

T.C.  
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
YAPAY ZEKA VE ROBOTİK ANABİLİM DALI

**U-NET DERİN ÖĞRENME MODELLERİ KULLANILARAK BEYİN TÜMÖRÜ  
TESPİTİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Merve KAYAR  
DANIŞMAN: Prof. Dr. Rıdvan SARAÇOĞLU

VAN-2022



T.C.  
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
YAPAY ZEKA VE ROBOTİK ANABİLİM DALI

**U-NET DERİN ÖĞRENME MODELLERİ KULLANILARAK BEYİN TÜMÖRÜ  
TESPİTİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Merve KAYAR

Bu çalışma YYÜ Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu tarafından  
2021/05-28 No'lu proje olarak desteklenmiştir.

VAN-2022



## KABUL VE ONAY SAYFASI

Yapay Zeka ve Robotik Anabilim Dalı'nda Prof. Dr. Rıdvan SARAÇOĞLU danışmanlığında, Merve KAYAR tarafından sunulan “U-NET DERİN ÖĞRENME MODELLERİ KULLANILARAK BEYİN TÜMÖRÜ TESPİTİ” isimli bu çalışma Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili hükümleri gereğince ...../...../..... tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile başarılı bulunmuş ve yüksek lisans tezi olarak kabul edilmiştir.

Başkan:.....

İmza:

Üye:.....

İmza:

Üye:.....

İmza:

Üye:.....

İmza:

Üye:.....

İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ...../...../..... tarih ve ..... sayılı kararı ile onaylanmıştır.

İmza

.....  
Enstitü Müdürü



## TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Merve KAYAR





## ÖZET

### U-NET DERİN ÖĞRENME MODELLERİ KULLANILARAK BEYİN TÜMÖRÜ TESPİTİ

KAYAR, Merve

Yüksek Lisans Tezi, Yapay Zeka ve Robotik Anabilim Dalı

Tez Danışmanı: Prof. Dr. Rıdvan SARAÇOĞLU

Ocak 2022, 67 sayfa

Tıbbi görüntü işleme, çeşitli tıbbi problemlerde; kanser, diyabet vb. hastalıkların teşhisinde yaygın olarak kullanılmaktadır. Kanser hastalığı son zamanlarda artış gösteren ve ölüme sebebiyet veren ciddi bir rahatsızlıktır. Sağlık alanında en çok ihtiyaç duyulan konulardan biri de vücuttaki kanserli bölgenin erken sürede teşhisidir. Manyetik rezonans görüntüleme ile elde edilen görüntülerden beyin tümörünü otomatik olarak tespit eden bir uygulama, sağlık çalışanlarına zaman kazandırırken; kanserde daha erken teşhise olanak sağlarken insandan kaynaklı hata oranını da en aza indirebilir. Bu tez çalışmasında beyin tümörünün teşhisi için Klasik U-net, U-Net+VGG16, U-Net+ResNet50 ve U-Net++ Evrişimli Sinir Ağları önerilmiştir. Bu yöntemler ile tümör segmentasyonu gerçekleştirilmiş ve tahminler oluşturulmuştur. Sonuçlar, dice coefficient, hassaslık, özgülük ve Jaccard İndeksi olarak verilmiş ve bu oranlar karşılaştırılmıştır. Uygulama sonuçları karşılaştırıldığında, en yüksek doğruluk değerine U-Net++ ile ulaşıldığı görülmüştür.

**Anahtar kelimeler:** Beyin Tümörü, Bilgisayar Destekli Teşhis, Manyetik Rezonans Görüntüleme, Görüntü İşleme, U-Net, Evrişimli Sinir Ağı



## ABSTRACT

### BRAIN TUMOR DETECTION USING U-NET DEEP LEARNING MODELS

KAYAR, Merve

M. Sc., Artificial Intelligence and Robotics  
Supervisor: Prof. Dr. Rıdvan SARAÇOĞLU

January 2022, 67 pages

Medical image processing, in various medical problems; cancer, diabetes etc. It is widely used in the diagnosis of diseases. Cancer is a serious disease that has increased in recent years and caused death. One of the most needed issues in the field of health is the early diagnosis of the cancerous area in the body. An application that automatically detects a brain tumor from images obtained with magnetic resonance imaging saves time for healthcare professionals; While it enables earlier diagnosis in cancer, it can also minimize the human error rate. In this thesis, Classical U-net, U-Net+VGG16, U-Net+ResNet50 and U-Net++ Convolutional Neural Networks are proposed for the diagnosis of brain tumor. With these methods, tumor segmentation was performed and predictions were created. The results were given as dice coefficient, sensitivity, specificity and Jaccard Index and these ratios were compared. When the application results were compared, it was seen that the highest accuracy value was achieved with U-Net++.

**Keywords:** Brain Tumor, Computer Assisted Diagnosis, Magnetic Resonance Imaging, Image Processing, U-Net, Convolutional Neural Networks



## ÖN SÖZ

Bu tez çalışmasında, ilgi ve yardımlarını esirgemeyen danışmanım Sayın Prof. Dr. Rıdvan SARAÇOĞLU'na, her zaman yanımda olan başta annem Zeynep KAYAR ve babam Abdülmecit KAYAR olmak üzere tüm geniş aileme teşekkür ederim.

2022

Merve KAYAR



# İÇİNDEKİLER

	<b>Sayfa</b>
ÖZET .....	i
ABSTRACT .....	iii
ÖN SÖZ.....	v
İÇİNDEKİLER.....	vii
ÇİZELGELER LİSTESİ .....	ix
ŞEKİLLER LİSTESİ.....	xi
SİMGELER VE KISALTMALAR .....	xv
1. GİRİŞ.....	1
2. KAYNAK BİLDİRİŞLERİ .....	3
3. MATERYAL VE YÖNTEM.....	7
3.1. Beyin yapısı ve bölümleri.....	8
3.1.1. Beyin tümörü ve çeşitleri.....	9
3.1.2. Beyin tümörünün sınıflandırılması .....	10
3.2. Beyin görüntüleme teknikleri .....	13
3.2.1. Manyetik rezonans görüntüleme.....	13
3.2.2. Bilgisayarlı tomografi .....	15
3.2.3. Pozitron emisyon tomografisi .....	16
3.2.4. Tek foton emisyon BT .....	16
3.2.5. Manyetoensefalografi .....	16
3.2.6. X-ışınları (X-rays) .....	16
3.2.7. Laboratuvar testleri ve biyopsi .....	17
3.3. Evrişimli sinir ağları .....	17
3.4. Klasik U-Net .....	18
3.5. VGG16.....	21
3.6. ResNet50.....	22
3.7. U-net++ .....	26
3.8. Uygulama sonuçlarının değerlendirilmesi .....	29

	<b>Sayfa</b>
4. BULGULAR .....	33
4.1. BraTS veri setinde bulunan HGG ve LGG beyin tümörü görüntüleri.....	33
4.2. Klasik U-Net modelli ağ sonuçlarının değerlendirilmesi .....	35
4.3. U-Net + VGG16 ağ sonuçlarının değerlendirilmesi .....	41
4.4. U-Net + ResNet50 ağ sonuçlarının değerlendirilmesi.....	45
4.5. U-Net++ ağ sonuçlarının değerlendirilmesi .....	49
4.6. U-Net ve U-Net++ ağların farklı veri seti ile değerlendirilmesi.....	55
5. TARTIŞMA VE SONUÇ.....	61
KAYNAKLAR.....	63
ÖZGEÇMİŞ.....	67

## ÇİZELGELER LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Merkezi sinir sistemi tümörlerinin WHO'ya göre sınıflandırılması..	12
Çizelge 3.2. Karışıklık matrisi.....	29
Çizelge 4.2. Beyin tümörü çalışmalarının karşılaştırılması.....	59





## ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 3.1. Beynin temel bölümleri .....	8
Şekil 3.2. İnsan beyinde bulunan loblar .....	9
Şekil 3.3. Damadian'ın kanser tespiti için geliştirdiği MRG metodu .....	13
Şekil 3.4. Beynin MR görüntüsüne ait kesit görünümeler .....	14
Şekil 3.5. (a) T1-ağırlıklı MRG, (b) T2-ağırlıklı MRG, (c) Flair MRG.....	14
Şekil 3.6. Klasik U-Net modeli .....	19
Şekil 3.7. 3x3 Evrişim ve ReLU gösterimi.....	20
Şekil 3.8. 2x2 Yukarı Evrişim (up-convolution) gösterimi .....	20
Şekil 3.9. VGG16 mimarisi .....	21
Şekil 3.10. 20 katmanlı Ağ ve 56 katmanlı ağ için eğitim ve test verilerindeki hata yüzdeleri .....	22
Şekil 3.11. Residual blok şeması .....	23
Şekil 3.12. ResNet bloku ve 1×1 evrişim içeren ResNet bloku .....	24
Şekil 3.13. VGG-19, 34 parametre katmanına sahip düz bir ağ ve 34 parametre katmanına sahip artık bir ağ modeli.....	25
Şekil 3.14. UNet++ modeli.....	26
Şekil 3.15. UNet++'ın ilk atlama yolunun ayrıntılı analizi.....	27
Şekil 3.16. U-Net++ derin denetim .....	28
Şekil 4.1. Aksiyel HGG beyin tümörü MRI örnekleri .....	33
Şekil 4.2. Sagittal HGG beyin tümörü MRI örnekleri.....	33
Şekil 4.3. Koronal HGG beyin tümörü MRI örnekleri.....	34
Şekil 4.4. Aksiyel LGG beyin tümörü MRI örnekleri.....	34
Şekil 4.5. Sagittal LGG beyin tümörü MRI örnekleri .....	34

## Sayfa

Şekil 4.6. Eğitim için segmente edilen HGG tümör örnekleri.....	35
Şekil 4.7. Eğitim için segmente edilen LGG tümör örnekleri .....	36
Şekil 4.8. Segmente edilen tümörlerin U-Net performans grafikleri .....	37
Şekil 4.9. Segmente edilen tümörlerin U-Net performans grafikleri .....	38
Şekil 4.10. HGG MR görüntüsü, orijinal maske ve tahmin edilen değerler.....	39
Şekil 4.11. LGG MR görüntüsü, orijinal maske ve tahmin edilen değerler .....	40
Şekil 4.12. Segmente edilen tümörlerin U-Net + VGG16 performans grafikleri....	41
Şekil 4.13. Segmente edilen tümörlerin U-Net + VGG16 performans grafikleri....	42
Şekil 4.14. HGG MR görüntüsü, orijinal maske ve tahmin edilen değerler.....	43
Şekil 4.15. LGG MR görüntüsü, orijinal maske ve tahmin edilen değerler .....	44
Şekil 4.16. Segmente edilen tümörlerin U-Net + ResNet50 performans grafikleri	45
Şekil 4.17. Segmente edilen tümörlerin U-Net + ResNet50 performans grafikleri	46
Şekil 4.18. HGG MR görüntüsü, orijinal maske ve tahmin edilen değerler.....	47
Şekil 4.19. LGG MR görüntüsü, orijinal maske ve tahmin edilen değerler .....	48
Şekil 4.20. Eğitim için segmente edilen HGG tümör örnekleri.....	49
Şekil 4.21. Eğitim için segmente edilen LGG tümör örnekleri .....	50
Şekil 4.22. Segmente edilen tümörlerin U-Net++ performans grafikleri .....	51
Şekil 4.23. Segmente edilen tümörlerin U-Net++ performans grafikleri .....	52
Şekil 4.24. HGG MR görüntüsü, orijinal maske ve tahmin edilen değerler.....	53
Şekil 4.25. LGG MR görüntüsü, orijinal maske ve tahmin edilen değerler .....	54
Şekil 4.26. U-Net için MR görüntüsü, orijinal maske ve tahmin edilen değerler ...	55
Şekil 4.27. U-Net + VGG16 için MR görüntüsü, orijinal maske ve tahmin edilen değerler .....	56

Şekil 4.28. U-Net + ResNet50 için MR görüntüsü, orijinal maske ve tahmin edilen değerler.....57

Şekil 4.29. U-Net++ için MR görüntüsü, orijinal maske ve tahmin edilen değerler .....58





## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

<b>Kısaltmalar</b>	<b>Açıklama</b>
<b>AlexNet</b>	Alex Network
<b>BESA</b>	Bölgesel Sinir Ağları
<b>BraTS</b>	Brain Tumor Segmentation
<b>BT</b>	Bilgisayarlı Tomografi
<b>CNN</b>	Convolutional Neural Networks
<b>CT</b>	Computed Tomography
<b>DNA</b>	Deoksiribo Nükleik Asit
<b>DNT</b>	Dysmbryoplastic neuroepithelial tumor
<b>DWT</b>	Discrete Wavelet Transform
<b>ESA</b>	Evrşimsel Sinir Ağları
<b>FLAIR</b>	Fluid Attenuated Inversion Recovery
<b>GAN</b>	Generative Adversarial
<b>GBM</b>	Glioblastoma
<b>GLCM</b>	Gray Level Co-occurrence Matrix
<b>GPU</b>	Graphics Processing Unit
<b>HGG</b>	High Grade Glioma
<b>LGG</b>	Low Grade Glioma
<b>MEG</b>	Magneto Encephalo Graphy
<b>MR</b>	Manyetik Rezonans
<b>MRG</b>	Manyetik Rezonans Görüntüleme
<b>MRI</b>	Magnetic Resonance Imaging
<b>MSS</b>	Merkezi Sinir Sistemi
<b>PET</b>	Positron Emission Tomography
<b>PFS</b>	Potential field Segmentation

<b>PSVM</b>	Proksimal Support Vector Machine
<b>ReLU</b>	Rectified Linear Units
<b>ResNet</b>	Residual Networks
<b>SOM</b>	Self-Organizing Maps
<b>SVM</b>	Support Vector Machine
<b>T1</b>	T1 Dinlenme (Relaxation) Zamanı
<b>T2</b>	T2 Dinlenme (Relaxation) Zamanı
<b>U-Net</b>	U Networks
<b>VGG</b>	Visual Geometry Group
<b>WHO</b>	World Health Organization



## 1. GİRİŞ

İnsan vücudundaki hücreler, yeni doğan bireylerde gelişimlerini tamamlayana kadar hızla bölünmektedir. Yetişkin insanlarda ise hasarlı olan hücrelerin yerine veya ölen hücrelerin yerini almak için bölünme gerçekleşmektedir. Fakat bu hücreler kontrol dışında büyür, normal hücrelere kıyasla değişikliklere sebep olursa kanserli hücre olarak nitelendirilir. Kalıtsal olayların gerçekleştiği yer olan DNA, bir hasar ile karşılaştığında bunu onarır. Fakat hücrenin kanserli olması durumunda DNA hücreyi onaramaz veya öldüremez. Hücrelerin kontrol dışında büyüyerek diğer dokulara yayılması ile yeni hücreler de hızla oluşturulmaya başlar. Yeni oluşan bu hücrelerin DNA'ları hasarlı olur (Dandıl, 2015).

