



DERİN ÖĞRENME TABANLI BEYİN TÜMÖRÜ SEGMENTASYONU

YÜKSEK LİSANS TEZİ

Merve AKMAN

Danışman

Dr. Öğr. Üyesi Gür Emre GÜRAKSIN

BİYOMEDİKAL MÜHENDİSLİĞİ

ANABİLİM DALI

Temmuz 2022

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME TABANLI BEYİN TÜMÖRÜ
SEGMENTASYONU

Merve AKMAN

Danışman

Dr. Öğr. Üyesi Gür Emre GÜRAKSIN

BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI

Temmuz 2022

TEZ ONAY SAYFASI

Merve AKMAN tarafından hazırlanan “Yapay Zekâ Teknikleri Kullanarak MR Görüntüleri Üzerinden Beyin Hastalıklarının Teşhisi” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 26 / 07 /2022 tarihinde aşağıdaki jüri tarafından **oy birliği / oy çokluğu** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Biyomedikal Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Gür Emre GÜRAKSIN

Başkan : Doç.Dr Utku Köse
Süleyman Demirel Üniversitesi, Mühendislik Fakültesi

Üye : Dr. Öğr. Üyesi Gür Emre Güraksın
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Doç.Dr Utku Köse
Süleyman Demirel Üniversitesi, Mühendislik Fakültesi

Üye : Dr. Öğr. Üyesi Burak Türker
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. İbrahim EROL

Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

22 / 08 / 2022

Merve Akman

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME TABANLI BEYİN TÜMÖRÜ SEGMENTASYONU

Merve AKMAN

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Dr.Öğr.Üyesi Gür Emre GÜRAKSIN

Beyin tümörü segmentasyonu, sağlıklı dokuyu tümörlü bölgelerden ayırmayı amaçlar. Günümüzde beyin tümörü segmentasyonu manuel olarak radyoloji uzmanları tarafından yapılmaktadır. Son yıllarda derin öğrenme yöntemleri kullanılarak uygulanan otomatik bilgisayar destekli sistemler manuel algılama sistemlerinin yerini alarak büyük bir ivme kazanmıştır. Beyin tümör türlerinin yarısından fazlasını gliomalar oluşturmaktadır. Beyin MR görüntülerini kullanarak glioma tümörlerini manuel olarak segmente etmek oldukça zordur. Bunun sebebi; glioma tümörlerin şekil, boyut, hacim, konum ve görünüm açısından farklı olması ve sağlıklı dokularla tümörlü dokuların yapısı birbirine benzediği için ikisini birbirinden ayırt etmenin zor olmasıdır. Veri seti olarak her sene düzenlenen BRATS yarışmasındaki 2019 yılının beyin MR görüntüleri kullanılmıştır. Bu çalışmada diğer çalışmalardan farklı olarak, tümörün farklı bölümlerinin daha net görülmesi için uygun modaliteler kullanılmış ve tümör boyutlarına göre MR görüntülerinin kırılma işlemi gerçekleştirilmiştir. Tam tümör segmentasyonu, genişleyen + nekroz ve genişleyen tümör segmentasyonu için ayrı ayrı 3 model eğitimi gerçekleştirilmiştir. Yapılan eğitimler sonucunda, literatürdeki çalışmalarla karşılaştırıldığında bu çalışma tam tümör segmentasyonunda 2., nekroz + genişleyen tümör segmentasyonunda 2., genişleyen tümör segmentasyonunda 1. olarak öncü çalışmalar arasında girmiştir.

2022, x + 70 sayfa

Anahtar Kelimeler: Görüntü Segmentasyonu, Görüntü İşleme, Beyin Tümörü Segmentasyonu, Beyin MR Görüntüsü, Yapay Zekâ, Derin Öğrenme

ABSTRACT

M.Sc. Thesis

DEEP LEARNING BASED BRAIN TUMOR SEGMENTATION

Merve AKMAN

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Biomedical Engineering

Supervisor: Asst. Prof. Gür Emre GÜRAKSIN

Brain tumor segmentation aims to separate healthy tissue from tumor sites. Today, brain tumor segmentation is performed manually by radiologists. In recent years, automated computer-aided systems implemented using deep learning methods have gained great momentum by replacing manual detection systems. More than half of brain tumor types are gliomas. Manually segmenting glioma tumors using brain MRI images is quite challenging. The reason for this is; glioma tumors are different in shape, size, volume, location and appearance, and it is difficult to distinguish between the two because healthy tissues and tumorous tissues are similar in structure. As a data set, brain MRI images of 2019 in the BRATS competition held every year were used. In this study, unlike other studies, appropriate modalities were used to see different parts of the tumor more clearly and MR images were cropped according to tumor sizes. 3 model trainings were carried out separately for complete tumor segmentation, expanding + necrosis and expanding tumor segmentation. As a result of the trainings conducted, compared to the studies in the literature, this study was among the pioneering studies as the 2nd in complete tumor segmentation, 2nd in necrosis + expanding tumor segmentation, and 1st in expanding tumor segmentation.

2022, x + 70 pages

Keywords: Image Segmentation, Image Processing, Brain Tumor Segmentation, Brain MR Image, Artificial Intelligence, Deep Learning

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Dr. Öğr. Üyesi Gür Emre Güraksın'a, tez çalışmam sürecinde değerli önerileriyle Sayın Ar. Gör. Sezin Barın'a, her konuda öneri ve eleştirileriyle yardımlarını gördüğüm hocalarım ve arkadaşlarıma teşekkür ederim.

Hayatım boyunca bana her zaman gösterdikleri maddi ve manevi desteklerinden dolayı beni bugünlere getiren annem Medine Akman, babam İsa Akman, abim Kubilay Akman'a teşekkür ederim.

Merve AKMAN
Afyonkarahisar, 2022

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET.....	II
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ.....	ix
1. GİRİŞ	1
2. GENEL BİLGİLER ve LİTERATÜR İNCELEMESİ	4
2.1 Beyin Tümörü.....	4
2.1.1 Beyin Tümörü Dereceleri	4
2.2 Beyin Tümörü Türleri.....	4
2.2.1 Birincil Beyin Tümörleri	4
2.2.1.1 Gliomalar	5
2.2.2 İkincil Beyin Tümörleri.....	6
2.3 Beyin Tümörü Teşhis Yöntemleri	6
2.4 Manyetik Rezonans Görüntüleme (MRG) Sekansları	7
2.5 Yapay Zeka.....	8
2.6 Makine Öğrenmesi	8
2.7 Derin Öğrenme	11
2.8 Evrişimsel Sinir Ağları (CNN).....	17
2.8.1 Evrişim (Convolution) Katmanı	19
2.8.2 Havuzlama (Pooling) Katmanı	21
2.8.3 Tam Bağlantılı Katman	23
2.8.4 Seyreltme (Dropout) Katmanı	24
2.9 CNN Eğitiminde Kullanılan Hiper Parametreler	25
2.9.1 Öğrenme Oranı (Learning Rate).....	25
2.9.2 Kayıp Fonksiyonu (Loss Function)	26
2.9.3 Epok Sayısı	28
2.9.4 Yığın Boyutu (Batch Size)	28
2.10 Görüntü Segmentasyonu	29

2.10.1 UNET	30
2.11 Literatür İncelemesi	33
3. MATERYAL ve METOT	40
3.1 Veri Seti	40
3.2 Ön İşlemler	41
3.2.1 Veri Dönüştürme	42
3.2.2 Bilgi İçermeyen MR Dilimlerinin Atılması	42
3.2.3 Eşikleme (Binary Threshold)	43
3.2.4 Tümör Kırpma	44
3.3 Segmentasyon	46
3.3.1 Tam Tümör Segmentasyonu	47
3.3.2 Tümör Merkezi ve Genişleyen Tümör Segmentasyonu	48
3.4 Kırılan Görüntüler İçin Eğitim Sonrası İşlem	51
4. BULGULAR	52
5. SONUÇLAR VE TARTIŞMA	59
6. KAYNAKLAR	61
ÖZGEÇMİŞ	70

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

W	weight
Wi	ağırlık faktörleri

Kısaltmalar

2B	2 Boyutlu
3B	3 Boyutlu
ADAM	Adaptive Moment Estimation
BRATS	Brain Tumor Segmentation
CNN	Evrişimsel Sinir Ağı
CT	Computer Tomography
DCT	Ayrık Kosinüs Dönüşümü
DSC	Dice Similarity Coefficient
DWT	Ayrık Dalgacık Dönüşümü
FMRG	Fonksiyonel MRG
FLAIR	Fluid Attenuated Inversion Recovery-Akışkan Zayıflatılmış İnversiyon Kurtarma
GAN	Üretken Düşman Ağları
HGG	High Grade Glioma
IoU	Intersection over Union
IV	Intravenoz
LGG	Low Grade Glioma
MICCAI	Medical Image Computing and Computer Assisted Intervention
MR	Manyetik Rezonans
MRG	Manyetik Rezonans Görüntüleme
RGB	Red Green Blue
RMSProp	Root Mean Square Propagation
RNN	Tekrarlayan Sinir Ağları
SGD	Stochastic Gradient Descent
SOM	Kendi Kendini Düzenleyen Haritalar
T1	T1 ağırlıklı MRG
T2	T2 ağırlıklı MRG
T1Ce	Gadolinyumlu T1 ağırlıklı MRG
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 Glioma alt sınıfları	5
Şekil 2.2 Nekroz, ödem ve genişleyen tümör segmentasyon görüntüsü	6
Şekil 2.3 Manyetik rezonans görüntüleme (MRG) sekansları	7
Şekil 2.4 Makine öğrenme süreci	9
Şekil 2.5 Geleneksel programlama yaklaşımı	9
Şekil 2.6 Makine öğrenimi yaklaşımı.....	10
Şekil 2.7 Denetimli öğrenme.....	10
Şekil 2.8 Denetimsiz öğrenme	11
Şekil 2.9 Pekiştirmeli öğrenme	11
Şekil 2.10 Makine öğrenimi ve derin öğrenimi çalışma prensibi.....	12
Şekil 2.11 Derin öğrenme modellerinin daha fazla veriyle gelişimi	12
Şekil 2.12 Yapay sinir ağı (YSA) modeli.....	13
Şekil 2.13 Tek katmanlı YSA ve derin YSA modeli	13
Şekil 2.14 Biyolojik sinir hücrelerinin yapısı.....	14
Şekil 2.15 YSA nöronların yapısı	14
Şekil 2.16 En çok kullanılan aktivasyon fonksiyonları	16
Şekil 2.17 İleri yayılım ve geri yayılım.....	17
Şekil 2.18 Bilgisayarların sayılarla görüş özelliği	18
Şekil 2.19 Temsili CNN mimarisi.....	19
Şekil 2.20 Evrişim katmanında yapılan matematiksel işlem.....	19
Şekil 2.21 Yapılan matematiksel işlemle birlikte filtrenin giriş görüntü üzerinde kaydırılması işlemi	20
Şekil 2.22 RGB formatlı görüntüde filtrenin hareketi.....	21
Şekil 2.23 RGB resimlerde evrişim işlemi.....	21
Şekil 2.24 Maksimum havuzlama	22
Şekil 2.25 Ortalama havuzlama	23
Şekil 2.26 Tam bağlantılı katman yapısı.....	24
Şekil 2.27 Standart sinir ağı ve seyreltme katmanı uygulanmış sinir ağı.....	25
Şekil 2.28 Öğrenme oranlarına göre kayıp değerlerinin değişimi.....	26
Şekil 2.29 Semantik ve örnek segmentasyon uygulamaları	29
Şekil 2.30 Semantik segmentasyon mimari şeması	30

Şekil 2.31 UNet mimari yapısı.....	32
Şekil 2.32 Klasik CNN ve UNet arasındaki fark.....	33
Şekil 3.1 Çalışmaya ait akış diyagramı.....	40
Şekil 3.2 Tümör segmentasyonu görüntüsünün bölümleri.....	41
Şekil 3.3 Anlamlı bilgi içermeyen 2 boyutlu MR görüntüleri.....	42
Şekil 3.4 Anlamlı bilgi içeren 2 boyutlu MR görüntüleri.....	43
Şekil 3.5 Flair, T1ce ve T2 modalitelerinde nekroz, genişleyen tümör ve tam tümör görüntüleri.....	45
Şekil 3.6 Tümör boyutuna göre görüntü kırpma işlemi.....	47
Şekil 3.7 Kırmızı, yeşil, mavi renk kanalları ve RGB görüntü oluşumu.....	47
Şekil 3.8 MRG modalitelerinde tümör görüntüleri.....	48
Şekil 3.9 Tümör kırpma.....	49
Şekil 3.10 128x128 boyutundaki segmentasyon görüntüsünün parçalı hale getirilmesi.....	50
Şekil 3.11 Tahmin edilen segmentasyon görüntülerinin birbiri üzerine eklenmesi.....	51
Şekil 4.1 Zar benzerlik katsayısı çalışma prensibi.....	53
Şekil 4.2 Tam tümör tahmin ve segmentasyon görüntüsü	54
Şekil 4.3 Tümör merkezi (genişleyen + nekroz) tahmin ve segmentasyon görüntüsü.....	55
Şekil 4.4 Genişleyen tümör tahmin ve segmentasyon görüntüsü.....	56
Şekil 4.5 Segmentasyon işlemleri sonuçları.....	58

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 Segmentasyon mimarilerinde kullanılan kayıp fonksiyonları.....	26
Çizelge 4.1 Farklı giriş boyutları, modalite görüntüleri ile yapılan tam tümör segmentasyonu değerlendirme sonuçları.....	54
Çizelge 4.2 Farklı giriş boyutları ile yapılan genişleyen + nekroz segmentasyonu değerlendirme sonuçları.....	55
Çizelge 4.3 Farklı giriş boyutları ile yapılan genişleyen tümör segmentasyonu değerlendirme sonuçları.....	56
Çizelge 4.4 Tümör bölgelerinin segmentasyonunda Unet mimarisinin değerlendirme sonuçları	56
Çizelge 4.5 Literatür çalışmaları ile karşılaştırma.....	57

1. GİRİŞ

Beyin tümörü, beyindeki anormal hücrelerin yayılarak büyümesi olarak tanımlanmaktadır. Gliomalar, tedavisi en zor olan ve birincil merkezi sinir sistemi tümörlerinin %50'sinden fazlasını oluşturan en yaygın birincil beyin tümörü türüdür (Fountas ve Kapsalaki 2019).

Birincil beyin tümörü, beyinde başlayan bir tümördür. Birincil beyin tümör türlerinden biri olan gliomalar, Düşük Dereceli Gliomalar (LGG) ve Yüksek Dereceli Gliomalar (HGG) olarak ikiye ayrılır. LGG'ler genellikle ameliyatla tedavi edilebilmekte ve bazen ek tedavi gerektirebilmektedir. LGG hastalarında tedavi sonrası hayatta kalma süreleri yaklaşık 7 yıldır. LGG tümörler genellikle yavaş büyür, ancak tedavi edilmezse HGG tümörlere dönüşebilmekte ve ölüme kadar ilerleyebilmektedir. HGG tümörler LGG tümörlere göre çok daha agresiftir ve hızlı büyüme olasılığı da yüksektir. HGG'lerde ameliyat en iyi tedavidir. Ek olarak her zaman kemoterapi ve radyasyon tedavisi uygulanır. HGG hastalarında ise ortalama hayatta kalma süresi 2 yıldan daha azdır (Marra vd. 2019).

Beyin yapılarını ayrıntılı olarak görmek ve beyin tümörünü teşhis etmek için en yaygın görüntüleme sistemi yüksek çözünürlüklü özelliklere sahip Manyetik Rezonans Görüntüleme (MRG) teknolojisidir (Havaei vd. 2017). Ayrıca MRG ile beyin iç dokularının multimodal görüntüleri elde edilebilmektedir. Bu çalışmada da kullanılan MRG modaliteleri T1 ağırlıklı (T1), kontrastlı T1 ağırlıklı (T1ce), T2 ağırlıklı (T2) ve Flair taramalarıdır (Arora vd. 2021). Her modalitede, beyin dokusunun belirli bir bölümü daha iyi tespit edilmektedir. T1 ağırlıklı taramalar beyindeki sağlıklı dokuları izole etmede iyiye, T1ce ise kontrast madde ile birlikte tümör sınırlarının daha parlak görünmesine yardımcı olur. T2 modaliteli görüntülerde en yüksek yoğunluklu görüntüler elde edilir. Flair ağırlıklı taramalarda ise beyin sıvısı zayıflatılır ve anormal alanlar belirlenir (Aghalari vd. 2021).

Beyin tümörü segmentasyonu, tümörün normal beyin dokularından ayrılması işlemidir. Tümörün erken aşamada tanısı ve hastaya etkili tedavi uygulanabilmesi için doğru segmentasyon hayati önem taşıyan işlemlerden birisidir (Ahmad vd. 2020). Günümüzde segmentasyon radyoloji uzmanları tarafından yapılmaktadır. Beyin MR görüntülerini kullanarak glioma tümörlerini manuel olarak segmente etmek oldukça zorlu ve zaman alıcıdır. Bunun sebebi tümörlerin şekil, boyut, hacim, konum ve görünüm açısından farklı olması ve ek olarak glioma tümörlerin ödemli yapıya sahip olmasıdır. Aynı zamanda sağlıklı dokularla tümörlü dokuların yapısı birbirine benzediği için ikisini birbirinden ayırt etmek zor olmaktadır. Bu dezavantajlar da dikkate alındığında gelişen teknolojiyle birlikte beyin tümörlerinin segmentasyon işleminin tamamen otomatik olarak bilgisayarlar üzerinde gerçekleşmesi üzerine yapılan çalışmalar giderek hız kazanmaktadır (Barzegar ve Jamzad 2021).

