Bilgisayarlı tomografi, X-ışınları kullanarak kesitsel görüntüler elde etmek için kullanılan bir görüntüleme tekniğidir. Beyin tümörlerinin teşhisi, yerleşimi ve boyutları hakkında bilgi sağlar. Kontrastlı BT taramaları, tümörlerin vaskülarizasyonunu ve çevre dokularla olan etkileşimini daha iyi gösterir. Bu görüntüleme teknikleri, beyin tümörlerini tespit etmek, sınıflandırmak, boyutunu belirlemek ve tedavi planlaması yapmak için önemli araçlardır.

3.1.1 Beyin Tümörü ve Çeşitleri

Beyin tümörleri, merkezi sinir sisteminde (beyin ve omurilikte) oluşan anormal hücre büyümeleridir. Bu tümörler, çeşitli kriterlere göre sınıflandırılabilirler. Bunlar arasında hücresel köken, büyüme hızı, tümörün lokalizasyonu ve histolojik özellikler bulunur. En yaygın beyin tümörü sınıflandırma sistemleri, Dünya Sağlık Örgütü'nün (DSÖ) sınıflandırması ve tümörün histolojik özelliklerine dayanan DSÖ sınıflandırmasıdır. Beyin tümörleri, beyindeki konumları, histolojik özellikleri (hücre tipi ve derecesi) ve davranışları (iyi huylu veya kötü huylu) dahil olmak üzere çeşitli kriterlere göre sınıflandırılabilir. Birincil tümörler beyinden veya onu çevreleyen dokulardan kaynaklanır. Metastatik tümörler olarak da bilinen ikincil tümörler, akciğerler, göğüs veya deri gibi vücudun başka bir kısmından beyne yayılan (metastaz yapan) kanser hücrelerinden kaynaklanır. Supratentoryal tümörleri beynin üst kısmında, tentorium serebelli üzerinde meydana gelir. Bunlar serebral hemisfer tümörlerini içerir. İnfratentoryal tümörler beynin alt kısmında, tentorium serebelli'nin altında meydana gelir. Beyincik, beyin sapı ve dördüncü ventrikül tümörlerini içerirler.

3.1.2 Görüntüleme Teknikleri

Görüntüleme teknikleri, çeşitli nesnelerin veya olayların görüntülerini elde etmek için kullanılan yöntemlerdir. Görüntüleme teknikleri, tıbbi teşhislerden sanat ve film endüstrisine kadar geniş bir yelpazede kullanılmaktadır[45]. Teknolojideki ilerlemelerle birlikte, yeni ve geliştirilmiş görüntüleme teknikleri sürekli olarak geliştirilmekte ve kullanılmaktadır. En yaygın kullanılan bazı görüntüleme teknikleri aşağıda açıklanmıştır.

- *Magnetic Resonance Imaging (MRI)*, manyetik rezonans görüntüleme (MRI), vücudun iç yapılarının ayrıntılı görüntülerini oluşturmak için güçlü manyetik alanlar ve radyo dalgalarını kullanan, invazif olmayan bir tıbbi görüntüleme tekniğidir. MR, üstün yumuşak doku kontrastı ve çok düzlemli görüntüleme yetenekleri nedeniyle beyin tümörlerini değerlendirmek için tercih edilen bir görüntüleme yöntemidir[46]. Beyin tümörü değerlendirmesi için T1 ağırlıklı, T2 ağırlıklı, FLAIR (Sıvı Zayıflatılmış İnversiyon Kurtarma), DWI (Diffüzyon Ağırlıklı Görüntüleme) ve kontrastı artırılmış T1 ağırlıklı sekanslar dahil olmak üzere çeşitli MRI sekansları kullanılır. Kontrastlı T1 ağırlıklı MRI, anormal vaskülarite ve kan-beyin bariyeri bozulması alanlarını vurgulayarak beyin tümörlerini tespit etmek ve karakterize etmek için özellikle değerlidir.
- *Computed Tomography (CT)*, bilgisayarlı tomografi (BT) görüntüleme, vücudun kesitsel görüntülerini üretmek için X ışınlarını kullanır. BT, hızlı edinim süresi nedeniyle, özellikle acil durumlarda, beyin tümörü şüphesi olan hastaların değerlendirilmesinde sıklıkla ilk görüntüleme yöntemi olarak kullanılır[46]. Beyin tümörlerinin saptanmasına ve ilk karakterizasyonuna yardımcı olarak intrakraniyal lezyonların boyutu, konumu ve yoğunluğu hakkında değerli bilgiler sağlar. Kontrastlı BT taramaları vaskülarize lezyonların görüntülenmesini artırabilir ve tümörleri diğer intrakraniyal anormalliklerden ayırmaya yardımcı olabilir.
- *Positron Emission Tomography (PET)*, özellikle FDG (florodeoksiglukoz) gibi radyotraktörlerle yapılan PET görüntüleme, beyin tümörlerinin metabolik aktivitesi ve glikoz metabolizması hakkında değerli bilgiler sağlayabilir. Tümör derecesinin karakterize edilmesi, tümör nüksetmesinin tedavi sonrası değişikliklerden ayırt edilmesi ve tedaviye yanıtın değerlendirilmesi için faydalıdır[47].

3.1.3 Beyin Tümörü Segmentasyonu (Bölütme)

Beyin tümörü segmentasyonu, manyetik rezonans görüntüleme (MRI) veya bilgisayarlı tomografi (BT) gibi çeşitli görüntüleme yöntemleriyle elde edilen beyin görüntüleri içindeki tümörlerin sınırlarını tanımlama ve çizme işlemidir[23]. Tıbbi görüntü analizinde, özellikle beyin tümörü hastalarının tanısı, tedavisinin planlanması ve izlenmesinde çok önemli bir adımdır. Beyin tümörü segmentasyonu, tıbbi görüntü analizinde aktif bir araştırma alanıdır ve görüntü işleme teknikleri, makine öğrenme algoritmaları ve hesaplamalı kaynaklarda devam eden gelişmeler, segmentasyon yöntemlerinin doğruluğunu ve verimliliğini artırmaya devam etmektedir.

Derin öğrenme algoritmalarında kullanılan beyin görüntüleri, görüntü kalitesini artırmak, gürültüyü gidermek ve görüntüleri daha ileri analiz için standartlaştırmak üzere önceden işlenir.

Yaygın ön işleme teknikleri arasında yoğunluk normalizasyonu, kafatası sıyırma ve uzaysal normalizasyon bulunur. Beynin farklı bölgelerini karakterize etmek için önceden işlenmiş görüntülerden ilgili özellikler çıkarılır. Bu özellikler yoğunluk, doku, şekil ve mekansal bilgileri içerebilir. Beyin görüntülerini tümör, sağlıklı doku ve arka plan gibi farklı bölgelere veya sınıflara bölmek için çeşitli segmentasyon algoritmaları ve teknikleri uygulanır. Yaygın segmentasyon yöntemleri arasında eşikleme, bölge büyütme, kenar tabanlı yöntemler, kümeleme ve evrişimli sinir ağları (CNN'ler) gibi makine öğrenimi tabanlı yaklaşımlar bulunur.

Bölümlere ayrılmış bölgeler, sonuçları iyileştirmek ve doğruluğu geliştirmek için işlem sonrası adımlardan geçebilir. Bu, segmentasyondaki küçük artefaktları veya düzensizlikleri ortadan kaldırmak için erozyon, genişletme ve yumuşatma gibi morfolojik işlemleri içerebilir. Segmentasyon sonuçlarının doğruluğu, bunların tıp uzmanları tarafından sağlanan temel gerçek açıklamalarıyla karşılaştırılmasıyla değerlendirilir. Dice benzerlik katsayısı, Jaccard indeksi, duyarlılık, özgüllük ve Hausdorff mesafesi gibi metrikler, segmentasyon algoritmalarının performansını değerlendirmek için yaygın olarak kullanılır[48]. Bölümlere ayrılmış tümör bölgeleri, beyin tümörlerinin teşhisine, tedavi planlamasına (örneğin radyasyon terapisi) ve ilerlemenin veya tedaviye yanıtın izlenmesine yardımcı olmak için klinisyenler tarafından analiz edilir.

3.1.4 Beyin Tümörü Sınıflandırma

Beyin tümörü sınıflandırması, beyindeki anormal doku büyümeleri olan beyin tümörlerinin teşhis ve tedavisinde çok önemli bir husustur. Beyin tümörlerinin doğru sınıflandırılması, en uygun tedavi yaklaşımını belirlemek, hasta sonuçlarını tahmin etmek ve tanı ve tedaviyi iyileştirmeyi amaçlayan araştırma çabalarını ilerletmek için gereklidir. Sınıflandırma tipik olarak tümörlerin hücre tipi, beyindeki konumu, büyüme hızı, agresifliği ve genetik belirteçler gibi çeşitli özelliklerine göre sınıflandırılmasını içerir[2]. Beyin tümörü sınıflandırmasında kullanılan bazı yaygın yöntemler şunlardır:

- *Histolojik Sınıflandırma*, bu yöntem, tümörleri, ilgili hücrelerin türü ve büyüme düzenleri de dahil olmak üzere mikroskopik görünümüne göre sınıflandırır. Yaygın histolojik sınıflandırmalar arasında gliomalar (örneğin astrositomlar, oligodendrogliomalar ve glioblastomalar), menenjiyomlar, hipofiz adenomları ve medulloblastomlar bulunur[49].
- *Moleküler Sınıflandırma*, moleküler biyolojideki ilerlemeler, farklı tipte beyin tümörleriyle ilişkili spesifik genetik mutasyonların ve moleküler belirteçlerin tanımlanmasına yol açmıştır. Moleküler sınıflandırma, tümör davranışını tahmin etmeye, tedavi kararlarına rehberlik etmeye ve potansiyel terapötik hedefleri belirlemeye yardımcı olur. Örneğin, IDH

mutasyonları ve MGMT promoteri metilasyon durumu gibi moleküler belirteçler, gliomalar için önemli prognostik göstergelerdir.

- *Görüntüleme Sınıflandırması*, Beyin tümörleri, MR (Manyetik Rezonans Görüntüleme), CT (Bilgisayarlı Tomografi) ve PET (Pozitron Emisyon Tomografisi) gibi çeşitli görüntüleme yöntemlerindeki görünümüne göre de sınıflandırılabilir. Tümör boyutu, lokasyonu, kontrastlanma şekli ve ödem varlığı gibi radyolojik özellikler, farklı tümör tiplerinin ayırt edilmesine ve agresifliklerinin değerlendirilmesine yardımcı olabilir[34].
- *DSÖ Sınıflandırması*, Dünya Sağlık Örgütü (DSÖ), beyin tümörleri için yaygın olarak kullanılan, tümörleri saldırganlıklarına ve prognozlarına göre farklı derecelere (1'den 4'e kadar) kategorize etmek için histolojik ve moleküler özellikleri birleştiren bir sınıflandırma sistemi sağlar[50].

3.2. Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (ESA), derin öğrenme alanında yaygın olarak kullanılan bir yapay sinir ağı türüdür. Evrişimli Sinir Ağları, en yaygın olarak görsel görüntülerin analizinde uygulanan bir derin sinir ağı sınıfıdır[51]. Bilgisayarlı görme, görüntü tanıma ve tıbbi görüntü analizi gibi çeşitli alanlarda devrim yarattılar. ESA'lar özellikle görüntü sınıflandırma, nesne algılama ve görüntü bölümlendirme gibi görevlerde etkilidir. CNN'ler, görüntü sınıflandırma, nesne algılama, anlamsal bölümlendirme ve tıbbi görüntü analizi dahil olmak üzere çeşitli uygulamalarda olağanüstü performans sergilemiştir. Ham girdi verilerinden hiyerarşik özellikleri otomatik olarak öğrenme yetenekleri, onları karmaşık görsel bilgilerin analizinde güçlü araçlar haline getirir. CNN'ler, veriyi hiyerarşik olarak işleyebilme yetenekleri sayesinde özellik çıkarımı ve sınıflandırma gibi görevlerde önemli başarılar elde etmiştir. CNN'ler, genellikle büyük veri setleri üzerinde eğitilir ve gerçek dünya görüntü işleme görevlerinde kullanılmak üzere önceden eğitilmiş ağırlar (pretrained networks) da kullanılabilir. Önceden eğitilmiş ağırlar, yeni bir görev için daha küçük veri setleri üzerinde eğitilmek üzere ayarlanabilir (fine-tuning) veya transfer öğrenme (transfer learning) için kullanılabilir[52]. Bu, CNN'lerin çeşitli uygulamalarda etkili bir şekilde kullanılmasını sağlar, özellikle nesne tanıma, yüz tanıma, tıbbi görüntüleme ve otomatik sürüş gibi alanlarda. Bu bölümde ESA'ların nasıl çalıştığı ve temel bileşenleri genel bir bakış açısıyla açıklanacaktır. Klasik bir ESA mimarisi Şekil 3.1'de gösterilmektedir.



Şekil 3.1. Klasik ESA mimarisi

Evrişimli sinir ağları, bir giriş görüntüsü alan ve görüntüdeki çeşitli özellikleri ayırt eden bir derin öğrenme algoritmasıdır. Görüntüler matris formatına dönüştürülerek ESA ağına verilmektedir. ESA mimarisi evrişim, havuzlama, convolution (evrişim), pooling (havuzlama), non-linearity layer, batch normalization (toplu normalizasyon), dropout(bırakma), flattening (düzleştirme) ve fully connected (tamamen bağlı katman) gibi katmanlardan oluşur[53]. Modelin ana katmanı evrişim katmanıdır. Evrişim katmanı görüntüye belirli sayıda evrişim filtresi uygulayarak özellik haritası çıkarma işlemini gerçekleştirir. ESA ağına verilen girdi matris formunda olduğunda uygulanan filtre de matris formundadır. Genellikle $(a \times b \times c)$ şeklinde filtreler uygulanır. Burada a matrisin yüksekliğini, b genişliğini ve c derinliğini temsil etmektedir[54].

Filtrenin giriş matrisinin üzerine getirilmesiyle özellikler çıkarılır[55]. Görüntüdeki her bir alt bölgeye bazı matematiksel işlemler uygulanarak, görüntünün özellikleri elde edilir. Stride (adım) filtrenin giriş resminin üzerinde kaç basamak kayacağını belirler. Adım ne kadar büyük olursa, özellik haritası o kadar küçük görünecektir. Bir görüntüye filtre uygulandığında çıktı boyutlarından dolayı orijinal görüntüden daha küçük olacaktır. Bunu önlemek için doldurma yöntemi kullanılır. Doldurma işlemi sırasında görüntüye sanki bir çerçeveymiş gibi dört bir yanına sıfırlar eklenir. Filtrenin boyutuna bağlı olarak sıfır eklenen katmanlar artırılabilir[56]. ESA mimarilerindeki diğer önemli bir konu Düzeltilmiş Doğrusal Birim (ReLU) fonksiyonudur. ReLU fonksiyonun işlevi ağı negatif değerlerden kurtarmaktır. ReLU fonksiyonu sıfırdan küçük değerleri sıfır yapar; daha büyük veya ona eşit değerler için sonuç değişmeden kalır.

3.2.1. Girdi Katmanı

Giriş katmanı, Evrişimli Sinir Ağları dahil olmak üzere bir sinir ağının ilk katmanıdır. Birincil işlevi, ham girdi verilerini almak ve daha ileri işlemler için ağ üzerinden iletmektir. ESA'ların görüntü verilerine uygulanması durumunda, giriş katmanı görüntülerin ham piksel değerlerini alır[57]. Giriş katmanının boyutları, giriş verilerinin şekline ve boyutuna bağlıdır.

Örneğin, görüntü işleme görevlerinde giriş katmanının boyutları, genişlik, yükseklik ve kanalların sayısına (örneğin, renkli görüntüler için RGB kanalları) göre belirlenir. Giriş katmanındaki her nöron, giriş verilerinin bir piksel değerine veya bir özelliğine karşılık gelir. Görüntü verisi durumunda, her nöron tipik olarak görüntüdeki tek bir pikselin yoğunluk değerini temsil eder. Girdi verileri, tutarlılığı sağlamak ve eğitim sırasında yakınsamayı geliştirmek için normleştirme gibi ön işleme adımlarından geçebilir. Normleştirme teknikleri, piksel değerlerinin belirli bir aralığa (örneğin, [0, 1]) ölçeklendirilmesini veya piksel değerlerinin sıfır ortalama ve birim varyansa sahip olacak şekilde standartlaştırılmasını içerebilir.

Giriş katmanı herhangi bir eğitilebilir parametre (ağırlıklar veya sapmalar) içermez çünkü yalnızca giriş verilerinin ağa aktarılması için bir kanal görevi görür[58]. Giriş verileri giriş katmanından geçtikten sonra, hiyerarşik özellikleri çıkarmak ve tahminler yapmak için sonraki katmanlarda (örneğin, evrişimli katmanlar, havuzlama katmanları ve tam bağlı katmanlar) daha ileri işlemlere tabi tutulur. Genel olarak, girdi katmanı, girdi verilerinin ilk temsilinin tanımlanmasında ve sonraki katmanların veriler içindeki karmaşık kalıpları ve ilişkileri öğrenmesi için zemin hazırlamada çok önemli bir rol oynar.

3.2.2. Evrişim Katmanı


Evrişim katman, özellikle görüntüler gibi ızgara benzeri verilerin işlenmesinde etkili olan bir tür yapay sinir ağı olan evrişimli sinir ağlarının temel bir yapı taşıdır. Evrişim katmanları, girdi verilerinden anlamlı özelliklerin çıkarılmasında çok önemli bir rol oynar. Evrişim katmanı, ESA içinde temel yapı taşı olarak hizmet eder ve hesaplamaların çoğunun gerçekleştirilmesinde merkezi bir rol oynar[59]. Giriş verileri, filtreler ve özellik haritaları dahil olmak üzere birçok temel bileşene dayanır. Evrişim, giriş verilerinin küçük karelerini kullanarak görüntü özelliklerini öğrenerek pikseller arasındaki uzamsal ilişkiyi korur. Bu, iki tensörün girdi olarak görev yaptığı ve sonuçta ortaya çıkan bir tensörün çıktı olarak üretildiği bir tensör işlemidir. Bu katman, çekirdek olarak bilinen küçük bir pencereyi kullanarak giriş tensörü üzerinde döşeme benzeri bir filtreleme yaklaşımı kullanır[60]. Çekirdek, evrişim işleminin filtrelemeye çalıştığı belirli özellikleri belirler ve istenen özellikleri tespit ettiğinde önemli bir yanıt üretir. Evrişim katmanının çıktı boyutu, girdi boyutu, çekirdek (kernel) boyutu, adım (stride) ve dolgu dahil olmak üzere çeşitli faktörler tarafından belirlenir. Çıktı boyutunu hesaplama formül Denklem
$$\text{Çıktı Boyutu} = \frac{\text{Girdi boyutu} - \text{Filtre boyutu} + 2 \times \text{Dolgu}}{\text{Stride}} + 1$$
 (3.1'de gösterilmiştir.

$$\text{Çıktı Boyutu} = \frac{\text{Girdi boyutu} - \text{Filtre boyutu} + 2 \times \text{Dolgu}}{\text{Stride}} + 1 \quad (3.1)$$

Bu formül, giriş görüntüsünün ve evrişimli filtrenin aynı sayıda kanala (ör. gri tonlamalı veya RGB) sahip olduğunu varsayar. Giriş görüntüsü ve filtrenin farklı sayıda kanalı varsa formülün her kanal için ayrı ayrı uygulanması gerekir ve sonuçlar genellikle kanallar arasında toplanır. Her evrişim işleminden sonra, bir ESA özellik haritasına Düzeltmiş Doğrusal Birim (ReLU) dönüşümü uygulayarak modele doğrusal olmama özelliğini getirir[28].

Evrişim katmanlarının temel işlemi, evrişim işleminin kendisidir. Bu, giriş verilerine bir filtrenin (çekirdek olarak da bilinir) uygulanmasını içerir. Filtre uzamsal boyutta küçüktür ancak giriş hacminin tüm derinliği boyunca uzanır (RGB görüntüler gibi 3 boyutlu veriler söz konusu olduğunda derinlik genellikle üç kanalıdır: kırmızı, yeşil ve mavi). Filtre, giriş verileriyle eleman bazında çarpma ve toplama yoluyla evrilir ve çıktı özellik haritasında tek bir değer elde edilir. Daha sonra filtre, "kayan pencere" veya "evrişim" adı verilen bir işlem yoluyla tüm çıktı özelliği haritasının oluşturulması için giriş verileri boyunca hareket ettirilir (veya kaydırılır). Filtrenin (çekirdeğin) değerleri evrişim katmanındaki öğrenilebilir parametrelerdir. ESA'nın eğitim aşaması sırasında, bu filtre ağırlıkları, tipik olarak ağırlıklı bir görevdeki performansıyla (örneğin, görüntü sınıflandırması) ilişkili bir kayıp fonksiyonunu en aza indirmek için geri yayılım ve optimizasyon algoritmaları (stokastik gradyan iniş gibi) aracılığıyla güncellenir. Ağ, eğitim verilerinden öğrendikçe, görevle ilgili anlamlı özellikleri çıkarmak için filtre ağırlıklarını ayarlar.

Giriş verilerine birden fazla filtre (çekirdek) uygulamanın çıktısı, özellik haritaları adı verilen birden fazla iki boyutlu diziyle sonuçlanır. Her özellik haritası, giriş verilerindeki belirli bir özelliğin veya modelin varlığını temsil eder. Evrişimsel katman birden fazla filtre kullanarak çeşitli özellikleri aynı anda çıkarabilir[59]. Evrişimli katmanlar genellikle çıktı özellik haritalarının uzamsal boyutlarını kontrol etmek için parametreler içerir. Evrişim uygulandıktan sonra uzamsal boyutlarını korumak için giriş verilerine dolgu eklenebilir. Adım, filtrenin giriş verileri boyunca hareket ettirildiği adım boyutunu belirler. Bu parametreler çıktı özellik haritalarının uzamsal çözünürlüğünü etkiler. Evrişim işlemi bir örnek ile Şekil Şekil 3.2'de açıklanmıştır.



Şekil 3.2. Evrişim katmanında evrişim işlemi

Evrişim işleminden sonra, çıktı özellik haritalarına genellikle öge bazında bir aktivasyon işlevi (ReLU, sigmoid veya tanh gibi) uygulanır. Bu, ağa doğrusal olmamayı getirerek özellikler arasındaki karmaşık ilişkileri öğrenmesine olanak tanır[28]. Evrişimli katmanlar, görüntü sınıflandırma, nesne algılama ve görüntü bölümlendirme gibi görevler için giriş verilerinin hiyerarşik temsillerini öğrenebilen derin ESA mimarileri oluşturmak üzere havuzlama katmanları, etkinleştirme katmanları ve tamamen bağlantılı katmanlar gibi diğer katman türleriyle birlikte kullanılır.

3.2.3. Havuzlama Katmanı


Havuzlama işlemleri veya havuzlama katmanları olarak da bilinen havuzlama katmanları, evrişimli sinir ağlarının önemli bir bileşenidir. Genellikle ağ mimarisindeki evrişim katmanlarından hemen sonra kullanılırlar. Havuzlama katmanları, önemli bilgileri korurken özellik haritalarının uzamsal boyutlarını azaltmada çok önemli bir rol oynar; bu, aşırı uyum ve hesaplama karmaşıklığının kontrol edilmesine yardımcı olur[61]. Aşağı örnekleme olarak da adlandırılan havuzlama katmanları, girdinin boyutsallığını azaltmaya ve böylece parametre sayısını azaltmaya yarar. Evrişimli katmanlara benzer şekilde, havuzlama işlemleri giriş

boyunca bir filtrenin geişini içerir. Ancak evrişimli katmanlardan farklı olarak havuzlama filtresinin ağırlıkları yoktur. Bunun yerine filtre, alıcı alanı içindeki değere bir toplama işlevi uygulayarak çıktı dizisini oluşturur.

Havuzlama, girdi özellik haritalarının farklı bölgelerine (mahallelere) bağımsız olarak uygulanır. Tipik olarak kare veya dikdörtgen bir pencere (genellikle havuzlama penceresi veya çekirdek olarak anılır) giriş özellik haritasının üzerine kaydırılır ve işlem her pencere içinde gerçekleştirilir[62]. Her havuzlama penceresinde, bilgilerin toplanması için bir havuzlama işlemi uygulanır. En yaygın iki havuzlama işlemi şunlardır:

- *Maksimum Havuzlama*, maksimum havuzlamada, her havuzlama penceresindeki maksimum değeri, o bölgeyi temsil eden değeri olarak seçilir. Maksimum havuzlama, her yerel bölgedeki en baskın özelliklerin korunmasına yardımcı olur.
- *Ortalama Havuzlama*, ortalama havuzlamada, her havuzlama penceresindeki tüm öğelerin ortalama değeri hesaplanır ve o bölgenin temsili değeri olarak kullanılır. Ortalama havuzlama, girdinin daha düzgün bir temsili sağlama eğilimindedir.

Evrişimli katmanlara benzer şekilde, havuzlama katmanları aynı zamanda havuzlama penceresinin giriş özellik haritası boyunca hareket ettiği adım boyutunu belirleyen "adım" adı verilen bir parametreyi de içerebilir. Daha büyük bir adım, daha agresif alt örnekleme ve uzaysal boyutlarda daha fazla azalmaya neden olur. Maksimum havuzlama ve ortalama havuzlamanın yanı sıra, minimum havuzlama, küresel havuzlama ve kesirli havuzlama gibi her birinin kendine özgü özellikleri ve kullanım durumları olan başka havuzlama işlemleri çeşitleri de vardır[63]. Evrişimli katmanlardan farklı olarak, havuzlama katmanlarının öğrenilebilir parametreleri yoktur. Havuzlama işlemi sabittir ve eğitim sürecinde öğrenilmesi gereken herhangi bir ağırlık parametresini içermez. Havuzlama katmanları, önemli bilgileri korurken özellik haritalarının uzamsal boyutlarının azaltılmasına yardımcı oldukları ve böylece ağırlık giriş verilerinin hiyerarşik temsillerini verimli bir şekilde öğrenmesini sağladığı için ESA mimarilerinde önemlidir[64]. Şekil 3.3'te örnek bir maksimum havuzlama işlemi gösterilmiştir.



Şekil 3.3. Maksimum havuzlama işlemi

Şekil 3.3'te görüldüğü gibi 4x4 lük bir matrise 2x2'lik bir havuzlama işlemi uygulanmıştır. Maksimum havuzlama işleminde 2x2'lik matrisin üzerinde tutulduğu alanın en büyük değeri alınır ve 2x2'lik matriste buna denk gelen alana yazılır. Örneğimizde mavi alandaki en büyük değer olan 7, turuncu bölgedeki en büyük değer olan 4, yeşil bölgedeki en büyük değer 9 ve gri bölgedeki en büyük değer olan 6 alınarak 2x2'lik matriste yerlerine yazılmıştır. Bu şekilde 4x4'lük matrise maksimum havuzlama işlemi uygulanmıştır. Evrişimli katmanlardan farklı olarak, havuzlama katmanlarının öğrenilebilir parametreleri yoktur. Havuzlama işlemi sabittir ve eğitim sürecinde öğrenilmesi gereken herhangi bir ağırlık parametresini içermez[65]. Havuzlama katmanları, önemli bilgileri korurken özellik haritalarının uzamsal boyutlarının azaltılmasına yardımcı oldukları ve böylece ağır giriş verilerinin hiyerarşik temsillerini verimli bir şekilde öğrenmesini sağladığı için ESA mimarilerinde önemlidir.

3.2.4. Tamamen Bağlı Katman

Tamamen bağlı katman tipik olarak ConvNet mimarisinin sonunda görünür ve önceki evrişim ve havuzlama katmanlarından düzleştirilmiş özellik haritalarını girdi olarak alır[66]. Amacı, bu yüksek seviyeli özellikleri birleştirerek belirli göreve bağlı olarak sınıf olasılıkları veya regresyon değerleri gibi nihai çıktıya dönüştürmektir. Evrişimli ve havuzlama katmanları ReLu işlevlerini kullanma eğilimindeyken, FC katmanları genellikle girdileri uygun şekilde sınıflandırmak için bir softmax aktivasyon işlevinden yararlanır ve 0'dan 1'e kadar bir olasılık üretir. Her evrişimli katmanın çıktısı daha sonra boyutsallığı azaltmak ve en belirgin bilgileri yakalamak için havuzlama katmanları kullanılarak örneklenir. Son olarak, ortaya çıkan özellik haritaları düzleştirilir ve sınıflandırma veya regresyon görevlerini gerçekleştiren bir veya daha fazla tamamen bağlantılı katmana beslenir. Evrişim, havuzlama ve tamamen bağlantılı katmanlardan oluşan bu kombinasyon, bir CNN'nin temel yapısını oluşturur ve görüntülerdeki

veya diğer verilerdeki karmaşık modelleri öğrenmesini ve tanımasını sağlar[67].

