

**T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**BEYİN MR GÖRÜNTÜLERİNİN GÖRÜNTÜ İŞLEME
TEKNİKLERİ KULLANILARAK SINIFLANDIRILMASI**

Ercüment GÜVENÇ

**Danışman
Dr.Öğr. Üyesi Mevlüt ERSOY**

**II. Danışman
Doç.Dr. Gürcan ÇETİN**

**DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
ISPARTA - 2023**



© 2023 [Ercüment GÜVENÇ]

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER	i
ÖZET.....	iii
ABSTRACT.....	v
TEŞEKKÜR.....	vii
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ	ix
SİMGELER VE KISALTMALAR DİZİNİ	x
1. GİRİŞ.....	1
2. KAYNAK ÖZETLERİ.....	8
3. MATERYAL ve YÖNTEM.....	16
3.1. Beyin Tümörü	16
3.2. Kullanılan Veri Seti.....	17
3.3. Makine Öğrenmesi	19
3.4. Yapay Sinir Ağları	20
3.4.1. Aktivasyon fonksiyonları	22
3.4.1.1. Doğrusal fonksiyon.....	22
3.4.1.2. Sigmoid fonksiyonu:.....	23
3.4.1.3. Tanh fonksiyonu:	24
3.4.1.4. ReLU fonksiyonu:.....	25
3.4.1.5. Leaky ReLU fonksiyonu:.....	25
3.4.1.6. Softmax fonksiyonu:.....	26
3.5. Derin Öğrenme	27
3.5.1. Evrimsel sinir ağları.....	27
3.5.2. Yinelemeli sinir ağları.....	29
3.5.3. Uzun-Kısa Süreli Hafıza	30
3.5.4. Üretken Çekişmeli Ağlar.....	32
3.5.4.1. CGAN (Conditional GAN)-Koşullu GAN	35
3.5.4.2. DCGAN (Deep convolutional GAN) – Derin konvolüsyonel GAN	36
3.5.4.3. ACGAN (Auxiliary classifier GAN)-Yardımcı sınıflandırıcı GAN	38
3.5.4.4. InfoGAN-Bilgi GAN	39
3.5.4.5. SGAN – Yarı eğitici GAN.....	40
3.5.4.6. WGAN - Wasserstein GAN’ların geliştirilmiş eğitimi.....	41
3.5.4.7. LSGAN - En az kareler GAN	42
3.5.5. Oto Kodlayıcılar	42
3.6. Görüntü İşleme.....	44
3.7. K-Ortalamalar Yöntemi ile Görüntü Bölütleme.....	45
3.8. Karar Verme Ölçütleri.....	46
3.9. Derin Öğrenme Mimarileri.....	47
3.9.1. UNET	47
3.9.2. RESUNET	48
3.9.3. RESNET50	49
3.9.4. VGG16.....	50
3.9.5. VGG19.....	51
4. MR GÖRÜNTÜLERİNDEN DC-GAN TABANLI OTOMATİK TÜMÖR BÖLGE BÖLÜTLEMESİ.....	52

4.1. Derin Öğrenme ile Tümörlü Bölge Bölütlemesi	52
4.2. DC-GAN ile MR Görüntü Çoğaltma ve K-Ortalamlar ile Tümörlü Bölgenin Otomatik Bölütlenmesi.....	58
5. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	65
6. SONUÇ ve ÖNERİLER.....	73
KAYNAKLAR	74
ÖZGEÇMİŞ	81



ÖZET

Doktora Tezi

BEYİN MR GÖRÜNTÜLERİNİN GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK SINIFLANDIRILMASI

Ercüment GÜVENÇ

Süleyman Demirel Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Mevlüt ERSOY

II. Danışman: Doç. Dr. Gürcan ÇETİN

Yaşadığımız yüzyılda beyin tümörlerinden kaynaklanan ölümlerin sayısı her geçen gün artmaktadır. Beyin tümörleri genellikle, radyasyona maruz kalma, zararlı yiyecek ve içeceklerin aşırı tüketilmesi, aşırı stresli durumlar ile alkol ve sigaranın aşırı olarak tüketilmesi sonucunda ortaya çıkmaktadır. Beyin tümörünün erken tespiti, bu tümöre yönelik yapılacak tedavinin erken başlamasını da hızlandıracaktır. Eğer beyin tümörüne sahip bir hasta erken tedavi sürecine girmezse hayatta kalma süresi kısalmaktadır. Modern Tıp'ın getirdiği teknolojik gelişmelere bağlı olarak insan vücudunun görselleştirilmesi için kullanılan yöntemlerde artmıştır. Manyetik Rezonans (MR) görüntüleri bu anlamda en sık kullanılan yöntemlerden birisidir.

MR görüntülerinin analizinin başarımı insan gözünün görme yeteneği ve doktorun deneyimleri ile sınırlıdır. Ayrıca, beyin tümörlerinin farklı şekil ve büyüklüklere sahip olması tümörlerin tespitini zorlaştıran diğer bir faktördür. Gerçekleştirilen bu tez çalışmasında, beyin tümörlerinin sınıflandırılmasında MR görüntüleri ile uzman doktor tarafından yapılan tespitlerdeki hataların en aza indirgenmesini sağlayacak bir uygulama üzerinde çalışılmıştır. Uygulama derin öğrenme modellerini kullanarak, uzman doktorların MR görüntülerindeki tümörlü bölgeleri tespit edebilmesini doğru ve hızlı bir şekilde sağlayacaktır. Bu uygulama ile birlikte ayrıca, uygulamanın tümörlü bölge tespitindeki başarımlarının artırılmasında kullanılan Üretken Çekişmeli Ağ (GAN) ve K-Ortalamlar modelleri üzerinde çalışılmıştır. Çalışmanın başlıca amacı, özellikle tıbbi bilişim alanında veri toplamanın zor olduğu, yeterince veriye ulaşılamayan durumlarda mevcut MR görüntülerinden yeni gerçekçi sentetik veriler üreterek, mevcut modellerin başarımını arttırmaktır. Çalışmada birçok araştırmada da kullanılan BraTS'ın (Brain Tumor Segmentation) 2018 yılına ait olan veri seti seçilmiştir..

Tez çalışmasında, veri setinden elde edilen görüntülerin bölütlenmesi için literatürde başarılı sonuçlar veren derin öğrenme modelleri (U-NET, RESUNET, VGG16, VGG19) kullanılmıştır. Öncelikle, bu modellerin tümörlü bölgenin bölütlenmesi sürecindeki başarımı Dice skoru, IoU ve kesinlik gibi ölçüm değerleriyle araştırılmıştır. Çalışmanın ilerleyen aşamalarında ise, derin öğrenme modellerinin bölütleme başarımlarını arttırmak için MR görüntülerinin çoğaltılmasında GAN

modelleri kullanılmıştır. Bu aşamada, BraTS2018 veri setinde yer alan 210 yüksek dereceli tümöre sahip (HGG) hastaya ait görüntü içerisinden seçilen 144 görüntü kaynak olarak belirlenmiştir. GAN yöntemiyle üretilen, sentetik görüntülerden uygun olan 572 MR görüntüsü seçilmiştir. Üretilen sentetik görüntülerdeki tümörlü bölgelerin otomatik olarak belirlenmesi için de K-Ortalamlar kümeleme algoritması kullanılmıştır. Üretilen MR görüntülerinin, mevcut veri setine eklenmesi sonucunda, veri setinin boyutu 782'ye çıkartılmıştır. GAN tabanlı sentetik MR görüntülerinin eklendiği veri seti kullanılarak gerçekleştirilen bölütleme işleminin sonuçları ile ilk veri setindeki görüntüler ile elde edilen sonuçlar karşılaştırıldığında hem eğitim hem de test verilerinde tümörlü bölgenin bölütleme başarımında önemli oranda bir artış gözlemlenmiştir. Çalışma sonucunda, ResNet50 modeli derin öğrenme modelleri arasında en yüksek başarıyı sağlamıştır. Modelin başarımlar değerleri, kesinlik için 98.99%'dan 99.26%'ya, dice coefficient score için 57.33%'den 81.32%'ye ve IoU için 40.89%'den 66.86%'ya yükselmiştir.

Anahtar Kelimeler: Derin Öğrenme, Üretken Çekişmeli Ağlar, K-ortalamlar, Beyin Tümörü Bölütlemesi.

2023, 81 sayfa

ABSTRACT

Ph.D. Thesis

CLASSIFICATION OF BRAIN MR IMAGES USING IMAGE PROCESSING TECHNIQUES

Ercüment GÜVENÇ

**Süleyman Demirel University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering**

Supervisor: Asst. Prof. Dr. Mevlüt ERSOY

Co-Supervisor: Assoc. Prof. Dr. Gürcan ÇETİN

In the century we live in, the number of deaths caused by brain tumors is increasing every day. Brain tumors usually arise as a result of factors such as exposure to radiation, excessive consumption of harmful foods and beverages, excessive stressful conditions, and excessive consumption of alcohol and tobacco. Early detection of brain tumors will also accelerate the initiation of treatment for this tumor. If a patient with a brain tumor does not enter the early treatment process, their survival time will be shortened. Due to the technological advancements brought by modern medicine, the methods used for visualizing the human body have increased. Magnetic Resonance (MR) imaging is one of the most commonly used methods in this regard.

The performance of analyzing MR images is limited by the visual ability of the human eye and the experience of the doctor. Additionally, the fact that brain tumors can have different shapes and sizes is another factor that makes tumor detection difficult. In this thesis study, work has been done on an application that will minimize the errors in the detections made by expert doctors using MR images for the classification of brain tumors. The application will enable expert doctors to accurately and quickly identify tumor regions in MR images using deep learning models. In addition to this application, work has also been done on Generative Adversarial Network (GAN) and K-Means models used to increase the success rate of tumor region detection in the application. The main goal of the study is to increase the performance of existing models by generating new realistic synthetic data from existing MR images, especially in cases where data collection is difficult in the field of medical informatics and sufficient data cannot be obtained. The BraTS (Brain Tumor Segmentation) dataset from 2018, which is used in many studies, has been selected for this study.

Successful deep learning models (U-NET, RESUNET, VGG16, VGG19) that have yielded successful results in the literature for segmenting images obtained from the dataset were used. Firstly, the performance of these models in the segmentation process of the tumor region was investigated with measurement values such as Dice score, IoU, and accuracy. In the later stages of the study, GAN models were used to augment the MR images to increase the segmentation success rates of the deep learning models. In this stage, 144 selected images from the MR images of 210 patients with

high-grade tumors (HGG) in the BraTS2018 dataset were determined as the source of images. A total of 572 suitable MR images were selected from the synthetic images generated by the GAN method. The K-Means clustering algorithm was used to automatically identify the tumor regions in the generated synthetic images. As a result of adding the generated MR images to the existing dataset, the size of the dataset was increased to 782. When the results of the segmentation process performed using the dataset with GAN-based synthetic MR images were compared with the results obtained from the images in the initial dataset, a significant increase in tumor region segmentation performance was observed in both training and test data. In conclusion, the ResNet50 model achieved the highest performance among the deep learning models. The performance values of the model increased from 98.99% to 99.26% for accuracy, from 57.33% to 81.32% for the dice coefficient score, and from 40.89% to 66.86% for IoU.

Keywords: Deep Learning, Generative Adversarial Networks (GANS) , K-means, Brain Tumor Segmentation

2023, 81 pages

TEŞEKKÜR

Doktora sürecine başlamamda bana destek olan saygıdeğer hocam Prof. Dr. Tuncay YİĞİT ile bu araştırma için beni yönlendiren değerli danışman hocam Dr. Öğr. Üyesi Mevlüt ERSOY ve ikinci danışmanım olarak, karşılaştığım zorlukları bilgi ve tecrübesi ile aşmamda yardımcı olan birçok konuda bana desteğini gösteren arkadaşım ve değerli hocam Doç. Dr. Gürcan ÇETİN'e teşekkürlerimi sunarım. Ayrıca literatür araştırmalarımda yardımcı olan değerli hocam Doç. Dr. Osman ÖZKARACA ve tezi hazırlarken yaptığım çalışmalarda yardımlarını ve desteğini esirgemeyen arkadaşım Öğr. Gör. Dr. Murat SAKAL ile MR görüntülerinin incelenmesi ve elde edilen sonuçların değerlendirilmesinde yardımcı olan Op.Dr. Gökmen REYHANLI'ya teşekkür ederim.

Doktora sürecimin başlangıcından sonuna kadar, her aşamasında bana destek olan ve beni yalnız bırakmayan sevgili eşim Burcu GÜVENÇ ile biricik oğullarım Rüzgâr Enes ve Emre Nesim'e, ayrıca beni yetiştiren ve bugünlere gelmemde en çok emeği gösteren sevgili anneme ve babama da sonsuz sevgi ve saygılarımı sunarım.

Ercüment GÜVENÇ
ISPARTA, 2023

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. Tümörsüz ve Tümörlü beyin MR görüntüsü	2
Şekil 1.2. (A) Glioma, (B) Meningioma, (C) Pituitary Tümör MR Görüntüleri	3
Şekil 3.1. Yüksek dereceli Glioma tümörüne sahip beyin MR görüntüleri	16
Şekil 3.2. Tüm sekanslara ait MR görüntülerine ait katmanlardan bazıları	18
Şekil 3.3. Herhangi bir hastaya ait MR görüntüsündeki işaretlenen tümörlü bölgenin katmanlarından bazıları	18
Şekil 3.4. Tek Katmanlı Standart Yapay Sinir Ağı Modeli	21
Şekil 3.5. Doğrusal fonksiyona ait grafik	23
Şekil 3.6. Sigmoid fonksiyonu grafiği	24
Şekil 3.7. tanh fonksiyonu grafiği	24
Şekil 3.8. ReLU fonksiyonu grafiği	25
Şekil 3.9. leaky ReLU fonksiyonu grafiği	26
Şekil 3.10. Softmax fonksiyonu grafiği	26
Şekil 3.11. Sınıflandırma İçin Kullanılan bir Evrişimsel Sinir Ağı Modelinin Yapısı	28
Şekil 3.12. LSTM sinir ağı modeli	31
Şekil 3.13. GAN klasik mimari yapısı	35
Şekil 3.14. (A) Standart GAN mimarisi, (B) CGAN mimarisi	36
Şekil 3.15. DCGAN Mimari yapısı	38
Şekil 3.16. CGAN ve DCGAN karşılaştırma	39
Şekil 3.17. Standart GAN - InfoGAN yapısı	40
Şekil 3.18. SGAN mimari yapısı	41
Şekil 3.19. Otokodlayıcıların genel yapısı	43
Şekil 3.20. IoU formülasyonu	46
Şekil 3.21. Dice coefficient formülasyonu	47
Şekil 3.22. U-Net Mimarisinin görüntüsü	48
Şekil 3.23. ResUNet Mimarisinin görüntüsü	49
Şekil 3.24. VGG16 ve VGG19 mimari yapısı	50
Şekil 4.1. FLAIR MR görüntüleri ve tümörlü bölge bölütlemesi	53
Şekil 4.2. Önerilen modele göre çalışmanın ilk aşamasında yapılan işlemler	54
Şekil 4.3. DCGAN mimarisi	59
Şekil 4.4. Önerilen modelin çalışmanın ikinci aşamasındaki mimari yapısı	60
Şekil 4.5. DCGAN modelinin ürettiği bazı görüntüler	61
Şekil 4.6. Brats2018 ve DCGAN örnek MR görüntüleri	61
Şekil 4.7. K-Ortalamalar ile gerçekleştirilen işlem adımları	62
Şekil 4.8. DCGAN ile üretilen görüntüden tümörlü bölge çıkarımı işlem adımları ..	63
Şekil 4.9. DCGAN modeliyle üretilen MR görüntüleri ve tümörlü bölgeleri	64
Şekil 5.1. Eğitim verilerine göre Dice ve IoU skor değerleri	67
Şekil 5.2. Test verilerine göre Dice ve IoU skor değerleri	67

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 4.1. Brats2018 veri setindeki 210 hastaya ait görüntü ile gerçekleştirilen bölütleme sonuçları	55
Çizelge 4.2. Brats2018 veri setine göre modellerin tümörlü bölge tespiti.....	57
Çizelge 5.1. Üretilmiş verilerle birlikte oluşturulan yeni veri seti ile elde edilen sonuçlar	65
Çizelge 5.2. Ham veriler ile üretilen görüntüler ile elde edilen sonuçların karşılaştırılması	68
Çizelge 5.3. Veri Setinin İlk ve Son Haline Göre Modellerin Tümörlü Bölge Tespiti.....	68
Çizelge 5.4. Derin öğrenme yöntemlerinin literatür çalışmaları ile karşılaştırılması	70



SİMGELER VE KISALTMALAR DİZİNİ

b	Bias
BraTS	Brain Tumor Segmentation Challenge
BT	Bilgisayarlı Tomografi)
CNN	Convolutional Neural Networks
DCGAN	Deep Convolutional GAN
DÖ	Derin Öğrenme
DS	Dice Score
DSÖ	Dünya Sağlık Örgütünün
FLAIR	Fluid Attenuated Inversion Recovery
GAN	Generative Adversarial Networks
GPU	Graphic Processing Unit
HGG	High Grade Glioma
IoU	Intersection over union
ISBI	International Symposium on Biomedical Imaging
K-Means	K-Ortalamalar
LGG	Low Grade Glioma
MRG	Manyetik Rezonans Görüntüleme
MRS	Manyetik Rezonans Spektroskopi
MSS	Merkezi Sinir Sistemi
NIfTI	Neuroimaging Informatics Technology Initiative
NLP	Natural Language Processing
PET	pozitron emisyon tomografisi
RNN	Recurrent Neural Network
w	Ağırlık değeri
WHO	World Health Organization

1. GİRİŞ

Kanser hastalığı, günümüzde çok sayıda türü olan ve dünya üzerinde çok sayıda insanın sağlığını olumsuz yönde etkileyen bir hastalıktır. Kanser, vücudumuzun çeşitli bölgelerindeki hücrelerin kontrolsüz bir şekilde çoğalması ile oluşan hastalıklar olarak da adlandırılmaktadır (Halk Sağlığı Genel Müdürlüğü, 2017).


Literatürde bugüne kadar tespit edilmiş yüzden fazla kanser çeşidi bulunmaktadır. Kanser hastalıklarının çeşitlendirilmesi ve isimlendirilmesi bulunduğu organ veya dokuya göre belirlenmektedir. Buna göre en sık rastlanan kanser hastalıkları deri, akciğer, mide, bağırsak ve meme kanserleri olarak bilinmektedir (Halk Sağlığı Genel Müdürlüğü, 2017). Dünya Sağlık Örgütü'nün (D.S.Ö.) 2020 yılında yaptığı araştırmaya göre kanser hastalıklarına yakalanma hızı ve bu hastalıklardan dolayı ölümlerin önemli bir artış gösterdiği görülmektedir (World Health Organization, 2020). Teknolojinin gelişmesiyle birlikte teknolojik cihazların yaymış olduğu sinyaller, radyasyon ve zararlı ışınlar nedeniyle insan vücudunda tümörler de sıklıkla rastlanır bir hastalık haline gelmiştir.

Beyin tümörleri, diğer kanser türlerinde de olduğu gibi iyi huylu (benign) ve kötü huylu (malign) olarak derecelendirilmektedir. Burada iyi huylu tümörler düşük dereceli yani nispeten daha yavaş büyüme gösteren ve tedavisi daha kolay şekilde yürütülen, kötü huylu tümörler ise daha yüksek dereceli, hızlı büyüme gösteren ve tedavisi uzun sürebilen hatta tekrarlama riski daha yüksek olan tümörlerdir (Türkiye Kanserle Savaş Vakfı, 2021). Şekil 1.1'de normal ve tümörlü dokulara sahip iki farklı MR (Manyetik rezonans) görüntüsü verilmiştir.

Beyinde oluşan tümörlerin tespit edilmesi için bir tarama işlemi yapılması gerekmektedir. Tarama işlemi BT (Bilgisayarlı Tomografi) ve MR (Manyetik Rezonans) görüntüleme şeklinde olabilmektedir (Türkiye Kanserle Savaş Vakfı, 2021). BT taramasında X ışınları kullanılırken MR görüntüleme taramasında manyetik alanlı radyo dalgaları kullanılmaktadır. BT taramasında kontrast sayısının fazla olması sayesinde dokular birbirinden ayrılarak su, ödem, hematoma gibi yapılar daha iyi görüntülenir. BT taramaları sonucunda lezyonların daha görünür hale getirilmesi için kontrast madde kullanılır, bu da hastanın bir miktar radyasyona maruz kalması


anlamına gelmektedir (Aydoğdu, Aydoğdu, & Yakıncı, 2017). MR görüntüsü ile organlar, yumuşak doku ve kemikler görüntülenebilir ve bu tip görüntülemeye X ışınları kullanılmaz. Görüntüsü alınmak istenen bölgeye radyo frekans teller (coil) yerleştirilir ve bu yöntemle vücuttaki su moleküllerindeki değişiklikler bilgisayarlar vasıtası ile görüntüye dönüştürülür (Aydoğdu vd., 2017).

Günümüzde tümörlü bölgeleri görüntülemeye en yaygın olarak kullanılan yöntem MR görüntüleme yöntemidir. Ancak tek başına MR görüntüsü alınarak beyindeki tümörün yapısı ve türü hakkında tam anlamıyla bilgi sahibi olmak mümkün değildir. Bu konuda doktorlar MR görüntüsünü inceleyip analiz ederek hastalığın teşhisini yaparlar ve daha sonrasında ameliyat, radyoterapi veya kemoterapi tedavileri hastaya uygulanır (Dandıl, 2015).



Şekil 1.1. Tümörsüz ve Tümörlü beyin MR görüntüsü

MR görüntülerinin analizinin başarımı insan gözünün görme yeteneği ve doktorun deneyimleri ile sınırlıdır. Ayrıca, beyin tümörlerinin farklı şekil ve büyüklüklere sahip olması tümörlerin tespitini zorlaştıran diğer bir faktördür. Beyin tümörleri sınıflandırılırken MR görüntüleri uzman doktorlar tarafından dikkatli bir şekilde incelenir ve en düşük hata payıyla teşhis edilir. Literatürde en sık rastlanan beyin tümörleri Şekil 1.2 de gösterilen Glioma, Meningioma ve Pituitary gibi tümörlerdir.