Bu tez çalışmasında temel amaç derin öğrenme modeli kullanılarak beyin MR görüntülerindeki tümörlü bölgeleri segmente etmektir. Bunun için yapılan araştırma sonucunda beyin tümörü görüntü segmentasyonu için Evrişimsel Sinir Ağı (CNN) temeline sahip UNet tabanlı bir derin öğrenme modeli kullanılması uygun görülmüştür. Veri seti olarak ise Medical Image Computing and Computer Assisted Intervention (MICCAI) BRATS 2019 veri seti kullanılmıştır (İnt.Kyn.12, Menze vd. 2015, Bakas vd. 2017, Bakas vd. 2018). Paylaşılan veri seti içerisinde 335 kişiye ait MR çekimleri bulunmaktadır. Bu MR çekimlerinde HGG ve LGG türünde tümörler bulunmaktadır. Veri setinde her kişiye ait Flair, T1, T1ce, T2 modalitesindeki MR çekimleri ve radyoloğun yaptığı segmentasyon çalışması yer almaktadır.

UNet modeli ile segmentasyon işlemi oldukça ağır olduğu için bu çalışmada temel motivasyon modelin matematiksel hesaplama yükünü azaltırken CNN tabanlı segmentasyon modelinin performansını arttırmaktır. Bu nedenle beyin manyetik rezonans (MR) görüntüleri modele girmeden önce modelin verimliliğini arttıran çeşitli ön işlemlerden geçmiştir. İlk olarak veri setindeki görüntüler modelde kullanılabilecek hale dönüştürülmüştür. Sistemin fazla yoğunluğa maruz kalmaması için tümör içermeyen dilimler çıkartılmıştır. Küçük boyuttaki tümör görüntülerinin daha iyi analizini yapmak

iin de blme ve krpma ilemleri uygulanmıřtır. Krpma ileminde belirli koordinatları alırken verimizi etkilememesi iin, paylařılan grntler ierisindeki ok kk deęerlerde, daęınık ve gzle grlmeyen piksel deęerleri eřikleme ilemi ile grntlerden ıkarılmıřtır.

Radyoloęun yaptıęı segmentasyon grntlerinde farklı etiket deęerleriyle temsil edilen nekroz, geniřleyen tmr ve dem kısımları yer almaktadır. Bu blgelerin daha iyi tespit edilmesi iin farklı modalitedeki grntler birleřtirilerek modelin eęitiminde kullanılmıřtır. Yapılan bu ilem modelde doęruluęu arttıran ana faktrlerden birisidir. Modeli deęerlendirmek iin CNN mimarilerinin sınıflandırma performansının deęerlendirilmesinde en yaygın kullanılan doęruluk perfomans metrięi kullanılmamıřtır. Doęruluk metrięi yerine segmentasyon alıřmalarının sonularının deęerlendirmesinde en yaygın kullanılan Zar Benzerlik Katsayısı (DSC) performans metrięi kullanılmıřtır. alıřmada optimizasyon algoritması olarak, daha nceden yapılan alıřmalarda da kendini kanıtlayan Adaptive Moment Estimation (ADAM) kullanılmıřtır (Kingma ve Ba 2017). nerilen model ve eřitli n ilemler ile modelin performansı arttırılırken, farklı yıęın boyutu ve iterasyon deęerleri kullanılarak elde edilen sonular kıyaslanmıřtır.

2. GENEL BİLGİLER ve LİTERATÜR BİLGİLERİ

2.1 Beyin Tümörü

Tümör, hücrelerin olması gerekenden fazla büyüüp bölündüğü veya gerektiğinde ölmediği zaman oluşan anormal hücrelerin bir araya gelerek oluşturduğu doku kütesidir. Tümörler iyi huylu (malignant) veya kötü huylu (benign) olmaktadır. İyi huylu tümörler büyüyebilir, ancak yakındaki dokulara veya vücudun diğer bölümlerine yayılmazlar. Kötü huylu tümörler yakındaki dokulara, aynı zamanda kan ve lenf sistemleri yoluyla vücudun diğer bölgelerine de yayılarak tüm vücudu istila edebilmektedirler (Wang ve Chung 2022).

Beyin tümörü, beyinde kanserli veya kanserli olmayan bir kitle veya anormal hücrelerin gelişimi olarak tanımlanmaktadır.

2.1.1 Beyin Tümörü Dereceleri

Beyin tümörleri, ne kadar hızlı büyüdüklerine ve tedaviden sonra tekrar büyüme olasılıklarına göre derecelendirilirler. Derece 1 ve derece 2 tümörler düşük dereceli; derece 3 ve derece 4 tümörler yüksek derecelidir. Derece 1 ve 2 beyin tümörleri kanserli olmayan iyi huylu (benign) beyin tümörleridir. Düşük dereceli beyin tümörleri yavaş büyürler ve tedaviden sonra geri dönme olasılıkları daha düşüktür ancak düzenli olarak takip edilmesi şarttır. Derece 3 ve 4 beyin tümörleri kanserli yani kötü huylu (malignant) beyin tümörleridir ve yüksek derecelidirler. (Wang ve Chung 2022) . Kötü huylu beyin tümörleri ya beyinde başlar (birincil tümörler) ya da başka bir yerden beyne metastaz olarak yayılırlar (ikincil tümörler). Tedaviden sonra tekrar büyümeleri daha olası tümörlerdir (İnt.Kyn.1).

2.2 Beyin Tümörü Türleri


2.2.1 Birincil Beyin Tümörleri

Birincil beyin tümörleri, beyinde başlayan tümörlerdir. Bu tümörler beyin dokularından veya beyin yakın çevresinden kaynaklanan tümörlerden oluşmaktadır. Birincil tümörleri iyi huylu veya kanserli olabilmektedirler. Glial hücrelerden veya glial olmayan (sinirler, kan damarları ve bezleri dahil olmak üzere beyin yapılarında veya içinde gelişir) hücrelerden kaynaklanmaktadır. Glial hücrelerin görevi; merkezi sinir sisteminin yapısını desteklemek, merkezi sinir sistemine beslenme sağlamak, hücresel atık ve ölü nöronları parçalamaktır. Glial hücrelerden gelişen tümörlere glioma tümör denilmektedir (Barzegar ve Jamzad 2021).


2.2.1.1 Gliomalar

Gliomalar en sık görülen birincil beyin tümörleridir ve beyin tümörlerinin yarısından fazlasını oluşturmaktadırlar. LGG ve HGG olarak sınıflandırılmaktadır. LGG tümörler kanserli olmayan iyi huylu beyin tümörleridir; Derece 1 ve derece 2 tümörleri kapsar. HGG tümörler ise kanserli kötü huylu tümörlerdir; derece 3 ve derece 4 tümörleri kapsar.

Glioma görüntüleri kendi içerisinde 3 alt bölge içerir. Bunlar; Şekil 2.1’de görüldüğü üzere nekroz, ödem ve genişleyen tümördür. Nekroz tümörün çekirdeğini oluşturmaktadır. Glioma tümörlerin katmanlardan oluştuğu düşünülürse tümörün en iç kısmında nekroz bulunur. Nekrozdan bir sonraki katman ise genişleyen tümörlerdir. Tümörün en dış kısmında ödem yer almaktadır. Şekil 2.2’de segmentasyon işlemini uyguladığımızda elde edilen tümör görüntüsünün segmente edilmiş alt bölgeleri yer almaktadır.



Şekil 2.1 Glioma alt sınıfları (Rehman vd. 2020).



Şekil 2.2 Nekroz, ödem ve genişleyen tümör segmentasyon görüntüsü.

2.2.2 İkincil Beyin Tümörleri

İkincil yani metastatik beyin tümörleri, vücudun başka yerlerinde (meme veya akciğerler gibi) ortaya çıkan ve genellikle kan dolaşımı yoluyla beyne göç eden tümörlerdir. Metastatik tümörler kanser olarak kabul edilir ve kötü huyludurlar (Menze vd. 2015).

2.3 Beyin Tümörü Teşhis Yöntemleri


Ultrasonografi, tomografi, radyografi, nükleer tıp, MRG gibi tıbbi görüntüleme teknikleri hastalığın anatomisi ve teşhisinde günümüzde büyük önem arz etmektedir (Bakas vd. 2018). Bu görüntüleme teknikleri arasında MRG beyin tümörlerinin teşhisi için uygun bir görüntüleme tekniğidir. MRG, tümörlerin doğası, konumu ve büyüklüğü hakkında noninvaziv bir şekilde kapsamlı veriler sağlamaktadır. MRG, vücudun görüntülerini ayrıntılı bir şekilde üretmek için x-ışınlarını değil manyetik alanları kullanır. (Bakas vd. 2017).

Farklı MRG teknikleri vardır. Uzman tarafından yapılan muayene sonucunda hangi tip MRG'nin kullanılacağına karar verilir. Beyin tümörünün daha net bir görüntüsünü oluşturmak için intravenöz (IV) damar içine gadolinyumla güçlendirilmiş MRG kullanılmaktadır. Difüzyon ağırlıklı görüntüleme beyin hücresel yapısını göstermeye yardımcı olurken perfüzyon görüntüleme tekniği ise tümöre ne kadar kan ulaştığını gösterir. Fonksiyonel MRG (fMRG), beyin kas hareketi ve konuşmadan sorumlu olan belirli alanlarının konumu hakkında bilgi sağlar. fMRG incelemesi sırasında hastadan fMRG görüntüsünde değişikliklere neden olan belirli görevleri yapması istenir. Böylece ameliyat sırasında cerrah tümörü çıkarırken beyin fonksiyonel kısımlarına zarar vermekten kaçınır (Menze vd. 2015).

2.4 Manyetik Rezonans Görüntüleme Sekansları

Bilinen dört standart MRG sekansı vardır. Bunlar T1 ağırlıklı MRG (T1), T2 ağırlıklı MRG (T2), gadolinyumlu T1 ağırlıklı MRG (T1Ce) ve Fluid Attenuated Inversion Recovery-Akışkan Zayıflatılmış İnversiyon Kurtarma (FLAIR)'dır (Kronberg vd. 2022). Şekil 2.3'te MRG sekansları ile çekilen beyin MR görüntüleri yer almaktadır.

Sağlıklı dokuları kansere yatkın bölgeden ayırt etmek için Flair kullanılır. T2 görüntüleriyle tümörün ödem kısmı çekilirken; Flair görüntüleriyle de ödemin beyindeki diğer sıvı dolu yapılardan ayrımı yapılır. Tümörün genişleyen ve nekroz kısmı ise T1ce görüntüleri kullanarak incelenmektedir (Coupet vd. 2022).



Şekil 2.3 Beyin tümörü MRG sekans görüntüleri (Arora vd. 2021).

2.5 Yapay Zekâ

Yapay zekâ, görevleri yerine getirmek için insan zihninin problem çözme ve karar verme yeteneklerini taklit eden ve topladıkları bilgilere dayanarak kendilerini yinelemeli olarak geliştirebilen sistemler veya makineler anlamına gelmektedir. Günümüzde yapay zekâ sistemleri kullanılarak birçok uygulama gerçekleştirilmektedir. Konuşma tanıma, müşteri hizmetleri, bilgisayarla görme, öneri motorları, sürücüsüz arabalar bu uygulamalar arasındadır (Kayadibi 2021). Sağlık sektöründe ise ilaçların doz ayarı, hastaya uygun tedaviler, ameliyathanelerde cerrahi prosedürler ve ameliyat öncesi doğru tedavi için segmentasyon işlemlerinde kullanılmak üzere test edilmekte ve kullanılmaktadır (Bakas vd. 2018).


Doğru tedavi için segmentasyon işlemlerinde kullanılan yapay zekâ uygulamalarından birisi de beyin MRG görüntülerinin segmentasyon işlemidir. Günümüzde beyin tümörlerinin segmentasyonu manuel olarak radyoloji uzmanları tarafından yapılmaktadır. Beyin tümörü segmentasyonunun amacı sağlıklı dokuyu tümörlü bölgelerden ayırmak; tümör bölgelerinin alanını ve kapsamını belirlemektir. Beyin tümörlerinin manuel olarak

segmente edilmesi işlemi uzmanlık ve beceri gerektirmektedir. Çünkü beyin tümörlerinin boyut, şekil, konum ve görünüm açısından farklılıkları ve karmaşık yapısı nedeniyle MRG görüntülerini segmentlere ayırmak zorlu ve zaman alıcıdır. Gelişen teknoloji ile birlikte MRG görüntülerinde tümörlerin otomatik segmentasyonu üzerinde çalışmalar giderek hız kazanmaktadır. Tümörlü dokunun yapay zekâ ile tespiti, insan hatasını azaltma ve mümkün olan maksimum doğruluğu sağlama gerekliliği bu konuya olan ilgiyi arttırmaktadır.

2.6 Makine Öğrenmesi

Makine öğrenimi, sistemlerin veriler ve deneyimlerden öğrenip, kendilerini geliştirmelerini sağlayan bir yapay zekâ uygulamasıdır. Makine öğreniminde amaç, insan müdahalesi olmadan sistemin tek başına kendisi için öğrenmesini sağlamak ve eylemleri buna göre ayarlamaktır (Sertkaya 2018).


Makine öğreniminde çalışma süreci Şekil 2.4'te görülmektedir. Verileri bir araya getirmeyle başlayan süreçte, 2. adım resimleri modele uygun hale getirmektir. Sonrasında elde edilen veriler için model seçildikten sonra eğitim ve test verileriyle model çalıştırılır ve ardından bizim için anlamlı bir tahmin oluşturulur.



Şekil 2.4 Makine öğrenme süreci (İnt.Kyn.2).


Geleneksel programlamada genel yaklaşım makinelerle çözülmesi gereken problem için

veri seti ve kurallar verilir ve yanıt elde edilir. Burada bahsedilen kurallar algoritma ve prosedürlerdir. Şekil 2.5'te görüldüğü gibi geleneksel programlama yaklaşımında makine kendisine verilen veri setini ve kuralı kullanarak çıktı üretir. Beklenen çıktı ise problemin çözümü yani yanıttır.




Şekil 2.5 Geleneksel programlama yaklaşımı.

Makine öğrenmesinde ise Şekil 2.6'daki gibi veri seti ile birlikte sonuçlar verilerek makineden algoritma ve prosedürleri oluşturması beklenmektedir. Makine öğrenmesi, insan davranışını taklit etmekle kalmayıp aynı zamanda insanların nasıl öğrendiğini de taklit etmektedir (İnt.Kyn.2).




Şekil 2.6 Makine öğrenimi yaklaşımı.

Makine öğrenimi yaklaşımı üç alt gruba ayrılmaktadır. Bunlar; denetimli, denetimsiz ve pekiştirmeli öğrenmedir (Salas-Pilco ve Yang 2022). Denetimli öğrenim, modelin etiketli verilerle eğitilmesidir. Model eğitimi tamamlandığında, kendisine yeni veri verilir ve tahmin veya karar vermeye başlar (Ünlüsavuran 2019). Şekil 2.7'de denetimli öğrenme çalışma mekanizması yer almaktadır.




Şekil 2.7 Denetimli öğrenme (Taş 2021).

Şekil 2.8’de görüldüğü gibi denetimsiz öğrenmede makineye hiçbir etiketli veri sağlanmaz ve kendi içerisinde bağlantı kurarak gruplama sağlanır. Makine, daha önceden düzenlenmemiş yani etiketlenmemiş bilgileri benzerliklere, kalıplara ve farklılıklara göre gruplandırır (Ünlüsavuran 2019).



Şekil 2.8 Denetimsiz öğrenme (Taş 2021).


Pekiştirmeli öğrenmede ise modele etiketsiz veriler verilir ve deneme yanılma yoluyla öğrenmesi beklenir. Makineye etiketsiz veriler verilirken ürettiği her doğru çözüme ödül verilir. Böylece hep ödül alarak çözüm üretmesi sağlanır ve sürekli iyileştirme prensibiyle modeli geliştirmesi istenir (İnt.Kyn.3). Şekil 2.9’da pekiştirmeli öğrenme çalışma prensibi yer almaktadır.



Şekil 2.9 Pekiştirmeli öğrenme (Taş 2021).

2.7 Derin Öğrenme


Algoritmalar insan beyninin yapısını ve işlevini taklit ederek çalışmaktadır. Derin öğrenme makine öğreniminin bir alt kümesidir. Makine öğrenimi algoritmaları, etiketlenmiş verilerle tahmin yaparken; derin öğrenme, yapılandırılmamış verileri alıp işler ve insan uzmanlarına olan bağımlılığı azaltarak özellik çıkarmayı otomatik hale getirir. Makine öğrenmesinde daha fazla insan müdahalesi gerektirirken derin öğrenme algoritmaları çok daha az insan müdahalesi gerektirir (Salas-Pilco ve Yang 2022). Çalışma prensibindeki bu farklılık Şekil 2.10’da gösterilmektedir.



Şekil 2.10 Makine öğrenimi ve derin öğrenimi çalışma prensibi (Kayadibi 2021).


Derin öğrenmenin en iyi avantajı büyük miktarda veri ile desteklenmesidir. Geleneksel

makine öğreniminde modeller bir doygunluk noktasından sonra gelişmeyi bırakmaktadır. Derin öğrenme modelleri ise veri kümesi ve ağ yapısı büyüdükçe doğruluklarını da artırmaktadır. Şekil 2.11’de performanstaki artış grafikte birlikte yer almaktadır.



Şekil 2.11 Derin öğrenme modellerinin daha fazla veriyle gelişimi (İnt.Kyn.4).

Makine öğrenmesinde algoritmalar doğrusal regresyon veya karar ağacı gibi oldukça basit bir çalışma prensibine sahiptir. Derin öğrenme ise Şekil 2.12’deki gibi bir yapay sinir ağına (YSA) dayanmaktadır.