Yoğun katmanlar olarak da bilinen tamamen bağlı katmanlar, evrişimli sinir ağları (CNN'ler) ve derin sinir ağları (DNN'ler) dahil olmak üzere sinir ağı mimarilerinde yaygın olarak bulunan bir katman türüdür. Bu katmanlar genellikle daha önceki katmanlar tarafından çıkarılan özellikler üzerinde üst düzey akıl yürütme gerçekleştirmek için ağı sonuna doğru kullanılır[68]. Tamamen bağlı katmandaki her nöron, önceki katmandaki her nörona bağlıdır, dolayısıyla "tam bağlı" terimi de buradan gelir. Bu, tamamen bağlı katmandaki her çıkış nöronunun, önceki katmandaki tüm nöronlardan girdi aldığı anlamına gelir. Tamamen bağlı katmandaki her nöron, önceki katmandan aldığı girdilerin ağırlıklı toplamını hesaplar; burada ağırlıklar, nöronlar arasındaki bağlantının gücünü temsil eder. Bu ağırlıklı toplam, doğrusal bir dönüşüm kullanılarak hesaplanır, hesaplama Denklem $z=w_1x_1 + w_2x_2 + \dots + w_nx_n + b$ (3.2'de gösterilmiştir.

$$z = w_1x_1 + w_2x_2 + \dots + w_nx_n + b \quad (3.2)$$

Burada, z ağırlıklı toplamdır, $w_1, w_2, \dots, w_n$ bağlantılarla ilişkili ağırlıklardır. $x_1, x_2, \dots, x_n$ önceki atmandan gelen girdilerdir ve b önyargı terimidir. Ağırlıklı toplam hesaplandıktan sonra, ağı doğrusal olmamayı sağlamak için bir aktivasyon fonksiyonu uygulanır. Tamamen bağlı katmanlarda kullanılan yaygın aktivasyon fonksiyonları arasında Doğrultulmuş Doğrusal Birim (ReLU), sigmoid ve hiperbolik tanjant (tanh) bulunur. Aktivasyon fonksiyonunun seçimi spesifik göreve ve mimariye bağlıdır. Tamamen bağlı katmandaki her bir nöronun çıkışı, aktivasyon fonksiyonunun ağırlıklı toplama uygulanmasının sonucudur. Bu çıktılar sinir ağının son katmanını oluşturur ve genellikle ağı amacına bağlı olarak sınıflandırma, regresyon veya diğer görevler için kullanılır.

Tamamen bağlı bir katmanın parametreleri, her bir bağlantıyla ilişkili ağırlıkları ($w_1, w_2, \dots, w_n$) ve önyargı terimini (b) içerir[69]. Eğitim süreci sırasında bu parametreler, önceden tanımlanmış bir kayıp fonksiyonunu en aza indirmek amacıyla geri yayılım ve gradyan iniş gibi optimizasyon teknikleri yoluyla öğrenilir. Tamamen bağlı katmanlar, ağı, giriş verileri üzerinde karmaşık dönüşümler gerçekleştirme ve önceki katmanlar tarafından çıkarılan özellikler arasındaki karmaşık modelleri ve ilişkileri öğrenme yeteneği sağlar. Bununla birlikte, özellikle tamamen bağlı birçok katmana sahip ağlarda aşırı uyum sağlamaya yol açabilecek çok sayıda parametre de sunarlar. Bırakma ve ağırlık azalması gibi düzenleme teknikleri genellikle tamamen bağlı katmanlarda aşırı uyumu azaltmak için kullanılır.

3.2.5. Seyreltme (Dropout) Katmanı

Bırakma katmanı, sinir ağı mimarilerinde aşırı uyumu önlemek ve modelin genelleme yeteneğini geliştirmek için kullanılan bir düzenleme tekniğidir. Srivastava ve arkadaşları tarafından "Bırakma: Sinir Ağlarının Aşırı Uyumunu Önlemenin Basit Bir Yolu" başlıklı makalelerinde önerildi[70]. Eğitim sırasında, bırakma katmanı, giriş birimlerinin (nöronların) bir kısmını belirli bir olasılıkla (p) rastgele sıfıra ayarlar. Genellikle 0,2 ile 0,5 arasında ayarlanır. Bu, ileri geçiş ve geri yayılım sırasında bu nöronların çıktılarının göz ardı edildiği anlamına gelir. Bırakma katmanı, nöronları rastgele çıkararak, her eğitim örneği için farklı bir "inceltilmiş" ağı etkili bir şekilde örnekler. Bu, ağı gürültünün girmesine neden olur, onu daha sağlam özellikler öğrenmeye zorlar ve nöronların birbirine çok fazla uyum sağlamasına engel olur.

Çıkarım veya test sırasında tüm nöronlar beklenen çıktının değişmeden kalmasını sağlamak için kullanılır ancak çıktıları, bırakma olasılığına (p) göre ölçeklendirilir. Bu genellikle "ters çevrilmiş bırakma" tekniği olarak anılır. Bırakma katmanı tipik olarak bir sinir ağı mimarisinde tamamen bağlı katmanlardan veya evrişimli katmanlardan sonra uygulanır. Genelleştirme performansını daha da geliştirmek için ağırlık azaltma (L2 düzenleme) gibi diğer düzenleme teknikleriyle birlikte kullanılabilir[71]. Bırakma kullanmanın temel faydaları arasında aşırı uyumun azaltılması, modelin görünmeyen verilere genelleme yeteneğinin geliştirilmesi ve birden fazla ağı bir araya getirmek için hesaplama açısından ucuz bir yol sağlanması yer alır. Bununla birlikte, model dağıtımı sırasında istenmeyen rastgelelik ortaya çıkardığından, çıkarmanın çıkarım veya test sırasında değil, yalnızca eğitim sırasında uygulanması gerektiğine dikkat etmek önemlidir.

3.2.6. Sigmoid Fonksiyonu

Aktivasyon fonksiyon katmanı, ağı giriş ve çıkış arasındaki doğrusal olmayan ilişkileri öğrenmesine yardımcı olur. Ağı doğrusal olmama özelliği kazandırmaktan ve verilerdeki karmaşık kalıpları ve ilişkileri modellemesine izin vermekten sorumludur. Aktivasyon fonksiyonu tipik olarak ağıdaki her bir nöronun çıkışına uygulanır[72]. Girdilerin ağırlıklı toplamını alır ve daha sonra bir sonraki katmana aktarılan bir çıktı üretir. Aktivasyon Fonksiyonu, bir nöronun aktive edilip edilmeyeceğine karar verir. Bu, daha basit matematiksel işlemler kullanarak tahmin sürecinde nöronun ağı girişinin önemli olup olmadığına karar vereceği anlamına gelir. Aktivasyon fonksiyonunun rolü, bir düğüme (veya katmana) beslenen bir dizi giriş değerinden çıktı elde etmektir.


Sigmoid işlevi, yapay sinir ağının temel bir bileşenidir ve birçok makine öğrenimi uygulamasında çok önemlidir. Sigmoid işlevi, herhangi bir giriş değerini 0 ile 1 arasındaki bir değerle eşleştiren matematiksel bir işlevdir ve ikili sınıflandırma ve lojistik regresyon

problemlerinde yararlı olur[74]. Sigmoid fonksiyonunun şekli genellikle "S" şekli olarak anılır, çünkü yavaş bir artışla başlar, hızla 1'e yaklaşır ve sonunda sabitlenir. Yapay sinir ağlarında sigmoid fonksiyonu yaygın olarak nöronlarda aktivasyon fonksiyonu olarak kullanılır. Modele doğrusal olmamayı getirerek sinir ağının daha karmaşık karar sınırlarını öğrenmesine olanak tanır[75]. Bu işlev özellikle görüntü tanıma, doğal dil işleme ve konuşma tanıma gibi farklı uygulamalarda kullanılan ileri beslemeli sinir ağlarında kullanışlıdır. Lojistik fonksiyon olarak da bilinen sigmoid fonksiyonu, gerçek değerli herhangi bir sayıyı 0 ile 1 arasındaki bir değerle eşleştiren matematiksel bir fonksiyondur. Sigmoid formülü Denklem $\sigma(x) = \frac{1}{1+e^{-x}}$

(3.3'te gösterilmiştir.

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (3.3)$$

Burada x giriş değeridir ve e, 2,718'in matematiksel sabitidir. İşlev, herhangi bir giriş değerini 0 ile 1 arasındaki bir değerle eşler ve bu onu ikili sınıflandırma ve lojistik regresyon sorunları için yararlı kılar. Fonksiyonun aralığı (0,1) ve tanım kümesi (-sonsuz, +sonsuz)'dur. Sigmoid fonksiyonunun diğer bir özelliği de sinir ağlarının eğitiminde yaygın olarak kullanılan türevidir. Fonksiyonun türevi $f(x)(1-f(x))$ olarak tanımlanır, burada $f(x)$ fonksiyonun çıktısıdır[76]. Türev, sinir ağlarının eğitilmesinde faydalıdır çünkü ağı, nöronların ağırlıklarını ve önyargılarını daha verimli bir şekilde ayarlamasına olanak tanır. Sigmoid fonksiyonunun bazı sınırlamaları olduğunu da belirtmekte fayda var. Örneğin sigmoid çıkışının her zaman 0 ile 1 arasında olması, ağı çıkışının 1'den büyük veya 0'dan küçük olması gerektiğinde sorunlara neden olabilir. Bu gibi durumlarda ReLU ve tanh gibi diğer aktivasyon fonksiyonları kullanılabilir. Sigmoid fonksiyonu eğrisi Şekil Şekil 3.4'te gösterilmiştir.



Şekil 3.4. Sigmoid fonksiyonu grafiği

Sigmoid işlevi, sinir ağlarında, özellikle ikili sınıflandırma görevleri için çıktı katmanında bir aktivasyon işlevi olarak tarihsel olarak popülerdi. Sigmoid işlevi, büyük pozitif veya negatif girdiler için gradyanların çok küçük olduğu yok olan gradyan probleminden dolayı sorun yaşamaktadır. Bu, özellikle derin sinir ağlarında eğitim sürecini yavaşlatabilir[77]. Giriş çok büyük veya çok küçük olduğunda sigmoid fonksiyonunun çıkışı doyuma ulaşır (0 veya 1'e yaklaşır). Bu, ağ optimal çözümden uzak olduğunda öğrenmede zorluklara yol açabilir. Bu sınırlamalar nedeniyle, ReLU (Düzeltilmiş Doğrusal Birim) ve çeşitleri gibi alternatif aktivasyon fonksiyonları, modern sinir ağı mimarilerinde, özellikle gizli katmanlar için daha yaygın olarak kullanılmaktadır. Bununla birlikte, sigmoid işlevi, ikili sınıflandırma görevlerinin çıktı katmanı gibi belirli durumlarda veya çıktının bir olasılık olarak yorumlanmasının gerektiği durumlarda hala ara sıra kullanılmaktadır.


3.2.7. Rectified Linear Unit (ReLU) Fonksiyonu

Düzeltilmiş Doğrusal Birim (ReLU), sinir ağlarında, özellikle derin öğrenme modellerinde yaygın olarak kullanılan bir aktivasyon fonksiyonudur. Bir sinir ağındaki her bir nöronun çıkışı üzerinde çalışan basit bir matematiksel fonksiyondur. ReLU işlevi, negatif giriş değerleri için sıfır döndüren ve pozitif giriş değerlerinden değişmeden geçen parçalı doğrusal bir işlevdir[78]. Birçok sinir ağı türü için varsayılan aktivasyon işlevi haline gelmiştir çünkü onu kullanan bir modelin eğitilmesi daha kolaydır ve genellikle daha iyi performansa ulaşır. ReLU fonksiyonunun çıkışı maksimum 0'dır ve giriş x . Yani giriş pozitifse çıkış girişe eşittir, giriş negatifse çıkış 0'dır. ReLU fonksiyonunun formülasyonu Denklem $f(x) = \max(0, x)$

(3.4)'te gösterilmiştir.

$$f(x) = \max(0, x) \quad (3.4)$$

ReLU, temel olarak basitliği ve derin sinir ağlarının eğitimindeki etkinliği nedeniyle popüler hale geldi. Modelin eğitim sırasında daha hızlı öğrenmesini ve daha hızlı yakınsamasını sağlayarak, yok olan gradyan sorununun çözülmesine yardımcı olur. ReLU, sinir ağlarında seyrek temsiller üretir; bu, herhangi bir giriş için nöronların yalnızca bir kısmının etkinleştirildiği anlamına gelir. Bu daha verimli modellerin ortaya çıkmasına yol açabilir[79]. ReLU, üstel değerler içeren ve hesaplama açısından daha yoğun olabilen sigmoid veya tanh gibi bazı diğer aktivasyon fonksiyonlarıyla karşılaştırıldığında hesaplama açısından verimlidir. Negatif bölgede doygunluğa ulaşarak gradyan azalmasının kaybolmasına neden olan sigmoid veya tanh fonksiyonlarının aksine ReLU'da bu sorun yaşanmaz[80]. Pozitif girdiler için sabit bir eğim sağlar ve bu da daha iyi bir eğitime yardımcı olur. ReLU grafiği Şekil 3.5'te gösterilmiştir.



Şekil 3.5. Negatif ve pozitif girişler için ReLU grafiği

ReLU'nun ana sorunu, tüm negatif değerlerin anında sıfır olması, bu da modelin verilere uygun şekilde uyum sağlama veya verilerden eğitim alma yeteneğini azaltmasıdır. Bu, ReLU aktivasyon fonksiyonuna verilen herhangi bir negatif girişin, değeri grafikte anında sıfıra çevirdiği ve bunun da negatif değerleri uygun şekilde eşlemeyerek ortaya çıkan grafiği etkilediği anlamına gelir[81]. Tüm girdiler için 0 çıktısı veren nöronlar, artık öğrenme sürecine katkıda bulunmadığı için "ölü" olarak kabul edilir. Bu, bir ReLU nöronunun girişinin eğitim sırasında sürekli olarak negatif olması ve nöronun her zaman 0 çıkışı vermesine neden olması durumunda meydana gelebilir.

3.2.8. Softmax Fonksiyonu

Aktivasyon fonksiyonları, yapay sinir ağlarındaki nöronların çıktılarına uygulanan matematiksel fonksiyonlardır. Ağa doğrusal olmamayı getirerek verilerdeki karmaşık kalıpları öğrenmesine ve ağın herhangi bir isteğe bağlı işleve yaklaşma yeteneğine sahip olmasını sağlarlar[73]. Aktivasyon fonksiyonları, evrişimli sinir ağları (CNN'ler), tekrarlayan sinir ağları (RNN'ler) ve tamamen bağlı sinir ağları dahil olmak üzere sinir ağı mimarilerinin kritik bir bileşenidir.


Softmax, gerçek sayılardan oluşan bir vektörü olasılık dağılımına dönüştüren matematiksel bir fonksiyondur. Çok sınıflı sınıflandırma problemlerinde genellikle sinir ağlarında son aktivasyon fonksiyonu olarak kullanılır. Softmax işlevi, çok sınıflı sınıflandırma görevleri için bir sinir ağının çıkış katmanında yaygın olarak kullanılır[82]. Ağ tarafından üretilen ham puanları, toplamı 1 olan olasılıklara dönüştürür. Softmax işlevi girdi olarak bir vektör alır. Gerçek sayıların z'si ve bir vektörün çıktısı $\sigma(z)$ aynı uzunluktadır; burada her öge karşılık gelen sınıfın olasılığını temsil eder. Softmax fonksiyonunun formülü Denklem $Q(z) =$

$$\frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (3.5\text{'te gösterilmiştir.})$$

$$Q(z) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (3.5)$$

Burada z_i , z giriş vektörünün i 'inci elemanıdır. K toplam sınıf sayısıdır ve e doğal logaritmanın tabanıdır. Softmax işlevi, giriş vektörünün her bir ögesini yorumlar ve ardından bunları, yorumlanmış tüm değerlerin toplamına bölerek normalleştirir. Bu normalleştirme, çıktı vektörünün toplamının 1 olmasını sağlar ve bu da onu geçerli bir olasılık dağılımı haline getirir. Softmax, çok sınıflı sınıflandırma görevleri için genellikle sinir ağlarının çıktı katmanında kullanılır çünkü her sınıf için olasılıklar üretir, karar vermede yorumlanmasını ve kullanılmasını

kolaylaştırır[83]. Eğitim sırasında softmax çıkışı, çapraz entropi kaybı gibi bir kayıp fonksiyonu kullanılarak gerçek etiketlerle karşılaştırılır ve ağı parametreleri, bu kaybı en aza indirecek şekilde geri yayılım yoluyla ayarlanır. Softmax fonksiyonun grafiksel gösterimi Şekil 3.6'da gösterilmiştir.



Şekil 3.6. Softmax fonksiyonu grafiği

Softmax'ın önemli bir özelliği, giriş değerlerinin ölçeğine duyarlı olmasıdır. Giriş değerleri çok büyük veya çok küçükse çıkış olasılıkları sayısal olarak kararsız hale gelebilir[84]. Bu sorunu çözmek için, normalleştirilmiş logitlere bir softmax işlevi uygulamak yaygındır; burada logitler, softmax'ı uygulamadan önce ağı ham çıkış değerleridir. Bu normalleştirme, örneğin logit ölçeklendirme veya logit hilesi olarak bilinen bir teknik olan softmax'ı uygulamadan önce giriş vektörünün her bir ögesinden maksimum değeri çıkararak elde edilebilir. Bu, çıktı olasılıklarını değiştirmeden sayısal kararlılık sağlar.

3.2.9. Çıktı Katmanı

Bir sinir ağındaki çıktı katmanı, ağı tahminlerini veya çıktıları üretmekten sorumlu olan nöronların son katmanıdır. Çıkış katmanının yapısı ve aktivasyon fonksiyonu, sinir ağının çözmek üzere tasarlandığı göreve bağlıdır. Birden fazla evrişim ve dolgu katmanından sonra çıktının bir sınıf biçiminde olması gerekir. Evrişim ve havuzlama katmanları yalnızca orijinal görüntülerden özellikler çıkarabilir ve parametre sayısını azaltabilir[85]. Ancak nihai çıktıyı oluşturmak için, ihtiyacımız olan sınıf sayısına eşit bir çıktı üretmek amacıyla tamamen bağlı bir katman uygulamamız gerekir. Sadece evrişim katmanlarıyla bu sayıya ulaşmak zorlaşıyor. Evrişim katmanları 3 boyutlu aktivasyon haritaları oluştururken biz sadece bir görüntünün belirli bir sınıfa ait olup olmadığına ilişkin çıktıya ihtiyacımız var. Çıkış katmanı, tahmindeki hatayı hesaplamak için kategorik çapraz entropi gibi bir kayıp fonksiyonuna sahiptir. İleri geçiş tamamlandıktan sonra geri yayılım, hata ve kayıp azaltımı için ağırlığı ve önyargıları


güncellemeye başlar[86]. Yapı ve aktivasyon fonksiyonunun yanı sıra sinir ağının eğitimi için kullanılan kayıp fonksiyonu da çıkış katmanının görevine ve doğasına bağlıdır. Örneğin, ikili çapraz entropi kaybı genellikle ikili sınıflandırma için, kategorik çapraz entropi kaybı çok sınıflı sınıflandırma için ve ortalama karesel hata kaybı regresyon için kullanılır.

3.3. Evrişimli Sinir Ağ Mimarileri

Evrişimli Sinir Ağları, birçok son teknoloji ürünü bilgisayarlı görme sisteminin omurgası haline geldi. Yıllar boyunca her biri kendine özgü özelliklere ve performansa sahip olan çeşitli ESA mimarileri önerilmiştir. Mimari seçimi, görevin karmaşıklığı, mevcut hesaplama kaynakları ve doğruluk, hız ve model boyutu arasında istenen dengeler gibi faktörlere bağlıdır[69]. Evrişimli Sinir Ağları, görüntü tanıma, nesne algılama ve diğer çeşitli görsel görevlerdeki gelişmelere güç vererek bilgisayarlı görme alanında devrim yarattı. ESA'ların başarısı, verilerden hiyerarşik temsilleri otomatik olarak öğrenme yeteneklerinde yatmaktadır. ESA mimarisi en popüler derin öğrenme çerçevesidir. ESA'lar, görüntü tanıma sorununu çözmede dikkate değer bir başarı göstererek, yeni keşfedilen bir hassasiyet ve ölçeklenebilirlik düzeyi getirdi. Ancak tüm ESA'lar eşit yaratılmamıştır ve farklı ESA mimari türlerini anlamak, bunların tüm potansiyelini kullanmanın anahtarıdır. Bu tez çalışmasında en yaygın kullanılan ESA mimarileri açıklanacaktır.

3.3.1. ResNet

Artık Ağlar anlamına gelen ResNet, daha derin ağlarda sıklıkla ortaya çıkan kaybolan ve patlayan gradyan sorunlarını çözmek için tanıtılan bir tür evrişimli sinir ağı (CNN) mimarisidir. Kaiming He ve arkadaşları tarafından 2015'te "Görüntü Tanıma için Derin Kalıntı Öğrenme" başlıklı makalelerinde önerildi[87]. ResNet'in temel yapı taşı "artık blok" veya "bağlantıyı atla"dır. Bu blok, etkinleştirmelerin bir kısayol bağlantısı yoluyla bir veya daha fazla katman atlamasına olanak tanıyarak derin ağların optimizasyonunu kolaylaştırır. ResNet, bir veya daha fazla katman atlayan kimlik kısayolu bağlantısı kavramını sunar. Bunun arkasındaki temel fikir, artık haritalamayı (yani girdi ve çıktı arasındaki farkı) optimize etmenin istenen çıktıdan daha kolay olmasıdır. Bu artık blokları kullanarak ResNet mimarileri çok derin inşa edilebilir. ResNet'lerin 50, 101 ve 152 katmanlı versiyonları piyasaya sürüldü, ancak daha derin versiyonları da mevcut. ResNet mimarisindeki atlama bağlantısı Şekil 3.7'de gösterilmiştir.



Şekil 3.7. ResNet atlama bağlantıları

ResNet'in en önemli yeniliği, referans alınmayan fonksiyonları öğrenmek yerine ağı, katman girişlerine referansla artık fonksiyonları öğrenmesine olanak tanıyan artık blokların kullanılmasıdır[88]. Bu, bir veya daha fazla katmanı atlayan atlama bağlantılarının veya kısayolların eklenmesiyle elde edilir. Bu kısayollar, eğitim sırasında kaybolan gradyan ağı üzerinden daha doğrudan akmasını sağlayarak, yok olan gradyan sorununu hafifletir[89]. Sonuç olarak, ResNet mimarileri geleneksel CNN'lerden çok daha derin olabilir ve aynı zamanda eğitilebilir olmaya devam edebilir. Artık Bloklar fikri, bu tasarımla kaybolan/patlayan gradyan sorununu çözmek için yaratıldı. Bu ağda bağlantıları atlama olarak bilinen bir yöntem uygulanıyor. Atlama bağlantısı, katman aktivasyonlarını sonraki katmanlara bağlamak için aradaki bazı seviyeleri atlar. Bu, kalan bir blok oluşturur. Bu kalan bloklar ResNet mimarisi oluşturmak için istiflenir[90]. Bu ağı arkasındaki strateji, katmanların temel haritalamayı öğrenmesini sağlamak yerine ağı kalan haritalamaya uymasına izin vermektir. Böylece, örneğin $H(x)$ 'in ilk eşlemesini kullanmak yerine ağı uymasına izin verir. $H(x)$ artık bloğun çıktısı Denklem $H(x) = f(x) + x$ (3.6)'daki gibi ifade edilebilir.

$$H(x) = f(x) + x \quad (3.6)$$


$F(x)$, ağı tarafından öğrenilen artık haritalamayı temsil eder. Kimlik teriminin varlığı x , gradyanın daha kolay akmasını sağlar[91]. Atlama bağlantısı, artık blokların oluşturulmasına yardımcı olur. Atlama bağlantısı, evrişim katmanı üzerinden atlanan ve artık bloğun çıkışına eklenen artık bloğun girişinden oluşur. ResNet mimarileri tipik olarak, tamamen bağlı

katmandan önceki son katman olarak Küresel Ortalama Havuzlamayı (GAP) kullanır. GAP, uzamsal boyutları, özellik haritası başına tek bir değere indirir ve tüm özellik haritasının kompakt bir temsiliyi sağlar[92]. ResNet mimarileri, görüntü sınıflandırma, nesne algılama ve görüntü bölümlendirme gibi çeşitli bilgisayarlı görme görevlerinde yaygın olarak benimsenmiştir. Ayrıca ImageNet gibi kıyaslama veri kümelerinde en son teknoloji performansı elde etmede de etkili oldular.

3.3.2. VGGNet

Visual Geometry Group Network'ün kısaltması olan VGGNet, Oxford Üniversitesi'ndeki Visual Geometry Group tarafından önerilen evrişimli bir sinir ağı mimarisidir. 2014 yılında Karen Simonyan ve Andrew Zisserman'ın "Very Deep Convolutional Networks for Large-Scale Image Recognition" başlıklı makalesinde tanıtıldı[93]. VGGNet, esas olarak tekrarlanan evrişimli katman bloklarından ve bunu takip eden maksimum havuzlama katmanlarından ve sonunda tamamen bağlı katmanlardan oluşan basitliği ve tekdüze mimarisıyla bilinir. VGGNet'in arkasındaki temel fikir, ağı boyunca çok küçük (3x3) evrişimli filtreler kullanmaktır; bu, parametre sayısını nispeten düşük tutarken daha derin bir ağı mimarisine olanak tanır[94].

VGG'nin girişi 224x224 boyutunda bir RGB görüntüsüne ayarlanmıştır. Eğitim seti görüntüsündeki tüm görüntüler için ortalama RGB değeri hesaplanır ve ardından görüntü VGG evrişim ağına giriş olarak girilir[95]. 3x3 veya 1x1 filtre kullanılır ve evrişim adımı sabitlenir. Toplam evrişimli katman + tam bağlantılı katman sayısına göre VGG11'den VGG19'a kadar değişebilen 3 adet VGG tam bağlantılı katman vardır. Minimum VGG11'de 8 evrişimli katman ve 3 tam bağlantılı katman bulunur. Maksimum VGG19'un 16 evrişimli katmanı vardır. +3 tamamen bağlı katman. Ayrıca VGG ağını her evrişim katmanının arkasında bir havuzlama katmanı veya farklı evrişim katmanları altında dağıtılan toplam 5 havuzlama katmanı takip etmez. Şekil 3.8'de VGG mimarisi gösterilmiştir.



Şekil 3.8. VGGNet mimarisi (Simonyan ve Zisserman)


Ön işlemeden sonra giriş görüntüleri bu ağırlık katmanlarından geçirilir. Eğitim görüntüleri bir dizi evrişim katmanından geçirilir. VGG16 mimarisinde toplam 13 evrişimli katman ve 3 tam bağlantılı katman bulunmaktadır[96]. VGG'de büyük filtreler yerine daha derin ve daha küçük filtreler (3×3) bulunur. Sanki yalnızca bir adet 7×7 evrişim katmanınız varmış gibi aynı etkili alıcı alana sahip oldu. Derin sinir ağının 16 katmanı, adlarında 16 sayısı ile yani VGG (VGGNet) ile gösterilmektedir. Bu, VGG16 ağının toplamda 138 milyondan fazla parametreyle oldukça büyük olduğunu gösterir. Günümüzün yüksek standartlarına göre bile oldukça büyük bir ağıdır. Yine de ağ, VGGNet16 mimarisinin basitliği nedeniyle daha çekici. Tek başına mimarisi, ne kadar tekdüze olduğunu tanımlamak için kullanılabilir[97]. VGGNet'in başka bir varyasyonu, 3'ü tamamen bağlı katman ve aynı 5 havuzlama katmanından oluşan 16 evrişimli katmandan oluşan 19 ağırlık katmanına sahiptir. VGGNet'in her iki versiyonunda da her biri 4096 kanallı iki tamamen bağlı katman ve ardından 1000 etiketi tahmin etmek için 1000 kanallı başka bir tam bağlantılı katman bulunur[98]. Son tamamen bağlı katman, sınıflandırma amacıyla softmax katmanını kullanır.

VGGNet, ImageNet gibi karşılaştırmalı görüntü sınıflandırma veri kümelerinde rekabetçi bir performans elde ederek, büyük ölçekli görüntü tanıma görevleri için derin evrişimli sinir ağlarının etkinliğini ortaya koydu. Her ne kadar VGGNet, doğruluk ve hesaplama verimliliği açısından ResNet ve EfficientNet gibi daha yeni mimariler tarafından geride bırakılmış olsa da derin öğrenme alanında etkili olmaya devam ediyor ve birçok çalışmada karşılaştırma için bir temel görevi görüyor.

3.3.3. DenseNet

Yoğun Bağlantılı Evrişimli Ağ'ın kısaltması olan DenseNet, Gao Huang, Zhuang Liu ve Kilian Q. Weinberger tarafından 2017 yılında "Densely Connected Convolutional Networks" başlıklı makalelerinde önerilen evrişimli bir sinir ağı mimarisidir[99]. DenseNet'in en önemli yeniliği, her katmanın diğer katmanlara ileri beslemeli olarak bağlandığı yoğun bağlantı modelidir. Her katmanın çıktısının yalnızca bir sonraki katmana beslendiği geleneksel evrişimli sinir ağlarından farklı olarak DenseNet, herhangi bir katmandan sonraki tüm katmanlara doğrudan bağlantılar sağlar. Bu yoğun bağlantı, özelliklerin yeniden kullanımını kolaylaştırır, özelliklerin yayılmasını teşvik eder ve yok olan gradyan sorununu hafifleterek çok derin ağların daha etkili bir şekilde eğitilmesine olanak tanır[100].