Şekil 1.2. (A) Glioma, (B) Meningioma, (C) Pituitary Tumor MR Görüntüleri

Doktorların herhangi bir beyin MR görüntüsünde yer alan tümörlü bölgeyi tespit etme işlemi oldukça hassas bir işlem olduğu için bu işlemi en az hata ile gerçekleştirebilmeleri gerekmektedir. Bu noktada, uzman doktorların en düşük hata payıyla tümörlü bölge çıkarımı yapabilmeleri için çeşitli uzman sistemler ve karar destek sistemleri geliştirilmiştir. Gerçekleştirilen birçok uygulamada görüntü işleme algoritmaları ve derin öğrenme modelleri kullanılmıştır. Evrimsel Sinir Ağları (CNN) gibi tekniklerin, 2D ve 3D medikal görüntülerin segmentasyonunda oldukça etkili olduğu kanıtlanmıştır (Daimary vd., 2019). MR görüntülerinden ilgili özelliklerin çıkarılmasını en üst düzeye çıkarmak için Naceur vd. (2020), CNN modelini geliştirmek için seçici bir yöntem kullanılmıştır. Bu yaklaşım, bir görüntüdeki önemli nesneleri bulmak için ardışık katmanlarda değişen alan boyutları kullanır. Sağlanan modelin, bir radyoloğun yüzde 74 ila 85'lik puanına kıyasla, tüm tümör için 0,90, tümör çekirdeği için 0,83 ve iyileştirme bölgeleri için 0,83'lük bir ortalama Dice katsayısı puanı vardı. Çalışmanın öne çıkan özelliklerinden biri, önerilen modelin tüm beyni 12 saniyede doğru ve güvenilir bir şekilde segmentlere ayırabilmesidir. Zeineldin vd. (2020) gerçekleştirdikleri çalışmada, UNet, SegNet ve ResNet'in, görüntü bölütleme için en popüler CNN modelleri olduğunu ortaya koymuşlardır. Bu modellerin standart CNN'lerin hızını ve performansını önemli ölçüde artırdığını göstermişlerdir. Shehab vd. (2020), 2020 yılında yaptıkları araştırmada, Derin Sinir Ağlarındaki (DNN) gradyan sorununu çözmek için ResNet modeli kullanılmıştır. ResNet, CNN katmanlarına paralel bir kısayol baypas bağlantısı sunarak eğitim hızı ve doğruluğu açısından benzer DNN'lerden daha iyi performans gösterdi. BraTS2015 veri seti üzerinde yapılan deneylerin sonuçlarına göre, diğer DNN yaklaşımlarına göre ortalama hesaplama süresini 3 kat artırır ve tüm, çekirdek ve gelişen bölgelerde sırasıyla %83, %90, %85 doğruluk oranına sahiptir. Tümör segmentasyonunu geliştirmek için, Alqazzaz vd. (2019) SegNet performansını

değerlendirdi. Çalışmanın performansı, çeşitli tümör alanları için 0.85, 0.81 ve 0.79 değerleri veren F-ölçü puanları kullanılarak analiz edildi. UNet ise SegNet'e benzer yapılara sahip bir başka etkili biyomedikal görüntü bölütleme modelidir. UNeT tasarımı, başarılı bir kodlayıcı-kod çözücü ağıdır (Ronneberger vd., 2015). Daha kesin segmentasyon sağlamak ve daha az eğitim seti ile çalışmak için tamamen bağlı katmanı değiştirerek oluşturulmuş bir mimaridir. Dong vd. (2017), UNet modelinin zar katsayısı açısından performansını değerlendirmek için BraTS2015 veri kümesinden 2B görüntüler kullandı. Çalışma, tüm, çekirdek ve kontrast oluşturan tümör alanları için sırasıyla HGG için 0.88, 0.87 ve 0.81 ve LGG için 0.84 ve 0.85 elde edildiğini keşfetmişlerdir.

Derin öğrenme modelleri görüntü segmentasyonu çalışmalarında başarılı sonuçlar vermiştir. Ancak bu başarımlar kullanılan veri seti içerisindeki veri sayısı ile sınırlıdır. Barbedo (2018) yaptığı çalışmada, derin öğrenme modellerinin performansını arttırmada veri seti boyutunun önemli bir rol oynadığını göstermiştir. Ayrıca, Dawson vd. (2023) 9 farklı derin öğrenme modeli üzerinde veri boyutunun önemini kanıtlarken, daha küçük veri kümeleri üzerinde gerçekleştirilen train sürecinde modellerin overfit olma eğiliminde olduğunu da ifade etmiştir. Bir başka çalışmada ise Fang vd. (2019) farklı sayıda baş ve boyun kanseri görüntülerini içeren bir veri seti hazırlamış ve segmentasyon deneylerini tekrarlamıştır. Çalışmada 200 hasta değerlendirme verisi olarak seçilmiştir. Kalan 960 hasta arasından ise rasgele seçilen 200, 400, 600 ve 800 veri eğitim amaçlı kullanılmıştır. Eğitilen tüm DL modellerinde aynı structure ve hype-parameterler kullanılmıştır. Çalışma sonucunda tüm modeller için en yüksek dice coefficient score 800 veri ile eğitilen modellerde elde edilmiştir.

Yeterli veriye ulaşamamanın en büyük sorunlarından birisi gerçek dünyada veri toplamanın zahmetli olması ve sonrasındaki etiketlenme sürecinde farklı disiplinlerden kişileri gerektirmesidir. Örnek olarak, gerçek bir hastane ortamında MR görüntü verisi toplama aşamasında karşılaşılan sorunlar; çok farklı tümör çeşidinin olması, aynı lokasyonda yaşan benzer hastalığa sahip kişi sayısının az olması, ya da görüntüleme sırasında standart bir görüntü kalitesinin yakalanamaması gibi nedenler bulunabilmektedir. Bu nedenle, çalışmalar daha çok benchmark veri setleri üzerinde gerçekleştirilmektedir. ImageNet, CIFAR10/100, PASCAL VOC, MS COCO ve BRaTS bu verisetlerine örnek olarak verilebilir. Ancak, bu veri setleri de

incelendiğinde veri kümesi içerisindeki MR görüntü sayısının, yüksek başarımlı sağlayacak bir DL modeli için sınırlı olduğu görülmektedir.

Goodfellow vd. (2014) elde edilmesi zor olan görüntülerin üretilmesine yardımcı olmak için GAN mimarisini önermiştir. GAN mimarisi verilerdeki özellikleri belirleme yeteneğinin yanında orijinaline benzeyen tamamen yeni veri kümeleri de oluşturabilmesi ile sentetik veri üretme konusunda ana akım bir algoritma haline gelmiştir (Carreon vd., 2023). DCGAN, LSGAN, InfoGAN ve CGAN randomly distributed noise'den bir görüntü oluşturan tipik GAN modelleridir (Liu vd., 2023). Literatürde GAN modelleri, akciğer lezyonu sınıflandırması (Frid-Adar vd., 2018), cilt lezyonu segmentasyonu (Pollastri vd., 2018) ve akciğer görüntülerini kullanarak COVID-19 teşhisi (Ali ve Shah, 2022) için sentetik tıbbi görüntüler oluşturmak için kullanılmıştır. Kazuhiro vd. (2018), beyin MR görüntülerinin GAN yöntemiyle çoğaltılması konusunda çalışmışlardır. Çalışmada DCGAN yöntemi, T1 ağırlıklı görüntülerden bir eğitim veri seti oluşturarak yeni sentetik beyin görüntüleri üretmek için kullanılmıştır. Görüntülerin DCGAN tarafından oluşturulmuş veya edinilmiş olma olasılığı, gerçek ve oluşturulmuş görüntüleri belirlemek için 5 radyolog tarafından ikili bir şekilde değerlendirilmiştir. Sonuç olarak DCGAN ile üretilen MR görüntülerinin gerçekçi olduğu ve veri setinin büyütülmesinde kullanılabileceği sonucuna varılmıştır (Kazuhiro vd., 2018).

Gerçekleştirilen tez çalışmasında doktorların, MR görüntülerindeki beyin tümörünün bulunduğu bölge veya bölgeleri daha doğru ve gerçekçi bir şekilde tespit edebilmesini sağlayabilen ve bunu çeşitli modellerin sonuçlarında da ortaya koyan bir yöntemin geliştirilmesi amaçlanmıştır. Bu yöntemde kullanılacak MR görüntülerine ait veriler, "Multimodal Brain Tumor Segmentation Challenge" olarak bilinen BraTS 2018 veri setinden elde edilmiştir. Bu veri seti üç boyutlu beyin MR görüntüleri ile bu görüntülerdeki bütün tümörlü bölgelerin etiketlendiği farklı görüntülerden meydana gelmektedir.

BraTS2018 eğitim veri seti, 210 High Grade Glioma (HGG), 75 Low Grade Glioma (LGG) olmak üzere toplamda 285 adet her biri dört farklı sekansa (T1, T1c, T2, FLAIR) sahip 3 boyutlu MR görüntüsü içermektedir. Her sekans içerisinde 240x240 boyutunda 155 katmandan oluşan görüntü bulunur. Veri setinde, uzmanlar tarafından

etiketlenmiş 240x240 boyutunda 155 katmandan oluşan bölütlemesi yapılmış görüntülerin yanında, bölütlemesi yapılmamış 66 adet aynı sekanslara sahip test verileri de yer almaktadır. Test verileri, eğitilen sinir ağı modelinin tümörlü bölgeyi ne kadar doğrulukla tespit edebildiğini araştırmak için kullanılmaktadır.

Yapılan tez çalışmasında, T1, T1c, T2 ve FLAIR sekansları incelenmiştir. Ancak tüm sekansların kullanılması durumunda veri boyutu büyümekte ve model eğitimleri sırasında yaşanan gecikme artmaktadır. Bu nedenle, beyin tümörünün bölütlenmesi çalışmalarında tercih edilen ve başarılı sonuçlar veren FLAIR sekansına ait MR görüntüleri tez kapsamında seçilmiş ve ön işleme adımlarından geçirilerek iki boyutlu hale getirilmiştir. Elde edilen beyin MR görüntüleri ve bunlara ait tümörlü bölgelerin işaretlenmesinden oluşan 210 örnek kullanılarak derin öğrenme modellerinin tümörlü bölge tespitindeki performansı araştırılmıştır.

Gerçekleştirilen çalışmanın ilk aşamasında veri setinden ayrıştırılan 210 hastaya ait görüntülerin, derin öğrenme modelleri kullanılarak bölütlemesi yapılmış ancak kesinlik ve başarımları eğitim ve test verilerinde oldukça düşük kalmıştır. Bu alanda yapılan çalışmalar incelendiğinde görüntü miktarının artırılması sayesinde kesinlik ve başarımlarının da artabileceği sonucundan yola çıkılarak veri setindeki görüntü miktarının çoğaltılması sağlanmıştır.

Görüntü verilerinin çoğaltılması işlemi, makine öğrenmesi alanında son yıllarda oldukça ilgi çeken bir alan olan Generative Adversarial Networks – Üretken Çekişmeli Ağlar (GAN) modeli kullanılarak gerçekleştirilmiştir (Goodfellow vd., 2014). Kullanılan GAN modeliyle Google Colab ortamında binlerce görüntü üretilmiş ve GAN modeli ile elde edilen bu görüntülerden uzman doktor yardımıyla 572 yeni MR görüntüsü belirlenmiştir.

Ortaya çıkartılan yeni MR görüntülerinin mevcut veri setine eklenebilmesi için bu görüntülerdeki tümörlü alanların önceki veri setindeki yapıya uygun olarak farklı bir görüntü dosyası olarak saklanması gerekmektedir. Bu noktada, üretilen 572 MR görüntüsündeki tümörlü bölgeler de K-Means Clustering – K-Ortalamlar Kümeleme yöntemi kullanılarak otomatik olarak ortaya çıkartılmıştır.

Bu tez çalışmasında, beyin tümörü vakalarında MR görüntülerine bakılarak tümörlü bölgenin tespit edilmesinde uzman doktora yardımcı olacak yapay zekâ destekli bir derin öğrenme uygulaması gerçekleştirilmiştir. Kullanılan bu uygulamanın MR görüntülerindeki tümörlü bölgelerin bölütlemesinin yapılmasında ve uzman doktora bu konuda yardımcı olmada faydalı olacağı düşünülmüştür. Uygulamanın geliştirilme aşamasında ayrıca literatürde yapılan çalışmalarda sıklıkla kullanılan veri setlerindeki verilerin yetersiz kalması noktası da ele alınarak mevcut veri setlerinin GAN yöntemleri kullanılarak büyütülebileceği ve bu sayede bilgisayar sistemleriyle tümörlü bölge tespitinin daha kesin bir şekilde yapılabileceği ortaya konmuştur.



2. KAYNAK ÖZETLERİ

Literatürde yapılan çalışmalar incelendiğinde, çalışmaların iki farklı yaklaşımla beyin tümörlerini araştırdığı görülmüştür; İlk yöntemde çalışmalar, beyin MR görüntüsü üzerinde tümörlü bölgenin tespitinin (bölütleme) yapılmasına odaklanırlarken, ikinci yöntemde görüntünün bir tümör içerip içermediğini (sınıflandırma) araştırmışlardır. Derin öğrenmenin biyomedikal alanında kullanımının artması sonucunda son zamanlarda 3 boyutlu beyin MR görüntülerinin işlenmesi, MR görüntüsünün bölütlenmesi ve semantik bölütleme konuları da ön plana çıkmıştır.

Mehta ve Arbel (2019) gerçekleştirdikleri çalışmada, Multi-modal beyin MR görüntülerinden beyin tümörü bölütleme gerçekleştiren 3 boyutlu Evrişimli Sinir Ağı modeli geliştirmişlerdir. Bu ağ modeli 3 boyutlu U-Net ağının düzenlenmesiyle ortaya çıkartılmıştır ve giriş katmanında multi-modal beyin MR görüntülerini kullanarak çoklu ölçeklerde işleyen, çıkış olarak tam çözünürlüklü çok sınıflı tümör bölütlemesi ortaya çıkartan bir modeldir. Çalışmada kullanılan ağın eğitilmesinde Brats 2018 veri setinden faydalanılmıştır. Bu ağ modeli ile, Brats 2018 test veri setinde tümör büyümesi, tam tümör ve tümör çekirdeğinin belirlenmesinde sırasıyla 0.706, 0.871 ve 0.771 Dice katsayısı değerleri elde edilmiştir (Mehta ve Arbel, 2019).

Mlynarski vd. (2019) gerçekleştirdikleri çalışmada, çok sekanslı MR görüntülerinde tümör bölütlemesi için etkili bir derin öğrenme yaklaşımı sunmuşlardır. Geliştirilen yöntem 2 boyutlu ve 3 boyutlu kaynakların avantajlarını birleştiren Konvolüsyonel Sinir Ağları (Convolutional Neural Networks - CNN) tabanlı bir modeldir. Ayrıca, eğitim aşamasındaki eksik MR sekansları sorununa daha dayanıklı olması için modaliteye özgü alt ağları olan bir ağ mimarisi önerisinde bulunmuşlardır. Sonuç olarak büyük CNN modellerinin eğitimi için etkili ve basit bir algoritma ortaya çıkarmışlar ve bu yöntemi Brats 2017 veri setinin kötü huylu beyin tümörlerinin çok sınıflı bölütlemesi üzerinde değerlendirmişlerdir. Kullanılan yöntem ile tam tümör için 0.918, tümör çekirdeği için 0.883 ve tümör büyümesi için 0.854 Dice katsayısı değerleri elde edilmiş ve algoritmanın oldukça başarılı sonuçlar verdiği görülmüştür (Mlynarski vd., 2019).

Dandıl (2015), yazmış olduđu doktora tez çalışmasında, hem Manyetik Rezonans (MR) hem de Manyetik Rezonans Spektroskopi (MRS) verilerini kullanarak radyologlara beyin tümörlerinin tespit edilmesinde yardımcı olabilecek bilgisayar destekli yaklaşımlar sunmuştur. Yapılan çalışma kapsamında geliştirilen yöntemlerden bir tanesi MR görüntüleri ile çalışmakta ve beyin tümörlerinin iyi veya kötü huylu olup olmadıkları konusunda görüntü işleme ve örüntü tanıma tekniklerini kullanarak doğru bir sınıflandırma yapılmasına yöneliktir. Çalışmada 188 MR görüntüsü üzerinde gerçekleştirilen işlemler sonucunda, önerilen yöntem ile beyin tümörlerinin iyi veya kötü huylu olması durumunu %96.81 oranında başarıyla tespit edebilmiştir (Dandıl, 2015).

Ronneberger vd. (2019), U-NET isimli çok katmanlı evrişimli sinir ağı modelinin biyomedikal teknolojilerinde çeşitli alanlarda kullanılabileceğini öne süren bir çalışma gerçekleştirmişlerdir. Bu çalışmada 3 farklı bölütleme işleminde U-NET mimarisiyle elde edilen sonuçlar karşılaştırılmıştır. Bölütleme işlemleri, elektron mikroskopuyla elde edilen nöronlar arası ilişki yapılarını içeren görüntüler, Uluslararası Biyomedikal Görüntüleme Sempozyumu (International Symposium on Biomedical Imaging - ISBI) 2014 ve 2015 hücre takibi veri setine ait görüntüler üzerinde gerçekleştirilmiş U-NET modelinin, biyomedikal görüntüleri üzerinde bölütleme işlemini başarıyla gerçekleştirdiği ortaya konulmuştur (Ronneberger vd., 2015).

Arı (2019), tamamladığı tez çalışmasında, Bilgisayar Destekli Otomatik Tespit Sistemi (BDOTS) tasarlayarak beyin tümörlerini derecelerine ve türlerine göre sınıflandırmayı başarmıştır. Gerçekleştirilen çalışmada BRATS 2015, REMBREDANT, HARVARD, RIDER, FIGSHARE ve AANLIB isimli 6 farklı veri tabanından veri setleri tercih edilmiştir. Bu veri tabanlarından elde edilen veriler ile 5 farklı uygulama geliştirilmiştir. Bu uygulamalardan iki tanesi beyin tümörü görüntüleri ile ilgili ön işlemleri kapsarken diğer üç tanesi ise Evrişimli Sinir Ağları, Bölgesel Evrişimli Sinir Ağları ve Derin Öğrenme Mimarileri ile beyin tümörlerinin MR görüntüsü üzerindeki yerini tespit etmek için tasarlanmıştır. Yapılan çalışmanın sonucunda elde edilen verilere göre tasarlanan sistemin literatürdeki benzer uygulamalara göre üstün olduğu görülmüştür (Arı, 2019).

Sajjad vd. (2019) yapmış oldukları çalışmada yeni bir evrişimli sinir ağı temelli çok dereceli beyin tümörü sınıflandırma sistemi önerisinde bulunmuşlardır. Yapılan bu çalışmada ilk olarak MR görüntülerindeki tümör bölgeleri bir derin öğrenme tekniği kullanılarak bölütlenmiş, daha sonra MR görüntüleriyle çok dereceli beyin tümörü sınıflandırmasını yapabilmek için az sayıdaki verinin farklı veri çoğaltma teknikleriyle çoğaltılması sağlanmıştır. Önerilen sistemde orijinal ve daha sonradan çoğaltılan veriler deneysel olarak değerlendirilmiş, sonuçlar mevcut yöntemlere kıyasla ikna edici bulunmuştur. Ayrıca veri artırma yönteminin beyin tümörü MR görüntülerinin eksikliğini gidermede ve evrişimli sinir ağlarında eğitim verisi aşamasında kullanılabileceği sonucuna varılmıştır (Sajjad vd., 2019).

Seetha ve Raja (2018) yapmış oldukları çalışmalarında, Evrişimli Sinir Ağlarını kullanarak otomatik beyin tümörü sınıflandırılmasını gerçekleştiren bir model önerisinde bulunmuşlardır. Çalışmada kullanılan beyin MR görüntüleri BRATS 2015 ve RadioPedia isimli veri setlerinden elde edilmiştir. Bu veri setlerindeki beyin MR görüntüleri tümörlü ve tümörsüz olmak üzere iki şekilde etiketlenmiş, önerilen otomatik beyin tümörü tespit sistemiyle MR görüntülerinin inceleme süresinde kaybedilen zamanın büyük bir kısmında tasarruf edildiği görülmüştür. Gerçekleştirilen çalışmadaki eğitim verisi kesinlik oranı %97.5 olarak ortaya çıkmıştır (Seetha ve Raja, 2018).

Dong vd. (2017) yapmış oldukları U-Net tabanlı tam evrişimli ağlar kullanarak otomatik beyin tümörü tespiti ve bölütlemesi çalışmalarıyla MR görüntüsü üzerinde beyin tümörünü doğru şekilde tespit etmeyi başarmışlardır. Beyin tümörünün boyutunun 3 boyutlu MR görüntülerinden tespiti çok zaman alıcı bir iş olduğundan bu işin süresi operatörün deneyimi ile ölçeklenebilmektedir. Yapılan çalışmada, tümör boyutunun etkili bir şekilde ölçülebilmesi için beyin tümörünün tam otomatik bölütleme yoluyla tespitini sağlamak gerektiğinden yola çıkılarak, U-Net tabanlı derin evrişimli ağlar kullanılarak geliştirilen tam otomatik beyin tümörü bölütlemesi yapabilen bir yöntem önerilmiştir. Önerilen yöntem, BRATS2015 veri setinden 220 yüksek dereceli, 54 düşük dereceli beyin tümörü vakası ile geliştirilmiş olup sonuç değerleri bu yöntemin umut vaat edici olarak, bölütleme işlemini verimli bir şekilde gerçekleştirdiğini göstermiştir (Dong vd., 2017).

Anitha ve Raja (2017) yapmış oldukları çalışmada, evrişimli sinir ağı kullanılarak görüntü füzyon temelli beyin tümörü tespit ve bölütlemesi metodolojisini önermişlerdir. Önerilen bu metodoloji, görüntü füzyonu, özellik çıkarma, sınıflandırma ve bölütlemeyi içermektedir. Çalışmada görüntü füzyonu için ayrık dalgacık dönüşümü kullanılmış ayrıca, glioma görüntülerinin sınıflandırılması için gri düzey birlikte oluşturma matrisi özellikleri çıkarılmış ve bu özellikler CNN sınıflandırıcısı beslemiştir. Çalışmanın sonucunda önerilen sistem %97 lik sınıflandırma başarısına ulaşmıştır (Anitha ve Siva Sundhara Raja, 2017).

Marcinkiewicz vd. (2019) yapmış oldukları çalışmada, yaygın beyin tümörlerinden Glioma'ların uzman yardımıyla çiziminin zaman ve uzman kişiye bağımlılığının yüksek olmasından dolayı MR görüntülerinden bölütleme ve tümör tespitini otomatik olarak gerçekleştiren bir yaklaşım ortaya koymuşlardır. Çoklu MR görüntülerinden faydalanarak beyin tümörü bölütlemesi yapan Derin öğrenme tabanlı bu yaklaşım iki aşamadan oluşmakta ve her iki aşamada da U-NET modelinden ilham alınarak geliştirilmiş tam evrişimli sinir ağı modeli kullanılmıştır. İlk aşama önemli bölgeleri tespit ederken, ikinci aşama çok sınıflı sınıflandırmayı gerçekleştirmektedir. Gerçekleştirilen çalışmada en güncel BRATS veri seti olan 2018 versiyonu kullanılmış ve bir örnek üzerinde yapılan bölütleme işlemi için geçen sürenin önerilen yöntem ile daha kısa sürede gerçekleştirildiği görülmüştür (Marcinkiewicz vd., 2019).