Günümüzde tümör tespitinde Manyetik Rezonans Görüntüleme ve Bilgisayarlı Tomografi gibi cihazlar kullanılmaktadır. MRG'nin 1970'den bu yana kullanılması giderek yaygınlaşmış ve tümör tespiti için uzmanlara yardımcı olmaktadır. Fakat bu cihazlar tümör için otomatik bir tespit vermedikleri için tamamen insan gözü ile tanınmakta, bu da hata ve hasta sayısına bağlı olarak fazla zaman ve konsantrasyon kaybını beraberinde getirmektedir. Yalnızca Amerika Birleşik Devletleri ele alındığında, birincil beyin tümörü ile yaşayan 700.000 kişi vardır. Tüm Dünya genelinde tümör çeşitleri ve insan sayısı düşünülünce otomatik bir tümör tespit sisteminin var olması hem sağlıkçılar açısından hem de hastalar için oldukça yararlı olacaktır. Görüntü işleme tekniklerindeki tüm ilerlemeler sayesinde sağlık sistemindeki aksaklıklar ve hatalar en aza indirgenebilir (Dandıl, 2015).

Görüntü bölütleme iki aşamadan oluşmaktadır: Tanıma ve Tanımlama. Tanıma işlemi ile nesnenin nerede olduğu kabaca belirlenir. Tanımlama da ise nesnenin olduğu bölge ve boyutları belirlenir (Kaya ve ark., 2016; Chen ve ark., 2012). Görüntü bölütleme, bir görüntünün analiz edilmesini kolaylaştırır fakat bu görüntüyü yorumlamak için asıl yapılması gereken görüntüleri sınıflandırmaktır. Anlamsal segmentasyonda her piksele bir sınıf etiketi atanır, sonrasında birleştirilen bu pikseller görüntüdeki bölümlere karşılık gelir.

Bu tez çalışmasında, literatürdeki beyin tümörü tespit yaklaşımlarına ek olarak yeni yaklaşımlar önerilmiştir. Klasik U-Net, U-Net + VGG16, U-Net + ResNet50 ve U-

Net++ teknikleri önerilmiştir. Önerilen yöntemlerin her biri bölütleme (segmentation) ve kitle tespiti (detection) olmak üzere iki aşamadan oluşmaktadır. Görüntü bölütleme, tanıma ve tanımlama olmak üzere iki aşamadan oluşmaktadır.. Tanıma işlemi ile nesnenin nerede olduğu kabaca belirlenir. Tanımlama da ise nesnenin olduğu bölge ve boyutları belirlenir.

Çalışmada, hem eğitim hem de test verisi için BraTS 2019 veri seti (Bakas, 2019) kullanılmıştır. Eğitilen ağlar, Figshare veri seti (Jun, 2017)'nde bulunan beyin tümörü MR görüntüleri üzerinde ayrıca uygulanmış ve değerlendirilmiştir. Karışıklık matrisinden elde edilen dice coefficient, hassaslık, özgüllük ve Jaccard İndeksi parametreleri ile doğruluk yüzdeleri verilmiştir.



## 2. KAYNAK BİLDİRİŞLERİ

Bu bölümde bilgisayar destekli beyin tümörü tespiti için yapılmış önceki çalışmalara yer verilmiştir.

Kazdal ve ark. (2015), beyin Manyetik Rezonans görüntüleri ile tümör tespiti gerçekleştirmişlerdir. Çalışmada morfolojik özellikler ile kural tabanlı bir tespit sistemi ortaya konulmuştur. Sırasıyla ön işleme, bölütleme, ilgili alanları belirleme ve son olarak tümörün tespit edilmesi gerçekleştirilmiştir. Çalışma kapsamında 10 hastanın 497 beyin MR görüntüsü kullanılmış ve %84,26 oranında bir doğruluk elde edilmiştir.

Vaishnavee ve Amshakala (2015), yaptıkları çalışmada MRI beyin görüntü bölütlemesi için SOM kümeleme yöntemini önermişlerdir. Segmentasyondan önce, segmentasyon doğruluğunu artırmak için Histogram Eşitleme kullanılmıştır. Segmentasyon işleminden sonra Gri Düzey Oluşum Matrisi (Gray Level Co-occurrence Matrix) kullanılarak özellik çıkarımı yapılmıştır. Bu da orta kümelenmiş bölgelerin oluşumunu engeller. Öznitelik seçiminde Temel Bileşen Analizi (PCA) yöntemi, Sınıflandırıcı doğruluğunu iyileştirmek kullanılmıştır. Tümörü MRI beyin görüntüsünden otomatik bir şekilde tespit etmek için Proksimal Destek Vektör Makineleri (PSVM) kullanılmıştır. PSVM, SVM'ye göre hesaplama açısından daha verimli ve daha hızlıdır, tüm hacmin segmentasyonu için, SOM ile Histogram Eşitleme doku sınıflarını modellemek için bir yol sağlamıştır.

Arı ve Hanbay (2019), beyin MR görüntülerinde tümörün yerini kolayca tespit eden bir derin öğrenme mimarisi geliştirmişlerdir. Bu sistem derin öğrenme mimarilerinden biri olan Bölgesel Sinir Ağları (BESA) tabanlıdır. BESA, Evrişimsel Sinir Ağları (ESA) mimarisi kullanan bir yapıdır. Bu çalışmada Benchmark, Rembrandt ve Harvard veri setleri kullanılarak farklı BESA mimarileri tasarlanmıştır. Benchmark veri setinde geliştirilen BESA4 mimarisi ile %99,10 oranında en yüksek doğruluk ve %98,66 oranında ortalama doğruluk değerine ulaşılmıştır.

Demirhan ve Güler (2014) yaptıkları çalışmada, bir nöro-bulanık çıkarım sistemi ile beyin MR görüntülerini kurucu dokulara ayırdılar. T1, T2 ve FLAIR görüntüleri beyaz cevher, gri cevher, beyin omurilik sıvısı ve ödem ve tümör gibi hastalıklı dokulara böldüler. Çalışmanın dışında kalan kafatasını çıkartarak görüntülerde sadece

beyin dokusunu bırakmışlardır. Sistemin girdisi için durağan dalgacık dönüşüm katsayılarından elde edilen istatistiksel öznitelikler kullanılmıştır. Sistemden elde edilen sonuçlar manuel olarak bölütlenen doku alanları ile karşılaştırılmış ve Dice benzerlik indeksi ile değerlendirilmiştir. Nöro bulanık çıkarım sistemi beyin MR görüntülerini bölütlemeye oldukça yüksek performans göstermiştir.

Cabria ve Gondra (2016) BraTS MRI veri tabanını kullanarak bu beyin tümörlerini tespit etmek için Potansiyel Alan Segmentasyonu (PFS) adlı yeni bir algoritma ortaya koymuşlardır. PFS yöntemi bir kümeleme algoritmasıdır. MRG'deki bir pikselin yoğunluğu, potansiyel alan yaratan bir "kütle" olarak görülür. Spesifik olarak, MRG'deki her piksel için potansiyel alan hesaplanır ve adaptif potansiyel eşliğinden küçük ise, piksel tümör bölgesi ile ilişkilendirilir. Bu "küçük potansiyel" segmentasyon kriteri sezgisel olarak geçerlidir. Burada, tümör pikselleri daha büyük kütleyle sahip olduğu için çevreleyen bölgelerin potansiyeli de daha küçük veya kütlesi olmayan diğer bölgelerden çok daha büyüktür.

Anitha ve Raja (2017) yaptıkları çalışmada, beyin görüntüsünü normal veya anormal olarak sınıflandırmak amacı ile rastgele orman sınıflandırıcı tabanlı bir sistem önermişlerdir. İlk olarak ön işleme kısmında MR görüntülerine adaptif medyan filtre uygulanmıştır. Bunun sebebi görüntüdeki kenarlardaki kenar pikselleri korumaktır. Sonrasında tümörlü bölgeyi belirlemek için özellik çıkarımı uygulanmıştır. Tümörlü bölgeyi tümörsüz bölgeden ayırmak amacı ile, beyin görüntülerinin şiddet tanısını sınıflandırmak için ağırlıklı oylama tekniğini kullanan rastgele orman sınıflandırıcı kullanılmıştır.

Arunachalam ve Savarimuthu (2017) ortaya koyduğu bu çalışmada iyileştirme, dönüştürme, özellik çıkarma ve sınıflandırma yer almaktadır. Shift-invariant shearlet dönüşümü (SIST), beyin görüntüsünü geliştirmek için kullanılmıştır. Uzamsal alanla geliştirilmiş görüntüyü çok çözünürlüklü görüntüye dönüştürmek için çok çözünürlüklü dönüşüm olarak alt-örneklenmemiş dış hat dönüşümü kullanılmıştır. Gri Seviyeli Birlikte Oluşum Matrisi (GLCM), Gabor ve Ayrık Dalgacık Dönüşümünden (DWT) doku özellikleri, alt-örneklenmemiş dış hat dönüşümü görüntüsünün yaklaşık alt bandı ile çıkartılmıştır. Çıkarılan özellikler, sinir ağları kullanılarak normal ya da glioblastoma beyin görüntüsü olarak eğitilip ve sınıflandırılmıştır. Bununla beraber sınıflandırılmış glioblastoma beyin görüntüsündeki tümör bölgesini segmentlere ayırmak için K-

ortalamalar kümeleme algoritması kullanılmıştır. Bu çalışmada %99.8 doğruluk, %99.9 özgüllük ve %89.7 duyarlılık elde edilmiştir.





### 3. MATERYAL VE YÖNTEM

Framework, bilgisayar programlamada kullanılan kütüphane benzeri bir yapıdır. Fakat kütüphanede kodların genel akışı tanımlanmazken belirli bir görev için istenilen işlevler Framework'ta tanımlanır. Framework'ta Caffe, Theano, PyTorch ve Tensorflow gibi birçok derin öğrenme yöntemi vardır. Bu çalışmada, python programlama diline dayalı tensorflow kullanılmıştır. Tensorflow açık kaynak kodlu, Google tarafından desteklenmesi sayesinde geliştirilmekte olan bir yöntemdir. Bu çalışmada Google Colab Notebook, Python ve Tensorflow 1.6 kullanılmıştır. Eğitim 15 GB depolama alanına sahip Google Colab'ta gerçekleştirilmiştir. GPU işlemci kullanılmıştır.

Hem eğitim hem de değerlendirme için BraTS 2019 Veri Seti (Bakas, 2019) kullanılmıştır. Veri setinde 210 HGG ve 75 LGG olmak üzere 285 beyin görüntüsü vardır. Her hastanın olmak üzere 4 farklı MRG modalitesi vardır: T1, T2, T2 Flair ve T1c (kontrast maddeli T1). Bu modaliteler, 3B matrislerdir ve  $240 \times 240 \times 155$  boyutundadır. Kafatası ve göz gibi bölgeler olmadan sadece beyin dokusu vardır. Kafatasının çıkarılması için herhangi bir ön işleme gerek yoktur.


BraTS 2019 veri setinde 4 sınıf bulunmaktadır. Bunlar, peritümöral ödem, nekrotik-kontrastsız tümör (non-enhancing tumor), büyüyen tümör (enhancing tumor) ve arka plandır. Tüm tümör, büyüyen tümör, peritümöral ödem ve nekrotik-kontrastsız tümörden oluşurken; tümör çekirdeği, büyüyen tümör ve nekrotik-kontrastsız tümörün birleşimidir.

Büyüyen tümör, canlı olan tümör dokusudur ve malign hücreler içerir. Beynin diğer bölgelerine yayılmaya devam eder. Peritümöral ödem bölgesi genellikle kötü huylu tümöre tepki olarak hızla büyür, tümör çevresinde aşırı sıvı birikmesine karşılık gelir. Ödem büyüdükçe beynin diğer kısımlarına baskı yapar ve bu nedenle beynin diğer kısımlarına zarar verebilir. Nekrotik-kontrastsız tümör ise lezyonun malign olduğunun önemli belirtilerinden biridir ve bölgesi ölü dokuya karşılık gelir. Bu tez kapsamında eğitim ve değerlendirme aşamalarında tüm tümör üzerinde işlemler gerçekleştirilmiştir.

### 3.1. Beyin yapısı ve bölümleri

Beyin, insan vücudundaki en büyük ve karmaşık yapılardan biridir. Trilyonlarca bağlantıyla iletişim kuran 100 milyardan fazla sinirden ve birlikte çalışan birçok özel alandan oluşur (Hoffman, 2021).

Beyin üç temel bölümde incelenebilir: ön beyin, orta beyin ve arka beyin. Arka beyin, nefes alıp verme, kalp atış hızı gibi hayati öneme sahip fonsiyonları kontrol eder. Üç temel birime ayrılabilir: omuriliğin üst kısmı, beyin sapı ve serebellum. Orta beyin, beyin sapının üst kısmında yer alır, bazı refleks hareketlerin veya istemli hareketlerin kontrolünü sağlar. İnsan beyninin en büyük ve gelişmiş parçası ise ön beyindir: serebrum ve onun altındaki yapılardan oluşur. Beyin resimlerine bakınca gördüğümüz genellikle serebrumdur. Serebrum derin bir yarıkla iki yarım küreye ayrılır, iki yarıküre, birbirleri ile alt tabakada yer alan sinir lifleri aracılığı ile iletişim kurarlar (Anonim, 2021).

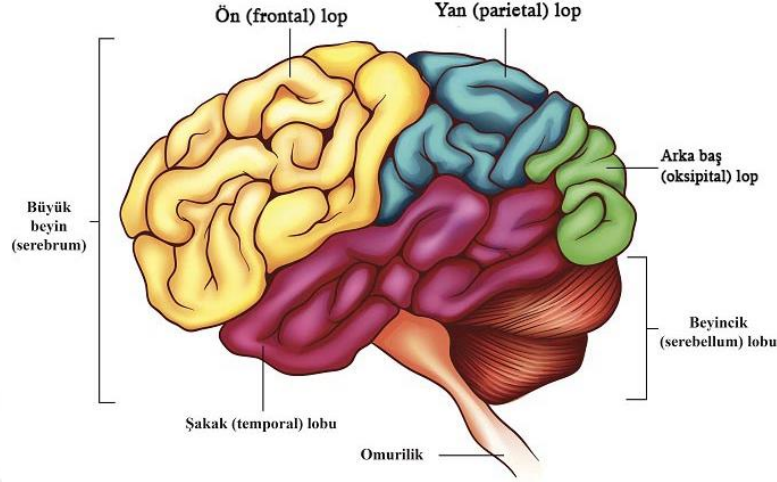


Şekil 3.1. Beynin temel bölümleri (Shah, 2019).