DenseNet mimarisi, her biri birden fazla evrişimsel katman içeren bir dizi yoğun bloğa dayanmaktadır. Her yoğun blok, bir önceki bloğun çıktısını ve önceki tüm blokların çıktılarını girdi olarak alır. Bu, ağın tüm katmanları arasında yoğun bir bağlantı modeli oluşturarak bilginin ağ üzerinden daha verimli bir şekilde akmasına olanak tanır[101]. DenseNet mimarisinin arkasındaki temel fikir, her katman tarafından üretilen özellik haritalarının bir sonraki katmana girdi oluşturacak şekilde birleştirilebilmesidir. Bu, her katmanın çıktısının sonraki tüm katmanların girdisi olduğu anlamına gelir. DenseNet ayrıca mekansal boyutluluğu ve özellik haritalarının sayısını azaltmak için her yoğun blok arasında bir geçiş katmanı kullanır. Geçiş katmanı, toplu normalleştirme katmanı, 1x1 evrişim katmanı ve havuzlama katmanından oluşur[102]. Yoğun blok mimarisi Şekil 3.9'da gösterilmiştir.



Şekil 3.9. DenseNet yoğun blok mimarisi (Huang ve arkadaşları).

Yüksek düzeyde, bu birbirine bağlı katmanlardan oluşan yoğun bloklar bulunmaktadır. Her katman kendi içinde toplu normalleştirme (batch normalization) ve

ardından ReLU ve bir evrişim katmanıdır. Tüm bu yoğun bloklar, bir dizi geçiş evrişimi ve havuzlama katmanıyla birbirine bağlanır[103]. Artık katmanın bu temel unsurlarını bildiğimize göre, istediğimiz sayıda yoğun blok ekleyerek kendi mimarimizi oluşturabiliriz. Şekil 3.10'da tipik bir DenseNet blok mimarisinin yapısı gösterilmektedir.



Şekil 3.10. Üç yoğun bloktan oluşan derin bir DenseNet mimarisi (Huang ve arkadaşları).

DenseNet'in ImageNet, CIFAR-10 ve CIFAR-100 gibi çeşitli görüntü sınıflandırma kriterlerinde en son teknolojiye sahip performansı elde ettiği ve diğer mimarilerle karşılaştırıldığında çoğu zaman parametre açısından daha verimli olduğu gösterilmiştir. Ek olarak, DenseNet'in mimarisi nesne tespiti, semantik segmentasyon ve tıbbi görüntü analizi gibi diğer görevlere uyarlanmış ve uygulanmıştır; bu da onun farklı alanlarda çok yönlülüğünü ve etkililiğini ortaya koymuştur.


3.3.4. EfficientNet

EfficientNet, ResNet, Inception ve MobileNet gibi diğer ESA mimarilerine kıyasla daha az parametre ve FLOPS (saniyedeki kayan nokta işlemleri) ile son teknoloji ürünü doğruluğu elde etmek üzere tasarlanmış bir evrişimli sinir ağı mimarileri ailesidir. EfficientNet modelleri, 2019 yılında Google Brain'deki araştırmacılar tarafından tanıtıldı. EfficientNet'in ardındaki temel fikir, ağın derinliğini, genişliğini ve çözünürlüğünü ilkeli bir şekilde ölçeklendirmektir[104]. Bu, ağın derinliğinin, genişliğinin ve çözünürlüğünün aynı anda ölçeklendiği bileşik ölçeklendirme yöntemi kullanılarak elde edilir. Bu, doğruluğu korurken ve hatta geliştirirken hesaplama kaynaklarının verimli kullanılmasına olanak tanır.

EfficientNet, çoklu görüntü sınıflandırma kriterlerinde en son teknoloji performansı elde eden ve aynı zamanda önceki modellere göre hesaplama açısından daha verimli olan ilk model ailesiydi. Bu, EfficientNet'i bilgisayarlı görme ve derin öğrenme alanında önemli bir atılım haline getirdi. EfficientNet piyasaya sürülmesinden bu yana geniş çapta benimsenmiş ve birçok gerçek dünya uygulamasında kullanılmıştır. EfficientNet, "darboğaz" yapısı olarak da bilinen, derinlemesine ayrılabilir evrişimler yığınınından oluşan, "MobileNetV2" tarzı mimari adı verilen özel bir ESA mimarisini kullanır[105]. Bu tür mimarinin, yüksek doğruluğu korurken, geleneksel evrişimli katmanlardan hesaplama açısından daha verimli olduğu gösterilmiştir.

EfficientNet mimarisinde, giriş görüntüsü ilk önce görüntünün çözünürlüğünü azaltan

EfficientNet-B0 mimarisi Şekil 3.11’de gösterilmiştir.




Şekil 3.11. Temel EfficientNet-B0 mimarisi

Sonuç olarak EfficientNet, evrişimli sinir ağları alanında çığır açan bir başarı olarak duruyor. Ağ genişliğini, derinliğini ve çözünürlüğünü etkili bir şekilde dengeleyen bileşik ölçeklendirmeye yönelik yenilikçi yaklaşımı, bilgisayarlı görme görevlerinde üst düzey doğruluk ve verimlilik elde etme standartlarını yeniden tanımladı. EfficientNet, bu boyutların güçlü yönlerini birleştirerek ve bunları eşit şekilde uygulayarak, hafifliğini ve hızlı uygulanmasını sürdürürken üstün performans sunar[104]. EfficientNet, üstün performansı ve verimliliği nedeniyle görüntü sınıflandırma, nesne algılama ve segmentasyon gibi çeşitli bilgisayarlı görme görevlerinde yaygın olarak benimsenmiştir. EfficientNet'in birçok önceden eğitilmiş sürümü mevcuttur; bu, araştırmacıların ve uygulayıcıların kendi özel görevleri için faydalarından yararlanmalarını kolaylaştırır.

3.3.5. U-Net

U-Net, özellikle tıbbi görüntü analizi alanında biyomedikal görüntü bölümlendirmesi için tasarlanmış evrişimli bir sinir ağı mimarisidir. Freiburg Üniversitesi'ndeki araştırmacılar tarafından 2015 yılında tanıtıldı ve o zamandan beri tıbbi görüntülemenin ötesinde çeşitli segmentasyon görevlerinde de yaygın olarak kullanılan bir mimari haline geldi[108]. Bu mimarinin görüntüyü daraltma, bağlamı çıkarma ve görüntüyü yerelleştirmek için görüntüyü genişletme konusundaki güçlü yeteneğinin, özellikle tıbbi görüntü analizinde olmak üzere çeşitli segmentasyon görevlerinde etkili olduğu kanıtlanmıştır.

U-Net'in mimarisi U şeklinde bir yapıyla karakterize edilir, dolayısıyla adı da buradan gelir. Bir kodlama yolu (daralan yol) ve bir kod çözme yolu (geniş yol) ile bunları birbirine bağlayan bir darboğaz katmanından oluşur[109]. Kodlama yolu, özellik kanallarının sayısını artırırken giriş görüntüsünün uzamsal boyutlarını kademeli olarak azaltan birden fazla evrişim ve havuz katmanından oluşur. Bu yol, giriş görüntüsünden hiyerarşik özellikleri çıkarır. U-Net mimarisi Şekil 3.12'de gösterilmiştir.



Şekil 3.12. U-Net mimarisi (Ronneberger ve arkadaşları)

Kodlayıcı ağı, özellik çıkarıcı olarak görev yapar ve bir dizi kodlayıcı blok aracılığıyla giriş görüntüsünün soyut bir temsilini öğrenir. Her kodlayıcı bloğu iki adet 3x3 evrişimden oluşur ve her evrişimi bir ReLU (Düzeltilmiş Doğrusal Birim) aktivasyon fonksiyonu takip eder. ReLU aktivasyon fonksiyonu, ağı doğrusal olmamayı getirerek eğitim verilerinin daha iyi genelleştirilmesine yardımcı olur[110]. ReLU'nun çıkışı, karşılık gelen kod çözücü bloğu için

bir atlama bağlantısı görevi görür. Daha sonra, özellik haritalarının uzamsal boyutlarının (yükseklik ve genişlik) yarı yarıya azaltıldığı 2x2 maksimum havuzlama takip eder. Bu, eğitilebilir parametrelerin sayısını azaltarak hesaplama maliyetini azaltır.

Kod çözme yolu, kanal sayısını azaltırken özellik haritalarının uzamsal boyutlarını kademeli olarak artıran yukarı örnekleme ve evrişim katmanlarından oluşur[111]. Bu yol, kodlama işlemi sırasında kaybolan uzamsal bilgiyi kurtarmayı ve orijinal giriş görüntüsüyle aynı boyuta sahip bölümlene maskeleri oluşturmayı amaçlamaktadır. Kod çözücü ağı, soyut gösterimi almak ve anlamsal bir bölümlene maskesi oluşturmak için kullanılır. Kod çözücü bloğu 2x2 transpoze evrişimle başlar. Daha sonra kodlayıcı bloğundaki ilgili atlama bağlantı özelliği haritasıyla birleştirilir[112]. Bu atlama bağlantıları, daha önceki katmanlardan gelen ve bazen ağı derinliği nedeniyle kaybolan özellikler sağlar. Bundan sonra, her bir evrişimin ardından bir ReLU aktivasyon fonksiyonunun takip ettiği iki adet 3x3 evrişim kullanılır. Son kod çözücünün çıkışı, sigmoid aktivasyonu ile 1x1 evrişimden geçer[113]. Sigmoid aktivasyon fonksiyonu, piksel bazında sınıflandırmayı temsil eden segmentasyon maskesini verir.

U-Net ayrıca kodlama ve kod çözme yollarındaki karşılık gelen katmanları doğrudan bağlayan atlama bağlantılarını da içerir. Bu atlama bağlantıları, eğitim sırasında uzamsal bilgilerin ve gradyanların korunmasına yardımcı olur; bu, özellikle ince ayrıntıların korunması gereken durumlarda doğru segmentasyon için çok önemli olabilir. Bu atlama bağlantıları, kod çözücünün daha iyi anlamsal özellikler oluşturmaya yardımcı olan ek bilgiler sağlar[105]. Ayrıca gradyanların herhangi bir bozulma olmadan önceki katmanlara dolaylı akışına yardımcı olan bir kısayol bağlantısı görevi de görürler. Basit bir ifadeyle, atlama bağlantısının geri yayılım sırasında gradyanın daha iyi akışına yardımcı olduğunu ve bunun da ağı daha iyi temsili öğrenmesine yardımcı olduğunu söyleyebiliriz.

3.4. Kayıp Fonksiyonları

Derin öğrenmedeki kayıp fonksiyonları, bir sinir ağının tahmin edilen çıktısı ile gerçek hedef değerler arasındaki tutarsızlığı ölçtüğü için eğitim sürecinin önemli bileşenleridir. Kayıp fonksiyonunun seçimi, sınıflandırma, regresyon veya üretken modelleme gibi gerçekleştirilen görevin niteliğine bağlıdır[114]. Kayıp fonksiyonu, modelimizin nasıl çalıştığını değerlendirebileceğimiz veya ölçebileceğimiz bir yöntemdir. Maliyet fonksiyonu olarak da bilinen kayıp fonksiyonu, algoritmamızın veri kümesini ne kadar iyi modellediğini değerlendirmek için kullanılan matematiksel bir fonksiyondur[115]. Algoritmanın parametrelerinin fonksiyonudur. Kayıp fonksiyonunun değeri daha düşükse modelimiz iyi çalışıyor demektir, aksi halde kaybı azaltmak veya en aza indirmek için modelin parametresini değiştirmek zorundayız. Eğitim süresi boyunca modelin parametrelerini, yani ağırlıkları ve

önyargıları ayarlama öğrenme algoritmasına rehberlik eder.

Derin Öğrenmede, bir modelin eğitimi için kayıp fonksiyonunun seçimi çok önemlidir. Farklı görev türleri (sınıflandırma, regresyon vb.) farklı kayıp fonksiyonları gerektirir. Kayıp işlevi, sinir ağlarınıza çok fazla pratik esneklik sağlayabilir ve ağın çıktısının ağın geri kalanıyla tam olarak nasıl bağlanacağını tanımlayacaktır[116]. Kayıp çok yüksekse, bu büyük değer eğitim sırasında ağ üzerinden yayılacak ve ağırlıklar normalden biraz daha fazla değişecektir. Küçükse, ağ zaten iyi bir iş çıkardığından ağırlıklar çok fazla değişmeyecektir. Bu bölümde literatürde en yaygın kullanılan kayıp fonksiyonları açıklanacaktır.

3.4.1. Ortalama Kare Hatası (MSE)

Ortalama Karesel Hata (MSE), özellikle regresyon görevleri için derin öğrenmede en sık kullanılan kayıp işlevlerinden biridir. Tahmin edilen değerler ile gerçek değerler arasındaki ortalama kare farkını ölçer[117]. MSE'nin nasıl hesaplandığı Denklem $MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$ (3.7)'de gösterilmiştir. Burada n, veri kümesindeki örneklerin sayısı, y_i , i'inci örnek için gerçek hedef değerdir. MSE, kare alma işlemi nedeniyle büyük hataları küçük hatalardan daha ağır şekilde cezalandırır. Farklılaştırılabilir olması, stokastik gradyan iniş (SGD) veya bunun varyantları gibi gradyan tabanlı optimizasyon algoritmalarını kullanan sinir ağlarının eğitimi için uygun olmasını sağlar[118].

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (3.7)$$

MSE, verilerdeki aykırı değerlere karşı duyarlıdır çünkü kareleri alınan farklar büyük hataların etkisini artırabilir. Aykırı değerlerin mevcut olduğu durumlarda, Ortalama Mutlak Hata (MAE) veya Huber kaybı gibi diğer kayıp fonksiyonları daha sağlam alternatifler olabilir. Ek olarak, sınıflandırma görevleri için, MSE yerine genellikle İkili Çapraz Entropi veya Kategorik Çapraz Entropi gibi çapraz entropi bazlı kayıp fonksiyonları kullanılır[119]. MSE, tahmin edilen ve gerçek değerler arasındaki kare farkların ortalamasıdır. Gerçek zamanlı projelerde önemlidir çünkü modelin ne kadar iyi performans gösterdiğini niceliksel olarak ölçmemize olanak tanır[120].

3.4.2. İkili Çapraz Entropi Kaybı

Log kaybı veya lojistik kayıp olarak da bilinen İkili Çapraz Entropi Kaybı, derin öğrenmedeki ikili sınıflandırma görevlerinde kullanılan yaygın bir kayıp fonksiyonudur[121]. Tahmin edilen olasılıklar ile gerçek ikili etiketler arasındaki farklılığı ölçer. İkili çapraz entropi,

yalnızca 2 kategori arasında sınıflandırma sorunu olduğunda kullanılan kayıp fonksiyonudur. Basitçe "çapraz entropi" olarak da bilinen çapraz entropi kaybı, bir sınıflandırma modelinin ne kadar etkili çalıştığını değerlendirmek için kullanılan bir ölçüdür. Modelin hatalarından ders almasını sağlayarak daha iyi tahminler yapmasına destek olur[122]. Basitçe ifade etmek gerekirse, modelin öngördüğü ile gerçekte doğru olan arasındaki tutarsızlığı ölçer. Tek bir örnek için ikili çapraz entropi kaybı Denklem $\dot{ÇEK} = \frac{1}{N} \sum_{i=1}^N (y_i \log(\hat{y}_i)) + (1 - y_i) \log(1 - \hat{y}_i)$ (3.8 de gösterilmiştir).

$$\dot{ÇEK} = \frac{1}{N} \sum_{i=1}^N (y_i \log(\hat{y}_i)) + (1 - y_i) \log(1 - \hat{y}_i) \quad (3.8)$$

Uygulamada, İkili Çapraz Entropi Kaybı tipik olarak bir sinir ağının çıkış katmanında sigmoid aktivasyon işleviyle kullanılır. Sigmoid aktivasyon fonksiyonu, ağın çıkışını [0,1] aralığına sıkıştırarak, her numunenin pozitif sınıfa ait olma olasılığı olarak yorumlanabilecek tahmin edilen olasılıkları üretir[123]. İkili çapraz entropi kaybı, amacın girdileri iki sınıftan birine (örneğin spam tespiti, tıbbi teşhis) sınıflandırmak olduğu ikili sınıflandırma problemleri ve modelin çıktısının belirli bir sınıfa ait olma olasılığı olduğu lojistik regresyon. Genel olarak, ikili çapraz entropi kaybı, etkinliği ve gradyan inişine dayalı yöntemler kullanılarak optimizasyona uygunluğu nedeniyle ikili sınıflandırma görevleri için popüler bir seçimdir.

3.4.3. Kategorik Çapraz Entropi Kaybı

Softmax kaybı veya negatif log-olabilirlik kaybı olarak da bilinen Kategorik Çapraz Entropi Kaybı, derin öğrenmede çok sınıflı sınıflandırma görevlerinde yaygın olarak kullanılan bir kayıp fonksiyonudur[124]. Tahmin edilen sınıf olasılıkları ile gerçek tek sıcak kodlanmış sınıf etiketleri arasındaki farklılığı ölçer. Kayıp fonksiyonu, tahmin edilen olasılıkların gerçek sınıf etiketleriyle eşleşmesini teşvik eder. Doğru sınıfların olasılıklarını tahmin etmede büyük hataları cezalandırır ve ağın parametrelerini buna göre ayarlaması için güçlü bir sinyal sağlar. Kategorik çapraz entropi kaybı hesaplanma şekli Denklem $KÇEK = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C y_{ij} \log(\hat{y}_{ij})$ (3.9 da gösterilmiştir).

$$KÇEK = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C y_{ij} \log(\hat{y}_{ij}) \quad (3.9)$$

Burada C sınıf sayısı, y_i gerçekte sınıfı (0 veya 1), y^i i'inci sınıfın tahmin edilen

olasılığı ve log doğal logaritmayı belirtir. Uygulamada, kategorik çapraz entropi kaybı, softmax aktivasyon fonksiyonuna sahip bir sinir ağının çıkış katmanında yaygın olarak kullanılır. Softmax aktivasyon fonksiyonu, çıktı logitlerini olasılıklara göre normalleştirerek tüm sınıflarda toplamalarının 1 olmasını sağlar[125]. Kategorik çapraz entropi, amacın girdileri birden fazla sınıftan birine sınıflandırmak olduğu çok sınıflı sınıflandırma problemleri (örneğin, görüntü sınıflandırması, duygu analizi) ve modelin hedef kelime dağılımı üzerindeki olasılık dağılımını tahmin ettiği sinirsel makine çevirisi problemlerinde yaygın olarak kullanılır. Genel olarak, Kategorik çapraz entropi kaybı, etkinliği, gradyan inişine dayalı yöntemler kullanılarak optimizasyona uygunluğu ve tahmin edilen ve gerçek sınıf dağılımları arasındaki tutarsızlığın bir ölçüsü olarak net yorumlanması nedeniyle çok sınıflı sınıflandırma görevleri için standart bir seçimdir[126].

3.4.4. Zar (Dice) Kaybı

Zar Kaybı, özellikle ön plan ve arka plan sınıfları arasında sınıf dengesizliğinin mevcut olduğu senaryolarda, görüntü bölümlendirmeyi içeren görevlerde yaygın olarak kullanılan bir kayıp işlevidir[127]. İki küme arasındaki benzerliği ölçen, Sørensen-Dice katsayısı olarak da bilinen Zar katsayısına dayanmaktadır. Zar kaybı, görüntü segmentasyon görevlerinde yaygın olarak kullanılır. Tahmin edilen ve gerçek segmentasyon maskeleri arasındaki örtüşmeyi ölçer. Model, Zar kaybını optimize ederek nesne sınırlarını doğru şekilde tanımlamayı ve ince taneli ayrıntıları yakalamayı öğrenir. Zar katsayısı Denklem $DSC = \frac{2x|X \cap Y|}{|X| + |Y|}$ (3.10'da gösterilmiştir.

$$DSC = \frac{2x|X \cap Y|}{|X| + |Y|} \quad (3.10)$$

Burada X, temel doğruluk segmentasyon maskesinde belirli bir sınıfa atanan piksel kümesi, Y, model tarafından o sınıfa ait olduğu tahmin edilen piksel kümesi ve $| \cdot |$ bir kümenin önem derecesini (eleman sayısını) belirtir. Zar katsayısı 0 ile 1 arasında değişir; daha yüksek değerler, tahmin edilen ve temel gerçek segmentasyonları arasında daha fazla benzerliğe işaret eder. Zar Kaybı, Zar katsayısının tamamlayıcısı olarak tanımlanır ve bu da onu optimizasyon için uygun bir kayıp fonksiyonu haline getirir[128]. Zar kaybı Denklem $DSC Loss = 1 - \frac{2x|X \cap Y|}{|X| + |Y|}$ (3.11'de gösterilmiştir.

$$DSC Loss = 1 - \frac{2x|X \cap Y|}{|X| + |Y|} \quad (3.11)$$

Eğitim sırasındaki amaç Zar Kaybını en aza indirmektir, bu da modeli temel gerçek maskeleriyle yakından eşleşen segmentasyonlar üretmeye teşvik eder. Zar kaybı, ön plandaki sınıfın (ilgi konusu nesnenin) arka plandaki sınıfa göre çok daha küçük olduğu durumları doğal olarak ele aldığından, sınıf dengesizliğinin mevcut olduğu senaryolarda özellikle kullanışlıdır[129]. Zar kaybı, tahmin edilen ve temel gerçek segmentasyonları arasındaki anlaşmazlığı cezalandırarak, segmentasyon görevindeki nesnelerin ince ayrıntılarının ve sınırlarının yakalanmasına yardımcı olur.

Zar kaybı genellikle görüntü segmentasyon görevleri için çok görevli bir öğrenme kurulumunda İkili Çapraz Entropi veya Kategorik Çapraz Entropi gibi diğer kayıp fonksiyonlarıyla birlikte kullanılır. Model, Piksel bazında sınıflandırma kayıplarının yanı sıra Zar kaybını da dahil ederek hem her pikseli sınıflandırmayı hem de doğru sınırlarla segmentasyonlar üretmeyi öğrenebilir[130]. Genel olarak zar kaybı, tıbbi görüntü segmentasyon görevlerinin yanı sıra görüntülerdeki nesnelerin kesin olarak tanımlanmasının önemli olduğu diğer alanlarda da popüler bir seçimdir.

3.5. Transfer Öğrenme

Transfer öğrenme, daha önce eğitilmiş derin öğrenme yöntemleri ile yeni bir problemle karşılaşıldığında bu bilgilerin tekrar kullanılmasını sağlayan bir yöntemdir[131]. Transfer öğrenimi ile önceki veriler kullanılarak modeller daha az veri seti ile daha iyi sonuçlar üretebilirler. Daha önce çok büyük veri setleri kullanılarak eğitilen modeller yeni sınıflandırma problemlerinde transfer öğrenme yöntemi ile kullanılabilir. Ancak veri seti ve sınıflandırma süreci ortak özellikler taşımalıdır. İlgisiz veri setleri kullanılarak transfer öğrenme yöntemi kullanılamaz. Örneğin beyin tümörü tespiti için akciğer veri seti ile önceden eğitilmiş bir model kullanılamaz[37].

Bir sinir ağı modeli, görüntü sınıflandırma, nesne algılama veya doğal dil işleme gibi belirli bir görev için büyük bir veri kümesi üzerinde eğitilir. Bu model, girdi verilerinden yararlı özellikler çıkarmayı ve göreve uygun tahminler yapmayı öğrenir[132]. Ön eğitim sonrasında modelin öğrenilen özellikleri yeni bir göreve aktarılabilir. Tüm modeli sıfırdan eğitmek yerine, önceden eğitilmiş model, özellik çıkarıcı olarak kullanılır. Önceden eğitilmiş modeldeki bir veya daha fazla katmanın çıktısı, daha sonra yeni göreve göre eğitilen yeni bir model için girdi

özellikleri olarak kullanılır. Bazı durumlarda aktarılan modelin ağırlıklarına yeni göreve göre ince ayar yapılır. Bu, yeni veri kümesi üzerinde eğitim sırasında önceden eğitilmiş modelin katmanlarının ağırlıklarının güncellenmesini içerir. İnce ayar, modelin öğrenilen temsillerini yeni görevin özelliklerine daha iyi uyacak şekilde uyarlamasına olanak tanır[133].

Önceden eğitilmiş model, büyük bir veri kümesinden yararlı özellikleri zaten öğrendiğinden, sıfırdan eğitime kıyasla yeni görev üzerinde eğitim almak için daha az veri ve daha az hesaplama kaynağı gerektirir. Çeşitli veri kümelerinden öğrenilen özelliklerden yararlanarak, transfer öğrenimi genellikle yeni görevlere iyi genelleme yapan modellere yol açar, özellikle de yeni görev sınırlı eğitim verisine sahip olduğunda. Transfer öğrenimi, özellikle önceden eğitilmiş modelin geniş ve çeşitli bir veri kümesi üzerinde eğitildiği durumlarda, yeni görevde performansın iyileşmesine yol açabilir[134]. Transfer öğrenimi, bilgisayarlı görme, doğal dil işleme ve konuşma tanıma dahil olmak üzere çeşitli alanlarda yaygın olarak kullanılmaktadır. Transfer öğrenimine yönelik popüler önceden eğitilmiş modeller arasında bilgisayarlı görme görevleri için VGG, ResNet ve Inception gibi ImageNet tarafından önceden eğitilmiş modeller ve doğal dil işleme görevleri için BERT ve GPT gibi modeller yer alır.

4. VERİ SETLERİ, VERİ ÖN İŞLEME VE DEĞERLENDİRME METRİKLERİ


Bu tez çalışmasında önerilen modeller ve veri setleri, belirli bir görev veya problem alanına bağlı olarak seçilmiştir. Her yöntemin benzersiz gereksinimleri ve özellikleri olduğundan, uygun bir model ve veri seti seçerken detaylı literatür taramaları yaparak, amacımıza en uygun modeli ve bu model ile en iyi sonucu alabileceğimiz güvenilir veri setlerini kullandık. Bu bölümde, tez çalışması kapsamında, derin öğrenme yöntemlerini kullanarak beyin tümörü tespiti için geliştirdiğimiz modeller, yaptığımız veri ön işleme süreçleri, kullandığımız değerlendirme metrikleri ve elde ettiğimiz sonuçlar detaylı bir şekilde açıklanmıştır.

Veri ön işleme teknikleri, verileri analiz veya modelleme için hazırlamanın önemli adımlarıdır. Ham verileri temizlemeyi, dönüştürmeyi ve sonraki görevlere uygun bir formatta düzenlemeyi amaçlarlar. Veri ön işleme, derin öğrenme modelinin veri setini daha etkili bir şekilde öğrenmesine yardımcı olmak için kullanılan önemli bir adımdır[139]. Derin öğrenme modelleri genellikle büyük ve karmaşık veri setleri üzerinde eğitildiğinden, verinin kalitesi ve yapısının model performansını doğrudan etkileyebilir. Veri ön işleme süreçleri, veriyi temizlemek, öznitelikleri çıkarıp seçmek, boyut indirgeme yapmak ve veri setini normalize etmek gibi adımları içerebilir. Derin öğrenme modelleri için yaygın veri ön işleme süreçlerinden bazıları aşağıda açıklanmıştır.

4.1. BraTS 2019 Veri Seti

BraTS, "Beyin Tümörü Segmentasyonu" anlamına gelir ve beyin tümörlerini MRI görüntülerinden segmentlere ayırmaya yönelik farklı yöntemleri değerlendirmeyi ve karşılaştırmayı amaçlayan bir yarışmadır. BraTS yarışması, araştırmacıların BraTS veri setinin en son sürümünü kullanarak beyin tümörü segmentasyonu ve sınıflandırmasına yönelik algoritmalarını sunabilecekleri yıllık bir yarışmadır. BraTS 2019, çok merkezli ameliyat öncesi MRI taramalarını kullanıyor ve doğası gereği heterojen (görünüş, şekil ve histoloji açısından) beyin tümörlerinin, yani gliomaların segmentasyonuna odaklanıyor. BraTS (Brain Tumor Segmentation) 2019 veri seti T1, T2, Flair ve T1C sekanslarındaki beyin manyetik rezonans görüntülerinden oluşmaktadır. Her bir sekans 155 farklı MR görüntü parçalarından oluşmaktadır. Ayrıca, bu veri seti 259 yüksek dereceli glioma ve 76 düşük dereceli glioma olmak üzere toplam 335 vakadan meydana gelmiştir. Toplamda kamuya açık ve yarışmalarda kullanılan 335 farklı vakaya ait MR görüntüsü bulunmaktadır. Başlangıçta, bu veri seti, tam tümör, çekirdek tümör ve genişleyen tümör olmak üzere üç tür segmentasyon işlemi gerçekleştirmek için tasarlandı[135]. Her MR sekansında birer örnek görüntü Şekil 4.1'de

gösterilmiştir.