Havaei vd. (2017), "Brain Tumor Segmentation with Deep Neural Networks" başlığı ile yayınladıkları makalede, beş farklı derin öğrenme mimarisinin kullanıldığı bir beyin tümörü bölütleme yöntemi kullanmışlardır. Çalışmada, birinci dereceden evrişimsel ağlar (ConvNets), ikinci dereceden evrişimsel ağlar (ConvNets), tekrarlayan sinir ağları (RNN'ler), ResNet ve GoogLeNet kullanılarak beş farklı model oluşturulmuştur. Bu modellerin hepsi, üç boyutlu MR görüntülerinden otomatik olarak beyin tümörlerinin bölütlemesini gerçekleştirmek için eğitilmiş ve sonuç olarak sırasıyla %87.9, %88.6, %85.2, %89.8 ve %89.6 kesinlik oranlarını elde edilmiştir. Literatürdeki diğer çalışmalar incelendiğinde bu sonuçlar, derin öğrenme tekniklerinin beyin tümörü bölütlemesi için oldukça etkili olduğunu göstermektedir (Havaei vd., 2017).

Pereira vd. (2016), yaptıkları “Brain Tumor Segmentation Using Convolutional Neural Networks in MR Images” adlı çalışmalarında beyin tümörlerinin doğru bir şekilde tanımlanması ve sınıflandırılmasının, tedavi stratejilerini belirlemede önemli olduğunu ortaya koymuşlardır. Çalışmalarında, MR görüntülerinde beyin tümörlerinin bölütlemesi için bir evrişimli sinir ağı (CNN) yaklaşımı önermişlerdir. Geliştirdikleri yöntem, görüntüleri bölütlemek için VGG-16 modeli üzerinde eğitilmiş ve daha sonra bu model, BraTS 2013 veri seti kullanılarak test edilmiştir. Elde edilen sonuçlar, önerilen yöntemin diğer yöntemlere kıyasla daha yüksek bir kesinlik oranı ve daha düşük bir hata oranı elde ettiğini göstermiştir. Bu sonuçlara göre ortaya çıkarılan yöntem;

- BraTS 2013 veri setindeki görüntülerin bölütlemesi için başarılı bir şekilde kullanılabilmiş,
- Diğer yöntemlere kıyasla daha yüksek bir kesinlik oranı ve daha düşük bir hata oranı elde etmiş.
- Yöntemin geliştirilmesi, beyin tümörlerinin doğru bir şekilde tanımlanması ve sınıflandırılması için bir adım olarak önerilmiştir (Pereira, Pinto, Alves, & Silva, 2016).

Ayadi vd. "Deep CNN for Brain Tumor Classification" başlıklı makalelerinde, beyin tümörlerinin sınıflandırılması için bir derin sinir ağı kullanarak doğruluğu artırmayı amaçlamışlardır. Bu makalede kullanılan veri seti, farklı tümör tiplerini içeren 3064 beyin MR görüntüsünden oluşmaktadır. Çalışma aşamasında veri seti, 2664 görüntüyü eğitim için, 200 görüntüyü doğrulama için ve 200 görüntüyü test etmek için kullanılmak üzere üçe ayrılmıştır. Daha sonra, makalede, VGG-16 ve Inception-v3 gibi popüler mimarilerin performansları karşılaştırılmıştır. Sonuç olarak, araştırmacılar, bu problem için en iyi sonuçların elde edilmesi için özel olarak tasarlanan bir mimari olan "BraintumorNet" adlı bir ağ kullanmışlardır. Yapılan karşılaştırmaların sonucunda, BraintumorNet'in, diğer mimarilere kıyasla daha iyi performans gösterdiği ve kesinlik oranının %97.5 olduğu ortaya çıkartılmıştır (Ayadi vd., 2021).

Yurtsever (2019) tamamladığı tez çalışmasında, derin öğrenme yöntemiyle kolon kanseri tespiti için bir yaklaşım ortaya koymuştur. Çalışmada kullanılan veri setindeki görüntüler geliştirilmiş k-ortalamar algoritması ile bölütlenmiştir. Bölütlenmiş

görüntüler ve ham veri setindeki görüntüler GoogLeNet ve AlexNet evrişimli sinir ağı modelleriyle eğitilerek test edilmiştir. Test sonuçlarına göre bölütlenmiş görüntülerin kullanıldığı AlexNet modelinin performansında %2 ile %23 arasında bir performans artışı sağlanmış, aynı görüntüler ile GoogLeNet modelinin performansında da %2 ile %27 arasında bir performans artışı sağlanmıştır (Yurtsever, 2019).

Eker ve Duru (2021), yayınlanan Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları başlıklı makalelerinde, medikal görüntülerin derin öğrenme yöntemleri ile işlenmesi konusunu incelemişlerdir. Yapılan çalışmada makine öğrenmesi ile bölütleme, sınıflandırma ve hastalık teşhisi, görüntü oluşturma, dönüştürme ve iyileştirme alanları araştırılarak bu alanlarda kullanılan algoritmalar incelenmiştir. Çalışmanın bir bölümünde BraTS 2020 veri seti üzerinde derin öğrenme ile beyin tümör bölütlemesi gerçekleştirme işlemleri denenmiş, sonuç olarak %86 dice benzerlik oranı ve %80 hassasiyet değeri elde edilmiştir. Bu çalışma, medikal görüntüler üzerinde derin öğrenme yöntemleri kullanılarak yapılacak farklı çalışmalara yol göstermesi amacıyla hazırlanmıştır (Eker ve Duru, 2021).

Mzoughi vd. (2020) yaptıkları makalede, 3D MR görüntüleme verilerini kullanarak, glioma beyin tümörlerinin otomatik olarak sınıflandırılmasını amaçlamışlardır. Bu makalede önerilen yöntem, 3D evrişimsel sinir ağı (CNN) mimarisi kullanmakta ve MR görüntülerindeki yerel ve global bağlamsal bilgiyi birleştirmektedir. Gerçekleştirilen çalışmada ön işleme tekniği olarak, MR görüntülerindeki yoğunluk normalizasyonu ve adaptif kontrast artırma kullanılmıştır. Ayrıca, daha etkili bir eğitim için veri artırma teknikleri de kullanılmıştır. Çalışma, Brats-2018 veri seti üzerinde gerçekleştirilmiş ve önerilen yöntemin, 2D CNN varyantına göre daha iyi sonuçlar verdiği tespit edilmiştir. Önerilen yöntem, düşük dereceli gliomalar (LGG) ve yüksek dereceli gliomalar (HGG) arasında ayırım yapmak için en ayırmacı özellik haritasını oluşturmuştur ve kesinlik oranı %96.49 olarak belirlenmiştir. Elde edilen sonuçlar, önerilen yöntemin güncel denetimli ve denetimsiz yöntemlere göre daha iyi performans gösterdiğini göstermektedir (Mzoughi vd., 2020).

Demir vd. 2023 yılındaki “3D MR görüntülerinden 3ACL adlı yeni derin öğrenme modeline dayalı etkili bir yaklaşımla beyin tümörü sınıflandırma performansının iyileştirilmesi” başlıklı çalışmalarında doğrudan 3 boyutlu MR görüntülerinin

kullanıldığı farklı bir derin öğrenme modeli ortaya koymuşlardır. 3ACL adını verdikleri bu modelde 3 boyutlu MR görüntülerindeki T1, T1gd, T2, FLAIR sekansları kullanılarak öznitelikler çıkartılmıştır. Bu sayede özniteliklerin temsil gücü artırılmış ve 3ACL modelinin tam bağlantı katmanından yüksek dereceli derin özellikler çıkarılmıştır. Özelliklerin bulunduğu veri seti SVM algoritması kullanılarak değerlendirilmiştir. Bu aşamada üç boyutlu görüntüleri oluşturan tüm görüntü katmanlarından iletilen SVM tahmin sonuçlarını kullanan ağırlıklı ortalamalar algoritması ile sınıflandırma başarısını arttırmışlardır. Yapılan çalışmada BRATS 2015 ve 2018 veri setleri için çalışmada önerilen yaklaşımla %98.90 ve %99.29 kesinlik değerlerine sahip olmuştur (Demir vd., 2023).

Literatürde üzerinde çalışılan birkaç GAN tabanlı görüntü verisi büyütme tekniği vardır (Zhao vd., 2020). Bu tekniklerin, görüntü sentezi için sınıflandırıcıların ve GAN modellerinin doğruluğunu ve sağlamlığını geliştirdiği gösterilmiştir. GAN modelleri ile, karaciğer lezyonu sınıflandırması (Frid- vd., 2018), cilt lezyonu bölütlemesi (Pollastri vd., 2018) ve akciğer görüntülerini kullanarak COVID-19 teşhisi (Ali ve Shah, 2022) için sentetik tıbbi görüntüler oluşturmak için kullanılmıştır.

Gerçekleştirilen çalışmalar incelendiğinde kullanılan veri setlerinin dünya genelinde yapılan çalışmalarda kabul görmüş hazır veri setleri olduğu ve hazırlanan tez çalışmasında da kullanılan veri setinin bu çalışmalarda büyük oranda tercih edildiği görülmektedir. Bu alanda gerçekleştirilen çalışmaların amacı veri setlerinde yer alan MR görüntülerindeki tümörlü bölgelerin derin öğrenme modelleri kullanılarak bilgisayar destekli olarak tespit edilmesini sağlamaktır. Bu amaç doğrultusunda yapılan çalışmalarda kullanılan derin öğrenme modelleri biyomedikal alanında derin öğrenme uygulamalarında ve bölütleme işlemlerinde sıklıkla tercih edilen U-Net modeli ve bu modelden geliştirilmiş farklı derin öğrenme modelleri tercih edilmiştir. Çalışmalarda ayrıca ResNet, VGG16, VGG19, AlexNet, GoogleNet gibi derin mimariler de tercih edilerek bölütleme performanslarının karşılaştırması yapılmıştır.

Beyin tümörlerinin MR görüntüleri üzerindeki bölgelerinin tespiti konusunda yapılan çalışmalardaki genel problem veri setindeki MR görüntülerinin yetersiz kalması ve bu nedenle derin öğrenme modellerinin bölütleme performanslarının yetersiz kalmasıdır. Bu nedenle incelenen çalışmaların bazılarında farklı veri setlerindeki MR görüntüleri


birleřtirilerek veya g r nt  iřleme y ntemleri kullanarak eldeki g r nt  miktarı arttırılmaya  alıřılmış ve b ylece kullanılan derin  ğrenme modellerinin MR g r nt lerinden t m rl  b lgelerin tespitindeki performanslarının arttırılması saėlanmıřtır.

 alıřmalardaki veri yetersizliėi konusunun t m rl  b lge tespitindeki en  nemli noktalardan birisi olması ve veri  oėaltma y ntemlerinin basit bir řekilde uygulanması nedeniyle hazırlanan tez  alıřmasında, kullanılan veri setindeki MR g r nt s  miktarının arttırılması konusu da incelenmiř ve bu konuda derin  ğrenme y ntemiyle g r nt   retme konusunda olduk a bařarılı sonu lar veren GAN modelleri kullanılmıřtır. Ayrıca GAN modelleri ile elde edilen sentetik MR g r nt lerindeki t m rl  b lgeler de K-ortalamalar algoritması yardımıyla ortaya  ıkartılarak veri setine eklenebilecek bir yapıya d n řt r lm řt r.

3. MATERYAL ve YÖNTEM

3.1. Beyin Tümörü

Beyin ve omurilik (merkezi sinir sistemi veya MSS olarak da bilinir) tümörleri, iyi huylu veya kötü huylu olabilir. Birincil merkezi sinir sistemi (MSS) tümörleri, beyinde veya omurilikte başlar. Her yıl yaklaşık 79.000 kişi bir birincil MSS tümörü tanısı alır ve yaklaşık 24.000'ü kötü huyludur (National Cancer Institute, 2023).



Şekil 3.1. Yüksek dereceli Glioma tümörüne sahip beyin MR görüntüleri

Merkezi sinir sistemi tümörlerinin derecelendirilmesi aşamasında, tümör dokusunun mikroskop altında nasıl görüldüğüne ve bazen tümörde bulunabilen belirli genetik değişikliklere bakılır. Merkezi sinir sistemi tümörleri, WHO (World Health Organization) kriterlerine göre I. dereceden IV. dereceye kadar sınıflandırılmıştır. Bazı tümörler düşük dereceli tümörlerdir (I. ve II. derece), diğerleri yüksek dereceli (III. ve IV. derece) tümörlerdir. III ve IV üncü derecedeki tümörler yüksek dereceli glioma (High Grade Glioma - HGG) olarak adlandırılırken, I ve II nci derecedeki tümörler düşük dereceli glioma (Low Grade Glioma - LGG) olarak adlandırılır (Chen vd., 2020). Şekil 3.1'de yüksek dereceli glioma tümörlerinin beyin MR görüntülerindeki örnekleri görülmektedir.

Merkezi sinir sistemi tümörü olan kişiler genellikle görüntüleme prosedürleri ile izlenirler. Bunlardan en yaygın olanları MR görüntüleme ve özel bir MR türü olan spektroskopidir. Bunların yanında bazen BT taramaları ve pozitron emisyon tomografisi (Positron Emission Tomography - PET) de kullanılır (National Cancer Institute, 2021).


MR, yumuşak dokularda iyi bir şekilde kontrast sağladığı için kliniklerde yaygın olarak kullanılan bir yöntemdir (Liang ve Lauterbur, 1999). T1, T2, T2c ve FLAIR MR görüntüsü sekansları özellikle glioma tümörlerini tespit edebilmek ve klinik

uygulamada tedavinin başarısını değerlendirmek için oldukça faydalıdır (Bauer vd., 2013).

3.2.Kullanılan Veri Seti


Medikal görüntüler üzerinde çalışma yapabilmek için ilk etapta genellikle hazır veri setleri tercih edilmektedir (Chen vd., 2020). Hazır veri setleri dünya üzerindeki üniversitelerde çeşitli uzmanlar tarafından görüntülerin etiketlenilmesi tamamlandıktan sonra araştırmacılara sunulmakta ve belirtilen alanda yarışmalar düzenlenmektedir. Bunlardan bir tanesi de “Multimodal Brain Tumor Segmentation Challenge” olarak bilinen BraTS veri setidir. BRATS MR taramalarındaki beyin tümörü bölütlemesi algoritmalarının değerlendirilmesi ve beyin MR taramalarında tümör bölgelerini doğru bir şekilde bölütlemek için makine öğrenmesi algoritmalarının geliştirilmesi için kullanılan halka açık bir veri setidir. BRATS’ın 2018 sürümü, yüksek dereceli gliomlar ve düşük dereceli gliomlar dahil olmak üzere 285 hastaya ait MR taramalarını içermektedir. Taramalar, T1-ağırlıklı (T1), T1-ağırlıklı kontrast artırılmış (T1Gd), T2-ağırlıklı (T2) ve T2-Fluid Attenuated Inversion Recovery (FLAIR) olmak üzere 4 farklı sekansadır. Her tarama, uzman tarafından sağlanan tümör bölütlemesi için zemin gerçeklik verilerini de içermektedir. Yani her MR görüntüsünde tümörlü bölgeler etiketlenerek veri setine ayrıca eklenmiştir.

Veri kümesi, eğitim ve doğrulama kümeleri halinde düzenlenmiştir. Eğitim setinde 285 hasta için MR görüntülerine ait taramalar ve açıklamaları bulunurken, doğrulama seti 66 hasta için MR görüntülerine ait taramaları ve açıklamaları içerir. Her hastanın taramasına ilişkin notlar, tıbbi görüntü analizi için yaygın bir format olan Nörogörüntüleme Bilişim Teknolojisi Girişimi (Neuroimaging Informatics Technology Initiative - NIfTI) formatında ayrı bir dosya ile sağlanır. Bu dosyalarda her sekans için 240x240 piksel boyutunda 155 katmandan oluşan görüntüler yer almaktadır. Gerçekleştirilen çalışmada tümörlü alanların daha net ve belirgin şekilde gösterildiği için literatürdeki çalışmalarda da sıklıkla kullanılan FLAIR sekansına ait görüntüler tercih edilmiştir. Şekil 3.2’de herhangi bir hastaya ait bütün sekanslardaki MR görüntülerinin taramasına ait örnek katmanlar gösterilmiştir. Buradan da görüldüğü gibi FLAIR sekansındaki MR görüntülerindeki tümörlü bölge ve diğer katmanlar daha net şekilde gözlemlenmektedir.



Şekil 3.2. Tüm sekanslara ait MR görüntülerine ait katmanlardan bazıları

Şekil 3.3'te ise yine herhangi bir hastaya ait MR görüntüsü taramalarından, uzman tarafından etiketlenmiş ya da MR görüntüsü üzerinde bölütlemesi yapılmış görüntünün katmanlarından bazıları görülmektedir.



Şekil 3.3. Herhangi bir hastaya ait MR görüntüsündeki işaretlenen tümörlü bölgenin katmanları

BRATS 2018 veri seti, MR görüntüsü taramalarının önceden işlenmiş sürümleri ve makine öğrenimi algoritmalarına girdi olarak kullanılabilecek özellik haritaları gibi ek verileri de içerir. Genel olarak veri seti, MR görüntüsü taramalarında beyin tümörü bölütlemesi için algoritmaları değerlendirmek için kapsamlı ve standartlaştırılmış bir kıyaslama sağlayacak şekilde yapılandırılmıştır.

3.3.Makine Öğrenmesi

Makine Öğrenmesi, makinelere verilerden, kalıplardan ve deneyimlerden öğretmeyi içeren Yapay Zekanın bir alt alanıdır. Makine Öğreniminin birincil amacı, makinelerin örneklerden öğrenerek belirli görevlerdeki performanslarını geliştirmelerini sağlamaktır.

Üç ana Makine Öğrenimi türü vardır: denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme. Denetimli öğrenme, etiketlenmiş verilerden öğrenmeyi ve bu bilgiyi yeni, görünmeyen veriler hakkında tahminler yapmak veya kararlar almak için kullanmayı içerir. Denetimsiz öğrenme, etiketlenmemiş verilerden öğrenmeyi ve verilerdeki kalıpları ve ilişkileri bulmayı içerir. Takviyeli öğrenme, bir ödülü en üst düzeye çıkarmak için bir dizi eylemden ve geri bildirimden öğrenmeyi içerir (Russell vd., 2003).

Makine Öğrenimi algoritmaları, doğal dil işleme, bilgisayar görüşü, dolandırıcılık tespiti, öneri sistemleri, otonom araçlar ve daha fazlasını içeren çok çeşitli uygulamalarda kullanılır. Bazı popüler Makine Öğrenimi algoritmaları arasında karar ağaçları, sinir ağları, destek vektör makineleri, k-ortalama kümeleme ve rastgele orman algoritmaları bulunur.

Makine Öğrenimi hızla büyüyen bir alandır ve yaşama ve çalışma şeklimizde devrim yaratma potansiyeline sahiptir. Ancak, Makine Öğrenimi modellerinin etik ve sorumlu bir şekilde geliştirilmesini ve kullanılmasını sağlamak önemlidir.


3.4.Yapay Sinir Ağları

Yapay sinir ağları, biyolojik sinir sistemlerinden esinlenerek tasarlanan bir makine öğrenmesi yöntemidir. Yapay sinir ağları, çok katmanlı ağlarda nöronlar ve sinapslar

aracılığıyla bilgiyi işler. Bu nöronlar, girdi verilerini işler, işlem yaparak belirli bir sonuç üretir ve sonuçları belirli bir çıktıya bağlar.

Yapay sinir ağları teşhis, sınıflandırma, tahmin, kontrol, veri ilişkilendirme, veri filtreleme, yorumlama gibi alanlarda kullanılmaktadır. Günümüzdeki kullanım alanları incelendiğinde geniş çaplı bir uygulama alanına sahip olduğu görülmektedir. Bankacılık sektöründe kredi derecelendirme, bilgisayarla görü alanında görüntü işleme ve nesne tanıma, biyomedikal alanında tümör tespiti ve DNA dizilimi, enerji alanında fiyat ve yük tahmini, lojistik alanında ürün stok tahmini ve dağıtımı konularında oldukça verimli sonuçlar elde edilmiştir.

Yapay sinir ağları Şekil 3.4'te de görüldüğü gibi Girdi Katmanı, Gizli Katman ve Çıktı Katmanı olmak üzere üç ana katmandan oluşmaktadır. Gizli katman sayısı problemin türüne göre arttırılabilir. Bu durumdaki yapay sinir ağları çok katmanlı yapay sinir ağı olarak kullanılır ve çok katmanlı yapay sinir ağları karmaşık problemlerin çözümünde tercih edilirler ve birden çok girdi ve gizli katmana sahip olabilirler.



Şekil 3.4. Tek Katmanlı Standart Yapay Sinir Ağı Modeli

Yapay sinir ağları öğrenme algoritması ve aktivasyon fonksiyonu olmak üzere iki bileşenden oluşur. Öğrenme algoritması, yapay sinir ağlarının eğitilmesinde önemli bir yere sahiptir. Yapay sinir ağının eğitilmesi, aynı zamanda hesaplanan ağırlık değerlerinden en uygun olanının bulunması anlamına gelmektedir. Yani yapay sinir ağında hesaplanan ağırlık değerleri en uygun değere sahip olduğunda ağın eğitimi de tamamlanmış olur. Bu noktada eğitim işlemini öğrenme algoritmaları gerçekleştirmektedir.

Basit bir yapay sinir ağında x girdileri, w ağırlıkları temsil eder ve nöronların çıktılarını üretmek için de aktivasyon fonksiyonları kullanılır. Daha sonra nöronlardan Denklem 3.1'deki gibi aktivasyon fonksiyonu ile elde edilen değerler yapay sinir ağının diğer katmanlarının giriş değeri olarak hesaplanarak kullanılırlar (Kızrak A. , 2019).

$$f\left(\sum_i w_i x_i + b\right) \quad (3.1.)$$

Bu denklemde, nöronların girdi özelliklerinin ağırlıklı toplamaları ($w_0x_0 + w_1x_1 + w_2x_2 \dots + w_nx_n$) ve bias değeri toplanarak hesaplanır ve sonuç aktivasyon fonksiyonu olan f fonksiyonundan geçirilir.

3.4.1. Aktivasyon fonksiyonları

Yapay sinir ağlarında her bir nöronun çıktısı, aktivasyon fonksiyonu tarafından hesaplanan bir değerdir. Aktivasyon fonksiyonları, yapay sinir ağlarının en önemli bileşenlerinden biridir. Bu fonksiyonların seçimi, sinir ağının performansını ve öğrenme hızını etkileyebilir.