Beyin, vücudun kontrol merkezidir ve kalp, akciğerler gibi tüm organlar ile koordineli bir şekilde çalışır. Görme, duyma, koku alma, dokunma, tatma duyularımız beyine bağlıdır. Örneğin tat alma duyusu, damaktan alınan sinyaller beyine iletildiğinde ve kodu çözüldüğü zaman mümkün olmaktadır (Anonim, 2010).

Frontal lob; vücudun hareketi, konsantrasyon, planlama, kişilik, kelimelerin anlamı, problem çözme, konuşma, duygusal tepkiler, koku alma gibi işlevleri sağlar. Oksipital lob; görme, beyincik; ince kas kontrolü, denge ve koordinasyonu sağlarken temporal lob; işitme, yüzleri tanıma, duygu, uzun süreli hafızayı sağlar. Limbik lob;

mutluluk, üzüntü ve aşk gibi duyguları kontrol ederken parietal lob; dokunma ve baskı, damak zevki, vücut bilincinde görevlidir. (Anonim, 2010).



Şekil 3.2. İnsan beyninde bulunan loblar (Ekici, 2015)

### 3.1.1. Beyin tümörü ve çeşitleri

Bebeklerde ve çocuklarda büyümek ve gelişimi devam ettirmek için yeni hücreler meydana gelirken, yetişkinlerde yaşlı ve zarar gören hücrelerin yerini yeni hücreler almaktadır. Beyin tümörü ise MSS veya beyinde hücrelerin anormal derecede büyümesidir (Dandıl, 2015).

Beyin tümörü iki kategoride incelenir: Birincil beyin tümörleri ve ikincil (metastatik) beyin tümörleri. Birçok farklı beyin tümörü bu iki kategori altında yer almaktadır. Beyin tümörü tedavisinde tümörün çeşidinin bilinmesi hayati öneme sahiptir (Dandıl, 2015).

Birincil Beyin Tümörleri, Beynin kendi veya yakın çevresindeki dokudan kaynaklı bir tümördür. Birincil beyin tümörleri iyi huylu ve kötü huylu olmak kategorize edilirler (Dandıl, 2015).

İyi huylu tümörler: iyi huylu beyin tümörleri nispeten daha yavaş büyürler. Tek bir bölgede kalmaya eğilimlidir ve bu sebeple yayılmamaktadır. İyi huylu tümörler operasyon sırasında doğru bir şekilde çıkartılırsa büyük oranda geri gelmemektedir. Tümörün tamamen çıkartılamaması durumunda yeniden büyüme riski görülmektedir.

Kötü huylu tümörler: beynin ve omurga sisteminin diğer bölgelerine yayılan bir tümördür. Hızla büyüme eğilimindedir. Kötü huylu tümörler metastatik olarak adlandırılan ikincil kanserlerdir. Vücudun başka bir yerinde başlar ve beyne yayılır. Beyin tümörleri ne kadar hızlı büyüdüklerine göre 1 ile 4 arasında derecelendirilir. 3 ve 4 derece beyin tümörü kötü huylu olarak nitelendirilirken, 1 ve 2 derece iyi huylu olarak nitelendirilir (Dandıl, 2015).

Metastatik Beyin Tümörleri, vücuttaki başka bir organdaki dokuda (meme, akciğer vb.) meydana gelen ve kan dolaşımı yoluyla beyne göç eden bir kanser türüdür. Metastatik tümörler kötü huylu tümör olarak kabul edilmektedir (Dandıl, 2015).

### 3.1.2. Beyin tümörünün sınıflandırılması

Beyin kanseri dereceleme sistemi kullanılarak 4 farklı derecede incelenir. Bu sistem, tedavi için tümöre nasıl bir operasyon veya bakım yapılacağına yardımcı olur (Markman, 2021). Dünya genelinde şu an için Dünya Sağlık Örgütü'nün (WHO) belirlemiş olduğu sınıflandırma sistemi kullanılmaktadır.

Günümüzde uzmanlar tümör büyümesini ve gelişmesini saptamak için, tümörün işlevine ve özelliklerine bakarak hareket ederler. Beyin tümörünü belirlemek için kullanılan bazı başlıklar şunlardır:

- Boyut ve konum
- Etkilenen doku veya hücrelerin türü
- Rezektabilite (tümörün bir kısmının veya tamamının ameliyatla çıkarılabilme olasılığı)
- Kanser beyin veya omurilik içinde yayılması
- Kanser beyin veya merkezi sinir sisteminin ötesine yayılma olasılığı

Beyin kanseri derecelendirme olarak vücuttaki diğer kanser türlerine göre farklılık gösterir. Örneğin meme kanserinde tümör vücuttaki konumuna, boyutuna ve yayılma olasılığına göre evrelendirilir. Beyin tümöründe ise tümör derecelendirilirken tümörlü hücrelerin mikroskop altında ne kadar agresif görüldüğüne bakılmaktadır (Markman, 2021).

Dünya Sağlık Örgütü (WHO) tarafından belirlenen ve günümüzde tümörün derecelendirilmesinde kullanılan 4 evre şöyledir:

- Derece I: Tümör nadiren yakın dokulara yayılır, yavaş büyür ve tümörü ameliyatla tamamen çıkarmak mümkün olabilir.
- Derece II: Tümör yakındaki dokulara yayılabilir, yavaş büyür fakat tekrarlayabilir.
- Derece III: Tümör yakındaki dokulara yayılma olasılığı yüksektir, hızla büyür. Bu derecede olan tümör hücreleri normal olan diğer hücreler göre farklı görünür.
- Derece IV: Bu evredeki tümör hücreleri normal hücrelere benzemez, çok hızlı büyür ve yayılır.

### **Merkezi sinir sistemi tümörlerinin WHO sınıflandırması**

WHO'a ait merkezi sinir sisteminde görülen beyin tümörleri için liste aşağıda verilmiştir. Tabloda tümörlerin gelişmeye başladığı yer ile tümörler gruplara ayrılmış ve her bir tümörün evresi gösterilmiştir (Louis, 2007). Her yeni keşfedilen tümör ile bu tablo güncellenmektedir.




### 3.2. Beyin görüntüleme teknikleri

Günümüzde hastalıkların tanı, teşhis ve tedavilerinde biyomedikal görüntüleme sistemleri kullanılmaktadır. Radyodiyagnostik Cihazlar (Radyasyonlu Görüntüleme Cihazları) biyomedikal görüntüleme ve tıp elektroniğinde kullanılan önemli cihazlardır. Bilgi edinme amacı için insan vücudunun tamamını ya da bir bölümü görüntülenip incelenebilmektedir. Elektiksel, radyolojik veya sonik yöntemler ile tıbbi görüntüler elde edilmektedir. Vücudun radyolojik görüntülenmesinde X-ışınları, Elektromanyetizma, Ses Dalgaları ve Radyoizotoplar kullanılmaktadır. Beyin görüntüleme tekniklerinde ise en yaygın kullanılan cihazlar BT ve MRG'dir (Anonim, 2021).

#### 3.2.1. Manyetik rezonans görüntüleme

Manyetik Rezonans Görüntüleme, beyin görüntülemeye kullanılan radyolojik görüntüleme tekniklerinden biridir. 1971 yılında Paul C. Lauterbur tarafından geliştirilmiştir. Aynı tarihte Raymond Damadian ise MRG ile tümörlü dokuları tespit edebilmiştir (Damadian, 1971; Anonim, 2021). Şekil 3.3'te çalışmada ortaya konulan yöntemin düzeneği gösterilmektedir.




Şekil 3.3. Damadian'ın kanser tespiti için geliştirdiği MRG metodu (Anonim, 2021)

Cihazın silindirik yapının içerisinde güçlü elektromanyetik bir alan yer almaktadır. Hastanın vücuduna gönderilen radyo dalgaları vücuttaki hidrojen

atomlarının salınımına sebep olmakta, bu sayede görüntüleme gerçekleşmektedir (William, 2019).


MRG vücuttaki farklı dokular arasında iyi bir kontrast sağladığı için iyi bir görüntüleme tekniğidir. MRG, iyonize edilmiş radyasyon kullanmadığı için beyin kanseri gibi hatalıkların teşhis edilmesinde diğer cihazlara ve görüntüleme teknikleriyle kıyaslandığında avantajlıdır (Anonim, 2021).

MRG cihazı ile elde edilen görüntüler üç farklı düzeydedir. Şekil 3.4'te görüldüğü gibi bunlar aksiyel, koronal ve sagittal'tir. Aksiyel görünümde kesitler yukarıdan aşağıya, koronal görünümde arkadan öne ve sagittal görünümde soldan sağa doğru kesitler elde edilir.



Şekil 3.4. Beynin MR görüntüsüne ait kesit görünümler (Saxena ve ark., 2021)

X-ışınları ve BT taramalarında iyonize radyasyon kullanılırken MRG'de güçlü manyetik alan ve radyo frekans ile iyonize olmayan elektromanyetik alan kullanılır. Günümüzde çoğunlukla T1, T2 ve flair gibi MRG tipleri kullanılmaktadır. Bununla birlikte gelişme aşamasında olan MRG tipleri de bulunmaktadır (Anonim, 2021). Şekil 3.5'de farklı MRG tiplerine dair örnek görüntüler verilmiştir.



Şekil 3.5. (a) T1-ağırlıklı MRG, (b) T2-ağırlıklı MRG, (c) Flair MRG (Preston, 2016)

T1-ağırlıklı MRG, T1 (spin-kafes) dinlenme zamanında değişik dokuların farklılıklarını gösteren standart taramalardır. Güçlü bir kontrast farkı oluşturduğu için gri ve beyaz maddelerin ayrımını sağlar. Vücuttaki su-yağ içeren dokuları ayırmakta kullanılır. Su içeren dokular daha karanlıkken yağ içerenler parlak; ödem ve lezyon karanlıkken kan ve yağ dokuları parlak bir görüntüye sahip olur (Preston, 2016).

T2-ağırlıklı MRG, MRG'de kullanılan taramalardan biridir. T1-ağırlıklı taramalardaki görüntülere benzer olarak su ve yağ dokuları ayrıştırılır. T1'in aksine su içeren dokular parlak iken yağ içeren dokular karanlıktır. Ödem ve lezyonların çoğu ve kan ise parlak bir görüntüye sahiptir (Preston, 2016).

FLAIR MRG, beyindeki lezyonların ve MS lekelerinin görüntülenmesinde kullanılabilir. FLAIR taramalarında patolojilerin çoğunluğu parlak bir görünüme sahip olarak görüntülenir (Preston, 2016).

Çoğunlukla T1, T2 ve Flair MRG görüntüleri kullanılıyor olsa da bunun dışında tercih edilen veya gelişme durumunda olan MRG çeşitleri de bulunmaktadır. T2\*-ağırlıklı MRG, Proton yoğunluğu MRG, Difüzyon MRG, Manyetizasyon transfer MRG, T1rho MRG, Manyetik rezonans anjiyografi, Fonksiyonel MRG, Gerçek zamanlı MRG, Manyetik rezonans perfüzyon, Girişimsel MRG, Akış duyarlı MRG, Hassas ağırlıklı MRG, Manyetik rezonans spektroskopisi diğer MRG tipleri arasında sınıflandırılabilir.

### **3.2.2. Bilgisayarlı tomografi**

Hastanın yatay olarak uzanabileceği hareket eden bir masa ve baş kısmında dönen bir tarayıcıdan oluşmaktadır. X-ışını ve bilgisayardan oluşan bir sistemdir. Dokunun taranması için vücuda X-ışınları gönderilmektedir. Burada tek bir görüntünün yerine birden fazla kesit alınıp birleştirilerek görüntü elde edilir. Örneğin tarayıcı X-ışınları yollayarak beyin etrafında dönerken çok sayıda dilimler halinde görüntüler elde edilir, daha sonra bu dilimler bilgisayar yardımı ile bir araya getirilir.

Bilgisayarlı tomografi ile dokular hakkında ayrıntılı bilgiler elde etmek mümkündür. Özellikle bazı tümör tiplerinde bilgi sahibi olmak adına kontrast iyileştirme ve kontrast iyileştirme olmadan kullanılabilir. Beyin tümörü için MRG kadar çok tercih edilmemekle birlikte vücuttaki anormallikleri saptamak için başvurulan bir tekniktir (Dandıl, 2015).

### 3.2.3. Pozitron emisyon tomografisi

PET taramasında önce hastaya radyoaktif bir madde verilmekte ve tarayıcı ile bu maddenin vücuttaki hareketi esnasında tutulduğu bölgeler saptanmaktadır. PET ile beyin taramasında elde edilen aktiviteler renkli olarak bilgisayara aktarılır. PET tarayıcı tümör büyüklükleri arasındaki farkları belirleyebilir ve ölçülebilir bilgiler verir. Fakat beyin görüntülenmesinde ayrıntılı bir sonuç veremediği için MRG ve BT kadar kullanılan bir teknik değildir. MRG ve BT'ye ek bir veri olması için kullanılabilir (Dandıl, 2015).

### 3.2.4. Tek foton emisyon BT

Tek Foton Emisyon BT, PET ile benzer özelliklere sahiptir. Vücuda önceden verilen bir radyoaktif madde ile vücut taranır ve radyoaktif maddenin tutulma oranları görüntülenir. Yine PET'te olduğu gibi beyin görüntülemeleri için tek başına uygulanan bir teknik değildir, MRG ve BT'den elde edilen verilere tamamlayıcı olmak için kullanılır. Yüksek ve düşük tümör evrelerini saptamak için kullanılabilir (Dandıl, 2015).

### 3.2.5. Manyetoensefalografi

MEG cihazı eski tip saç kurutma cihazına benzer bir sisteme sahiptir. Bir bilgisayar aracılığıyla kafatasından görüntüler elde edilmektedir. MEG küçük elektrik akımları vererek beynin sinir hücreleri arasında bir akım oluşturur, akım sonucu oluşan manyetik alan ölçülür. Bu görüntüleme tekniği sayesinde beyin içerisindeki kısımların birbiriyle nasıl etkileşim halinde olduğu bilgisi elde edilir (Dandıl, 2015).

### 3.2.6. X-ışınları (X-rays)

Beyinde meydana gelen tümör veya kafatasında oluşan kireçleme gibi durumları saptamak adına X-ışınları kullanılmaktadır. X-ışını kullanılarak elde edilen görüntüler bilgisayara aktarılır ve uzmanların yorumlamasına olanak sağlar (Dandıl, 2015).

### 3.2.7. Laboratuvar testleri ve biyopsi

Günümüzde laboratuvar teknikleri beyin tümör ile ilgili çok sayıda araştırma yapılabilmektedir. Beynin DNA'sı gibi yapılarla alakalı bilgiler edinilmektedir. Kandaki maddelerin ölçümü yapılarak klinik uygulamalara destek sağlamaktadır (Dandıl, 2015).