Şekil 2.12 Yapay sinir ağı (YSA) modeli (Sertkaya 2018).

Burada derin kelimesinin anlamı katman sayısının çok olmasından gelmektedir. Giriş katmanı ile çıkış katmanı arasında ne kadar gizli katman varsa model o kadar derindir. Derin öğrenme uygulamaları, yapay sinir ağı (YSA) adı verilen katmanlı bir algoritma


yapısı kullanır. YSA'lar birbirine bağı katmanlardan oluşur. Verilen girdileri işleyen ve her katman arasında bilgi aktaran bir bilgi işlem sistemine sahiptir (Tiken 2015).

Bu çok katmanlı YSA, insan beyninin biyolojik sinir ağından esinlenerek çalışmaktadır. Böyle bir YSA'nın tasarımı, standart makine öğrenimi modellerinden çok daha yetenekli bir öğrenme sürecine yol açar. Bu yüzden çok katmanlı YSA'lara derin YSA denilmektedir. Şekil 2.13'te tek katmanlı YSA ve derin YSA modellerinin katman yapıları yer almaktadır.




Şekil 2.13 Tek katmanlı YSA ve derin YSA modeli (İnt.Kyn.5).

Yapay sinir ağları katmanlar halindeki nöronlardan oluşur. Nöronlar sistemden aldıkları bilgiyi bazı işlemlerden geçirdikten sonra bir sonraki nörona aktarır. Bu çalışma prensibi de insanlardaki sinir ağı yapısına oldukça benzemektedir. Şekil 2.14'te biyolojik sinir hücre yapısı görülmektedir. YSA'daki weight (w) yani ağırlık faktörleri (w_i) biyolojik sinir hücrelerindeki sinapslara, birimler arasındaki bağlantılar akson ve dendritler, transfer fonksiyonu da hücre gövdesinin göreviyle bağdaşmaktadır (Şanlıtürk 2018).



Şekil 2.14 Biyolojik sinir hücrelerinin yapısı (Yakıt ve Özkan 2017).



Şekil 2.15 YSA nöronların yapısı (İnt.Kyn.6).

Nöronlarda çalışma şu şekilde gerçekleşir; gelen girdiyi (input), ağırlık (weight) değişkeniyle çarptıktan sonra sapma değişkeni (bias) ile toplayıp bir sonuç üretir. Oluşan bu sonucu aktivasyon fonksiyonundan (activation function) geçirerek bir çıktı üretilmesi sağlanır. Daha sonrasında üretilen bu çıktı diğer nörona aktarılır ve katmanlar içinde bu durum Şekil 2.15'teki gibi devam eder (Kurt 2018). Nöronların çalışma şeklinin matematiksel formülasyonu Denklem 2.1'de ifade edilmiştir.

$$Y = \text{aktivasyon}(\Sigma(\text{ağırlık} * \text{girdi}) + \text{değişken}) \quad (2.1)$$

Denklem 2.1'de yer alan matematiksel işlemdeki amaç sonucun doğrusal olmayan bir


yapıda olmasını sağlamaktır. Eğer sonuç doğrusal olursa karmaşık öğrenme işlemleri gerçekleştirilememektedir. Sonuç olarak aktivasyon fonksiyonu, karmaşık işlemlerin öğrenilmesinde önemlidir. Bu nedenle aktivasyon fonksiyonuna karar verilirken lineer olmaması önemlidir. Şekil 2.16'da en çok kullanılan aktivasyon fonksiyonları yer almaktadır.

Yukarıdaki denklemde kullanılan bias değerinin önemi ise şu şekilde anlatılmaktadır: Eğer modelde kullanılan aktivasyon fonksiyonu çıktıları 0–1 aralığında ve denklemin sonucu da 1'den büyük çıkıyorsa nöronlar sürekli aktif olacaktır. Bu durumu engellemek için denklemde uygun bias değeri kullanılmaktadır.

$$(x1.w1 + x2.w2 + x3.w2) > 1 \quad (2.2)$$

Sonuçlar Denklem 2.2'deki gibi 1'den büyük çıkarsa nöron sürekli olarak aktive olmaya devam edecektir ve bu istenen sonuca ulaşılmasını engelleyecektir. Ancak Denklem 2.3'te de belirtildiği gibi denklemini etkileyecek bias değeri gibi bir değişken eklenirse istenilen ayar yapılacaktır. Böylece aktivasyon fonksiyonunun grafik üzerinde uygun yere taşınması sağlanacaktır. Uygun değer bulunması işlemi algoritma tarafından kontrol edilir. Bu değer bulunması işlemine de öğrenme denir (Tiken 2018).

$$(x1.w1 + x2.w2 + x3.w2) + b < 0 \quad (2.3)$$




Şekil 2.16 En çok kullanılan aktivasyon fonksiyonları (Kurt 2018).

Derin öğrenme modellerinde çalışma soldan sağa ileri yayımlı şeklindedir. Şekil 2.17’de her iki yapıda da ileri yayılım modeli bulunmaktadır. İleri yayılım modelinde nöronlar giriş katmanından aldıkları veriyi ağırlıklarla çarpıp, uygun aktivasyondan geçirdikten sonra bağlantılı bir sonraki nörona aktarmaktadırlar. Katmanlar arasındaki bu süreç çıkış katmanına kadar devam etmektedir. Nöronlardan alınan bu sonuçlar çıkış katmanına geldiğinde nihai sonuca çevrilir ve tahmin olarak nitelendirebileceğimiz sonuç üretilir (Pekel 2018).

Elde edilen tahmin değeri beklenen değerden farklı da gelebilmektedir. Bunun anlamı modeldeki öğrenme değeri istenen seviyeye ulaşamamış demektir. Bu durumu düzeltmek

için son gizli katmandan ilk katmana kadar tüm ağırlık ve sapma değişkenleri yeniden düzenlenerek geriye doğru işlem gerçekleşir. Yapılan bu işleme geri yayılım denir (Tiken 2018).



Şekil 2.17 İleri yayılım ve geri yayılım (İnt.Kyn.7).

Temel olarak kullanılan bazı derin öğrenme teknikleri vardır. Bunlar;


- Klasik sinir ağları
- Evrişimli sinir ağları (CNN)
- Tekrarlayan sinir ağları (RNN)
- Üretken düşman ağları (GAN)
- Kendi kendini düzenleyen haritalar (SOM)
- Boltzmann makineleri
- Derin takviyeli öğrenme
- Otomatik kodlayıcılar
- Geriye yayılma
- Dereceli alçalma

2.8 Evrişimsel Sinir Ağları (CNN)

Derin öğrenme tekniklerinden en popülerlerinden olan Evrişimsel sinir ağları (CNN) görüntülerdeki belirli özellikleri tanıyabilen, sınıflandırabilen ve görüntüleri analiz etmek için yaygın olarak kullanılan yöntemlerden birisidir (Sertkaya 2018). CNN; bilgisayarların girdi görüntüsünü görmesine, sınıflandırmasına, kalıpları görmesine ve

ondan öğrenmesine yardımcı olmaktadır. CNN’de ağırlar bölüm 2.5’te de bahsedildiği üzere biyolojik süreçlerden ilham almaktadır.


İnsanlar doğduğu andan itibaren nesneleri tanımlamak için gözlerini kullanmaya başlamaktadır. Ancak bilgisayarlar insanların bu şekilde görme ve anlama yetisine sahip değildir. Bilgisayarlar bir görüntü gördükleri zaman sadece resmin özelliğini, belli yerlerdeki parlaklık vb. gibi özelliklerine tanımlı piksellerin değerini görmektedirler. Örneğin bir ‘a’ harfini CNN Şekil 2.18’deki gibi görmektedir. CNN’ler bilgisayarlara kendilerine has bir görüş özelliği vermektedir. Bu sayede bilgisayarlar, görüntü tanıma ve görüntü sınıflandırmasına yardımcı olacak, gördüğü tüm pikselleri ve sayıları alır. Görülen bu piksel değerleri sayesinde CNN’ler bilgisayarların da insan gözlerine sahip olmasına yardımcı olmaktadır (İnt.Kyn.8).



Şekil 2.18 Bilgisayarların sayılarla görüş özelliği (Barın 2021).

CNN mimarileri temel olarak üç katmana sahiptir: evrişim katmanı, havuz katmanı ve tamamen bağlantılı katman. Evrişim katmanı, evrişimsel sinir ağının ilk katmanıdır. Evrişim katmanlarını ek evrişim katmanları veya havuz katmanları izlemektedir. Tam bağlantılı katman CNN’de son katmandır. CNN mimarilerinin çalışma prensibi; ilk katmanlarda renkler, kenarlar gibi daha basit özelliklere odaklanılır. Katmanlarda ilerledikçe görüntünün daha büyük bölümlerine odaklanarak karmaşıklık giderek arttırılır. Katmanlarda ileriye doğru gittikçe amaçlanan nesne tanımlanana kadar,


nesnenin daha büyük öğelerini veya şekillerini tanır (Yamashita vd. 2018). Şekil 2.19’da CNN mimarilerindeki katmanlar yer almaktadır.




Şekil 2.19 Temsili CNN mimarisi (Arı ve Hanbay 2019).

2.8.1 Evrişim (Convolution) Katmanı

Evrişim katmanı, sinir ağı modelindeki gibi girdi görüntüsünün bir dizi ağırlıklarla çarpılmasını ve sonunda toplanmasını içeren matematiksel işlemleri kapsamaktadır. Bahsedilen matematiksel işlem Şekil 2.20’de gösterilmektedir. Matematiksel işlemdeki çarpma işlemi, giriş resmi ile filtre (çekirdek) arasında gerçekleşir. Görüntü üzerinde gerçekleşen evrişim işleminde, görüntü matrisinden daha küçük boyutta seçilen filtreler görüntü üzerinde piksel piksel kaydırılmaktadır. Filtredeki ağırlıklarla görüntü arasındaki matematiksel işlem sonucunda ‘evrişimli görüntü’ oluşmaktadır (Öğüt 2019). Filtre boyutu ve kaydırma sayısı en iyi sonucu elde etme amacıyla uzmanlar tarafından değiştirilebilmektedir.




Şekil 2.20 Evrişim katmanında yapılan matematiksel işlem (Öğüt 2019).




Şekil 2.21 Yapılan matematiksel işlemle birlikte filtrenin giriş görüntü üzerinde kaydırılması işlemi (Fathi ve Shoja 2018).

Şekil 2.21’de evrişim işleminde bahsedilen filtre kaydırma ve evrişim görüntüsü oluşturma işlemi yer almaktadır. Burada 2 boyutlu ve 5x5 büyüklüğündeki resime 3x3 boyutundaki filtre uygulanmıştır. Uygulanan her filtre işleminde Şekil 2.20’de yer alan matematiksel işlem uygulanmaktadır. Bu işlem filtrenin pikseller üzerindeki her kayışında tekrarlanmaktadır.

Günümüzde CNN modelleri RGB formatındaki renkli resimler gibi 3 boyutlu görüntülerle de çalışmaktadır. 3 boyutlu görüntüler üzerindeki filtre hareketi Şekil 2.22’deki gibidir. RGB resimlerle evrişim işlemi 2 boyutlu resimlerdekine benzer şekilde gerçekleştirilmektedir. Renkli resimlerde her renk katmanı için ayrı evrişim işlemi gerçekleştirilmektedir. Şekil 2.23’te evrişim işlemi çalışma şekli yer almaktadır.



Şekil 2.22 RGB formatlı görüntüde filtrenin hareketi (İnt.Kyn.9).




Şekil 2.23 RGB resimlerde evrişim işlemi (İnt.Kyn.9).

2.8.2 Havuzlama (Pooling) Katmanı


CNN mimarilerinde genellikle evrişim katmanlarından sonra havuzlama katmanı eklenmektedir. Bunun sebebi; havuzlama katmanının evrişim işleminden sonra girdi görüntüsünün boyutunu azaltmasıdır. Eğer tam bağlantılı katmandan sonra havuzlama uygulaması yapılmazsa hesaplama maliyeti yüksek olacaktır. Hesaplama maliyetinin yüksek olması mimarinin gelişmiş donanım ihtiyacına veya eğitimin çok uzun sürmesine sebep olacaktır (Öğüt 2019). Bu nedenle, havuzlama işlemi girdi görüntüsünün hacmini

azaltmak için oldukça önemli bir işlemdir. Maksimum havuzlama ve ortalama havuzlama olmak üzere iki tip havuzlama çeşidi vardır. Şekil 2.24'te görüldüğü gibi, maksimum havuzlamada girdi belirli boyutlarda filtre içine alınmakta ve filtre içerisinde bulunan değerlerden en büyük değer kullanılmaktadır. Ortalama havuzlamada, filtre içinde bulunan değerlerin ortalaması alınmakta ve ortalama değer kullanılmaktadır (Baykal 2019). Ortalama havuzlama işlemindeki çalışma şekli Şekil 2.25'te yer almaktadır.

Maksimum havuzlama, özelliği gereği hem gürültülü aktivasyonları tamamen ortadan kaldırır hem de boyut azaltmayla da birlikte gürültünün giderilmesini sağlamaktadır. Ortalama havuzlamada ise sadece boyut azaltma özelliği ile gürültü giderme sağlanmaktadır. Dolayısıyla maksimum havuzlama ortalama havuzlamadan daha iyi performans göstermekte ve daha çok tercih edilmektedir (Baykal 2019).



Şekil 2.24 Maksimum havuzlama (Kurt 2018).




Şekil 2.25 Ortalama havuzlama (Kurt 2018).

2.8.3 Tam Bağlantılı Katman

Tam bağlantılı katmanlar çoğunlukla CNN mimarilerinin son katmanlarını oluşturmaktadır. Bu katmandaki nöronlarla önceki katmandaki tüm nöronlar arasında doğrudan bağlantı bulunmaktadır. Bu bağlantı sayesinde tam bağlantılı katman; önceki katmanlardaki nöronlarla kendi nöronlarını bağlayarak düzleştirme işlemini gerçekleştirir. Böylece evrişim katmanı ile havuzlama katmanlarından geçen matris halindeki veriler düz bir vektör haline getirilir ve daha sonra bu çıkış katmanına bağlanır. Sonuç olarak önceki katmanlardan ve bunların farklı filtrelerinden çıkarılan özniteliklere dayalı olarak sınıflandırma görevi gerçekleştirilir (Baykal 2019).

Evrişim ve havuzlama katmanları ReLu işlevlerini kullanma eğilimindedir. Ancak tam bağlantılı katman, katmanları uygun sınıflandırma yapmak için genellikle softmax etkinleştirme işlevinden yararlanır ve 0 ile 1 arasında bir olasılık üretir (Yamashita vd. 2018). Şekil 2.26'daki CNN mimarisinde 3 sınıflı çıkışa sahip tam bağlantılı katman yapısı gösterilmektedir.




Şekil 2.26 Tam bağlantılı katman yapısı (Barın 2021).

2.8.4 Seyreltme (Dropout) Katmanı

Seyreltme katmanı genellikle CNN’lerde tam bağlı katmanlardan sonra kullanılır. Büyük sinir ağlarında az miktarda veri kullanıldığı zaman çoğunlukla ağ veriyi ezberlemekte, bu da ağı diğer verilerle eğitmek istediğimizde başarı oranının oldukça düşük çıkmasına sebep olmaktadır. Bu durumun önüne geçmek için ise seyreltme (dropout) katmanı kullanılmaktadır. Seyreltme katmanının çalışma prensibi eğitim sırasında rastgele veya belli eşik değerlerine göre bazı düğümlerin kaldırılması yani ağırlıklarının sıfır olarak ayarlanması mantığıyla çalışmaktadır. Nöronların birbirlerinin ağırlık değişimlerinden daha az etkilenmesiyle birlikte daha tutarlı (robust) modeller oluşturulmakta ve ağın performansı artmaktadır (Türkoğlu vd. 2020).

Şekil 2.27’de standart sinir ağı yapısı ve seyreltme katmanı uygulanmış sinir ağı yapısı yer almaktadır. Şekilde görüldüğü üzere standart sinir ağı yapısında tüm nöronlar kullanılırken; seyreltilmiş katman uygulanmış sinir ağında bazı nöronlar kullanılmamaktadır.



Şekil 2.27 Standart sinir ağı ve seyreltme katmanı uygulanmış sinir ağı (Karakullukçu 2020).


2.9 CNN Eğitiminde Kullanılan Hiper Parametreler

Derin öğrenme modellerinde, kullanılan veri seti ve ihtiyaca bağlı olarak bazı parametrelerin belirlenmesi gerekir. Eğitimde en iyi sonucu elde edebilmek için kullanılan bu parametrelerin uygun değerlerde seçilmesi oldukça önemlidir.

2.9.1 Öğrenme Oranı (Learning Rate)

Öğrenme oranı (learning rate), model ağırlıkları her güncellendiğinde tahmini hataya yanıt olarak modelin ne kadar değiştirileceğini kontrol eden bir hiper parametredir (Tiken 2015). Öğrenme oranı çok küçük bir değer seçildiğinde uzun bir eğitim süreci ile sonuçlanabilirken, çok büyük değer Şekil 2.28'deki gibi kararsız bir eğitim süreci ile sonuçlanabilir.

Derin sinir ağları için öngörülen öğrenme oranı 0.000001 ile 1 arasında olmalıdır (Ay Karakuş 2018). Öğrenme oranını başlangıçta 0.1 veya 0.01 gibi büyük değerler seçip belli bir epoktan sonra bu değerlerin kademeli olarak düşürülmesi daha uygundur (Patterson ve Gibson 2017).



Şekil 2.28 Öğrenme oranlarına göre kayıp değerlerinin değişimi (Altun ve Talu 2021).

