

# Derin Öğrenme İle Beyin Tümör Segmentasyonu \*

*Araştırma Makalesi/Research Article*

 Bilal TAŞDEMİR<sup>1</sup>,  Necaattin BARIŞCI<sup>2\*</sup>

<sup>1</sup>Fen Bilimleri Enstitüsü, Teknoloji Fakültesi, Bilgisayar Mühendisliği, Gazi Üniversitesi, Ankara, Türkiye

<sup>2</sup>Fen Bilimleri Enstitüsü, Teknoloji Fakültesi, Bilgisayar Mühendisliği, Gazi Üniversitesi, Ankara, Türkiye

[tsdmr.bilal@gmail.com](mailto:tsdmr.bilal@gmail.com), [nbarisci@gazi.edu.tr](mailto:nbarisci@gazi.edu.tr)

(Geliş/Received:27.11.2023; Kabul/Accepted:15.05.2024)

DOI: 10.17671/gazibtd.1396872

**Özet**— Artan nüfus ile birlikte her geçen gün daha fazla insan beyin tümöründen etkilenmektedir. Diğer hastalıklar ile kıyaslandığında beyin tümörünün ölüm oranı çok daha yüksektir. Ayrıca beyin tümörü hastalığına yakalanan bireyler günlük yaşamlarında önemli zorluklarla karşılaşmaktadır. Beyin tümörünün tanısı doktorlar için zorlu bir süreçtir. Teşhis aşamasında doktorların karşılaştığı zorluklar ve bu sorunların üstesinden gelmek adına bir çözüm önerisi olarak, beyin MR görüntülerinin otomatik segmentasyonunu sağlayacak bir modelin tasarlanması hedeflenmiştir. Bu çalışmada beyin MR görüntülerinin segmentasyonundaki zorluğu aşmak için topluluk öğrenimi yöntemi kullanılmıştır. Topluluk öğrenimi yönteminde derin öğrenme tabanlı dikkat mekanizmalı u-net ve u-net modelleri kullanılmıştır. Bu yöntem ile iki farklı modelden gelen tahmin değerlerinin ortalamasının alınması ve daha kararlı bir modelin geliştirilmesi amaçlanmıştır. Model eğitimi için BRATS veri setinin 2018, 2019 ve 2020 versiyonları kullanılırken, model testleri için 2017 versiyonu tercih edilmiştir. Veri setindeki dengesiz sınıf dağılımı problemine çözüm olarak farklı veri ön işleme adımları kullanılmıştır ve topluluk öğrenimi modeli ile beyin MR görüntülerinin segmentasyon problemi ele alınmıştır. Elde edilen topluluk öğrenimi yöntemi ile BRATS2017 veri seti üzerinde %87,33 ortalama zar skoru, %81,74 nekrotik sınıfı zar skoru, %91,57 ödem sınıfı zar skoru, %76,03 artırılmış tümör sınıfı zar skoru, %99,96 arka plan sınıfı zar skoru ve Tüm Tümör (TT), Çekirdek Tümör (ÇT) ve Artırılmış Tümör (AT) için sırasıyla %83,11, %78,88 ve %76,03 zar skoru elde edilmiştir.

**Anahtar Kelimeler**— segmentasyon, tümör, derin öğrenme, u-net, görüntü işleme, normalizasyon, topluluk öğrenimi

## Brain Tumor Segmantation With Deep Learning \*

**Abstract**— With the increasing population, more and more people are affected by brain tumors every day. Compared to other diseases, the death rate of brain tumors is much higher. In addition, people suffering from brain tumor disease have important difficulties in their daily lives. The diagnosis of brain tumors poses a challenging process for medical professionals. To address the difficulties faced by doctors during the diagnostic phase and propose a solution, the objective is to design a model that enables the automatic segmentation of brain MR images. In this study, Ensemble learning method was used to overcome the difficulty in segmentation of brain MRI images. Deep learning base attention u-net and u-net models were used in ensemble learning method. The aim is to develop a more stable model by averaging the prediction values from two different models. While the 2018, 2019 and 2020 versions of BRATS dataset were used for model training, the 2017 version was preferred for model testing. With different data preprocessing steps and ensemble learning model, the difficulty of segmentation of brain MR images has been overcome on imbalanced dataset. With the ensemble learning method created, 87.33% average zar score, 81.74% necrotic class zar score, 91.57% edema zar score, 76.03% enhancing zar score, 99.96% background class zar score and zar score of 83.11%, 78.88% and 76.03% for Whole Tumor (WT), Tumor Core (TC) and Enhancing Tumor (ET) were obtained on BRATS2017 dataset.

**Keywords**— segmantation, tumor, deep learning, u-net, image processing, normalization, ensemble learning

## 1. GİRİŞ (INTRODUCTION)

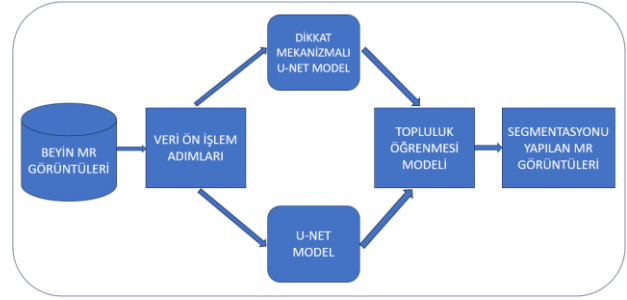
Beyin, sinir sisteminin merkezi olarak hizmet eden bir organdır. Her insanın beyni komplike bir yapıya sahiptir, bilgiler beyin tarafından çağrılır toplanır ve değerlendirilir. Beyin veya omurilikte anormal bir hücre büyümesi sonucunda oluşan kitlelere beyin tümörü denilmektedir. Beyin tümörü günümüzde yaygın olarak görülen bir hastalık türüdür. Doğrudan beyin üzerinde meydana gelen zararlı tümör hücreleri insanların yaşamlarını da olumsuz etkilemektedir. Beyin tümörü ile mücadele eden hastalarda nörolojik semptomlar sebebiyle hareket bozuklukları, denge kaybı, kas güçsüzlüğü, duyu kaybı, konuşma güçlüğü gibi belirtiler ortaya çıkabilmektedir. Beyin tümörünün teşhisi ve tedavisi için doktorlar beyin manyetik rezonans (MR) görüntülerini incelemektedirler. MR görüntüleri değerli tamamlayıcı bilgiler sağlamaktadır ve beyin tümörü segmentasyonunun performansını önemli ölçüde artırmaktadır [1]. Beyin tümörü hastalığında ölüm oranı çok yüksektir, Çin’de beyin tümöründen ölen insan sayısı yıllık 50,000 ile 100,000 arasındadır [2]. Amerikada her yıl 80,000 kişide beyin tümörü teşhis edilmektedir [3]. Beyin tümörü insanlar açısından çok önemli bir hastalık olduğundan üzerinde birçok çalışma yapılmaktadır.

Beyin tümörlerinin tanısı genellikle MR veya bilgisayarlı tomografi (BT) görüntüleri ile konulmaktadır. Beyin tümörü tanı sürecinde uzman bir nöroloji doktoruna ihtiyaç duyulmaktadır. Tedavi yöntemleri tümörün tipine, boyutuna ve konumuna göre değişmektedir.

Beyin tümörünün tanısı oldukça zorlu bir süreçtir, tanı esnasında tümörün boyutu ve konumu manuel olarak dikkatlice tespit edilmelidir. Bazı tümörlerin boyutu küçüktür ve belli bir görüntüleme tekniği ile net bir şekilde görüntülenemeyebilir. Ayrıca bazı tümörlerin iyi veya kötü huylu olması da görüntüleme sonuçlarını etkileyebilmektedir.

Beyin MR görüntülerinin doğru ve güvenilir bir şekilde segmentasyonun yapılması kanser teşhisinde kritik rol oynamaktadır [4]. Beyin tümörü hastalığının teşhis ve tedavi süreçlerindeki olası hatalar insanların ölümü ile sonuçlanabilir.

Beyin MR görüntülerinin yapay zeka desteğiyle otomatik olarak segmente edilmesi hastalığın teşhisi ve tedavisi açısından son derece kritiktir. Bu nedenle sağlık alanında hataları minimuma indirmek amacıyla yapay zeka kullanımı giderek artmaktadır. Bu yaklaşım, uzman doktor işgücüne olan ihtiyacı azaltmanın yanı sıra beyin MR görüntülerinin doğru bir şekilde segmentasyonunu sağlamaktadır. Bu araştırma çalışmasının amacı Şekil 1’de görüldüğü üzere beyin MR görüntüsünü otomatik olarak tarayıp, beynin farklı bölümlerinde hangi tümör sınıfının bulunduğunu otomatik olarak segmente edecek ve Şekil 2’de görüldüğü üzere doktorlar tarafından verilecek beyin MR görüntülerinin segmentasyonunu yapıp doktorlara sonuçları iletecek model elde etmektir.



Şekil 1. Beyin MR görüntülerinin segmentasyon süreci  
(Segmentation process of brain MR images)

Bu çalışmanın diğer çalışmalardan ilk farkı, Brain Tumor Segmentation (BRATS) veri setinin 2018, 2019 ve 2020 versiyonları ile derin öğrenme modelinin eğitilip, 2017 versiyonu ile testler yapılmasıdır. Bu sayede modelin hiç görmediği bir versiyon üzerindeki başarısı test edilmektedir. İkinci farkı ise veri ön işleme adımında dengesiz sınıf dağılımı problemini ele almasıdır.



Şekil 2. Segmentasyon modelinin sonuç üretmesi  
(Segmentation model outcome producing)

Bu çalışmada 4 adet amacımız bulunmaktadır. Çalışmanın hedefleri şu şekilde özetlenebilir:

- Farklı derin öğrenme yöntemlerini kullanarak beyin MR görüntülerinin segmentasyon problemini çözmek
- Beyin tümörü hastalığının tanı ve teşhis aşamasında uzman doktorlara doğru bilgi sağlamak
- Dengesiz veri dağılımına sahip beyin MR görüntüsü veri seti için özel veri ön işleme adımları kullanarak derin öğrenme yöntemlerinin başarı oranını artırmak
- Beyin MR görüntülerini segmente ederek hastaların tedavi süreçlerine destek olmak

Bu çalışmanın ana katkıları aşağıda özetlenmiştir.