Tümörden alınan dokuların incelenmesi biyopsi işlemi ile gerçekleştirilir. Alınan parçalar düzenli olarak patologlar tarafından teste tabi tutulur ve analiz edilir.

### 3.3. Evrişimli sinir ağları

Bu bölümde evrişimli sinir ağları, onun bir yaklaşımı olarak “tamamen evrişimli ağ” olarak nitelendirilen Klasik U-Net, U-Net+VGG16, U-Net+ResNet50 ve U-Net++ mimarileri anlatılmıştır. Bu ağlarda kullanılan bazı özel yöntemler ve yöntemlerin sınıflandırma ve segmentasyonda nasıl kullanıldığına yer verilmiştir.

Fukushima (1980), Neocognitron adını verdiği çok katmanlı bir yapay sinir ağı mimarisini ortaya koymuştur. Bu mimaride, basit ve kompleks hücreler olarak ifade edilebilecek iki tip hücre olan S-hücreleri ve C-hücreleri vardır. Neocognitron mimarisinde temel olan özellikler S-hücreleri tarafından yerel olarak bulunduktan sonra C-hücreleri tarafından birleştirilir ve daha karmaşık özellikler elde edilir. Bu mimari, mekansal değişimlerinden bağımsız olarak farklı kalıpları tanımayı başarmıştır. Biyolojik sinir ağlarından esinlenmiş yapay sinir ağlarına benzer olarak, evrişimli sinir ağları da hayvanların görsel sisteminden ilham alınarak ortaya konulmuştur.

Evrişim, özel lineer bir matematiksel işlem türüdür. Evrişimli sinir ağları, bu evrişim işleminin kullanıldığı ağlardır. Bu ağlar, bir giriş ve bir çıkış katmanı ve birden fazla gizli katmandan oluşmaktadır. Evrişimli sinir ağları, ReLU, havuzlama katmanları, tamamen bağlı katmanlar ve normalleştirme katmanları bir dizi kıvrımlı katmandan oluşur. Son evrişim, nihai ürünü daha doğru bir şekilde ağırlaştırmak için genellikle geri yayılım içermektedir (Goodfellow ve ark., 2016).


### 3.4. Klasik U-Net

U-net bir tür Evrişimli Sinir Ağı yaklaşımıdır. 2015 yılında, Olaf Ronneberger, Phillip Fischer, ve Thomas Brox tarafından, biomedikal görüntülerde daha iyi bir bölütleme (segmentasyon) yapmak amacı ile ortaya konulmuştur (Ronneberger ve ark., 2015).

Evrişimli Sinir Ağları'nda bir görüntünün çıktısı, tek bir sınıf etiketi olarak ele alınır. Fakat biyomedikal ve savunma sanayisi gibi oldukça hassas ölçümlerin yapıldığı görüntülerde her bir pikselin bilgisine ihtiyaç duyulmaktadır. Yani her bir piksel için bir sınıf etiketi gereklidir (Ronneberger ve ark., 2015). Bununla birlikte Evrişimli Sinir Ağlarında büyük veri kümelerine gereksinim duyulmaktadır. Büyük veri kümelerine erişim ve depolama her zaman yeterli olmamakla birlikte bu verileri işlemek için ihtiyaç duyulan zaman ve insan enerjisi yeterli olmayacaktır. Ronneberger ve ark. (2015), yapmış oldukları çalışmada, “tamamen evrişimli bir ağ” (Long ve ark., 2017) olarak nitelendirilen, daha hassas bir mimari yapı üzerine inşa ettikleri U-Net modelini ortaya koymuşlardır. U-Net mimarisi sayesinde daha net segmentasyonlar elde edilmekte ve az sayıda eğitim görüntüsüne ihtiyaç duyulmaktadır.


Long ve ark. (2017) yaptıkları çalışmada, ortak bir “contracting” ağını ardışık katmanlarla desteklemekte ve havuzlama operasyonları üst örnekleme operatörleri tarafından değiştirilmektedir. Çıktının çözünürlüğü bu katmanlar sayesinde arttırılmaktadır. Bu bilgilere dayalı olarak da, başarılı bir evrişim katmanı kesin bir çıktı oluşturmayı öğrenebilmektedir. U-Net buna ek olarak, örnekleme bölümünde ağın bağlam bilgilerini daha yüksek çözünürlüklü katmanlara yaymasına izin veren çok sayıda özellik kanalı içerir. Genişleyen yol, daralan parçaya az çok simetriktir. Şekil 3.6'da görüldüğü gibi U şeklinde bir görüntü verir ve adını bu görüntüsünden almaktadır.

Burada ağ, tam olarak bağlı katmanlar olmadan yalnızca her bir konvolüsyonun geçerli kısmını kullanır (Long ve ark., 2017). Girdi görüntüsünün aynalanmasıyla eksik bağlam tahmin edilir ve böylelikle, görüntünün sınır bölgesindeki pikselleri tahmin etmek mümkün olur. Bu stratejiyle ağı büyük görüntülere uygulamak çözünürlüğün GPU belleği ile sınırlı olmamasını sağlar.




Şekil 3.6. Klasik U-Net modeli (Ronneberger, 2015)

Şekil 6’da görüldüğü gibi U-net mimarisi solda tarafta bir daralan yol ve sağ tarafta bir genişleyen yoldan oluşmaktadır. Daralan yol tipik bir evrişimli ağ modelidir. Her bir aşamada 3x3 bir evrişim uygulanır: Doğrultulmuş doğrusal birim (ReLU) ve alt örnekleme 2x2 maksimum havuzlama (max-pooling) işlemi vardır. Her alt örnekleme işlemi sırasında özellik kanallarının sayısı iki katına çıkar. Genişleyen yolda ise; bir üst örnekleme ve 2x2 “yukarı evrişim” (up-convolution) ve her biri bir ReLU ile takip edilen iki 3x3 evrişimden oluşur. Daralma yolundan gelen uygun bir şekilde kırılmış özellik haritasıyla birleşmektedir. Burada yukarı örnekleme ile özellik kanallarının sayısı yarıya inmektedir. Her evrişim sırasında kenar piksellerde kayıp olduğu için kırma işlemi uygulanmalıdır. Son katmanda kullanılan 1x1’lik evrişim sayesinde her 64 bileşenli özellik vektörü istenen sayıda sınıfa eşlenir. Bu ağ içerisinde 23 tane katman bulunmaktadır (Ronneberger, 2015).



Şekil 3.7. 3x3 evrişim ve ReLU gösterimi (Ronneberger, 2015)




Şekil 3.8. 2x2 Yukarı evrişim (up-convolution) gösterimi (Ronneberger, 2015)

Şekil 3.7 ve Şekil 3.8’de U-net mimarisinin meydana geldiği iki bölüm, daralma yolu ve genişleme yolu gösterilmiştir. U-net mimarının özel yanı ikinci yarıda yer alan genişleme yoludur. Bu ağda tamamen bağlı (fully connected) katman yoktur, sadece evrişim katmanı kullanılmaktadır. Evrişim işlemi ise ReLU ile aktive edilmektedir (Ronneberger, 2015).

### 3.5. VGG16

VGG16, bir evrişimsel sinir ağı modelidir. Oxford Üniversitesi'nden Simonyan ve arkadaşları tarafından “Büyük Ölçekli Görüntü Tanıma için Çok Derin Evrişimli Ağlar” (Simonyan ve ark., 2015) makalesinde tanıtılmıştır.

VGG Sinir Ağlarından önceki AlexNet (Krizhevsky, 2017) türevleri, ilk evrişim katmanında daha küçük pencere boyutlarına ve adımlara odaklanır, VGG ise CNN'lerin çok önemli bir başka yönü olan “derinliği” ele almaktadır.



Şekil 3.9. VGG16 mimarisi (Ferguson ve ark., 2017)


VGG, giriş görüntüsünün boyutunu tutarlı bir durumda tutmak için her görüntüyü  $224 \times 224$  piksel RGB olarak ele alır. VGG'deki evrişim katmanları mümkün olan en küçük boyutta alanı kullanır. Bunun haricinde var olan  $1 \times 1$  evrişim filtreleri ise, bir ReLU birimi tarafından takip edilen girişin doğrusal dönüşümü olarak işlev görmektedir (Simonyan ve ark., 2015). Evrişim adımı, evrişimden sonra uzamsal çözünürlüğün korunması için 1 piksele sabitlenmektedir. VGG'nin tam bağlantılı üç katmanı bulunur. Bunların ilk ikisinde ayrı ayrı 4096 kanal vardır. Üçüncüsünde ise

1000 kanal bulunur. VGG'nin tüm gizli katmanları ReLU'yu kullanmaktadır. Bu sayede eğitim süresini kısaltmaktadır (Krizhevsky ve ark., 2017; Simonyan ve ark., 2015; Wei, 2019). Bu çalışma için uygulanan U-Net + VGG16 mimarisinde 2. ve 3. katmanlar alınmıştır.

### 3.6. ResNet50

ResNet (Residual Network) 2015 yılında Kaiming He ve arkadaşları tarafından “Görüntü Tanıma için Derin Kalıntı Öğrenme” (He ve ark., 2015) makalesinde tanıtıldı.


Karmaşık sorunlarda daha iyi doğruluk ve performans elde edebilmek için, Derin Sinir Ağlarında ek katmanlar eklenmektedir. Daha fazla katman eklenerek, ağın giderek daha karmaşık katmanları öğrenmesi amaçlanmaktadır. Bir görüntü için kenarları, dokuları, nesnelere tanımak için farklı katmanlar düşünülebilir. Fakat Evrişimli Sinir Ağlarında derinlik için maksimum bir eşik olduğu bulunmuştur (He ve ark., 2015). Şekil 3.10’da gösterildiği gibi, 20 katmanlı ve 56 katmanlı “düz” ağlarla eğitim hatası ve test hatası verilmiştir. Buradan hareketle daha derin ağın daha yüksek eğitim hatasına, dolayısıyla daha yüksek test hatasına sahip olduğu görülebilir. Hem eğitim verisi hem de test verisi durumunda katman sayısını arttırmanın hata yüzdesini düşürmediğini, tersine yükselttiğini görebiliriz.



Şekil 3.10. 20 katmanlı ağ ve 56 katmanlı ağ için eğitim ve test verilerindeki hata yüzdeleri (He ve ark., 2015).

## Residual block

Derin Ağları eğitme sorununa ResNet olumlu bir katkı sağlamıştır. Şekil 3.11’de bir Residual Blok örneği gösterilmiştir. “Atlama Bağlantısı” olarak adlandırılan, katmanları doğrudan atlayan bir bağlantı vardır. Bu bağlantı, blokların çekirdeğini oluşturmaktadır ve farklı bir çıktı elde edilmesine neden olur (Mujtaba, 2020).



Şekil 3.11. Residual blok şeması (Mujtaba, 2020)

Atlama Bağlantısı kullanılmadığında, ‘x’ girişi katman ağırlığıyla çarpılmakta ve ardından denklem 3.1 ve 3.2’de gösterildiği gibi bias terimi eklenmektedir.

$$H(x) = f(wx + b) \quad (3.1)$$

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

Atlama bağlantısının eklenmesiyle formül, denklem 3.3 halini alır

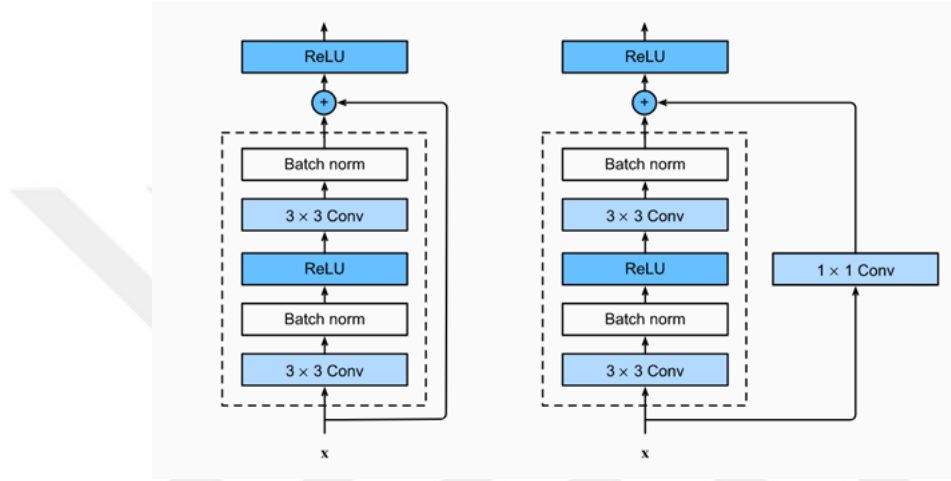
$$H(x) = f(x) + x \quad (3.3)$$

Şekil 3.12’de gösterildiği gibi Residual Blokte her 3x3 evrişimli katman, bir toplu normalleştirme katmanı ve bir ReLU ile devam eder. Daha sonra evrişim işlemleri atlanıp girdi doğrudan son ReLU işlevinden önce eklenir. Burada iki evrişimli katmanın çıktısının girdi ile aynı yapıya sahip olması beklenir, bu sayede toplanabilir (He ve ark., 2015; Mujtaba, 2020). Bu çalışmada, U-Net + ResNet için ilk 4 katman alınmıştır.