2.9.2 Kayıp Fonksiyonu (Loss Function)

Kayıp fonksiyonu, model eğitim sonucunda ulaşılmak istenilen sonuçla elde edilen sonuç arasındaki hata oranını ölçer ve ölçülen bu değere kayıp (loss) denir. Eğer iyi tahminde bulunan bir model oluşturmuşsak gerçek değer (ground truth) ile tahmin edilen değer arasındaki fark az olacak ve kayıp değeri oldukça düşük, sıfıra yakın değere sahip olacaktır. Ancak aradaki fark yüksek olursa kayıp değeri yüksek olacak ve tahminler gerçek sonuçlardan epey sapmış olacaktır (Tan 2019). Çizelge 2.1’de segmentasyon işlemleri için kullanılmakta olan kayıp fonksiyonları ve formülasyonları yer almaktadır.

Çizelge 2.1 Segmentasyon Mimarilerinde Kullanılan Kayıp Fonksiyonları (Barın 2021).

Kayıp Fonksiyon	Formülasyon
İkili Çapraz Entropi (Binary Cross Entropy)	$BCE(\hat{p}, p) = -(p \cdot \log(p) + (1 - \hat{p}) \cdot \log(1 - p))$
Ağırlıklı Çapraz Entropi (Weighted Cross Entropy)	$WBCE(\hat{p}, p) = -(\beta \cdot p \cdot \log(p) + (1 - \hat{p}) \cdot \log(1 - p))$

Çizelge 2.1 (Devam) Segmentasyon Mimarilerinde Kullanılan Kayıp Fonksiyonları (Barın 2021).

Kayıp Fonksiyon	Formülasyon
Merkezi (Focal)	$p_t = \begin{cases} p & \text{if } y = 1 \\ 1 - p & \text{otherwise,} \end{cases}$ $FL(p_t) = -(1 - p_t)^\gamma \log(p_t)$
Hassasiyet- Duyarlılık (Sensitivity-Specifity)	$SSL = W * \text{hassasiyet} + (1 - w) * \text{duyarlılık}$ $\text{Hassasiyet} = \frac{TP}{TP + FN}$ $\text{Duyarlılık} = \frac{TN}{TN + FP}$
Hausdorff Uzaklığı (Hausdorff Distance)	$d(X,Y) = \max_{x \in X} \min_{y \in Y} x-y _2$
Kombinasyon(Combo)	$L_{m-bce} = -\frac{1}{n} \sum_i \beta(y - \log(\tilde{y})) + (1 - \beta)(1 - y) \log(1 - \tilde{y})$ $CL(y, \tilde{y}) = \alpha L_{m-bce} - (1 - \alpha) DL(y, \tilde{y})$
Mesafe Haritası Kaynaklı Kayıp Ceza Süresi (Distance Map Derived Loss Penalty Term)	$L(y, p) = \frac{1}{N} \sum (1 + \emptyset)(\mathcal{E}) L_{ce}(y, p)$
Zar Benzerlik Katsayısı(Dice)	$DL(y,p)=1-\frac{2yp+1}{y+p+1}$
Tversky	$TL(p, \rho) = \frac{1 - p\rho}{1 + p\rho + \beta(1 - p)\rho + (1 - \beta)p(1 - \rho)}$
Merkezi Tversky (Focal Tversky)	$T1(p\rho) = \frac{1 - p\rho}{1 + p\rho + \beta(1 - p)\rho + (1 - \beta)p(1 - \rho)}$ $FTL = \sum (1 - T1c)^Y$
Şekile Duyarlı (Shape Aware)	$E_i = D(\hat{C}, C_{GT})$
Üstel Logaritmik (Exponential Logarithmic)	$L_{\text{shape-aware}} = \sum CE(y, \hat{y}) - \sum_i E_i CE(y, \hat{y})$ $L_{EXD} = W_{\text{Dice}} L_{\text{Dice}} + W_{\text{Cross}} L_{\text{Cross}}$ $L_{\text{Dice}} = E(-\ln(DC))^{Y_{\text{Dice}}}$ $L_{\text{Cross}} = E(-\ln(p_t))^{Y_{\text{Cross}}}$

2.9.3 Epok Sayısı

Epok sayısı öğrenme algoritmasının tüm eğitim veri kümesi boyunca çalışacağı sayıyı tanımlayan bir hiperparametredir. Eğer epok sayısı çok küçük seçilirse ağ yeterince öğrenemez. Bunun tam tersi bu sayı çok büyük seçilirse de model aşırı öğrenir ve artık

ezberleme yoluna girer. Bu da modelin farklı verilerle iyi sonuçlar elde edemeyeceği anlamına gelir. Bunu önlemenin bir yolu kayıp değeri takip edilerek model için en uygun epok sayısını belirlemektir. Diğer bir yol ise keras kütüphanesinde bulunan ‘earlystopping’ özelliği sayesinde sonuç istenilen seviyeye geldiğinde modelin otomatik olarak durdurulmasıdır (Sertkaya 2018).

2.9.4 Yığın Boyutu (Batch Size)

Yığın boyutu sinir ağlarında bir epokta kullanılan eğitim örneklerinin sayısını ifade etmektedir. Yığın boyutları modele 3 farklı şekilde verilebilir:

- Batch mod (Toplu yığın mod).
- Mini batch mod (Küçük yığın mod).
- Stochastic mod (Stokastik mod).

Toplu yığın mod; verilerin hepsinin yığın halinde modele verilmesi anlamına gelmektedir. Küçük yığın mod; verilerin parçalar halinde modele verilmesi, stokastik mod; verilerin eğitime 1’er 1’er verilmesidir (İnt.Kyn.10). Ancak derin öğrenme modellerinde genelde çok büyük veriler ile çalışıldığı için küçük yığın mod ile verileri bölerek çalışmak büyük bellek maliyetlerini azaltmakta ve her yineleme sonrası ağırlıklar güncellendiği için model performansını arttırmaktadır.


Küçük yığın boyutunun seçilmesinde veri seti ve kullanılacak ağ modeli gibi kriterler önem göstermekle birlikte literatürde bunun için yapılan deneysel çalışmalar ve sonuçları da yer almaktadır (Ay Karakuş 2018, Tan 2019).

- 1, 2, 4, 8, 16 gibi küçük yığın boyutları hesaplamalarda daha fazla gürültüye sebep olmaktadır.
- 512, 1024, 2048 gibi çok büyük mini yığın değerleri hesaplamada fazla maliyetli olmakta ve modelin performansının düşük olmasına yol açmaktadır.
- 32, 64, 128, 256 gibi değerlerin veri boyutu ve türü, epok sayısı ve yapılacak işleme bağlı olarak en iyi sonucu verdiği belirtilmektedir.

2.10 Görüntü Segmentasyonu

Görüntü segmentasyonu, görüntünün analizini kolaylaştırmak için görüntünün belirli özelliklere göre çeşitli alt gruplara ayrıldığı bir yöntemdir. Segmentasyonda, görüntüdeki her piksel bir nesne ile ilişkilendirilmektedir yani piksellere etiketler atanmaktadır. Bu sayede aynı kategoriye ait tüm resim öğeleri veya pikseller, kendilerine atanmış ortak bir etikete sahip olurlar.


İki ana görüntü segmentasyonu türü vardır: anlamsal (semantik) segmentasyon ve örnek (instance) segmentasyonu (İnt.Kyn.11). Anlamsal (semantik) segmentasyonda, aynı tipteki tüm nesneler bir sınıf etiketi kullanılarak işaretlenmektedir. Örnek (instance) segmentasyonunda her nesne, birbirine benzer nesneler de dahil olmak üzere ayrı ayrı etiketlenmektedir. Şekil 2.29'da da görüldüğü üzere semantik segmentasyon uygulaması olan ilk resimdeki kişiler tek bir etikete sahipken örnek segmentasyon uygulanmış ikinci resimde her kişi ayrı etikete sahiptir.



Şekil 2.29 Semantik ve örnek segmentasyon uygulamaları (Arnab vd. 2018).

Semantik segmentasyon uygulamaları; otonom sürüş, endüstriyel muayene, uydu görüntüsü ve tıbbi görüntüleme analizini içerir. Semantik segmentasyon ağları kullanılarak etiketlenmiş görüntülerle model tasarlayıp eğitebilir ve ardından yeni görüntüleri etiketlemek için eğitilmiş ağ kullanılabilir. Eğitim görüntülerini etiketlemek için image label, video label veya ground truth label uygulamaları kullanılmaktadır (İnt.Kyn.11).

Görüntü segmentasyon işleminin temel mimari yapısı Şekil 2.30’da görüldüğü üzere genel olarak bir kodlayıcı (encoder) ve bir kod çözücünden (decoder) oluşmaktadır. Kodlayıcı, filtreler aracılığıyla görüntüden özellikleri çıkarır. Kod çözücü ise nesnenin ana hatlarını içeren bir segmentasyon maskesi olan nihai çıktının üretilmesinden sorumludur. Segmentasyon mimarilerin bir çoğu bu mimariye veya bir türevine sahiptir.



Şekil 2.30 Semantik segmentasyon mimari şeması (İnt.Kyn.11).

DeepLab v1, DeepLab v2, DeepLab v3, DeepLab v3 + , UNet, 3D UNet, V-Net, Res-UNet, DenseUNet, H DenseUNet, GANs, SegAN, SCAN, PAN, AsynDGAN, FCN, SegNet vb. gibi tıbbi görüntü segmentasyonu için kullanılan birçok mimari mevcuttur (Gite vd. 2022).


Bu çalışmada beyin MR görüntüleri segmente edilmektedir. Segmente edilen görüntüler kendi içerisinde nekroz, genişleyen tümör ve ödem olmak üzere 3 bölüme ayrılmaktadır. Bu işlem için piksel bazlı segmentasyon yapabilen kodlayıcı – kod çözücü (encoder – decoder) CNN mimarilerinden UNet mimarisi kullanılmaktadır.

2.10.1 UNET

UNet mimarisi biyomedikal görüntü segmentasyonu için Olaf Ronneberger, Philipp Fischer ve Thomas Brox tarafından Almanya Freiburg Üniversitesi’nde geliştirilmiştir (Ronneberger vd. 2015). İsmi Şekil 2.31’de görüldüğü gibi ‘ U’ harfine benzemesinden dolayı almaktadır.


Mimari sıkışma ve genişleme olmak üzere 2 bölümden oluşmaktadır. Sıkışma olarak adlandırılan bölüm görüntüdeki bağlamı yakalamak için kullanılan daralma yoludur. Sıkışma bölümü aynı zamanda kodlayıcı olarak da adlandırılmaktadır. Sıkışma kısmı geleneksel evrişim ve maksimum havuzlama katmanlarından oluşmaktadır. Evrişim ve havuzlama işlemleri sonucunda yüksek çözünürlüklü görüntü düşük çözünürlüklü görüntüye dönüştürülmektedir. Genişleme, diğer adıyla kod çözücü bölümünde ise transpoze konvolüsyonlar kullanılarak düşük çözünürlüklü bir görüntü yüksek çözünürlüklü bir görüntüye dönüştürülür. Bu işlem ile kesin lokalizasyon işlemi sağlanır (Ronneberger vd.2015).

UNet mimarisinin işleyişi şu şekildedir: aşağı doğru giden sıkışma yolunda görüntüde bulmak istenilen nesne yakalanır ancak konum bilgisi kaybedilmektedir. Kaybedilen konum bilgisine ise sıkışma işleminin ardından yapılan genişleme işlemiyle birlikte ulaşılarak nesne ve konum bilgisi elde edilmektedir (Rehman vd. 2020). Tüm bu işlemler sonucunda giriş görüntüsüyle aynı çözünürlüğe sahip bir sonuç, konum bilgisiyle birlikte elde edilerek başarılı bir segmentasyon işlemi tamamlanır. UNet mimarisindeki diğer avantaj, süreç sadece girişten çıkışa değil tüm katmanlar arasında gerçekleşmektedir. Bu da az veriyle de ezberleme gerçekleşmeden başarılı modeller elde edilmesini sağlamaktadır.




Şekil 2.31 UNet mimari yapısı (Ronneberger vd. 2015).

KLASİK CNN



U-NET



Şekil 2.32 Klasik CNN ve UNet arasındaki fark.

Şekil 2.32’de klasik CNN ve UNet modellerinin çalışma prensiplerinin temel farkı gösterilmektedir. CNN modellerinde mimariye giriş olarak görüntüler verilmekte ve

sonuç olarak 1- 2 gibi sayısal değerler elde edilmektedir. UNet modellerindeyse CNN'den farklı olarak mimariye görüntüler verilir ve çıkışta giriş görüntüsüyle aynı çözünürlükte görüntü elde edilir. Özetle iki mimari arasındaki temel fark çıkışta elde edilen çıkışın tipidir.

2.11 Literatür İncelemesi

Son on yılda, kötü huylu beyin tümörlerinden etkilenenlerin ve ölümle sonuçlanan bireylerin sayısı oldukça artmaktadır (Pitchai vd. 2022). Ulusal Beyin Tümörü Vakfı (NBTF) tarafından açıklandığı üzere gelişmiş ülkelerde beyin tümörlerinden ölen bireylerin sayısı son yıllarda 3 kat artmıştır. Tümörlerin erken evrede doğru şekilde tespit ve tedavi edilmesi hastaların hayatta kalma oranını iyileştirmektedir (Abd-Allah 2016). Bu yüzden yapılan segmentasyon işleminin önemi oldukça hayatidir. Radyologlar tarafından yapılan manuel segmentasyon sırasında gözden kaçırılacak detaylar olabilmektedir. Bunun üzerine son zamanlarda yapay zekâ yardımıyla otomatik segmentasyon işlemi üzerine yapılan çalışma sayısı giderek artmaktadır. Bu çalışmaların temel kapsamı yeni yöntemlerin geliştirilmesi ve mevcut yöntemlerin başarı oranları artırılması üzerinedir. Normal şartlar altında bir uzmanın tümörü tespit etmesi ve segmentasyon işlemini gerçekleştirmesi yaklaşık 30 dakika sürebilir (Cinar vd. 2022). Günümüzde geliştirilen otomatik segmentasyon sistemlerinin geliştirilmesinde asıl amaç uzmanlar üzerindeki yükü azaltarak tümörlerin daha hızlı ve doğru bir şekilde tespit edilmesine yardımcı olmaktır.

Tümörlerin yaklaşık %50'sini oluşturan gliomaların diğer tümör çeşitlerine göre segmentlere ayrılması önemli ölçüde daha zordur. Bu çalışma glioma tümörlerinin otomatik segmentasyonu üzerinedir. Gliomaların doğru şekilde otomatik segmentasyonunu yapmak zor ve karmaşık olabilmektedir. Gliomaların;

- zayıf kontrastlı bir yapısı,
- MRG taramalarındaki yoğunluk değişimleri,
- ödemli yapısı ve oluşturduğu bazı yapılar,
- kafatasının herhangi bir yerinde oluşup benzersiz şekil ve boyutlara sahip olması,

- sınırlarının çoğunlukla belirsiz olması,
- sağlıklı beyin dokusu ile bulanık sınırları ve gri skala değerlerinin sabit bir tanımının bulunmaması, segmentasyon işlemini zorlaştırmaktadır (Maji vd. 2022 , Soltaninejad vd. 2017).

Bu tez çalışmasında kullanılan veri seti 3 boyutlu (3B) MR görüntülerinden oluşmaktadır. 3B'lu MR taramaları ekstenel, koronal ve sagittal görünümünden alınan 2 boyutlu (2B) kesitlerden oluşmaktadır. 2B ekstenel dilimler tümör dokularını segmente etmek için ayırt edici bilgilere sahip olduğu için bu çalışmada giriş görüntüleri olarak yalnızca ekstenel görünümünden oluşan 2B kesitler kullanılmıştır (Aghalari vd. 2021). Aşağıda bahsedilen literatür çalışmalarında BRATS veri seti kullanarak glioma tümör görüntülerini segmente eden çalışmalar yer almaktadır. Bazı çalışmalar sadece tam tümör (nekroz + genişleyen tümör + ödem) segmentasyonu yaparken bazı çalışmalar tam tümör, nekroz ve genişleyen tümör kısımlarını da segmente etmektedir.

Tam tümör segmentasyonu yapılan çalışmalar;

Aghalari ve arkadaşları (Aghalari vd. 2021), BRATS 2018 verileriyle birlikte klasik UNet modelinde bazı değişiklikler yaparak 3 farklı model oluşturmuşlardır. Oluşturulan bu modellerle sadece tam tümör segmentasyonu işlemi gerçekleştirilmiştir. Veri seti olarak Flair, T2, T1ce modaliteleri kullanılmıştır. Bu çalışmada ilk önce bilgi içermeyen MR kesitleri atılmıştır. Ardından UNet modelinin encoder ve decoder kısımlarına eklemek için TPR (two pathway residual) adında lineer bir blok oluşturulmuştur. Oluşturulan bu bloklar UNet modeline asimetrik olarak encoder ve decoder kısmına, simetrik olarak ise hem encoder hem decoder kısmına eklenerek 3 farklı model oluşturulmuştur. Elde edilen bu 3 model ile segmentasyon işlemi gerçekleştirilmiş ve sonuçları karşılaştırılmıştır.

Ilhan ve arkadaşları (Ilhan vd. 2022), çalışmalarında orijinal UNet mimarisiyle BRATS 2012 HGG - LGG, BRATS 2019 ve BRATS 2020 olmak üzere dört ayrı veri seti ile değerlendirme işlemi gerçekleştirmişlerdir. Başlangıçta, tüm tümörlü görüntüler, paraziti gidermek için 5x5 ortalama filtre kullanılarak filtrelenir. Daha sonra tümörlü bölgelerin netleştirilmesi ve daha etkin bir segmentasyon işlemi için tümörlü bölgenin görsel

görünümünü arttıran görüntü histogram yöntemi uygulanmıştır. Son olarak, elde edilen görüntüler kullanılarak tümörlerin segmentasyonunu gerçekleştirmek için orijinal UNet mimarisi kullanılmaktadır. Bu çalışmada BRATS veri setindeki Flair modalitesi kullanılarak sadece tam tümör segmentasyon işlemi gerçekleştirilmiştir.