- Beyin MR görüntülerinin segmentasyonu otomatikleştirilmektedir.
- Beyin MR görüntülerinin segmentasyon işlemi otomatikleştirilerek hastalığın tanısı ve teşhisinde harcanan süre kısaltılmaktadır.
- Doktorlar tarafından hataya açık şekilde manuel olarak yapılan segmentasyon işleminin daha doğru ve güvenilir olması sağlanmaktadır.
- Doktorların teşhis ve tanı aşamasında daha az zaman harcayarak hastalığın tedavisine yoğunlaşmasını sağlamaktadır.
- Hastaların tedavi sürecine katkıda bulunarak iyileşme oranını artırmaktadır.

## 2. LİTERATÜR TARAMASI (LITERATURE REVIEW)

Yapay zeka alanında yapılan çalışmalarda derin öğrenme yöntemleri yaygın olarak kullanılmaktadır. Çok büyük miktarda veri üreten kaynakların artması ile birlikte derin öğrenme yöntemleri giderek önem kazanmaktadır. Sağlık alanında da günümüzde çok büyük veriler üretilerek çeşitli derin öğrenme yöntemleri ile bazı hastalıklara çözüm aranmaktadır, beyin tümörü de bu hastalıklardan birisidir. Günümüz dünyasında beyin tümörü birçok insanda görülmektedir, beyin tümöründen etkilenen insan sayısı yaş ve cinsiyet farketmeksizin gün geçtikçe artmaktadır. Beyin MR görüntülerinin doğru bir şekilde segmentasyonunun yapılması beyin tümörünün tanı ve tedavisi için önemlidir [5]. Derin öğrenme yöntemleri kullanılarak beyin tümörü üzerinde çeşitli çalışmalar gerçekleştirilmiştir. Zhang ve ark. [5] modalite çeşitlerinden farklı ve tamamlayıcı özneliklerin çıkarılmasını ve birleştirilmesini içeren derin öğrenme yöntemi önermiştir, çalışma kapsamında BRATS2021 veri seti kullanmıştır. Huang ve ark. [6] literatürdeki beyin MR görüntüleri üzerine yapılan yapay zeka çalışmalarını incelemiştir, inceleme sonucunda bu alanda yapılan çalışmaların son yıllarda arttığını, fakat yapılan çalışmaların klinik ortamlardaki pratiğe adopte olması gerektiği sonucunu elde etmiştir. Wang ve Chung [7] beyin MR görüntülerinin segmentasyonu için hibrit bir Evrişimli Sinir Ağı (ESA) modeli önermiştir, çalışmayı BRATS2019 veri seti ile gerçekleştirmiştir, veri setindeki dengesiz sınıf dağılımı problemini çözmek için ise dinamik odak kayıp fonksiyonu önermiştir. Jiang ve ark. [2] Çift Akış Kod Çözmeli U-net ismini verdikleri ESA mimarisi ile U-net mimarisini kombineledikleri bir model önermiştir, model içerisinde dengesiz sınıf problemini çözmek için ağırlıklı çapraz entropi kayıp fonksiyonu kullanmıştır, çalışmayı BRATS2017 ve BRATS2018 veri setleri ile gerçekleştirmiştir. Goceri [8] Kapsül Ağı mimarisi ile ikili sınıflandırma yöntemi geliştirmiştir. Kullandığı beyin MR görüntülerini normal ve anormal olarak sınıflandırarak %92,65 doğruluk oranı elde etmiştir. Alzahrani [9] beyin MR görüntülerinin sınıflandırılması için Evrişimsel Dikkat Mekanizmalı Karıştırıcı yöntemini önermiştir. Önerilen model %97,94 doğruluk oranı elde etmiştir. Zhang ve ark. [10] iki aşamalı bir model önermiştir. Çapraz Modalite Özellik Geçiş aşamasını bilgiyi farklı türler arasında aktararak zengin özellik temsilleri elde etmek için, Çapraz Modalite Özellik Füzyonu aşamasını ise farklı türden gelen bilgileri birleştirmek için kullanmıştır. Naser ve Deen [11] U-net modeli ile Görsel Geometri Grup 16 modelini kombineleyerek bir model 6 önermiştir. Modeli normal ve anormal olacak şekilde ikili sınıflandırma yöntemi ile oluşturmuştur. Dengesiz sınıf dağılımı problemi için kayıp fonksiyonunda sınıflara ağırlık vermiştir. Diao ve ark. [1] beyin MR görüntülerindeki eksik bilgileri tamamlamak için yeniden yapılandırma yöntemi ve eksik modaliteli MR görüntü segmentasyonu için ortak öğrenmeye dayalı özellik yeniden yapılandırma ve geliştirme yöntemi önermiştir. Önerilen yöntem ile BRATS2018 veri seti üzerinde testler yapılmıştır. Yapılan testlerde Tüm Tümör (TT), Çekirdek Tümör (ÇT), Artırılmış Tümör (AT) sınıf kümeleri için sırasıyla %86,28, %77,02, %59,64 zar skoru


elde etmiştir. Rammurthy ve Mahesh [12] beyin MR görüntülerinden tümörü tespit etmek için Balina Harris Hawks Optimizasyonu yöntemini önermiştir. Balina Optimizasyon Algoritması ve Harris Hawks Optimizasyon algoritmalarının kombinlenmesiyle oluşturulan yöntem Derin Evrişimsel Sinir Ağı modeli ile birlikte ikili sınıflandırmada %81,6 doğruluk oranı elde etmiştir. Hashemzahi ve ark. [13] beyin MR görüntüleriyle ikili sınıflandırıcı hibrit model önermişlerdir. Önerilen hibrit modeli Sinirsel Otoregresif Dağılım Tahmini ve ESA modelini kombineleyerek oluşturmuşlardır. Önerilen model %95 doğruluk oranı elde etmiştir. Nalepa ve ark. [14] geliştirdikleri derin öğrenme modeline ek olarak hata oranını düşüren kübik model geliştirmiştir. Naceur ve ark. [15] beyin MR görüntülerinin segmentasyonu için ESA modeli kullanmıştır, dengesiz sınıf dağılımı problemini çözmek için ağırlıklı çapraz entropi kayıp fonksiyonu, görüntüler arası uzaysal ilişkiyi yakalamak için ise Çakışan Yamalar yöntemini önermiştir. Çalışmada sırasıyla her bir sınıf için %90, %83 ve %83 zar skoru elde edilmiştir. Deepak ve Ameer [16] beyin MR görüntülerinin segmentasyonunda ilk olarak GoogLeNet modeli ile öznelik çıkarımı gerçekleştirmiştir. Sonrasında ise Destek Vektör Makinesi (DVM) sınıflandırıcı algoritması kullanmıştır. Maharjan ve ark. [17] beyin tümör tespiti için ESA modeli geliştirmiştir, kayıp fonksiyonu olarak özelleştirilmiş softmax kayıp fonksiyonu kullanmıştır. Saba ve ark. [18] beyin MR görüntülerinin segmentasyonunda Yakalama Kesme metodunu kullanmıştır, öznelik çıkarımında ise Görsel Geometri Grup 19 hazır modelini kullanmıştır. Veri seti olarak BRATS2015, BRATS2016 ve BRATS2017 veri setlerini kullanmıştır. Mittal ve ark. [19] öznelik çıkarımı için Sabit Dalgacık Dönüşümü kullanmıştır, Büyüyen Evrişimli Sinir Ağı kullanarak segmentasyon modelini oluşturmuştur, önerilen hibrit yöntem %98 kesinlik oranına sahiptir. Zhao ve ark. [4] Tam Evrişimli Sinir Ağı ve Koşullu Rastgele Alanlar yöntemini kullanarak beyin MR görüntülerinin segmentasyonu için bir framework geliştirmiştir. Geliştirilen framework ile 3 farklı beyin MR görüntüsünü kullanarak 3 farklı model eğitmiştir ve oylama tabanlı yöntem ile segmentasyon yapmıştır. Model eğitimini ve testlerini BRATS2013, 7 BRATS2015 ve BRATS2016 veri setleri üzerinde gerçekleştirmiştir. Yang ve ark. [20] Küçük Çekirdekli İki Yollu Evrişimsel Sinir Ağı ve Rastgele Orman algoritması ile hibrit model önermiştir. Küçük Çekirdekli İki Yollu Evrişimsel Sinir Ağı modelinin öznelik çıkarımı yapılarak Rastgele Orman algoritması ile sınıflandırma işlemi yapılmıştır. Sonuçlar BRATS2015 veri seti ile değerlendirilmiştir. Önerilen method sırasıyla TT zarskoru bazında %89, ÇT zar skoru bazında %80 ve AT zar skoru bazında ise %87 başarı oranı elde etmiştir. Mehrotra ve ark. [21] derin öğrenme algoritmalarını kullanarak normal ve anormal olarak ikili sınıflandırma şeklinde bir sınıflandırıcı önermiştir. Çeşitli öğrenme aktarımı modelleri ile testler yapmıştır. Veri seti olarak The Cancer Imaging Archive (TCIA) veri setini kullanarak %99 oranında doğruluk oranı elde etmiştir. Xu ve ark. [22] beyin tümör segmentasyonu için hibrit bir model önermiştir. Köşe Dikkat Mekanizmalı Modül ile dilimler arası bilgiyi yakalamayı amaçlamıştır.