Şekil 4.1. BraTS 2019 MR görüntülerinin 4 farklı sekans örneği

Gliomalar, nekrotik (çekirdek) doku, ödem, genişleyen ve genişlemeyen tümör olmak üzere dört kısımdan oluşmaktadır. Segmentasyon değerlendirmesi için gliomalar, tam tümör, nekroz yani çekirdek tümör ve genişleyen tümör olmak üzere 3 farklı bölüitten oluşmaktadır. Jiang ve arkadaşları, arka planda tümör olmayan bölge, nekroz, ödem ve genişleyen olmak üzere görüntüleri dört etiketli sınıfa ayırdı[136]. 2B eksenel dilim görünümünün seçilmesi sağlanan tümör bilgisini ayırt edebilir. Ayrıca eğitim için veri setinin %70'i (235 hasta), doğrulama için %15'i (50 hasta) ve geri kalan %15'i (50 hasta) görüntüler modelin test edilmesi için ayrılmıştır. Veri setindeki MR görüntülerinin her bir sekansından birer örnek görüntü Şekil 4.1'de gösterilmiştir.

4.2. Kaggle (figshare) Veri Seti


Kaggle veri seti, glioma, meningioma (menenjiyom) ve hipofiz (pituitary) tümörleri gibi üç farklı beyin tümörü tipini içeren 3064 T1 ağırlıklı görüntüden oluşmaktadır. Üç farklı sınıf MR görüntüsü içeren bu veri seti Kaggle'dan indirildi. Veri seti <https://www.kaggle.com/datasets/ashkhagan/figshare-brain-tumor-dataset> linkinden indirilebilir. Glioma (1426 dilim), meningioma (menenjiyom) (708 dilim) ve hipofiz (930 dilim) dahil olmak üzere 233 hastada üç tip beyin tümörü vardır. Veri setinde 2 boyutlu görüntülerin orijinal boyutları 512 x 512 ve piksel boyutu 0,49 x 0,49 mm²'dir. Kesit genişliği 6 mm ve kesit aralığı 1 mm'dir[137]. Alınan görüntüler incelenerek bozuk görseller veri setinden çıkarıldı. Tümör boyutları dikkate alınarak yeniden boyutlandırma işlemi yapılmış olup, tümörlerde herhangi bir yapısal bilgi kaybı yaşanmamıştır[138]. Dört farklı sınıfa ait örnek görseller Şekil 4.2'de gösterilmektedir.




Şekil 4.2. Dört farklı sınıfa ait MR görüntüleri

4.3. Kaggle (Br35H) Veri Seti

Bu tez çalışmasında kullanılan veri setlerinden biri de, beyin tümörünün teşhisine yönelik Beyin MR Görüntüleri (Br35H) adı verilen Kaggle veri setidir. İki sınıf MRI taramasından oluşur. 1500 tümörlü olmayan beyin MR görüntüsü, 1500 tümörlü beyin MR görüntüsü bulunmaktadır. Bunların dışında veri setinde 60 adet tahmin için MR görüntüsü bulunmakta olup toplamda 3060 adet görüntü içermektedir. Bu veriler 3 ayrı klasör şeklinde düzenlenmiştir. Veri seti <https://www.kaggle.com/datasets/ahmedhamada0/brain-tumor-detection> adresinden ücretsiz olarak indirilebilir. Tümör var ve tümör yok sınıflarına ait örnek görüntüler Şekil 4.3 ve Şekil 4.4'te gösterilmiştir.



Şekil 4.3. Tümörlü görüntüler



Şekil 4.4. Tümörlü olmayan (normal) görüntüler

4.4. Veri Arttırma

Tıbbi veri analizinde en büyük sorunlardan biri ihtiyaç duyulan verilere erişimin sınırlı olmasıdır. Verilerin ilgili kuruluşlardan alınabilmesi için birçok izin alınması gerekmekte olup aynı zamanda bu veriler işlenebilecek durumda olmayabilir. Bu nedenlerden dolayı tıbbi veri analizi genellikle az miktarda veri seti ile kullanılmaktadır. Bu durum eğitim modelinin başarısını etkilemektedir. Modelin verimli bir şekilde öğrenebilmesi için mevcut veri setinin büyük olması gerekir. Modelin verimli şekilde öğrenilmesi modelin performansını da artıracaktır. Bu nedenle eğitilecek yeterli veriye sahip olmak oldukça önemlidir. Bunun için artırma teknikleri kullanılarak veri çoğaltma yapılabilir. Veri artırma, derin sinir ağlarının öğrenme yeteneklerinin artırılmasına yardımcı olan ve ağların düzenlenmesini sağlayan bir yöntemdir. Doğru tekniklerle veri büyütme sadece modelin başarısını artırmakla kalmayacak aynı zamanda aşırı uyumu da azaltacaktır[140].

Görüntü büyütme, bir görüntüden yeni bir görüntü oluşturmakla ilgili değildir. Tamamen ilk görüntünün farklı açılardan görüntülerinin elde edilmesidir. Elde edilen yeni görüntü, ilk görüntünün farklı perspektiflerinden oluşmaktadır[141]. Eski görüntünün her bir kopyası, o görüntünün farklı teknikler uygulanarak elde edilen bir örneğini temsil eder. Bunun sonucunda elde edilen yeni görüntü, modelin eğitimini kolaylaştırmakta ve görüntüdeki özelliklerin daha yüksek oranda yakalanmasını sağlamaktadır. Veri artırmayı uygulayarak eğitim veri kümesinin boyutunu etkili bir şekilde artırabilirsiniz; bu, aşırı uyumun önlenmesine ve derin öğrenme modellerinizin genelleme performansının iyileştirilmesine yardımcı olabilir. Bununla birlikte, oluşturulan verilerin anlamsal olarak anlamlı kalmasını sağlamak için, spesifik veri alanınıza ve sorun bağlamınıza uygun genişletme tekniklerini uygulamak önemlidir. Ayrıca, model performansını düşürebilecek gerçekçi olmayan veya ilgisiz varyasyonların ortaya konulmasından kaçınmaya özen gösterilmelidir.

Veri artırma, mevcut verilere çeşitli dönüşümler uygulayarak bir veri kümesinin boyutunu yapay olarak artırmak için derin öğrenmede yaygın olarak kullanılan bir tekniktir. Bu yaklaşım, modelin genelleştirilmesinin ve sağlamlığının geliştirilmesine, onu verilerdeki daha geniş bir çeşitlilik aralığına maruz bırakarak yardımcı olur. Bu yöntemde orijinal görüntü üzerinde döndürme, çevirme, yakınlaştırma, kırpma ve çevirme işlemleriyle aynı görüntünün farklı açılardan yeni bir görüntüsü elde edilir[142]. Bir diğer veri artırma tekniği ise sentetik veri üretimidir. İlk yapay görüntüler, Goodfellow'un 2014 yılında tanıttığı ve evrişimli sinir ağı mimarisinden farklı olan GAN: Generative Adversarial Network ile üretildi. Genel GAN mimarisinde iki derin ağ vardır; jeneratör ve ayırıcı. Ayırıcı ağ sahte ve gerçek görüntüleri ayırmaya çalışırken, jeneratör ağı gürültü ekleyerek gerçekçi görüntüler üretmeyi hedefliyor[21].

4.5. Normalizasyon (Normalleştirme)

Derin öğrenme bağlamında normalleştirme, tipik olarak girdi verilerine bir sinir ağına beslenmeden önce uygulanan bir ön işleme adımını ifade eder. Bu anlamda normalleştirme, giriş özelliklerinin genellikle 0 ile 1 arasında veya ortalama 0 ve standart sapma 1 olacak şekilde benzer bir aralığa ölçeklendirilmesini içerir[143]. Bu ön işleme adımı sinir ağının, optimizasyon algoritmasının yakınsamasını geliştirmeye ve genel performansı artırmaya yardımcı olabilir. Derin öğrenmede kullanılan birkaç yaygın normalleştirme tekniği vardır.

Normalleştirme, derin öğrenmede çok önemlidir çünkü belirli özelliklerin, daha büyük ölçekleri veya farklılıkları nedeniyle öğrenme sürecine hâkim olmasını önlemeye yardımcı olur. Ayrıca eğitim süreci sırasında sayısal istikrarsızlıkların önlenmesine de yardımcı olabilir. Ancak normalleştirme tekniğinin ve parametrelerinin seçimi, verilerin belirli özelliklerine ve sinir ağı mimarisinin gereksinimlerine bağlıdır. Özet olarak, derin öğrenmede bir ön işleme adımı olarak normalleştirme, girdi özelliklerinin benzer ölçekte olmasını sağlamaya yardımcı olur ve sinir ağlarının verimli eğitimini ve yakınsamasını kolaylaştırır.

4.5.1. Minimum-Maksimum Ölçeklendirme

Bu yöntem, minimum değeri çıkarıp ardından maksimum ve minimum değerler arasındaki farka bölerek verileri genellikle 0 ile 1 arasında sabit bir aralığa ölçeklendirir[144]. Normalleştirmenin en basit yöntemlerinden biridir ve çeşitli makine öğreniminde ve yaygın olarak kullanılır. Ölçeklendirme işlemi Denklem $X_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}}$ (4.1)'de gösterilmiştir.

$$X_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (4.1)$$

4.5.2. Ortalama Normalleştirme

Merkezlleme veya sıfır ortalama olarak da bilinen normalleştirme, bir özelliğin ortalamasını sıfıra ayarlamak için kullanılan bir veri ön işleme tekniğidir. Bu yöntem, özelliğin ortalamasının her veri noktasından çıkarılmasını içerir, bu da özelliğin ortalamasının sıfır olduğu ortalama kaydırmalı bir dağılımla sonuçlanır[146]. Hesaplama şekli Denklem $X_{normalized} = X - \mu$ (4.2)'de gösterilmiştir. $X_{normalized}$ özelliğin normalleştirilmiş değeri, X , özelliğin orijinal değeri

ve μ özelliğın ortalamasıdır.

$$X_{normalized} = X - \mu \quad (4.2)$$

Ortalamaların normalleştirilmesi, verilerin sıfırlanması etrafında ortalar; Bu, belirli programlar, özellikle de sıfırlanmış veriler varsayan veya özelliklerin duyarlı olmayanlar için faydalı olabilir. Gradyanların çok büyük veya çok küçük olmasını önleyerek, gradyan düşüşleri gibi büyümelerinin yakınsamasının gerçekleşmesine yardımcı olabilir. Ancak ortalama normalleştirmenin verilerin ölçeğini veya yayılmasını etkilemediğini unutmamak önemlidir. Bu nedenle özelliklerin farklı ölçek veya varyanslara sahip olması tek başına yeterli olmayabilir. Bu gibi durumlarda ortalama normalleştirmeyi standardizasyon (Z-skoru normalleştirme) veya Min-Maks ölçeklendirme gibi ölçeklendirme teknikleriyle birleştirmek daha uygun olabilir.

4.5.3. Standardizasyon (Z-puan normalizasyonu)

Z-puanı normalizasyonu veya Z-puanı ölçeklendirme olarak da bilinen standardizasyon, sayısal özellikleri ortalama 0 ve standart sapma 1 olacak şekilde ölçeklendirerek dönüştürmek için kullanılan bir veri ön işleme tekniğidir[147]. Çeşitli makine öğreniminde ve istatistiksel uygulamalarda yaygın olarak kullanılan bir tekniktir. Hesaplanma

$$\text{şekli Denklem } X_{standardized} = \frac{X - \mu}{\sigma} \quad (4.3\text{te})$$

gösterilmiştir. Burada, $X_{standart}$, özelliğın standartlaştırılmış değeri, X , özelliğın orijinal değeri, μ özelliğın ortalaması ve σ özelliğın standart sapmasıdır.

$$X_{standardized} = \frac{X - \mu}{\sigma} \quad (4.3)$$

Standardizasyon, veri dağılımını ortalama 0 ve standart sapma 1 olacak şekilde dönüştürerek normal dağılımlı verileri varsayan veya bundan yararlanan algoritmalar için uygun hale getirir. Verileri sıfır etrafında ortalar ve ortak bir standart sapmaya göre ölçeklendirir, böylece özellikler arasında daha kolay karşılaştırma yapılmasına olanak tanır. Standartlaştırma, tüm veri aralığını sabit bir aralığa sıkıştırmadığı için Min-Maks ölçeklendirme gibi diğer ölçeklendirme teknikleriyle karşılaştırıldığında aykırı değerlere karşı dayanıklıdır. Ölçeği ayarlarken orijinal dağılımın şeklini korur. Bu, verilerin değişken ölçeklere sahip olduğu ve algoritmanın performansının ölçek ve özelliklerin dağılımına duyarlı olduğu durumlarda, onu özellikle yararlı kılar.

4.5.4. Toplu Normalleştirme

Toplu Normalleştirme, derin öğrenmede dahili ortak değişken kayması sorununu çözmek için kullanılan bir tekniktir; bu, eğitim sırasında ağı parametreleri güncellendiğinde gizli katmanlardaki aktivasyonların dağılımındaki değişikliği ifade eder. Bu değişim, daha düşük öğrenme oranları gerektirerek eğitim sürecini yavaşlatabilir ve daha derin ağların eğitilmesini zorlaştırabilir. Toplu Normalleştirme, bir mini grup içindeki her katmanın aktivasyonlarını normalleştirerek bu sorunu giderir[148]. Normalleştirme, aktivasyonların hem toplu boyutu hem de özellik boyutu genelinde gerçekleştirilir. Normalleştirmeden sonra, modelin her özellik için en uygun ölçeği ve ortalamayı öğrenmesine olanak sağlamak amacıyla aktivasyonlar, öğrenilebilir parametreler (gamma ve beta) kullanılarak ölçeklendirilir ve kaydırılır. M'nin parti boyutu olduğu bir mini aktivasyon grubu $\{x^{(1)}, x_1^{(2)}, \dots, x_1^{(m)}\}$, göz önüne alındığında, belirli bir x özelliği için toplu normalizasyon işlemi Denklem $\hat{x}^{(i)} = \frac{x^{(i)} - \mu}{\sigma^2 + \epsilon}$

$$\hat{x}^{(i)} = \frac{x^{(i)} - \mu}{\sigma^2 + \epsilon} \quad (4.4)$$

$$y^{(i)} = \gamma \hat{x}^{(i)} + \beta \quad (4.5)$$

Burada, μ mini partinin ortalaması, mini grubun varyansı, ϵ , sıfıra bölünmeyi önlemek amacıyla sayısal kararlılık için eklenen küçük bir sabit, x^2 normalleştirilmiş aktivasyon, γ normalleştirilmiş aktivasyonu ölçeklendiren öğrenilebilir bir parametre, β normalleştirilmiş aktivasyonu kaydıran öğrenilebilir bir parametre ve $y^{(i)}$ ölçeklendirme ve kaydırma sonrasındaki çıktıdır. Eğitim sırasında Toplu Normalleştirme, her mini grubun ortalamasını ve varyansını hesaplar ve bunları aktivasyonları normalleştirmek için kullanır. Bununla birlikte, çıkarım (değerlendirme) sırasında ortalama ve varyans, tutarlılığı sağlamak için genellikle eğitim veri kümesinin tamamı veya eğitim veri kümesinin hareketli ortalaması üzerinden hesaplanır.

Toplu Normalleştirme, dahili ortak değişken kaymasını azaltarak eğitim sürecinin dengelenmesine ve hızlandırılmasına yardımcı olur[149]. Aynı zamanda bir düzenleyici görevi görerek bırakma gibi diğer düzenleme tekniklerine olan ihtiyacı azaltır. Ek olarak, eğitimi daha da hızlandırabilecek daha yüksek öğrenme oranlarının kullanılmasına olanak tanır. Genel olarak Toplu Normalleştirme, derin sinir ağı mimarilerinin standart bir bileşeni haline gelen güçlü bir

tekniktir.

4.6. Değerlendirme Metrikleri

Değerlendirme metrikleri, bir modelin performansını ölçmek için kullanılan ölçütlerdir ve uygulama alanına göre değişebilir. Görüntü işleme veya bilgisayarlı görmedeki segmentasyon görevlerine yönelik değerlendirme metrikleri, segmentasyon algoritmalarının performansını değerlendirmek için çok önemlidir. Değerlendirme metrikleri, temel gerçek açıklamalarıyla karşılaştırıldığında tipik olarak segmentasyon çıktısının kalitesini değerlendirir. Karşılaştırılabilir görüntülerdeki benzer pikselleri (kesişme, giriş ve çıkış görüntülerini alarak) sayan ve bunu her iki görüntüdeki toplam piksel sayısına bölen modelimizi değerlendirmek için Zar Benzerliği Katsayısı (DSC) ölçülür. DSC, 0 ile 1 arasında aralık değerlerine sahip ikili görüntüler arasındaki uzamsal örtüşme oranı aracılığıyla, temel doğruluk segmentasyonu sonuçları karşılaştırılarak ölçülür; burada 0, eşleşme olmadığını ve 1, mükemmel eşleşmeyi temsil eder[150].

$$\text{Denklem} \quad DSC = \frac{2x|X \cap Y|}{|X| + |Y|}$$

(4.6 DSC'nin formülasyonunu temsil eder; burada X ve Y, tümörlü veya tümörsüz görüntüleri temsil eden ikili sınıflardır. Benzer şekilde jaccard indeks ölçüsü hesaplanır, Denklem $Jaccard = \frac{2x|X \cap Y|}{|X \cup Y|}$ (4.7 de

gösterilmiştir. Diğer bir değerlendirme ölçütü, segmentasyonda yaygın olarak kullanılan Ortalama Kesişme-Birleşim (IoU)'dir, Denklem 4.8'de gösterilmiştir. Hassasiyet (Gerçek pozitif oran) Denklem $Duyarlilik = \frac{X \cap Y}{Y}$ (4.9 da

ve özgüllük (Gerçek Negatif Orandır) Denklem $Kesinlik = \frac{|(B-X) \cap (B-Y)|}{|B-Y|}$

(4.10 da gösterilmiştir[151].

$$DSC = \frac{2x|X \cap Y|}{|X| + |Y|} \quad (4.6)$$

$$Jaccard = \frac{2x|X \cap Y|}{|X \cup Y|} \quad (4.7)$$


$$Mean IoU = \frac{|X \cap Y|}{|X \cup Y|} \quad (4.8)$$

$$Duyarlilik = \frac{X \cap Y}{Y} \quad (4.9)$$

$$Kesinlik = \frac{|(B-X) \cap (B-Y)|}{|B-Y|} \quad (4.10)$$

Daha önce de belirtildiği gibi DSC, boyut ve lokalizasyonu algısal kaliteyle yansıtan tıbbi görüntü segmentasyonunda oldukça popülerdir. Ayrıca, tıbbi görüntü segmentasyonunda

sıklıkla kullanılan bir doğrulama ölçüsü olan örtüşme indeksi olarak da bilinir. Daha önce bahsedilen nedenlerden dolayı piksel bazında doğrulukla karşılaştırıldığında daha iyidir. Gri alan, manuel olarak etiketlenen bölgeleri, mavi, tahmin edilen bölgeleri, yeşil alanlar, tahmin edilen gerçek ile temel gerçek arasındaki örtüşme alanını belirtir. Otomatik ve temel doğruluk segmentasyonu karşılaştırıldığında tekrarlanabilirliği ölçmek için DSC kullanılır. DSC'nin görsel formülasyonu Şekil 4.5'te gösterilmektedir.



Şekil 4.5. DSC formülasyonunun gösterimi

Modelin başarısını ölçmek için doğru metrikleri seçmek oldukça önemli bir noktadır. Sınıflandırma problemlerinde performans ölçümü ve modelin değerlendirilmesi için daha farklı metrikler kullanılmaktadır. Sınıflandırma için en önemli değerlendirme ölçütü Accuracy (Doğruluk)'tur. Doğruluk formülü Denklem $\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN}$ (4.11'de gösterilmiştir. Bunun yanında duyarlılık, kesinlik ve F1 puan ölçümleri diğer en önemli metriklerdir. Bu metriklerin genel olarak sınıflandırma süreçlerinde kullanılması ve literatürde genel olarak kabul görmesi, an yaygın kullanılmasının temel sebebidir[152]. Sınıflandırmada kullanılan diğer önemli bir metrik ise karışıklık (hata) matrisidir. Karışıklık matrisi, gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) parametrelerden oluşur. Gerçek pozitif ve gerçek negatif model doğru sınıflandırmadır. Yanlış

pozitif ve yanlış negatif, modelin yanlış sınıflandırılmasıdır[37]. Doğruluk, bir modelin doğru şekilde sınıflandırılma kapasitesidir. Hassasiyet, pozitif olarak tahmin edilmesi gereken işlemlerden kaçının pozitif olarak tahmin edildiğini göstermektedir. Denklem $F1 Puanı = \frac{2*Precision*Recall}{Precision+Recall}$ (4.122’de gösterilen F1 puanı, bir testin doğruluğunun ölçüsüdür; kesinlik ve duyarlılığın harmonik ortalamasıdır. Maksimum 1 (mükemmel hassasiyet ve kesinlik) ve minimum 0 değerine sahip olabilir[153].

$$Doğruluk = \frac{TP+TN}{TP+TN+FP+FN} \quad (4.11)$$

$$F1 Puanı = \frac{2*Precision*Recall}{Precision+Recall} \quad (4.122)$$

5. ÖNERİLEN MODELLER

Bu tez çalışmasında MR görüntüleri kullanarak beyin tümörlerini otomatik tespit etmeye yönelik çalışmalar gerçekleştirildi. Beyin tümörü tespitinin temel amacı, tipik olarak beyin MRI (Manyetik Rezonans Görüntüleme) taramaları gibi tıbbi görüntüleme verileri içindeki tümörlerin sınırlarını ve tümör tiplerini doğru bir şekilde tanımlamak ve özetlemektir. Bu görev, beyin tümörü hastalarının tıbbi teşhisinde, tedavi planlamasında ve izlenmesinde birçok önemli amaca hizmet eder. Bu nedenle bu tez çalışmasına başlarken temel motivasyonumuz insan hayatı için son derece önemli olan konuya önemli bir katkı sağlamak ve literatürde elde edilmiş başarıları daha yüksek bir seviyeye çıkarmaktır. Bu nedenle tez çalışmasına başlamadan önce bu alanda yapılmış birçok çalışmayı inceledik ve bu çalışmalarda kullanılan modelleri bizde aynı veri setleri ile çalıştırıp değerlendirdik. Bugüne kadar elde edilmiş sonuçlardan daha yüksek başarılı sonuçlar elde etmek için farklı modeller kullanmak veya yeni modeller geliştirmek gerekiyordu. Bizde bu kapsamda bazı çalışmalarımızda mevcut modelleri kullanıp farklı veri ön işleme teknikleri uyguladık. Bazı çalışmalarımızda mevcut ESA ağlarını iyileştirerek tamamen yeni ağlar tasarladık ve kullandık. Bazı çalışmalarımızda ise farklı ESA modellerini bir araya getirerek hibrit modeller kullandık. Bu bölümde, tez kapsamında yaptığımız çalışmaları, geliştirdiğimiz ve önerdiğimiz modeller ve elde ettiğimiz sonuçlar detaylı bir şekilde açıklanmaktadır.

5.1. Hibrit DenseNet-121-UNet Modeli Kullanarak MR Görüntülerinden Beyin Tümörü Segmentasyonu

Tümör segmentasyonunun temel amacı, aktif tümörlü dokuların, nekrotik dokuların ve ödemin (tümör yakınındaki şişlik) bölgelerini tespit etmektir. Bu tespitler, normal ve anormal bölgeler arasında ayırım yapılarak tanımlanabilir. Ancak infiltre glioma tümörlerinin sınırları belirsiz olduğundan tespit edilmesi zordur. Bu tür tümörler için çözüm, T1, T1C, T2 ve Flair sekansların birlikte kullanılmasıdır. Bu sekansların her biri farklı özelliklere sahiptir çünkü bu yöntemlerin her biri, her doku için benzersiz bir imza oluşturur[154]. Son yıllarda, derin sinir ağları (DNN'ler), yüksek doğruluk elde ederek görüntü bölümlenmede ümit verici sonuçlar göstermiştir[14]. Bu yöntemler başarılı olmasına rağmen hala dikkate alınması gereken sorunlar ve geliştirilmesi gereken alanlar bulunmaktadır.

İlk olarak, çoğu derin öğrenme tabanlı beyin tümörü segmentasyonu yaklaşımındaki temel sorun, yerel etiketler ve bağımlılıklar üzerinde iyi çalışmayan piksel sınıflandırmasını gerçekleştirmesidir. Piksel sınıflandırması, bir görüntüdeki tek tek piksellere bir etiket veya sınıf atama işlemini ifade eder. Bu teknik, görüntü işleme ve bilgisayarlı görme görevlerinde, özellikle de görüntü bölümlenme ve nesne tanıma gibi alanlarda yaygın olarak kullanılır. Piksel

bazlı sınıflandırmanın temel sınırlamalarından biri, hedef piksellerin sınıfının doğru bir şekilde tanımlanmasına yardımcı olabilen çevredeki piksellerden gelen bilgilerin kullanılmamasıdır.

İkincisi, literatürde önerilen birçok çalışmada tam tümör bölgesi yüksek DSC doğruluğu ile tespit edilmesine rağmen çekirdek tümör ve genişleyen tümör alanların tespitinde DSC oranı düşüktür. Bu sorunun temel neden çekirdek tümör ve genişleyen tümör bölgeleri daha küçüktür ve öznelikleri tespit etmek zorlaşmaktadır.

Bu zorlukların üstesinden gelmek için MR görüntülerinin ön işleme ve son işleme sürecine tabi tutulup hibrit bir DenseNet121-UNet modeli önerilmektedir. Bu çalışmanın iki temel motivasyon kaynağı bulunmaktadır; birincisi sınıf dengesizliği sorunun üstesinden gelmek, ikincisi ise tümörlü bölgede daha küçük alan kaplayan çekirdek tümör ve genişleyen tümör alanlarının tespit oranını arttırmaktır. Bu amaç doğrultusunda, görüntüyü tümör merkezi koordinatlarına ve tümör boyutuna göre (64x64) boyutlarında 1, 2 veya 4 parçaya bölüyoruz. Görüntü segmentasyon işlemi tamamlandıktan sonra bu (64x64) görselleri aynı koordinatları kullanarak birleştirilmektedir. Literatürde veri dengesizliği sorununu çözmek için 2 boyutlu hacimden küçük yamaların kullanılması yaygındır[155]. DenseNet121-UNet, kodlayıcı ve kod çözücü arasında parametre güncellemelerini kararlı hale getirmeye yardımcı olan atlama bağlantılarını kullanır. Genellikle daha derin ağlar, diğer modellere göre daha fazla özellik yakaladıklarından özellikle görüntü işlemede daha iyi performans gösterir. DenseNet121-UNet hibrit modeli, parametre güncellemesini stabilize ettiği için modelin daha sorunsuz ve verimli bir şekilde eğitilmesine yardımcı olan kısa bir atlama bağlantısı kullanır[18]. Literatürdeki diğer çalışmalar karşılaştırıldığında önerilen modelin daha etkili, rekabetçi olduğu ve daha iyi doğruluk elde ettiği görülmektedir.

Bu çalışmada beyin MR görüntülerin segmentasyonu için BraTS2019 veri seti kullanan bir hibrit DenseNet121-UNet mimarisi önerilmektedir. Ayrıca çekirdek tümörler ve genişleyen tümörler gibi küçük alanların segmentasyonunu kolaylaştırmak için görüntüleri ön işleme teknikleriyle normalleştirilmiş ve kırılmıştır. Literatürdeki benzer çalışmalarda çekirdek ve genişleyen tümör bölgeleri için DSC doğruluk değerleri çok düşüktür. Bu çalışmada bu tür alanların DSC doğruluğunu iyileştirmeye odaklanılmıştır. Sonuçlarımızı diğer temel yöntemlerle karşılaştırmak için verimli eğitim ve test sürecini tanımlayarak BRATS 2019 veri seti ile model eğitilmektedir. Önerilen hibrit DenseNet121-UNet modelinin ana katkıları aşağıdaki gibidir:

- Görüntüleri küçük parçalara bölerek eğittiğimiz için eğitim süresi daha kısadır.
- Dengesiz etiket dağılımlarında kritik olan veri kümesini ön işleme tabi tutarak hibrit bir model önerilmiştir.

- DenseNet121-UNet mimarisi kullanılarak beyin tümörü segmentasyonu için daha önce denenmemiş hibrit bir algoritma önerilmiştir.
- Özellik çıkarma için gereksiz alanlar tespit edilip ve görüntüler kırpılarak akldırılmıştır, bu da segmentasyon sürecinin doğruluğunu artırır ve modelin eğitim süresini kısaltır.
- Tam tümör, çekirdek tümör ve genişleyen tümör tiplerinde DSC oranında ciddi bir artış elde edilmiş diğer çalışmalara göre daha iyi sonuçlar elde edilmiştir.

5.1.1. Veri Ön İşleme Süreci

Gliomalar dört kategoriye ayrılır: (1) nekrotik doku, (2) ödem, (3) genişleyen tümörler ve (4) genişlemeyen tümörler. Segmentasyon değerlendirmesi için bu glioma dokuları üç gruba ayrılır: (1) Tüm Tümör, (2) nekrotik dokudan oluşan çekirdek tümör ve (3) genişleyen tümör[136]. BraTS veri setinde bulunan bölümlere ayrılmış görüntüler dört etiketli sınıfa ayrılır: (0) Arka planda tümör olmayan bölge, (1) Nekroz, (2) Ödem ve (3) genişleyen tümör. Önerilen modelimizde girdi görüntüleri (240, 240, 155) boyutlu eksenel dilim görünümü kullanılmıştır. Bu çalışmada eğitim için veri setinin %70'i (235 hasta), doğrulama için %15'i (50 hasta) ve geri kalan %15'i (50 hasta) veriler modelin test edilmesi için kullanılmıştır.