Yapay sinir ağlarında kullanılan temel aktivasyon fonksiyonları şunlardır:

- Doğrusal fonksiyon
- Sigmoid fonksiyonu
- Tanh fonksiyonu
- ReLU fonksiyonu
- Leaky ReLU fonksiyonu
- Softmax fonksiyonu

3.4.1.1. Doğrusal fonksiyon

$$f(x) = x \quad (3.2.)$$

Doğrusal (Lineer) fonksiyon Denklem 3.2’de görüldüğü gibi ifade edilir. Bu fonksiyonda giriş değeri hiçbir değişikliğe uğramadan çıkış değerini verir. Doğrusal problemlerin çözümünde tercih edilir. Doğrusal fonksiyona ait grafik Şekil 3.5’te gösterildiği gibidir.




Şekil 3.5. Doğrusal fonksiyona ait grafik

3.4.1.2. Sigmoid fonksiyonu:

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

Sigmoid fonksiyonun matematiksel ifade şekli Denklem 3.3'teki gibidir. En yaygın kullanılan aktivasyon fonksiyonlarından birisidir, giriş değerleri $-\infty, +\infty$ arasında olsa bile daima $[0,1]$ aralığında çıktı üretir. Doğrusal olmayan problemlerin çözümünde tercih edilen bir aktivasyon fonksiyonudur. Sigmoid fonksiyonunun grafiği Şekil 3.6'da gösterildiği gibidir.




Şekil 3.6. Sigmoid fonksiyonu grafiği

3.4.1.3. Tanh fonksiyonu:

$$f(x) = \frac{2}{(1 + e^{-2x})} - 1 \quad (3.4.)$$

Sigmoid fonksiyonunun bir benzeridir, Denklem 3.4'teki fonksiyon ile hesaplanır. Fakat $[-1, +1]$ aralığında doğrusal olmayan çıktılar üretir. Sigmoid fonksiyonundan daha avantajlı olmasının sebebi daha geniş bir veri aralığında çıktılar üretmesidir. Tanh fonksiyonunun grafiği Şekil 3.7'de gösterildiği gibidir.




Şekil 3.7. tanh fonksiyonu grafiği

3.4.1.4. ReLU fonksiyonu:

$$f(x) = \max(0, x) \quad (3.5.)$$

Doğrultulmuş lineer birim (rectified linear unit- RELU) doğrusal olmayan bir fonksiyondur. Fonksiyonu, Denklem 3.5'te gösterildiği gibi yazılır ReLU fonksiyonu negatif girdiler için 0 değerini alırken, x'in pozitif değerleri için x değerini almaktadır. ReLU fonksiyonunun grafiği Şekil 3.8'deki gibidir.




Şekil 3.8. ReLU fonksiyonu grafiği

3.4.1.5. Leaky ReLU fonksiyonu:

$$f(x) = \max(0, 0.01x, x) \quad (3.6.)$$

Bu fonksiyon, ReLU fonksiyonuna benzer ancak negatif girdiler için küçük bir eğim ekleyerek daha iyi sonuçlar verir. Denklem 3.6'daki gibi yazılır. Sigmoid veya tanh gibi diğer aktivasyon fonksiyonlarından daha hızlı hesaplanabilir ve aynı zamanda daha iyi sonuçlar verir. Leaky ReLU fonksiyonunun grafiği Şekil 3.9'da gösterildiği gibidir.




Şekil 3.9. leaky ReLU fonksiyonu grafiği

3.4.1.6. Softmax fonksiyonu:

$$S(x_i) = \frac{e^{x_i}}{\sum_{j=1}^K e^{x_j}} \quad (3.7.)$$

Denklem 3.7'deki çoklu sınıflandırma problemleri için kullanılan bu fonksiyon, verilen her bir girdinin bir sınıfa ait olma olasılığını gösteren $[0,1]$ arası çıktılar üretmektedir. Özellikle derin öğrenme modellerinin çıktı katmanında tercih edilir. Softmax fonksiyonunun grafiği Şekil 3.10'da gösterildiği gibidir.



Şekil 3.10. Softmax fonksiyonu grafiği

3.5. Derin Öğrenme

Derin Öğrenme (DÖ), insan beynini taklit ederek öğrenmeyi amaçlayan makine öğrenmesi alt dallarından bir tanesidir. DÖ çok katmanlı sinir ağları yapısını kullanarak özellik çıkarımına dayalı bir algoritma yapısına sahiptir. Bu sayede çok büyük boyutlardaki verilerle işlemler gerçekleştirebilmekte ve bu verilerden daha önce ortaya çıkartılmamış özelliklerde sonuçlar elde etmeye olanak sağlamaktadır (LeCun vd., 2015).

Geleneksel makine öğrenmesi teknikleri, veri özniteliklerini manuel olarak ayarlamayı gerektirirken, derin öğrenme teknikleri otomatik öznitelik çıkarımı yapabilir. Bu, daha geniş bir uygulama yelpazesi için verimli bir şekilde çalışmalarını sağlar.

Derin öğrenme, görüntü, dil, ses ve doğal dil işleme gibi birçok alanda uygulanmaktadır. Örneğin, görüntü sınıflandırması, nesne tespiti, yüz tanıma, dil modelleme, çeviri, konuşma tanıma ve otonom sürüş gibi alanlarda kullanılır (Goodfellow vd., 2015).


Günümüzde birçok alanda farklı derin öğrenme modelleri kullanılmaktadır. Bunlardan başlıca öne çıkan derin öğrenme modelleri şunlardır;

- Evrişimsel Sinir Ağları (Convolutional Neural Networks – CNNs)
- Yinelemeli Sinir Ağları (Recurrent Neural Networks – RNNs)
- Üretken Çekişmeli Ağlar (Generative Adversarial Networks – GANs)
- Uzun-Kısa Dönemli Bellek (Long / Short Term Memory – LSTM)
- Oto Kodlayıcılar (Autoencoders – AE)

3.5.1. Evrişimsel sinir ağları

Evrişimsel sinir ağları (Convolutional Neural Network – CNNs), temel olarak görüntüleri sınıflandırmak, benzerliklerine göre kümelemek ve nesne tanıma işlemleri için kullanılan derin yapay sinir ağlarıdır. Evrişimsel sinir ağları, hastalık teşhisi ve tıbbi görüntülerden sınıflandırma, nesne tanımlama, ses tanıma, metin ve video işleme,

görüntü bölütlemesi, yüz bilgisi çıkarma, otomatik video sınıflandırması gibi birçok bilgisayarlı görme çalışmasında üstün performansları nedeniyle yaygın olarak kullanılmaktadır. Şekil 3.11’de beyin tümörü görüntüsünün sınıflandırılmasının Evrişimsel sinir ağı modeli ile gerçekleştirilirken hangi katmanlardan geçtiği görülmektedir.



Şekil 3.11. Sınıflandırma İçin Kullanılan bir Evrişimsel Sinir Ağı Modelinin Yapısı

Evrişimsel sinir ağları, görsel nitelikler arasındaki tüm özellikleri bulmak için birden çok katmana ihtiyaç duyarlar. Şekil 3.11’de de görüldüğü gibi girdi ve çıktı arasında evrişim katmanı (Convolution), havuzlama katmanı (Pooling) ve tam bağlantı katmanlarından (Fully Connected) oluşan bir yapıya sahiptir. Burada girdi verisi olarak bir görüntü ham şekilde ağı gönderilir. Ancak görüntü verisinin boyutu ve çözünürlüğü bu noktada oldukça önemlidir. Çünkü verinin boyutunun büyük olması ile işlem süresi ve donanım kaynakları arasında doğru bir orantı vardır. Bunun yanında yeterli miktarda donanım kaynağı ile çalışılırsa büyük boyuttaki görüntü verileriyle daha doğru sonuçlar da elde edilebilmektedir (Eker ve Duru, 2021).

Evrişim katmanı (Convolution), ağıdaki en temel katmandır ve dönüşüm katmanı olarak da bilinir. Giriş görüntüsünün üzerine bir filtre geçirilerek yeni bir matris çıkarılır. Filtreler burada önemli bir rol oynar. Bu filtreler sayesinde önüne gelen görüntüye evrişim işlemini uygulayarak bir çıktı verisi oluşturur. Böylece bir özellik haritası elde edilir. Eğitim sırasında kullanılan filtrelerin katsayıları her adımda tekrarlanır (Eker ve Duru, 2021).

Havuzlama katmanı (Pooling) isteğe bağlı olmasına rağmen, asıl amaç ağıın parametre ve boyutlarının sayısını azaltmaktır. Boyut küçülmesinin bir sonucu olarak bilgi kaybı kaçınılmazdır, ancak bu bilgi kaybı aslında ağıın yararınadır. İlk fayda, hesaplama yükünün azaltılmasıdır. İkinci fayda, ağıdaki ezberlemenin en aza indirilmesidir. Bu nedenle, havuzlama katmanı, özellik çıkarmada da ikincil bir rol oynar. Son katman tam bağlantı katmanıdır. Burada, önceki katmanlardan gelen veriler ağırlıklandırılarak birleştirilir. Daha sonra bir kayıp fonksiyonu sayesinde antrenman boyunca nöronlara verilecek en uygun ağırlık değerleri bulunur. Bu katmanda sınıflandırma için olasılık değerleri çeşitli aktivasyon fonksiyonları kullanılarak hesaplanır. Bu nedenle, evrişimli sinir ağıları genellikle tıbbi görüntü sınıflandırması için ilk tercihtir (Eker ve Duru, 2021).

Tam bağlı katman (Fully Connected), genellikle son katman olarak belirlenir. Önceki katmanlarda elde edilen özellikler düzleştirme (Flatten) işlemi ile bir diziye dönüştürülür. Tam bağlı katmanda düzleştirme adımında, nesneye ait çıkarılan özellikler bir önceki katmandan alınarak nesneyi belirleyen bu özelliklerin hangi sınıfla ilişkili olduğu ortaya çıkartılır. Yani bu katmanda aynı zamanda sınıflandırma işlemi de gerçekleştirilmektedir. Sınıflandırma işlemi için tam bağlı katmandan sonra, sınıflandırılacak nesne sayısı kadar sonuç üretilir. Bu sonuçlar aynı zamanda modelin tespit etmesi istenilen sınıflardır. Çoklu sınıflandırma problemleri olarak bilinen nesne tanıma işlemlerinde genellikle softmax fonksiyonu kullanılmaktadır (Doğan ve Türkoğlu, 2019).

3.5.2. Yinelemeli sinir ağıları

Yinelemeli sinir ağıları (Recurrent Neural Networks - RNN) ilk olarak Basit Tekrarlayan Ağ (Simple Recurrent Neural Networks - SRN) olarak Jeff Elman tarafından tasarlanmıştır. Elman'ın hazırladığı tasarım ile cümle yapısı simülasyonunda kullanılan kelimelerin gizli kalıpları ortaya çıkartılmıştır. SRN modeli, ortalama örüntü kümeleme yöntemiyle isim ve fiil kategorileri arasında net bir ayırım yapabilmiş ve ayrıca isimlerden canlı-cansız, insan-hayvan kümeleri ile birlikte hayvanları da avcı-yırtıcı gibi sınıflara ayırmayı başarmıştır (Elman, 1990). RNN bir yapay sinir ağı sınıfıdır ve birimler arasındaki bağlantıları yönlendirilmiş bir döngü

oluşturur. Bu döngü sayesinde RNN, zamansal davranışları modelleyebilir ve iç durumunu dinamik olarak güncelleyebilir. RNN'ler, ileri beslemeli sinir ağlarının aksine, girdilerin rastgele dizilerini işleyebilmekte ve kendi giriş belleğini kullanarak bu işlemi gerçekleştirebilmektedirler (Mikolov vd., 2010).


RNN temel olarak sıralı bilgileri kullanarak işlem yapar. Görüntü temelli verilerde, tüm girdilerin birbirinden bağımsız olduğu varsayılırken, Doğal Dil İşleme (Natural Language Processing - NLP) gibi zamanla değişen alanlarda böyle bir varsayım mümkün değildir. Örneğin, bir cümle içinde bir sonraki kelimeyi tahmin etmek için o andaki kelimenin öncesinde gelen kelimelerin neler olduğunu bilmek gereklidir. RNN mimarisi yinelenen olarak adlandırılır çünkü her bir dizinin elemanı için önceki çıktılara bağlı olarak aynı görevi yerine getirir (Şeker vd., 2017).

Yinelemeli sinir ağları daha çok dil çevrimleri için kullanılmakla birlikte arka arkaya meydana gelen bir dizi yapıdan bir sonraki noktanın tahmin edilmesi işlemi yapar. Buna basitçe örnek vermek gerekirse finansal bir hareketin dizi şeklinde zaman serileri ile giriş verisi olarak kullanılarak sonraki bir zamanda hangi durumda olacağının tahmin edilmesi olarak gösterilebilir. Ya da kurulacak bir cümlede art arda gelen kelimelerin akabinde cümlenin devamının nasıl geleceğini gösteren kelimenin tahmin edilmesi işlemi örnek olarak verilebilir. Karpathy ve Fei-Fei yaptıkları “Deep VisualSemantic Alignments for Generating Image Descriptions” başlıklı makalelerinde RNN ve CNN modellerini birlikte kullanarak etiketlenmemiş görüntüleri tanımlamayı sağlayan yeni bir model ortaya çıkarmışlardır. Ortaya çıkartılan bu yeni model, görüntü üzerindeki nesneleri tanımlamakla birlikte tanımlayıcıların görüntü üzerindeki yerlerini tespit edebilmiştir (Karpathy ve Fei-Fei, 2015).

3.5.3. Uzun-Kısa Süreli Hafıza

Uzun-Kısa Süreli Hafıza ağları (Long-Short Term Memory) genellikle "LSTM" olarak adlandırılmaktadır ve RNN özel bir türüdür. Yinelemeli sinir ağlarında dizi içerisinde her bir çıktı kendinden önceki elemanların çıktı değerlerine bağlı olarak oluşmaktadır. Ancak cümle içerisindeki bağlamlar arası mesafeler arttıkça, Yinelemeli Sinir Ağlarının geçmişten gelen bilgileri kullanması zorlaşmaktadır. İşte bu noktada geriye

dönük bilgilerin hafızada saklanması ve tekrar kullanılması durumu söz konusu olduğundan LSTM sinir ağlarındaki gizli katmanlarda bulunan LSTM hücresi adındaki yapı ön plana çıkmaktadır (Doğan ve Türkoğlu, 2019).



Şekil 3.12. LSTM sinir ağı modeli (Graves, 2012)

Şekil 3.12’de de görüldüğü gibi, LSTM’in temel yapısındaki hücre iletişim hattı (Cell State) ve kullandığı çeşitli kapılar en önemli bölümleridir. “Cell State”, tahmin yapmak için anlamlı bilgileri hücreler boyunca taşıyan bir iletişim hattı ve ağı hafızası olarak açıklanabilir. Bu sayede kısa süreli bellek problemi çözülerek eski veriler ağ zinciri boyunca taşınabilir. Hafızada bu yolculuk boyunca taşınması gereken bilgiler ise kapılar aracılığı ile belirlenir. Bu kapılar hangi bilginin gerekli veya gereksiz olduğunu belirleyebilir (Graves, 2012). Kapılar ise verileri 0 ile 1 aralığına sıkıştıran sigmoid aktivasyon fonksiyonunu kullanır. Sigmoid aktivasyonu sonucunda 0 olan bilgiler unutulur ve 1 olan bilgiler ise iletişim hattı ile ilerlemeye devam eder (Graves, 2012). Bu yapı Şekil 3.12’de gösterildiği gibi hücre ve sinir ağı boyunca bilgi akışını kontrol eden giriş, unutma ve çıkış kapılarına sahiptir.

Unutma kapısında hangi bilgilerin unutulacağı veya tutulacağı kararı verilir. Önceki hücreden gelen bilgi (h_t) ve mevcut bilgi (x_t) sigmoid aktivasyon fonksiyonuna

sokulduktan sonra sonuçta 0 olan bilgiler unutulur ve 1 olan bilgiler iletişim hattı ile taşınmaya devam ederler (Graves, 2012).

Giriş kapısı ise iletişim hattında yer alan verileri günceller. Önceki ve mevcut bilgi sigmoid fonksiyonu ile işleme girer, işlem sonucunda 0 olan bilgi önemsiz ve 1 olan bilgi ise önemli olarak kabul edilir. Bunun yanında ağıın düzenlenmesi işlemi için tanh aktivasyon fonksiyonu da kullanılır. Son olarak sigmoid ve tanh fonksiyonlarına ait çıkış değerleri çarpılır ve hangi bilginin güncelleneceği kararına varılır.

Çıkış kapısı ise bir sonraki hücrenin girişini ($ht+1$) belirlemek ve bunun yanında tahmin yapmak için de kullanılır. Bu kapıda ilk olarak önceki bilgi ve mevcut girişe ait veri sigmoid fonksiyonu ile işleme sokulur. Daha sonra iletişim hattı üzerinde var olan bilgiyi tanh fonksiyonu ile işleme girer ve son olarak bu iki sonuç çarpılarak hangi bilgilerin bir sonraki hücre için giriş ($ht+1$) verisi olacağına karar verilir. Mevcut hücre için kapı işlemleri tamamlandığında bir sonraki hücreye gidecek olan iletişim hattındaki ve hücrenin giriş bilgisi olarak belirlenen değer (ht) ortaya çıkartılmış olur (Graves, 2012).

LSTM ağları bir kelime dizisi ile beslendiğinde metin üretme uygulamaları için kullanılabilir, resimleri işleyerek verilen görüntü hakkında açıklamalarda bulunabilir, notaları kullanarak farklı kategorilerde müzikler üretebilir ve cümleleri farklı dillere çevirebilirler.

3.5.4. Üretken Çekişmeli Ağlar

Derin öğrenme, gerçek dünyadaki çok büyük miktarda verilerle karmaşık yapıdaki işlemlerin çözümlenmesinde kullanılan bir makine öğrenmesi yaklaşımıdır. Büyük ölçekteki verilerin kullanıldığı derin sinir ağları, görüntülerden anlamsal bilgilerin çıkartılmasında klasik görüntü işleme tekniklerinden daha iyi bir performans ortaya koymuştur. Derin öğrenmede ortaya konulan yaklaşımlar, görüntü üretme konusunda da oldukça başarılı sonuçlar sergilemiştir. Derin sinir ağları ile görüntü üretmek adına geliştirilen ilk model 2014 yılında Ian Goodfellow tarafından önerilmiştir. Üretken Çekişmeli Ağlar olarak adlandırılan bu model, İngilizce karşılığı olan Generative Adversarial Network kelimelerinin baş harfleri (GAN) kullanılarak adlandırılmıştır.

GAN modeli, stil transferi yapılması, tabular veri üretimi, görüntülerin iyileştirilmesi, ses transferi ve yapay yüz üretilmesi gibi alanlarda yoğun olarak kullanılmaktadır. GAN, var olan insan yüzlerinden hiç var olmamış farklı yüzler üretilmesi için de başarılı şekilde kullanılmıştır (Çelik ve Talu, 2020).

GAN modelinin yapısında üretici ve ayırıcı olmak üzere iki farklı derin ağ bulunmaktadır. GAN yapısındaki bu iki ağ birbiriyle çekişmeli olarak çalışarak öğrenmeyi gerçekleştirir. Ayırıcı denilen derin ağ, üretilen görüntüleri gerçek görüntülerle karşılaştırarak ayırt etmeye çalışırken, üretici derin ağ da giriş verisi olarak aldığı gürültü sinyallerine dayanarak eldeki gerçek görüntülere en yakın görüntüleri üretmeye çalışır. Bu şekilde ayırıcı ve üretici ağlar birbiriyle rekabetçi bir şekilde eğitilmiş olurlar. Eğitim işlemi belli bir tekrar sayısına ulaşıncaya kadar devam eder ve ağların eğitimi tamamlandıktan sonra üretici ağ gerçek görüntülere benzer yeni görüntüler üretir (Goodfellow vd., 2014).


Çoğu GAN modeli altı adımdan oluşan algoritmayı kullanarak eğitilir. Birinci adımda rastgele bir gürültü vektörü üretilir. Birinci adımda üretilen gürültü değeri ikinci adımda üretici derin sinir ağına gönderilir. Daha sonra üçüncü adımda eğitim veri setinde bulunan gerçek görüntülerden örneklem seçilerek üretilen sentetik görüntülerle karıştırılır. Dördüncü adım karıştırılan bu veri setindeki görüntülerle ayırıcı derin sinir ağının eğitilmesi adımıdır. Bu adımda ayırıcının amacı, bütün görüntüleri gerçek veya sahte olarak etiketlemektir. Ardından beşinci adımda tekrar rastgele gürültü değeri üretilir, fakat bu kez üretilen bu vektör değerleri gerçek görüntü olarak etiketlenir. Son adımda gerçek görüntüler olmasalar bile gerçek görüntü olarak etiketlenmiş gürültü vektörlerini kullanarak GAN eğitilir.

Bu adımlara göre GAN modellerinin çalışma algoritması aşağıdaki gibidir. Bu algorithmada yer alan $x(i)$ gerçek görüntü örneklerini, $z(i)$ gürültü vektörünü, $G(z_i)$ de sahte görüntü örneklerini ifade etmektedir.

1. **For** *iterasyon_sayısı* **do**
2. **For** *adım_sayısı(k)* **do**
3. *Sahte görüntüler üret* $\{G(z^{(1)}), \dots, G(z^{(m)})\}$
4. *Gerçek görüntüler al* $\{x^{(1)}, \dots, x^{(m)}\}$
 D'yi eğit (ağırlıkları güncelle): $\nabla_{\theta_d} = \frac{1}{m} \sum_{i=1}^m [\log D(x^i) + \log(1 - D(G(z^i)))]$
5. **end for**
6. *Sahte görüntüler üret* $\{G(z^{(1)}), \dots, G(z^{(m)})\}$
 G'yi eğit (ağırlıkları güncelle): $\nabla_{\theta_g} = \frac{1}{m} \sum_{i=1}^m \log(1 - D(G(z^i)))$
7. **end for**

Algoritmadaki iterasyon sayısı değişkeni G ve D ağırlarının kaç tekrarda eğitileceğini göstermektedir. Ayırıcıya uygulanan adım sayısı değeri (k) minimum maliyet olması açısından 1 olarak belirlenebilir. Bunun dışında adım sayısı, toplam görüntü sayısının belirlenen örnek sayısı (batch_size) değerine bölünmesi ve çıkan sonucun toplam tekrar sayısı ile çarpılmasıyla bulunabilir.