Algısal benzerliği keşfeden ve lokal tutarlılığı muhafaza eden Yüksek Boyutlu Algısal Kayıp kayıp fonksiyonu kullanmıştır, segmentasyon modeli için U-net kullanmıştır. Model üzerindeki testleri BRATS2018, BRATS2019 ve BRATS2020 veri setleri üzerinde gerçekleştirmiştir. Liu ve ark. [23] beyin tümör segmentasyonu için Ölçeğe Uyarlanabilir Süper Özellik Metrik U-net modelini önermiştir. Ayrıca önerdiği Ölçeğe Uyarlanabilir Metrik kayıp fonksiyonu ile modelin daha fazla bilgi öğrenmesini sağlamıştır. Model testlerini BRATS2019 veri seti üzerinde gerçekleştirmiştir. Drai ve ark. [24] beyin MR görüntüleri üzerinden öznelik çıkarımı için Otomatik MR Beyin Çıkarma Algoritması ve otomatik tümör segmentasyonu için Otomatik Tümör Segmentasyonu modelini önermiştir. Model başarısını ölçümlemek için zar skoru kullanmıştır. Bidkar ve ark. [25] beyin tümörünü sınıflandırmak için Salp Su Optimizasyonu Temelli Derin İnanç Ağı modelini önermiştir. Veri seti olarak BRATS2018 kullanmıştır. Önerilen model ile %93,3 doğruluk oranı elde etmiştir. Zhou ve ark. [26] bir veya daha fazla beyin MR görüntüsünü dışarıda tutarak yeni bir U-net tabanlı beyin tümör segmentasyon ağı önermiştir. Model testlerini BRATS2018 veri seti ile gerçekleştirmiştir. Model performansı zar skoru ile ölçülmüştür. Sırasıyla zar skoru bazında her bir sınıf için %82, %74,9 ve %59,1 başarı oranı elde etmiştir. Huang ve ark. [27] ilk olarak arkaplan kaldırma ve görüntü normalizasyonunu iteratif olarak uygulamıştır. Ardından önerilen Kanallar Arası Dikkat Mekanizmalı Kalıntı U-net segmentasyon modelini uygulamıştır. Önemli öznelik gruplarını vurgulamak için ise Grup Kanallar Arası Dikkat Mekanizması modelini önermiştir. Model eğitimi ve testleri için BRATS2017 ve BRATS2018 veri setleri kullanılmıştır. Cinar ve ark. [28] U-net ile DenseNet121 modellerini hibrit şekilde kullanarak öğrenme aktarımı tabanlı hibrit bir sistem önermiştir. Dengesiz sınıf dağılımı 8 problemini çözmek için MR görüntüsündeki tümörlü alanı otomatik tespit edip kesen bir algoritma önermiştir. Model eğitimi ve testleri için BRATS2019 veri seti kullanmıştır. Mazumdar ve Mukherjee [29] mevcutta önerilen ESA modellerinden daha hızlı ve daha az parametreye sahip, U-net tabanlı Verimli Mekansal Dikkat Ağı modelini önermiştir. Dengesiz sınıf dağılımı problemini çözmek için zar, odak ve Hausdorff Uzaklık kayıp fonksiyonlarının bileşimi olan yeni bir kayıp fonksiyonu önermiştir. Veri seti olarak BRATS2021 kullanmıştır.

### 3. VERİ SETİ (DATASET)


BRATS veri setleri nörolojik radyoloji alanında kullanılan, hastalara ait beyin tümörü MR görüntülerini içeren veri setleridir. BRATS2018 veri seti 285 hastadan, BRATS2019 veri seti 335 hastadan ve son olarak BRATS2020 veri seti ise farklı görüntüleme merkezlerine başvuran 369 farklı hastadan elde edilmiş MR görüntülerini içermektedir. Özellikle yapay zeka ve derin öğrenme gibi çalışmalarda sıklıkla kullanılmaktadır. BRATS veri setleri ilk olarak 2012 yılında düzenlenmeye başlamıştır.

BRATS veri setleri T1, T1-CE, T2 ve FLAIR gibi farklı MR görüntü modalitelerinden elde edilen beyin tümörü görüntülerini içerisinde bulundurmaktadır. Her modalite çeşidi farklı görüntüleme teknolojisi ile elde edildiğinden dolayı beyne ait farklı özellikleri içerisinde barındırır [30]. Ayrıca Şekil 3'te görüldüğü üzere her bir modalite görüntüsü 155 dilimden oluşmaktadır, her bir dilim ise 240 genişlik ve 240 yükseklik boyutlarına sahiptir.




Şekil 3. Beyin MR görüntüsü boyutları  
(Shape of brain MR images)

Farklı modalite çeşitleri farklı görüntüleme teknolojileri ile oluşturuldukları için her bir modalite çeşidinde beyin farklı bir bölgesi ön plana çıkmaktadır. Şekil 4'te farklı modalite çeşitlerinin aynı diliminden elde edilmiş görüntüler ve görüntülere karşılık uzman kişilerin yapmış olduğu segmentasyon gösterilmiştir.



Şekil 4. Farklı modalite çeşitlerinin aynı dilimindeki görüntüler  
(Images of different modalities in same slice)

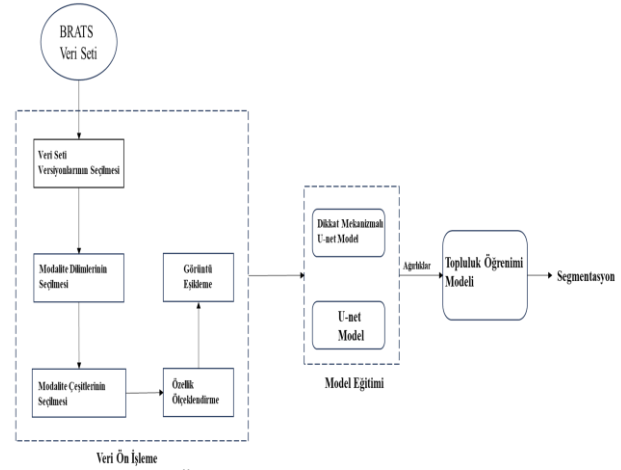
Uzmanlar tarafından etiketlenen beyin segmentasyon görüntüleri içerisinde toplamda 4 farklı sınıf bulundurmaktadır. Bu sınıflar tümör sınıflarını ifade etmektedir. Sınıf 0 arka plan, sınıf 1 nekrotik, sınıf 2 ödem ve sınıf 3 ise artırılmış tümör olarak isimlendirilmektedir. Ek olarak literatürde yapılan çalışmalarda farklı sınıf kümelerine farklı isimlendirmeler yapılarak model sonuçları bu isimlendirmeler ile değerlendirilmektedir. Tüm Tümör (TT) ile isimlendirilen küme içerisinde artırılmış, ödem ve nekrotik sınıfları bulunmaktadır. Çekirdek Tümör (ÇT) ile isimlendirilen küme içerisinde artırılmış ve nekrotik tümör sınıfı bulunmaktadır. Artırılmış Tümör (AT) ile isimlendirilen kümede ise yalnızca artırılmış tümör sınıfı bulunmaktadır [37]. Şekil 5'te uzmanlar tarafından etiketlenen segmentasyon görüntüsünün her bir sınıfının farklı renkte renklendirilmesiyle elde edilen görüntü gösterilmiştir.



Şekil 5. Renklendirilmiş segmentasyon görüntüsü  
(Colored segmentation image)

#### 4. YÖNTEM (METHOD)

Önerilen modelin temel amacı, BRATS veri setinin farklı versiyonlarını kullanarak beyin tümör segmentasyonu yapan bir sistem oluşturmaktır. Bu sistem için sırası ile uygulanan işlemler şu şekildedir; BRATS veri seti versiyonlarından hangi kombinasyonun eğitim veri seti olarak seçileceğine karar verilmesi, veri seti içerisinde bulunan modalitelerin hangi dilim aralıklarının kullanılacağına karar verilmesi, hangi modalitelerin model eğitim aşamasında kullanılması gerektiğinin tespit edilmesi, görüntü eşikleme ve özellik ölçeklendirme yöntemlerinin uygulanması ve son olarak farklı derin öğrenme modelleri ile segmentasyon işleminin gerçekleştirilmesidir. Çalışmada önerilen modelin mimarisi Şekil 6'da gösterilmiştir. Çalışma kapsamında hangi veri seti versiyonlarının model eğitim aşamasına dahil olması gerektiği ile ilgili yapılan testler sonucunda BRATS veri setinin 2018, 2019 ve 2020 versiyonları model eğitim aşamasında kullanılırken, 2017 versiyonu modelin testleri için kullanılmıştır. (240 x 240 x 155) boyutlarına sahip olan modaliteler ile yapılan testlerde 155 adet dilim içerisinden 15 – 143 arası dilimler aşağı örnekleme yöntemi ile seçilmiştir. BRATS veri seti içerisinde 4 farklı modalite çeşidi bulunmaktadır, bunlar; Flair, T1, T1-CE, T2. Yapılan testler sonucunda 4 farklı modalite çeşidinden Flair, T1 ve T1-CE modalite çeşitleri seçilmiştir. Minimum-maksimum özellik ölçeklendirme yöntemi ile veri seti üzerinde bulunan farklı örneklerin birbirleri üzerinde üstünlük kurması engellenmiştir. Sıfıra eşikle görüntü eşikleme yöntemi ile de beyin MR görüntüsü üzerindeki tümör içeren bölgenin ayrıştırılarak daha belirgin olması sağlanmıştır. Veri ön işleme adımları tamamlandıktan sonra segmentasyon problemlerinde sıklıkla tercih edilen derin öğrenme tabanlı 2 farklı model oluşturulmuştur, bunlar; dikkat mekanizmalı u-net ve u-net modelleridir. Eğitilen 2 farklı model ile birlikte daha kararlı ve güçlü bir model ortaya çıkarabilmek için topluluk öğrenimi modeli oluşturulmuştur. Oluşturulan topluluk öğrenimi modeli 2 farklı u-net modelinden gelen sınıf tahminlerinin ortalamasını hesaplayarak her bir sınıf için yeni ortalama bir tahmin üretmektedir. Bu şekilde 2 farklı modelin tahmin gücü ile tahminler gerçekleştirilmiştir.