Ön işleme sürecinin ilk adımında, görüntülerin arka planında bulunan bazı siyah görseller beyin tümörü kategorisine ait olmadığı için elenmiştir. Tıbbi görüntü analizinde görüntünün tamamının kullanılmasına gerek yoktur. Bu nedenle görselin arka planını ve gereksiz kısımlarını kırparak kaldırmak gerekir[136]. Görüntülerin bazıları siyah dilimler (hiçbir bilgi içermeyen) içerir ve bunlar ön işleme adımında atılır[27]. Veri dağıtımındaki dengesizlik segmentasyonu zorlaştırıyor. Bu nedenle görüntüler kırpılarak küçük parçalara bölündü. Sonuç olarak daha küçük bir görüntü elde edildi ancak tümör alanının büyüklüğünde bir değişiklik olmadığı için veri dağılımındaki dengesizlik azaldı[156]. Tümör bölgesinin bloklara bölünmesindeki amaç görüntüden tümörün bulunmadığı kısımları çıkarmak ve modelin sadece tümör alanının özelliklerini tespit etmesini sağlamaktır. Farklı yöntemlerle tümör bölgesi tespit edilebiliyor ve bunun sonucunda kırpma işlemi uygulanabiliyor. Ancak modelin bu görselleri kabul edebilmesi için genişlik ve uzunluk boyutlarının aynı olması gerekmektedir. Bu nedenle görüntüler 64x64 piksellik bloklara bölünür.


İkinci aşamada NumPy kullanılarak tümör merkezinin koordinatları bulundu. Daha sonra bu koordinatlar merkez alınarak görüntüye kırpma işlemi uygulandı. Kırpma sonrasında tümör boyutunda herhangi bir değişiklik olmadan daha küçük bir görüntü elde edildi. Kırpma sonucunda veri dağılımındaki eşitsizlik azalır. Modeli eğitmek için görüntüler (64x64) boyutuna dönüştürüldü. Örneğin tümör merkezinin koordinatlarını bulma yöntemi Şekil 5.1'da gösterilmektedir. Bu görüntüde Xcenter ve Ycenter'ı bulmak için şu işlemleri yapıyoruz:

Xcenter değeri, tümörün y ekseninde başlayıp bittiği yerdeki değerlerin toplanması ve ikiye bölünmesiyle elde ediliyor. Aynı şekilde tümörün x ekseninde başlayıp bittiği yerdeki değerlerin toplamı alınarak ikiye bölünerek Ycenter değeri elde edilir. Değerler bu şekilde hesaplandığında


$$(5.1) \quad \text{Denklem} \quad \text{indeks} - xy = np.where(img)$$

$$(5.3) \quad \text{Denklem} \quad X_{\text{merkez}} = \frac{(max(indeks-xy[1])+(min(indeks-xy[1])))}{2}$$

(5.3 uygulanarak (Xcenter, Ycenter) = (153, 135) değerleri elde edilir. Tümörün merkez koordinatlarını bulma yöntemi Şekil 5.1 ve Şekil 5.2'de gösterilmektedir. Şekil 5.3, görüntünün dört parçaya bölünmesini göstermektedir.



Şekil 5.1. Tümör merkezinin koordinatlarının nasıl elde edildiği gösterilmektedir.



Şekil 5.2. MR görüntüsü koordinatlar kullanılarak 64x64 boyutunda parçalara nasıl bölündüğü gösterilmektedir.



Şekil 5.3. Genişliği ve uzunluğu 64'ten büyük, merkez koordinatları belirlenmiş bir görüntü 4 parçaya bölünmüş olarak gösterilir.

En önemli kısım tümör alanının genişliği ve uzunluğudur. Tümör alanı, alan uzunluğuna göre bölünür. Tümör alanının genişliği veya yüksekliği 64'ten büyükse iki (64x64) boyutunda parçaya bölünür. Tümör alanının hem genişliği hem de uzunluğu 64'ten büyükse görüntü dört (64x64) boyutlu parçaya bölünür. Ayrıca tümör alanının hem genişliği hem de uzunluğu 64'ten küçükse ve piksel değeri eşik değerinden yüksekse kırpma yapılarak 64x64 görüntü elde edilir. Tümör merkezi koordinatları Denklem $indeks - xy = np.where(img)$

$$(5.1) - X_{merkez} = \frac{(max(indeks-xy[1])+(min(indeks-xy[1])))}{2} \quad (5.3)'de$$

gösterilmiştir.

$$indeks - xy = np.where(img) \quad (5.1)$$

$$Y_{merkez} = \frac{(max(indeks-xy[0])+(min(indeks-xy[0])))}{2} \quad (5.2)$$

$$X_{merkez} = \frac{(max(indeks-xy[1])+(min(indeks-xy[1])))}{2} \quad (5.3)$$

$$uzunluk = max(indeks - xy[0]) - min (indeks - xy[0]) \quad (5.4)$$

$$genislik = max(indeks - xy[1]) - min (indeks - xy[1]) \quad (5.5)$$

Burada img, piksel değeri 0,2'den büyük olan giriş görüntüsüdür ve np Denklem $indeks - xy = np.where(img)$ (5.1)'teki

numpy kitaplığıdır. Denklem $Y_{merkez} = \frac{(max(indeks-xy[0])+(min(indeks-xy[0])))}{2}$

(5.2)'da Ycenter, tümör merkezinden y eksenine olan mesafedir. Denklem $X_{merkez} = \frac{(max(indeks-xy[1])+(min(indeks-xy[1])))}{2}$ (5.3)'de Xcenter, tümör

merkezinden x eksenine olan mesafedir. Ayrıca Denklem $uzunluk = max(indeks - xy[0]) - min (indeks - xy[0])$ (5.4)'de uzunluk, tümör alanının

uzunluğudur ve Denklem $genislik = max(indeks - xy[1]) - min (indeks - xy[1])$

(5.5)'da, genişlik tümör alanının genişliğidir.

MR görüntülerinde görülmeyen alanlar varsa, merkezi koordinatları elde etmek amacıyla bu alanları dışarıda bırakacak bir eşik değeri belirlenir. Bu çalışmada optimal piksel değeri olarak 0,2 seçilmiştir. Yani piksel değeri 0,2'den küçük olan alanlar MR görüntülerinden çıkarılır. Daha sonra tümör alanının piksel değerlerinden x eksen ve y eksen için minimum ve maksimum değerler belirlenir. Bu iki değer, tümör alanının merkezi koordinatlarının elde edilmesinde faydalıdır. Bu koordinatları analiz ederek tümörün var olup olmadığını bulmak için kırpmaya yaparak 64x64 boyut aralığında dilimler elde edilir.

Bu çalışmada Otsu eşik tekniği kullanılmıştır. Otsu eşik tekniği, görüntüdeki nesneleri arka plandan ayırmaya yönelik bir yöntemdir. Bu eşik, görüntüdeki küçük görünmez pikselleri ortadan kaldırmak için kullanılır çünkü merkez koordinatları belirlenirken bu piksel değeri dikkate alınmıştır. Görüntüdeki gözle görülmeyen görüntü bozukluklarının koordinatların belirlenmesini etkilememesi için eşik değeri kullanılmıştır. Optimum eşik değerini seçmek için 0,1 ile 0,9 aralığındaki eşik değerleri ayarlandı ve 0,9'un üzerindeki değerler tümörün bir parçası olabileceğinden 0,9'un üzerindeki değerler incelenmedi[157]. Veri seti için en uygun değerin 0,2 olarak hesaplandığı belirlendi.

Ön işlemenin son aşamasında ise MR görüntülerini daha düzenli bir hale getirmek için z-puanı normalizasyonu uygulanmıştır. Etkili ön işleme tekniklerinin kullanılması beyin tümörü segmentasyonunda daha iyi sonuçlar sağlar. Bu gibi nedenlerden dolayı beyin MR görüntülerinin ön işlenmesi eğitim sürecinde verimliliğin artırılması ve eğitim süresinin kısaltılması açısından oldukça önemlidir[158].

5.1.2. Önerilen Hibrit DenseNet121-UNet Mimarisi

Bu çalışma, beyin tümörü segmentasyonu için ImageNet, önceden eğitilmiş ImageNet veri seti ve UNet mimarisi ile birleştirilmiş hibrit bir DenseNet121-UNet model mimarisi önermektedir. Önerilen mimaride, tamamen bağlantılı bir DenseNet121 katmanı kaldırılır ve üst örnekleme katmanları eklenir. Ancak geri kalan tüm katmanlar orijinal çalışmadakiyle aynıdır. UNet mimarisi kodlayıcı ve kod çözücü yapılardan oluşur. Önerilen hibrit modelde kodlayıcı yerine DenseNet121 ağı kullanılmıştır. Bu nedenle DenseNet121 ağındaki tam bağlantılı katman kaldırılmıştır. Çünkü segmentasyon için evrişim ve havuzlama katmanlarından elde edilen özellikler tam bağlı katmanda softmax kullanılarak sınıflara ayrılmaktadır. Enkoder kısmında herhangi bir sınıflandırma ve segmentasyon olmadığından tam bağlantılı bir katmana ihtiyaç duyulmaz. Kodlayıcı kısmında giriş görüntüsünün öznetelikleri çıkarılarak atlama bağlantıları ile aynı seviyedeki kod çözücü katmanlarına iletilir[158]. Ağın her bir havuzlama katmanından önceki katman, kombinasyon katmanları oluşturmak için aynı

boyutu içeren bir sonraki katmanla birleştirilir[159]. Şekil 4.9’da gösterildiği gibi, üç aşamalı ön işleme, giriş görüntülerinin iyileştirilmesine yardımcı olur ve segmentasyon için DenseNet121-UNet mimarileri uygulanır. Tüm MR sekansları arasında T1 görüntü çözünürlüğü diğer dokuya göre daha düşüktür. Bu nedenle tümör alanını keşfetmek için (Flair, T2, T1C) gibi diğer sekansları kullanılmaktadır.




Şekil 5.4. Hibrit DenseNet121-UNet mimarisinin bir diyagramı gösterilmektedir.

Şekil 5.4’da görüldüğü gibi MR görüntüsünün giriş olduğu mimaride öncelikle bir veri ön işleme süreci bulunmaktadır. Veri ön işleme sürecinden geçen MR görüntüleri önerilen hibrit mimari ile eğitilmektedir. Eğitim sonucunda elde edilen çıktı MR görüntülerinin son işlemlerinin ardından segmentasyon işlemi tamamlanır. Önerilen model kodlayıcı-kod çözücü mimarisine dayanmaktadır. Veri kümelerinde önceden eğitilmiş modellerin kullanılması, tasarlanan modellerin hızla yakınsamasına yardımcı olur. Giriş görüntüsü, önceden eğitilmiş blok serisi Densenet121 kodlayıcıya beslenir. Bu yoğun bloklar, giriş görüntüsünden yararlı bilgileri alır ve kod çözücüye iletir. Kod çözücünün işlevi, görüntü özelliklerini yükseltmek ve bunları gerekli şekle eşlemektir. Daha sonra bu tür ölçeklendirilmiş özellikler, atlama bağlantıları aracılığıyla filtrelerle (belirli şekilli özellikler) birleştirilir. Atlama bağlantıları, kod çözücünün istenen özellikleri üretmesine olanak tanıyan anlamsal bilgilerin getirilmesine yardımcı olur[160]. Ayrıca, işlenen özellikleri toplu normalizasyon ve ReLU içeren 3×3 evrişim katmanı takip eder. Son olarak, son kod çözücü katmanının çıktısı, 1×1 evrişim katmanına ve ardından bir sigmoid fonksiyonuna aktarılır. Önerilen hibrit DenseNet121-UNet model mimarisi Şekil 5.5’da gösterilmektedir.

DenseNet mimarisi, tüm katmanları yoğun bir şekilde birbirine bağlayarak bu sorunu çözmeye çalışır. Her yeni katman, önceki tüm katmanlardan girdi alır ve bilgilerini sonraki tüm katmanlara iletir. Sonuç olarak, son çıktı katmanı, ilk katman da dahil olmak üzere her katmandan doğrudan bilgi alır. Gereksiz katmanın kaldırılması amaçlanmaktadır. Spesifik olarak, bilgiyi doğrudan yoğun blokların farklı seviyelerine iletmek ve daha iyi doğruluk elde etmek için atlama bağlantılarını kullanan bir DenseNet121-UNet ağı tasarlanmaktadır[162].

5.1.4. Veri Son İşleme Süreci

Eğitim işlemi öncesinde görseller (64x64) boyutuna dönüştürülerek modele giriş yapılır. Eğitimden sonra bu bölümlere ayrılmış görüntülerin yeniden birleştirilmesi gerekir. Bu amaçla, öncelikle daha önce elde edilen koordinat verileri kullanılarak her bir tümör etiketinin (tüm tümör, çekirdek tümör, genişleyen tümör) parçaları birleştirilmektedir. Daha sonra bu tümürlü alanlar birleştirilir ve radyoloğun yaptığı gibi segmentasyon işlemi tamamlanır. Beyin MR görüntüleri önerilen mimariyle eğitildikten sonra son işlemler gerçekleştirilir. Bu işlemde 64x64 boyutunda parçalara ayrılan görüntüler koordinat verileri kullanılarak birleştirilir ve orijinal boyutlarına dönüştürülür. Şekil 5.6, tümör alanlarındaki dilimlerin birleştirilmesine ilişkin işlem sonrası aşamaları göstermektedir.



Şekil 5.6. Tümör parçalarının birleştirilmesi işlemi

5.1.5. Uygulama Detayları

Mümkün olan en iyi modeli tasarlamak için farklı parametreler test edilmiş ve en verimli parametreler seçilmiştir. Eğitim için 50 epoch 16 batch boyutu seçilmiştir. Daha sonra BraTS 2019 veri seti üzerindeki eğitim seti Adam optimizör ve 0,0001 öğrenme oranı ile birlikte 5 kat çapraz doğrulaması altında eğitilmiştir. Ayrıca, her işlem katmanında ağı stabilize etmek ve normalleştirmek için toplu normalizasyon kullanılmıştır. Modelin performansını ölçmek için DSC, ortalama iou ve jaccard metrikleri kullanılmıştır. Tüm çalışmalar Google Colab Pro ortamında gerçekleştirilmiştir.

5.1.6. Uygulama Sonuçları

UNet'li hibrit model DenseNet121, küçük veri sınıflandırma sorununun üstesinden gelmeye yardımcı olan kodlayıcılara dayanmaktadır. Üstelik UNet, eğitim için önemli miktarda zaman gerektiren karmaşık bir mimaridir ve eğitim, bilgisayar özelliklerinden de etkilenir. Bu sorunların üstesinden gelmek için önerilen hibrit modeli eğitmek amacıyla transfer öğrenmeyi gerçekleştirdik. Kayıp ve doğruluk açısından en iyi modeli elde etmek için çeşitli senaryolar test edilmiştir. Ayrıca model segmentasyon sonuçlarını temel gerçek değerleriyle karşılaştırmak için DSC, ortalama iou ve jaccard indeks metrikleri ile ölçülmüştür. Önerilen modelin doğruluğunu sağlamak için model en yaygın beş parametreyle değerlendirilmiştir. Bu beş parametre DSC, jaccard indeksi, ortalama iou, duyarlılık ve özgüllük metrikleridir. Bu parametreleri değerlendirmek için tahmin edilen bölge (X), temel gerçek (Y) ve arka plan (B) alanları kullanıldı. Bu metriklerle elde edilen değerler Tablo 5.1'de gösterilmektedir. Önerilen model ile karşılaştırılan 5 modelin sonuçları Tablo 5.2'de gösterilmiştir.

Tablo 5.1. Önerilen hibrit DenseNet121-UNet mimarimizi doğrulamak için kullanılan metrikler


Metrik	Tüm Tümör	Çekirdek Tümör	Genişleyen Tümör
DSC	%95.9	%94.3	%89.2
Jaccard	%91.4	%90.2	%79.0
Ort. IoU	%62.9	%75.9	%77.3
Duyarlılık	%95.5	%95.7	%88.1
Kesinlik	%99.6	%99.7	%99.2

Tablo 5.2. Önerilen hibrit DenseNet121-UNet mimarisinin diğer derin sinir ağıları karşılaştırılması

DSA	Tüm Tümör	Çekirdek Tümör	Genişleyen Tümör
UNet	%85.9	%80.7	%82.9
ResUNet	%89.4	%86.2	%82.8
VGG16-UNet	%93.6	%89.6	%84.5
ResNet50-UNet	%91.4	%88.2	%83.9
Önerilen DenseNet121-UNet	%95.9	%94.3	%89.2


Literatürde görüntü segmentasyonu için kullanılan en yaygın beş model, UNet, ResUNet, VGG16-UNet, ResNet50-UNet ve DenseNet121-UNet aynı veri seti ve aynı parametreler ile eğitilmiştir. Hibrit modelde kullanılan DenseNet kısmı kaldırılarak yerine diğer modeller entegre edilmiş ve elde edilen sonuçlar değerlendirilmiştir. Önerdiğimiz DenseNet121-UNet modeli ve diğer modeller ile elde edilen DSC, Jaccard ve Ort. IoU değerleri

karşılaştırılmış ve en yüksek başarı oranının önerilen model ile elde edildiği görülmüştür. Önerilen model, tüm tümör, çekirdek tümör ve genişleyen tümör segmentasyonu üzerinde sırasıyla %95.9, %94.3 ve %89.2'lik DSC doğruluğu elde etti. Şekil 5.7, önerilen modelin kayıp ve DSC fonksiyonlarının grafiksel durumunu göstermektedir.



Şekil 5.7. Beyin tümörünün üç bölgesi için Zar Katsayısı (DSC) ve Zar Kaybı (DSC Loss) değerleri gösterilmektedir.

Sınıf dengesizliği sorunu tıbbi görüntü bölütlemeye yaygındır ve DSC bu sorunu en aza indirir. Daha önceki bölümlerde bahsedildiği gibi, tümörler bölgelerine göre tüm tümör, çekirdek tümör ve genişleyen tümör olmak üzere üç gruba ayrılır. Önerilen model, bahsedilen üç grup için DSC'lerine dayalı olarak en son teknolojiye sahip mimarilerle karşılaştırılarak değerlendirilmiştir. Şekil 4.13'te önerdiğimiz modelin yaptığı segmentasyon ve temel gerçeğini (radyologların yaptığı segmentasyon) göstermektedir. Ayrıca parçalı görüntünün farklı kısımlarını temsil etmek için çeşitli sınıflar kullanılır. Şekil 5.8'teki yeşil bölgeler ödemi, sarı bölgeler ise genişleyen tümörü temsil etmektedir[163].



Şekil 5.8. Farklı tümör tiplerinin segmentasyon sonuçları gösterilmektedir.

5.1.7. En Gelişmiş Yöntemlerle Karşılaştırmalar

UNet, özellikle görüntü işleme görevleri için tasarlanmış CNN mimarisini temel alır. UNet'in zaman ve mekan karmaşıklığı yüksek olduğundan birçok bilgisayar kaynağına ihtiyaç duyar. Bu sorunun üstesinden gelmek için bu çalışmada MR tabanlı beyin tümörü görevlerinde transfer öğrenmeli DenseNet121-UNet önerilmiştir. DenseNet121, UNet'e kıyasla katmanları ve parametreleri azaltan atlama bağlantılarını kullanarak modelin zaman ve alan karmaşıklığını azaltır. Üstelik modelde kolayca erişilebilen parametrelerden ağırlıklar DenseNet121'de zaten mevcuttur.

Önerilen yöntemin verimliliğini doğrulamak için önerilen modeli UNet, ReSUNet, VGG16-UNet ve ResNet50-UNet modelleriyle karşılaştırılmıştır. Bu mimarilerin tercih edilmesinin nedeni literatürde yüksek verimli mimariler olmaları ve yaygın kullanılmalarıdır. Diğer modeller ile elde edilen sonuçlar yüksek olmasına rağmen DenseNet121-UNet hibrit modelin performansını aşmadı. Bu da önerdiğimiz hibrit DenseNet121-UNet modelinin beyin tümör tespiti için ne kadar doğru bir model olduğunu göstermektedir.

Ayrıca önerilen model, BraTS 2019 veri seti üzerinde eğitilen son teknoloji ürünü dört modelle karşılaştırılmıştır. Karşılaştırma yapılan çalışmalarda özellikle aynı veri setinin kullanılmış olmasına ve bu çalışmaların literatürde kabul görmüş yayınlar olmasına dikkat edilmiştir. Maji ve arkadaşları beyin tümörlerinin semantik segmentasyonu için yönlendirilmiş kod çözücüye sahip dikkat Res-UNet'i kullanmışlardır[158]. Wang ve Chung, 3 boyutlu UNet tabanlı beyin tümörü segmentasyonunu önermişlerdir[164]. Ahmed ve arkadaşları, beyin tümörü segmentasyonu için bağlama duyarlı 3 boyutlu UNet'i önermişlerdir[28]. Barzegar ve Jamzad, beyin MRI'da glioma tümör segmentasyonu için ağırlıklı etiket füzyon öğrenme yaklaşımını önermişlerdir[26]. Tablo 5.3, önerdiğimiz model ile bahsedilen literatürdeki en gelişmiş yöntemlerle yapılan çalışmalar arasındaki karşılaştırmayı göstermektedir.

Tablo 5.3. Önerilen hibrit DenseNet121-UNet mimarisinin en gelişmiş yöntemlerle karşılaştırılması

Yöntem	Tüm Tümör	Çekirdek Tümör	Genişleyen Tümör
Barzegar and Jamzad	%90.1	%88.7	%89.0
Maji ve ark.	%92.3	%84.7	%83.4
Ahmad ve ark.	%90.2	%83.4	%72.2
Wang ve ark.	%91.4	%88.2	%83.9
Önerdiğimiz DenseNet121-UNet	%95.9	%94.3	%89.2

5.2. MR Görüntülerini Kullanarak Beyin Tümörü Sınıflandırmasına Yönelik Yeni bir Yaklaşım

Beyin tümörlerinin tespitinde derin öğrenme yöntemlerinin kullanılmasının amacı, MR görüntülerinden tümör tespitini otomatik hale getirmek, uzmanların yoğunluğunu azaltmak, hastalığın teşhis süresini kısaltmak ve uzmanların yapabileceği hataları önlemektir. Bu yöntem iki aşamada gerçekleşir. İlk aşamada beyin MR görüntüsünde tümör olup olmadığı tespit edilir. İkinci aşamada eğer tümör varsa tümörün tipi belirlenir. Beyin tümörleri üç tiptir; glioma, menenjiyom ve hipofiz[11]. Literatürde beyin MR görüntülerinden tümör tespiti konusunda birçok çalışma yapılmıştır. Bu çalışmalarda oldukça başarılı sonuçlar elde edilmiştir. Ancak hala iyileştirilmesi gereken noktalar bulunmaktadır.

Güncel yöntemler incelendiğinde beyin MR görüntüsünde tümör olup olmadığını tespit etseler de tümör tipini belirlemedeki başarı oranı bir miktar azalmaktadır. Bu sorunun temel nedeni, tümör tipinin belirlenmesi için daha fazla özelliğe ihtiyaç duyulmasıdır. Bu, özellikleri tespit etmek için daha etkili bir yaklaşıma ihtiyaç duyulduğunu gösterir. Bu da görüntüdeki özellikleri tespit edecek ve bu doğrultuda sınıflandırma yapacak verimli bir model tasarlanmasıyla mümkündür[20]. Diğer bir sorun ise birçok çalışmanın beyin tümörü sınıflandırması için derin sinir ağlarını kullanmasıdır. Derin sinir ağlarında katman sayısı arttıkça azalan gradyan sorunu ortaya çıkar. Sınıflandırma, segmentasyona göre daha basit bir işlemdir. Etkin bir CNN ağı ile derin sinir ağlarına ihtiyaç duymadan beyin tümörü sınıflandırması yapılabilmektedir[33].

Bu sorunları çözmek için MR görüntülerini kullanarak beyin tümörü sınıflandırmasına yönelik yeni bir yaklaşım önerilmektedir. Veri ön işleme sürecinde öncelikle veriler one hot kodlama yöntemiyle ikili hale dönüştürülür. Daha sonra veriler kırılır. Bu sayede görüntülerdeki gereksiz alanların ortadan kaldırılması amaçlanmaktadır. Kırma işleminden sonra görüntüler veri artırma tekniği kullanılarak çoğaltılır. Görüntüler eğitime hazır hale getirildikten sonra sıfırdan oluşturulan CNN model tabanlı bir ağ ile eğitilir. Sıfırdan yeni bir ağ tasarlanmasının temel nedeni, mevcut derin sinir ağlarında başarı sağlanamaması ve derin

sinir ağlarının yaşadığı darboğaz ve gradyan inişi gibi sorunlardır[22].

Bu çalışmada beyin MR görüntülerinden tümör tespiti için sıfırdan bir CNN modeli önerilmiştir. Önerilen model, 6 evrişim ve 2 tam bağlantılı katmandan oluşan 8 katmanlı bir CNN ağından oluşmaktadır. Her evrişim katmanından sonra, modeli hızlandırmak ve kolaylaştırmak için bir toplu normalleştirme katmanı eklenmiştir. Modelin aşırı uyumunu önlemek için tamamen bağlı katmanlardan sonra bırakma katmanı kullanıldı. Sıfırdan bir CNN ağı tasarlayanın amacı, sınıflandırma işlemini hızlı ve yüksek doğrulukla gerçekleştirebilen basit ama etkili bir ağ geliştirmektir. Önerilen modelin ana katkıları aşağıdaki gibidir:

- i. MR görüntüleri kullanılarak beyin tümörü sınıflandırması için yeni bir yaklaşım önerilmiştir.
- ii. 6 evrişim ve 2 tam bağlantılı katmandan oluşan 8 katmanlı bir CNN modeli sıfırdan tasarlandı.
- iii. Kullanılan filtreler ile modelin özellik çıkarım yeteneği artırılmıştır. Bu da modelin başarısını artırdı.
- iv. Literatürdeki benzer çalışmalara kıyasla MR görüntüleri kullanılarak tümörlerin ve tümör tiplerinin tespitinde daha yüksek doğruluk oranı elde edildi.

5.2.1. Ön İşleme Süreci

Modeli eğitmek için verilerin belirli bir formatta ve düzgün olması gerekir. Ancak mevcut veri seti eğitime hazır olmayabilir. Görüntülerde bazı bozulmalar, gereksiz alanlar ve gürültüler olabilir. Bu nedenle eğitime başlamadan önce görüntülerin ön işleme tabi tutulması gerekir. Bu çalışmada kullanacağımız veri seti, gliomalar, menenjiyomlar ve hipofiz tümörleri gibi üç farklı beyin tümörü tipini içeren 3064 T1 ağırlıklı görüntüden oluşur. Üç farklı sınıf MR görüntüsü içeren bu veri seti Kaggle'dan indirildi (figshare, 2020). Bu çalışmada kullanılan görsellerin orijinal boyutu 512x512'dir. Modelin hesaplama yükünü azaltmak ve daha verimli çalışmasını sağlamak için görüntüler 224x224 olarak yeniden boyutlandırıldı. Veri setinin %80'i eğitime, %20'si ise teste ayrılmıştır. Bu çalışmada kullanılan görseller bazı kırpma ve veri artırma işlemlerinden geçirilerek eğitime hazır hale getirildi.

5.2.2. Önerilen Evrişimli Sinir Ağ Mimarisi

Literatürde birçok araştırmacı sınıflandırma işlemi için transfer öğrenme yöntemini kullanmıştır. Bunun temel nedeni kullanılan ağların derin sinir ağları olması ve bu ağların çok sayıda katmandan oluşması nedeniyle sıfırdan eğitilmesinin uzun zaman alması ve yüksek kapasiteli bilgisayarlara ihtiyaç duyulmasıdır. Bu nedenlerden dolayı transfer öğrenme yöntemini kullanmak mantıklı görünse de bu yöntemlerde aşırı uyum ve hatalı sonuçlar gibi

durumlar söz konusu olabilir. Beyin tümörü sınıflandırması gibi az sınıflı bir veri seti ile çalışırken daha basit CNN ağlarının kullanılması yeterli olacaktır. Hatta bazen tümörlü ve tümörsüz olmak üzere sadece 2 sınıfın tespitine yönelik çalışmalar yapılıyor. Etkin bir CNN ağı ile sınıflandırma çok daha başarılı bir şekilde ve aşırı öğrenme olmadan gerçekleştirilebilir. Bu çalışmada normal bir CNN ağı geliştirilerek elde edilen bir ağ önerilmektedir[153]. Önerilen model Şekil 5.9'te gösterilmektedir.



Şekil 5.9. Önerilen CNN modelinin mimarisi gösterilmiştir.

Bu çalışmada öncelikle mevcut CNN ağı değiştirilerek 8 katmanlı yeni bir CNN ağı oluşturulmuştur. Daha sonra yeni CNN modeli, Kaggle platformundan ücretsiz olarak indirilen 3064 beyin MR görüntüsünden oluşan veri seti ile eğitildi. Modelin sonuçları normal CNN ağı ve önceden eğitilmiş VGG19, ResNet201 ve DenseNet121 modelleri ile karşılaştırılmıştır. Önerilen CNN modeli 6 evrişimli ve 2 tam bağlantılı katmandan oluşmaktadır. Model bir evrişim katmanı ile başlar, ilk evrişim katmanında 64 filtre bulunur ve filtre boyutu 3x3'tür. Model oluşturulduktan sonra filtre numaraları sürekli değiştirilerek eğitim gerçekleştirildi. Birinci evrişim katmanı için filtre sayısı başlangıçta 32 olarak belirlendi. Ancak yapılan testler sonrasında 64 adet filtre sayısında daha iyi sonuçlar alındığı görülmüş ve filtre sayısı bu şekilde revize edilmiştir.