Girdi boyutu, aradaki havuzlama katmanları ve evrişimli katman ile meydana gelebilecek çıktının boyutundan farklı olabilir. Böyle bir sorun olduğunda, boyutlarını artırmak için atlama bağlantısını ekstra sıfır girişleriyle doldurmak mümkündür, bunun

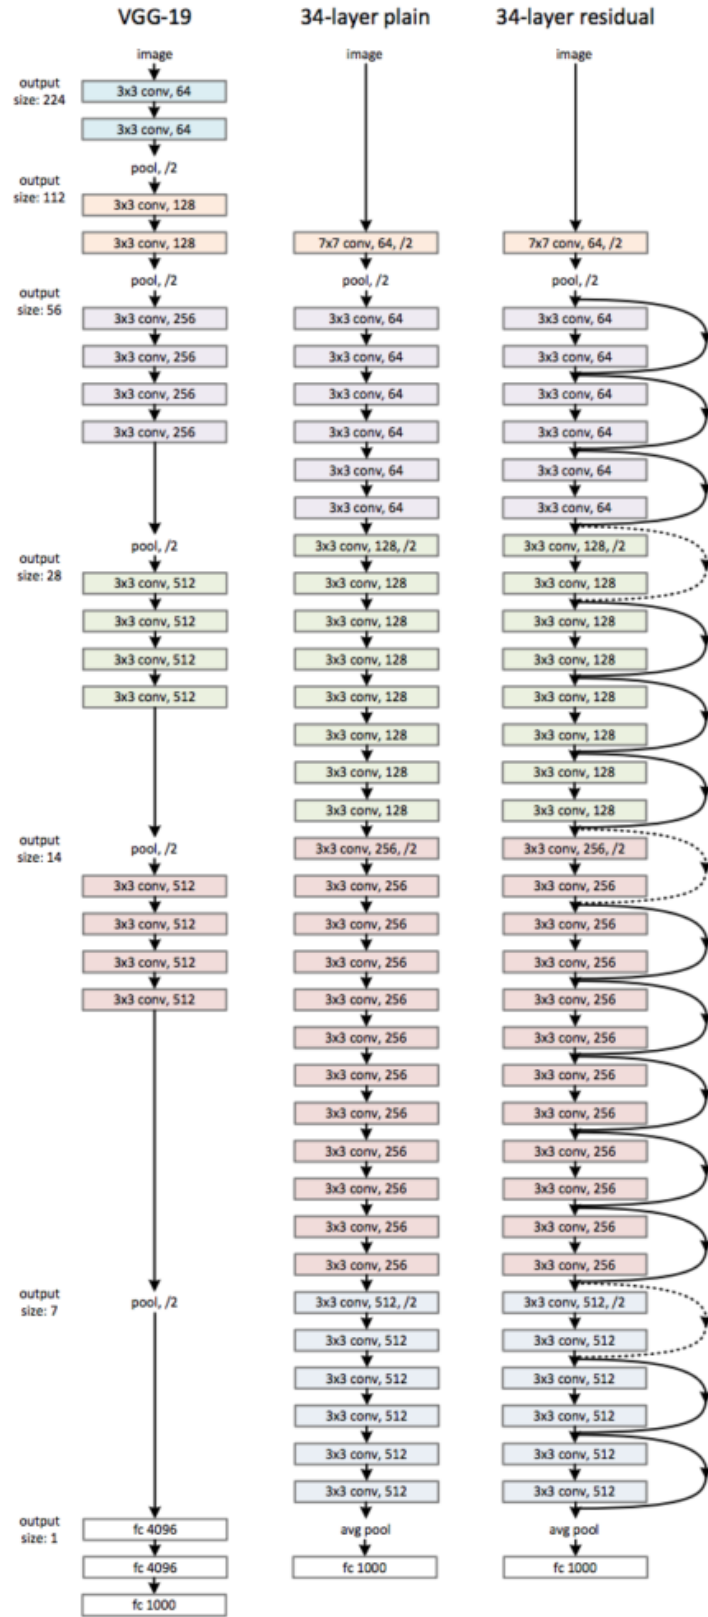
için ek bir parametre kullanılmamaktadır. Diğer bir yol ise kanal sayısında değişiklik yapmak istiyorsak, toplama işlemi esnasında, girdiyi olması istenen şekle getirirken ek bir 1x1 katman koymaktır (Muhtaba, 2020). Bunun için ek parametre kullanılmaktadır. Ek parametre ile yeni çıktı Denklem 3.4’de olduğu gibi ifade edilir.

$$H(x) = f(x) + w1.x \quad (3.4)$$



Şekil 3.12. ResNet bloku ve  $1 \times 1$  evrişim içeren ResNet bloku


ResNet mimarisinde VGG-19’den ilham alınan 34 katmanlı düz bir ağ mimarisi kullanılır. Daha sonra eklenen atlama bağlantıları ile mimari ResNet halini almıştır (He ve ark., 2015).



Şekil 3.13. Sol: VGG-19 modeli. Orta: 34 parametre katmanına sahip düz ağ. Sağ: 34 parametre katmanına sahip artık ağ (He ve ark., 2015).



Şekil 3.14’de siyah renk bileşeni orijinal U-Net’i yeşil ile mavi atlama yollarında yoğun evrişim bloklarını gösterirken; kırmızı, derin denetimi gösterir. Burada ifade edilen yeşil, mavi ve kırmızı bileşenler UNet++’ı, U-Net’ten ayırır.



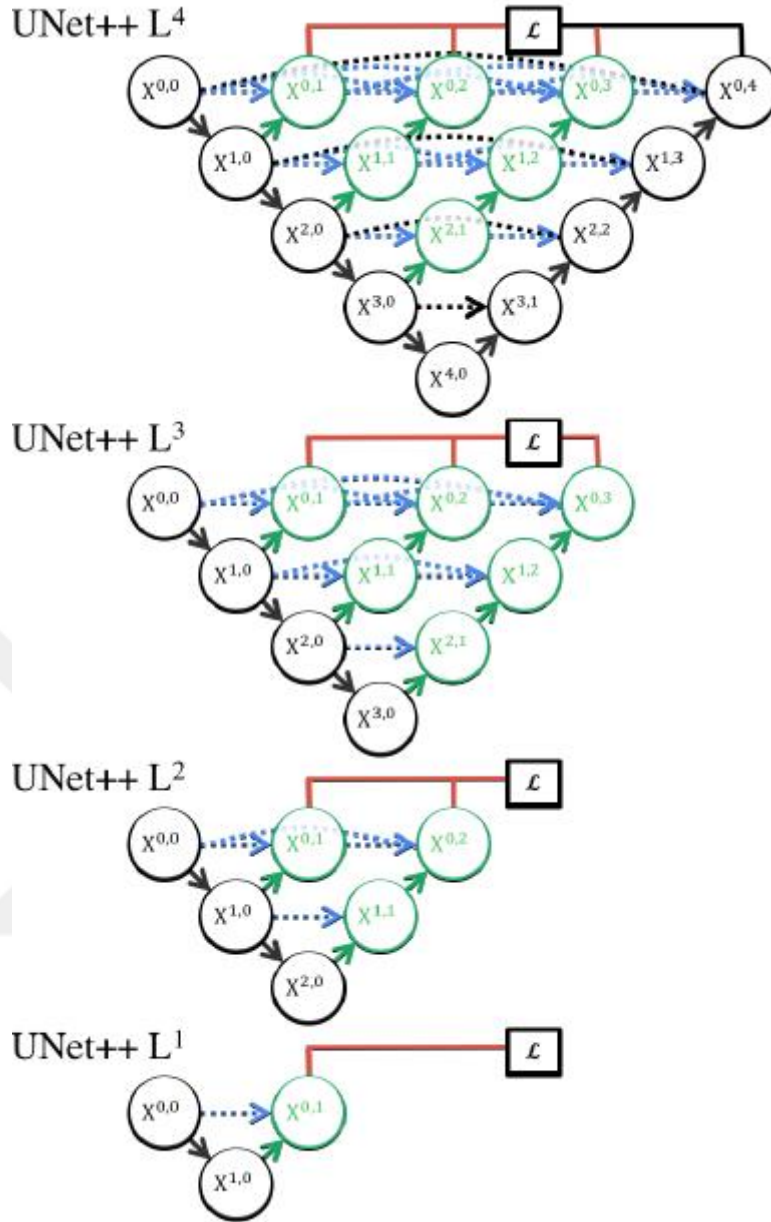
Şekil 3.15. UNet++’ın ilk atlama yolunun analizi (Zhou ve ark., 2018).

Şekil 3.15’de UNet ++ ’ın üst atlama yolunda özellik haritalarının nasıl ilerlediğini gösteren bir örnek verilmiştir. Burada  $x^{0,0}$  ve  $x^{1,3}$  düğümleri arasındaki atlama yolu düşünüldüğünde, atlama yolu üç evrişim katmanına sahip yoğun bir evrişim bloğundan oluşur. Yoğun evrişim bloğu, kodlayıcı özellik haritalarının anlamsal düzeyini, kod çözücüde bekleyen özellik haritalarının düzeyine yaklaştırır. Alınan kodlayıcı ve karşılık gelen kod çözücü özellik haritaları semantik olarak benzer olduğunda, optimize edicinin daha kolay bir optimizasyon problemiyle karşılaştırılması amaçlanmaktadır (Zhou ve ark., 2018).

Atlama yolu, denklem 3.5’de gösterildiği gibi formüle edilir:  $x^{i,j}$ ,  $x^{i,j}$  düğümünün çıktısını gösterirken, burada  $i$  kodlayıcı boyunca alt örnekleme katmanını ve  $j$ , atlama yolu boyunca yoğun bloğun evrişim katmanını indeksler.  $x^{i,j}$  ile temsil edilen özellik haritaları yığını şu şekilde hesaplanır:

$$x^{i,j} = \begin{cases} H(x^{i-1,j}), & j = 0 \\ H\left(\left[x^{i,k}\right]_{k=0}^{j-1}, U(x^{i+1,j-1})\right), & j > 0 \end{cases} \quad (3.5)$$

Burada  $H(\bullet)$  fonksiyonu, bir aktivasyon fonksiyonunun izlediği bir evrişim işlemiyken,  $U(\bullet)$  bir yukarı-örnekleme katmanını ve  $[ ]$  birleştirme katmanını ifade eder.



Şekil 3.16. U-Net++ derin denetim (Zhou ve ark., 2018)

UNet++'da derin denetim (Lee ve ark., 2015) kullanılmaktadır, bu da modelin iki modda çalışmasını sağlar: 1) tüm segmentasyon dallarından gelen çıktıların ortalamasının alındığı doğru mod; 2) son segmentasyon haritasının segmentasyon dallarından sadece birinden seçildiği hızlı mod. UNet++, derin denetimle eğitilirse, çıkarım zamanında budanabilir.

Şekil 3.16'da, hızlı modda segmentasyon dalı seçiminin değişen karmaşıklıkta mimarilerle nasıl sonuçlandığı gösterilmiştir. İç içe atlama yolları sayesinde, UNet++,

derin denetime uygun olan çoklu semantik düzeylerde tam çözünürlüklü özellik haritaları oluşturur. Yukarıdaki dört semantik düzeyin her birine kayıp fonksiyonu olarak ikili çapraz entropi ve zar katsayısının bir kombinasyonu eklendiğinde denklem 3.6'daki gibi tanımlanır:

$$L(Y, \hat{Y}) = -\frac{1}{N} \sum_{b=1}^N \left( \frac{1}{2} \cdot Y_b \cdot \log \hat{Y}_b + \frac{2 \cdot Y_b \cdot \hat{Y}_b}{Y_b + \hat{Y}_b} \right) \quad (3.6)$$

### 3.8. Uygulama sonuçlarının değerlendirilmesi

Çalışmada kullanılan Klasik U-Net, U-Net + VGG16, U-Net + ResNet50 ve U-Net++ ağlarının performansını derecelendirmek için karışıklık matrisi kullanılarak dice coefficient, hassaslık, özgüllük ve Jaccard İndeksi parametreleri elde edilmiştir.

Bir karışıklık matrisi, gerçek değerlerin bilinmekte olduğu bir dizi test verisi üzerinde, bir sınıflandırma modelinin nasıl bir performansla sonuç verdiğini tanımlamak için kullanılan bir tablodur. Karışıklık matrisi çizelge 3.2'de gösterilmiştir.

Çizelge 3.2. Karışıklık matrisi

		<b>GERÇEK DEĞER</b>	
		<i>POZİTİF</i>	<i>NEGATİF</i>
<b>TAHMİN EDİLEN DEĞER</b>	<i>POZİTİF</i>	DP Doğru-Pozitif	YP Yanlış-Pozitif
	<i>NEGATİF</i>	YN Yanlış-Negatif	DN Doğru-Negatif

Karışıklık matrisinde yer alan DP, DN, YP ve YN'nin birbirleriyle ilişkisini gösteren terminolojiler denklem 3.7 ile 3.9 arasında verilmiştir.

$$Toplam = DP + DN + YP + YN \quad (3.7)$$

$$Gerçek Pozitif = DP + YN \quad (3.8)$$

$$Gerçek Negatif = DN + YP \quad (3.9)$$

### Doğruluk oranı (Accuracy rate)

Sınıflayıcının yaptığı tahminin ne kadar doğru olduğunun bir ölçüsüdür. Denklem 3.10'da olduğu şekilde formüle edilmektedir.

$$\text{Doğruluk Oranı} = \frac{(DP + DN)}{\text{Toplam}} \quad (3.10)$$

### Dice coefficient

İki örneğin benzerliğini hesaplamak için kullanılan bir istatistiktir. Sonuçtaki temel gerçeğe eşit olan olumlu unsurlar bulunduktan sonra bu sonuç, her ikisindeki toplam pozitif sayısına bölünür. Denklem 3.11'de olduğu şekilde formüle edilmektedir.

$$DICE = \frac{2|A \cap B|}{|A| + |B|} = \frac{2(DP)}{(YP) + (YN) + 2(DP)} \quad (3.11)$$

### Jaccard indeksi

Bölütleme performansı değerlendirilirken başvurulan piksel temelli ölçütlerden biridir. Hedef matris ile tahmin edilen matris arasındaki örtüşen oran dikkate alınır. Denklem 3.12'de olduğu şekilde formüle edilmektedir.

$$Jaccard = \frac{|A \cap B|}{|A \cup B|} = \frac{DP}{(DP + YP + YN)} \quad (3.12)$$

### Özgüllük (Specificity)

Özgüllük ile tüm negatif verilere göre, yanlışlıkla pozitif olarak kabul edilen negatif verilerin oranı hesaplanmaktadır. Denklem 3.13'de olduğu gibi ifadesi edilir.

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (3.13)$$

**Hassaslık (Sensitivity)**

Hassaslık, tüm pozitif verilere göre, pozitif olarak kabul edilen pozitif veri noktalarının oranını göstermektedir. Denklem 3.14’de olduğu gibi ifadesi edilir.

$$Hassaslık = \frac{DP}{DP+YN} \quad (3.14)$$






## 4. BULGULAR


Bu bölümde Klasik U-net, U-net + VGG16, U-net + ResNet50 ve U-net++ ile elde edilen veriler ve doğruluk grafikleri verilmiştir. Yapılan uygulamalara ait sonuçlar, dice coefficient, hassaslık, özgüllük ve Jaccard İndeksi olacak şekilde farklı parametreler kullanılarak ifade edilmiştir.

### 4.1. BraTS veri setinde bulunan HGG ve LGG beyin tümörü görüntüleri


Veri setinde kullanılan HGG ve LGG beyin tümörü MRI örnekleri aksiyal, sagittal ve koronal olarak resmedilmiştir.