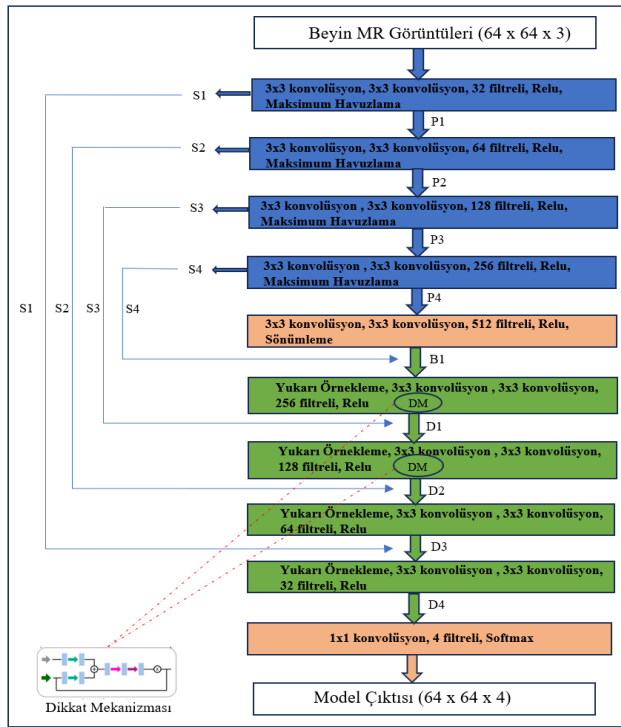


Şekil 6. Önerilen modelin detaylı mimarisi  
(Detailed architecture of proposed model)

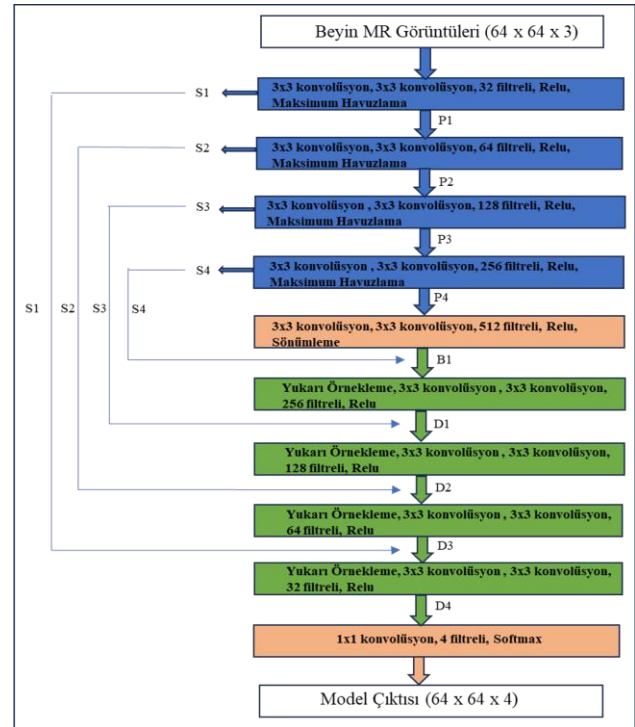
#### 4.1. Derin Öğrenme Tabanlı Modeller (Deep Learning Based Models)

##### 4.1.1. Dikkat mekanizmalı u-net modeli (Attention u-net model)

Çalışma kapsamında geliştirilen dikkat mekanizmalı u-net modeli Şekil 7'de gösterilmiştir. İlk olarak modele 3 farklı modalite çeşidinden oluşan veri girdi olarak verilmektedir. Daha sonra 4 parçadan oluşan kodlayıcı bölümünün ilk parçası gerçekleşerek iki farklı çıktı üretmektedir. S1 ile isimlendirilen çıktı konvolüsyon işleminden elde edilen çıktı, P1 ise maksimum havuzlama işleminden sonra elde edilen çıktıdır. Kodlayıcı bölümünün ikinci, üçüncü ve dördüncü parçalarında da sırasıyla S2, P2, S3, P3 ve S4, P4 çıktıları elde edilmektedir. S2, S3 ve S4 çıktıları konvolüsyon işlemlerinden elde edilen çıktılar olurken, P2, P3 ve P4 çıktıları maksimum havuzlama işlemlerinden elde edilen çıktılar olmaktadır. Kodlayıcı bölümünün her parçasında maksimum havuzlama işleminden elde edilen çıktılar bir sonraki parçaya iletilmektedir. Kodlayıcı bölümünden sonra orta bölümde konvolüsyon işlemi uygulanır ve burada elde edilen çıktı ile kodlayıcı katmanının dördüncü parçasında konvolüsyon işlemi ile elde edilen çıktı çözücü katmanının ilk parçasına girdi olarak verilir. Daha sonra girdilere sırasıyla yukarı örnekleme, dikkat mekanizması ve konvolüsyon işlemi uygulanır. Dikkat mekanizması çözücü katmanının yalnızca ilk iki bölümünde kullanılmaktadır. Bu işlemler sırasıyla çözücü bölümündeki tüm parçalarda gerçekleştirilir. Sonuç olarak (64 x 64 x 4) boyutlarında çıktı elde edilmektedir. Çalışma kapsamında aktivasyon fonksiyonu olarak ara katmanlarda Relu çıkış katmanında ise softmax tercih edilmiştir. Relu ve softmax tercih edilme sebebi literatürdeki çalışmalarda yoğun olarak kullanılmasıdır.



Şekil 7. Geliştirilen dikkat mekanizmalı u-net modeli  
(Developed u-net model with attention mechanism)



Şekil 8. Geliştirilen u-net modeli  
(Developed u-net model)

Model üzerinde eğitim gerçekleştirilirken BRATS veri setinin 2018, 2019 ve 2020 versiyonları kullanılmaktadır. Test aşamasında ise BRATS veri setinin 2017 versiyonu kullanılmaktadır.

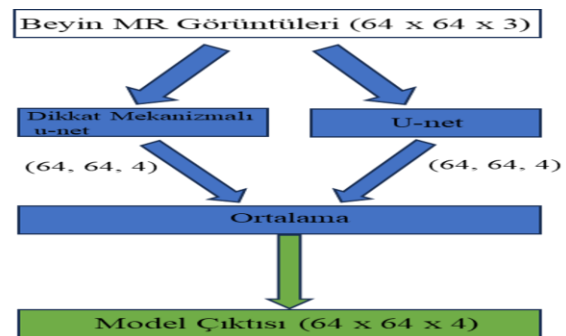
#### 4.1.2. U-net modeli (U-net model)

Çalışma kapsamında geliştirilen u-net modeli Şekil 8'de gösterilmiştir. İlk olarak modele 3 farklı modalite çeşidinden oluşan veri girdi olarak verilmektedir. Daha sonra 4 parçadan oluşan kodlayıcı bölümünün her bir parçası gerçekleşerek iki farklı çıktı üretmektedir. S1, S2, S3 ve S4 ile isimlendirilen çıktılar konvolüsyon işleminden elde edilen çıktılar, P1, P2, P3 ve P4 ile isimlendirilen çıktılar ise maksimum havuzlama işleminden sonra elde edilen çıktılar ifade etmek için kullanılmaktadır. Kodlayıcı bölümünün her parçasında maksimum havuzlama işleminden elde edilen çıktılar bir sonraki parçaya iletilmektedir. Kodlayıcı bölümünden sonra orta bölümde konvolüsyon işlemi uygulanır, bu bölümdeki çıktı B1 ile isimlendirilmektedir. Orta bölümde elde edilen çıktı ile kodlayıcı katmanının dördüncü parçasında konvolüsyon işlemi ile elde edilen çıktı çözücü katmanın ilk parçasına girdi olarak verilir. Daha sonra girdilere yukarı örnekleme ve konvolüsyon işlemi uygulanır. Bu işlemler sırasıyla çözücü bölümündeki tüm parçalarda gerçekleştirilir. Sonuç olarak (64 x 64 x 4) boyutlarında çıktı elde edilmektedir. Çalışma kapsamında aktivasyon fonksiyonu olarak ara katmanlarda Relu çıkış katmanında ise softmax tercih edilmiştir. Relu ve softmax tercih edilme sebebi literatürdeki çalışmalarda yoğun olarak kullanılmasıdır.

Model üzerinde eğitim gerçekleştirilirken BRATS veri setinin 2018, 2019 ve 2020 versiyonları kullanılmaktadır. Test aşamasında ise BRATS veri setinin 2017 versiyonu kullanılmaktadır.

#### 4.1.3. Topluluk öğrenimi modeli (Ensemble learning model)

Çalışma kapsamında geliştirilen dikkat mekanizmalı u-net ve u-net modellerinden elde edilen çıktılar ile topluluk öğrenimi modeli oluşturulmaktadır. Şekil 9'da topluluk öğrenimi modeli gösterilmektedir. Dikkat mekanizmalı u-net ve u-net modellerinin eğitim işlemi tamamlandıktan sonra ağırlık dosyaları ile model ağırlıkları yeniden yüklenerek oluşturulan ortalama katmanına çıktılar iletilmektedir. Ortalama katmanında her bir modelin her bir sınıf için yaptığı olasılık tahminlerinin ortalaması alınarak sonuç tahmin çıktısı üretilmektedir. Bu şekilde her iki modelin de sınıf tahminine katkı yaptığı topluluk öğrenimi modelinde başarı oranı modellerin bireysel başarılarından daha iyi olmaktadır.



Şekil 9. Topluluk öğrenimi modeli mimarisini  
(Architecture of ensemble learning model)

## 5. SONUÇLAR VE TARTIŞMA (RESULTS AND DISCUSSION)

Literatürde BRATS veri setleri kullanılarak yapılan birçok çalışma bulunmaktadır. Bu çalışma kapsamında beyin tümör segmentasyonu ile ilgili yapılan güncel çalışmaların incelenmesi sonucunda BRATS veri setlerinin kullanılmasına karar verilmiştir. Derin öğrenme tabanlı mimariler beyin tümör segmentasyonu konusunda en çok kullanılan yöntemlerden biridir, sıklıkla kullanılan mimarilerden birisi de u-net mimarisidir [38]. Beyin tümör segmentasyonu doktorlara tümörlerin yerini ve boyutunu doğru bir şekilde tanımlama olanağı tanıdığı için kritik bir işlemdir [39]. Medikal alanda yapılan segmentasyon çalışmalarının değerlendirilmesi sonucunda u-net tabanlı model mimarilerinin yoğun olarak kullanıldığı görülmüştür. Bu kapsamda u-net tabanlı modeller ile deneysel çalışmalar yapılmaktadır.

### 5.1. Veri Ön İşlemleri (Data Preprocessing)

Veri ön işleme adımı yapay zeka projelerinin en temel ve en önemli adımıdır. Bu adımda makine öğrenmesi modellerine girdi olarak verilecek olan veri seti üzerinde çeşitli işlemler yapılarak verinin model için hazır hale getirilmesi sağlanır. Aynı zamanda bu adımda yapılacak işlemler makine öğrenmesi modellerinin başarı oranlarını doğrudan etkilemektedir.

#### 5.1.1. Veri seti versiyonlarının seçilmesi (Dataset versions selection)

Çalışma kapsamında BRATS veri setinin 4 farklı versiyonu kullanılmaktadır. Bu versiyonlardan 2017 versiyonu test için ayrılmıştır. 2018, 2019 ve 2020 versiyonlarından hangi kombinasyonun kullanılacağına karar vermek için ise 40 adımlık temel bir u-net modeli ile testler yapılmıştır. 2018, 2019 ve 2020 versiyonlarının olası tüm kombinasyonları ile aynı model 40 adım olacak şekilde eğitilmiştir. Eğitim sonuçları tablo 1' de gösterilmektedir. Yapılan testler sonucunda en başarılı performansı 2018, 2019 ve 2020 versiyonlarının bulunduğu kombinasyon sağladığı için 3 versiyon da eğitim verisi olarak seçilmiştir.