Pitchai ve arkadaşlarının (Pitchai vd. 2022) çalışmalarında tam tümör segmentasyonu çalışması ve tümörlerin iyi veya kötü huylu olarak sınıflandırılması işlemi gerçekleştirilmiştir. BRATS 2019 veri seti görüntüleri üzerinde DWT (ayrık dalgacık dönüşümü) ve DCT (ayrık kosinüs dönüşümü) işlemleri gerçekleştirilmiştir. Bu işlemlerden elde edilen sonuçlar birleştirilerek elde edilen görüntüler UNet modeli olan 2D U-ConvNet ağına verilmiş ve segmentasyon işlemi gerçekleştirilmiştir. Ardından segmentli görüntüler ile öznetelik çıkarımı gerçekleştirilir ve SVM sınıflandırıcı ile tümör sınıflandırma işlemi gerçekleştirilmiştir. Yapılan ön işlemler daha yüksek sınıflandırma puanı elde edilmesini sağlamıştır.

Neelima ve arkadaşları (Neelima vd. 2022), çalışmalarında veri seti olarak BRATS 2018 ve Figshare görüntülerini kullanmışlardır. Bu çalışmada tam tümör segmentasyon işlemi ardından tümör sınıflandırma (iyi huylu yada kötü huylu) işlemi gerçekleştirilmiştir. Burada yapılan işlemler sırasıyla: normalizasyon ile ön işleme, segmentasyon, CNN ile veri üretimi ve beyin tümör görüntülerini tümörlü tümörsüz olarak sınıflandırma işlemidir. Bu çalışmada MR görüntüleri ilk önce min - max normalleştirme kullanılarak yoğunluklar normalleştirilmiştir. Ardından sailfish political optimizier (yelken balığı politik optimize edici-SFO) ve political optimizier (politik optimize edici-PO)'i entegre ederek tasarladıkları SPO tabanlı Optimal DeepMrSeg ile segmentasyon işlemi gerçekleştirilmiştir. Segmentasyon işleminden hemen sonra veri büyütme işlemi (rastgele çeviri, rastgele sola, sağa çevirme, parlaklık ve kontrast ayarı ve döndürme ile) yapılmıştır. Son olarak ise model kullanılarak tümör görüntülerinin sınıflandırılması gerçekleştirilmiştir.

Segmentasyon işleminde tümör görüntüsünü kendi içerisinde nekroz (tümör çekirdeği), genişleyen tümör ve ödem olarak bölümlere ayıran çalışmalar;

Abd- Ellah ve arkadaşları (Abd-Ellah vd. 2019), BRATS 2017 veri setindeki HGG ve LGG görüntülerini kullanarak asimetrik kalıntı tabanlı derin evrişimli sinir ağı (TPUAR-Net) ile iki paralel UNet kullanan bir beyin tümörü segmentasyon yöntemini tanıtmışlardır. Tanıtılan bu çalışmada Flair, T1, T1ce, T2 modalitelerinin tümü kullanılmıştır. Veri setinde 240x240 boyutunda verilen tüm resimler 128x128 olarak kırpılmıştır. Sonrasında kırılan bu görüntüler TPUAR-NET modelinde işleme alınmıştır. TPUAR-NET çalışması sonucunda tümör görüntüsünün nekroz, genişleyen tümör ve ödem kısımları segmentlere ayrılmıştır.

Cinar ve arkadaşları (Cinar vd. 2022), BRATS 2019 veri setini kullanarak beyin tümör görüntüleri segmente etmişlerdir. Segmentasyon işlemi için MRG çekim modalitelerinden Flair, T1ce ve T2 modaliteleri kullanılmıştır. Ön işleme adımıda otsu eşikleme tekniğiyle görüntüdeki küçük pikseller atılmıştır. Ardından z skoru normalizasyonu ve gauss gürültü azaltma işlemi uygulanmıştır. Elde edilen görüntüler segmentasyon ağına girdi olarak verilmiştir. Önerilen hibrit modelde kodlayıcı yerine DenseNet121 ağı kullanılmıştır. Önceden eğitilmiş ImageNet veri seti ve UNet'in birleştirilmesiyle oluşan DenseNet121-Unet model mimarisi oluşturulmuştur. Segmentasyon işleminde beyin tümör görüntülerinin tam tümör, nekroz ve genişleyen tümör kısımları segmente edilmiştir.

Maji ve arkadaşları (Maji vd. 2022), BRATS 2019 veri setinde yer alan HGG ve LGG görüntülerinden eğitim ve değerlendirme için sadece HGG verilerini kullanmışlardır. MRG modalitelerinden de Flair, T1, T1ce, T2 modalitelerinin tümü birleştirilerek kullanılmıştır. Veri ön işleme kısmında 155x240x240 boyutundaki görüntülerin beyin görüntüsünü net tümör görüntüsü içeren 25 dilim kullanılmıştır. Bunun sonucunda 25x240x240 boyutundaki görüntüler ile model için hazırlanmıştır. Ardından eğitim sırasında ağın ezberlenmesini önlemek için görüntülere yatay ve dikey çevirme, yükseklik ve genişlik kaydırma, döndürme, yakınlaştırma ve kesme işlemleri uygulanmıştır. Bu işlemler rastgele olacak şekilde gerçekleştirilmiştir. Bazı ön işleme süreçlerinden geçen görüntüler yazarlar tarafından oluşturulan ARU-GD attention res-unet guided decoder (dikkat modüllü res-unet kılavuzlu dekode) modeline verilmiştir. Elde edilen sonuçlarla UNet, ResUNet ve attention gates (AG) Res-UNet (Res-UNet ile

dikkat geçitleri) modellerinden elde edilen sonuçlar arasında karşılaştırma işlemi gerçekleştirilmiştir. Bu çalışmada tam tümör, nekroz ve genişleyen tümör segmentasyon çalışması yapılmıştır.

MR görüntüleri üzerinden beyin tümörü segmentasyonu ile tanı, tedavi ve büyüme hızı tahminlerini yapılabilmektedir. Hastaların yüksek doğrulukla tedavi edilmesi için beyin tümörlerini erken aşamada tanımlamak zorlayıcı bir süreçtir. MR tekniğiyle çekilen görüntüler beyin tümörü analizi için diğer görüntüleme yöntemlerine göre segmentasyon işleminde kullanmak için daha uygundur (Abd-Ellah vd. 2016). Beyin tümörü tedavisinde radyologlar tarafından yapılan manuel inceleme MR görüntülerinden tümörlerin tanımlanması, lokalize edilmesi ve sınıflandırılması işlemi önemli ölçüde zaman ve çaba gerektirmektedir. Aktarılan bu zaman ve çabayı azaltmak için günümüzde yapay zekâ destekli sistemler uzmanlar tarafından geliştirilmeye devam etmektedir. Gelişen teknolojiyle birlikte anormal doku büyümesinin bilgisayar destekli tespiti zaman ve harcanan çabanın yanında insan hatasını azaltmakta ve maksimum doğruluğu sağlamayı amaçlamaktadır. Uzmanlara rehberlik etmesi amacıyla gelişmeye devam eden otomatik segmentasyon işlemi giderek daha da önem kazanmaktadır.

Biyomedikal görüntülerin segmentasyonu için geliştirilmiş derin öğrenme mimarilerinden UNet modeli, denetimli öznitelik çıkarma yeteneği ile tıbbi görüntülerin etkili bir şekilde segmente edilmesini sağlamaktadır (Ilhan vd. 2022). Görüntüler üzerinde uygun şekilde ön işlemenin yapılması, sinir ağlarının üzerinde olumlu etki yaratmaktadır (Ozsahin vd. 2019). Bu nedenle, otomatik segmentasyonda görüntülerin derin öğrenme modellerine verilmeden önce ön işlemenin yapılması beyin tümörlerinin yüksek doğrulukta segmentasyonunu sağlayacaktır.

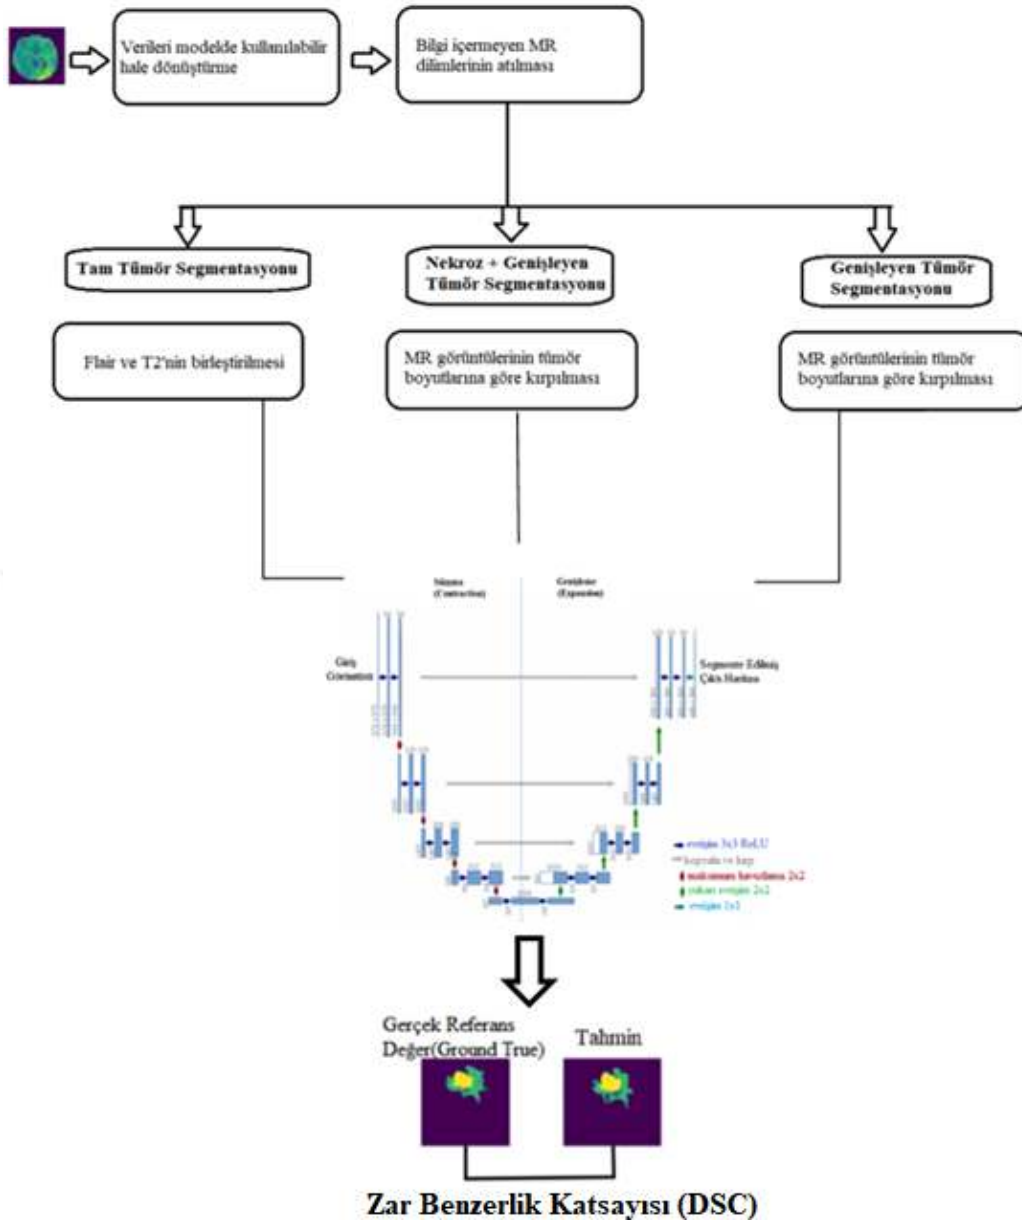
Yukarıda bahsedilen çalışmalar ve yapılan araştırmalar, tam beyin tümörü segmentasyonu ve alt sınıfları (nekroz, genişleyen tümör, ödem) için en yüksek başarı oranını ve minimum hatayı elde etmek için farklı yöntemler önermiş ve uygulamıştır. Ancak tümör bölgelerinin, farklı modalitelerin birlikte kullanımı ile görünümünün daha da belirgin hale gelmesine yönelik çalışmalarda eksiklik olduğu fark edilmiştir. Dolayısıyla bu çalışmada, tümörün alt sınıfına göre uygun modalite görüntülerinin

kullanılması önerilmiştir. Aynı zamanda tümör görüntülerinin bazılarının küçük, bazılarının büyük olmasından kaynaklı oluşan veri dağılımındaki dengesizlik sorununun üzerinde az durulduğu tespit edilmiştir. Bu yüzden bu çalışmada önerilen diğer yöntem, tümör boyutlarına göre görüntülerin kırılarak veri dağılımındaki eşitsizlerin azaltılması ve bunun sonucu olarak daha yüksek doğruluk puanı elde edilmesi amaçlanmıştır.

Bu çalışmada beyin tümörü segmentasyonu işleminin iyileştirilmesine yönelik yöntem önerilmiştir. Önerilen yöntemde ödem ve tümör merkezi (nekroz + genişleyen) görüntülerinin belirginliği Flair ve T2 modaliteleri birlikte kullanıldığında arttığı gözlemlenmiştir. Bu nedenle tam tümör merkezinde bu modalitelerin 2 boyutlu eksenel görüntüleri kullanılmıştır. Tümörün merkez kısmı T1ce modalitesiyle oldukça belirgin olarak görülmektedir. Bu yüzden nekroz + genişleyen tümör ve genişleyen tümör segmentasyonunda T1ce modalitesi kullanılmıştır. Veri setindeki görüntülerin boyutsal açıdan dengesiz dağılımı mevcuttur. Bu dengesizliği azaltmak için görüntülere boyutlarına göre kırma işlemi uygulanmıştır. Tüm görüntüye göre küçük kalan görüntülerin daha belirgin hale gelmesi için görüntüler tümör boyutlarına göre 64x64, 64x128, 128x64, 128x128 boyutlarında kırma işlemi uygulanmıştır. Yapılan ön işleme ve modalite görüntülerinin birleştirilip birlikte kullanma yöntemleriyle elde edilen görüntüler orijinal UNet mimarisine verilerek daha yüksek başarı elde etmek amaçlanmıştır. Sonuç olarak bu çalışmada tam tümör segmentasyonu, genişleyen tümör + nekroz ve genişleyen tümör segmentasyon işlemi gerçekleştirilmiştir.

3. MATERYAL ve METOT

Bu çalışmada glioma tümör içeren beyin görüntülerinin tam otomatik segmentasyonu için UNet mimarisi kullanılmıştır. Görüntüler mimariye verilmeden önce farklı görüntü ön işleme teknikleri ile segmentasyon performansını arttırmaya yönelik çalışmalar yapılmıştır. Çalışmada gerçekleştirilen işlem basamakları Şekil 3.1’de yer almaktadır. İlk adımda veri setindeki görüntüler modelde kullanılabilir hale dönüştürülmekte ve bilgi içermeyen MR dilimleri atılmaktadır. Bu çalışmada tam tümör, nekroz + genişleyen ve genişleyen tümör görüntüleri için ayrı ayrı 3 segmentasyon işlemi gerçekleştirilmektedir. Tam tümör segmentasyonu için Flair ve T2 modalite görüntüleri birleştirilerek modele verilmekte ve segmentasyon işlemi gerçekleştirilmektedir. Nekroz + genişleyen ve genişleyen tümör segmentasyonu için ise T1ce modalite görüntüleri kullanılmaktadır. Aynı zamanda nekroz + genişleyen ve genişleyen tümör görüntüleri tüm görüntüye göre küçük kaldığı için T1ce modalite görüntüleri tümörlerin boyutlarına göre kırpılarak modelde kullanılmaktadır.



Şekil 3.1 Çalışmaya ait akış diyagramı.

3.1 Veri Seti


Çalışmada Pennsylvania Üniversitesi Perelman Tıp Fakültesi tarafından 2013 yılından beri her sene düzenlenen MICCAI BRATS yarışmasından alınan BRATS 2019 veri seti kullanılmıştır (İnt.Kyn.12, Menze vd. 2015, Bakas vd. 2017, Bakas vd. 2018). Brain Tumor Segmentation Challenge (Beyin Tümörü Segmentasyonu Yarışması | BRATS)'ta kullanılan görüntüler birçok farklı kurum tarafından sağlanmaktadır. Veri setindeki MR görüntüleri farklı tarayıcılara ve klinik protokollere sahiptir. Aynı zamanda veri seti halka

açık olarak yayımlanmaktadır (Dong vd. 2017). Bu yarışmada kullanılan veri setindeki örnek sayısı her yıl arttırılmaktadır. BRATS 2013'te 80 kişiye ait MRG taraması mevcutken BRATS 2019'da bu sayı 335'e ulaşmıştır. Her bir MRG taraması 155 adet 2 boyutlu görüntüden oluşmaktadır. BRATS veri seti, HGG ve LGG tümör kategorilerindeki beyin tümör görüntülerini içermektedir.

Veri setinde her hasta için ayrı klasör bulunmaktadır. Veri seti içerisinde her klasörde; bir hastaya ait çekilen MR görüntülerinin dört modalitesi ve referans değer görüntüsü yer almaktadır. Bahsedilen dört modalite şunlardır: T1, T2 ağırlıklı (T2), kontrast sonrası T1 ağırlıklı (T1ce) ve T2 akışkan zayıflatılmış inversiyon kurtarma (FLAIR). Referans değer: MR görüntülerinin manuel olarak bir ila dört doktor tarafından yapılan segmentasyon görüntüleridir (İnt.Kyn.12).