Ayırt edici derin ağı (D), aslında gerçek ve sahte görüntüleri birbirinden ayıran ikili sınıflandırıcı içermektedir. Bu nedenle bu derin ağın kayıp fonksiyonu olarak İkili Çapraz Entropi (binary_crossentropy) kullanılır. Üretici derin ağı (G) olarak gösterilmektedir ve $G(z^i)$ ifade şekli, üretilen sahte görüntüleri temsil etmektedir. Daha önce de belirtildiği gibi üretici derin ağ öyle gerçeğe yakın görüntüler üretmeye çalışır ki, ayırt edici derin ağ bu görüntüleri gerçeğinden ayırt edemesin (Langr ve Bok, 2019). Bu sayede üreticiden gelen sahte görüntüler gerçeğine ne kadar yakın olurlarsa elde edilen hata değeri yükseleceğinden bu hata değeriyle üreticinin eğitilmesi sağlanarak daha da gerçeğine yakın görüntüler üretmesi sağlanır (Langr ve Bok, 2019). GAN modellerinin genel çalışma prensibi Şekil 3.13'te görüldüğü gibidir.




Şekil 3.13. GAN klasik mimari yapısı (Langr ve Bok, 2019)

Günümüzde GAN yapısının farklı modelleri kullanılarak farklı alanlarda çalışmalar yapılmakta ve bu doğrultuda farklı GAN modelleri de ortaya çıkartılmaktadır. Bu modellerden bazıları incelenerek gerçekleştirilen uygulamada faydalanılmıştır.

3.5.4.1. CGAN (Conditional GAN)-Koşullu GAN

Çalışma prensibi Şekil 3.14'te de görüldüğü gibi olan CGAN modelinde, standart GAN modelinden farklı olarak üretici ve ayırıcı derin ağlarının girişine ek bir etiket bilgisi gönderilmektedir. Bu sayede ayırıcı, girişteki gerçek veya sahte görüntünün hangi sınıfa ait olduğu bilgisini alarak işlemleri gerçekleştirir. Ayrıca üretici derin ağı da gürültü verisiyle birlikte görüntünün hangi sınıfa ait olduğu bilgisini kullanarak üretme işlemini gerçekleştirir (Mirza ve Osindero, 2014).

Burada c , sınıf etiketleri gibi yardımcı bilgi olabilir. $D(x|c)$ ve $G(z|c)$, sırasıyla c etiketi ile verilen görüntüyü ayırt etmemizi ve bu etikette görüntü üretilmesini sağlayan fonksiyonları ifade etmektedir.



Şekil 3.14. (A) Standart GAN mimarisi, (B) CGAN mimarisi (Mirza ve Osindero, 2014)

3.5.4.2. DCGAN (Deep convolutional GAN) – Derin konvolüsyonel GAN


DCGAN, standart GAN mimarisi ile CNN'yi bir araya getirir. Bu özellik, DCGAN'ın daha büyük ve karmaşık görüntüleri daha verimli bir şekilde işlemesini sağlar. Standart GAN mimarisinde, bir önceki katmandan çıkan çıktı boyutu sonraki katmanın giriş boyutuna eşit olacak şekilde ayarlanırken, DCGAN görüntüden kesitler kullanarak bu boyutları değiştirebilir. Böylece, daha büyük ve daha karmaşık görüntüler işlenebilmektedir.

DCGAN mimarisi convolutional layer, batch normalization layer, activation function ve loss function'dan meydana gelir. Convolutional layer görüntü verisinden özellikleri çıkartmak için, batch normalization ise training ve convergence speed'i arttırmak için kullanılır. Aktivasyon fonksiyonu ile sinir ağı nonlinear problemleri çözebilir hale gelirken, kayıp fonksiyonu da sinir ağının accuracy'sini değerlendirmeye yarar (Liu vd., 2023). Radford vd tarafından geliştirilen DCGAN'da üretici ve ayırtıcıya getirilen kısıtlamalar şunlardır (Radford vd., 2016).

- Pooling, G ve D derin sinir ağında kullanılmamaktadır.
- Görüntü daraltma işlemi discriminator ağda konvolüsyon işlemiyle yapılmaktadır.
- Hem G ağı hem D ağı batch normalization kullanılır.
- Daha derin mimariler için FC gizli katmanlar kullanılmaz.
- G ağında çıkış katmanı hariç diğer katmalarda ReLU aktivasyon fonksiyonu kullanılır.
- D ağının tüm katmanlarında LeakyReLU aktivasyon fonksiyonu kullanılır.

Yapılan bu kısıtlamalar ile DCGAN eğitim sürecinde daha kararlı hale gelerek daha kaliteli görüntüler üretebilmiştir. Bu nedenle DCGAN'nın birçok uygulamada yaygın olarak kullanılmaktadır (Wu vd., 2017).


Şekil 3.15'te DCGAN modelinin yapısı gösterilmiştir. Şekil 3.15'e göre G ağı rastgele gürültü vektörünü alır ve ardından farklı ölçeklerde öznitelik haritaları oluşturmak için “upper sampling” sürecini gerçekleştirir. G ağının eğitmenin amacı, gerçek örnekleri öğrenmek ve ayırt edici ağı (discriminatorü) aldatmak için sahte örnekler oluşturmaktır. Bu işlemi, üretilen örnek ve gerçek örnek arasındaki dağılım mesafesini azaltarak gerçekleştirir. Her bir “upper sampling” işlemi bir örneklem normalizasyonu (batch normalization) katmanı ve bir aktivasyon fonksiyonu ile devam eder. Son katmanda *Tanh* fonksiyonu dışında tüm aktivasyon fonksiyonları *ReLU* olarak uygulanır. D ise üretilen örnekleri ve gerçek verileri alır. D ağının eğitim amacı ise üretilen örnekleri gerçek görüntülerden ayırt etmektir. Girdi örneğinin gerçek olma olasılığını temsil eden discriminatorün amaç fonksiyonu değeri, bir ikili sınıflandırma problemidir. Bu eğitim süreci D sinir ağı girdi örneklerini gerçek görüntülerden ayırt edemeyene kadar (loss function value=0) devam eder (Liu vd., 2023).



Şekil 3.15. DCGAN Mimari yapısı (Liu vd., 2023)

3.5.4.3. ACGAN (Auxiliary classifier GAN)-Yardımcı sınıflandırıcı GAN

Bu modelin ayırıcı ve üretici ağlarında log-olabilirlik dağılımı kullanılmaktadır. G giriş olarak z gürültü vektörüne ek olarak c sınıf bilgisi alır ve sahte görüntü ($X_{sahte} = G(z, c)$) üretir. CGAN ve ACGAN mimarilerinin arlarındaki fark Şekil 3.16'da gösterilmiştir. Ayırıcı $LC - LS$ 'yi, üretici ise $LC + LS$ 'yi maksimum yapmak için eğitilmektedir.



Şekil 3.16. CGAN ve DCGAN karşılaştırma

LS , imgeler üzerindeki log-olabilirlik dağılımını gösterirken, LC ise sınıflar üzerindeki log-olabilirlik dağılımını göstermektedir.


3.5.4.4. InfoGAN-Bilgi GAN

InfoGAN, yorumlanabilir ve anlamlı temsilleri öğrenmeye teşvik etmek için GAN hedefini değiştiren bir tür üretken çekışmeli ağıdır. Bu işlem, GAN'ın gürültü değişkenlerinin sabit bir küçük alt kümesi ile gözlemler arasındaki karşılıklı bilgiyi maksimize ederek yapılır (Chen vd., 2016).

Aslında InfoGAN, karşılıklı bilgi ve hiperparametrenin değişken bir şekilde düzenlenmesiyle bir min-max oyunu olarak da tanımlanır (Chen vd., 2016).

$$\min_{G,Q} \max_D V_{INFOGAN}(D, G, Q) = V(D, G) - \lambda L_I(G, Q) \quad (3.8.)$$

Denklem 3.8'deki formüle göre q , sonsal $P(c|x)$ 'e yaklaşan bir yardımcı dağılım olduğunda (x verisi verilen gizli kodun c olasılığı) ve L_I , gizli kod ile gözlemler arasındaki karşılıklı bilginin değişken alt sınırıdır. Şekil 3.17'de Standart GAN ve InfoGAN mimarileri gösterilmiştir.




Şekil 3.17. Standart GAN - InfoGAN yapısı (Chen, vd., 2016)

3.5.4.5. SGAN – Yarı eğitici GAN

Bu modelde ayırıcı ağın son katmandaki aktivasyon fonksiyonu değiştirilir. Klasik ayırıcı ağ, giriş olarak aldığı görüntüden bir olasılık değeri üreten, yani tek bir sigmoid fonksiyonla biten bir ağıdır. Ancak SGAN'ın çıkış katmanı gerçek ve sahte sınıfların tamamı için çıkışlar üreten bir softmax katmanına sahiptir (Odena, 2016).

Yarı denetimli öğrenme, tahmine dayalı bir modelin gerekli olduğu ve az sayıda etiketli örnek ve çok sayıda etiketlenmemiş örneğin bulunduğu bir sorunu ifade eder.

Yarı eğitimci GAN veya bazen kısaca SGAN, yarı denetimli öğrenme problemlerini ele almak için Üretken çekişmeli Ağ mimarisinin bir uzantısıdır. Mimari yapısı Şekil 3.18’deki gibidir.



Şekil 3.18. SGAN mimari yapısı (Odena, 2016)

3.5.4.6. WGAN - Wasserstein GAN’ların geliştirilmiş eğitimi

Wasserstein GAN veya kısaca WGAN, Martin Arjovsky ve arkadaşları tarafından 2017 yılındaki “Wasserstein GAN” başlıklı makalelerinde tanıtılmıştır.

WGAN, belirli bir eğitim veri setinde gözlemlenen verilerin dağılımına daha iyi bir biçimde yaklaşırken, üretici derin ağ modelini eğitmek için alternatif bir yol arayan bir GAN uzantısıdır (Arjovsky vd., 2017).

Oluşturulan görüntülerin gerçek veya sahte olma olasılığını sınıflandırmak veya tahmin etmek için bir ayırıcı kullanmak yerine, WGAN, ayırıcı modelini belirli bir görüntünün gerçekliğini veya sahteliğini puanlayan bir eleştirmeyle değiştirir veya değiştirir. Bu değişiklik, üreticinin eğitiminin, eğitim veri setinde gözlemlenen verilerin dağılımı ile oluşturulan örneklerde gözlemlenen dağılım arasındaki

mesafenin en aza indirilmesini araması gerektiğine dair teorik bir argüman tarafından motive edilir.

WGAN'ın yararı, eğitim sürecinin daha kararlı ve model mimarisine ve hiperparametre konfigürasyonlarının seçimine daha az duyarlı olmasıdır. Belki de en önemlisi, ayrımcının kaybı, üretici tarafından oluşturulan görüntülerin kalitesiyle ilgili görünmektedir.

WGAN, bazen sadece kötü örnekler üretebildiği görülmüştür (Gulrajani vd., 2017). Bu olumsuz duruma ağırlık kırpma fonksiyonunun neden olduğu anlaşılmıştır. Daha sonra ağırlık kırpma yöntemine alternatif olarak yeni bir yöntem WGAN-GP önerilmiştir.

3.5.4.7. LSGAN - En az kareler GAN

Ayrımcıyı bir sınıflandırıcı olarak gören GAN'larda hata fonksiyonu olarak Sigmoid Cross Entropy (SCE) fonksiyonu kullanılmaktadır. Bu fonksiyon yardımıyla üretici güncellenirken, bazı örnekler için gradyan bilgisi yok olmaktadır. Çözüm olarak SCE yerine en az kareler yaklaşımı önerilmiştir (Mao vd., 2016). Buna göre maliyet fonksiyonları Denklem 3.9'daki gibi güncellenmektedir.


$$\begin{aligned} \min_D V_{LSGAN}(D) &= \frac{1}{2} \mathbb{E}_{x \sim p_{data}(x)} [(D(x) - b)^2] + \frac{1}{2} \mathbb{E}_{z \sim p_z(z)} [(D(G(z)) - a)^2] \\ \min_G V_{LSGAN}(G) &= \frac{1}{2} \mathbb{E}_{z \sim p_z(z)} [(D(G(z)) - c)^2] \end{aligned} \quad (3.9.)$$

Burada c , üreticinin ayrımcıyı sahte verilere inanmasını istediği değeri belirtir. a ve b , sahte ve gerçek veriler için kullanılan etiketlerdir (Mao vd., 2016).

3.5.5. Oto Kodlayıcılar

Oto-kodlayıcılar, girdinin çıktıyla aynı olduğu belirli bir ileri beslemeli sinir ağı türüdür. Girdiyi daha düşük boyutlu bir koda sıkıştırırlar ve ardından çıktıyı bu gösterimden yeniden oluştururlar. Kod, gizli alan temsili olarak da adlandırılan girdinin kompakt bir "özet" veya "sıkıştırılmasıdır".

Bir oto-kodlayıcı kodlayıcı (encoder), kod veya darboğaz (bottleneck) ve kod çözücü (decoder) olmak üzere üç bölümden oluşur. Oto kodlayıcının ilk bölümü olan kodlayıcı, özellikle bir özellik çıkarıcı görevi gören convnet'tir. Birincil işlevi, görüntülerden en göze çarpan özellikleri çıkarmaya yardımcı olmak ve bunları bir vektör olarak döndürmektir. Kodlayıcıdan hemen sonra yer alan ve kod katmanları olarak da adlandırılan darboğaz, çıkarılan özelliklerin daha küçük bir vektör temsiline sıkıştırılmasına yardımcı olan ekstra bir katman görevi görür. Bu, kod çözücünün özellikleri anlamasını zorlaştırmak ve onu daha karmaşık eşlemeleri öğrenmeye zorlamak amacıyla yapılır. Oto kodlayıcının son bölümü olan kod çözücü, orijinal görüntüyü olduğu gibi yeniden oluşturmak için daha sonra darboğazda sıkıştırılan kodlayıcıdan gelen özellikleri anlamlandırmaya çalışan convnet'tir. Tipik bir oto kodlayıcıya ait katmanlar Şekil 3.19'da gösterilmiştir.



Şekil 3.19. Otokodlayıcıların genel yapısı

Sinir ağlarına dayalı otomatik kodlayıcılarda, çıktı katmanının aktivasyon işlevi özellikle önemli bir rol oynar. En çok kullanılan fonksiyonlar ReLU ve Sigmoid fonksiyonlarıdır. Girdilere ait değerleri x_i olarak kabul ettiğimizde, x_i geniş bir pozitif değer aralığını gösteriyorsa ReLU fonksiyonu doğru bir seçim olarak kullanılabilir. x_i negatif değerler alıyorsa ReLU'nun kullanımı çok doğru olmayacaktır. Giriş değerlerinin hepsi $[0, 1]$ aralığındaysa veya değerler bu aralıkta olacak şekilde normalleştirildiyse Sigmoid fonksiyonu kullanılabilir. Örneğin MNIST veri seti kullanıldığında, girdi değerlerinin (x_i) her biri, 0 ile 255 arasında herhangi bir değer alabilen piksellerin gri değerleridir. Piksel değerleri 255'e bölünerek veriler normalleştirildiğinde, her görüntünün yalnızca piksel değerlerine sahip olması sağlanmış olur ve 0 ile 1 arasında değerler elde edilir. Bu durumda Sigmoid fonksiyonu, çıktı katmanının aktivasyon fonksiyonu olarak iyi bir seçim olur (Michelucci, 2022).

3.6. Görüntü İşleme

Görüntü işleme sürecinde kullanılan başlıca yöntemler aşağıda verilmiştir.

Kaydırma: Yatay eksen kaydırma, dikey eksen döndürme işleminden çok daha yaygındır. Bu veri çoğaltma yöntemi uygulanması en kolay yöntemlerden birisidir ve CIFAR-10 ve ImageNet gibi veri setlerinde oldukça başarılı sonuçlar elde edilmiştir (Shorten ve Khoshgoftaar, 2019).

Renk alanı: Renk kanalları alanında büyütme gerçekleştirek veri çoğaltma işlemi uygulaması çok pratik olan başka bir yöntemdir. Bir görüntünün parlaklığını artırmak veya azaltmak için basit matris işlemleriyle RGB değerleri bu yöntemle kolayca değiştirilebilir (Shorten ve Khoshgoftaar, 2019).

Kırpma: Görüntü kırpma, her görüntünün merkezi bir parçasını kırparak karışık yükseklik ve genişlik boyutlarına sahip görüntü verileri için pratik bir görüntü işleme tekniğidir. Bunun yanında, döndürme işlemine benzer bir etki sağlamak için rastgele kırpma yöntemi de kullanılabilir. Rastgele kırpma yönteminde görüntünün piksel olarak boyutunda değişiklik gerçekleştirilmektedir (Shorten ve Khoshgoftaar, 2019).

Döndürme: Döndürme yöntemi, görüntüyü 1° ile 359° arasında bir eksen üzerinde sağa veya sola döndürerek yapılır. Döndürme yöntemiyle veri çoğaltmada döndürme derecesi parametresi önemlidir. 1 ile 20 veya -1 ile -20 arasındaki gibi hafif döndürmeler bazı hazır veri setlerindeki gibi basamak tanıma görevlerinde faydalı olabilirken, döndürme derecesi arttıkça verilerin etiketlerinde bozulmalar olabilmektedir (Shorten ve Khoshgoftaar, 2019).

Üretken Çekişmeli Ağ (GAN) temelli görüntü çoğaltma: Veri çoğaltma için son dönemde popüler olan yöntemlerden bir tanesi de üretken çekişmeli ağlardır. Üretken çekişmeli ağ modeli ile bir veri kümesinden, orijinal kümeye benzer özellikleri koruyacak şekilde yapay oluşturulur. Üretken çekişmeli ağların görüntü üretmedeki başarılı performansı, veri çoğaltma yöntemleri arasında önemli bir model olmasını sağlamıştır (Shorten ve Khoshgoftaar, 2019).

3.7. K-Ortalamlar Yöntemi ile Görüntü Bölütleme

K-ortalamlar algoritması, benzer özelliklere sahip örneklerin kategorilere ayrılması için kullanılan bir kümeleme algoritmasıdır. Temel prensibi, k merkez noktası hesabına dayanır. Başlangıçta, her nokta veriye en yakın merkez noktası olan kümeye alınır. Her grup tamamlandıktan sonra, her bir kümenin yeni centroid'i yeniden hesaplanır. Centroid c_j ($j = 1, 2, \dots, k$) şekilde tanımlanırsa; elemanlar arasındaki fark $O \in c_j$, ve küme temsilcisi r_j arasındaki uzaklık $\text{dist}(O, r_j)$ Euclidean distance yöntemi kullanılarak hesaplanır. Kümeleme başarımı, tüm veri noktaları ile onlara karşılık gelen küme merkezleri arasındaki minimum mesafenin toplamı kullanılarak doğrulanabilir. Mesafelerin toplamı için matematiksel denklem Denklem 3.10'da verilmiştir. Burada k, küme sayısını ve n_j , j. kümedeki veri noktalarını belirtir (Palakonda vd., 2023).

$$SD = \sum_{i=1}^k \sum_{O \in C_j} \text{dist}(O, r_j) \quad (3.10.)$$

$$r_j = \frac{1}{n_j} \sum_{O \in C_j} O \quad (3.11.)$$

K-ortalamlar kümeleme yaklaşımı uygulama kolaylığı, esnekliği ve ölçeklenebilirliği gibi avantajları ile görüntü bölütlenmesi alanında da popüler olmuştur. Bu yöntem ile gri seviyeli bir MR görüntüsü renkli uzay görüntüsüne dönüştürülebilmekte ve kümeleme işlemi yoluyla tümör bölgelerinin konumu diğer alanlardan ayrılabilir (Wu, Lin, & Chang, 2007). Boyutu $p(x, y)$ ile temsil edilen bir görüntünün k sayıda kümeye ayrılabilmesi için aşağıda verilen adımlar uygulanır (Faragallah vd., 2023).

Küme sayısı k ve merkezleri (c_k) tanımlanır.

Görüntüdeki her bir piksel ve küme merkezleri arasında ilişkiye bakılarak d Öklit uzaklığı Denklem 3.12'ye göre hesaplanır.

$$d = \|p(x, y) - c_k\| \quad (3.12.)$$


Görüntünün her bir pikseli d mesafesine göre en yakın kümenin merkeze atanır. Denklem 3.13 kullanarak merkezin yeni konumu yeniden hesaplanır.

$$c_k = \frac{1}{k} \sum_{y \in c_k} \sum_{x \in c_k} p(x, y) \quad (3.13.)$$

Hata değeri karşılanana kadar işlem tekrarlanır ve küme pikselleri görüntüye dönüştürülür.

3.8. Karar Verme Ölçütleri

Intersection over union – Jaccard index: Jaccard indeksi olarak da bilinen Intersection Over Union (IoU), semantik bölütlemelerde en sık kullanılan metriklerden biridir. Tahmin edilen bölütleme alanı ile temel gerçek kesişiminin, tahmin edilen bölütleme ile temel gerçek birleşimine bölümü ile ortaya çıkan sonuçtur. Burada temel gerçek, literatürdeki Ground Truth ifadesine karşılık gelmektedir. Şekil 3.20’de IoU’nun formülasyonu gösterilmektedir.




Şekil 3.20. IoU formülasyonu

Bu metrik, 0–1 (%0–100) arasında değişmektedir; 0, görüntüler arasında herhangi bir örtüşme olmadığını ve 1 ise mükemmel şekilde örtüşen bir bölütleme olduğunu gösterir.

Dice Coefficient – Sørensen-Dice index: Sørensen-Dice indeksi veya kısaca Dice katsayısı olarak da bilinen Zar benzerlik katsayısı, iki veri seti arasındaki benzerliği ölçen istatistiksel bir araçtır. Derin öğrenme ile bölütleme işlemlerinde oldukça yaygın olarak kullanılmaktadır. İki görüntünün kesişimlerinin iki katının görüntülerdeki

piksel sayılarının toplamına bölünmesiyle elde edilir. Formülasyonu Şekil 3.21’deki gibidir.

$$\text{Dice} = \frac{2 \times \text{Intersection}}{\text{Blue} + \text{Red}}$$


Şekil 3.21. Dice coefficient formülasyonu

3.9. Derin Öğrenme Mimarileri


Derin öğrenme, insan beynini taklit etmek için yapay sinir ağlarını kullanan bir makine öğrenimi türüdür (Abdel-Jaber vd., 2022). Derin mimariler otomatik olarak öğrenmek için denetimli, yarı denetimli veya denetimsiz öğrenme stratejileri gibi makine öğrenimi yöntemlerini kullanılır ve büyük miktarda verilerden üstün öğrenme yeteneği nedeniyle birçok alanda popülerlik kazanmıştır (Abdel-Jaber vd., 2022).

Günümüzde pek çok alanda hazır derin mimariler kullanılmaktadır. Bu mimariler kullanılan uygulamanın türüne göre farklı şekillerde tercih edilebilmektedir. Bilgisayarlı görü alanında yapılan çalışmaların ilerlemesiyle birlikte büyük boyutlardaki görüntülerin de bu hazır mimariler kullanılarak işlenmesi oldukça hızlı bir şekilde gerçekleştirilmektedir. Bu mimariler, kullanım alanlarının genişlemesiyle birlikte tıp alanında da oldukça popüler hale gelmişlerdir. Derin ağ modellerinden bazıları U-Net, ResNet, VGG16, VGG19, Inception V3 ve Xception gibi modeller olarak sıralanabilir. Günümüzde görüntü ve nesne tanıma uygulamalarının geliştirilmesiyle birlikte bu derin ağ modelleri de farklı şekillerde kullanılabilir.