Tablo 1. Farklı veri seti kombinasyonları ile elde edilen sonuç tablosu

(Result table obtained with different data set combinations)

Veri Seti Kombinasyonu	Adım Sayısı	Eğitim Ortalama Zar Skoru	Doğrulama Ortalama Zar Skoru
2018	40	0,5160	0,5022
2019	40	0,4280	0,4177
2020	40	0,5986	0,4336
2018 - 2020	40	0,7763	0,7150
2018 - 2019	40	0,7814	0,7184

2019 - 2020	40	0,7824	0,7382
-------------	----	--------	--------

#### 5.1.2. Modalite dilimlerinin seçilmesi (Selection of modalities slices)

Çalışma kapsamında kullanılan BRATS veri setine ait tüm versiyonlarda her bir modalite çeşidi (240x240x155) boyutlarından oluşmaktadır. 155 adet dilimden oluşan beyin MR görüntülerine karşılık gelen segmentasyon görüntüsü incelendiğinde etiketli piksellerin büyük bir çoğunluğunu arka plan sınıfının oluşturduğu görülmüştür. Tablo 2'de segmentasyon görüntülerindeki belirli dilim aralıklarında sınıfların bulunma oranları paylaşılmıştır.

Tablo 2. Segmentasyon görüntüleri dilim aralıklarının sınıfları bulundurma oranları

(Classification rates of slice intervals in segmentation images)

Dilim	Arka Plan	Artırılmış Tümör	Tümör Çekirdeği	Tüm Tümör
0-15	1,0	0	0	0
15-30	0,99	0	0	0
30-45	0,99	0,0008	0,0021	0,0008
45-60	0,98	0,0037	0,0085	0,0036
60-75	0,97	0,0059	0,0145	0,0054
75-90	0,9705	0,0067	0,0171	0,0055
90-105	0,9758	0,0056	0,0143	0,0041
105-120	0,9876	0,0028	0,0076	0,0018
120-135	0,9968	0,0007	0,0021	0,0003
135-143	0,9998	0	0,0001	0
143-155	1,0	0	0	0

Makine öğrenmesi modellerinde dengesiz sınıf problemi modelin başarısını olumsuz yönde etkilemektedir. Dengesiz sınıf dağılımı probleminin modeller üzerindeki negatif etkisini azaltmak için yukarı örnekleme veya aşağı örnekleme yöntemi kullanılmaktadır. Segmentasyon görüntülerinde arka plan sınıfı diğer sınıflara oranla daha fazla bulunmaktadır.

Tablo 3. Orjinal veri seti ile aşağı örnekleme uygulanan veri setinin sınıf oranlarının karşılaştırılması  
(Comparison of class ratios of the original data set and the downsampled data set)

	Arka Plan Sınıfı Bulunma Oranı	Artırılmış Tümör Sınıfı Bulunma Oranı	Tümör Çekirdeği Sınıfı Bulunma Oranı	Tüm Tümör Sınıfı Bulunma Oranı
Orjinal Veri Seti	0,9888	0,0025	0,0064	0,0021
Aşağı Örnekleme Yöntemi Uygulanan Veri Seti	0,9865	0,0031	0,0078	0,0025

Tablo 3'te orjinal veri setinde arka plan sınıfının çoğunluğu oluşturduğu görülmektedir. Bu sebeple dengesiz sınıf dağılımı problemi oluşmaktadır. Tablo 2'de 0-15 arasındaki dilimlerin ve 143-155 arasındaki dilimlerin yalnızca arka plan sınıfını içerdiği görülmektedir. Arka plan sınıfının çoğunlukta olduğu dengesiz sınıf dağılımı problemini çözmek için 0-15 arasındaki tüm dilimler ve 143-155 arasındaki tüm dilimler veri setinden çıkarılarak aşağı örnekleme yöntemi uygulanmıştır. Tablo 4'te aşağı örnekleme yönteminin 10 adımlık temel u-net modeline yaptığı katkı gösterilmiştir.

Tablo 4. Orjinal veri seti ve aşağı örnekleme yöntemi uygulanmış veri setleri ile elde edilen model başarı oranları

(Model success rates obtained with the original data set and data sets with downsampling method applied)

Dilim Aralığı	Adım Sayısı	Ortalama Eğitim Zar Skoru	Ortalama Doğrulama Zar Skoru
0 - 155	10	0.6213	0.6031
15 - 143	10	0.6345	0.6341

### 5.1.3. Modalite çeşitlerinin seçilmesi (Selection of modality types)

Çalışma kapsamında kullanılan BRATS veri seti versiyonlarında Flair, T1, T1-CE ve T2 olmak üzere 4 farklı modalite çeşidi bulunmaktadır. Eğitim aşamasında hangi modalite kombinasyonunun daha iyi sonuç verdiğini tespit edebilmek için temel bir u-net modeli ile 10 adımlık testler yapılmıştır.

Tablo 5. Farklı modalite kombinasyonlarının 10 adımlık temel u-net modelinde göstermiş oldukları performans değerleri

(Performance values of different modality combinations in the 10 step basic u-net model)

Modalite Kombinasyonu	Kayıp Skoru	Ortalama Eğitim Zar Skoru
Flair	0,0039	0,3346
T1	0,0066	0,2280
T1-CE	0,0057	0,2326
T2	0,0054	0,1211
Flair, T1-CE	0,0034	0,4659
Flair, T1	0,0036	0,3750
Flair, T2	0,0039	0,3463
T1, T1-CE	0,0052	0,3302
T1, T2	0,0051	0,1861
T2, T1-CE	0,0048	0,3430
Flair, T1, T1-CE	0,0033	0,5111
Flair, T1, T2	0,0037	0,3715
Flair, T1-CE, T2	0,0033	0,4828
T1, T1-CE, T2	0,0047	0,3650
Flair, T1, T1-CE, T2	0,0031	0,5093

Tablo 5'te yapılan testler gösterilmektedir. Elde edilen sonuçlarda Flair, T1 ve T1-CE modalite kombinasyonunun hem kayıp skorunda hem de ortalama eğitim zar skorunda diğer kombinasyonlara oranla daha iyi sonuç elde ettiği görülmektedir.

### 5.1.4. Özellik ölçeklendirme (Feature scaling)

Özellik ölçeklendirme yöntemleri makine öğrenmesi çalışmalarında sıklıkla başvurulan veri ön işlemlerinden birisidir. Çalışma kapsamında farklı özellik ölçeklendirme yöntemleri ile 10 adımlık temel u-net modeli eğitilerek özellik ölçeklendirme yöntemlerinin modellere yaptığı katkılar araştırılmıştır. Tablo 6'da farklı özellik ölçeklendirme yöntemleri ile yapılan testler gösterilmektedir.



Tablo 6. Farklı ölçeklendirme yöntemleri ile yapılan test sonuçları


(Test results made with different scaling methods)

	Adım Sayısı	Ortalama Eğitim Zar Skoru	Ortalama Doğrulama Zar Skoru
Ölçeklendirme Kullanılmadan	10	0,3138	0,3120
Minimum Maksimum Ölçeklendirme	10	0,6692	0,6684
Standardizasyon	10	0,6389	0,6336


Tablo 6'da elde edilen test sonuçları neticesinde çalışma kapsamında minimum maksimum ölçeklendirme yöntemi kullanılmıştır.

### 5.1.5. Görüntü eşikleme (Image thresholding)

Çalışma kapsamında modelin başarı oranını artırmak için Sıfıra Eşikle görüntü eşikleme yöntemi uygulanmıştır. Uygulanan bu görüntü eşikleme uygulamasında bir eşik değeri belirlenmektedir. Belirlenen bu eşik değerden büyük olan piksel değerleri sabit kalırken, eşik değerden küçük olan piksel değerleri belirlenen bir değer ile yer değiştirilmektedir. Beyin MR görüntüsü segmentasyon probleminde tümörlü alana daha çok yoğunlaşabilmek için görüntü eşikleme yöntemi ile tümörlü bölgenin ön plana çıkması sağlanmıştır. Aynı zamanda farklı tümör sınıflarına ait özellik değerleri sabit bırakılarak modelin sınıf bazlı özellik değerlerini kaybetmemesi sağlanmıştır. Şekil 10'da görüntü eşikleme uygulanmadan önce ve uygulandıktan sonraki MR görüntüleri gösterilmektedir. Şekil 11'de ise görüntü eşikleme uygulandıktan sonra elde edilen MR görüntüsü ile aynı görüntüye karşılık gelen uzmanlar tarafından etiketlenerek segmentasyonu yapılmış MR görüntüsü arasındaki benzerlik gösterilmektedir.



Şekil 10. Görüntü eşikleme uygulaması sonrasında elde edilen görüntü ile orjinal görüntü arasındaki farklar (Differences between the image obtained after image thresholding application and the original image)




Şekil 11. Görüntü eşikleme uygulaması sonrası elde edilen görüntü ile segmentasyon görüntüsü arasındaki benzerlik

(Similarity between the image obtained after image thresholding application and the segmentation image)


### 5.2. Dikkat Mekanizmalı U-net Modeli (Attention U-net Model)

Çalışma kapsamında kullanılan veri seti toplamda 4 sınıftan oluşmaktadır. Sınıflardan biri arka planı ifade ederken diğer 3 sınıf tümör çeşitlerini ifade etmektedir. Eğitilen modelin başarısını test etmek için 4 sınıfın zar skorlarının ortalamasına ek olarak 3 sınıf (nekrotik, ödem, artırılmış) ayrıca incelenmiştir. Ek olarak modelin başarısını test etmek amacıyla literatürde farklı sınıf kümelerini temsil etmek için kullanılan TT, ÇT ve AT kümeleri de kullanılmıştır. TT kümesi artırılmış, ödem ve nekrotik sınıflarını, ÇT kümesi artırılmış ve nekrotik sınıflarını, AT kümesi ise artırılmış sınıfını içermektedir. Model eğitim aşamasında kullanılan kategorik çapraz entropi kayıp skoru da model performansını ölçmek için kullanılmıştır. 100 devir sonunda %87,33 eğitim ortalama zar skoruna ulaşılırken %82,73 doğrulama ortalama zar skoruna ulaşılmıştır. Test veri seti ile yapılan testlerde nekrotik, ödem ve artırılmış sınıfları için sırasıyla %69,56, %86,58 ve %72,83 zar skoru elde edilirken, arka plan sınıfı için ise % 99,93 zar skoru elde edilmiştir. Ek olarak TT, ÇT ve AT sınıf kümeleri için sırasıyla, %76,32, %71,19, %72,83 zar skoru elde edilmiştir. Şekil 12'de 100 devir sonunda eğitim ortalama zar skoru ve doğrulama ortalama zar skoru için elde edilen grafik gösterilmektedir.