Her evrişim katmanından sonra 2x2 maksimum havuzlama katmanı kullanıldı.

Havuzlama katmanının amacı, görüntülerin çok büyük olduğu durumlarda parametre sayısını azaltarak görüntüyü küçültmektir. Bu işlem her haritanın boyutunu azaltır ancak önemli bilgileri korur[165]. Genel olarak iki tür havuzlama yöntemi kullanılmaktadır. Bunlar maksimum havuzlama yöntemi ve ortalama havuzlama yöntemidir. Bu çalışmada giriş verilerinin mekansal boyutunu azaltmak için maksimum havuzlama yöntemi kullanılmıştır. Maksimum havuzlama yönteminde rotasyonel ve konumsal olarak değişmeden yükseklik ve genişlik azaltılarak baskın özelliklerin ortadan kaldırılması modelin başarısını artırmaktadır[166]. Maksimum havuzlama katmanından sonra, evrişimsel sinir ağını daha düzenli hale getirmek için toplu normalizasyon katmanı kullanıldı. Toplu normalizasyon, düzenleyici etkinin yanı sıra, eğitim sırasında evrişimli sinir ağının yok olma derecesine karşı da bir direnç sağlar. Bu, eğitim süresini azaltabilir ve modelin daha iyi performans göstermesini sağlayabilir[167].

Modelin üçüncü ve dördüncü evrişim katmanları 128 filtreye ve 3x3 filtre boyutuna sahiptir. Görsellerde birçok farklı özellik bulunduğu için genel olarak birden fazla filtre uygulamak modun verimliliğini arttırabilir[168]. Görüntüdeki farklı özelliklerin daha iyi algılanması için filtre sayısı artırıldı. Evrişim katmanından sonra tekrar maksimum havuzlama ve toplu normalizasyon katmanları kullanıldı. Daha sonra 256 filtreli ve 3x3 filtre boyutunda bir evrişim katmanı eklendi. Evrişim katmanını maksimum havuzlama katmanı ve toplu normalizasyon katmanı takip eder. Toplu normalizasyon katmanından sonra, girişin tam bağlı katmana verilebilmesi için düzleştirme katmanı eklenmiştir. Bu katmanda girdi matrisi tek boyutlu bir matrise dönüştürülür.

Düzleştirme katmanından sonra ortalama bir havuzlama katmanı eklenmiştir. Normalde burada tam bağlantılı bir katman kullanılabilir ancak ortalama bir havuzlama katmanı kullanmanın amacı modelin boyutunu küçültmek ve performansını artırmaktır. Havuzlama katmanından sonra 3x3 512 filtreli tam bağlantılı katman eklenmiştir. Aşırı uyumun önlenmesi için tam bağlı katmanın sonuna 0,2 değerinde bir bırakma katmanı eklenir. Bırakma değeri başlangıçta 0,5 olarak alınmış ve bu değer azaltılarak modelin performansı ölçüldü ve 0,2 değeri optimal olarak bulundu[167]. Tamamen bağlı katmanlarda çok fazla parametre olduğundan, aşırı uyumdan kaçınmak için bırakmayı kullanmak çok daha faydalı olabilir. Evrişim katmanlarından sonra bırakma yerine toplu normalleştirme kullanılmasının nedeni parametre sayısının daha az olmasıydı. Dropout (bırakma) katmanından sonra aynı özelliklere sahip tam bağlantılı bir katman daha eklenmiştir. Model, sınıflandırma için evrişimli sinir ağının sonuna softmax aktivasyon fonksiyonu eklenerek tamamlanır[169].

Yeni modelin oluşturulması sırasında birçok farklı varyasyon denendi. Literatür takip edilerek denenmiş ve başarılı yöntemler incelenmiştir. Belirli iyileştirme yöntemleri uygulanarak modelin başarısının artırılacağı gösteren birçok çalışma bulunmaktadır. Bu

nedenle model kurulurken hem modelin tasarımı hem de kullanılan parametreler modelin başarısını arttıracak şekilde belirlenmiştir. Modelin başarısına katkı sağlamasa bile modelin boyutunun ve karmaşıklığının azaltılmasına katkı sağlayacak değişiklikler yapılmıştır.

5.2.3. Uygulama Detayları

Modelin eğitim başarısını etkileyen birçok parametre bulunmaktadır. Bu nedenle modele ilişkin parametreler belirlenirken her parametrenin modelin eğitim başarısına etkisi ayrı ayrı değerlendirilmiştir. Örneğin dropout değerini belirlerken başlangıçta dropout değeri 0,5 olarak ayarlandı. Daha sonra bu değer sürekli azaltılarak modelin eğitim ve test doğruluk değerlerine bakıldı. Dropout değeri belli bir seviyeye kadar azaltıldığında doğruluk değerinin arttığı gözlemlenmiştir. Bir süre sonra bu dropout değeri düşürüldüğünde doğruluk değerinin azaldığı görülmüştür ve dropout değeri optimal olan 0,2 olarak belirlenmiştir. Diğer tüm parametreler benzer şekilde optimize edildi. Bu çalışmada birçok değer test edildikten sonra batch büyüklüğü değeri 32 olarak belirlenmiştir. Adam optimizier kullanılmış ve öğrenme oranı 0,0001 olarak alınmıştır. Giriş görsellerinin boyutu 224x224 olarak kullanılmıştır. Mevcut veri setinin %80'i eğitim için, kalan %20'si ise test için ayrılmıştır. Kodlar Google Colab platformunda çalıştırıldı. Kullanılan parametreler ve değerleri Tablo 5.4'te gösterilmektedir.

Tablo 5.4. Modelde kullanılan ve modelin başarısına en fazla etki eden parametreler

Hyper-parametre	Değer
Kayıp	Categorical Crossentropy
Metrik	Accuracy
Optimizer	Adam
Girdi Boyutu	224x224
Epoch	100
Batch Size	32
Initial Learning Rate	0.0001
Bırakma	0.2
Eğitim	0.8
Test	0.2

Epoch, veri setinin ağırlıklarının model boyunca işlenerek güncellenmesidir. Epoch sayısı çok yüksek ayarlandığında model, öğrenme yerine ezberlemeye girebilir. Epoch sayısı düşük olduğunda ağırlıklar optimum şekilde güncellenmeyebilir. Bu çalışmada epoch sayısı başlangıçta 20 olarak belirlenmiş ancak eğitim sırasında validasyon setinde herhangi bir gelişme olmazsa aktif olan erken durdurma seçeneği modele eklenerek hem zaman kaybının önüne

geçilmiş hem de doğru sonuç elde edilmiş olur.

5.2.4. Uygulama Sonuçları

Bu çalışmada beyin tümörü tiplerinin MR görüntüleri kullanılarak sınıflandırılması için CNN tabanlı bir yaklaşım önerilmektedir. Öncelikle önerilen model, ücretsiz olarak indirilebilen veri artırmaz figshare veri seti ile çalıştırıldı ve tümör tespiti yapıldı. Veri ön işleme sürecinde veri seti, veri artırma teknikleri kullanılarak çoğaltılmıştır. Veri artırmanın modelin başarısı üzerindeki etkisini ve verimli veri artırma tekniğini anlamak için, model ilk önce veri artırma olmadan veri seti ile çalıştırıldı.


Veri artırma uygulanmadan önce ortalama doğruluk oranı %97,68'di. Glioma tümör tipi %98,73, menenjiyom tümör tipi %95,82 ve hipofiz bezi %97,43 doğrulukla sınıflandırıldı. Daha sonra model çoğaltılan verilerle çalıştırıldı ve sonuçlar tekrar değerlendirildi. Önerilen CNN tabanlı model, sınıflandırma işlemini %98,32 doğruluk oranıyla gerçekleştirmiştir. En yüksek sınıflandırma oranı %99,64 ile glioma etiketli görüntülerden elde edildi. Gliomalar diğer tümör türlerine göre sınırları daha net olan bir tümör türüdür. Bu nedenle tespiti yüksek başarı oranıyla gerçekleşmiştir. Daha sonra en yüksek doğruluk oranı %98,39 ile hipofiz tümörü türünde elde edildi. Hipofiz'den sonra menenjiyom tümör tipi %96,53 doğruluk oranıyla elde edilen tümör türüdür. Menenjiyom'un tespiti diğer tümör türlerine göre daha küçük bir alanda oluşabildiği için biraz daha zordur. Eğer sınıf dağılımı dengeliyse, doğruluk ve F1 skoru genellikle birbirine yakın değerler alır. Eğer sınıf dağılımı dengesizse (yani bir sınıf diğerinden çok daha fazla sayıda örneğe sahipse), doğruluk yanıltıcı olabilir. Bu durumda F1 skoru daha anlamlı bir performans ölçütü olur. Bu çalışmada elde edilen tümör tiplerinin doğruluk değerleri, kesinlik, hatırlama ve F1 skorları Tablo 5.5'te gösterilmektedir.

Tablo 5.5. Önerilen modeli doğrulamak için kullanılan performans ölçümleri


Tümör Tipi	Doğruluk	Kesinlik	Duyarlılık	F1-puanı	Ort.. Doğruluk
Glioma	%99.64	%98.16	%98.39	%98.27	%98.32
Menenjiyom	%96.53	%97.45	%95.80	%96.61	%98.32
Hipofiz	%98.39	%96.68	%97.42	%97.04	%98.32

Öğrenme eğrileri, bir eğitim veri kümesinden derin öğrenme algoritmalarının adım adım öğrenme sürecini gösterdikleri için son derece önemlidir. Bu eğriler, eğitim sırasındaki her güncellemeden sonra eğitimdeki öğrenme aşamalarını gösterir. Bir modelin aşırı uyum, eksik uyum gibi durumlarla karşılaştığı bu eğriler incelenerek belirlenebilir. Aynı şekilde bir

modeli deęerlendirmek iin kullanılan doęrulama veri setinin uygunluęu da bu eęriler incelenerek grlebilir. Kayıp fonksiyonu, aęın eęitim srecini ve ęrenmesini anlık olarak gsterir. Kayıp fonksiyonunun eęrileri incelendięinde eęitim ve test veri seti iin ęrenme srecinin paralel olarak ilerledięi grlmektedir. Epoch sayısı artarken belli bir sayıdan sonra kayıp deęerinin deęiřmedięi grlmektedir. řekil 5.10'te nerilen CNN tabanlı modelin kayıp fonksiyonunun eęitim sırasındaki aę sayısına gre deęiřimi grafiksel olarak gsterilmektedir.



řekil 5.10. Kayıp fonksiyonunun eęrisi




Şekil 5.11. Accuracy fonksiyonunun eğrisi

Şekil 5.11 modelin doğruluk eğrisini göstermektedir. Eğri incelendiğinde doğruluk değerinin başlangıçta belli bir değerden başladığı, çağ sayısı arttıkça bu değerin belli bir noktaya kadar arttığı görülmektedir. Daha sonra doğruluk değeri belirli bir sayıdan sonra artık artmaz ve değerinde çok küçük değişiklikler meydana gelir. Bu aşamada modelin eğitiminin gerçekleştiği söylenebilir. . Önerilen modelin karışıklık matrisi Şekil 5.12'de gösterilmektedir.

	Tahmin		
Glioma	284	1	2
Menenjiyom	0	136	1
Hipofiz	1	4	183
	Glioma	Menenjiyom	Hipofiz
	Gerçek		

Şekil 5.12. Önerilen ESA'nın karışıklık matrisi

Karışıklık matrisi, modelin bilinen bir veri için ne tahmin ettiğini gösterir. Karışıklık matrisinin detaylı incelenmesi modelin değerlendirilmesi açısından önemli bir noktadır. Önerilen modelin karışıklık matrisi değerlendirildiğinde glioma tümör tipinin çoğunlukla doğru belirlendiği, 285 görüntüden 284'ünün doğru şekilde sınıflandırıldığı görülmektedir. Yanlış sınıflandırılan bir görüntü, hipofiz tümörü türü olarak sınıflandırıldı. Menenjiyom tümör tipi incelendiğinde 141 test görüntüsünden 136'sının doğru şekilde menenjiyom olarak sınıflandırıldığı görülmektedir. Yanlış sınıflandırılan beş görüntüden dördü hipofiz ve biri glioma olarak sınıflandırıldı. Bu durum menenjiyom tümör tipinin çoğunlukla hipofiz tümör tipi ile karıştırıldığını göstermektedir. 186 hipofiz görüntüsünden 183'ü doğru şekilde hipofiz olarak sınıflandırıldı. İki görüntü glioma, bir görüntü ise menenjiyom olarak sınıflandırıldı. Yanlış pozitif ve yanlış negatifin örnek görüntüleri Şekil 5.13'de gösterilmektedir.



Şekil 5.13. Yanlış pozitif ve yanlış negatif örneği

Mevcut derin ağların çoğu, sınıflandırma sürecini zaten başarıyla gerçekleştirmektedir. Önerilen CNN tabanlı mimarinin mevcut DNN mimarilerine göre daha az karmaşıklığa ve düşük parametre sayısına sahip olduğu gerçeğine odaklandık. Burada amaç modelin kısaltılmasıyla modelin veriminin artırılması ve çalışma süresinin kısaltılmasıdır. Bu amaçla tasarladığımız modelin başarısını doğru değerlendirmek için mevcut DNN mimarileri ile karşılaştırdık. Önerilen CNN tabanlı model ile elde edilen sonuçlar ResNet50, VGG19, DenseNet121 ve Inceptionv3 ile elde edilen sonuçlarla karşılaştırılarak bu modellerin başarısı değerlendirilmiştir. Bu modeller aynı veri seti ve aynı parametrelerle transfer öğrenme yöntemi kullanılarak çalıştırılmıştır. Aynı veri seti ve parametreler diğer modellerde de çalıştırılmış ancak en yüksek verim bu dört modelde elde edilmiştir. Özellikle ResNet50 modeli bu dört

DNN modeli arasında en yüksek doğruluğu gösterdi. Ancak önerdiğimiz CNN modeli ResNet50'yi geçerek çok yüksek bir doğruluk oranı gösterdi. Önerilen model ile Resnet50, VGG19, DenseNet121 ve InceptionV3 modellerinin doğruluk değerleri Tablo 5.6'da gösterilmektedir.

Tablo 5.6. Önerilen modelin diğer derin öğrenme algoritmaları ile karşılaştırılması

Tümör Tipi	Glioma	Menenjiyom	Hipofiz
ResNet50	%98.94	%94.15	%96.53
VGG19	%93.58	%89.41	%90.16
DenseNet121	%97.44	%93.82	%95.36
InceptionV3	%89.20	%84.61	%87.45
Önerilen ESA	%99.64	%96.53	%98.39

Son aşamada önerilen modelin başarısını test etmek için sınıflandırma işlemi farklı bir sınıflandırıcı ile gerçekleştirilerek sonuçları karşılaştırıldı. Klasik CNN tabanlı modellerde sınıflandırma softmax veya sigmoid fonksiyonlarıyla yapılır. Ancak makine öğrenmesi yöntemlerinin kullanılması halinde birçok sınıflandırma yöntemi de kullanılabilir. Örneğin SVM, KNN, Karar Ağaçları, Naïve Bayes gibi sınıflandırma yöntemleri kullanılabilir. Bu çalışmada farklı bir sınıflandırma yöntemi kullanmak üzere sınıflandırıcı olarak Destek Vektör Makinesi (SVM) seçilmiştir. Öznitelik çıkarımı için önerilen CNN modeli kullanılmış ve elde edilen öznitelikler SVM modeline girdi olarak verilerek sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemi yapıldıktan sonra elde edilen sonuçlar softmax fonksiyonu ile elde edilen sonuçlarla karşılaştırılmıştır. SVM sınıflandırıcı ile glioma tümör tipi %97,24 doğruluk oranıyla, hipofiz tümör tipi %95,81 ve menenjiyom tümör tipi %92,57 doğruluk oranıyla sınıflandırıldı. Bu sonuçlar sınıflandırıcı olarak DVM kullanıldığında softmax fonksiyonuna göre başarının azaldığını göstermektedir.

Bu çalışmada önerilen modelin sağlamlığı birçok farklı yöntemle test edilmiş ve bu testler sonucunda elde edilen sonuçlar ışığında modelin son hali oluşturulmuştur. Önerilen modelin her bir parametresi ayrı ayrı test edilerek en uygun değer belirlenmiştir. Model katmanlarının sayısı da aynı şekilde belirlenmiştir. Önerilen mimarinin sekiz katmanlı olmaya karar vermeden önce beş, altı, yedi, dokuz ve on katmanlı mimariler oluşturulmuş, aynı veri seti ile çalıştırılmış ve sonuçlar değerlendirilmiştir. Hangi katmanda kaç filtre kullanılacağına da

aynı şekilde karar verilmiştir. Bu çalışmada önerilen model oluşturulurken literatürdeki benzer çalışmalar incelenmiş, tüm parametreler test edilerek belirlenmiş ve modelin sağlamlığı farklı yöntemlerle test edilmiştir.

5.2.5. En Gelişmiş Yöntemlerle Karşılaştırmalar

Beyin tümörlerinin MR görüntüleri kullanılarak sınıflandırılmasına yönelik literatürde birçok çalışma yapılmıştır. Çalışmalarda genellikle aynı veri seti kullanılmıştır. Ancak her çalışmada farklı bir yöntem veya model kullanılmıştır. Önerdiğimiz modelin başarısını test etmek için literatürde yapılmış, çok yüksek başarı elde edilmiş ve çok sayıda atıf almış benzer çalışmaları inceledik. Karşılaştırmamızın sağlıklı yapılabilmesi için aynı veri setini kullanan çalışmaların olmasına özen gösterildi. Aynı veri seti ancak farklı yöntemler kullanılarak yapılmış en yaygın yöntemler ile önerdiğimiz modelin başarısı karşılaştırıldı. Üç tümör tipi için elde edilen doğruluk değerinin averajı alınıp, diğer yöntemlerden elde edilen doğruluk değerleri ile karşılaştırıldı. Önerdiğimiz yaklaşımın bütün yöntemlere göre daha yüksek bir başarı elde ettiği tespit edilmiştir. Sadece Deepak ve arkadaşlarının önerdiği yaklaşım ile çok yakın sonuçlar elde ettiğimiz gözlemlenmiştir. Deepak ve arkadaşları transfer öğrenmesi tabanlı bir GoogleNet kullanarak sınıflandırma işlemini yapmışlardır[170]. En önemli altı çalışmanın sonuçları ve önerilen modelden elde edilen sonuçlar Tablo 5.7'de karşılaştırılmıştır. Önerdiğimiz model, karşılaştırdığımız altı modelden daha yüksek başarı elde etmiştir.

Tablo 5.7. Önerilen model ile literatürdeki altı çalışmanın karşılaştırılması


Yöntem	Veri Seti	Accuracy (Doğruluk)
Kaplan ve ark.	Figshare (3064)	%95.56
Sajjad ve ark.	Figshare (3064)	%90.67
Swati ve ark.	Figshare (3064)	%94.82
Deepak ve ark.	Figshare (3064)	%98
Pei ve ark.	Figshare (3064)	%94.39
Ghosal ve ark.	Figshare (3064)	%93.83
Önerilen ESA	Figshare (3064)	%98.32

5.3. MRI görüntülerini kullanarak beyin tümörü sınıflandırmasına yönelik derin öğrenme modellerinin karşılaştırılması

Beyin MR görüntülerinden tümörlerin tespit edilmesi için birçok yöntem kullanılmaktadır. Bu yöntemler arasında derin öğrenme yöntemleri diğer yöntemlere göre önemli bir gelişme kaydetmiştir. Bu çalışmada derin öğrenme yöntemleri kapsamında beyin MR görüntülerinden tümör tespiti için kullanılan modellerin karşılaştırılması amaçlanmaktadır. Daha sonra beyin MR görüntüleri kullanılarak tümör tespiti için derin öğrenme modelleri karşılaştırıldı. Amaç bu modelleri aynı veri seti ve aynı parametrelerle çalıştırıp hangisinin daha yüksek doğruluk ve performansa sahip olduğunu bulmaktır. Literatürde beyin tümörlerinin sınıflandırılmasına yönelik pek çok çalışma incelenmiştir. Bu çalışmaların her biri farklı bir modelin daha başarılı olduğunu ortaya koyuyor. Çünkü her çalışmada farklı veri setleri ve farklı parametreler kullanılıyor. Dolayısıyla modelleri karşılaştırmak açısından bu tam olarak doğru olmayacaktır. Modellerin gerçek anlamda karşılaştırılabilmesi için aynı veri seti ve aynı parametrelerle çalıştırılması gerekmektedir. Bu çalışmada literatürde en yaygın kullanılan CNN ağları olan ResNet101, DenseNet169, VGG19, AlexNet ve InceptionV3 modelleri karşılaştırılmıştır. Aynı veri seti ve ön işleme süreçlerinden geçen MR görüntüleri, aynı hiper parametrelere sahip bu modellerle eğitildi.

5.3.1. Veri Ön İşleme Süreci

Veri seti indirildikten sonra 2400 adet eğitim ve 600 adet test olmak üzere 2 farklı klasöre ayrılmıştır. Bu aşamada Evet ve Hayır olmak üzere iki klasördeki görseller Train ve Test olmak üzere iki ayrı klasör altında toplandı. Daha sonra, veri setinin eğitim sürecine hazır hale getirilmesi için bazı ön işleme süreçlerine tabi tutuldu. Bu kapsamda ilk olarak veri arttırma tekniği ile görüntü sayısı arttırıldı. Ardından görüntüler normalizasyon işlemine tutularak daha düzenli hale getirildi. Veri ön işleme sürecinin amacı veriyi modele hazır hale getirmektir. Son aşamada görseller yeniden boyutlandırıldı ve gereksiz kısımlar kırıldı. Görüntüler çeşitli kırpma teknikleri kullanılarak kırıldı. Daha sonra eğitim veri seti ayrı bir klasöre kaydedildi. Her iki veri setinden görseller yüklendikten sonra görseller (224 x 224) olarak yeniden boyutlandırıldı. Görüntüler kırıldıktan sonra genişlik ve yükseklik önemli ölçüde değiştiği için bu işlem tekrar edildi. Kırpma tekniğinin adım adım uygulanması Şekil 5.14'da gösterilmektedir.



Şekil 5.14. MR görüntülerinde kırpma işlemi

5.3.2. Uygulama Detayları

Bu çalışmada modellerin sonuçlarının değerlendirilmesi amacıyla literatürde kullanılan kesinlik, geri çağırma, doğruluk ve F1-skor yöntemleri ele alınmıştır[37]. VGG19, DenseNet169, InceptionV3, AlexNet ve ResNet101'i temel alan sıralı modeller Keras kullanılarak oluşturuldu. Transfer öğrenme yaklaşımı, evrimsel sinir ağı modeli aracılığıyla kullanılmaktadır. Uygulama python kodlarıyla geliştirilmiş ve Google Colab ortamında çalıştırılmıştır. Çalışma aynı ortamda ve aynı hiper parametrelerle gerçekleştirildi. Tüm modeller için kullanılan hiper parametreler Tablo 5.8'de gösterilmektedir.

Tablo 5.8. Modelde kullanılan ve modelin başarısına en fazla etki eden parametreler

Hyper-parametre	Değer
Kayıp	Categorical Crossentropy
Metrik	Accuracy
Optimizer	Adam
Girdi Boyutu	224x224
Ağırlık	ImageNet
Epoch	60
Batch Size	16
Initial Learning Rate	0.0001
Bırakma	0.5
Eğitim	0.8
Test	0.2

Bu çalışmada veri setinin %80'i eğitime, %20'si ise kullanılan testlere ayrılmıştır. Çalışmada beş modelin doğruluk oranları karşılaştırılmış, doğruluk oranı yüksek ve düşük olan modellerin başarı oranları değerlendirilmiştir. Çalışmada kullanılan görüntülerin boyutu, kullanılan mimari yapılara uygun (224×224) formatına göre yeniden boyutlandırıldı. Diğer hiper etki için en ideal değeri yakalamak için, birçok değer denendi ve en yüksek başarı elde

edilen değerler seçildi. Modelin performansını en üst seviyeye çıkarmak için bu şekilde iyileştirmeler yapıldı.


5.3.3. Uygulama Sonuçları

Bu adımda modeller çeşitli değerlendirme kriterleri kullanılarak analiz edildi. ResNet101, tüm beyin tümörü vakalarını %98,6 doğrulukla tespit ederek diğer modellerden daha iyi performans gösterdi. VGG19 modeli ise %97,2 doğruluk oranı gösterdi. ResNet modelinden sonra en yüksek doğruluk değeri VGG ile elde edilmiştir. InceptionV3 modeliyle %94,3 doğruluk elde edildi. DenseNet169 modeli %92,8 doğruluk ve AlexNet %89,5 doğrulukla diğer 3 modele göre daha düşük performans gösterdi. ResNet101 için diğer metrikleri ile de sırasıyla, recall (geri çağırma) 98.6%, precision (kesinlik) için 98.4% ve F1-score (f1 puanı) için 97.9% değerleri elde edilmiştir. Transfer öğrenme yaklaşımının ayrıntılı performansı Tablo 5.9’da gösterilmektedir.

Tablo 5.9. ESA ağlarının doğruluk değerleri

Tümör Tipi	Doğruluk	Duyarlılık	Kesinlik	F1-Puanı
ResNet101	%98.6	%98.6	%98.4	%97.9
VGG19	%97.2	%97.1	%97.2	%97.1
DenseNet169	%92.8	%91	%92	%90
InceptionV3	%94.3	%91.9	%94.2	%91.9
AlexNet	%89.5	%87.7	%89	%88.4

ResNet101 modelinin karışıklık matrisi incelendiğinde; ResNet101 modelinin %98,6 gibi yüksek bir doğruluk oranı elde ettiği görülmektedir. Bu doğruluk oranı modelin başarısı açısından oldukça önemlidir. Bu modelde 11 görüntü aslında tümörlü olmasına rağmen tümörlü olduğu tespit edilemedi ve tümör yok olarak sınıflandırıldı. Ayrıca tümörlü olmayan ve tümörlü olarak sınıflandırılan görüntüye de rastlanmadı. Bu durum, modelin tümör tespitinde ne kadar başarılı olduğunu gösteriyor. Doğruluk ve karışıklık matrisi dikkate alındığında bu modelin beyin tümörü tespit uygulamaları için uygun olduğu söylenebilir. ResNet101 modelinin karışıklık matrisi Şekil 4.20’de gösterilmiştir.



Şekil 5.15. ResNet101 modelin karışıklık matrisi

Bu çalışmada ResNet101 modelinin eğitim süresi diğer modellere göre daha kısa sürede gerçekleşmiştir. Bu çalışmadan anlaşılabileceği üzere ResNet101 modelinin başarısı diğer CNN modellerine göre daha yüksektir. ResNet mimarisinin diğer mimarilerden temel farkı, darboğaz problemini çözebilecek atlama bağlantılarına sahip olmasıdır. CNN ağları derinleştikçe bir darboğazla karşı karşıya kalıyor. ResNet mimarisi, bu sorunu çözmek için ağı paralel atlama bağlantıları ekledi. Bu atlama bağlantısı aynı zamanda artık bloklar olarak da bilinir. Artık bloklar ResNet mimarisinde çok önemli bir yere sahiptir. Artık blok, önceki katmanın girişi doğrudan bir sonraki katmanın çıkışına eklenir, böylece $F(x)+x$ olur. Burada x , katman girişini belirtir. $F()$, ReLU aktivasyon fonksiyonudur. Blok, aynı sayıda çıkış kanalına sahip iki adet 3×3 evrişimli katmana sahiptir. Her evrişim katmanını bir toplu normalleştirme katmanı ve bir ReLU aktivasyon işlevi takip eder. Daha sonra bu iki evrişim atlanır ve giriş, son ReLU aktivasyon fonksiyonunun hemen öncesine eklenir. Diğer derin ağların daha başarılı olamamasının temel nedeni ağlarda derinlik arttıkça karşılaşılan darboğaz sorunudur.

6. SONUÇLAR

Bu tez çalışmasında MR görüntülerinden otomatik tümör tespiti için derin öğrenme tabanlı iki aşamalı bir yaklaşım önerilmiştir. İlk aşamada tümörün yeri, boyutları, büyüklüğünü tespit etmek için segmentasyon işlemi, ikinci aşamada ise tümör tipini tespit etmek için bir sınıflandırma modeli önerilmiştir. Bu kapsamda segmentasyon işlemi için literatürde daha önce hiç denenmeyen hibrit bir DenseNet121 U-Net modeli ve sınıflandırma işlemi için de sıfırdan bir ESA mimarisi tasarlanmıştır. Daha sonra literatürden beyin tümör tespiti için literatürde en yaygın kullanılan derin öğrenme modelleri karşılaştıran bir uygulama gerçekleştirilmiştir.