Şekil 4.1. Aksiyel HGG beyin tümörü MRI örnekleri




Şekil 4.2. Sagittal HGG beyin tümörü MRI örnekleri



Şekil 4.3. Koronal HGG beyin tümörü MRI örnekleri




Şekil 4.4. Aksiyel LGG beyin tümörü MRI örnekleri




Şekil 4.5. Sagittal LGG beyin tümörü MRI örnekleri

#### 4.2. Klasik U-Net modellenin sonuçlarının deęerlendirilmesi

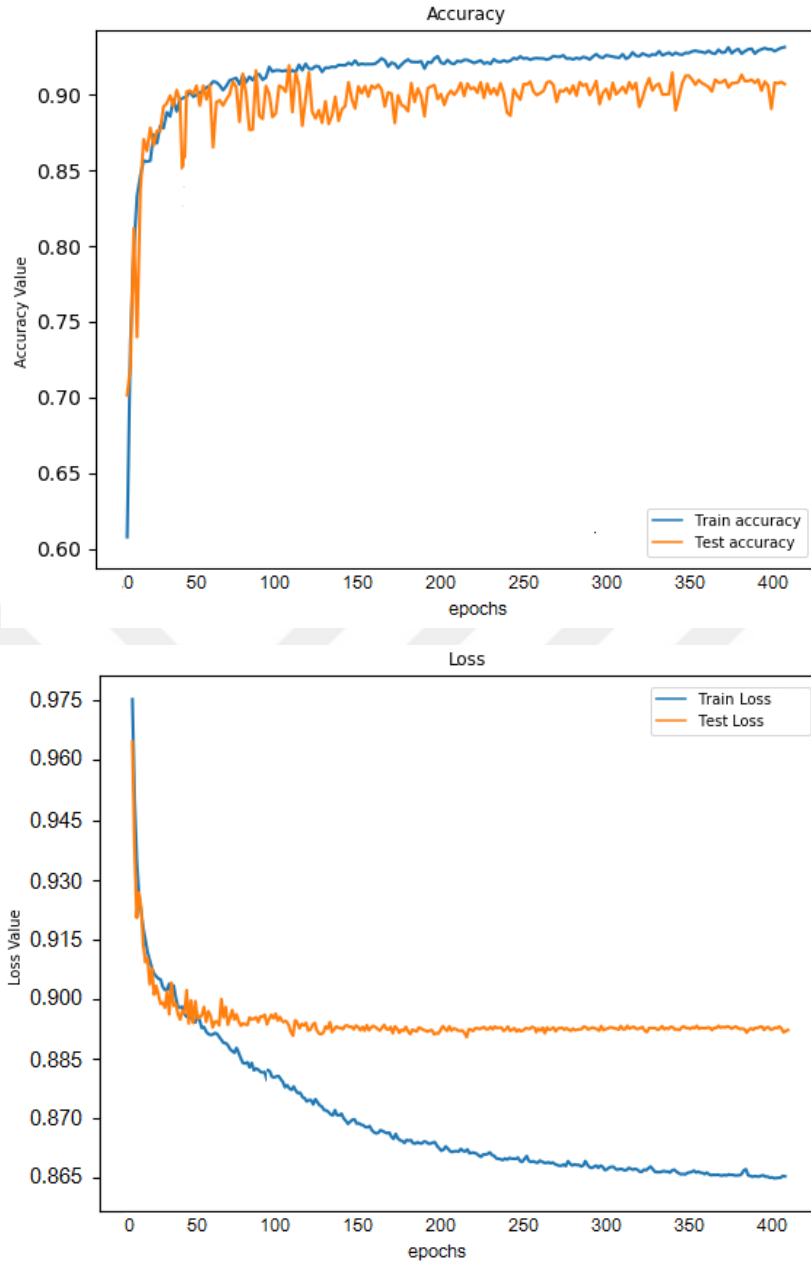
Bu bölümde eğitim veri seti için segmente edilmiş HGG ve LGG beyin tümörü görüntülerine sırasıyla aksiyel, sagittal ve koronal olacak şekilde örnekler verilmiştir.



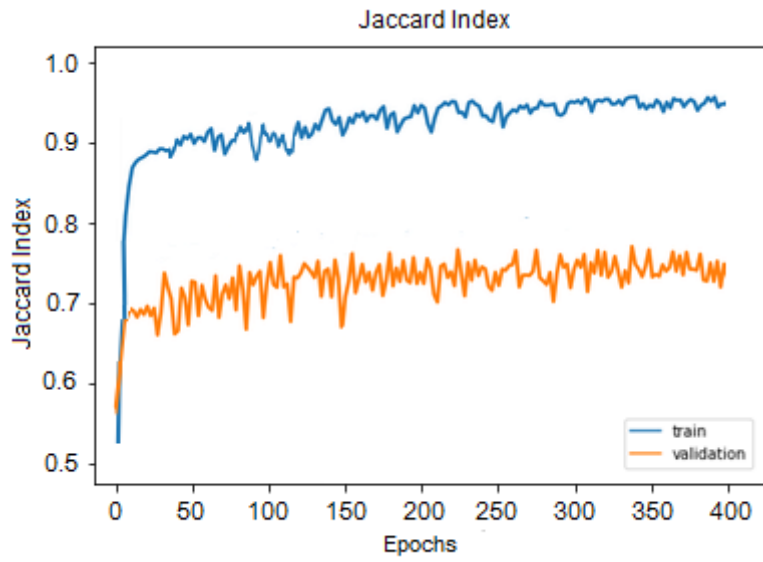
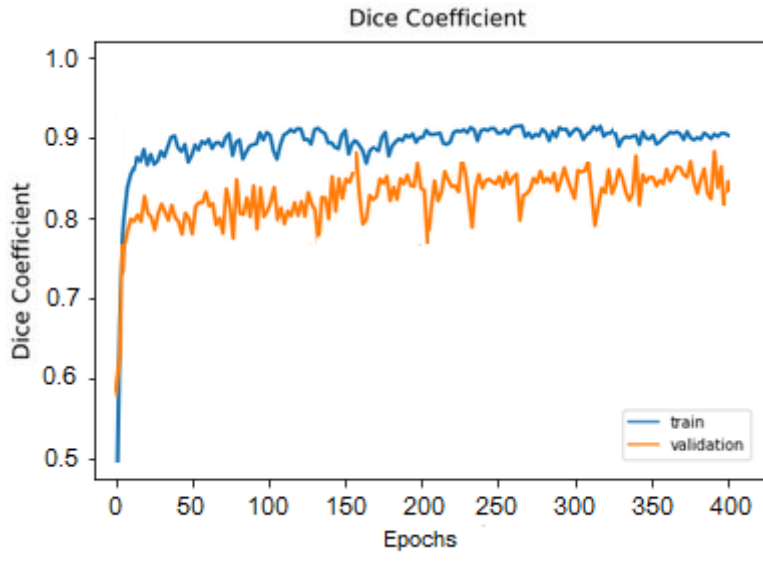
Şekil 4.6. Eğitim için segmente edilen HGG tümör örnekleri



Şekil 4.7. Eğitim için segmente edilen LGG tümör örnekleri




Şekil 4.8. Segmente edilen tümörlerin U-Net performans grafikleri




Şekil 4.9. Segmente edilen tümörlerin U-Net performans grafikleri


BraTS veri setinde bulunan MRI görüntüleri, bu görüntülerde bulunan orijinal tümörler ve kullanılan Klasik U-Net mimarisi ile elde edilen tahmin sonuçları aşağıda gösterilmiştir.




(a) MR Görüntüsü




(b) Orijinal Maske




(c) Tahmin Edilen Maske




(d) MR Görüntüsü




(e) Orijinal Maske




(f) Tahmin Edilen Maske




(g) MR Görüntüsü




(h) Orijinal Maske




(i) Tahmin Edilen Maske



(j) MR Görüntüsü




(k) Orijinal Maske




(l) Tahmin Edilen Maske


Şekil 4.10. HGG MR görüntüsü, orijinal maske ve tahmin edilen değerler



(a) MR Görüntüsü




(b) Orijinal Maske




(c) Tahmin Edilen Maske




(d) MR Görüntüsü




(e) Orijinal Maske




(f) Tahmin Edilen Maske




(g) MR Görüntüsü




(h) Orijinal Maske




(i) Tahmin Edilen Maske



(j) MR Görüntüsü



(k) Orijinal Maske

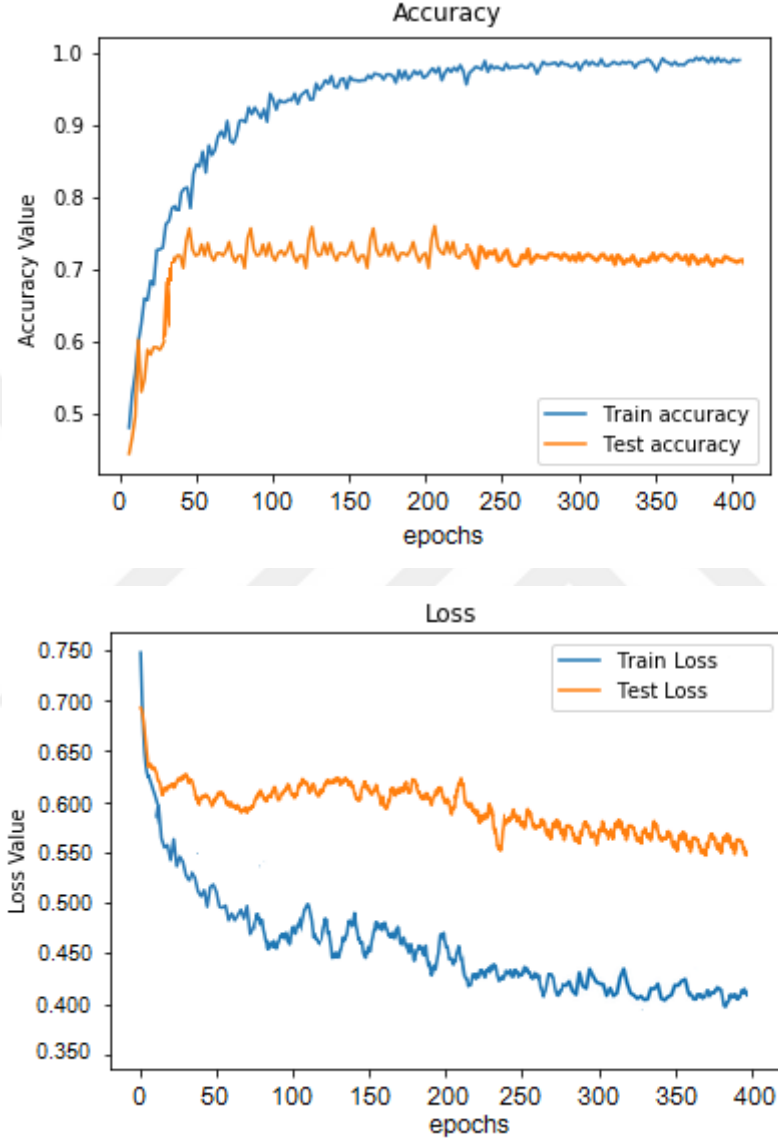


(l) Tahmin Edilen Maske



Şekil 4.11. LGG MR görüntüsü, orijinal maske ve tahmin edilen değerler

### 4.3. U-Net + VGG16 ađ sonuçlarının deđerlendirilmesi

Bu bۆlümde Klasik U-Net için omurga olarak kullanılan VGG16 ile elde edilen ađ sonuçları verilmiştir.




Şekil 4.12. Segmente edilen tümörlerin U-Net + VGG16 performans grafikleri




Şekil 4.13. Segmente edilen tümörlerin U-Net + VGG16 performans grafikleri


BraTS veri setinde bulunan MRI görüntüleri, bu görüntülerde bulunan orijinal tümörler ve kullanılan U-Net + VGG16 mimarisi ile elde edilen tahmin sonuçları aşağıda gösterilmiştir.