Şekil 12. Dikkat mekanizmalı u-net modeli eğitim ve doğrulama ortalama zar skoru (Training and validation of u-net model with attention mechanism average dice score)

Şekil 13'te ödem sınıfının 100 devirlik zar skoru performansı gösterilmektedir. 100 devir sonunda %91,40 eğitim ödem sınıfı zar skoru ve %85,94 doğrulama ödem sınıfı zar skoru elde edilmiştir.




Şekil 13. Dikkat mekanizmalı u-net modeli eğitim ve doğrulama ödem sınıfı zar skoru  
(Training and validation of u-net model with attention mechanism edema class dice score)

Şekil 14'te artırılmış sınıfının 100 devirlik zar skoru performansı gösterilmektedir. 100 devir sonunda %77,65 eğitim artırılmış sınıfı zar skoru ve %71,20 doğrulama artırılmış sınıfı zar skoru elde edilmiştir.




Şekil 14. Dikkat mekanizmalı u-net modeli eğitim ve doğrulama artırılmış sınıfı zar skoru  
(Training and validation of u-net model with attention mechanism enhancing class dice score)

Şekil 15'te nekrotik sınıfının 100 devirlik zar skoru performansı gösterilmektedir. 100 devir sonunda %80,29 eğitim nekrotik sınıfı zar skoru ve %73,83 doğrulama nekrotik sınıfı zar skoru elde edilmiştir.



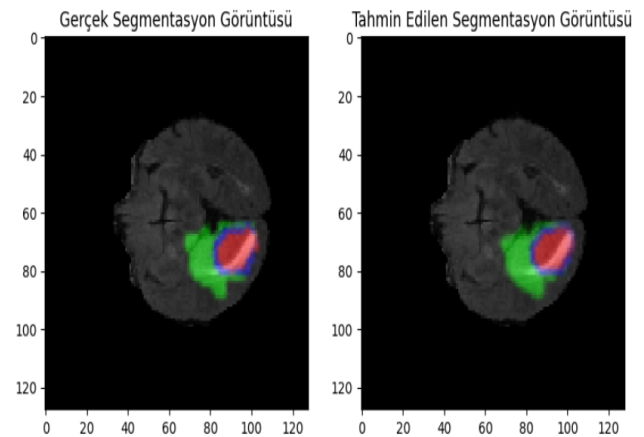
Şekil 15. Dikkat mekanizmalı u-net modeli eğitim ve doğrulama nekrotik sınıfı zar skoru  
(Training and validation of u-net model with attention mechanism necrotic class dice score)

Şekil 16'da dikkat mekanizmalı u-net modelinin 100 devir sonundaki kategorik çapraz entropi kayıp skoru performansı gösterilmektedir. 100 devir sonunda 0,0061 eğitim kayıp skoru ve 0,0137 doğrulama kayıp skoru elde edilmiştir.



Şekil 16. Dikkat mekanizmalı u-net modeli eğitim ve doğrulama kayıp skoru  
(Training and validation of u-net model with attention mechanism loss score)

Şekil 17'de örnek bir test verisinin rastgele bir dilimi seçilerek bu dilim üzerindeki gerçek segmentasyon görüntüsü ile tahmin edilen segmentasyon görüntüsü paylaşılmaktadır.

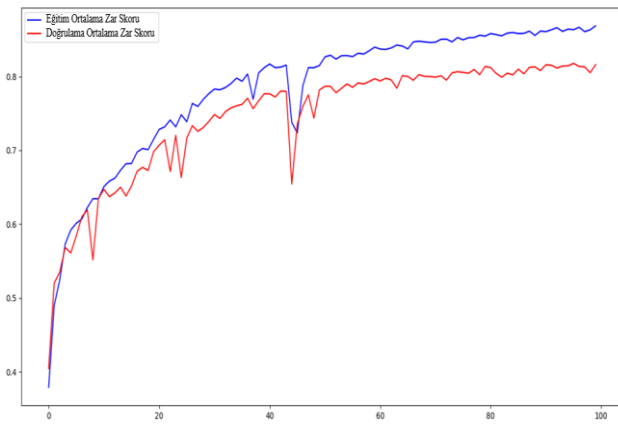


Şekil 17. Dikkat mekanizmalı u-net modeli tahmin edilen segmentasyon görüntüsü ile gerçek segmentasyon görüntüsünün karşılaştırılması  
(Comparison of the u-net model predicted segmentation image with attention mechanism and the actual segmentation image)

Dikkat mekanizmalı u-net modelinin eğitim ve doğrulama sonuçlarına ait grafikler incelendiğinde doğrulama sonuçlarının eğitim sonuçlarından bir miktar geride kaldığı görülmektedir. Dengesiz sınıf dağılımı problemi mevcut veri setinde tam anlamıyla çözülemediği için model arka plan sınıfına daha fazla ağırlık vermektedir. Bu sebeple de modelin doğrulama sonuçları eğitim sonuçlarına oranla bir miktar geride kalmaktadır fakat Şekil 12 ve Şekil 17 incelendiğinde modelin test verisi ile yaptığı tahminin gerçek değerler ile benzer olduğu görülmektedir. Dikkat mekanizmalı u-net modeli test verisi üzerinde başarılı bir performans göstermektedir, ezberleme problemi oluşmamaktadır.


### 5.3. U-net Modeli (U-net Model)

Modelin başarısını test etmek amacıyla sırasıyla ortalama zar skoru, artırılmış sınıfı zar skoru, ödem sınıfı zar skoru ve nekrotik sınıfı zar skoru kullanılmıştır. Ek olarak model eğitim aşamasında kategorik çapraz entropi kayıp skoru kullanılmıştır. 100 devir sonunda %86,32 eğitim ortalama zar skoruna ulaşılırken %81,61 doğrulama ortalama zar skoruna ulaşılmıştır. Test veri seti ile yapılan testlerde nekrotik, ödem ve artırılmış sınıfları için sırasıyla %70,24, %84,26 ve %66,03 zar skoru elde edilirken arka plan sınıfı için %99,92 zar skoru elde edilmiştir. TT, ÇT ve AT sınıf kümeleri için sırasıyla, %73,51, %68,13, %66,03 zar skoru elde edilmiştir. Şekil 18’de 100 devir sonunda eğitim ortalama zar skoru ve doğrulama ortalama zar skoru için elde edilen grafik gösterilmektedir.




Şekil 18. U-net modeli eğitim ve doğrulama ortalama zar skoru  
(Training and validation of u-net model average dice score)

Şekil 19’da ödem sınıfının 100 devirlik zar skoru performansı gösterilmektedir. 100 devir sonunda %91,01 eğitim ödem sınıfı zar skoru ve %85,52 doğrulama ödem sınıfı zar skoru elde edilmiştir.




Şekil 19. U-net modeli eğitim ve doğrulama ödem sınıfı zar skoru  
(Training and validation of u-net model edema class dice score)

Şekil 20’de artırılmış sınıfının 100 devirlik zar skoru performansı gösterilmektedir. 100 devir sonunda %77,22 eğitim artırılmış sınıfı zar skoru ve %68,38 doğrulama artırılmış sınıfı zar skoru elde edilmiştir.



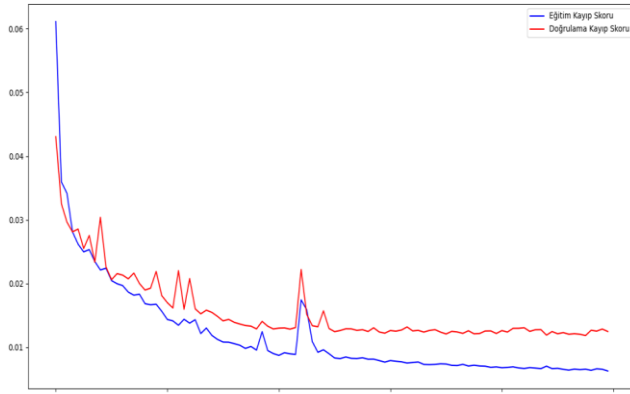
Şekil 20. U-net modeli eğitim ve doğrulama artırılmış sınıfı zar skoru  
(Training and validation of u-net model enhancing class dice score)

Şekil 21’de nekrotik sınıfının 100 devirlik zar skoru performansı gösterilmektedir. 100 devir sonunda %79,28 eğitim nekrotik sınıfı zar skoru ve %72,60 doğrulama nekrotik sınıfı zar skoru elde edilmiştir.




Şekil 21. U-net modeli eğitim ve doğrulama nekrotik sınıfı zar skoru  
(Training and validation of u-net model necrotic class dice score)

Şekil 22’de u-net modelinin 100 devir sonundaki zar kayıp skoru performansı gösterilmektedir. 100 devir sonunda 0,0063 eğitim kayıp skoru ve 0,0125 doğrulama kayıp skoru elde edilmiştir.



Şekil 22. U-net modeli eğitim ve doğrulama kayıp skoru  
(Training and validation of u-net model loss score)

Şekil 23'te örnek bir test verisinin rastgele bir dilimi seçilerek bu dilim üzerindeki gerçek segmentasyon görüntüsü ile tahmin edilen segmentasyon görüntüsü paylaşılmaktadır.




Şekil 23. U-net modeli tahmin edilen segmentasyon görüntüsü ile gerçek segmentasyon görüntüsünün karşılaştırılması

(Comparison of the u-net model predicted segmentation image and the actual segmentation image)

#### 5.4. Topluluk Öğrenimi Modeli (Ensemble Learning Model)

Şekil 24'te topluluk öğrenimi modeli ile örnek bir test verisinin bir dilimi üzerinde yapılan test gösterilmektedir. Gerçek segmentasyon görüntüsü ile topluluk öğrenimi modelinin yaptığı tahminleri içeren segmentasyon görüntüsü karşılaştırılmıştır.