Bu tez çalışmasında segmentasyon işlemi için BraTS 2019 veri seti kullanılmıştır. Bu veri setinde bulunan görüntüler ilk olarak 256x256 boyutunda eğitilmiş ve DSC değeri tüm tümör, çekirdek tümör ve genişleyen tümör için sırasıyla %93.8, %88.4 ve %84.6 olmuştur. Daha sonra görüntüler 64x64 parçalara bölünerek yeniden eğitilmiş ve aynı alanlar için DSC sırasıyla %95.9, %94.3 ve %89.2 olmuştur. Sonuçlar, görüntüyü bloklara bölmenin daha verimli olduğunu göstermektedir. Son işleme aşamasında görüntüler koordinatlar kullanılarak aynı şekilde birleştirildi. Çalışma sonucunda elde edilen DSC değeri ile görüntü bloklarının birleştirilmesiyle elde edilen görüntüler birebir aynıdır. Ancak orijinal görüntüler, bu kırpmaya işleminin görüntünün özelliklerinde herhangi bir kayba neden olmadığını göstermektedir.

Tıbbi görüntü segmentasyonundaki en büyük zorluk MR görüntülerinin düşük kalitesidir. Bu tür görüntüler, beyin dokusunun farklı bölgelerinde belirsizliği yüksek, düşük çözünürlük ve kontrast değerlerine sahiptir. Genel olarak tümör şekilleri duruma göre farklıdır ve her görüntü bölgesini hassas bir şekilde bölümlere ayırmak zordur. Bu nedenle MR görüntülerini küçük parçalara bölmek zordur. Ancak bu çalışmada çalışmamızın ana odağı olan çekirdek ve genişleyen tümör alanlarının tespitinde DSC değerlerinde daha iyi sonuçlar elde ettik. Bu sonuçlar gelecekteki çalışmalar için küçük tümör alanların segmentasyon performansında iyileşme potansiyeli olduğunu göstermektedir.

Hibrit modeldeki her bir bileşen, bağımsız bir segmentasyon yöntemini temsil eder ve modüllerin iş birliği içinde birleştirilmesinin avantajlarını sağlar. Bu olgu, temsil ettikleri sınıftan bağımsız olarak performansın artmasına neden olur. Farklı modül alt kümelerinin entegre edilmesi, birden fazla hibrit segmentasyon yönteminin türetilmesini ve bunların belirli bir tıbbi görüntüleme uygulamasına en iyi şekilde hizmet edecek şekilde uyarlanmasını mümkün kılar. DenseNet mimarisi, tüm katmanları yoğun bir şekilde birbirine bağlayarak dengesiz sınıf sorununu çözer; bu, her yeni katmanın önceki tüm katmanlardan girdi alması ve bilgilerini sonraki tüm katmanlara iletmesi anlamına gelir. Sonuç olarak son çıktı katmanı,

birinci katman da dahil olmak üzere her katmandan doğrudan bilgi alır. Spesifik olarak, daha iyi doğruluk elde etmek amacıyla MR görüntülerinin ön işlenmesiyle bilgileri farklı seviyelerdeki yoğun bloklara doğrudan iletmek için atlama bağlantılarını kullanan bir DenseNet121-UNet ağı tasarlandı.

Bu çalışma, MR görüntülerini kullanarak beyin tümörü segmentasyonunu gerçekleştirmek için UNet ve önceden eğitilmiş DenseNet121'i temel alan hibrit bir model sunmaktadır. Sınıf dengesizliği sorunu için veri ön işleme adımında görselleri (64x64) boyutuna küçültülerek modele kazandırıldı. Çalışmamız literatürdeki benzer çalışmalara kıyasla tüm, çekirdek ve genişleyen tümör alanlarının segmentasyonunda diğer çalışmalara göre daha yüksek bir DSC elde etmiştir. Sonuç olarak, yöntemimiz farklı beyin tümörü alt bölgelerini segmentlere ayırmada daha kesindir ve klinik araştırmalara etkili bir şekilde uygulanabilir.

Bu tez çalışmasının ikinci aşamasında tümör tiplerini sınıflandırmak için sıfırdan CNN tabanlı bir mimari tasarlandı. Sıfırdan bir mimari tasarlanmanın amacı, modeldeki parametreleri ve filtreleri değiştirerek mevcut modellerin başarısını artırmak ve derin ağlar kullanılmadan sınıflandırma yapılabilmesini göstermektir. Bu kapsamda öncelikle mevcut veri seti ile oluşturulan model, veri artırımı yapılmadan eğitilmiştir. Daha sonra veriler artırılarak aynı model tekrar eğitildi. Buradaki amaç veri artırmanın modelin başarısı üzerindeki etkisini ölçmektir. Veri artırma sonrasında elde edilen yüksek sonuçlar, doğru veri büyütme teknikleri kullanıldığında modelin başarısına olumlu etkileri olduğunu göstermektedir.

Bu çalışmada beyin tümörü tiplerinin MR görüntülerinden tespiti için CNN tabanlı bir yaklaşım önerilmektedir. Modelin başarısını artırmak için veri ön işleme, veri artırma ve hiper parametre ayarlama teknikleri uygulanmıştır. Sıfırdan CNN tabanlı bir ağ oluşturularak beyin tümörü sınıflandırması için etkili bir yaklaşım önerilmiştir. Önerilen modelimiz, glioma tümör tipi için %99.64, menenjiyom için %96.53, hipofiz bezi tümör tipi için %98.39 ve ortalama %98.32 ortalama doğruluk oranı gösterdi. Önerilen modelimiz literatürde aynı veri seti ile karşılaştırılan benzer çalışmalarla karşılaştırıldığında en iyi sonuçları verdiği görülmüştür. Model ayrıca önceden eğitilmiş derin öğrenme ağları Resnet50, VGG19, DenseNet121 ve InceptionV3 ile karşılaştırıldı ve daha iyi sonuçlar aldığı görüldü. Önerilen yaklaşımımız tüm glioma, menenjiyom ve hipofiz bezi tümör tipleri için daha yüksek doğruluk gösterdi. Deneysel sonuçlar, önerdiğimiz yaklaşımın beyin tümörü türlerini sınıflandırmada çok etkili olduğunu ve tıbbi görüntü analizinde bilgisayar tabanlı otomatik tümör tespiti için kullanılabileceğini göstermektedir.

Sıfırdan tasarlanan CNN tabanlı modelin başarısı birçok açıdan test edildi. Sonuçlar incelendiğinde modelin oldukça başarılı olduğu görülmektedir. Ancak bu, modelin süper olduğu ve geliştirilebilecek yönleri olmadığı anlamına gelmemektedir. Oluşturulan modelin birçok

avantajı olduğu gibi dezavantajları da bulunmaktadır. Modelin en önemli avantajı, modelin katmanları ve parametreleri değiştirilerek beyin tümörü tespiti için en uygun yapının oluşturulabilmesidir. Yani bu model oluşturulurken beyin tümörü görüntülerine en uygun yapıda tasarlanmış ve beyin tümörü tespitinde başarılı olan modellerin yapısı dikkate alınmıştır. Ancak bunların yanında modelin bazı dezavantajları da bulunmaktadır, en önemlisi transfer öğrenme yöntemi kullanılmadığından küçük bir veri seti kullanıldığında bile eğitim süresi çok uzun sürmektedir. Bazı sınırlamalardan dolayı daha büyük veri kümeleriyle çalışmak mümkün olmadı. Bu modeli ImageNet gibi bir veri seti ile eğitmek normal bilgisayarlarda imkansızdır. Bu durumda modelin çok büyük veri setleriyle eğitilerek başarısının artırılması zor hale gelebilir.

Bu tez çalışmasının son aşamasında literatürde en yaygın kullanılan derin öğrenme mimarilerini karşılaştırdık. Yapılan bu çalışmada derin öğrenme modelleri arasında beyin tümör tespiti için en yüksek başarı ResNet101 modeli ile elde edildi. ResNet101 mimarisinin test veri seti üzerindeki başarısı doğruluk, geri çağırma, kesinlik ve F1-skor kriterlerine göre belirlenmiştir. Yapılan eğitim ve test deneyleri sonucunda ResNet101 modelinin VGG19, InceptionV3, DenseNet169 ve AlexNet modellerine göre daha yüksek doğruluk oranı sağladığı görülmüştür. ResNet101 mimarisini diğer CNN mimarilerinden ayıran temel fark, mimarisindeki katmanların sayısı ve yapısıdır. Mimaride kullanılan kayıp ve aktivasyon fonksiyonlarının da performansa doğrudan etki ettiği söylenebilir. Kullanılan filtreler ve bu filtrelerin boyutları modelin başarısını etkileyen diğer faktörlerdir. MR görüntüleri gibi yüksek çözünürlüklü görüntüler için de uygun bir model olduğu söylenebilir. ResNet101 yönteminin doğruluk değeri daha önce yapılmış benzer çalışmalarla karşılaştırıldığında ResNet101 yönteminin performansının yüksek olduğu görülmüştür.

ÖNERİLER

Bu tez çalışmasında beyin MR görüntülerinden otomatik tümör tespiti için derin öğrenme tabanlı literatürde daha önce denenmemiş yöntemler geliştirilmiştir. Çalışmanın literatüre en önemli katkısı özgün şekilde gerçekleştirilen veri ön işleme süreçleri ve sıfırdan tasarlanan CNN mimarisidir. Veri ön işleme, veri setinin kalitesini artırarak modelin doğruluğunu ve genelleme yeteneğini iyileştirebilir. Büyük boyutlarda veri setleri, modelin eğitim sürecini yavaşlatabilir ve gereksiz karmaşıklık ekleyebilir. Modelin başarısını etkileyen en önemli konulardan biri de dengeli bir veri setinin kullanılmasıdır. Sınıflar arasında dengeli bir veri seti, modelin her sınıfı eşit derecede öğrenmesini sağlar. Dengesiz veri setleri, nadir sınıfların tanınmasını zorlaştırabilir ve modelin yanlış sonuçlar vermesine neden olabilir. Farklı veri setlerinin bulunmaması, bu alanda karşılaşılan en önemli sorunların başında gelmektedir. Çünkü genellikle daha geniş ve çeşitli veri setleri, derin öğrenme modellerinin daha iyi genelleme yapmasına ve daha güvenilir sonuçlar üretmesine yardımcı olabilir. Ancak, bu durumda da bazı çözümler ve yaklaşımlar kullanılabilir. Veri setinin çeşitliliğini artırmak için sentetik veri oluşturma teknikleri kullanılabilir. Bu yöntemler, mevcut veri setini çeşitlendirmek ve modelin daha geniş bir bilgi yelpazesiyile eğitilmesine yardımcı olmak için kullanılabilir.

KAYNAKLAR

- [1] W. Ayadi, W. Elhamzi, I. Charfi, M. Atri, Deep CNN for Brain Tumor Classification, *Neural Process. Lett.* 53 (2021) 671–700. <https://doi.org/10.1007/s11063-020-10398-2>.
- [2] U. Raghavendra, A. Gudigar, A. Paul, T.S. Goutham, M.A. Inamdar, A. Hegde, A. Devi, C.P. Ooi, R.C. Deo, P.D. Barua, F. Molinari, E.J. Ciaccio, U.R. Acharya, Brain tumor detection and screening using artificial intelligence techniques: Current trends and future perspectives, *Comput. Biol. Med.* 163 (2023) 107063. <https://doi.org/10.1016/j.compbiomed.2023.107063>.
- [3] M.M. Emam, N.A. Samee, M.M. Jamjoom, E.H. Houssein, Optimized deep learning architecture for brain tumor classification using improved Hunger Games Search Algorithm, *Comput. Biol. Med.* 160 (2023) 106966. <https://doi.org/10.1016/j.compbiomed.2023.106966>.
- [4] G.S. Tandel, A. Balestrieri, T. Jujaray, N.N. Khanna, L. Saba, J.S. Suri, Multiclass magnetic resonance imaging brain tumor classification using artificial intelligence paradigm, *Comput. Biol. Med.* 122 (2020) 103804. <https://doi.org/10.1016/j.compbiomed.2020.103804>.
- [5] H. Mohsen, E.-S.A. El-Dahshan, E.-S.M. El-Horbaty, A.-B.M. Salem, Classification using deep learning neural networks for brain tumors, *Futur. Comput. Informatics J.* 3 (2018) 68–71. <https://doi.org/10.1016/j.fcij.2017.12.001>.
- [6] Z.N.K. Swati, Q. Zhao, M. Kabir, F. Ali, Z. Ali, S. Ahmed, J. Lu, Brain tumor classification for MR images using transfer learning and fine-tuning, *Comput. Med. Imaging Graph.* 75 (2019) 34–46. <https://doi.org/10.1016/j.compmedimag.2019.05.001>.
- [7] T. Zhou, Multi-modal brain tumor segmentation via disentangled representation learning and region-aware contrastive learning, *Pattern Recognit.* 149 (2024) 110282. <https://doi.org/10.1016/j.patcog.2024.110282>.
- [8] S. Min, B. Lee, S. Yoon, Deep learning in bioinformatics, *Brief. Bioinform.* 18 (2017) 851–869. <https://doi.org/10.1093/bib/bbw068>.
- [9] Z. Zhou, Z. He, Y. Jia, AFPNet: A 3D fully convolutional neural network with atrous-convolution feature pyramid for brain tumor segmentation via MRI images, *Neurocomputing.* 402 (2020) 235–244. <https://doi.org/10.1016/j.neucom.2020.03.097>.
- [10] N. Bhagat, G. Kaur, MRI brain tumor image classification with support vector machine, *Mater. Today Proc.* 51 (2022) 2233–2244. <https://doi.org/10.1016/j.matpr.2021.11.368>.
- [11] K. Kaplan, Y. Kaya, M. Kuncan, H.M. Ertunç, Brain tumor classification using modified local binary patterns (LBP) feature extraction methods, *Med. Hypotheses.* 139 (2020). <https://doi.org/10.1016/j.mehy.2020.109696>.
- [12] P. Tripathi, V.K. Singh, M.C. Trivedi, Brain tumor segmentation in magnetic resonance imaging using OKM approach, in: *Mater. Today Proc.*, Elsevier Ltd, 2020: pp. 1334–1340. <https://doi.org/10.1016/j.matpr.2020.06.548>.

- [13] M. Havaei, A. Davy, D. Warde-Farley, A. Biard, A. Courville, Y. Bengio, C. Pal, P.M. Jodoin, H. Larochelle, Brain tumor segmentation with Deep Neural Networks, *Med. Image Anal.* 35 (2017) 18–31. <https://doi.org/10.1016/j.media.2016.05.004>.
- [14] D. Daimary, M.B. Bora, K. Amitab, D. Kandar, Brain Tumor Segmentation from MRI Images using Hybrid Convolutional Neural Networks, in: *Procedia Comput. Sci.*, Elsevier B.V., 2020: pp. 2419–2428. <https://doi.org/10.1016/j.procs.2020.03.295>.
- [15] A. Kumar Sahoo, P. Parida, K. Muralibabu, S. Dash, Efficient simultaneous segmentation and classification of brain tumors from MRI scans using deep learning, *Biocybern. Biomed. Eng.* 43 (2023) 616–633. <https://doi.org/10.1016/j.bbe.2023.08.003>.
- [16] M.F. Ahamed, M.M. Hossain, M. Nahiduzzaman, M.R. Islam, M.R. Islam, M. Ahsan, J. Haider, A review on brain tumor segmentation based on deep learning methods with federated learning techniques, *Comput. Med. Imaging Graph.* 110 (2023) 102313. <https://doi.org/10.1016/j.compmedimag.2023.102313>.
- [17] S. Qamar, H. Jin, R. Zheng, P. Ahmad, 3D Hyper-Dense Connected Convolutional Neural Network for Brain Tumor Segmentation, *Proc. - 2018 14th Int. Conf. Semant. Knowl. Grids, SKG 2018.* (2018) 123–130. <https://doi.org/10.1109/SKG.2018.00024>.
- [18] N. Aldoj, F. Biavati, F. Michallek, S. Stober, M. Dewey, Automatic prostate and prostate zones segmentation of magnetic resonance images using DenseNet-like U-net, *Sci. Rep.* 10 (2020). <https://doi.org/10.1038/s41598-020-71080-0>.
- [19] R. Hossain, R.B. Ibrahim, H.B. Hashim, Automated Brain Tumor Detection Using Machine Learning: A Bibliometric Review, *World Neurosurg.* 175 (2023) 57–68. <https://doi.org/10.1016/j.wneu.2023.03.115>.
- [20] B. Srikanth, S. Venkata Suryanarayana, Multi-Class classification of brain tumor images using data augmentation with deep neural network, *Mater. Today Proc.* (2021). <https://doi.org/10.1016/j.matpr.2021.01.601>.
- [21] M. Sajjad, S. Khan, K. Muhammad, W. Wu, A. Ullah, S.W. Baik, Multi-grade brain tumor classification using deep CNN with extensive data augmentation, *J. Comput. Sci.* 30 (2019) 174–182. <https://doi.org/10.1016/j.jocs.2018.12.003>.
- [22] J. Cheng, W. Huang, S. Cao, R. Yang, W. Yang, Z. Yun, Z. Wang, Q. Feng, Enhanced performance of brain tumor classification via tumor region augmentation and partition, *PLoS One.* 10 (2015) 1–13. <https://doi.org/10.1371/journal.pone.0140381>.
- [23] T. Ruba, R. Tamilselvi, M. Parisa Beham, Brain tumor segmentation using JGate-AttResUNet – A novel deep learning approach, *Biomed. Signal Process. Control.* 84 (2023) 104926. <https://doi.org/10.1016/j.bspc.2023.104926>.
- [24] Z. Huang, Y. Liu, G. Song, Y. Zhao, GammaNet: An intensity-invariance deep neural network for computer-aided brain tumor segmentation, *Optik (Stuttg).* 243 (2021). <https://doi.org/10.1016/j.ijleo.2021.167441>.

- [25] X. Lei, X. Yu, J. Chi, Y. Wang, J. Zhang, C. Wu, Brain tumor segmentation in MR images using a sparse constrained level set algorithm, *Expert Syst. Appl.* 168 (2021). <https://doi.org/10.1016/j.eswa.2020.114262>.
- [26] Z. Barzegar, M. Jamzad, WLFS: Weighted label fusion learning framework for glioma tumor segmentation in brain MRI, *Biomed. Signal Process. Control.* 68 (2021). <https://doi.org/10.1016/j.bspc.2021.102617>.
- [27] M. Aghalari, A. Aghagolzadeh, M. Ezoji, Brain tumor image segmentation via asymmetric/symmetric UNet based on two-pathway-residual blocks, *Biomed. Signal Process. Control.* 69 (2021). <https://doi.org/10.1016/j.bspc.2021.102841>.
- [28] P. Ahmad, S. Qamar, S.R. Hashemi, L. Shen, Hybrid labels for brain tumor segmentation, in: *Lect. Notes Comput. Sci. (Including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, Springer, 2020: pp. 158–166. https://doi.org/10.1007/978-3-030-46643-5_15.
- [29] M.U. Rehman, S. Cho, J.H. Kim, K.T. Chong, Bu-net: Brain tumor segmentation using modified u-net architecture, *Electron.* 9 (2020) 1–12. <https://doi.org/10.3390/electronics9122203>.
- [30] P. Ahmad, S. Qamar, S.R. Hashemi, L. Shen, Hybrid labels for brain tumor segmentation, *Lect. Notes Comput. Sci. (Including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*. 11993 LNCS (2020) 158–166. https://doi.org/10.1007/978-3-030-46643-5_15.
- [31] C.R. Edwin Selva Rex, J. Annrose, J. Jenifer Jose, Comparative analysis of deep convolution neural network models on small scale datasets, *Optik (Stuttg.)*. 271 (2022) 170238. <https://doi.org/10.1016/j.ijleo.2022.170238>.
- [32] H.T. Le, H.T. Thu Pham, Brain tumour segmentation using U-Net based fully convolutional networks and extremely randomized trees, *Vietnam J. Sci. Technol. Eng.* 60 (2018) 19–25. [https://doi.org/10.31276/VJSTE.60\(3\).19](https://doi.org/10.31276/VJSTE.60(3).19).
- [33] H.A. Khan, W. Jue, M. Mushtaq, M.U. Mushtaq, Brain tumor classification in MRI image using convolutional neural network, *Math. Biosci. Eng.* 17 (2020) 6203–6216. <https://doi.org/10.3934/MBE.2020328>.
- [34] M. Sajjad, S. Khan, K. Muhammad, W. Wu, A. Ullah, S.W. Baik, Multi-grade brain tumor classification using deep CNN with extensive data augmentation, *J. Comput. Sci.* 30 (2019) 174–182. <https://doi.org/10.1016/j.jocs.2018.12.003>.
- [35] M. Arbane, R. Benlamri, Y. Brik, M. Djerioui, Transfer Learning for Automatic Brain Tumor Classification Using MRI Images, in: *2020 2nd Int. Work. Human-Centric Smart Environ. Heal. Well-Being, IHSH 2020*, Institute of Electrical and Electronics Engineers Inc., 2021: pp. 210–214. <https://doi.org/10.1109/IHSH51661.2021.9378739>.
- [36] A.A. Abbood, Q.M. Shallal, M.A. Fadhel, Automated brain tumor classification using various deep learning models: A comparative study, *Indones. J. Electr. Eng. Comput. Sci.* 22 (2021) 252–259. <https://doi.org/10.11591/ijeecs.v22.i1.pp252-259>.
- [37] S. Deepak, P.M. Ameer, Brain tumor classification using deep CNN features via transfer learning, *Comput. Biol. Med.* 111 (2019) 103345. <https://doi.org/10.1016/j.compbiomed.2019.103345>.

- [38] A. Çınar, M. Yildirim, Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture, *Med. Hypotheses*. 139 (2020). <https://doi.org/10.1016/j.mehy.2020.109684>.
- [39] A. Çınar, M. Yildirim, Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture, *Med. Hypotheses*. 139 (2020) 109684. <https://doi.org/10.1016/j.mehy.2020.109684>.
- [40] M. Toğaçar, B. Ergen, Z. Cömert, BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model, *Med. Hypotheses*. 134 (2020). <https://doi.org/10.1016/j.mehy.2019.109531>.
- [41] L. Pei, L. Vidyaratne, W.W. Hsu, M.M. Rahman, K.M. Iftikharuddin, Brain tumor classification using 3D convolutional neural network, *Lect. Notes Comput. Sci. (Including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*. 11993 LNCS (2020) 335–342. https://doi.org/10.1007/978-3-030-46643-5_33.
- [42] P. Ghosal, L. Nandanwar, S. Kanchan, A. Bhadra, J. Chakraborty, D. Nandi, Brain tumor classification using ResNet-101 based squeeze and excitation deep neural network, 2019 2nd Int. Conf. Adv. Comput. Commun. Paradig. ICACCP 2019. (2019). <https://doi.org/10.1109/ICACCP.2019.8882973>.
- [43] T. Agrawal, P. Choudhary, V. Kumar, P. Singh, M. Diwakar, S. Kumar, A comparative study of brain tumor classification on unbalanced dataset using deep neural networks, *Biomed. Signal Process. Control*. 94 (2024) 106256. <https://doi.org/10.1016/j.bspc.2024.106256>.
- [44] P.S. Tejashwini, J. Thriveni, K.R. Venugopal, Biomedical Signal Processing and Control EBT Deep Net : Ensemble brain tumor Deep Net for multi-classification of brain tumor in MR images, *Biomed. Signal Process. Control*. 95 (2024) 106312. <https://doi.org/10.1016/j.bspc.2024.106312>.
- [45] N. Nazir, A. Sarwar, B.S. Saini, Recent developments in denoising medical images using deep learning: An overview of models, techniques, and challenges, *Micron*. 180 (2024) 103615. <https://doi.org/10.1016/j.micron.2024.103615>.
- [46] N. Benameur, R. Mahmoudi, S. Zaid, Y. Arous, B. Hmida, M.H. Bedoui, SARS-CoV-2 diagnosis using medical imaging techniques and artificial intelligence: A review, *Clin. Imaging*. 76 (2021) 6–14. <https://doi.org/10.1016/j.clinimag.2021.01.019>.
- [47] C. Balmforth, B. Whittington, E. Tzolos, R. Bing, M.C. Williams, L. Clark, C.A. Corral, A. Tavares, M.R. Dweck, D.E. Newby, Translational Molecular imaging: Thrombosis Imaging with Positron Emission Tomography, *J. Nucl. Cardiol.* (2024) 101848. <https://doi.org/10.1016/j.nuclcard.2024.101848>.
- [48] S. Sangui, T. Iqbal, P.C. Chandra, S.K. Ghosh, A. Ghosh, 3D MRI Segmentation using U-Net Architecture for the detection of Brain Tumor, *Procedia Comput. Sci.* 218 (2022) 542–553. <https://doi.org/10.1016/j.procs.2023.01.036>.
- [49] G. Mohan, M.M. Subashini, MRI based medical image analysis: Survey on brain tumor grade classification, *Biomed. Signal Process. Control*. 39 (2018) 139–161. <https://doi.org/10.1016/j.bspc.2017.07.007>.

- [50] H.B. Einarsson, A.L. Frederiksen, I.S. Pedersen, M.S. Ettrup, M. Wrenfeldt, H. Boldt, N. Nguyen, M.S. Andersen, C.R. Bjarkam, F.R. Poulsen, PDP type brain tumor in association with multiple endocrine neoplasia type 1, *Heliyon*. 10 (2024). <https://doi.org/10.1016/j.heliyon.2024.e27418>.
- [51] L. Chen, W. Chen, L. Wang, C. Zhai, X. Hu, L. Sun, Y. Tian, X. Huang, L. Jiang, Convolutional neural networks (CNNs)-based multi-category damage detection and recognition of high-speed rail (HSR) reinforced concrete (RC) bridges using test images, *Eng. Struct.* 276 (2023). <https://doi.org/10.1016/j.engstruct.2022.115306>.
- [52] D. Roy, P. Panda, K. Roy, Tree-CNN: A hierarchical Deep Convolutional Neural Network for incremental learning, *Neural Networks*. 121 (2020) 148–160. <https://doi.org/10.1016/j.neunet.2019.09.010>.
- [53] N. Cinar, B. Kaya, M. Kaya, Comparison of deep learning models for brain tumor classification using MRI images, 2022 Int. Conf. Decis. Aid Sci. Appl. DASA 2022. (2022) 1382–1385. <https://doi.org/10.1109/DASA54658.2022.9765250>.
- [54] N. Cinar, M. Kaya, B. Kaya, A novel convolutional neural network-based approach for brain tumor classification using magnetic resonance images, *Int. J. Imaging Syst. Technol.* 33 (2023) 895–908. <https://doi.org/10.1002/ima.22839>.
- [55] F. Demir, D.A. Abdullah, A. Sengur, A New Deep CNN Model for Environmental Sound Classification, *IEEE Access*. 8 (2020) 66529–66537. <https://doi.org/10.1109/ACCESS.2020.2984903>.
- [56] J. Zhang, M. Guo, J. Fan, A novel CNN structure for fine-grained classification of Chinese calligraphy styles, *Int. J. Doc. Anal. Recognit.* 22 (2019) 177–188. <https://doi.org/10.1007/s10032-019-00324-1>.
- [57] Y. Tai, Y. Tan, E. Zou, B. Lei, Q. Fan, Y. He, Where to model the epistemic uncertainty of Bayesian convolutional neural networks for classification, *Neurocomputing*. 583 (2024) 127568. <https://doi.org/10.1016/j.neucom.2024.127568>.
- [58] A. Saxena, An Introduction to Convolutional Neural Networks, *Int. J. Res. Appl. Sci. Eng. Technol.* 10 (2022) 943–947. <https://doi.org/10.22214/ijraset.2022.47789>.
- [59] I. Namatēvs, Deep Convolutional Neural Networks: Structure, Feature Extraction and Training, *Inf. Technol. Manag. Sci.* 20 (2018) 40–47. <https://doi.org/10.1515/itms-2017-0007>.
- [60] J. Murphy, An Overview of Convolutional Neural Network Architectures for Deep Learning, *Microw. Inc.* (2016) 1–22.
- [61] J. Hyun, H. Seong, E. Kim, Universal pooling – A new pooling method for convolutional neural networks, *Expert Syst. Appl.* 180 (2021) 115084. <https://doi.org/10.1016/j.eswa.2021.115084>.
- [62] C.Y. Lee, P.W. Gallagher, Z. Tu, Generalizing pooling functions in convolutional neural networks: Mixed, gated, and tree, *Proc. 19th Int. Conf. Artif. Intell. Stat. AISTATS 2016*. 51 (2016) 464–472.
- [63] A. Zafar, M. Aamir, N. Mohd Naw, A. Arshad, S. Riaz, A. Alruban, A.K. Dutta, S. Almotairi, A Comparison of Pooling Methods for Convolutional Neural Networks, *Appl. Sci.* 12 (2022) 1–21. <https://doi.org/10.3390/app12178643>.