Veri setinde gerçek referans değer olarak verilen doğrulama yani segmentasyon görüntüleri kendi içerisinde rakamlarla 3 bölüme ayrılmaktadır. Bu bölümler nekroz, ödem ve genişleyen tümördür (Bakas vd. 2017).

Şekil 3.2'de beyin tümör görüntülerinin gerçek referans değeri ve bölümleri yer almaktadır. Resimdeki gerçek referans değer (ground truth) başlıklı görüntüde görüldüğü üzere en iç kısım tümörün çekirdeğidir ve nekroz olarak adlandırılır. Nekrozdan hemen sonra görünen bölge genişleyen tümördür ve en dışta görülen kısım ise ödemdir.



Şekil 3.2 Tümör segmentasyonu görüntüsünün bölümleri.

Bu veri setindeki her kişiye ait MRG taraması 3 boyutludur. Ancak bu çalışmada 3 boyutlu görüntülerin boyutuna karşılık gelen 2 boyutlu aksel kesitler kullanılmaktadır.

Her bir modalite 240x240 boyutunda 155 dilimden oluşmaktadır. Modelde; 51.925 veri içerisinde faydalı bilgi içeren 23.450 veri kullanılmıştır.

3.2 Ön İşlemler


Bu bölümde BRATS 2019 veri setinin modele verilmeden önce yapılan ön işlem adımları açıklanmaktadır. Daha sonra görüntü segmentasyonu işleminde kullanılacak model olan UNet mimarisi hakkında detaylı bilgi verilmektedir. Ayrıca, bu modeli seçme nedenleri, modeli eğitmek için yapılan son işlemler adımlarıyla birlikte ayrıntılı olarak açıklanmaktadır. Model eğitimi Python dilinde Anaconda 2020.02 64 bit versiyonu kullanılarak gerçekleştirilmiştir.

3.2.1. Veri Dönüştürme

Veri setindeki görseller nii.gz (nifti) olarak paylaşılmıştır. Modelde kullanabilmek için nifti formatındaki görseller Numpy dizilerine dönüştürülmüştür. Dönüştürme işlemi tıbbi görüntüler için (CT, MR) özel olarak geliştirilmiş olan Python'un SimpleITK kitaplığı kullanılarak gerçekleştirilmiştir.


3.2.2 Bilgi İçermeyen MR dilimlerinin Atılması

Yukardaki bölümde de bahsedildiği üzere veri setindeki her 3 boyutlu görsel, 2 boyutlu aksel 155 dilimden oluşmaktadır. Ancak bu dilimlerin hepsi anlamlı bilgiler içermemektedir. Bu bilgi içermeyen görselleri modele vermek de modeli ekstra meşgul edecek ve doğruluk oranını düşürecektir. Bu yüzden bu bilgi içermeyen görseller modelde kullanılacak olan veri setinden atılmıştır. Şekil 3.3'te 2 boyutlu MR dilimlerinden 20. ve 140. dilimler yer almaktadır. Bu görsellerde görüldüğü üzere anlamlı beyin görüntüsü yer almamaktadır.



Şekil 3.3 Anlamalı bilgi içermeyen 2 boyutlu MR görüntüleri.

Şekil 3.4'te ise MR kesitlerinden 70. ve 130'uncu görseller yer almaktadır. Bu görseller çalışmada kullanılabilecek anlamlı bilgiler içermektedir.



Şekil 3.4 Anlamalı bilgi içeren 2 boyutlu MR görüntüleri.

Dolayısıyla bu çalışmada 155 dilim arasından 60 ile 130'uncu kesitler arasındaki görseller modelde kullanılmış ve geri kalan kesitler atılmıştır. Böylelikle (155, 240, 240) boyutu (70, 240, 240) boyutuna dönüşmüştür.

3.2.3 Eşikleme (Binary Threshold)

Ön işleme aşamasında görüntülerdeki siyah arka planı atmak için kırpma işlemi yapılmaktadır. Yapılan bu kırpma işlemi merkez koordinatları kullanılarak yapılmaktadır. Görüntüde bulunan gözle görülmeyecek derecede çok küçük olan dağınık veriler yapılacak olan kırpma işleminde merkez koordinatını alırken veriyi etkilemektedir. Kırpma işlemindeki etkilenmeyi önlemek için eşikleme yapılmaktadır. Eşikleme işlemi görüntü matrisinde bulunan belirli bir eşik değeri altındaki değerleri 0; üstünde olan değerleri 1 yaparak ikili bir görüntü oluşturmaktadır.

Bu çalışmada eşik değeri 0.2 olarak seçilmiştir. Böylelikle 0.2 altındaki değerler 0; 0.2'den büyük olan değerler 1'e eşitlenerek ikili görüntü oluşturulmuştur. Elde edilen bu ikili görüntü ile tümör kırpma işlemi gerçekleştirilmektedir.

3.2.4 Tümör Kırpma

Eşikleme yöntemiyle elde edilen görüntüdeki x ve y eksenindeki 1 değerli piksellerin koordinatları Denklem 3.1'deki Numpy kütüphanesinin “where” komutu kullanılarak bulunur. Bulunan koordinatlar tümörün merkez koordinatlarının bulunmasında kullanılmaktadır. Elde edilen maksimum ve minimum piksel değerleri toplanıp 2'ye bölünerek merkez koordinatları elde edilmektedir. Denklem 3.2 ve Denklem 3.3'te x ve y eksenlerindeki merkez koordinatlarının nasıl elde edildiği gösterilmiştir. Bulunan merkez koordinatlarına göre kırpma işlemi gerçekleştirilmektedir. Burada yer alan “index_xy [0]” y eksenini, “index_xy[1]” ise x eksenini belirtmektedir.

$$\text{index_xy} = \text{np.where}(\text{img} == 1) \quad (3.1)$$

$$\text{Merkez_x} = (\max(\text{index_xy}[1]) + (\min(\text{index_xy}[1])))/2 \quad (3.2)$$


$$\text{Merkez_y} = (\max(\text{index_xy}[0]) + (\min(\text{index_xy}[0])))/2 \quad (3.3)$$

Şekil 3.6’da tam tümör, nekroz ve genişleyen tümör görüntüler incelendiğinde nekroz ve genişleyen tümör ile tam tümör arasında görüntünün tamamına kıyasla boyutsal olarak dengesizlik mevcuttur. Görüntüler arasındaki boyutsal dengesizlik, segmentasyon işlemini zorlaştırmaktadır. Bu dengesizliği azaltmak için tümörün boyutuna göre görüntüye kırpma ve bölme işlemi uygulanmıştır.

Tam tümör görüntülerinde piksel miktarı görüntünün tamamına kıyasla fazladır. Bu yüzden tam tümör segmentasyonu için görüntüler modele 240x240 boyutunda verilmiştir. Görüldüğü üzere nekroz ve genişleyen tümörlerde bulunan piksel sayısı görüntünün tamamına kıyasla çok az kalmaktadır. Dolayısıyla nekroz ve genişleyen tümör görüntülerindeki dengesizliği azaltmak için bu görüntüler kırılmakta ve küçük parçalara ayrılmaktadır. Buradaki asıl amaç daha küçük görüntü elde ederken veri dağılımındaki dengesizliği azaltmanın yanında tümör alanının boyutunda herhangi bir değişiklik meydana getirmemektir.

Tümör alanını parçalara ayırmanın amacı tümörün olmadığı kısımları görüntüden çıkarmak ve modelin sadece tümörün olduğu kısmı tespit etmesini sağlayarak başarı oranını arttırmaktır. Farklı yöntemlerle de tümör bölgesi tespit edilebilmekte ve bunun sonucunda kırpma işlemi yapılabilmektedir. Ancak modelin bu görüntüleri kabul etmesi için genişlik ve uzunluk ölçülerinin aynı olması gerekir. Bu nedenle görüntüler 4’ün de katı olan 64x64 piksel boyutundaki bloklara bölünmüştür.

Bu çalışmada tümör kırpma işlemi tümörün genişliği ve boyuna göre yapılmaktadır. Veri setindeki verilerde tümörleri incelediğimizde kimi tümörler enine, kimi tümörler boyuna, kimi tümörler ise hem enine hem de boyuna 64 pikselden daha fazla uzunluğa sahip olabilmektedir. Görüntüdeki tümör alanının hem genişliği hem de uzunluğu 64’ten küçükse görüntü kırılarak 64x64 boyutuna dönüştürülür. Tümör alanının genişliği veya yüksekliği 64’ten büyükse (64x128 veya 128x64), görüntü 64x64 boyutunda 2 parçaya bölünür. Tümör alanının hem genişliği hem de uzunluğu 64’ten büyükse (128x128) ; görüntü dört tane 64x64 boyutunda parçaya bölünür. Şekil 3.5’te görselin tümör boyutuna göre kırılma prensibi ve işlemi gösterilmiştir.



Şekil 3.5 Tümör boyutuna göre görüntü kırpma işlemi.


Burada görüntü boyutları 96x96 yada 120x120 yapıp, parçalama işlemine gerek duymadan kırpma işlemi de gerçekleştirilebilirdi. Ancak bu çalışmada asıl amaç tümör boyutlarının farklılığından dolayı oluşan veri dağılımındaki dengesizliğe çözüm getirebilmektir. Görüntü boyutları ne kadar arttırılırsa bahsedilen sorunun çözümünden o kadar uzaklaşılmış olacaktır. Bunun sebebi nekroz, genişleyen tümör görüntülerinde bulunan piksel değerlerinin, tüm görüntünün piksel değerlerine göre küçük kalmasıdır. Bu yüzden bu çalışmada görüntüler 64x64'lük parçalara bölünerek verideki dengesizlik sorununun minimize edilmesi amaçlanmaktadır.

Bu görüntüler bölündükten sonra eğitime sunulduğunda hem giriş MR görüntüleri hem de modeli eğittiğimiz segmentasyon görüntüleri parçalı halde eğitime girmektedir. Giriş görüntüleri 2 parçaya bölündüyse segmentasyon görüntüleri de iki parçaya bölünerek modele verilmektedir. Parçalara bölünen bu görüntüler model oluşturulduktan sonra birleştirilmektedir.

3.3 Segmentasyon

Beyin tümörü segmentasyonu işlemi sağlıklı dokuyu tümörlü bölgelerden ayırmayı amaçlar. Bu, başarılı tedavi olasılığını en üst düzeye çıkarmak için teşhis ve tedavi planlamasında önemli bir adımdır. Çalışmada biyomedikal görüntülerin segmentasyonu için geliştirilmiş ve en çok kullanılan mimarilerden birisi olan UNet mimarisi kullanılmaktadır. Mimari öncesinde yapılan ön işlemler ile modelin performansının artırılması amaçlanmıştır.


Bu çalışmada tam tümör, genişleyen tümör ve nekroz + genişleyen tümör bölgeleri için ayrı ayrı segmentasyon işlemi gerçekleştirilmiştir. Bunun sebebi tümörün segmentasyon görüntüsü içinde bulunan bölümlerin farklı modalite görüntüleriyle belli olmasıdır. Şekil 3.6'da görüldüğü üzere Flair ve T2 görsellerinde ödem ve tümör merkezi net şekilde görünürken, T1ce görüntüsünde ise tümörün nekroz + genişleyen tümör kısmı net olarak görünmektedir. Bu yüzden bu çalışmada tam tümör segmentasyonunda Flair ve T2; nekroz ve genişleyen tümör segmentasyonu için T1ce görüntüleri kullanılarak segmentasyon işlemi gerçekleştirilmiştir.



Şekil 3.6 Flair, T1ce ve T2 modalitelerinde nekroz, genişleyen tümör ve tam tümör görüntüleri.

3.3.1 Tam Tümör Segmentasyonu


İlk modelde tam tümör segmentasyonu işlemi gerçekleştirilmektedir. Bahsedildiği üzere bu işlemde Flair ve T2 görüntüleri kullanılmaktadır. Ancak sinir ağ modelleri bir giriş ve bir çıkış verisi ile çalışmaktadır. Bunun için Flair ve T2 görüntüleri birbiri üzerine eklenerek modelde kullanılabilecek bir input haline getirilmiştir. Burada yapılan birbiri üzerine ekleme işlemi red- green- blue (RGB) kanal oluşturma işlemine benzemektedir. Şekil 3.7’de görüldüğü üzere red, green ve blue kanalları ayrı ayrıdır. Bu kanalların üçü üst üste bindirilir ve renkli görüntü oluşturulur.



Şekil 3.7 Kırmızı, yeşil, mavi renk kanalları ve RGB görüntü oluşumu (İnt.Kyn.13).

Bu çalışmada Flair ve T2 görselleri sanki RGB kanal oluşturuyormuş gibi görüntüler birbiri üzerine eklenerek modelin eğitiminde kullanılmaktadır. Flair ve T2 görüntülerinin boyutu ayrı ayrı (1, 240, 240)’tır. Birbiri üzerine ekleme işlemiyle giriş haline getirilen Flair + T2 görüntüsünün boyutu (2, 240, 240) olmuştur. Birbiri üzerine ekleme işlemi concatenate fonksiyonu kullanılarak gerçekleştirilmiştir.

Tam tümör segmentasyonu için Flair ve T2’nin birlikte modele verilmesinin nedeni iki görüntünün birbirlerinin eksikliklerini gidermesidir. Örneğin Flair görüntülerinde tümörün ödem kısmı daha net görünürken; bazı T2 görüntülerinde tümörün merkez kısmı daha net görülmektedir. Bu nedenle bu iki görüntü modalitesi beraber modele verilerek, uygun ön işleme ve hiperparametreler kullanılarak başarılı sonuçların elde edilmesi amaçlanmıştır. Şekil 3.8’de belirtilen MR modalite çekimlerinin görünümüleri yer almaktadır.



Şekil 3.8 MRG modalitelerinde tümör görüntüleri.

Sezin Barın ve Gür Emre Güraksın tarafından yapılan çalışmada derin öğrenme mimarilerinde en yaygın kullanılan SGD, ADAM, RMSProp olmak üzere 3 farklı eğitim optimizasyon algoritmasının segmentasyon mimarisi üzerinde başarıları değerlendirilmiştir. Bunun sonucunda ADAM optimizasyon algoritmasının başarıları en yüksek çıkmıştır (Barın ve Güraksın 2022). Bu bilgiden yola çıkarak çalışmada Diederik P. Kingma, Jimmy Ba tarafından geliştirilen ADAM optimizasyon algoritması U-Net segmentasyon mimarisinin eğitiminde kullanılmıştır. (Kingma ve Ba 2017).


Tam tümör segmentasyonu Flair ve T2 modalite görüntüleri kullanılarak 16 yığın boyutu (batch size), 64 epok, $1e-4$ öğrenme oranı (learning rate) eğitim parametre değerleri ile 9 katmanlı UNet modelinde gerçekleştirilmiştir. Verilerin %80'i eğitimde kullanılırken %20'si ise doğrulama için kullanılmıştır.

3.3.2 Tümör Merkezi ve Genişleyen Tümör Segmentasyonu

Şekil 3.6'da da görüldüğü üzere tümör merkezi (nekroz + genişleyen tümör), nekroz ve genişleyen tümörde bulunan pikseller görüntünün tamamına kıyasla çok azdır. Verilerdeki bu eşitsizlik modelin görüntüyü segmente etmesini zorlaştırmaktadır. Bu yüzden tümör merkezi ve genişleyen tümör görüntüleri kırpma işlemi uygulanarak kullanılmaktadır. T1ce modalite çekimlerinde bahsedilen tümör görüntüleri daha net olduğu için modelde T1ce görüntüleri kullanılmaktadır.

Kırpma işleminde ilk önce orijinal T1ce görüntüsüne Denklem 3.1, 3.2 ve 3.3'te yer alan hesaplama yöntemi uygulanarak tümörlü bölgenin bulunduğu koordinatlar ve merkez

koordinatları bulunmuştur. Tümörün merkez noktası kullanılarak orijinal görüntü Şekil 3.9'daki gibi 64x64 boyutunda kırpılmış ve modele kırpılan görüntü verilmiştir. Burada görüntü 64x64 boyut aralığında olduğu için modele tek parça halinde verilmektedir.



Şekil 3.9 Tümör kırpma.

Ancak bazı tümörlerin boyutu 64x64'ten daha büyük olabilmektedir. Bu yüzden tümörlere boyutlarına göre kırpma işlemi uygulanmaktadır. Kırpma işlemi için, görüntülerin genişlik (w) ve yükseklik (h) değerleri Denklem 3.4 ve 3.5'deki gibi hesaplanmaktadır. Hesaplanan değerler kullanılarak tümör boyutu belirlenmekte ve tümör boyutuna göre görüntüye kırpma işlemleri uygulanmaktadır.

$$\text{Yükseklik} = \max(\text{index_xy}[0]) - \min(\text{index_xy}[0]) \quad (3.4)$$

$$\text{Genişlik} = \max(\text{index_xy}[1]) - \min(\text{index_xy}[1]) \quad (3.5)$$

Elde edilen genişlik ve yükseklik değerlerine göre ;

- $w \leq 64$ ve $h \leq 64$
görüntü 1 parça halinde,


- $w > 64$ ve $h \leq 64$ veya $w \leq 64$ ve $h > 64$ ise

görüntü 2 parça halinde,

- $w > 64$ ve $h > 64$ ise

görüntü 4 parça halinde modele verilmektedir.