Şekil 24. Topluluk öğrenimi modeli tahmin edilen segmentasyon görüntüsü ile gerçek segmentasyon görüntüsünün karşılaştırılması

(Comparison of the ensemble learning model predicted segmentation image and the actual segmentation image)

Topluluk öğrenimi modeli oluşturulurken dikkat mekanizmalı u-net ve u-net modellerinin çıktularından faydalanılmıştır. Dikkat mekanizmalı u-net ve u-net modelleri eğitilip ağırlık dosyaları kaydedildikten sonra topluluk öğrenimi modeli oluşturulurken kullanılmıştır ve test aşamasında BRATS2017 veri seti ile testler yapılmıştır. Yapılan testlerde topluluk öğrenimi modeli ile ortalama zar skoru, arka plan sınıfı zar skoru, nekrotik sınıfı zar skoru, ödem sınıfı zar skoru ve artırılmış sınıfı zar skoru için sırasıyla %87,33, %99,96, %81,74, %91,57, %76,03 zar skoru elde edilmiştir. Ek olarak TT, ÇT ve AT sınıf kümeleri için sırasıyla %83,11, %78,88, %76,03 zar skoru elde edilmiştir. Kayıp skoru olarak ise 0,0063 elde edilmiştir.

Tablo 7, dikkat mekanizmalı u-net ve u-net modellerine ait eğitim skorlarını içermektedir. Aynı veri seti ile eğitilen iki modelin eğitim aşamasındaki elde ettiği skorlar kıyaslandığında dikkat mekanizmalı u-net modelinin u-net modelinden daha iyi sonuçlar verdiği görülmektedir. İki model nekrotik, artırılmış ve ödem tümör sınıfları bazında incelendiğinde en büyük fark 0,1496 ile nekrotik sınıfı zar skorunda, en küçük fark ise 0,0665 ile ödem sınıfı zar skorunda elde edilmiştir.

Tablo 7. Dikkat mekanizmalı u-net ve u-net modellerine ait eğitim skorları

(Training scores of u-net and u-net models with attention mechanism)

	Dikkat mekanizmalı u-net	U-net
Eğitim Ortalama Zar Skoru	0,8733	0,8687
Eğitim Arka Plan Sınıfı Zar Skoru	0,9996	0,9996

Eğitim Nekrotik Sınıfı Zar Skoru	0,8029	0,7928
Eğitim Ödem Sınıfı Zar Skoru	0,9140	0,9101
Eğitim Artırılmış Sınıfı Zar Skoru	0,7765	0,7722
Eğitim TT Skoru	0,8311	0,8250
Eğitim ÇT Skoru	0,7897	0,7825
Eğitim AT Skoru	0,7765	0,7722
Eğitim Kayıp Skoru	0,0061	0,0063

Tablo 8, dikkat mekanizmalı u-net ve u-net modellerine ait doğrulama skorlarını içermektedir. İki modele ait doğrulama sonuçları incelendiğinde tüm skorlarda dikkat mekanizmalı u-net modeli doğrulama sonuçlarının u-net modeli doğrulama sonuçlarına oranla daha yüksek olduğu görülmektedir. İki model nekrotik, artırılmış ve ödem tümör sınıfları bazında incelendiğinde en büyük fark 0,0282 ile artırılmış sınıfı zar skorunda, en küçük fark ise 0,0042 ile ödem sınıfı zar skorunda elde edilmiştir. Dikkat mekanizmalı u-net modeli hem eğitim skorlarında hem de doğrulama skorlarında u-net modeline göre daha iyi performans göstermiştir.

Tablo 8. Dikkat mekanizmalı u-net ve u-net modellerine ait doğrulama skorları

(Validation scores of u-net and u-net models with attention mechanism)

	Dikkat mekanizmalı u-net	U-net
Doğrulama Ortalama Zar Skoru	0,8273	0,8161
Doğrulama Arka Plan Sınıfı Zar Skoru	0,9993	0,9993
Doğrulama Nekrotik Sınıfı Zar Skoru	0,7383	0,7260
Doğrulama Ödem Sınıfı Zar Skoru	0,8594	0,8552
Doğrulama Artırılmış Sınıfı Zar Skoru	0,7120	0,6838
Doğrulama TT Skoru	0,7699	0,7550
Doğrulama ÇT Skoru	0,7251	0,7049
Doğrulama AT Skoru	0,7120	0,6838
Doğrulama Kayıp Skoru	0,0137	0,0125

Tablo 9’da dikkat mekanizmalı u-net, u-net ve topluluk öğrenimi modellerine ait test skorları paylaşılmaktadır. Test skorları incelendiğinde dikkat mekanizmalı u-net modeli nekrotik sınıfı hariç diğer tüm sınıflarda u-net modelinden daha iyi performans göstermiştir. Birbirlerine farklı sınıflar bazında üstünlük kuran iki farklı model ile oluşturulan topluluk öğrenimi modeli tüm skorlarda dikkat mekanizmalı u-net ve u-net modellerinden üstün bir performans göstermiştir. 3 model TT, ÇT ve AT sınıf kümelerine ait zar skorları bazında incelendiğinde, dikkat mekanizmalı u-net modeli, u-net modelinden belirgin bir şekilde daha iyi performans gösterirken, topluluk öğrenimi modeli yüksek bir farkla iki modelden de daha iyi bir performans göstermiştir.

Tablo 9. Dikkat mekanizmalı u-net, u-net ve topluluk öğrenimi modellerine ait test skorları

(Test scores of u-net and u-net models with attention mechanism)

	Dikkat mekanizmalı u-net	U-net	Topluluk Öğrenimi Modeli
Test Ortalama Zar Skoru	0,8222	0,8011	0,8733
Test Arka Plan Sınıfı Zar Skoru	0,9993	0,9992	0,9996
Test Nekrotik Sınıfı Zar Skoru	0,6956	0,7024	0,8174
Test Ödem Sınıfı Zar Skoru	0,8658	0,8426	0,9157
Test Artırılmış Sınıfı Zar Skoru	0,7283	0,6603	0,7603
Test TT Skoru	0,7632	0,7351	0,8311
Test ÇT Skoru	0,7119	0,6813	0,7888
Test AT Skoru	0,7283	0,6603	0,7603
Test Kayıp Skoru	0,0144	0,0147	0,0063

Tablo 10’da literatürde gerçekleştirilen çalışmaların sonuçları ile önerilen modelin sonuçları paylaşılmaktadır. Önerilen topluluk öğrenimi modeli ile literatürde gerçekleştirilen çalışmalar karşılaştırıldığında önerilen modelin sonuçlarının literatürde gerçekleştirilen bazı çalışmaların sonuçlarını yakaladığı görülürken bazı çalışmalar ise daha üstün performans göstermektedir. Literatürde gerçekleştirilen çalışmalar TT sınıfında önerilen modelden genel olarak daha iyi performans gösterirken ÇT ve AT sınıflarında önerilen model

literatürdeki bazı çalışmalardan daha üstün performans göstermektedir. Bu durum gerçekleştirilen çalışmanın literatürdeki sonuçları destekler nitelikte olduğunu göstermektedir.

Tablo 10. Literatürde gerçekleştirilen çalışmaların sonuçları ve önerilen model ile elde edilen sonuç (The results of the studies carried out in the literature and the result obtained with the proposed model)

	BRATS Veri Seti Versiyonu	TT	ÇT	AT
Tam Evrişimli Ağ [34]	2017	0,8760	0,7630	0,6420
Kademeli Anizotropik Evrişimsel Sinir Ağı [35]	2017	0,9050	0,8378	0,7859
Çift Akış Kod Çözmeli U-net [2]	2018	0,8986	0,8388	0,7837
Çapraz Modaliteli Derin Özellik Öğrenme Çerçevesi [10]	2017	0,8900	0,8230	0,7620
Ortak Öğrenmeye Dayalı Özellik Yeniden Yapılandırma ve Geliştirme Yöntemi [1]	2018	0,8628	0,7702	0,5964
Derin Evrişimsel Sinir Ağları [15]	2018	0,9000	0,8300	0,8300
Ardışık 3D U-net [36]	2017	0,8820	0,7320	0,7300
Süper Özellik Metrik U-net [23]	2019	0,8304	0,7625	0,8048
Geliştirilmiş Özellikli Nesil ve Çok Modlu Füzyon Tabanlı Derin Sinir Ağı [26]	2018	0,8290	0,7490	0,5910
Kanallar Arası Dikkat Mekanizmalı Kalıntı U-net [27]	2017	0,8720	0,7960	0,7810
Önerilen Model	2017	0,8311	0,7888	0,7603

## 6. SONUÇ

Bu çalışmada, derin öğrenme yöntemlerinin performansını değerlendirmek amacıyla çeşitli testler yapılmıştır. Gerçekleştirilen çalışmada BRATS veri setinin 2018, 2019 ve 2020 versiyonları eğitim aşamasında, 2017 versiyonu ise test aşamasında kullanılmıştır. Çalışma kapsamında aşağı örnekleme, özellik ölçeklendirme ve görüntü işleme gibi veri ön işleme yöntemleri uygulanmıştır. Eğitim aşamasında kullanılacak veri setine karar vermek için

temel bir u-net modeli üzerinde veri seti versiyonlarının tüm kombinasyonları ile testler yapılmıştır. Modalite dilimleri seçilirken dengesiz sınıf dağılımı gözetilerek örnekler içerisinde fazla sayıda bulunan sınıfı azaltacak şekilde aşağı örnekleme yöntemi uygulanmıştır. Modalite grubu seçilirken modalite türlerinin tüm kombinasyonları ile temel u-net modeli kullanılarak testler yapılmıştır. Veri seti içerisindeki farklı örneklerin birbirine üstünlük kurmasını engellemek için minimum-maksimum özellik ölçeklendirme yöntemi kullanılmıştır. Sıfıra Eşikle görüntü eşikleme yöntemi ile beyin MR görüntülerindeki tümör içeren bölgelerin daha fazla görünür olması sağlanmıştır. Veri seti üzerindeki ön işlemler tamamlandıktan sonra dikkat mekanizmalı u-net, u-net ve topluluk öğrenimi modelleri oluşturulmuştur. Dikkat Mekanizmalı u-net ve u-net modelleri eğitilirken BRATS veri setinin 2018, 2019 ve 2020 versiyonları kullanılmıştır. Eğitilen dikkat mekanizmalı u-net ve u-net modellerinin ağırlıkları ile topluluk öğrenimi modeli oluşturulmuştur. Önerilen topluluk öğrenimi modeli ile eğitilen iki modelin her bir sınıf için yaptığı tahmin olasılık değerlerinin ortalaması alınmıştır. Eğitilen modeller ve topluluk öğrenimi modellerinin başarıları veri kümesi üzerinde test edilmiştir. Dikkat mekanizmalı u-net, u-net ve topluluk öğrenimi modelleri ile test veri kümesi üzerinde sırasıyla %82,22, %80,11 ve %86,87 ortalama zar skoru oranı elde edilmiştir. Ayrıca dikkat mekanizmalı u-net modeli ile test veri seti üzerinde TT, ÇT ve AT sınıf kümelerinde sırasıyla %76,32, %71,19, %72,83 zar skoru, u-net modeli ile test veri seti üzerinde TT, ÇT ve AT sınıf kümelerinde sırasıyla %73,51, %68,13, %66,03 zar skoru ve son olarak topluluk öğrenimi modeli ile test veri seti üzerinde TT, ÇT ve AT sınıf kümelerinde sırasıyla %83,11, %78,88, %76,03 zar skoru elde edilmiştir. Literatür çalışmalarından farklı olarak modeller eğitilirken veri setinin 2018, 2019 ve 2020 versiyonları kullanılırken test aşamasında modellerin daha önce hiç görmediği 2017 versiyonu ile testler yapılmıştır ve farklı görüntü işleme teknikleri ile modelin daha kararlı ve doğru çalışması sağlanmıştır. Önerilen yöntemin dezavantajı arka plan sınıfının oluşturduğu dengesiz sınıf dağılımı probleminin üstesinden yeteri kadar gelememesi ve arka plan sınıfına daha fazla yoğunlaşmasıdır. Gelecekteki araştırmalarda dengesiz veri seti dağılımı problemini çözmek için yeni yöntemlerin nasıl kullanılması gerektiği konusu araştırılacaktır, ayrıca önerilen topluluk öğrenimi modelinin daha fazla eğitilmiş model ile beslenmesi amaçlanmaktadır.