- [64] J. Fan, M.J. Bocus, B. Hosking, R. Wu, Y. Liu, S. Vityazev, R. Fan, EasyChair Preprint Multi-Scale Feature Fusion: Learning Better Semantic Segmentation for Road Pothole Detection Multi-Scale Feature Fusion: Learning Better Semantic Segmentation For Road Pothole Detection, 2021.
- [65] H. Gholamalinezhad, H. Khosravi, Pooling Methods in Deep Neural Networks, a Review, (2020). <http://arxiv.org/abs/2009.07485>.
- [66] N. Aloysius, M. Geetha, A review on deep convolutional neural networks, Proc. 2017 IEEE Int. Conf. Commun. Signal Process. ICCSP 2017. 2018-Janua (2017) 588–592. <https://doi.org/10.1109/ICCSP.2017.8286426>.
- [67] A. Patil, M. Rane, Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition, Smart Innov. Syst. Technol. 195 (2021) 21–30. https://doi.org/10.1007/978-981-15-7078-0_3.
- [68] S. Albawi, T.A. Mohammed, S. Al-Zawi, Understanding of a convolutional neural network, Proc. 2017 Int. Conf. Eng. Technol. ICET 2017. 2018-Janua (2017) 1–6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>.
- [69] Q. Zhang, M. Zhang, T. Chen, Z. Sun, Y. Ma, B. Yu, Recent advances in convolutional neural network acceleration, Neurocomputing. 323 (2019) 37–51. <https://doi.org/10.1016/j.neucom.2018.09.038>.
- [70] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, Dropout: A simple way to prevent neural networks from overfitting, J. Mach. Learn. Res. 15 (2014) 1929–1958.
- [71] J. Koushik, Understanding Convolutional Neural Networks, (2016) 1–6. <http://arxiv.org/abs/1605.09081>.
- [72] S. Qian, H. Liu, C. Liu, S. Wu, H.S. Wong, Adaptive activation functions in convolutional neural networks, Neurocomputing. 272 (2018) 204–212. <https://doi.org/10.1016/j.neucom.2017.06.070>.
- [73] S. Sharma, S. Sharma, A. Athaiya, Activation Functions in Neural Networks, Int. J. Eng. Appl. Sci. Technol. 04 (2020) 310–316. <https://doi.org/10.33564/ijeast.2020.v04i12.054>.
- [74] F. Agostinelli, M. Hoffman, P. Sadowski, P. Baldi, Learning activation functions to improve deep neural networks, 3rd Int. Conf. Learn. Represent. ICLR 2015 - Work. Track Proc. (2015) 1–9.
- [75] B. Ding, H. Qian, J. Zhou, Activation functions and their characteristics in deep neural networks, Proc. 30th Chinese Control Decis. Conf. CCDC 2018. (2018) 1836–1841. <https://doi.org/10.1109/CCDC.2018.8407425>.
- [76] Y. Wang, Y. Li, Y. Song, X. Rong, The influence of the activation function in a convolution neural network model of facial expression recognition, Appl. Sci. 10 (2020). <https://doi.org/10.3390/app10051897>.
- [77] H. Zhu, H. Zeng, J. Liu, X. Zhang, Logish: A new nonlinear nonmonotonic activation function for convolutional neural network, Neurocomputing. 458 (2021) 490–499. <https://doi.org/10.1016/j.neucom.2021.06.067>.
- [78] A. Dhillon, G.K. Verma, Convolutional neural network: a review of models, methodologies and applications to object detection, Prog. Artif. Intell. 9 (2020) 85–112. <https://doi.org/10.1007/s13748-019-00203-0>.

- [79] Q. Zheng, M. Yang, X. Tian, X. Wang, D. Wang, Rethinking the role of activation functions in deep convolutional neural networks for image classification, *Eng. Lett.* 28 (2020) 80–92.
- [80] M.M. Lau, K.H. Lim, Review of adaptive activation function in deep neural network, 2018 IEEE EMBS Conf. Biomed. Eng. Sci. IECBES 2018 - Proc. (2019) 686–690. <https://doi.org/10.1109/IECBES.2018.08626714>.
- [81] M. Varshney, P. Singh, Optimizing nonlinear activation function for convolutional neural networks, *Signal, Image Video Process.* 15 (2021) 1323–1330. <https://doi.org/10.1007/s11760-021-01863-z>.
- [82] W. Liu, Y. Wen, Z. Yu, M. Yang, Large-Margin Softmax Loss for Convolutional Neural Networks, (2016). <http://arxiv.org/abs/1612.02295>.
- [83] P. Li, R. Jing, X. Shi, Apple Disease Recognition Based on Convolutional Neural Networks With Modified Softmax, *Front. Plant Sci.* 13 (2022). <https://doi.org/10.3389/fpls.2022.820146>.
- [84] Y. Liu, Q. Liu, Convolutional neural networks with large-margin softmax loss function for cognitive load recognition, *Chinese Control Conf. CCC.* (2017) 4045–4049. <https://doi.org/10.23919/ChiCC.2017.8027991>.
- [85] J. Gu, Z. Wang, J. Kuen, L. Ma, A. Shahroudy, B. Shuai, T. Liu, X. Wang, G. Wang, J. Cai, T. Chen, Recent advances in convolutional neural networks, *Pattern Recognit.* 77 (2018) 354–377. <https://doi.org/10.1016/j.patcog.2017.10.013>.
- [86] T. Liu, S. Fang, Y. Zhao, P. Wang, J. Zhang, Implementation of Training Convolutional Neural Networks, (2015). <http://arxiv.org/abs/1506.01195>.
- [87] K. He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.* 2016-Decem (2016) 770–778. <https://doi.org/10.1109/CVPR.2016.90>.
- [88] P. Yuan, S. Lin, C. Cui, Y. Du, R. Guo, D. He, E. Ding, S. Han, HS-ResNet: Hierarchical-Split Block on Convolutional Neural Network, (2020) 1–7. <http://arxiv.org/abs/2010.07621>.
- [89] B. Li, Y. He, An Improved ResNet Based on the Adjustable Shortcut Connections, *IEEE Access.* 6 (2018) 18967–18974. <https://doi.org/10.1109/ACCESS.2018.2814605>.
- [90] M. Sankupellay, D. Konovalov, Bird call recognition using deep convolutional neural network, ResNet-50, *Aust. Acoust. Soc. Annu. Conf. AAS* 2018. (2019) 200–207. <https://doi.org/10.13140/RG.2.2.31865.31847>.
- [91] J. Liang, Image classification based on RESNET, *J. Phys. Conf. Ser.* 1634 (2020). <https://doi.org/10.1088/1742-6596/1634/1/012110>.
- [92] L. Wen, X. Li, L. Gao, A transfer convolutional neural network for fault diagnosis based on ResNet-50, *Neural Comput. Appl.* 32 (2020) 6111–6124. <https://doi.org/10.1007/s00521-019-04097-w>.
- [93] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, 3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc. (2015) 1–14.
- [94] W. Yu, W.Y.E. Cn, K. Yang, Y. Bai, T. Xiao, H. Yao, H.Y.E. Cn, Y. Rui, Visualizing and Comparing AlexNet and VGG using Deconvolutional Layers, *Icml.* 48 (2016) 1–7. <https://icmlviz.github.io/icmlviz2016/assets/papers/4.pdf>.

- [95] A.E. Minarno, B.Y. Sasongko, Y. Munarko, H.A. Nugroho, Z. Ibrahim, Convolutional Neural Network featuring VGG-16 Model for Glioma Classification, *Int. J. Informatics Vis.* 6 (2022) 660–666. <https://doi.org/10.30630/joiv.6.3.1230>.
- [96] Z. Qawaqneh, A.A. Mallouh, B.D. Barkana, Deep Convolutional Neural Network for Age Estimation based on VGG-Face Model, (2017). <http://arxiv.org/abs/1709.01664>.
- [97] C. Alippi, S. Disabato, M. Roveri, Moving Convolutional Neural Networks to Embedded Systems: The AlexNet and VGG-16 Case, *Proc. - 17th ACM/IEEE Int. Conf. Inf. Process. Sens. Networks, IPSN 2018.* (2018) 212–223. <https://doi.org/10.1109/IPSN.2018.00049>.
- [98] A. Vedaldi, A. Zisserman, VGG Convolutional Neural Networks Practical, (2015) 1–28. <http://www.robots.ox.ac.uk/~vgg/practicals/cnn/index.html>.
- [99] G. Huang, Z. Liu, L. Van Der Maaten, K.Q. Weinberger, Densely connected convolutional networks, *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017.* 2017-Janua (2017) 2261–2269. <https://doi.org/10.1109/CVPR.2017.243>.
- [100] G. Li, M. Zhang, J. Li, F. Lv, G. Tong, Efficient densely connected convolutional neural networks, *Pattern Recognit.* 109 (2021). <https://doi.org/10.1016/j.patcog.2020.107610>.
- [101] T. Liao, L. Li, R. Ouyang, X. Lin, X. Lai, G. Cheng, J. Ma, Classification of asymmetry in mammography via the DenseNet convolutional neural network, *Eur. J. Radiol. Open.* 11 (2023) 100502. <https://doi.org/10.1016/j.ejro.2023.100502>.
- [102] N. Cinar, A. Ozcan, M. Kaya, A hybrid DenseNet121-UNet model for brain tumor segmentation from MR Images, *Biomed. Signal Process. Control.* 76 (2022) 103647. <https://doi.org/10.1016/j.bspc.2022.103647>.
- [103] F. Iandola, M. Moskewicz, S. Karayev, R. Girshick, T. Darrell, K. Keutzer, DenseNet: Implementing Efficient ConvNet Descriptor Pyramids, (2014) 1–11. <http://arxiv.org/abs/1404.1869>.
- [104] V.T. Hoang, K.H. Jo, Practical Analysis on Architecture of EfficientNet, *Int. Conf. Hum. Syst. Interact. HSI.* 2021-July (2021). <https://doi.org/10.1109/HSI52170.2021.9538782>.
- [105] Y. Chen, K. Wang, X. Liao, Y. Qian, Q. Wang, Z. Yuan, P.A. Heng, Channel-Unet: A Spatial Channel-Wise Convolutional Neural Network for Liver and Tumors Segmentation, *Front. Genet.* 10 (2019) 1–13. <https://doi.org/10.3389/fgene.2019.01110>.
- [106] A. Lavin, On the Efficiency of Convolutional Neural Networks, (2024). <http://arxiv.org/abs/2404.03617>.
- [107] M. Krichen, Convolutional Neural Networks: A Survey, *Computers.* 12 (2023) 1–41. <https://doi.org/10.3390/computers12080151>.
- [108] W. Weng, X. Zhu, INet: Convolutional Networks for Biomedical Image Segmentation, *IEEE Access.* 9 (2021) 16591–16603. <https://doi.org/10.1109/ACCESS.2021.3053408>.
- [109] V. Zyuzin, P. Sergey, A. Mukhtarov, T. Chumarnaya, O. Solovyova, A. Bobkova, V. Myasnikov, Identification of the left ventricle endocardial border on two-dimensional ultrasound images using the convolutional neural network Unet, *Proc. - 2018 Ural Symp. Biomed. Eng. Radioelectron. Inf. Technol. USBEREIT 2018.* (2018) 76–78. <https://doi.org/10.1109/USBEREIT.2018.8384554>.

- [110] S.W. Chang, S.W. Liao, KUnet: Microscopy image segmentation with deep unet based convolutional networks, *Conf. Proc. - IEEE Int. Conf. Syst. Man Cybern.* 2019-Octob (2019) 3561–3566. <https://doi.org/10.1109/SMC.2019.8914048>.
- [111] R. Levie, C. Yapar, G. Kutyniok, G. Caire, RadioUNet: Fast Radio Map Estimation with Convolutional Neural Networks, *IEEE Trans. Wirel. Commun.* 20 (2021) 4001–4015. <https://doi.org/10.1109/TWC.2021.3054977>.
- [112] Z. Xiao, B. Liu, L. Geng, F. Zhang, Y. Liu, Segmentation of lung nodules using improved 3D-UNet neural network, *Symmetry (Basel)*. 12 (2020) 1–15. <https://doi.org/10.3390/sym12111787>.
- [113] D. Harrison, F.C. De Leo, W.J. Gallin, F. Mir, S. Marini, S.P. Leys, Machine learning applications of convolutional neural networks and unet architecture to predict and classify demosponge behavior, *Water (Switzerland)*. 13 (2021). <https://doi.org/10.3390/w13182512>.
- [114] H. Zhao, O. Gallo, I. Frosio, J. Kautz, Loss Functions for Neural Networks for Image Processing, (2015) 1–11. <http://arxiv.org/abs/1511.08861>.
- [115] K. Janocha, W.M. Czarnecki, On loss functions for deep neural networks in classification, *Schedae Informaticae*. 25 (2016) 49–59. <https://doi.org/10.4467/20838476SI.16.004.6185>.
- [116] H. Zhao, O. Gallo, I. Frosio, J. Kautz, Loss Functions for Image Restoration With Neural Networks, *IEEE Trans. Comput. Imaging*. 3 (2017) 47–57. <https://doi.org/10.1109/TCI.2016.2644865>.
- [117] A. Nicolson, K.K. Paliwal, Deep learning for minimum mean-square error approaches to speech enhancement, *Speech Commun.* 111 (2019) 44–55. <https://doi.org/10.1016/j.specom.2019.06.002>.
- [118] M. Mathieu, C. Couprie, Y. LeCun, Deep multi-scale video prediction beyond mean square error, 4th Int. Conf. Learn. Represent. ICLR 2016 - Conf. Track Proc. (2016) 1–14.
- [119] T.O. Hodson, T.M. Over, S.S. Foks, Mean Squared Error, Deconstructed, *J. Adv. Model. Earth Syst.* 13 (2021) 1–10. <https://doi.org/10.1029/2021MS002681>.
- [120] B. Zhang, R. Sennrich, Root mean square layer normalization, *Adv. Neural Inf. Process. Syst.* 32 (2019) 1–12.
- [121] A. Creswell, K. Arulkumaran, A.A. Bharath, On denoising autoencoders trained to minimise binary cross-entropy, (2017) 2–9. <http://arxiv.org/abs/1708.08487>.
- [122] R. Fei, Q. Yao, Y. Zhu, Q. Xu, A. Li, H. Wu, B. Hu, Deep Learning Structure for Cross-Domain Sentiment Classification Based on Improved Cross Entropy and Weight, *Sci. Program*. 2020 (2020). <https://doi.org/10.1155/2020/3810261>.
- [123] A. Mao, M. Mohri, Y. Zhong, Cross-Entropy Loss Functions: Theoretical Analysis and Applications, *Proc. Mach. Learn. Res.* 202 (2023) 23803–23828.
- [124] P. Li, X. He, X. Cheng, M. Qiao, D. Song, M. Chen, T. Zhou, J. Li, X. Guo, S. Hu, Z. Tian, An improved categorical cross entropy for remote sensing image classification based on noisy labels, *Expert Syst. Appl.* 205 (2022) 117296. <https://doi.org/10.1016/j.eswa.2022.117296>.
- [125] A. Rusiecki, Trimmed categorical cross-entropy for deep learning with label noise, *Electron. Lett.* 55 (2019) 319–320. <https://doi.org/10.1049/el.2018.7980>.
- [126] A.H. Mostafa, H. Abdel-Galil, M. Belal, Ensemble Model-based Weighted Categorical Cross-

- entropy Loss for Facial Expression Recognition, Proc. - 2021 IEEE 10th Int. Conf. Intell. Comput. Inf. Syst. ICICIS 2021. (2021) 165–171. <https://doi.org/10.1109/ICICIS52592.2021.9694244>.
- [127] Q. Huang, J. Sun, H. Ding, X. Wang, G. Wang, Robust liver vessel extraction using 3D U-Net with variant dice loss function, *Comput. Biol. Med.* 101 (2018) 153–162. <https://doi.org/10.1016/j.compbiomed.2018.08.018>.
- [128] N.-T. Do, S.-D. Joo, H.-J. Yang, S.T. Jung, S.-H. Kim, Knee Bone Tumor Segmentation from radiographs using Seg-Unet with Dice Loss, 25th Int. Work. Front. Comput. Vis. (2019).
- [129] R. Zhao, B. Qian, X. Zhang, Y. Li, R. Wei, Y. Liu, Y. Pan, Rethinking dice loss for medical image segmentation, Proc. - IEEE Int. Conf. Data Mining, ICDM. 2020-Novem (2020) 851–860. <https://doi.org/10.1109/ICDM50108.2020.00094>.
- [130] M. Yeung, L. Rundo, Y. Nan, E. Sala, C.B. Schönlieb, G. Yang, Calibrating the Dice Loss to Handle Neural Network Overconfidence for Biomedical Image Segmentation, *J. Digit. Imaging.* 36 (2023) 739–752. <https://doi.org/10.1007/s10278-022-00735-3>.
- [131] A. Lumini, L. Nanni, Deep learning and transfer learning features for plankton classification, *Ecol. Inform.* 51 (2019) 33–43. <https://doi.org/10.1016/j.ecoinf.2019.02.007>.
- [132] D.H. Kim, T. MacKinnon, Artificial intelligence in fracture detection: transfer learning from deep convolutional neural networks, *Clin. Radiol.* 73 (2018) 439–445. <https://doi.org/10.1016/j.crad.2017.11.015>.
- [133] Z. Khademi, F. Ebrahimi, H.M. Kordy, A transfer learning-based CNN and LSTM hybrid deep learning model to classify motor imagery EEG signals, *Comput. Biol. Med.* 143 (2022) 105288. <https://doi.org/10.1016/j.compbiomed.2022.105288>.
- [134] S. Coulibaly, B. Kamsu-Foguem, D. Kamissoko, D. Traore, Deep neural networks with transfer learning in millet crop images, *Comput. Ind.* 108 (2019) 115–120. <https://doi.org/10.1016/j.compind.2019.02.003>.
- [135] J. Wang, J. Gao, J. Ren, Z. Luan, Z. Yu, Y. Zhao, Y. Zhao, DFP-ResUNet: Convolutional Neural Network with a Dilated Convolutional Feature Pyramid for Multimodal Brain Tumor Segmentation, *Comput. Methods Programs Biomed.* 208 (2021) 106208. <https://doi.org/10.1016/j.cmpb.2021.106208>.
- [136] M. Jiang, F. Zhai, J. Kong, A novel deep learning model DDU-net using edge features to enhance brain tumor segmentation on MR images, *Artif. Intell. Med.* 121 (2021) 102180. <https://doi.org/10.1016/j.artmed.2021.102180>.
- [137] S. Anjum, L. Hussain, M. Ali, A.A. Abbasi, T.Q. Duong, Automated multi-class brain tumor types detection by extracting RICA based features and employing machine learning techniques, *Math. Biosci. Eng.* 18 (2021) 2882–2908. <https://doi.org/10.3934/MBE.2021146>.
- [138] K. Gürkahraman, R. Karakiş, Brain tumors classification with deep learning using data augmentation, *J. Fac. Eng. Archit. Gazi Univ.* 36 (2021) 997–1011. <https://doi.org/10.17341/gazimmfd.762056>.
- [139] K. Maharana, S. Mondal, B. Nemade, A review: Data pre-processing and data augmentation techniques, *Glob. Transitions Proc.* 3 (2022) 91–99. <https://doi.org/10.1016/j.gltp.2022.04.020>.

- [140] G.S. Tandel, A. Balestrieri, T. Jujaray, N.N. Khanna, L. Saba, J.S. Suri, Multiclass magnetic resonance imaging brain tumor classification using artificial intelligence paradigm, *Comput. Biol. Med.* 122 (2020). <https://doi.org/10.1016/j.combiomed.2020.103804>.
- [141] Q. Zhu, L. Fan, N. Weng, Advancements in Point Cloud Data Augmentation for Deep Learning : A Survey, *Pattern Recognit.* (2024) 1–29. <https://doi.org/10.1016/j.patcog.2024.110532>.
- [142] S.U. Khan, N. Islam, Z. Jan, I. Ud Din, J.J.P.C. Rodrigues, A novel deep learning based framework for the detection and classification of breast cancer using transfer learning, *Pattern Recognit. Lett.* 125 (2019) 1–6. <https://doi.org/10.1016/j.patrec.2019.03.022>.
- [143] C. Ozdemir, Y. Dogan, Y. Kaya, RGB-Angle-Wheel: A new data augmentation method for deep learning models, *Knowledge-Based Syst.* 291 (2024) 111615. <https://doi.org/10.1016/j.knosys.2024.111615>.
- [144] A. Mikołajczyk, M. Grochowski, Data augmentation for improving deep learning in image classification problem, 2018 Int. Interdiscip. PhD Work. IIPhDW 2018. (2018) 117–122. <https://doi.org/10.1109/IIPhDW.2018.8388338>.
- [145] C. Shorten, T.M. Khoshgoftaar, A survey on Image Data Augmentation for Deep Learning, *J. Big Data.* 6 (2019). <https://doi.org/10.1186/s40537-019-0197-0>.
- [146] P. Chlap, H. Min, N. Vandenberg, J. Dowling, L. Holloway, A. Haworth, A review of medical image data augmentation techniques for deep learning applications, *J. Med. Imaging Radiat. Oncol.* 65 (2021) 545–563. <https://doi.org/10.1111/1754-9485.13261>.
- [147] C. Khosla, B.S. Saini, Enhancing Performance of Deep Learning Models with different Data Augmentation Techniques: A Survey, *Proc. Int. Conf. Intell. Eng. Manag. ICIEM 2020.* (2020) 79–85. <https://doi.org/10.1109/ICIEM48762.2020.9160048>.
- [148] M. Usef Khosravi Khaliran, I. Zabbah, M. Faraji, R. Ebrahimpour, Improving deep learning in arrhythmia Detection: The application of modular quality and quantity controllers in data augmentation, *Biomed. Signal Process. Control.* 91 (2024) 105940. <https://doi.org/10.1016/j.bspc.2023.105940>.
- [149] E. Montin, C.M. Deniz, R. Kijowski, T. Youm, R. Lattanzi, The impact of data augmentation and transfer learning on the performance of deep learning models for the segmentation of the hip on 3D magnetic resonance images, *Informatics Med. Unlocked.* 45 (2024) 101444. <https://doi.org/10.1016/j.imu.2023.101444>.
- [150] R. Almajalid, J. Shan, Y. Du, M. Zhang, Development of a Deep-Learning-Based Method for Breast Ultrasound Image Segmentation, in: *Proc. - 17th IEEE Int. Conf. Mach. Learn. Appl. ICMLA 2018, Institute of Electrical and Electronics Engineers Inc., 2019: pp. 1103–1108.* <https://doi.org/10.1109/ICMLA.2018.00179>.
- [151] M. Polak, H. Zhang, M. Pi, An evaluation metric for image segmentation of multiple objects, *Image Vis. Comput.* 27 (2009) 1223–1227. <https://doi.org/10.1016/j.imavis.2008.09.008>.
- [152] A. Deshpande, V. V. Estrela, P. Patavardhan, The DCT-CNN-ResNet50 architecture to classify brain tumors with super-resolution, convolutional neural network, and the ResNet50, *Neurosci. Informatics.* 1 (2021) 100013. <https://doi.org/10.1016/j.neuri.2021.100013>.

- [153] M. Agarwal, S.K. Gupta, K.K. Biswas, Development of Efficient CNN model for Tomato crop disease identification, *Sustain. Comput. Informatics Syst.* 28 (2020) 100407. <https://doi.org/10.1016/j.suscom.2020.100407>.
- [154] Z. Jia, D. Chen, Brain Tumor Identification and Classification of MRI images using deep learning techniques, *IEEE Access.* 1 (2020) 1–1. <https://doi.org/10.1109/access.2020.3016319>.
- [155] S. Qamar, H. Jin, R. Zheng, P. Ahmad, 3D Hyper-Dense Connected Convolutional Neural Network for Brain Tumor Segmentation, in: *Proc. - 2018 14th Int. Conf. Semant. Knowl. Grids, SKG 2018*, Institute of Electrical and Electronics Engineers Inc., 2018: pp. 123–130. <https://doi.org/10.1109/SKG.2018.00024>.
- [156] H. Firat, D. Hanbay, Classification of hyperspectral images using 3D CNN based ResNet50, in: *SIU 2021 - 29th IEEE Conf. Signal Process. Commun. Appl. Proc.*, Institute of Electrical and Electronics Engineers Inc., 2021. <https://doi.org/10.1109/SIU53274.2021.9477899>.
- [157] Y. Feng, H. Zhao, X. Li, X. Zhang, H. Li, A multi-scale 3D Otsu thresholding algorithm for medical image segmentation, *Digit. Signal Process. A Rev. J.* 60 (2017) 186–199. <https://doi.org/10.1016/j.dsp.2016.08.003>.
- [158] D. Maji, P. Sigeddar, M. Singh, Attention Res-UNet with Guided Decoder for semantic segmentation of brain tumors, *Biomed. Signal Process. Control.* 71 (2022) 103077. <https://doi.org/10.1016/j.bspc.2021.103077>.
- [159] H. Uzen, M. Turkoglu, D. Hanbay, Surface defect detection using deep U-net network architectures, in: *SIU 2021 - 29th IEEE Conf. Signal Process. Commun. Appl. Proc.*, Institute of Electrical and Electronics Engineers Inc., 2021. <https://doi.org/10.1109/SIU53274.2021.9477790>.
- [160] S. Hussain, S.M. Anwar, M. Majid, Segmentation of glioma tumors in brain using deep convolutional neural network, *Neurocomputing.* 282 (2018) 248–261. <https://doi.org/10.1016/j.neucom.2017.12.032>.
- [161] J. Xue, J. Hu, Y. Wang, D. Kong, S. Yan, R. Zhao, D. Li, Y. Liu, X. Liu, Hypergraph membrane system based F2 fully convolutional neural network for brain tumor segmentation, *Appl. Soft Comput. J.* 94 (2020). <https://doi.org/10.1016/j.asoc.2020.106454>.
- [162] T.D. Bui, J. Shin, T. Moon, Skip-connected 3D DenseNet for volumetric infant brain MRI segmentation, *Biomed. Signal Process. Control.* 54 (2019). <https://doi.org/10.1016/j.bspc.2019.101613>.
- [163] N. Sheng, D. Liu, J. Zhang, C. Che, J. Zhang, Second-order ResU-Net for automatic MRI brain tumor segmentation, *Math. Biosci. Eng.* 18 (2021) 4943–4960. <https://doi.org/10.3934/mbe.2021251>.
- [164] P. Wang, A.C.S. Chung, Relax and Focus on Brain Tumor Segmentation, *Med. Image Anal.* (2021) 102259. <https://doi.org/10.1016/j.media.2021.102259>.
- [165] P. Nagaraj, V. Muneeswaran, L. Veera Reddy, P. Upendra, M. Vishnu Vardhan Reddy, Programmed Multi-Classification of Brain Tumor Images Using Deep Neural Network, *Proc. Int. Conf. Intell. Comput. Control Syst. ICICCS* 2020. (2020) 865–870. <https://doi.org/10.1109/ICICCS48265.2020.9121016>.

- [166] S. Duan, H. Zheng, J. Liu, A novel classification method for flutter signals based on the CNN and STFT, *Int. J. Aerosp. Eng.* 2019 (2019). <https://doi.org/10.1155/2019/9375437>.
- [167] A. Chattopadhyay, M. Maitra, MRI-based brain tumour image detection using CNN based deep learning method, *Neurosci. Informatics.* 2 (2022) 100060. <https://doi.org/10.1016/j.neuri.2022.100060>.
- [168] J. Kim, A.D. Nguyen, S. Lee, Deep CNN-Based Blind Image Quality Predictor, *IEEE Trans. Neural Networks Learn. Syst.* 30 (2019) 11–24. <https://doi.org/10.1109/TNNLS.2018.2829819>.
- [169] L.H. Shehab, O.M. Fahmy, S.M. Gasser, M.S. El-Mahallawy, An efficient brain tumor image segmentation based on deep residual networks (ResNets), *J. King Saud Univ. - Eng. Sci.* 33 (2021) 404–412. <https://doi.org/10.1016/j.jksues.2020.06.001>.
- [170] S. Deepak, P.M. Ameer, Brain tumor classification using deep CNN features via transfer learning, *Comput. Biol. Med.* 111 (2019) 103345. <https://doi.org/10.1016/j.combiomed.2019.103345>.



ÖZGEÇMİŞ

Necip ÇINAR

[illegible]

[REDACTED]	
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]

■ _____

[REDACTED]	
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]

AKADEMİK FAALİYETLER

Makaleler:

1. N. Cinar, A. Ozcan, and M. Kaya, "A hybrid DenseNet121-UNet model for brain tumor segmentation from MR Images," *Biomed. Signal Process. Control*, vol. 76, no. February, p. 103647, 2022, doi: 10.1016/j.bspc.2022.103647.
2. N. Cinar, M. Kaya, and B. Kaya, "A novel convolutional neural network-based approach for brain tumor classification using magnetic resonance images," *Int. J. Imaging Syst. Technol.*, vol. 33, no. 3, pp. 895–908, 2023, doi: 10.1002/ima.22839.

Bildiriler:

1. N. Cinar, B. Kaya, and M. Kaya, "Comparison of deep learning models for brain tumor classification using MRI images," *2022 Int. Conf. Decis. Aid Sci. Appl. DASA 2022*, pp. 1382–1385, 2022, doi: 10.1109/DASA54658.2022.9765250.
2. N. Çinar, B. Kaya, and M. Kaya, "Brain Stroke Detection from CT Images using Transfer Learning Method," *Proc. - Int. Conf. Adv. Comput. Inf. Technol. ACIT*, pp. 595–599, 2023, doi: 10.1109/ACIT58437.2023.10275682.
3. N. Cinar and M. Kaya, "An automated pothole detection via transfer learning," *2022 Int. Conf. Decis. Aid Sci. Appl. DASA 2022*, pp. 1355–1358, 2022, doi: 10.1109/DASA54658.2022.9765021.