Görüntüler parçalar haline getirilirken karışıklık meydana gelmemesi için sadece segmentasyon görüntüleri değil index değerlerine karşılık gelen giriş görüntüleri de kırpılmaktadır. Modelde hem giriş görüntüleri hem de segmentasyon görüntüleri kırpılarak kullanılmaktadır. Şekil 3.10'da görüldüğü üzere segmentasyon görüntüsü parçalar haline getirilerek modele verilmektedir.




Şekil 3.10 128x128 boyutundaki segmentasyon görüntüsünün parçalı hale getirilmesi.

Tümör merkezi ve genişleyen tümör segmentasyonu için ayrı ayrı gerçekleştiren 7 katmanlı UNet model eğitimi T1ce modalite görüntüleri kullanılarak 16 yığın boyutu (batch size), 64 epok, $1e-4$ öğrenme oranı (learning rate) eğitim parametre değerleri ile gerçekleştirilmiştir. Burada UNet modelinin 7 katmanlı olarak çalıştırılmasının amacı daha doğru ve hızlı model geliştirmektir. CNN'lerde katman sayısı azaldıkça, model aşağı doğru inerken oluşan gradyan azalmaktadır. Bu da modelin daha hızlı ve başarılı olmasını sağlamaktadır. Verilerin %80'i eğitimde kullanılırken %20'si ise doğrulama için kullanılmıştır.

3.4 Kırpılan Görüntüler İçin Yapılan Eğitim Sonrası İşlem

Yapılan tam tümör, genişleyen + nekroz ve genişleyen tümör segmentasyonunda genişleyen + nekroz ve genişleyen tümör görüntüleri eğitim işleminden önce Şekil 3.11'deki gibi parçalar haline getirilmiştir. Eğitimden sonra, bu segmentli görüntüler etiket değerleri kullanılarak yeniden üstüne ekleme metoduyla birleştirilmiştir. Bahsedilen birleştirme işleminde sırasıyla şu işlemler gerçekleştirilmiştir:

- 1) Tahmin edilen tam tümör, genişleyen ve genişleyen + nekroz segmentasyon görüntülerinin her birine ayrı ayrı eşikleme metodu ile 1, 2 ve 4 etiket değerleri atandı.
- 2) 240x240 boyutunda sıfırlardan oluşan numpy dizisi oluşturdu.
- 3) Oluşturulan bu diziye tam tümör segmentasyonunun tahmin görüntüsü koordinat değerleri kullanılarak Şekil 3.11- a'daki gibi eklendi.
- 4) Ardından tahmin edilen tümör merkezi ve genişleyen tümör görüntülerinin parçalı hallerinin hepsi etiket değerleri ve koordinatları ile birlikte tam tümör görüntüsünün üstüne eklendi (Şekil 3.11-b).
- 5) Tüm bu işlemler sonucunda, tümörün tüm alt sınıflarının da bulunduğu segmentasyon görüntüsü elde edilmiştir.



Şekil 3.11 Tahmin edilen segmentasyon görüntülerinin birbiri üzerine eklenmesi.

4. BULGULAR

Bu çalışmada, glioma beyin tümörleri segmentasyonu işleminde literatürde en yaygın kullanılan UNET mimarisi kullanılmıştır. UNet biyomedikal görüntülerinin segmentasyonu için geliştirilmiş olan CNN tabanlı segmentasyon mimarisidir. Görüntüler modele verilmeden önce doğruluk oranını arttıracak şekilde çeşitli ön işlemlerden geçirilmiştir. Tam tümör segmentasyonunda tümörün daha net görüldüğü modaliteler birleştirilerek kullanılmıştır. Bu, doğruluk oranını arttıran bir faktör olmuştur. Sadece nekroz ve genişleyen tümör bulunduran görüntüler, boyutuna göre kırpılıp parçalar haline getirilerek modele verilmiştir. Buradaki amaç veri dağılımındaki eşitsizliği azaltarak en iyi doğruluk değerini elde etmektir.

Yapılan çalışma, Intel Tiger Lake Core i5-11400H 6C/12T işlemci, 16GB RAM, NVIDIA GeForce GTX1650 GPU işletim sistemi ve diğer donanım destekleri olan bir sistem üzerinde Python ortamında gerçekleştirilmiştir.

Modelin doğruluğunu ölçmek için DSC , jaccard, sensitivity (hassasiyet) ve specificity (duyarlılık) metrikleri kullanılmıştır. Denklemlerde yer alan X ve Y değerleri tahmin edilen görüntü ve gerçek referans değer görüntüyü, B ise arka planı temsil etmektedir.

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|} \quad (4.1)$$


$$Jaccard = \frac{2|X \cap Y|}{|X \cup Y|} \quad (4.2)$$

$$Sensitivity = \frac{X \cap Y}{Y} \quad (4.3)$$

$$Specificity = \frac{|B - X| \cap |B - Y|}{|B - Y|} \quad (4.4)$$

UNet modelinde performans ölçümlemesi olarak doğruluk (accuracy) yerine DSC metriği kullanılmaktadır. Bunun sebebi; UNet modelinde modele görüntü verilmekte ve çıkış veri türü olarak görüntü elde edilmektedir.

DSC metriği iki tane görseli üst üste koyup aradaki piksel farkına göre değerlendirme yapmaktadır. Piksel farkı ne kadar azsa DSC değeri o kadar artmaktadır. Zar benzerlik katsayısı, 0 ile 1 arasındaki aralık değerlerine sahip ikili görüntüler arasındaki uzamsal örtüşme oranı aracılığıyla ölçülür. Buradaki 0; eşleşme yok ve 1; mükemmel eşleşmeyi temsil etmektedir. Kullanılan giriş ve çıkış verileri görsel olduğu için ikisi arasındaki piksel farkını almak modeli değerlendirmek için daha yararlı bilgi verecektir (Zou vd. 2004). DSC görsel formülasyonu Şekil 4.1’de görüldüğü gibidir.



Şekil 4.1 Zar benzerlik katsayısı çalışma prensibi (Zou vd. 2004).


Çalışmada ilk olarak BRATS 2019 veri seti kullanılarak tam tümör segmentasyonu gerçekleştirilmiştir. Tam tümör segmentasyonu için üç ayrı eğitim gerçekleştirilmiş ve sonuçlar karşılaştırılmıştır. Eğitimler; Flair ve T2 görüntülerinin concatenate (birleştirme) fonksiyonu ile birleştirilerek ve Flair ve T2 modalite görüntüleri ile ayrı ayrı kullanılarak yapılmıştır. Elde edilen sonuçlarda, Flair ve T2 MR modaliteleri üst üste eklenerek eğitilen modelden elde edilen sonuçlarda daha yüksek başarı puanı elde edilmiştir. Dolayısıyla tam tümör segmentasyonu işleminde Flair ve T2 modalite görüntüleri birleştirilerek kullanılmıştır. Görüntüler modelde orijinal boyutunda (240x240) kullanılmıştır. Sadece Flair modalite görüntüleriyle yapılan 64 epok, 16 batch size (yığın boyutu) ile çalıştırılan modelde 0.893, T2 modalite görüntüleriyle yapılan eğitimde 0.873, Flair ve T2 görüntülerinin birleştirilmesiyle 0.954 DSC değerleri elde edilmiştir. Çizelge

4.1’de görüldüğü üzere tam tümör segmentasyonunda en yüksek DSC değeri, Flair ve T2 modalite görüntülerinin birleştirilerek 9 katmanlı UNet modeli eğitiminde elde edildiği görülmüştür.

Çizelge 4.1 Farklı giriş boyutları, modalite görüntüleri ile yapılan tam tümör segmentasyon değerlendirme sonuçları.

Kullanılan Modalite Görüntüsü ve Görüntü Boyutu	9 Katmanlı UNet modelinde elde edilen DSC Değeri
Flair (240x240)	0.893
T2 (240x240)	0.873
Flair + T2 (240x240)	0.954

Şekil 4.2’de tam tümör giriş görüntüsünün model ile yapılan tahmin görüntüsü ve radyoloğun yaptığı segmentasyon çalışması yer almaktadır.



Şekil 4.2 Tam tümör tahmin ve segmentasyon görüntüsü.


Tümör merkezi görüntüleri için (nekroz + genişleyen tümör) T1ce modalite görüntüleri kullanılarak segmentasyon işlemi ikinci bir modelde gerçekleştirilmiştir. 64 epok, 16 yığın boyutu (batch size) ile çalıştırılan modelde 240x240 boyutunda modele verildiğinde 0.864, 64x64 boyutunda 0.921 DSC değerleri elde edilmiştir. Tümör merkez görüntüsünün pikselleri tüm görüntüye göre küçük olduğu için görüntülerin modele tümör boyutuna göre kırılarak verilmesi uygun görülmüştür. Çizelge 4.2’de genişleyen tümör + nekroz için 240x240 ve 64x64 boyutlu T1Ce modalite görüntüleri 7 katmanlı

UNet modelinde eğitime girmiştir. Yapılan karşılaştırma sonucunda 64x64 boyutundaki görüntülerin 7 katmanlı UNet eğitimi sonucunda en iyi sonucu aldığı görülmektedir.

Çizelge 4.2 Farklı giriş boyutları ile yapılan genişleyen + nekroz segmentasyon değerlendirme sonuçları.

Kullanılan Modalite Görüntüsü ve Görüntü Boyutu	7 Katmanlı UNet modelinde elde edilen DSC Değeri
T1Ce (240x240)	0.864
T1Ce (64x64)	0.921

Şekil 4.3'te genişleyen tümör + nekroz segmentasyonu için T1ce giriş görüntüsü, model sonucunda elde edilen segmentasyon görüntüsü ve radyoloğun yaptığı segmentasyon çalışması yer almaktadır.




Şekil 4.3 Tümör merkezi (genişleyen + nekroz) tahmin ve segmentasyon görüntüsü.

Genişleyen tümör görüntüleri için de T1ce modalite görüntüleri kullanılarak segmentasyon işlemi üçüncü bir modelde gerçekleştirilmiştir. Tümör merkez görüntüsündeki gibi genişleyen tümör görüntüsünün de pikselleri tüm görüntüye göre küçük olduğu için görüntüler modele tümör boyutuna göre kırpılarak verildiğinde daha başarılı sonuçlar elde edilmiştir. 64 epok, 16 yığın boyutu (batch size) ile çalıştırılan modelde görseller 240x240 boyutunda modele verildiğinde 0.843, 64x64 boyutuna kırıldığında 0.913 değerleri elde edilmiştir. Çizelge 4.3'te görüldüğü üzere genişleyen tümör segmentasyonunda en yüksek DSC değeri, 64x64 boyutundaki T1Ce modalite görüntüleri kullanılarak 7 katmanlı UNet modeli eğitiminde elde edildiği görülmüştür.

Çizelge 4.3 Farklı giriş boyutları ile yapılan genişleyen tümör segmentasyon değerlendirme sonuçları.

Kullanılan Modalite Görüntüsü ve Görüntü Boyutu	7 Katmanlı UNet modelinde elde edilen DSC Değeri
T1Ce (240x240)	0.843
T1Ce (64x64)	0.913

Şekil 4.4'te genişleyen tümör segmentasyonu için T1ce giriş görüntüsü, model sonucunda elde edilen tahmin görüntüsü ve radyoloğun yaptığı segmentasyon çalışması yer almaktadır.



Şekil 4.4 Genişleyen tümör tahmin ve segmentasyon görüntüsü.

Çizelge 4.4 Tümör bölgelerinin segmentasyonunda UNet mimarisinin değerlendirme sonuçları.

Metrik	Tam Tümör	Tümör Merkezi	Genişleyen Tümör
DSC	0.954	0.921	0.913
Jaccard	0.908	0.901	0.810
Sensitivity	0.942	0.937	0.893
Specificity	0.994	0.998	0.991

Çizelge 4.4'te önerilen modelin değerlendirme sonuçları yer almaktadır. Çizelge 4.5'te diğer literatür çalışmaları ile başarı karşılaştırması yer almaktadır. Tabloda yer alan çalışmaların tümünde veri seti olarak kullanılan BRATS yarışmasındaki farklı yıllardaki görüntüler kullanılmıştır. Önerilen yöntemde ise BRATS 2019 veri setinde yer alan

51.925 veri arasından 23.450 görüntü kullanılmıştır. Çizelge 4.5’de yer alan diğer çalışmalarda mimari olarak ise biyomedikal görüntülerin segmentasyonu için geliştirilmiş olan UNet modeli veya UNet modeli üzerinde çeşitli değişiklikler yapılarak elde edilen hibrit modellerin kullanıldığı çalışmalar yer almaktadır. Önerilen çalışmada ön işlemde yapılan çeşitli işlemler ile segmentasyon işlemindeki zar benzerlik katsayısı (dice similarity coefficient) değeri artırılması amaçlanmış ve elde edilen değer diğer çalışmalar ile karşılaştırılmıştır. Tabloda yer alan çalışmalar arasında önerilen çalışma zar benzerlik katsayısı değeri (DSC) sıralamasında tam tümörde 2, genişleyen + nekrozda 2. ve genişleyen tümör için 1. sırada yer almaktadır.

Tam tümör ve genişleyen + nekroz segmentasyon işleminde DSC puanında ilk sırada yer alan çalışmada, geliştirdikleri hibrit model olan DenseNet121-UNet kullanılmıştır. Görüntüler modele verilmeden önce eşikleme, otsu, z skoru ve gauss gürültü azaltma ön işlemlerine tabî tutulmuştur. Önerilen sistemde ise, görüntüler modele verilmeden önce boyutlarına göre kırılmış, tümörün belirli bölgelerinin tespiti için uygun modalite görüntüleri kullanılmıştır. Kullanılan orijinal UNet modeli alınan sonuçlar doğrultusunda tam tümör segmentasyonu için 9 katmanlı kullanılırken, genişleyen + nekroz ve genişleyen tümör segmentasyonu için 7 katmanlı UNet modeli kullanılmıştır. Elde edilen sonuçlar doğrultusunda genişleyen tümör segmentasyonunda önerilen yöntem DSC puan sıralamasında ilk sırada yer almaktadır.


Çizelge 4.5 Literatür çalışmaları ile karşılaştırma.

Çalışmalar	Kullanılan Modalite Görüntüsü	Tam Tümör	Tümör Merkezi	Genişleyen Tümör
Barzegar ve Jamzad (Barzegar ve Jamzad 2021)	T1, T1ce, T2, Flair	0.901	0.887	0.890
Maji vd.(Attention ResUNet) (Maji vd. 2022)	T1, T1ce, T2, Flair	0.923	0.847	0.834

Çizelge 4.5 (Devam) Literatür çalışmaları ile karşılaştırma.

Çalışmalar	Kullanılan Modalite Görüntüsü	Tam Tümör	Tümör Merkezi	Genişleyen Tümör
Ahmad vd. (3D-UNet) (Ahmad vd. 2020)	T1, T1ce, T2, Flair	0.902	0.834	0.722
Wang vd. (Wang 2022)	T1, T1ce, T2, Flair	0.916	0.888	0.830
Cinar vd. (DenseNet121-UNet) (Çınar vd. 2022)	T1ce, T2, Flair	0.959	0.943	0.892
Abd-Ellah vd. (TPUAR-Net) (Abd-Ellah vd. 2019)	T1, T1ce, T2, Flair	0.89	0.82	0.79
Önerilen Yöntem	T1ce,T2, Flair	0.954	0.921	0.913

Önerilen model ile yapılan segmentasyon işleminden elde edilen görsel sonuçlar Şekil 4.5'te yer almaktadır.



Şekil 4.5 Segmentasyon işlemleri sonuçları.

5. SONUÇLAR ve TARTIŞMA

Beyin tümörü, beyindeki kanserli veya kanserli olmayan bir kitlenin kontrolsüz şekilde büyümesidir. Bu tümörler arasında glial hücrelerden kaynaklanan gliomalar, en yaygın beyin tümörüdür. Beyin tümörlerinin teşhisinde ve uygulanacak tedavinin belirlenmesinde özellikle yumuşak doku görüntülemeye başarılı bir görüntüleme yöntemi olan MRG, yumuşak doku tümörlerini saptamak için etkili bir tanı tekniğidir. Bilindiği üzere MR görüntüleri düşük kaliteye sahip görüntü türleridir. düşük çözünürlük ve kontrast değerlerine sahip beyin görüntüleri yüksek belirsizliğe sahiptir. Genel olarak, tümör şekilleri vakadan vakaya farklıdır ve her bir görüntü bölgesini hassas bir şekilde segmentlere ayırmak zordur. Bu nedenle MR görüntülerini küçük parçalara bölmek zordur. Tümörlerin türü ve glioma alt bölgelerinin ölçümü uzman kurul onaylı nöroradyologlar tarafından ameliyat öncesi yapılan segmentasyonlarda belirlenmektedir. Manuel segmentasyon çok fazla uzmanlık ve beceri gerektiren işlemlerdir. Gliomaların dağınık yapısı ve zayıf kontrast özelliklerinden dolayı tespit edilmesi oldukça zor ve zaman alıcıdır. Glioma teşhisi konan hastalarda otomatik algoritmalar kullanılarak yapılan segmentasyon işleminin, teşhis, tedavi planlaması ve sonuç tahmini için sağladığı rehberliğin önemi yapılan son çalışmalarda görülmektedir.

Bu çalışmada, radyologlar tarafından yapılan manuel inceleme sırasında önemli ayrıntıların tespit edilmesine yardımcı olmak için otomatik segmentasyon çalışması gerçekleştirilmiştir. BRATS 2019 veri setindeki HGG ve LGG tümör görüntülerinin bilgi içeren kısmı kullanılarak UNet modeli üzerinde segmentasyon işlemi gerçekleştirilmiştir. Görüntüler modele verilmeden önce gereksiz MR dilimleri atılmıştır. Eğitimde doğruluk oranını arttırmak için modalitele görüntüleri birleştirilmiş ve görüntüler boyutlarına göre 64x64 boyutunda 1, 2 veya 4 parçaya bölünmüştür. Modele, glioma içeren görüntüleri olabildiğince küçük boyutta vermek DSC puanını arttırmada ana faktörlerdendir. Diğer faktör ise tümörlerin daha belirgin olması için modalitelerin birlikte kullanılması olmuştur.