3.9.1. UNET

U-NET, son yıllarda oldukça fazla dikkat çeken başarılı bir kodlayıcı-çözücü ağıdır (Mehta ve Arbel, 2019). Ağın kodlayıcı bölümü, anlamsal bilgileri bir araya getirmesi

bakımından geleneksel CNN sınıflandırma ağına benzer. Bölütleme işleminde hem semantik hem de uzamsal bilgi bir ağı başarısı için çok önemli olduğundan, eksik uzamsal bilgilerin bir şekilde kurtarılması gerekir. U-Net ağ modeli bu işlemi, "U" şeklindeki yapının en alt kısmından anlamsal bilgileri alan ve bunları, atlama bağlantıları aracılığıyla doğrudan kodlayıcıdan elde edilen daha yüksek çözünürlüklü özellik çıkarımlarını yeniden birleştiren kod çözücü aracılığıyla yapar (Mlynarski vd., 2019). Şekil 3.22’de mimarisi görülmektedir.




Şekil 3.22. U-Net Mimarisinin görüntüsü (Mlynarski vd.,2019)

3.9.2. RESUNET

RESUNET, Deep Residual UNET anlamına gelmektedir. Semantik bölütleme için Zhang vd. tarafından geliştirilen bir kodlayıcı-kod çözücü mimarisidir. Başlangıçta, uzaktan algılama görüntü analizi alanında yüksek çözünürlüklü hava görüntülerinden yol çıkarımı için kullanılmıştır. Daha sonra araştırmacılar tarafından polip bölütlemesi, beyin tümörü bölütlemesi, insan görüntüsü bölütlemesi ve daha pek çok başka uygulama için benimsenmiştir (Zhengxin vd., 2018).

RESUNET, daha az parametre ile yüksek performans elde etmek için tasarlanmış tamamen evrişimli bir sinir ağıdır. Mevcut UNET mimarisi üzerinde geliştirilmiştir. Standart U-Net mimarisinden farklı olarak, yok olan gradyan veya patlayan gradyanlar

sorununu yaşamadan daha derin bir ağı oluşturmaya yardımcı olur ve ayrıca ağı daha kolay eğitilmesine yardımcı olur. Şekil 3.23'te ResUnet mimarisine ait görüntü yer almaktadır (Zhengxin vd., 2018).



Şekil 3.23. ResUNet Mimarisinin görüntüsü (Zhengxin vd., 2018)

3.9.3. RESNET50


Günümüzde kullanılan en popüler Konvolüsyonel Sinir Ağı mimarilerinden birisi olan ResNET, 2015 yılında gerçekleştirilen ImageNet yarışmasında rekor kırarak birinciliği elde etmiştir. ResNet ağı, VGG-19 mimarisinden esas alınarak VGG ağlarından daha az filtreye ve daha düşük karmaşıklığa sahip 34 katmanlı düz bir ağı mimarisi kullanır. Daha sonra bu düz ağı atlama bağlantıları veya artık bloklar eklenerek mimari artık ağıya dönüştürülür. Resnet 50 ağı ise, 34 katmanlı ağıdaki her 2 katmanlı bloğun 3 katmanlı darboğaz bloğuyla değiştirilmesiyle elde edilir. Böylece Resnet50 mimarisinde 177 katmandan oluşan bir ağı yer ortaya çıkartılmış olur (He vd., 2016).

3.9.4. VGG16

VGG16 derin öğrenme mimarisi daha derin ağların daha iyi ağlar olduğu fikrine dayanarak tasarlanmıştır. VGG-16, basit bir ağ modeli olup öncesindeki modellerden en önemli farkı evrişim katmanlarının 2'li ya da 3'li kullanılmasıdır. Tam bağlantı (FC) katmanında $7 \times 7 \times 512 = 4096$ nöronlu bir öznitelik vektörüne dönüştürülür. İki FC katmanı çıkışında 1000 sınıflı softmax başarımı hesaplanır. Yaklaşık 138 milyon parametre hesabı yapılmaktadır. Diğer modellerde olduğu gibi girişten çıkışa doğru matrislerin yükseklik ve genişlik boyutları azalırken derinlik değeri (kanal sayısı) artmaktadır (Kızrak, 2018).

VGG16 mimarisi tüm evrişim katmanlarında değişken sayıda 64, 128, 256 filtre sayısı ile sabit 3×3 boyutlu filtreler kullanmaktadır. VGG16, 13 evrişim 3 tam bağlı katmanından oluşan bir ağıdır. Maksimum havuzlama (max pooling), tam bağlı katman (fully connected layer), ReLu katmanı, çıktı katmanı (output layer) ve Softmax katmanlarıyla birlikte toplamda 41 katmandan oluşmaktadır. Girdi katmanında yer alacak görüntü $224 \times 224 \times 3$ boyutundadır. Son katman ise sınıflandırma katmanıdır (Doğan ve Türkoğlu, 2018).

VGG16 mimarisi, görüntü sınıflandırma, nesne tanıma, nesne yerleştirme ve özellik çıkarımı gibi işlemleri başarıyla gerçekleştirebilmiştir. VGG16 mimarisi, ResNet ve Inception modelleri gibi diğer popüler CNN mimarileriyle birlikte, derin öğrenme alanında yaygın olarak kullanılmaktadır. Modelin mimari yapısı Şekil 3.24'te gösterildiği gibidir.



Şekil 3.24. VGG16 ve VGG19 mimari yapısı

3.9.5. VGG19

VGG19, VGG16 modelinin bir benzeridir. Bu model, 16 evriřim katmanı, 3 tam baęlantılı katman, 5 havuzlama katmanı ve 1 SoftMax katmanından oluřmaktadır. VGG16’da olduęu gibi giriř katmanında 224x224x3 boyutundaki grntleri desteklemektedir (He vd., 2016). VGG19’un mimari yapısı da řekil 3.24’te gsterildięi gibi VGG16 ile aynıdır.


VGG19, VGG16 modeline kıyasla daha fazla derin bir mimariye sahiptir. Bu nedenle daha yksek ęrenme kapasitesi ve kesinlik derecesine sahiptir denilebilir. Katman sayısının fazla olmasından dolayı daha fazla zellik ıkarımı yaparak daha fazla ayrıntılı zellik tanımlayabilir. Ancak tabi ki, daha derin bir mimariye sahip olmak demek uygulama ařamasında daha fazla kaynak ihtiyaı doęurmaktadır (Simonyan & Zisserman, 2014). Bu nedenle VGG19 modelinin uygulanabilmesi iin yksek kapasiteli iřlemci ve GPU ihtiyaı ortaya ıkmaktadır.

4. MR GÖRÜNTÜLERİNDEN DC-GAN TABANLI OTOMATİK TÜMÖR BÖLGE BÖLÜTLEMESİ

4.1. Derin Öğrenme ile Tümörlü Bölge Bölütlemesi

Hazırlanan bu tez çalışmasında hazır veri setlerinde yer alan MR görüntüleri ön işlemlerden geçirilerek, gerçekleştirilen uygulamada kullanılabilir hale getirilmiştir. Bu aşamada ilk olarak veri setinde yer alan farklı sekanslardaki MR görüntüleri uzman görüşleri alınıp, literatürdeki benzer çalışmalar incelendikten sonra kullanılabilen en uygun sekansın FLAIR olduğu ortaya çıkartılmıştır. Bu görüntüler kontrastlı olması sebebiyle beyin görüntüsüne ait görüntü katmanlarından tümörlü veya tümörsüz bölgelerin daha net şekilde ayırt edilebildiği görülmüştür. Dolayısıyla kullanılan veri setinden FLAIR sekansında yer alan 210 yüksek dereceli tümöre sahip hasta verisi kullanılmıştır.


Veri setinde yer alan görüntüler nöro-görüntüleme alanında bilinen bir dosya formatı olan NIfTI türündedir. Bu dosya formatındaki görüntüler python’da yer alan kütüphaneler kullanılarak incelendiğinde görüntülerin 155 katmanın birleştirilmesiyle ortaya çıkartılmış üç boyutlu görüntüler olduğu görülmüştür. Bu noktada, alanda gerçekleştirilen çalışmalar ışığında her bir hastaya ait 155 görüntü katmanı içindeki beyin tümörünün en net şekilde görüntülendiği katmanlar kullanılarak yeni bir veri seti elde edilmiştir. Veri setinde FLAIR görüntülerinin dışında ayrıca her hastaya ait tümörlü bölge bölütlemelerinin yapılmış olduğu görüntüler de aynı formatta yer almakta ve tümörlü bölgelerin net şekilde çıkartıldığı katmanlar ayrılarak bölütleme dosyaları için de yeni bir veri seti elde edilmiştir. Böylece son olarak uygulamada kullanılmak üzere 210 hastanın her birisine ait MR görüntüsü ve tümörlü bölgelerinin yer aldığı bölütleme görüntüleri Şekil 4.1’deki gibi elde edilmiştir.



Şekil 4.1. FLAIR MR görüntüleri ve tümörlü bölge bölütlemesi

Hazırlanan tez çalışmasında, veri ön işlemenin ikinci adımında görüntü boyutları ayarlanmıştır. Veri setinde yer alan görüntüler 240x240 ve 3 kanallı görüntüler olduğundan, oluşturulan modelde 240x240x3 şeklindeki matrise dönüştürülerek işleme girmesi gerekmektedir. Bu aşamada kullanılan modelleri çalıştırabilmek için kullanılan bilgisayar Intel i7-8550 CPU ve NVIDIA GeForce930 MX with a 8 GB GPU özelliklerindedir. Bu nedenle kullanılan bilgisayarın performansı da dikkate alındığında görüntü boyutlarında küçültme işlemi gerçekleştirilmiş ve her bir görüntü 128x128x3 boyutuna indirgenmiştir. Bu sayede kullanılan modellerin eğitim süreleri de kısaltılmıştır.

Çalışmanın birinci aşamasında gerçekleştirilen işlem adımları Şekil 4.2’de gösterilmiştir. Buna göre; ilk veri setinden elde edilen görüntülerle tümörlü bölge tespitinin yapılabilmesi için 5 adet derin öğrenme modeli kullanılmıştır. Bu modeller Unet, ResUnet, Res50, VGG16 ve VGG19 modelleridir. Bu modellerin tercih edilmesinin nedeni literatürde en tercih edilen modeller olmaları ve beyin tümörü tespitinde yüksek başarımlarına sahip olmalarıdır. Modellerin kesinlik değerleri veri setinden ayrılan 14 hastaya ait test verisi kullanılarak elde edilmiştir. Kesinlik değerleri hesaplanırken derin öğrenmede sıklıkla kullanılan metrikler olan Dice Coefficient ve Intersection over Union değerleri kullanılmıştır.



Şekil 4.2. Önerilen modele göre çalışmanın ilk aşamasında yapılan işlemler

Tez çalışmasının birinci aşamasında veri集中的 210 hastaya ait görüntüler kullanılarak, görüntü bölütlemesi üzerine literatürde gerçekleştirilen çalışmalarda sıklıkla tercih edilen derin öğrenme modellerinden beş tanesi kullanılarak tümörlü bölge tespitinin kesinlik ve benzerlik değerleri hesaplanmıştır. Kullanılan derin öğrenme modelleri sırasıyla U-Net, ResU-Net, Res50, Vgg16 ve Vgg19 modelleridir. Çalışmada ilk olarak bu modellerin eğitimi 210 hastaya ait veri seti ile sağlanmış daha sonra veri setinde doğrulama için ayrılan 66 hastaya ait görüntülerden rastgele 14 hastaya ait MR görüntüsü test verisi olarak seçilerek modellerin metrikleri hesaplanmıştır.

Bütün modeller için en uygun örneklem boyutu (batch_size), tekrar (epoch) vb. gibi parametrelerin belirlenebilmesi için farklı parametre değerleri için testler yapılmış ve en uygun olan, eğitim test oranı %10, kesinlik test oranı %10, epoch sayısı 200 ve

batch_size 16 deęerleri belirlenmiřtir. Ayrıca, bütün modellerde çıkıř katmanında sınıflandırma için sigmoid aktivasyon fonksiyonu kullanılmıřtır.

Çizelge 4.1’de 210 hastaya ait veriler ile modellerin eęitilmesi sonucunda ortaya çıkan bařarım deęerleri ile, test verisi olarak belirlenmiř 14 hastaya ait görüntü kullanılarak yapılan bölütleme sonucundaki bařarım deęerleri gösterilmektedir. Belirlenen bu metrikler daha önce de belirtildięi gibi derin öğrenme ile görüntü iřleme ve bölütleme iřlemlerinde sıklıkla kullanılan metriklerdir. Çizelge 4.1’de Brats2018 veri setindeki 210 hastaya ait görüntü kullanılarak elde edilen eęitim verisi sonuçları ile yine Brats2018 veri setinde doęrulama için ayrılmıř 66 hastadan rastgele belirlenmiř 14 hastaya ait görüntülerin kullanıldıęı test verisi sonuçları karřılařtırılmıř ve böylece elde edilen sonuçlara göre modellerin performansları ortaya çıkartılmıřtır.

Çizelge 4.1. Brats2018 veri setindeki 210 hastaya ait görüntü ile gerekleřtirilen bölütleme sonuçları

Brats2018 Veri Seti				Brats2018 Test Veri Seti		
Eęitim Verisi Sonuçları				Test Verisi Sonuçları		
Model	Kesinlik	Iou	DS	Kesinlik	Iou	DS
UNET	99.51%	68.18%	80.66%	99.06%	48.05%	64.37%
RESUNET	99.43%	66.21%	79.27%	99.03%	46.64%	63.00%
RES50	99.64%	74.37%	84.95%	98.99%	40.89%	57.33%
VGG16	99.70%	76.76%	86.60%	99.25%	57.47%	64.60%
VGG19	99.62%	72.71%	83.96%	98.96%	41.21%	57.70%

BraTS2018 veri seti ile gerekleřtirilen bölütleme deneylerinin sonuçları Çizelge 4.1’de verilmiřtir. Eęitim verisi için UNeT, ResUnet, ResNet50, VGG16 ve VGG19 modelleri sırasıyla 99.51%, 99.43%, 99.64%, 99.70% ve 99.62% kesinlik deęeri elde etmiřlerdir. Dięer taraftan, test verileri aısından modeller incelendięinde, en bařarılı model 99.25% kesinlik deęeri ile VGG16 modeli olurken, 98.99% kesinlik deęeri ile en bařarısız model VGG19 olmuřtur. Test ve eęitim verileri benzerlik oranları aısından da deęerlendirilmiřtir. Literatüre göre; derin öğrenme modelleri kullanılarak gerekleřtirilen bölütleme iřlemlerinde, elde edilen sonuçların Dice ve IoU skorları

belirli bir benzerlik oranının üzerindeyse kabul görmektedir. Buna göre Dice skoru için görüntü doğrulamada $DC > 0.70$ ve $IoU > 0.50$ koşulları sağlandığında iyi bir örtüşme olduğu varsayılmaktadır (Zijdenbos vd., 1994). Eğitim verileri için analizler incelendiğinde, VGG16 modeli 76.76% IoU ve 86.60% Dice skoru ile en yüksek değerlere sahip olmuştur. ResUNet ise 66.21% IoU ve 79.27% Dice skoru değeri ile en düşük değeri elde etmiştir. Bu değerlere göre eğitim verisi için kullanılan derin öğrenme modellerinin Dice skoru ve IoU skorları kabul edilebilir değer aralıklarındadır. Test verileriyle gerçekleştirilen bölütleme işleminde ise Dice skoru değerine göre model sonuçlarının kabul edilebilir aralıklarda olmadığı, IoU skorlarına göre ise sadece VGG16 modelinin ($IoU = 57.47\%$) kabul edilebilir aralıkta olduğu belirlenmiştir.

Çizelge 4.1’de elde edilen sonuçlar ile bu sonuçların elde edilmesinde ortaya çıkan MR görüntüsü – Temel Gerçek – Tahmin Edilen görüntülerden modellere göre örnekler Çizelge 4.2’de yer almaktadır. Bu çizelgede test verilerinden ayrılan rastgele 14 hastaya ait MR görüntüsünden bazılarına ait bölütleme işlemleri örnek olarak gösterilmiştir. Test verisi olarak belirlenen görüntüler burada kullanılmadan önce uzman görüşü alınarak bölütleme işlemi görüntü işleme uygulamalarıyla gerçekleştirilmiş ve orijinal bölütlenmiş bölüm olarak etiketlenmiş ve sonrasında MR görüntülerinin modellere göre bölütlemesi gerçekleştirilmiştir. Modellerden elde edilmiş bölütleme sonuçları da tahmin edilen bölütleme olarak üçüncü sütuna eklenmiştir.

Çizelge 4.2. Brats2018 veri setine göre modellerin tümörlü bölge tespiti

MODEL	Brats2018 Veri Setindeki 210 Hastaya Ait Görüntülerle Elde Edilen Sonuçlar		
	MR Görüntüsü	Orijinal Bölütleme	Derin Öğrenme modellerinin Bölütlemesi
UNET			
RESUNET			
RES50			
VGG16			
VGG19			

Bu noktadan sonra modeller üzerinde yapılan çalışmalar ve literatür araştırmaları sonucunda, veri setinde yer alan görüntü miktarının yetersizliğinden kaynaklanan bir sorun olduğu tespit edilmiştir. Bu nedenle eldeki 210 hastaya ait verinin çoğaltılmasının, modellerin bölütleme başarımlarını arttırabileceği öngörülmüştür.

Bu aşamada kullanılan bilgisayarın performansı yetersiz kaldığı için Google Colab Pro kullanılarak bu aşamadaki kaynak eksikliği giderilmeye çalışılmıştır. İkinci aşamadaki veri çoğaltma işlemleri için yüksek performanslı RAM, donanım hızlandırıcı olarak GPU ve GPU türü olarak da T+ tercih edilmiştir.

4.2. DC-GAN ile MR Görüntü Çoğaltma ve K-Ortalamlar ile Tümörlü Bölgenin Otomatik Bölütlenmesi


Derin öğrenme ile gerçekleştirilen görüntü işleme uygulamalarında veri çoğaltma, oldukça sık rastlanan bir yöntemdir. Yapılan çalışmalar incelendiğinde görüntü çoğaltma ile ilgili birçok yöntemin kullanıldığı görülmüştür.

Hazırlanan tez çalışmasının birinci aşamasında, modellerin başarımının veri setindeki görüntü verilerinin artırılmasıyla doğru orantılı olarak artabileceği literatürdeki çalışmalarda açıkça görülmektedir. Bu nedenle tez çalışmasının özgün değerine ve sonuçların iyileştirilmesine katkıda bulunacağı göz önünde bulundurularak 210 hastaya ait 128x128x3 boyutlarındaki görüntülerden yeni görüntüler elde ederek veri setindeki görüntü sayısının artırılması sağlanmıştır. Bu aşamada tezde kullanılan veri artırma yöntemi olarak üretken çekişmeli ağlar (GAN), elde edilen görüntülerdeki tümörlü bölgelerin bölütlenmesi için de K-Ortalamlar kümeleme yöntemi tercih edilmiştir.

Tez çalışmasında k-ortalamlar kümeleme yönteminin uygulanacağı MR görüntüleri GAN modeliyle üretilmiş görüntülerden oluşmaktadır. Uygulamada GAN modeli olarak DcGAN tercih edilmiştir. Beyin MR görüntülerinin GAN yöntemiyle çoğaltılması konusunda Kazuhiro ve diğerleri gerçekleştirdikleri çalışmada, T1 ağırlıklı görüntülerden bir eğitim veri seti oluşturarak yeni sentetik beyin görüntüleri oluşturmak için DCGAN yöntemini uygulamışlardır. Görüntülerin DCGAN tarafından oluşturulmuş veya edinilmiş olma olasılığı, gerçek ve oluşturulmuş görüntüleri belirlemek için 5 radyolog tarafından ikili bir şekilde değerlendirilmiş ve sonuç olarak DCGAN ile üretilen MR görüntülerinin gerçekçi olduğu ve veri setinin büyütülmesinde kullanılabileceği sonucuna varılmıştır (Kazuhiro vd., 2018).


DCGAN, GAN'ın bir türüdür ve standart GAN mimarisine derin konvolüsyonel sinir ağları ekler. Bu ek özellikler, DCGAN'ın daha büyük ve karmaşık görüntüleri daha verimli bir şekilde işlemesine ve daha istikrarlı sonuçlar elde etmesine olanak tanımaktadır Standart GAN mimarisinde, bir önceki katmandan çıkan çıktı boyutu önceki katmanın giriş boyutuna eşit olacak şekilde ayarlanır. Ancak, DCGAN mimarisi görüntüden kesitler kullanarak bu boyutları değiştirebilir. Bu, daha büyük ve

daha karmaşık görüntüleri işlemek için daha uygun hale getirir. Uygulamada kullanılan DCGAN modeline ait mimari yapı Şekil 4.3’de gösterildiği gibidir. Modelin çalışma prensibi Şekil 4.3’de de gösterildiği gibi eğitim için ayrılmış gerçek görüntüler üzerinden gerçekleşmektedir.




Şekil 4.3. DCGAN mimarisi

Önerilen modelde birinci adım ile üçüncü adım arasında, DCGAN modeli ile hazır veri setinden ayrılmış rasgele görüntüler kullanılarak yeni MR görüntülerinin üretildiği yeni bir işlem adımı eklenmiştir. Çalışmanın ikinci adımında DC-GAN ve K-Ortalamlar yöntemleri eklenerek oluşturulan modele ait mimari yapı Şekil 4.4’de verilmiştir. Burada, elde edilen yeni görüntülerden uygun olmayanlar uzman görüşüne dayanarak temizlenmiştir. Sonraki aşamada ise veri setinin yapısına uygun olarak tümörlü bölge çıkarımı K-ortalamlar yöntemi ile yapılmıştır. Böylece çalışmada önerilen modele ait mimari çalışmanın ikinci aşamasında 6 adımda gerçekleşen bir yapıya dönüşmüştür.