## KAYNAKLAR

- [1] Diao, Y., Li, F., Li, Z. (2023). Joint learning-based feature reconstruction and enhanced network for incomplete multi-modal brain tumor segmentation. *Computers in Biology and Medicine*, 163, 107234.
- [2] Jiang, M., Zhai, F., Kong, J. (2021). A novel deep learning model DDU-net using edge features to enhance brain tumor segmentation on MR images, *Artificial Intelligence in Medicine*, 121, 102180.

- [3] Zhou, T. (2023). Feature fusion and latent feature learning guided brain tumor segmentation and missing modality recovery network. *Pattern Recognition*, 141, 109665.
- [4] Zhao, X., Wu, Y., Song, G., Li, Z., Zhang, Y., Fan, Y. (2018). A deep learning model integrating FCNNs and CRFs for brain tumor segmentation. *Medical Image Analysis*, 43, 98-111.
- [5] Zhang, G., Zhou, J., He, G. and Zhu, H. (2023). Deep fusion of multi-modal features for brain tumor image segmentation. *Heliyon*, 9 (8).
- [6] Huang, J., Shlobin, N. A., Lam, S. K. and DeCuypere, M. (2022). Artificial Intelligence Applications in Pediatric Brain Tumor Imaging: A Systematic Review. *World Neurosurgery*, 157, 99-105.
- [7] Wang, P. and Chung, A. C. S. (2022). Relax and focus on brain tumor segmentation. *Medical Image Analysis*, 75 (102259).
- [8] Gocer, E. (2020). CapsNet topology to classify tumours from brain images and comparative evaluation. *IET Image Processing*, 14, 882-889.
- [9] Alzahrani, S. M. (2023). ConvAttenMixer: Brain Tumor Detection and Type Classification using Convolutional Mixer with External and Self-Attention Mechanisms. *Journal of King Saud University - Computer and Information Sciences*, 35 (10).
- [10] Zhang, D., Huang, G., Zhang, Q., Han, J., Han, J. and Yu, Y. (2021). Cross-modality deep feature learning for brain tumor segmentation. *Pattern Recognition*, 110 (107562).
- [11] Naser, M. A. and Deen, M. J. (2020). Brain tumor segmentation and grading of lowergrade glioma using deep learning in MRI images. *Computers in Biology and Medicine*, 121 (103758).
- [12] Rammurthy, D. and Mahesh, P. K. (2022). Whale Harris hawks optimization based deep learning classifier for brain tumor detection using MRI images. *Journal of King Saud University - Computer and Information Sciences*, 34, 3259-3272.
- [13] Hashemzahi, R., Mahdavi, S. J. S., Kheirabadi, M. and Kamel, S. R. (2020). Detection of brain tumors from MRI images base on deep learning using hybrid model CNN and NADE. *Biocybernetics and Biomedical Engineering*, 40, 1225-1232. 58
- [14] Nalepa, J., Lorenzo, P. R., Marcinkiewicz, M., Billewicz, B. B., Wawrzyniak, P., Walczak, M., Kawulok, M., Dudzik, W., Kotowski, K., Burda, I., Machura, B., Mrukwa, G., Ulrych, P. and Hayball, M. P. (2020). Fully-automated deep learning-powered system for DCE-MRI analysis of brain tumors. *Artificial Intelligence in Medicine*, 102 (101769).
- [15] Naceur, M. B., Akil, M., Saouli, R. and Kachouri, R. (2020). Fully automatic brain tumor segmentation with deep learning-based selective attention using overlapping patches and multi-class weighted cross-entropy. *Medical Image Analysis*, 63 (101692).
- [16] Deepak, S. and Ameer, P. M. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in Biology and Medicine*, 111 (103345).
- [17] Maharjan, S., Alsadoon, A., Prasad, P. W. C., Al-Dalain, T. and Alsadoon, O. H. (2020). A novel enhanced softmax loss function for brain tumour detection using deep learning. *Journal of Neuroscience Methods*, 330 (108520).
- [18] Saba, T., Mohamed, A. S., El-Affendi, M., Amin, J. and Sharif, M. (2020). Brain tumor detection using fusion of hand crafted and deep learning features. *Cognitive Systems Research*, 59, 221-230.
- [19] Mittal, M., Goyal, L. M., Kaur, S., Kaur, I., Verma, A. and Hemanth, D. J. (2019). Deep learning based enhanced tumor segmentation approach for MR brain images. *Applied Soft Computing*, 78, 346-354.
- [20] Yang, T., Song, J. and Li, L. (2019). A deep learning model integrating SK-TPCNN and random forests for brain tumor segmentation in MRI. *Biocybernetics and Biomedical Engineering*, 39, 613-623.
- [21] Mehrotra, R., Ansari, M. A., Agrawal, R. and Anand, R. S. (2020). A Transfer Learning approach for AI-based classification of brain tumors. *Machine Learning with Applications*, 2 (100003).
- [22] Xu, W., Yang, H., Zhang, M., Cao, Z., Pan, X. and Liu, W. (2022). Brain tumor segmentation with corner attention and high-dimensional perceptual loss. *Biomedical Signal Processing and Control*, 73 (103438).
- [23] Liu, Y., Du, J., Vong, C., Yue, G., Yu, J., Wang, Y., Lei, B. and Wang, T. (2022). Scaleadaptive super-feature based MetricUNet for brain tumor segmentation. *Biomedical Signal Processing and Control*, 73 (103442).
- [24] Draï, M., Testud, B., Brun, G., Hak, J. F., Scavarda, D., Girard, N. and Stellman, J. P. (2022). Borrowing strength from adults: Transferability of AI algorithms for paediatric brain and tumour segmentation. *European Journal of Radiology*, 151 (110291).
- [25] Bidkar, P. S., Kumar, R. and Ghosh, A. (2022). SegNet and Salp Water Optimizationdriven Deep Belief Network for Segmentation and Classification of Brain Tumor. *Gene Expression Patterns*, 45 (119248).
- [26] Zhou, T., Canu, S., Vera, P. and Ruan, S. (2021). Feature-enhanced generation and multimodality fusion based deep neural network for brain tumor segmentation with missing MR modalities. *Neurocomputing*, 466, 102-112. 59
- [27] Huang, Z., Zhao, Y., Liu, Y. and Song, G. (2021). GCAUNet: A group cross-channel attention residual UNet for slice based brain tumor segmentation. *Biomedical Signal Processing and Control*, 70 (102958).
- [28] Cinar, N., Ozcan, A. and Kaya, M. (2022). A hybrid DenseNet121-UNet model for brain tumor segmentation from MR Images. *Biomedical Signal Processing and Control*, 76 (103647).
- [29] Mazumdar, I. and Mukherjee, J. (2022). Fully automatic MRI brain tumor segmentation using efficient spatial attention convolutional networks with composite loss. *Neurocomputing*, 500, 243-254.
- [30] Zhou, T., Zhu, S. (2023). Uncertainty quantification and attention-aware fusion guided multi-modal MR brain tumor segmentation. *Computers in Biology and Medicine*, 163, 107142.
- [31] Hu, J., Gu, X., Wang, Z., Gu, X. (2023). Active consistency network for multi-source domain generalization in brain tumor segmentation. *Biomedical Signal Processing and Control*, 86, 105132.

- [32] Akbar, A. S., Fatichah, C., Suciati, N. (2022). Single level UNet3D with multipath residual attention block for brain tumor segmentation. *Journal of King Saud University - Computer and Information Sciences*, 34, 3247-3258.
- [33] Taşdemir, B., Barışçı, N. (2023). Dynamic Image Scaling for Imbalanced Brain MRI Dataset. International Conference on Global Practice of Multidisciplinary Scientific Studies-IV Turkish Republic of Northern Cyprus, 2710-2719.
- [34] Li, H., Li, A., Wang, M. (2019). A novel end-to-end brain tumor segmentation method using improved fully convolutional networks. *Computers in Biology and Medicine*, 108, 150-160.
- [35] Wang, G., Li, W., Ourselin, S. (2018). Automatic Brain Tumor Segmentation using Cascaded Anisotropic Convolutional Neural Networks. International MICCAI Brainlesion Workshop, 178-190.
- [36] Beers, A., Chang, K., Brown, J. (2017). Sequential 3D U-Nets for Biologically-Informed Brain Tumor Segmentation. arXiv:1709.02967.
- [37] Hu, J., Gu, X., Wang, Z. and Gu, X. (2023). Active consistency network for multi-source domain generalization in brain tumor segmentation. *Biomedical Signal Processing and Control*, 86 (105132).
- [38] Akbar, A. S., Fatichah, C. and Suciati, N. (2022). Single level UNet3D with multipath residual attention block for brain tumor segmentation. *Journal of King Saud University - Computer and Information Sciences*, 34, 3247-3258.
- [39] Taşdemir, B. and Barışçı, N. (2023). Dynamic Image Scaling for Imbalanced Brain MRI Dataset. International Conference on Global Practice of Multidisciplinary Scientific Studies-IV Turkish Republic of Northern Cyprus, 2710-2719.