BRATS 2019 veri setinde 335 kişiye ait MR çekim dosyaları bulunmaktadır. Her çekim dosyasında Flair, T1, T1ce, T2 ve radyolog tarafından hazırlanan segmentasyon görüntüsü yer almaktadır. Bu segmentasyon görüntüsü kendi içerisinde iç içe geçmiş

katmanlar olarak düşünülebilir. Burada en iç katmanda nekroz, bir sonraki katmanda genişleyen tümör ve en dış katmanda ödem kısmı bulunmaktadır. Bu çalışmada tümör içerisindeki bölgelerin, MR modalitelerinin birlikte kullanılmasıyla daha belirgin hale gelmesi üzerine bir segmentasyon yöntemi önerilmiştir. Tam tümör tespiti için Flair ve T2 görüntüleri ile model ayrı ayrı eğitilmiştir. Flair ve T2 modalite görüntülerinin birleştirilerek yapılan eğitimdeki DSC puanı, modalitelerin birleştirilmeden tek tek kullanıldığı eğitimden daha yüksek çıkmıştır. Böylelikle tam tümör segmentasyonu için önerilen çalışma, literatürde yapılan başarılı çalışmalar arasında yer almıştır.

Genişleyen + nekroz ve genişleyen tümör segmentasyonunda T1Ce modalite görüntüsü kullanılmıştır. Nekroz ve genişleyen tümör görüntüleri tüm görüntüye göre küçük kalmaktadır. Bu yüzden T1ce modalite görüntüleri modelde 64x64 boyutunda kırılarak kullanılmıştır. Böylelikle tüm görüntüye göre küçük kalan nekroz + genişleyen ve genişleyen tümör görüntüleri tüm görüntüye kıyasla daha büyük hale gelmiştir. Bu da veri dağılımındaki dengesizliği azaltarak modelin performansını arttırmıştır. Genişleyen + nekroz ve genişleyen tümör segmentasyonunda Unet modeli 7 katmanlı hale getirilmiştir. Bunun sebebi, modelde katman sayısını azaltınca, model aşağı doğru inerken oluşan gradyan miktarını azaltmaktır. Böylelikle segmentasyon işleminde hız ve başarı değerinin arttığı görülmüştür. 7 katmanlı UNet modeli kullanılarak elde edilen sonuçlarda genişleyen + nekroz ve genişleyen tümör segmentasyonu için literatürdeki çalışmalara göre yüksek doğruluk puanı elde edildiği gözlemlenmiştir.

Tam tümör (nekroz + genişleyen + ödem), tümör merkezi (nekroz + genişleyen) ve genişleyen tümörlerin segmentasyonu 3 ayrı modelde gerçekleştirilmiştir. Tam tümör segmentasyonunda 240x240 orijinal boyutunda olan görseller 9 katmanlı U-Net modelinde gerçekleştirilmiştir. 240x240 orijinal boyutunda yapılan eğitimin DSC değerlendirme metrik sonuçları Flair, T2 ve Flair + T2 modaliteleri kullanıldığında sırasıyla 0.893, 0.873, 0.954 olarak çıkmıştır. Genişleyen + nekroz ve genişleyen tümör segmentasyonunda görüntüler modele 240x240 boyutunda ve 64x64 boyutunda parçalara ayrılarak verilmiştir. Yapılan eğitimin sonucunda ise DSC sonuçları sırasıyla 0.864, 0.921 olarak çıkmıştır. Genişleyen tümör segmentasyonunda görüntüler modele 240x240 boyutunda ve 64x64 boyutunda parçalara ayrılarak verilmiştir. Eğitim sonucunda DSC

sonuçları sırasıyla 0.843, 0.913 olarak çıkmıştır. Yapılan karşılaştırma sonucunda genişleyen + nekroz ve genişleyen tümör için 64x64 boyutunda bölünen görüntüyle yapılan segmentasyon sonuçları daha başarılı olmuştur.

Yapılan tüm işlemler sonucunda tahmin edilen segmentasyon görüntülerine etiket değerleri atanmıştır. Ardından etiket ve konum değerleri kullanılarak segmentasyon görüntüleri üst üste eklenmiş ve Şekil 4.5'teki segmentasyon işlemleri sonuçları başlıklı görüntü elde edilmiştir. Elde edilen sonuç ve literatür çalışmaları ile yapılan karşılaştırma sonucunda önerilen yöntem DSC indeksinde tam tümör segmentasyonunda ilk 2, tümör merkezi segmentasyonunda 2, Genişleyen tümör segmentasyonunda 1. olduğu gözlenmiştir. Önerilen çalışma, matematiksel olarak hesaplama maliyetinde kayda değer bir azalma meydana getirirken, performans değerlendirme kriterlerinde önemli ölçüde artış sağladığı görülmüştür. Farklı tümör bölgelerinin tespiti için uygun modalitelerin birlikte kullanılması, veri setindeki dengesizliği azaltmak için yapılan kırpma işlemi doğruluk sonucunu arttıran önemli faktörlerdendir. Görüntülerde tümörlerin boyutuna göre kırpma işleminin yapılması hesaplama maliyetini azaltan bir etken olmuştur. Elde edilen sonuçlar önerilen yöntemin beyin tümörü alt bölgelerinin segmentasyonunda etkin bir şekilde kullanılabileceğini göstermektedir. Modeldeki bu başarı gelecekte yapılacak çalışmalar için de rehberlik sağlayacaktır.

6. KAYNAKLAR

- Abd-Ellah M K, Awad A I, Khalaf A A M, Hamed H F A, 2016, Classification of Brain Tumor MRIs Using a Kernel Support Vector Machine, Communications in Computer and Information Science, 636, 151-160.
- Abd-Ellah M K, Khalaf A A M, Awad A I, Hamed H F A, 2019, 1, Lecture Notes in Computer Science, 11663, 106-116.
- Aghalari M, Aghagolzadeh A, Ezoji M, 2021, Brain tumor image segmentation via asymmetric/symmetric UNet based on two-pathway-residual blocks, Biomedical Signal Processing and Control, 69, Article Number 102841.
- Ahmad P, Qamar S, Hashemi S R, Shen L, 2020, Hybrid Labels for Brain Tumor Segmentation, BrainLes 2019: Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries, 11993, 158–166
- Altun S, Talu F, 2021, Derin Sinir Ağları için Hiperparametre Metodlarının ve Kitlerinin İncelenmesi, DÜMF Mühendislik Dergisi, 12:2, 187-199.
- Arı A, Hanbay D, 2019, Tumor detection in MR images of regional convolutional neural networks, Journal of the Faculty of Engineering and Architecture of Gazi University, 34, 1395-1408.
- Arnab A, Zheng S, Jayasumana S, Romera-Paredes B, Larsson M, Kirillov A vd. , 2018, Conditional Random Fields Meet Deep Neural Networks for Semantic Segmentation: Combining Probabilistic Graphical Models with Deep Learning for Structured Prediction, IEEE Signal Processing Magazine, 35, 37-52.
- Arora A, Jayal A, Gupta M, Mittal P, Satapathy C S, 2021, Brain Tumor Segmentation of MRI Images Using Processed Image Driven U-Net Architecture, Advances of Machine and Deep Learning in the Health Domain, 10 (11), 139.
- Ay Karakuş B, 2018, Derin Öğrenme ve Büyük Veri Yaklaşımları İle Metin Analizi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 246, Elazığ.
- Bakas S, Akbari H, Sotiras A, Bilello M, Rozycki M, Kirby J S, 2017, Advancing The Cancer Genome Atlas glioma MRI collections with expert segmentation labels and radiomic features, Nature, Article Number 170117.

- Bakas S, Reyes M, Jakab A, Bauer S, Rempfler M, Crimi A vd. , 2018, Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation, Progression Assessment, and Overall Survival Prediction in the BRATS Challenge, arXiv:1811.02629.
- Barın S, 2021, Deri Lezyonlarının Derin Öğrenme Yöntemleri İle Segmentasyonu, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 78, Afyonkarahisar.
- Barın S, Güraksın G E, 2022, An automatic skin lesion segmentation system with hybrid FCN-ResAlexNet, Engineering Science and Technology, an International Journal, Article Number 101174.
- Barzegar Z, Jamzad M, 2021, WLFS: Weighted label fusion learning framework for glioma tumor segmentation in brain MRI, Biomedical Signal Processing and Control, 68, Article Number 102617.
- Baykal Y, 2019, Derin Öğrenme İle Manyetik Rezonans Görüntülerde Temporomandibular Eklem Disk Deplasmanlarının Diagnozu, Karadeniz Teknik Üniversitesi, Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, 74, Trabzon.
- Coupet M, Urruty T, Leelanupab T, Naudin M, Bourdon P, Maloigne C F, Guillevin R, 2022, A multi-sequences MRI deep framework study applied to glioma classification, Multimedia Tools and Applications, 81, 13563–13591.
- Cinar N, Ozcan A, Kaya M, 2022, A hybrid DenseNet121-UNet model for brain tumor segmentation from MR Images, Biomedical Signal Processing and Control, 76, Article Number 103647.
- Dong H, Yang F, Liu F, Mo Y, Guo Y, 2017, Automatic Brain Tumor Detection and Segmentation Using U-Net Based Fully Convolutional Networks, arXiv:1705.03820.
- Fathi E, Shoja B M, 2018, Chapter 9 - Deep Neural Networks for Natural Language Processing, Handbook of Statistics, 38, 229-316.
- Fountas K, Kapsalaki E Z, 2019, Epilepsy Surgery and Intrinsic Brain Tumor Surgery A Practical Atlas: A Practical Atlas, A Practical Atlas, Springer Cham, 301, Switzerland.

- Gite S, Mishra A, Kotecha K, 2022, Enhanced lung image segmentation using deep learning, Neural Computing for IOT based Intelligent Healthcare Systems, PMC8720554, 1-15.
- Havaei M, Davy A, Warde-Farley D, Biard A, Courville A, Bengio Y, 2017, Brain tumor segmentation with Deep Neural Networks, Medical Image Analysis, 35, 18-31.
- Ilhan A, Sekeroglu B, Abiyev R, 2022, Brain tumor segmentation in MRI images using nonparametric localization and enhancement methods with U-net, International Journal of Computer Assisted Radiology and Surgery volume, 17, 589-600.
- Karakullukçu E, 2020, Yanık Görüntülerinin Çok Değişkenli İstatistiksel Yöntemler Ve Derin Öğrenme Yaklaşımları İle Analizi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 124, Trabzon.
- Kayadibi İ, 2021, Optik Koherens Tomografisi Görüntüleri Kullanarak Evrişimsel Sinir Ağı Tabanlı Retinal Hastalık Tespiti, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 90, Afyonkarahisar.
- Kingma D P, Ba J, 2017, Adam: A Method for Stochastic Optimization, arXiv:1412.6980.
- Kronberg R M, Meskelevicius D, Sabel M, Kollmann M, Rubbert C, Fischer I, 2022, Optimal acquisition sequence for AI-assisted brain tumor segmentation under the constraint of largest information gain per additional MRI sequence, Neuroscience Informatics, 2, Article Number 100053.
- Kurt F, 2018, Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi Analysis of The Effects of Hyperparameters In Convolutional Neural Networks, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans, 130, Ankara.
- Maji D, Sigedar P, Singh M, 2022, Attention Res-UNet with Guided Decoder for semantic segmentation of brain tumors, Biomedical Signal Processing and Control, 71, Article Number 103077.
- Marra J S, Mendes G P, Yoshinari Jr G H, Guimaraes F S, Mazin S C, Oliveria H F, 2019, Survival after radiation therapy for high-grade glioma, Reports of Practical Oncology & Radiotherapy, 24, 35-40.
- Menze B H, Jakab A, Bauer S, Kalpathy-Cramer J, Farahani K, Kirby J vd. , 2015, The

- Multimodal Brain Tumor Image Segmentation Benchmark (BRATS), IEEE Trans Med Imaging, 34, 1993-2024.
- Neelimaa G, Chigurukota D R, Maram B, Girirajan B, 2022, Optimal DeepMRSeg based tumor segmentation with GAN for brain tumor classification, Biomedical Signal Processing and Control, 74, Article Number 103537.
- Ozsahin I, Sekeroglu B, Mok Great S P, 2019, The use of back propagation neural networks and 18F-Florbetapir PET for early detection of Alzheimer's disease using Alzheimer's Disease Neuroimaging Initiative database, Article Number 101371.
- Öğüt G E, 2019, Makine Öğrenmesi Ve Derin Öğrenmede Cpu Ve Gpu Tabanlı Hızlandırma Tekniklerinin Karşılaştırılması, Muğla Sıtkı Koçman Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 44, Muğla.
- Patterson J, Gibson A, 2017, Deep Learning, O'Reilly Media, Inc, 507, United States Of America.
- Pekel E, 2018, Farklı Makine Öğrenmesi Algoritmalarının Karşılaştırılması, Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 76, Samsun.
- Pitchai R, Supraja P, Razia Sulthana A, Veeramakali T, Ch.Madhu Babu, 2022, MRI image analysis for cerebrum tumor detection and feature extraction using 2D U-ConvNet and SVM classification, Personal and Ubiquitous Computing, Article Number 10.1007.
- Rehman M U, Cho S, Kim J H, Chong K T, 2020, BU-Net: Brain Tumor Segmentation Using Modified U-Net Architecture, Electronics 2020, 9(12), 2203
- Ronneberger O, Fischer P, Brox T, 2015, U-Net: Convolutional Networks for Biomedical Image Segmentation, arXiv:1505.04597.
- Salas-Pilco S Z, Yang Y, 2022, Artificial intelligence applications in Latin American higher education: a systematic review, International Journal of Educational Technology in Higher Education, 19, Article Number 2.
- Sertkaya M E, 2018, Derin Öğrenme Tekniklerinin Biyomedikal İmgeler Üzerine Uygulamaları, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 70,

Elazığ.

- Soltaninejad M, Yang G, Lambrou T, Allinson N, Jones T L, Barrick T R, 2017, Automated brain tumour detection and segmentation using superpixel-based extremely randomized trees in FLAIR MRI, International Journal of Computer Assisted Radiology and Surgery, 12, 183-203.
- Şanlıtürk E, 2018, Makine Öğrenme Algoritmalarıyla Hatalı Ürün Tahmini, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 53, İstanbul.
- Tan Z, 2019, Derin Öğrenme Yardımıyla Araç Sınıflandırma, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 75, Elazığ.
- Taş S P, 2021, Retinal Hatalıkların Oftalmolojik Görüntüler Üzerinden Derin Öğrenme Teknikleri ile Tespit Edilmesi, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 69, Afyonkarahisar.
- Tiken C, 2015, Derin Öğrenme Uygulamaları, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 46, İstanbul.
- Türkoğlu M, Hanbay K, Saraç Sivrikaya I, Hanbay D, 2020, Derin Evrimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması, 9, 334-345.
- Ünlüsavuran M, 2019, Omik Verilerinde Otomatik Makine Öğrenimi Algoritmalarının Performansının Değerlendirilmesi, Erciyes Üniversitesi, Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, 95, Kayseri.
- Yakıt O, ÖZKAN Y, 2017, Kurumsal Kaynak Planlama Sistemlerinde Yapay Sinir Ağlarının Değerlendirilmesi Yaklaşımı, Siyaset, Ekonomi ve Yönetim Araştırmaları Dergisi, 5, 287-296.
- Yamashita R, Nishio M, Do R K G, Togashi K, 2018, Convolutional neural networks: an overview and application in radiology, Insights into Imaging, 9, 611–629.
- Zou K H, Warfield S, Bharatha A, Tempany C M C, Kaus M R, Haker S J, 2004, Statistical validation of image segmentation quality based on a spatial overlap index, 11, 178-189.
- Wang P, Chung A C S, 2022, Relax and focus on brain tumor segmentation, Medical Image Analysis, 75, Article Number 102259.

İnternet Kaynakları

- 1- <https://www.nhs.uk/conditions/brain-tumours/> 21.12.2021.
- 2- <https://www.simplilearn.com/tutorials/artificial-intelligence-tutorial/ai-vs-machine-learning-vs-deep-learning#:~:text=Artificial%20Intelligence%20is%20the%20concept,algorithms%20to%20train%20a%20model> 10.01.2022.
- 3- <https://www.ibm.com/cloud/learn/machine-learning> 11.01.2022.
- 4- <https://towardsdatascience.com/artificial-intelligence-vs-machine-learning-vs-deep-learning-2210ba8cc4ac> 12.01.2022.
- 5- <http://veribilimci.org/yapay-sinir-aglari-ysa-nedir-bolum-2/> 13.01.2022.
- 6- <https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks> 20.12.2021.
- 7- <https://enginunal.medium.com/derin-%C3%B6%C4%9Frenme-giri%C5%9F-dad1a98241d0> 04.02.2022.
- 8- <https://www.wgu.edu/blog/what-convolutional-neural-network2008.html#openSubscriberModal> 10.09.2020.
- 9- <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53> 15.03.2021.
- 10- <https://radiopaedia.org/articles/batch-size-machine-learning#:~:text=Batch%20size%20is%20a%20term,iteration%20and%20epoch%20values%20equivalent> 14.01.2022.
- 11- <https://neptune.ai/blog/image-segmentation> 16.03.2022.
- 12- <https://www.med.upenn.edu/cbica/brats2019/data.html> 16.05.2022.
- 13- <https://www.udemy.com/> 16.05.2022