(a) MR Görüntüsü




(b) Orijinal Maske




(c) Tahmin Edilen Maske




(d) MR Görüntüsü




(e) Orijinal Maske




(f) Tahmin Edilen Maske




(g) MR Görüntüsü




(h) Orijinal Maske




(i) Tahmin Edilen Maske



(j) MR Görüntüsü

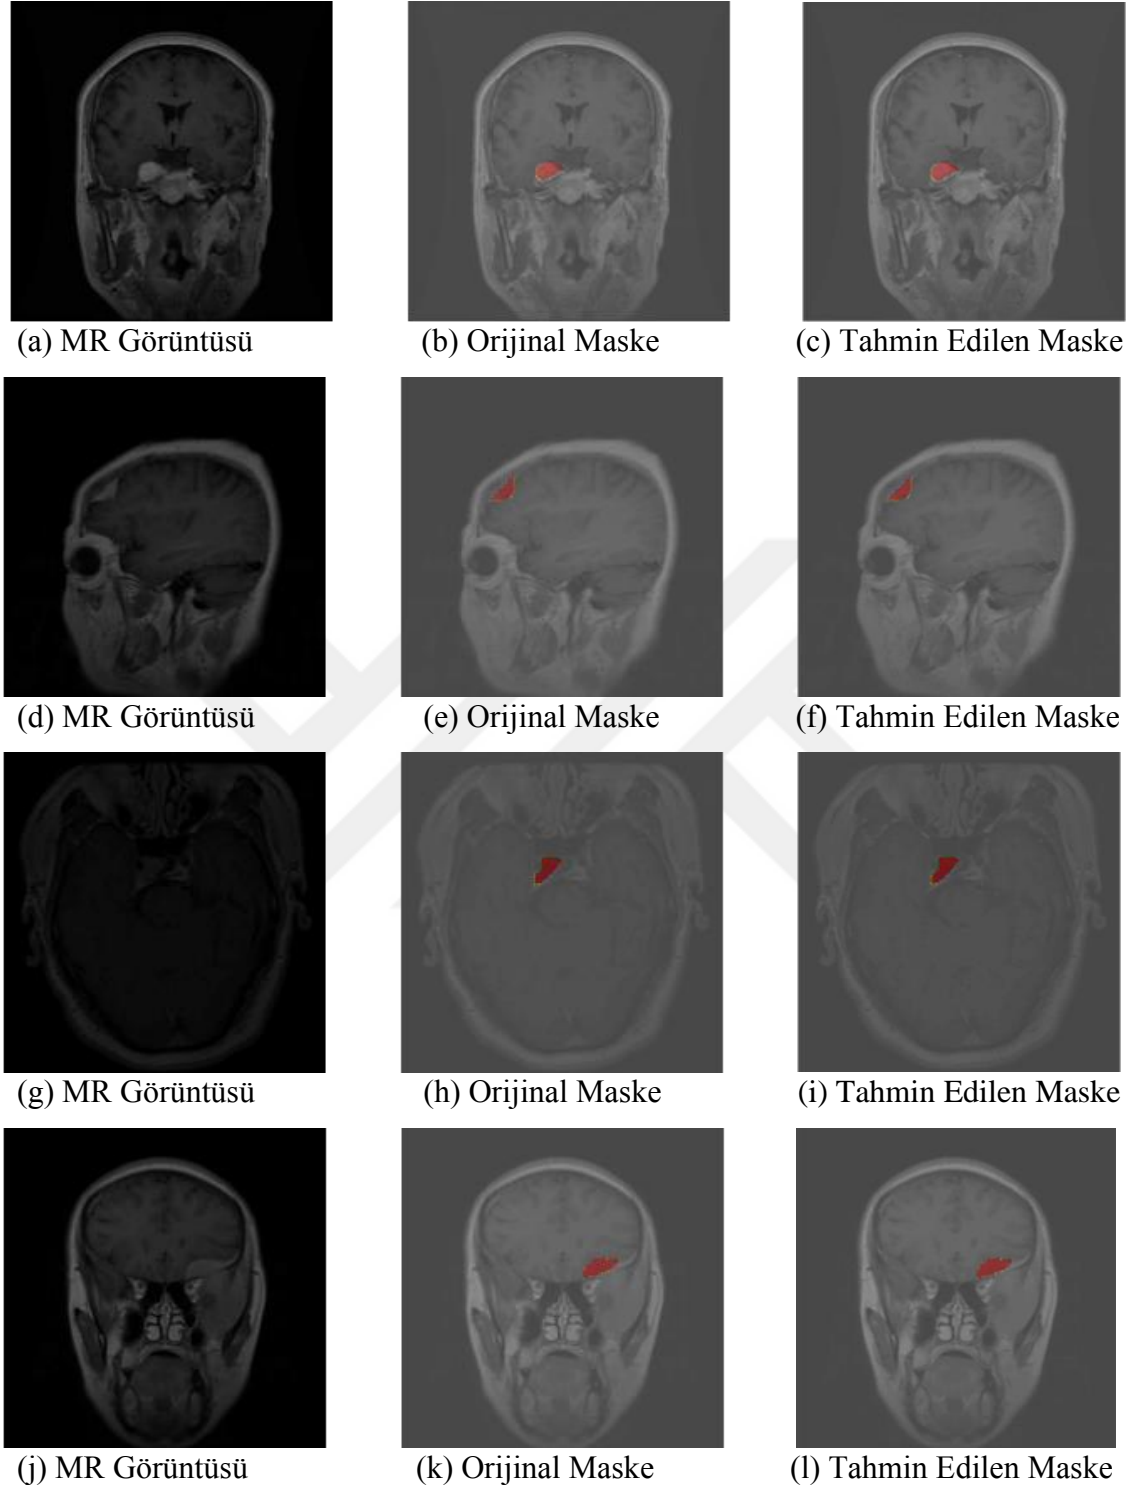


(k) Orijinal Maske



(l) Tahmin Edilen Maske


Şekil 4.14. HGG MR görüntüsü, orijinal maske ve tahmin edilen değerler





Şekil 4.15. LGG MR görüntüsü, orijinal maske ve tahmin edilen değerler

#### 4.4. U-Net + ResNet50 ađ sonuçlarının deęerlendirilmesi

Bu bölümde Klasik U-Net için omurga olarak kullanılan ResNet50 ile elde edilen ađ sonuçları verilmiştir.




Şekil 4.16. Segmente edilen tümörlerin U-Net + ResNet50 performans grafikleri




Şekil 4.17. Segmente edilen tümörlerin U-Net + ResNet50 performans grafikleri


BraTS veri setinde bulunan MRI görüntüleri, bu görüntülerde bulunan orijinal tümörler ve kullanılan U-Net + ResNet50 mimarisi ile elde edilen tahmin sonuçları aşağıda gösterilmiştir.




(a) MR Görüntüsü




(b) Orijinal Maske




(c) Tahmin Edilen Maske




(d) MR Görüntüsü




(e) Orijinal Maske




(f) Tahmin Edilen Maske




(g) MR Görüntüsü




(h) Orijinal Maske




(i) Tahmin Edilen Maske



(j) MR Görüntüsü




(k) Orijinal Maske




(l) Tahmin Edilen Maske


Şekil 4.18. HGG MR görüntüsü, orijinal maske ve tahmin edilen değerler




(a) MR Görüntüsü



(b) Orijinal Maske




(c) Tahmin Edilen Maske




(d) MR Görüntüsü




(e) Orijinal Maske




(f) Tahmin Edilen Maske




(g) MR Görüntüsü




(h) Orijinal Maske



(i) Tahmin Edilen Maske



(j) MR Görüntüsü



(k) Orijinal Maske




(l) Tahmin Edilen Maske


Şekil 4.19. LGG MR görüntüsü, orijinal maske ve tahmin edilen değerler

#### 4.5. U-Net++ modelli ađ sonuçlarının deęerlendirilmesi


Bu bölümde eđitim veri seti için segmente edilmiř HGG ve LGG beyin tümörü görüntülerine sırasıyla aksiyel, sagittal ve koronal olacak řekilde örnekler verilmiřtir.



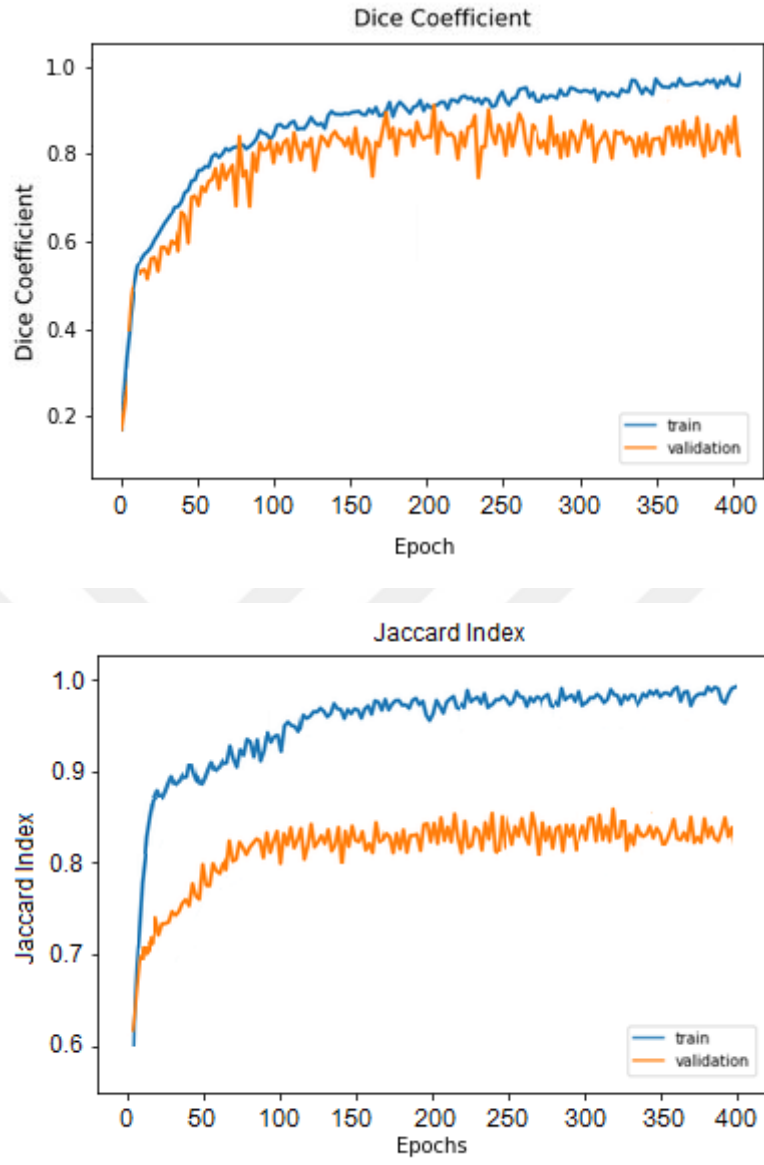
řekil 4.20. Eđitim için segmente edilen HGG tümör örnekleri



Şekil 4.21. Eğitim için segmente edilen LGG tümör örnekleri




Şekil 4.22. Segmente edilen tümörlerin U-Net++ performans grafikleri




Şekil 4.23. Segmente edilen tümörlerin U-Net++ performans grafikleri

Veri setinde bulunan MRI görüntüleri, bu görüntülerde bulunan orijinal tümörler ve kullanılan U-Net++ mimarisi ile elde edilen tahmin sonuçları aşağıda gösterilmiştir.




(a) MR Görüntüsü




(b) Orijinal Maske




(c) Tahmin Edilen Maske




(d) MR Görüntüsü




(e) Orijinal Maske




(f) Tahmin Edilen Maske



(j) MR Görüntüsü




(k) Orijinal Maske




(l) Tahmin Edilen Maske


Şekil 4.24. HGG MR görüntüsü, orijinal maske ve tahmin edilen değerler




(a) MR Görüntüsü




(b) Orijinal Maske




(c) Tahmin Edilen Maske




(d) MR Görüntüsü




(e) Orijinal Maske




(f) Tahmin Edilen Maske



(j) MR Görüntüsü



(k) Orijinal Maske

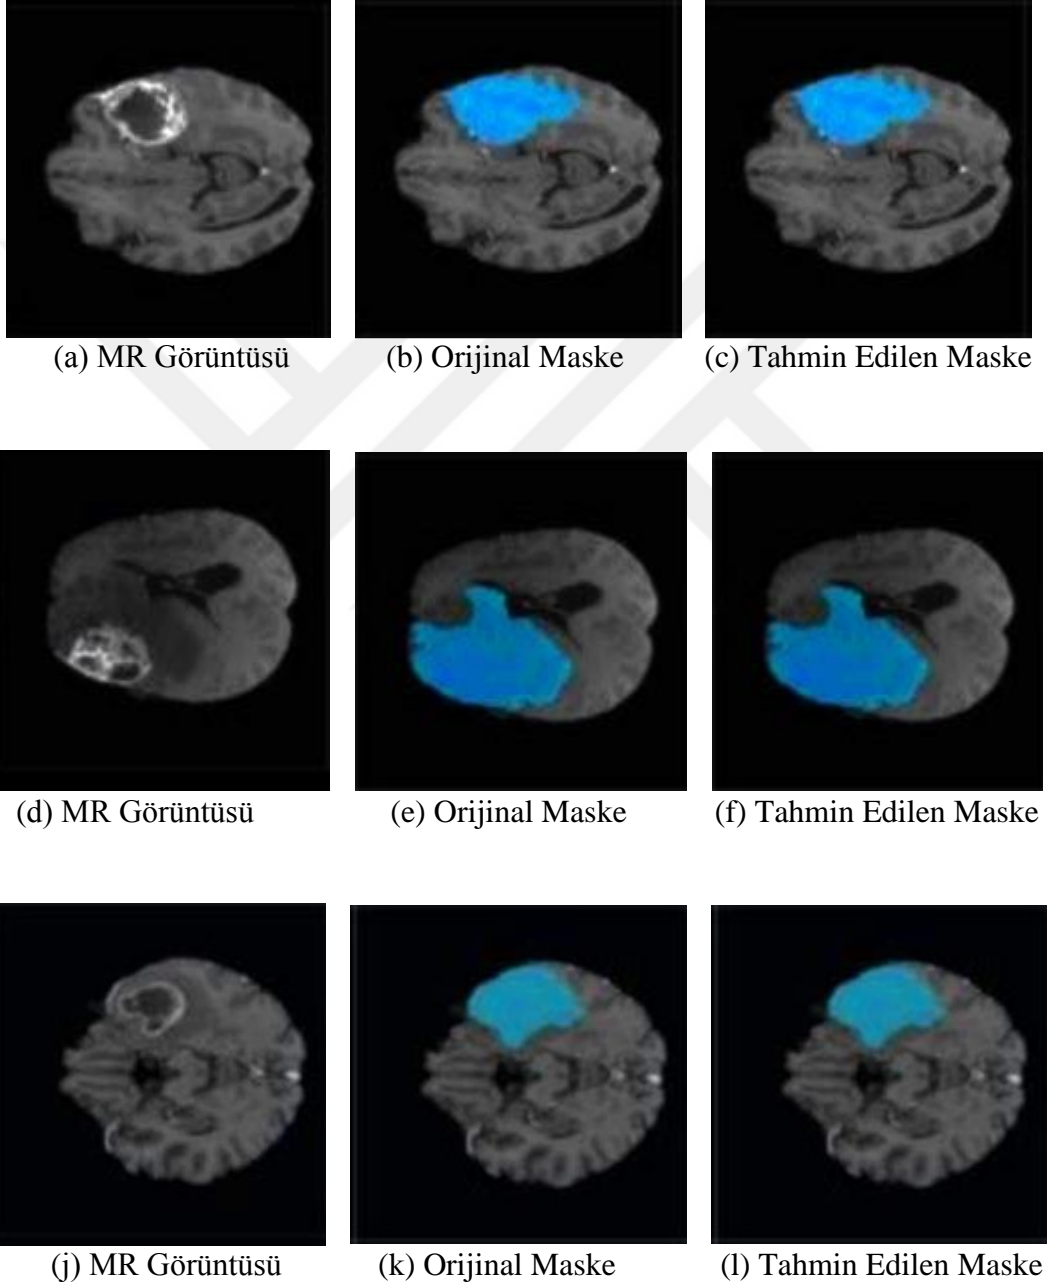


(l) Tahmin Edilen Maske

Şekil 4.25. LGG MR görüntüsü, orijinal maske ve tahmin edilen değerler


#### 4.6. U-Net ve U-Net++ ağların farklı veri seti ile değerlendirilmesi

Figshare veri setinde bulunan MRI görüntüleri, bu görüntülerde bulunan orijinal tümörler ve kullanılan U-Net mimarisi ile elde edilen tahmin sonuçları aşağıda gösterilmiştir.




Şekil 4.26. U-Net için MR görüntüsü, orijinal maske ve tahmin edilen değerler


Figshare veri setinde bulunan MRI görüntüleri, bu görüntülerde bulunan orijinal tümörler ve kullanılan U-Net + VGG16 mimarisi ile elde edilen tahmin sonuçları aşağıda gösterilmiştir.




(a) MR Görüntüsü




(b) Orijinal Maske




(c) Tahmin Edilen Maske




(d) MR Görüntüsü




(e) Orijinal Maske




(f) Tahmin Edilen Maske



(j) MR Görüntüsü




(k) Orijinal Maske



(l) Tahmin Edilen Maske


Şekil 4.27. U-Net+VGG16 için MR görüntüsü, orijinal maske ve tahmin edilen değerler

Figshare veri setinde bulunan MRI görüntüleri, bu görüntülerde bulunan orijinal tümörler ve kullanılan U-Net + ResNet50 mimarisi ile elde edilen tahmin sonuçları aşağıda gösterilmiştir.



Şekil 4.28. U-Net+ResNet50 için MR görüntüsü, orijinal maske ve tahmin edilen değerler

Figshare veri setinde bulunan MRI görüntüleri, bu görüntülerde bulunan orijinal tümörler ve kullanılan U-Net++ mimarisi ile elde edilen tahmin sonuçları aşağıda gösterilmiştir.