Şekil 4.4. Önerilen modelin çalışmanın ikinci aşamasındaki mimari yapısı

GAN yapısının özelliğinden kaynaklı olarak, üretici ağ tarafından rastgele gürültü eklenerek üretilen görüntülerin ayırt edici ağ'da gerçek görüntülerle karşılaştırılmasıyla elde edilen hata değerinin artırılması hedeflenir. Yapılan uygulamada modele uygun olarak 210 hastaya ait MR görüntüsü içerisinde uzman görüşü yardımıyla ayıklanan 144 MR görüntüsü DCGAN modelinin eğitim veri seti olarak kullanılmıştır. DCGAN modelinde tekrar sayısı optimize edilerek belirlenmiş ve modelin her tekrarda üreteceği görüntü sayısı da uygun şekilde ayarlanmıştır. Modelin çalışması için GPU ve işlemci yetersizliğinden dolayı Google Colab'dan faydalanılmıştır. Modelin Colab'daki çalışma süresi yaklaşık 8-10 saat olarak belirlenmiş ve bu sürenin sonunda yaklaşık olarak 250.000 görüntü üretilmiştir. Elde edilen görüntülerin gerçek görüntülere benzerliğinin en yüksek seviyeye ulaştığı nokta belirlenerek DCGAN modelinin tekrar sayısı (epoch) 10000 olarak belirlenmiş ve Colab üzerinde modelin farklı zamanlarda ürettiği 750.000 görüntü içerisinde uzman görüşü alınarak seçimler yapılmıştır. Modelin farklı tekrar sayılarında ürettiği görüntülerden bazı örnekler Şekil 4.5'de tekrar sayıları ile birlikte gösterilmiştir.



Şekil 4.5. DCGAN modelinin ürettiği bazı görüntüler


Üretilen MR görüntüleri, eğitim veri setinden ayrılan görüntüler kullanılarak üretildiğinden aynı şekilde 240x240 piksel boyutundadır. Yeni görüntüler içinden, gerçek görüntülere benzerlik durumlarına göre ayrıştırma işlemi sonucunda 572 yeni MR görüntüsü elde edilmiştir. Brats2018 veri setinde yer alan bazı örnek MR görüntüleri ile DCGAN modelinin ürettiği sentetik MR görüntülerinin ilk halleri Şekil 4.6’da gösterilmiştir.



Şekil 4.6. Brats2018 ve DCGAN örnek MR görüntüleri

DCGAN modelinin ürettiği görüntüler veri setine eklenmeden önce ön işlemlerden geçirilmiştir. Bu adımda gerçekleştirilen ön işlemler gürültü azaltma ve tümörlü bölge çıkarımıdır. Gürültü azaltma yöntemi ile görüntülerdeki gölgeler ve sisli alanlar temizlenerek beyin görüntüsünün daha net hale getirilmesi sağlanmıştır. Bu sayede

tümörlü bölge çıkarımı daha kolay ve hızlı şekilde tamamlanmıştır. Bütün bu ön işlemler için python’da opencv kütüphanesindeki K-ortalamlar kümeleme algoritmasından faydalanılmıştır. K-Ortalamlar kümeleme algoritması ile, üretilen görüntülerin tümörlü alanlarının etiketlenmesi işleminin akış şeması Şekil 4.7’de gösterilen adımlardan meydana gelmektedir.



Şekil 4.7. K-Ortalamlar ile gerçekleştirilen işlem adımları

Uygulanan yöntemde sırasıyla aşağıdaki işlem adımları gerçekleştirilir;

- MR görüntüleri dosyadan sırayla okunur,
- Görüntü piksellere ayrılarak 2 boyutlu bir diziye dönüştürülür,
- Matris şeklindeki görüntü için sabit bir küme değeri belirlenir,
- İlk olarak görüntülerdeki sisli alanlar temizlenir ve yeni görüntü farklı bir dosya olarak kaydedilir,
- Yeni görüntüler dosyadan okunarak seçilir,


- Görüntü üzerindeki küme sayısı rastgele belirlenerek görüntü üzerindeki alanlar bölümlere ayrılır ve küme sayısı netleştirilir,
- Bölümlere ayrılan alanlar küme sayısının 1 eksiği olacak şekilde döngü değeri belirlenir ve bu bölgeler sırasıyla siyah bölgeye dönüştürülerek tümörlü alanın yalnız kalması sağlanır,
- Elde edilen son görüntü tümörlü bölge görüntüsü olarak kaydedilir.

Bu adımlar GAN ile üretilen bütün görüntülere uygulanmış ve sonuç olarak uygulamada kullanılmak üzere 572 MR görüntüsü ile bu görüntülere ait tümörlü bölge görüntüleri ortaya çıkartılmıştır. Modelin ortaya çıkarttığı tümörlü bölgeler uzman doktor kontrolünde gerçekleştirilerek doğrulukları kesinleştirilmiştir. Sonuç olarak yeni görüntüler veri setine eklenmiş ve son durumda 782 MR görüntüsü ile bunlara ait tümörlü bölgeler kullanıma hazır hale getirilmiştir. Şekil 4.8’de DCGAN modeliyle üretilen görüntüye uygulanan ön işlemlerden sonra elde edilen tümörlü bölge görüntüsü gösterilmiştir.



Şekil 4.8. DCGAN ile üretilen görüntüden tümörlü bölge çıkarımı işlem adımları

K-ortalamlar kümeleme yöntemi literatürde görüntü işleme ve görüntü bölütlemesi gibi konu başlıklarında genellikle tercih edilen hızlı bir yöntem olduğu için bu çalışmada tercih edilmiştir. K-ortalamlar yöntemiyle MR görüntüleri üzerinde yer alan dokulara ait renklerin küme sayısı tespit edilerek tümörlü bölge dışındaki bölgelerin karartılması sağlanmıştır. Şekil 4.9’da üretilen MR görüntüleri ve bu görüntülerden çıkartılmış tümörlü alanlar gösterilmiştir.



Şekil 4.9. DCGAN modeliyle üretilen MR görüntüleri ve tümörlü bölgeleri

Görüntülerde elde edilen sonuçlara göre sentetik MR görüntülerinin ve bu görüntülerden çalışmada kullanılan bölütleme yöntemi ile elde edilmiş etiketlenmiş tümörlü bölgelerin gerçeğe yakın olduğu gözlemlenmiştir.

5. ARAŞTIRMA BULGULARI VE TARTIŞMA

Uygulamanın son adımında veri setindeki 782 MR görüntüsü kullanılarak ilk veri setindeki verilerle gerçekleştirilen eğitim ve test adımları tamamlanmıştır. İlk veri setinde kullanılan 5 derin öğrenme modeli aynı şekilde 782 görüntüden oluşan veri setine uygulanmış ve Çizelge 5.1’deki sonuçlar elde edilmiştir.

Çizelge 5.1. Üretilmiş verilerle birlikte oluşturulan yeni veri seti ile elde edilen sonuçlar

Brats2018 ve GAN ile Üretilen Görüntülerden Oluşan Veri Seti				Test Veri Seti		
Model	Eğitim Verisi Sonuçları			Test Verisi Sonuçları		
	Kesinlik	Iou	DS	Kesinlik	Iou	DS
UNET	99.61%	79.41%	89.39%	99.28%	66.12%	80.71%
RESUNET	99.63%	80.11%	89.84%	99.15%	57.66%	77.59%
RES50	99.74%	86.16%	93.63%	99.26%	66.86%	81.32%
VGG16	99.74%	86.88%	94.09%	99.17%	64.16%	79.04%
VGG19	99.74%	86.36%	93.76%	99.22%	62.17%	77.49%


782 MR görüntüsü kullanılarak elde edilen sonuçlar ile ilk veri setindeki görüntüler kullanılarak elde edilen sonuçlar karşılaştırıldığında hem eğitim hem de test verilerinin sonuçlarında önemli oranda bir artış gözlemlenmiştir. Hazırlanan yeni veri setindeki verilerin %10’luk kısmı test %10’luk kısmı da doğrulama verisi olarak ayrıldıktan sonra bütün modellerle eğitimi gerçekleştirilmiş ve Çizelge 5.1’deki kesinlik, IoU ve Dice skor (DS) sonuçları elde edilmiştir. Yeni veri setiyle eğitilen modeller kullanılarak çalışmanın birinci aşamasında kullanılan veri setindeki test verilerinin bölütleme işlemi tekrar gerçekleştirilmiş ve elde edilen kesinlik, IoU ve Dice skor sonuçları Çizelge 5.1’de Test Verisi Sonuçları olarak verilmiştir.

Çizelge 5.1’e göre; eğitim verisi için UNeT, ResUnet, ResNet50, VGG16 ve VGG19 modelleri sırasıyla 99.61%, 99.63%, 99.74%, 99.74% ve 99.74% kesinlik değeri elde etmişlerdir. Test verileri açısından modeller incelendiğinde, en başarılı model 99.28% kesinlik değeri ile UNeT modeli olurken, ResUNeT’in kesinlik değeri 98.15% de kalmıştır. Eğitim ve test verileri için model kesinlik değerlerinde dramatik bir artış


görülmemiştir. Diğer taraftan, benzerlik açısından modeller değerlendirildiğinde; eğitim verilerine göre VGG16 modeli 86.88% IoU ve 94.09% Dice skor ile en yüksek değerlere sahip olmuştur. UNeT ise 79.41% IoU ve 89.39% Dice skor değeri ile en düşük skorları elde etmiştir. Test verileriyle gerçekleştirilen bölütleme işleminde, çalışmanın ilk fazından farklı olarak kullanılan tüm derin öğrenme modellerinin Dice skor ve IoU skorları kabul edilebilir değer aralıklarına yükselmiştir. Bu modeller içerisinde 66.86% IoU ve 81.32% Dice skor değerleri ile ResNet50 en yüksek skorları elde etmiştir. ResUNeT modeli ise 57.66% IoU ve 77.59% Dice skor değerleri ile benzerlik değeri en az model olmuştur.

Çalışma sonuçları, IoU ve Dice skor benzerlik kriterleri açısından analiz edilerek Şekil 5.1 ve Şekil 5.2’de eğitim ve test verileri için ayrı ayrı gösterilmiştir. Şekil 5.1’e göre eğitim verisi için VGG16 modeli 76.76% IoU ve değeri ile 86.60% Dice skor ile en yüksek başarıyı göstermiştir. Modelin eğitim aşamasındaki başarıyı, sentetik veriler de kullanıldığında yükselmiş ve 86.88% IoU ve 94.09% Dice skor değerlerine ulaşmıştır. Çalışmada kullanılan tüm modeller için söylenebilir ki, eğitim aşamasında sentetik verilerin kullanılması model eğitim başarılarını önemli ölçüde arttırmıştır. Diğer taraftan Şekil 5.2’ye göre test verileri için ResNet50 derin öğrenme modelinin IoU değeri 40.89%’dan 66.86%’ya çıkarak 61% bir iyileşme ile en yüksek benzerliği sağlamıştır. Benzer şekilde Dice skor değeri 57.33% den 81.32%’ye yükselmiş ve 42% oranında artmıştır.

Bunun yanında test datası için sırası ile VGG16, UNeT, ResUNeT, VGG19 ve ResNet50 modelleri başarı göstermişlerdir. Çalışmanın ikinci fazında sentetik verilerin eğitim kümesine eklenmesi sonucunda, test verileri için benzerlik sıralaması ise ResNet50, UNeT, VGG16, ResUNeT ve VGG19 şeklinde değişmiştir. Buna göre az miktarda eğitim verisi ile gerçekleştirilen çalışmalarda VGG16 daha yüksek başarı gösterirken, eğitim verisinin yüksek olduğu çalışmalarda ResNet50 modeli çok daha başarılı olmaktadır. UNeT modeli ise genel olarak hem az hem de yüksek sayıda veri ile eğitilen modellerde genel olarak başarı göstermektedir.



Şekil 5.1. Eğitim verilerine göre Dice ve IoU skor değerleri



Şekil 5.2. Test verilerine göre Dice ve IoU skor değerleri

İlk veri setindeki MR görüntülerine GAN ile üretilmiş görüntüler eklendikten sonraki veri seti kullanılarak elde edilen Kesinlik, Iou ve DS sonuçları Çizelge 5.2’de de karşılaştırmalı olarak gösterilmiştir.


Çizelge 5.2. Ham veriler ile üretilen görüntüler ile elde edilen sonuçların karşılaştırılması

Model	EĞİTİM VERİSİ SONUÇLARI						TEST VERİSİ SONUÇLARI					
	Kesinlik		Iou		DS		Kesinlik		Iou		DS	
	İlk Veri Seti	Son Veri Seti	İlk Veri Seti	Son Veri Seti	İlk Veri Seti	Son Veri Seti	İlk Veri Seti	Son Veri Seti	İlk Veri Seti	Son Veri Seti	İlk Veri Seti	Son Veri Seti
UNET	99.51%	99.61%	68.18%	79.41%	80.66%	89.39%	99.06%	99.28%	48.05%	66.12%	64.37%	80.71%
RESUNET	99.43%	99.63%	66.21%	80.11%	79.27%	89.84%	99.03%	99.15%	46.64%	57.66%	63.00%	77.59%
RESS0	99.64%	99.74%	74.37%	86.16%	84.95%	93.63%	98.99%	99.26%	40.89%	66.86%	57.33%	81.32%
VGG16	99.70%	99.74%	76.76%	86.88%	86.60%	94.09%	99.25%	99.17%	57.47%	64.16%	64.60%	79.04%
VGG19	99.62%	99.74%	72.71%	86.36%	83.96%	93.76%	98.96%	99.22%	41.21%	62.17%	57.70%	77.49%

Tablodaki sonuçlar incelendiğinde görüntü sayısının artırılması ile birlikte eğitim ve test sonuçlarının başarımında artışlar görülmüştür. Uygulamada kullanılan derin öğrenme modelleri karşılaştırıldığında tümörlü bölge tespitini en doğru şekilde tahmin edebilen model Res50 modeli gerçekleştirmiş ve daha sonra UNet, VGG16 ve VGG19 modellerinin başarılı sayılabilecek ölçüde tahmin yaptığı görülmüştür.

Tablodaki verilerin haricinde modellerin gerçekleştirdiği tümörlü bölge tahminine ait görüntülere bakıldığında, ilk veri seti ile tümörlü bölge tahmini yapılan aynı görüntülerin önerilen model ile gerçekleştirilen tümörlü bölge tahmini arasındaki farklar da Çizelge 5.3'te gösterilmiştir.

Çizelge 5.3. Veri Setinin İlk ve Son Haline Göre Modellerin Tümörlü Bölge Tespiti

MODEL	BRATS2018 Veri Seti ile Elde Edilen Sonuçlar	Brats2018+GAN ile Elde Edilen Sonuçlar
UNET		
RESUNET		
RESS0		
VGG16		
VGG19		

Çalışma sonuçları, BRATS veri seti için, literatürde yapılan çalışmalar ile iki açıdan karşılaştırılmıştır. Öncelikle çalışma sonuçları, literatürde yer alan mevcut derin öğrenme yöntemlerine göre kesinlik, DS ve IoU ölçütlerine göre değerlendirilmiştir. Buradaki başlıca amaç, tez çalışmasında elde edilen derin öğrenme başarımlarının kabul edilebilir seviyede olup olmadığını kanıtlamaktır. Literatür ile yapılan ikinci değerlendirme ise, sentetik veri üreterek başarımların artırılmasına yönelik gerçekleştirilen yöntemler ile olmuştur. Burada özellikle tez çalışmasında da kullanılan GAN mimarisinin başarımlarını literatür çalışmaları ile karşılaştırılmaktadır.

Demir vd. (2023) 3D MRI görüntülerinin bölütlenmesi için yaptıkları çalışmada MR görüntü verilerinin T1, T1gd, T2, FLAIR sekanslarını kullanarak derin özelliklerini çıkartmıştır. Sonrasında modelin genel başarımlarını arttırmak için ağırlıklı ortalama (weighted majority) kullanmışlardır. Ağırlıklı ortalama sürecinde en yüksek performans sağlayan SVM algoritmasına göre BRATS2015 veri seti ile 98.90% ve BRATS2018 veri seti ile 99.29% kesinlik değeri elde etmişlerdir. Diğer taraftan Pedada vd. (2023) klasik U-Net modelinin genel performansını arttırmaya yönelik yaptıkları çalışmada yine BRATS 2018 veri setini kullanarak 92.20% kesinlik ve 0.854 DS elde etmiştir. Ramasamy vd. (2023) ise BRATS2020 veri setini kullanarak farklı modellerin yöntemlerinin sonuçlarını karşılaştırarak bölütleme işlemi için bir model ortaya çıkarmışlardır.

Zeineldin vd. (2020) yaptıkları derin öğrenme bölütleme platformunda veri setindeki sadece FLAIR görüntülerini kullanmışlar ve kullanılan derin öğrenme mimarileri ile doğrulama veri setindeki tümörlü bölgelerin tespitini gerçekleştirerek gerçekleştirilen tespit işleminin başarımlarını DS kullanarak belirlemişlerdir. Jwaid vd. (2021) beyin tümörü tespiti için tasarladıkları yeni U-Net mimarisi ile segmentasyon başarımlarını IoU değerini hesaplayarak elde etmiş ve ayrıca Mzoughi vd. (2020) de DS ve IoU değerlerini başarımlarını hesaplamak için kullanmışlardır.

Bu çalışmalar ve tez çalışmasından elde edilen başarımların sonuçları Çizelge 5.4’de verilmiştir.

Çizelge 5.4. Derin öğrenme yöntemlerinin literatür çalışmaları ile karşılaştırılması

Çalışma	Yöntem	veriseti	Başarımlar ölçütü (Acc, DS, IoU)	Sekans
Demir vd. (2023)	3ACL, Weighed Majority (SVM)	BRATS 2015, BRATS 2018	98.90% (Acc) 99.29% (Acc)	T1, T1gd, T2, FLAIR
Mzoughi vd. (2020)	CNN	BRATS 2018	96.49% (Acc)	T1gd
Pedada vd. (2023)	Modified U-Net	BRATS 2017, BRATS 2018	93.40% (Acc), 82.1% (DS) 92.20% (Acc), 85.4% (DS)	T1, T1gd, T2, FLAIR,
Ramasamy vd. (2023)	MM-Link-Net SeNet U-Net	BRATS 2020	77.7% (DS) 73.2% (DS) 75% (DS)	T1, T1gd, T2, FLAIR,
Zeineldin et al (2020)	UNet, Modified U-Net, VGGNet, ResNet, DenseNet	BRATS 2019	80% (DS) 81% (DS) 83% (DS) 81% (DS) 83% (DS)	FLAIR
Jwaid (2021)	3D U-Net CNN, SegNet5	BRATS 2017	98.9% (Acc), 69% (IoU) 96.2% (Acc), 55% (IoU)	T1, T1gd, T2, FLAIR,
DNNs modellerinin başarımları	U-Net RESUNET RES50 VGG16 VGG19	BRATS 2018	99.06%(Acc), 48.05% (IoU), 64.37% (DS) 99.03%(Acc), 46.64% (IoU), 63.00% (DS) 98.99%(Acc), 40.89% (IoU), 57.33% (DS) 99.25%(Acc), 57.47% (IoU), 64.60% (DS) 98.96%(Acc), 41.21% (IoU), 57.70% (DS)	2D FLAIR (210 veri)
DCGAN, K-means ve DNN kullanımı	U-Net RESUNET RES50 VGG16 VGG19	BRATS 2018	99.28%(Acc), 66.12% (IoU), 80.71%(DS) 99.15%(Acc), 57.66% (IoU), 77.59%(DS) 99.26%(Acc), 66.86% (IoU), 81.32%(DS) 99.17%(Acc), 64.16% (IoU), 79.04%(DS) 99.22%(Acc), 62.17% (IoU), 77.49%(DS)	2D FLAIR (782 veri)

Demir vd. (2023) 3D MRI görüntülerinin bölütlenmesi için derin öğrenme stratejisine dayalı bir yöntem önermiştir. Çalışmada, 3D Attention Convolutional LSTM (3ACL) modeli, MR görüntü verilerinin T1, T1gd, T2, FLAIR sekanslarını kullanarak derin özelliklerini çıkartmıştır. Sonrasında modelin genel başarımlarını arttırmak için ağırlıklı ortalama (weighted majority) kullanılmıştır. Ağırlıklı ortalama sürecinde en yüksek performans sağlayan SVM algoritmasına göre kesinlik değeri 98.90% (BRATS2015) ve 99.29% (BRATS2018) elde edilmiştir. Mzoughi vd. (2020) ise HGG ve LGG

sınıflandırması yapmak için CNN yöntemini kullanmıştır. Yöntem T1gd sekansı üzerine odaklanmış ve 3D MR görüntüleri üzerinde 96.49% kesinlik değeri elde etmiştir. Diğer taraftan Pedada vd. (2023) klasik U-Net modelinin kodlayıcısını bir ResNet-34 modelinin kodlayıcısı ile değiştirerek genel performansı arttırmaya çalışmıştır. BRATS 2018 veri seti üzerinde 92.20% kesinlik ve 0.854 DS elde etmiştir. BRATS 2020 veri seti üzerinde bir çalışma ise Ramasamy vd. (2023) tarafından önerilen MM-Link-Net modeli ile SeNet ve U-Net derin öğrenme yöntemlerini karşılaştırarak gerçekleştirilmiştir. Çalışmada, çok modlu MRI özellikleri birleştirilir ve kodlayıcı-kod çözücü tabanlı bir LinkNet Mimarisine verilir. Önceden eğitilmiş ResNET152 mimarisi, segmentasyon için omurga ayırıcı mimarisi olarak kullanılmaktadır. Zeineldin vd. (2020) sadece FLAIR görüntüleri üzerine odaklanmıştır. Bu amaçla farklı derin öğrenme modellerini içeren bir DeepSeg plarformu geliştirilmiştir. Önerilen derin öğrenme mimarileri, doğrulama setindeki tümör bölgelerini 0.80- 0.83 arasında değişen ortalama DS değeriyle tespit edebilmiştir. Jwaide vd. (2021) 3D MRI görüntülerini tespit edebilme başarımını arttırmak için yeni bir U-Net mimari önermişlerdir. Yeni U-Net mimarisinde üst/alt katman örnekleme modülü klasik U-Net mimarisindeki üst katman/ havuzlama katmanı ile yer değiştirilerek yeniden düzenlenmiştir. Yeni U-Net modelinin eğitim süresi daha uzun olmakla birlikte 98.9% kesinlik ve 0.69 IoU değerleri elde edilmiş ve SegNet5 mimarisine göre daha iyi sonuç vermiştir. Önerilen çalışmada ise Mzoughi vd. (2020) ve Zeineldin vd.(2020)'in çalışmalarında olduğu gibi, model yerine sadece tek bir sekansa (FLAIR) ve 2D görüntülere odaklanılmaktadır. Buradaki başlıca amaç 3D yapıdaki yüksek boyutlu veri miktarını azaltarak, 2D görüntüler üzerinde de yüksek başarılı bölütleme yapılabileceğini kanıtlamaktır. Çalışma sonucunda elde edilen kesinlik, DS ve IoU değerleri, kullanılan derin öğrenme modellerinin eğitiminde kullanılan parametreler de göz önünde bulundurulduğunda literatür çalışmalarını destekler niteliktedir.