Şekil 4.29. U-Net++ için MR görüntüsü, orijinal maske ve tahmin edilen değerler

Çizelge 4.2. Beyin tümörü çalışmalarının karşılaştırılması

<i>Uygulamalar</i>	<i>Dice Coefficient</i>	<i>Hassaslık</i>	<i>Özgüllük</i>	<i>Jaccard İndeksi</i>
Li ve arkadaşları	0.905	0.915	0.995	-
Kamnitsas ve arkadaşları	0.901	0.895	0.995	-
Isensee ve arkadaşları	0.903	0.902	0.996	-
Klasik U-Net	0.879	0.844	0.957	0.784
U-Net + ResNet	0.697	0.659	0.862	0.535
U-Net + VGG16	0.585	0.550	0.800	0.414
U-Net++	0.920	0.890	0.973	0.850

Çalışmada kullanılan Klasik U-Net, U-Net+VGG16, U-Net+ResNet50 ve U-Net++ ağlarının her biri 30 defa işleme sokulmuştur. Bu işlemlerden elde edilen sonuçların performansını derecelendirmek için dice coefficient, hassaslık, özgüllük ve Jaccard İndeksi olmak üzere 4 farklı parametre kullanılmıştır. Bu parametrelerden elde edilen değerler ile uygulamaların her biri için aritmetik ortalama ve standart sapma hesaplanmıştır. Klasik U-Net, U-Net+VGG16, U-Net+ResNet50 ve U-Net++ için sırasıyla 0.006, 0.005, 0.004 ve 0.005 standart sapma değerlerine ulaşılmıştır.

Çizelge 4.2’de beyin tümörü veri kümeleri ve segmentasyon yöntemleri kullanılarak yapılan beyin tümörü tespiti çalışmalarında elde edilen sonuçlar sıralanmıştır. Bu tez kapsamında ele alınan Klasik U-Net, U-Net+ResNet, U-Net+VGG16 ve U-net++’sa ait dice coefficient, hassaslık, özgüllük ve Jaccard İndeksi değerleri tabloda gösterilmiştir. Sonuçlar karşılaştırıldığında en iyi sonucun U-Net++ ile elde edildiği görülmektedir.



## 5. TARTIŞMA VE SONUÇ

Sağlık alanında yapılan teknolojik çalışmalar sağlık çalışanlarının daha verimli bir şekilde tanı ve tedavide bulunmasına yardımcı olmaktadır. Biyomedikal alanda ortaya konulan çalışmalar sayesinde tanı ve tedavide hataya daha az yer verilmek ve insan kaynaklı yanlışları en aza indirmek hedeflenmektedir. Bununla birlikte sağlık teknolojisindeki gelişmeler arttıkça sağlık çalışanlarının daha az sürede daha çok hastaya hizmet sunması sağlanmaktadır. Sağlık alanında en çok ihtiyaç duyulan konulardan biri de vücuttaki kanserli bölgenin erken sürede teşhisidir. Bilindiği üzere kanserde erken teşhis hayati öneme sahiptir. Yine tedavi süresince takip etmek ve tedaviden sonra da herhangi bir komplikasyonu önlemek için tümörlü bölgenin izlenmesi oldukça önemlidir.

Bu çalışmada beyin tümörünün teşhisi için bir Evrişimli Ağ Modeli olarak Klasik U-net, U-Net + VGG16, U-Net + ResNet50 ve U-net++ olmak üzere farklı U-Net modelleri önerilmiş ve her bir ağ için 2 ayrı aşamada gerçekleştirilmiştir. Bu aşamalar, BraTS 2019 veri setinde bulunan MR görüntülerinin segmentasyonu (bölütlenmesi) ve tümör tahminidir. Eğitilen ağlar, Figshare veri setinde bulunan beyin tümörü MR görüntüleri üzerinde ayrıca uygulanmış ve doğrulukları değerlendirilmiştir.

Uygulanan U-Net modelleri karşılaştırıldığında en iyi sonucun U-Net++ ile elde edildiği görülmektedir. Daha sonra Klasik U-net modeli, ResNet50 ve VGG16 omurgaları gelmektedir. Ayrıca Çizelge 4.2 incelenip son geliştirilen teknoloji yöntemlerinde 3B ağ kullandığı düşünüldüğünde, 2B ağ ile benzer sonuçların elde edilmesi dikkat çekicidir.



## KAYNAKLAR

- Anitha, R., Raja, D. S. S., 2017. Development of Computer-Aided Approach for Brain Tumor Detection Using Random Forest Classifier. *International Journal of Imaging System and Technology*, **28**: 48-53.
- Anonim, 2010. What are the regions of the brain and what do they do? <https://askbiologist.asu.edu/brain-regions>. The Database Center for Life Science, Japan. Eriřim tarihi: 4.10.2021
- Anonim, 2021. Beyin temelleri: Beyninizi tanıyın. <https://www.ninds.nih.gov/Disorders/Patient-Caregiver-Education/Know-Your-Brain>. National Institute of Neurological Disorders and Stroke, National Institutes of Health. Eriřim tarihi: 4.10.2021
- Anonim, 2021. Magnetic resonance imaging, [https://en.wikipedia.org/wiki/Magnetic\\_resonance\\_imaging](https://en.wikipedia.org/wiki/Magnetic_resonance_imaging). Eriřim Tarihi: 01.10.2020.
- Anonim, 2021. Medical imaging, [https://en.wikipedia.org/wiki/Medical\\_imaging](https://en.wikipedia.org/wiki/Medical_imaging). Eriřim Tarihi: 01.10.2020.
- Arı A., Hanbay D., 2018. Derin öğrenme tabanlı beyin tümörü sınıflandırma ve tespit sistemi, *Turkish Journal of Electrical Engineering & Computer Sciences*: **26**: 2275 – 2286.
- Arunachalam, M., Savarimuthu, S. R., 2017. An efficient and automatic glioblastoma brain tumor detection using shift-invariant shearlet transform and neural networks. *International Journal of Imaging System and Technology*, **27**: 216-226.
- Ay, Ş., 2020. Model performansını değerlendirmek için metrikler. <https://medium.com/deep-learning-turkiye/model-performansini-degerlendirmek-metrikler-cb6568705b1>. Eriřim Tarihi: 24.11.2021.
- Bakas., S., 2019. MICCAI 2019 BraTS. <https://www.med.upenn.edu/cbica/brats-2019/> Center for Biomedical Image Computing & Analytics, Perelman School of Medicine, University of Pennsylvania. Eriřim Tarihi: 10.07.2020.
- Cabria, I., Gondra I., 2016. MRI Segmentation fusion for brain tumor detection. *Information Fusion*, **36**: 1-9.
- Chen X., Udupa J.K., Bagci U., Zhuge Y., Yao J., 2012. Medical image segmentation by combining graph cuts and oriented active appearance models. *IEEE Transactions on Image Processing*, **2**: 2035-2046.
- Damadian, R., 1971. Tumor detection by nuclear magnetic resonance. *Science*, **171**: 1151-1153.
- Dandıl, E., 2015. *MR Görüntüleri ve MR Spektroskopi Verileri ile Yapay Öğrenme Tabanlı Beyin Tümörü Tespit Yöntemi ve Uygulaması*. (doktora tezi). Sakarya Üniversitesi. Fen Bilimleri Enstitüsü, Sakarya.
- Demirhan, A. and Güler İ., 2014. Sinirsel bulanık çıkarım sistemi kullanarak beyindeki tümör, ödem ve sağlıklı dokuların otomatik olarak bölütlenmesi. *Signal Processing And Communications Applications Conference (SIU)*: 120-123.
- Ekici, Ö., 2015. İnsan beyninin yapısı nasıldır? <https://bilimgenc.tubitak.gov.tr/makale/insan-beyninin-yapisi-nasildir>. Tübitak, Bilim Genç. Eriřim tarihi: 4.10.2021

- Ferguson, M., Ak, R., T, L, Yung-Tsun., Law, K. H., 2017. Automatic Localization of Casting Defects with Convolutional Neural Networks. *IEEE International Conference on Big Data*. 11-14 Aralık 2017, Boston.
- Fukushima, K., 1980. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, **36**: 193–202.
- Goodfellow I., Bengio, Y., and Aaron Courville 2016. Deep Learning. *MIT Press*: 326.
- He, K., Zhang, X., Ren, S., Sun, J., 2015. Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 27-30 Haziran 2016, Las Vegas, NV, USA.
- Hoffman, M., 2021. Beyin yapısı ve bölümleri. <https://www.webmd.com/brain/picture-of-the-brain>. Erişim tarihi: 4.10.2021.
- Isensee, F., Kickingereder, P., Wick, W., Bendszus, M., Maier-Hein, K. H., 2017. Brain tumor segmentation and radiomics survival prediction: Contribution to the brats 2017 challenge. *International MICCAI Brainlesion Workshop*. 17 Şubat 2018, Germany.
- Jun, C., 2017. Brain tumor dataset. Figshare dataset. [https://figshare.com/articles/dataset/brain\\_tumor\\_dataset/1512427/5](https://figshare.com/articles/dataset/brain_tumor_dataset/1512427/5). Erişim tarihi: 4.10.2021.
- Kamnitsas, K., Bai, W., Ferrante, E., McDonagh, S. G., Sinclair, M., Pawlowski, N., Rajchl, M., Lee, M. C. H., Kainz, B., Rueckert, D., and Glocker, B., 2017. Ensembles of multiple models and architectures for robust brain tumour segmentation. *Lecture Notes in Computer Science*. Eylül 2018, London. 450-562.
- Kazdal, S., Dogan, B., Camurcu, A. Y., 2015. Computer-aided detection of brain tumors using image processing techniques. *Signal Processing And Comm. Applications Conference (SIU)*: 863- 866.
- Krizhevsky, A., Sutskever, I., Hinton, E., 2017. *ImageNet classification with deep convolutional neural networks*. *Communications of the ACM*, **60**: 84–90.
- Lee, C.-Y., Xie, S., Gallagher, P., Zhang, Z., and Tu, Z., 2015. Deeply-supervised nets. *In Artificial Intelligence and Statistics*, **38**: 562–570.
- Long, J., Shelhamer, E., Darrell, T., 2017. Fully convolutional networks for semantic segmentation. *IEEE Trans. Pattern Anal. Mach. Intell.*, **39**: 640–651.
- Louis, D. N., Ohgaki, H., Wiestler, O. D., Cavenee, W. K., Burger, P. C., Jouvet, A., Scheithauer, B. W., Kleihues, P., 2007. The 2007 WHO classification of tumours of the central nervous system. *Acta Neuropathologica*, **114**: 97-109.
- Mander, S., 2018. Conditional - DCGAN in TensorFlow. <https://medium.com/@sam.maddrellmander/conditional-dcgan-in-tensorflow-336f8b03b7b6>. Erişim Tarihi: 24.11.2021
- Markman, M., 2021. Brain cancer grades. <https://www.cancercenter.com/cancer-types/brain-cancer/grades>. Cancer Treatment Center of America, ABD. Erişim tarihi: 4.8.2021.
- Mujtaba H., 2020. Introduction to ResNet or Residual Network. <https://www.mygreatlearning.com/blog/resnet/#sh1>. Great Learning. Erişim Tarihi: 01.8.2021.
- Preston, D., 2016. Magnetic resonance imaging (MRI) of the brain and spine. <https://case.edu/med/neurology/NR/MRI%20Basics.htm>. Erişim Tarihi: 01.10.2021.

- Ronneberger, O., Fischer, P., Brox, T., 2015. *U-Net: Convolutional Networks for Biomedical Image Segmentation*. University of Freiburg, Computer Science Department and BIOSS Centre for Biological Signalling Studies, Germany.
- Saxena, S., Kumari, N., Pattnaik, S., 2021. Brain tumour segmentation in flair MRI using sliding window texture feature extraction followed by fuzzy c-means clustering. *International Journal of Healthcare Information Systems and Informatics (IJHISI)*, **16**: 20. IIIT Bhubaneswar, India.
- Shah, N., 2019. *Left and Right Neural Networks -Inspired by Our Bicameral Brains*. Monash University, Melbourne.
- Simonyan, K., Shi, W., Caballero, J., Huszár, F., Totz, J., Aitken, A. P., Bishop, R., Rueckert, D., Zisserman, A., 2015. *Very Deep Convolutional Networks For Large-Scale Image Recognition*. University of Oxford, Visual Geometry Group, Department of Engineering Science, Oxford.
- Vaishnav, K. B. and Amshakala, K., 2015. An automated MRI brain image segmentation and tumor detection using SOM-clustering and proximal support vector machine classifier, *2015 IEEE International Conference on Engineering and Technology (ICETECH)*: 1-6.
- William, C. S. Jr., 2019. Magnetic resonance imaging (MRI Scan). [https://www.medicinenet.com/mri\\_scan/article.htm](https://www.medicinenet.com/mri_scan/article.htm) Erişim Tarihi: 12.10.2021.
- Zhou, Z., Siddiquee, M. R., Tajbakhsh, N., Liang, J., 2018. UNet++: A nested U-Net architecture for medical image segmentation. *4th Deep Learning in Medical Image Analysis (DLMIA)*. 20 Eylül 2018. Granada, Spain. 3-11.



## ÖZGEÇMİŞ

Merve KAYAR ilk ve orta eğitimini Van'da, lise öğrenimini Siirt'te tamamladı. 2019 yılında Karabük Üniversitesi Tıp Mühendisliği Bölümünden mezun oldu. 2019 yılında Van Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Yapay Zeka ve Robotik yüksek lisans programına kabul aldı. Halen lisansüstü eğitimine aynı üniversitede devam etmektedir.



VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
FEN BİLİMLER ENSTİTÜSÜ  
LİSANSÜSTÜ TEZ ORJİNALLİK RAPORU

Tarih: 19/01 /2022

Tez Başlığı / Konusu: U-Net Derin Öğrenme Modelleri Kullanılarak Beyin Tümörü Tespiti

Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam 60 sayfalık kısmına ilişkin, 19/01/2022. tarihinde tez danışmanım tarafından Turnitin intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezin benzerlik oranı %12 (on iki) dir.

Uygulanan filtreler aşağıda verilmiştir:

- Materyal ve yöntem hariç,
- Kaynaklar hariç,
- Tezden çıkan yayınlar hariç,
- 7 kelimeden daha az örtüşme içeren metin kısımları hariç (Limit inatch size to 7 words)

Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim.

19/01/2022

Adı Soyadı: Merve KAYAR

Öğrenci No: 19910001115

Anabilim Dalı: Yapay Zeka ve Robotik Anabilim Dalı

Programı:

Statüsü:  Yüksek Lisans

Doktora

DANIŞMAN ONAYI

ENSTİTÜ ONAY  
UYGUNDUR