GAN mimarisi kullanılarak gerçekleştirilen çalışmalara bakıldığında; Raja ve Vijayachitra (2023) beyinde oluşan anormallikleri tespit etmek için GAN, K-ortalamlar ve MobileNet kullanımına dayalı bir yöntem önermişlerdir. Çalışmada GAN, gerçek MR görüntülerinden sentetik görüntüler üretmek, K-means algoritması ise bu görüntüler üzerindeki anormal bölgeleri işaretlemek için kullanılmıştır. Çalışmada beyin üzerindeki anormal bölgeleri bölütleme için MobileNet V2

mimarisi seçilmiştir. BRATS veri seti üzerinde geliştirilen modelin başarımı UNet, UNet++, UNet-ResNet 50 ve Vanilla U-Net tekniklerinin başarımı ile karşılaştırılmıştır. Çalışma sonuçlarına göre önerilen model 99.31 DS, 0.99 kesinlik ve 0.98 F1-skor değeri ile en başarılı model olmuştur. Diğer bir yöntemde, 3D beyin MR görüntülerini otomatik olarak bölütlemek için dönüştürücü-tabanlı GAN, Huang vd. (2022) tarafından önerilmiştir. Önerilen mimari, min-maks oyun ilerlemesinde eğitilmiş bir oluşturucu ve bir ayırıcıdan oluşmuştur. Jeneratör, alt katmanı Resnet'li dönüştürme bloklarından oluşan tipik bir "U-şekilli" kodlayıcı-kod çözücü mimarisine dayalıdır. Yöntemin etkinliğini doğrulamak için BRATS 2015 veri seti üzerinde testler gerçekleştirilmiş ve mevcut yöntemlere göre daha başarılı sonuçlar elde edilmiştir. Tekniğin başarılı bir şekilde bölütleme yapabildiği ise BRATS2018 ve BRATS2020 veri setleri üzerinde kanıtlanmıştır. BRATS2018 doğrulama veri setinde, önerilen yöntem, genişleyen tümör, tüm tümör ve tümör çekirdeği bölgeleri için sırasıyla 0.7686, 0.9021 ve 0.8089'luk Dice skorunu elde etmiştir.

Çalışmalardan da görülebileceği gibi, GAN mimarileri, başarılı medikal görüntü sentezleme kapasitesi, veri çıkarma ve dağıtma potansiyeli ile tıbbi görüntü bölütleme sürecinin başarımına önemli ölçüde katkı sağlamaktadır. Bu tez çalışmasında da, literatür çalışmalarında elde edilen bulguları destekler nitelikte, sentetik olarak üretilen beyin MR görüntülerinin, K-ortalamlar ile otomatik bölütlenmesi ve derin öğrenme modellerine sunulması sonucunda mevcut modellere göre daha başarılı sonuçlar elde edilmiştir.

6. SONUÇ ve ÖNERİLER

Literatürde yer alan birçok çalışmada görüldüğü gibi tercih edilen veri setinin BRATS olması bu veri setinin derin öğrenme yöntemleriyle Beyin Tümörü Segmentasyonu işlemlerinde etiketlenmiş veri ihtiyacını karşıladığını göstermektedir. Bu nedenle bu çalışmalar hazırlanan tez çalışmasında kullanılan veri setinin doğruluğunu ispatlar niteliktedir. Aynı zamanda tümörlü bölgelerin tespiti yapıldıktan sonra kullanılan metriklerin de genel olarak alanda yapılan çalışmalarda sıklıkla kullanılan metrikler olduğu görülmektedir.

Hazırlanan tez çalışmasında kullanılan yöntemlerden olan GAN, medikal görüntülerin çoğaltılması aşamasında son zamanlarda tercih edilir hale gelmiştir. Medikal görüntü verilerine ulaşma gücü göz önüne alındığında, hazır veri setlerindeki veya hastane ortamından elde edilen MR görüntülerinin çoğaltılma ihtiyacı nedeniyle bu alanda yapılan çalışmalar için GAN yönteminin yol gösterici bir yöntem olabileceği ortaya konmuştur.

GAN yöntemi ile üretilen görüntülerin sağlıklı bir şekilde hazır veri setlerine dahil edilebilmesi için elde edilen MR görüntülerinin veri setine uygun bir hale getirilmesi gerekmektedir. Bu aşamada ise tez çalışmasında kullanılan open CV kütüphanesindeki K-ortalamlar algoritması literatürdeki pek çok görüntü işleme uygulamalarında olduğu gibi tez çalışmasında da kullanılmıştır. K-means yöntemi, tez çalışmasında üretilen görüntülerdeki tümörlü bölgelerin bölütleme işleminin gerçekleştirilmesi ve görüntülerin hazır veri setindeki yapıya uygun hale getirilmesinde kullanılmıştır.

Elde edilen sonuçlar incelendiğinde derin öğrenme modellerinin Beyin MR görüntülerinden tümörlü bölge tespitinin başarı oranını arttırmada görüntü verilerinin çoğaltılmasının önemli bir rol oynadığı görülmüştür. Çalışma sonucunda DCGAN mimarisi ile beyin MR görüntülerinin başarılı bir şekilde üretilbildiği ve üretilen bu görüntülerin derin öğrenme modellerinin başarılarını arttırdığı kanıtlanmıştır. Bu nedenle hazırlanan tez çalışmasında bu şekilde yenilikçi bir yöntemin uygulamadaki modelde kullanılmasının tez çalışmasının özgün değerine önemli bir katkıda bulunacağı öngörülmektedir.

KAYNAKLAR

- Abdel-Jaber, H., Devassy, D., Salam, A. A., Hidaytallah, L., & EL-Amir, M. (2022). A Review of Deep Learning Algorithms and Their Applications in Healthcare. *Algorithms*, 15(2), 71.
- Ali, H., & Shah, Z. (2022). Combating COVID-19 Using Generative Adversarial Networks and Artificial Intelligence for Medical Images: Scoping Review. *JMIR Med Inform*, 10(6).
- Ali, H., & Shah, Z. (2022). Combating COVID-19 Using Generative Adversarial Networks and Artificial Intelligence for Medical Images: Scoping Review. *JMIR Med Inform*, 10(6).
- Alqazzaz, S., Sun, X., Yang, X., & Nokes, L. (2019). Automated brain tumor segmentation on multi-modal MR image using SegNet. *Computational Visual Media*, 5(2), 209–219.
- Anitha, R., & Siva Sundhara Raja, D. (2017). Segmentation of glioma tumors using convolutional neural networks. *WILEY*, 27,354-360.
- Arı, A. (2019, Haziran). DERİN ÖĞRENME TABANLI BEYİN MR GÖRÜNTÜLERİNDEN BEYİN TÜMÖRLERİNİN TESPİT EDİLMESİ VE SINIFLANDIRILMASI. İnönü Üniversitesi Fen Bilimleri Enstitüsü.
- Arjovsky, M., Chintala, S., & Bottou, L. (2017). Wasserstein GAN. *arXiv:1701.07875*.
- Ayadi, W., Elhamzi, W., & Charfi, I. (2021). Deep CNN for Brain Tumor Classification. *Neural Processing Letters*, 53, 671-700.
- Aydoğdu, A., Aydoğdu, Y., & Yakıncı, Z. D. (2017). Temel Radyolojik İnceleme Yöntemlerini Tanıma. İnönü Üniversitesi Sağlık Hizmetleri Meslek Yüksekokulu Dergisi, 5(2), 44-53.
- Barbedo, J. (2018). Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification. *Computers and Electronics in Agriculture*, 153, 46-53.
- Bauer, S., Wiest, R., Nolte, L., & Reyes, M. (2013). A survey of MRI-based medical image analysis for brain tumor studies. *Physics in Medicine & Biology*, 58(13), 97-129.
- Carreon, A., Barwey, S., & Raman, V. (2023). A generative adversarial network (GAN) approach to creating synthetic flame images from experimental data. *Energy and AI*, 13.
- Chen, H., Qin, Z., Ding, Y., Tian, L., & Qin, Z. (2020). Brain tumor segmentation with deep convolutional symmetric neural network. *Neurocomputing*, 392, 305-313.

- Chen, X., Duan, Y., Houthoof, R., Schulman, J., Sutskever, I., & Abbeel, P. (2016). InfoGAN: Interpretable Representation Learning by Information Maximizing Generative Adversarial Nets. arXiv:1606.03657.
- Çelik, G., & Talu, M. F. (2020). Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi. BAUN Fen Bil. Enst. Dergisi (22), 181-192.
- Daimary, D., Bora, M., Amitab, K., & Kandar, D. (2019). Brain Tumor Segmentation from MRI Images using Hybrid Convolutional Neural Networks. International Conference on Computational Intelligence and Data Science.
- Dandıl, E. (2015). MR Görüntüleri ve MR Spektroskopi Verileri ile Yapay Öğrenme Tabanlı Beyin Tümörü Tespit Yöntemi ve Uygulaması. Sakarya Üniversitesi Fenbilimleri Enstitüsü, Doktora Tezi, 179, Sakarya.
- Dawson, H. L., Dubrule, O., & John, C. M. (2023). Impact of dataset size and convolutional neural network architecture on transfer learning for carbonate rock classification. Computers & Geosciences, 171.
- Demir, F., Akbulut, Y., Taşcı, B., & Demir, K. (2023). Improving brain tumor classification performance with an effective approach based on new deep learning model named 3ACL from 3D MRI data. Biomedical Signal Processing and Control, 81.
- Doğan, F., & Türkoğlu, İ. (2018). Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının. SAKARYA UNIVERSITY JOURNAL OF COMPUTER AND INFORMATION SCIENCES, 1(1), 10-21.
- Doğan, F., & Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. DÜMF Mühendislik Dergisi 10(2),409-445.
- Dong, H., Yang, G., Liu, F., Mo, Y., & Guo, Y. (2017). Automatic Brain Tumor Detection and Segmentation Using U-Net Based Fully Convolutional Networks. Communications in Computer and Information Science, 723,506-517. Springer, Cham.
- Eker, A., & Duru, N. (2021). Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları. ACTA INFOLOGICA, 5(2), 459 - 474.
- Elman, J. L. (1990). Finding Structure in Time. Cognitive Science, 14(2), 179-211.
- Fang, Y., Wang, J., Chen, S., Shen, S., Zhang, Z., & Hu, W. (2019). Impact of Dataset Size on Deep Learning-Based Auto Segmentation for Head and Neck Cancer. International Journal of Radiation Oncology* Biology*Physics, 105 (1).
- Faragallah, O. S., El-Hoseny, H. M., & El-Sayed, H. (2023). Efficient brain tumor segmentation using OTSU and K-means clustering in homomorphic transform. Biomedical Signal Processing and Control, 84.
- Frid-Adar, M., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018). Synthetic data augmentation using GAN for improved liver lesion

- classification. IEEE 15th International Symposium on Biomedical Imaging, 289-293.
- Frid-Adar, M., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018). Synthetic data augmentation using GAN for improved liver lesion classification. IEEE 15th International Symposium on Biomedical Imaging, 289-293.
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Bengio, Y. (2014). Generative Adversarial Nets. Proceedings of the 27th International Conference on Neural Information Processing Systems, 2, 2672-2680.
- Goodfellow, I., Bengio, Y., & Courville, A. (2015). Deep Learning.
- Graves, A. (2012). Long Short-Term Memory. Supervised Sequence Labelling with Recurrent Neural Networks, 385, 37-45.
- Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., & Courville, A. C. (2017). Improved Training of Wasserstein GANs. In Proceedings of the Advances in Neural Information Processing Systems, 5769–5779.
- Halk Sağlığı Genel Müdürlüğü, T. (2017). Kanser Nedir Belirtileri. Erişim Tarihi:01.15.2023. <https://hsgm.saglik.gov.tr/tr/kanser-nedir-belirtileri.html#:~:text=Kelime%20anlam%C4%B1%20olarak%20kanser%2C%20bir,100'den%20fazla%20hastal%C4%B1k%20grubudur>
- Halk Sağlığı Genel Müdürlüğü, T. (2017). Kanserin Nedenleri ve Sık Görülen Kanseler. Erişim Tarihi:01.15.2023. <https://hsgm.saglik.gov.tr/tr/kanser-nedir-belirtileri/kanser-nedir-belirtileri1/kanserin-nedenleri-ve-s%C4%B1k-g%C3%B6r%C3%BClen-kanseler.html>
- Havaei, M., Davy, A., Warde-Farley, D., Biard, A., Courville, A., Bengio, Y., . . . Larochelle, H. (2017). Brain tumor segmentation with Deep Neural Networks. Medical Image Analysis, 35, 18-31.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770-778.
- Huang, L., Zhu, E., Chen, L., Wang, Z., Chai, S., & Zhang, B. (2022). A transformer-based generative adversarial network for brain tumor segmentation. Frontiers in Neuroscience, 1-15.
- Jwaid, W. M., Al-Husseini, Z. S., & Sabry, A. H. (2021). Development of Brain Tumor Segmentation of Magnetic Resonance Imaging (MRI) Using U-Net Deep Learning. Eastern-European Journal of Enterprise Technologies, 4(9), 23-31.
- Karpathy, A., & Fei-Fei, L. (2015). Deep Visual Semantic Alignments for Generating Image Descriptions. CVPR, 3128-3137.

- Kazuhiro, K., Werner, R. A., Toriumi, F., Javadi, M. S., Pomper, M. G., Solnes, L. B., Rowe, S. P. (2018). Generative Adversarial Networks for the Creation of Realistic Artificial Brain Magnetic Resonance Images. *Tomography*, 4(4), 159–163.
- Kızrak, A. (2018). DERİNE DAHA DERİNE: Evrişimli Sinir Ağları. Medium, Erişim Tarihi: 19.03.2023: <https://ayyucekizrak.medium.com/deri%CC%87ne-daha-deri%CC%87ne-evri%CC%87fimli-sinir-a%C4%9Flar%C4%B1-2813a2c8b2a9>
- Kızrak, A. (2019). Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması. Medium Erişim Tarihi: 13.03.2023: <https://ayyucekizrak.medium.com/derin-%C3%B6%C4%9Frenme-i%C3%A7in-aktivasyon-fonksiyonlar%C4%B1n%C4%B1n-kar%C5%9F%C4%B1la%C5%9F%C4%B1r%C4%B1lmas%C4%B1-cee17fd1d9cd>
- Langr, J., & Bok, V. (2019). GANs in Action-Deep learning with Generative Adversarial Networks. Manning.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-44.
- Liang, Z., & Lauterbur, P. (1999). Principles of Magnetic Resonance Imaging: A Signal Processing Perspective. Wiley-IEEE Press, 432, .
- Liu, R., Liu, W., Zheng, Z., Wang, L., Mao, L., Qiu, Q., & Ling, G. (2023). Anomaly-GAN: A data augmentation method for train surface anomaly detection. *Expert Systems with Applications*, 228.
- Liu, Y., Zhang, J., Zhao, T., & Wang, Z. (2023). Reconstruction of the meso-scale concrete model using a deep convolutional generative adversarial network (DCGAN). *Construction and Building Materials*, 370.
- Liu, Y., Zhang, J., Zhao, T., & Wang, Z. (2023). Reconstruction of the meso-scale concrete model using a deep convolutional generative adversarial network (DCGAN). *Construction and Building Materials*, 370.
- Mao, X., Li, Q., Xie, H., Lau, R. Y., Wang, Z., & Smolley, S. (2016). Least Squares Generative Adversarial Networks. arXiv:1611.04076.
- Marcinkiewicz, M., Nalepa, J., Lorenzo, P., Dudzik, W., & Mrukwa, G. (2019). Segmenting Brain Tumors from MRI Using Cascaded Multi-modal U-Nets. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries s:13-24.
- Mehta, R., & Arbel, T. (2019). 3D U-Net for Brain Tumour Segmentation. Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. BrainLes 2018, Lecture Notes in Computer Science, vol 11384. Springer. Cham.

- Michelucci, U. (2022). An Introduction to Autoencoders. arXiv preprint arXiv:2201.03898.
- Mikolov, T., Karafiat, M., Burget, L., Černocký, J., & Khudanpur, S. (2010). Recurrent neural network based language model. . Interspeech.
- Mirza, M., & Osindero, S. (2014). Conditional Generative Adversarial Nets. arXiv:1411.1784v1.
- Mlynarski, P., Delingette, H., Criminisi, A., & Ayache, N. (2019). 3D convolutional neural networks for tumor segmentation using long-range 2D context. *Computerized Medical Imaging and Graphics*, 73, 60-72.
- Mzoughi, H., Njeh, I., Wali, A., Slima, M. B., Hamida, A. B., Mhiri, C., & Mahfoudhe, K. B. (2020). Deep Multi-Scale 3D Convolutional Neural Network (CNN) for MRI Gliomas Brain Tumor Classification. *Journal of Digital Imaging*, 33, 903–915.
- Mzoughi, H., Njeh, I., Wali, A., Slima, M. B., Hamida, A. B., Mhiri, C., & Mahfoudhe, K. B. (2020). Deep Multi-Scale 3D Convolutional Neural Network (CNN) for MRI Gliomas Brain Tumor Classification. *Journal of Digital Imaging*, 33, 903–915.
- Naceur, M. B., Akil, M., Saouli, R., & Kachouri, R. (2020). Fully automatic brain tumor segmentation with deep learning-based selective attention using overlapping patches and multi-class weighted cross-entropy . *Medical Image Analysis*, 63, 1-20.
- National Cancer Institute. (2021). About Rare Brain and Spine Tumors. National Cancer Institute. Erişim Tarihi: 03.03.223: <https://www.cancer.gov/rare-brain-spine-tumor/tumors/about-cns-tumors>
- National Cancer Institute. (2023). Cancer Stat Facts: Brain and Other Nervous System Cancer. National Cancer Institute. Erişim Tarihi: 03.03.223. <https://seer.cancer.gov/statfacts/html/brain.html>
- Odena, A. (2016). Semi-Supervised Learning with Generative Adversarial Networks. arXiv:1606.01583v2.
- Palakonda, V., Kang, J. M., & Jung, H. (2023). An effective ensemble framework for Many-Objective optimization based on AdaBoost and K-means clustering. *Expert Systems with Applications*, 227.
- Pedada, K. R., Bhujanga, R. A., Patro, K. K., Allam, J. P., Jamjoom, M. M., & Samee, N. A. (2023). A novel approach for brain tumour detection using deep learning based technique. *Biomedical Signal Processing and Control*, 82.
- Pereira, S., Pinto, A., Alves, V., & Silva, C. (2016). Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images. *IEEE Transactions on Medical Imaging*, 35(5), 1240-1251.

- Pollastri, F., Bolelli, F., Palacios, R. P., & Grana, C. (2018). Improving Skin Lesion Segmentation with Generative Adversarial Networks. IEEE 31st International Symposium on Computer-Based Medical Systems, 442-443.
- Pollastri, F., Bolelli, F., Palacios, R. P., & Grana, C. (2018). Improving Skin Lesion Segmentation with Generative Adversarial Networks. IEEE 31st International Symposium on Computer-Based Medical Systems, (s. 442-443).
- Radford, A., Metz, L., & Chintala, S. (2016). Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. arXiv:1511.06434.
- Radford, A., Metz, L., & Chintala, S. (2016). Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks.
- Raja, M., & Vijayachitra, S. (2023). A hybrid approach to segment and detect brain abnormalities from MRI scan. Expert Systems with Applications, 16, 1-9.
- Ramasamy, G., Singh, T., & Yuan, X. (2023). Multi-Modal Semantic Segmentation Model using Encoder Based Link-Net Architecture for BraTS 2020 Challenge. Procedia Computer Science, 218, 732-740.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, 234-241. Munich.
- Russell, S., Norvig, P., & Davis, E. (2003 [1995]). Artificial Intelligence - A Modern Approach (Third Edition). New Jersey: Pearson Education.
- Sajjad, M., Khan, S., Khan, M., Wu, W., Ullah, A., & Baik, S. (2019). Multi-grade brain tumor classification using deep CNN with extensive data augmentation. Journal of Computational Science, 30,174-182.
- Seetha, J., & Raja, S. S. (2018). Brain Tumor Classification Using Convolutional Neural Networks. Biomedical and Pharmacology Journal, 11(3),1457-1461.
- Shehab, L. H., Fahmy, O. M., Gasser, S. M., & El-Mahallawy, M. S. (2020). An efficient brain tumor image segmentation based on deep residual networks (ResNets). Journal of King Saud University – Engineering Sciences.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. Journal of Big Data, 6(60).
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. CoRR 1409(1556).
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. Gazi Mühendislik Bilimleri Dergisi, 3(3), 47-64.
- Türkiye Kanserle Savaş Vakfı. (2021). Kanser Türleri - Beyin Tümörleri. Erişim Tarihi:2023. <https://www.kanservakfi.com/kanser-turleri/beyin-tumorleri/>

- World Health Organization. (2020). Cancer. Eriřim Tarihi:12.02.2023. <https://www.who.int/news-room/fact-sheets/detail/cancer>
- Wu, M.-N., Lin, C.-C., & Chang, C.-C. (2007). Brain Tumor Detection Using Color-Based K-Means Clustering Segmentation. Third International Conference on Intelligent Information Hiding and Multimedia Signal Processing, 245-250.
- Wu, X., Xu, K., & Hall, P. (2017). A survey of image synthesis and editing with generative adversarial networks. Tsinghua Science and Technology(22), 660-674.
- Wu, X., Xu, K., & Hall, P. (2017). A survey of image synthesis and editing with generative adversarial networks. Tsinghua Science and Technology, 22,660-674.
- Yurtsever, U. (2019). BÖLÜTLENMİř HİSTOPATOLOJİK GÖRÜNTÜLER ÜZERİNDE DERİN ÖĞRENME YÖNTEMİYLE KOLON KANSERİ TESPİTİ. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 145s, Sakarya.
- Zeineldin, R. A., Karar, M. E., Coburger, J., Wirtz, C. R., & Burgert, O. (2020). DeepSeg: deep neural network framework for automatic brain tumor segmentation using magnetic resonance FLAIR images. International Journal of Computer Assisted Radiology and Surgery, 15, 909-920.
- Zeineldin, R. A., Karar, M. E., Coburger, J., Wirtz, C. R., & Burgert, O. (2020). DeepSeg: deep neural network framework for automatic brain tumor segmentation using magnetic resonance FLAIR images. International Journal of Computer Assisted Radiology and Surgery,15, 909-920.
- Zhao, Z., Zhang, Z., Chen, T., Singh, S., & Zhang, H. (2020). Image Augmentations for GAN Training.
- Zhengxin, Z., Qingjie, L., & Wang, Y. (2018). Road Extraction by Deep Residual U-Net. Road Extraction by Deep Residual U-Net, 15(5), 749-753.
- Zijdenbos, A. P., Dawant, B. M., Margolin, R. A., & Palmer, A. C. (1994). Morphometric analysis of white matter lesions in MR images: method and validation. IEEE Transactions on Medical Imaging, 13(4), 716-724.
- Zijdenbos, A. P., Dawant, B. M., Margolin, R. A., & Palmer, A. C. (1994). Morphometric analysis of white matter lesions in MR images: method and validation. IEEE Transactions on Medical Imaging, 13(4), 716-724.