



---

## Makale / Research Paper

---

### Evrişimli Sinir Ağları ile Beyin Tümörü Segmentasyonu

Emin GÖKÇE<sup>1a\*</sup>, Mehmet Fatih DEMİRAL<sup>2b</sup>, Ali Hakan IŞIK<sup>2c</sup>  
Mehmet BİLEN<sup>2d</sup>

<sup>1</sup> Burdur Mehmet Akif Ersoy Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği ABD, Burdur

<sup>2</sup> Burdur Mehmet Akif Ersoy Üniversitesi, Mühendislik Mimarlık Fakültesi, Burdur

\* emin.gokce@icisleri.gov.tr

Received/Geliş: 06.07.2022

Accepted/Kabul: 07.11.2022

**Öz:** Beyin tümörleri kafatası içinde anormal hücre ve kitle büyümesinin genel adıdır. Beyin tümörü tanısı konulabilmesi için en yaygın tetkik beyin dokusu ve dokudaki yabancı kitleleri gösteren MR (manyetik rezonans) görüntüleme tekniğinin kullanılmasıdır. Tanı konduktan sonra hızlıca tedavi süreci planlamalıdır. MR görüntüleri çekildikten sonra uzman radyologlar tarafından görüntülerin incelenerek raporlanması zaman alabilmektedir. Son yıllarda hızla gelişen derin öğrenme teknolojileri ile tıp alanında bulunan yenilikler sayesinde hastalıkların erken ve doğru teşhis edilmesi için çeşitli çalışmalar yapılmaktadır. İnsan kaynaklı hataların en aza indirilmesi bu çalışmalar içerisinde önemli bir yere sahiptir. Bu çalışmada MRI görüntülerinin işaretlenerek uzmanlara yardımcı olması için yapay zekâ tekniklerinden yararlanılarak yeni bir evrişimli sinir ağı modeli eğitilmiştir. Eğitim aşamasında U-Net modelinden yararlanılarak, Brats19 veri kümesinin %80'i kullanılmıştır. Veri kümesi içerisindeki örneklerin %20'si modelin performansının değerlendirilmesi için kullanılmıştır. Eğitim ve test işlemleri sonucunda elde edilen bulgular incelendiğinde eğitilen modelin tüm tümör, tümör çekirdeği ve genişleyen tümör bölgelerini sırayla 0.908, 0.807 ve 0.877 benzerlik oranı (Dice Coefficient) ile başarılı bir şekilde işaretlemeyebildiği görülmektedir.

**Anahtar Kelimeler:** U-Net, MRI, Beyin Tümörü, Segmentasyon, Evrişimli Sinir Ağı

## Brain Tumor Segmentation with Convolutional Neural Networks

**Abstract:** Brain tumors are the general name for abnormal cell and mass growth within the skull. In order to diagnose a brain tumor, the most common examination is the use of MR (magnetic resonance) imaging technique, which shows brain tissue and foreign masses in the tissue. After the diagnosis, he should quickly plan a course of treatment. After MR images are taken, it may take time for the images to be examined and reported by specialist radiologists. Thanks to the rapidly developing deep learning technologies and innovations in the field of medicine in recent years, various studies are being conducted to diagnose diseases early and accurately. Minimizing human-caused errors has an important place in these studies. In this study, a new convolutional neural network model was trained by using artificial intelligence techniques to help specialists by marking MR images. Using the U-Net model at the training stage, 80% of the Brats19 dataset was used. 20% of the samples in the data set were used to evaluate the performance of the model. When the findings obtained as a result of the training and testing procedures are examined, it is seen that the trained model may not successfully mark all tumors, tumor nuclei and expanding tumor regions with a similarity ratio (Dice Coefficient) of 0.908, 0.807 and 0.877 respectively.

**Keywords:** U-Net, MRI, Brain Tumor, Segmantation, Convolutional Nueral Network

### *How to cite this article*

Gökçe E., Demiral M.F., Işık A.H., Bilen M., "Brain Tumor Segmentation with Convolutional Neural Networks", El-Cezeri Journal of Science and Engineering, 2022, 9 (4); 1518-1528.

### *Bu makaleye atıf yapmak için*

Gökçe E., Demiral M.F., Işık A.H., Bilen M., "Evrişimli Sinir Ağları ile Beyin Tümörü Segmentasyonu", El-Cezeri Fen ve Mühendislik Dergisi, 2022, 9(4); 1518-1528.

ORCID: <sup>a</sup>0000-0001-6690-6516; <sup>b</sup>0000-0003-0742-0633; <sup>c</sup>0000-0003-3561-9375; <sup>d</sup>0000-0002-6016-2349

## 1. Giriş

Kanser vücuttaki hücrelerin kontrolsüz, doğal olmayan bir şekilde büyümesi ve bölünmesi olarak tanımlanabilir. Beyin dokusunda meydana gelen ve doğal olmayan hücre büyümesi ve bölünmesiyle oluşan kitlelere beyin tümörü denir. Beyin tümörleri her ne kadar çok yaygın olmasa bile, en ölümcül kanserlerden biridir [1]. Beyin tümörleri başlangıç noktalarına bağlı olarak birincil (primer) ve metastatik beyin tümörleri olarak ikiye ayrılır. Birincil tümörlerin kaynağı beyin dokusu hücreleridir. Metastatik tümörlerde ise kanser vücudun herhangi bir yerinde oluşup; beyne yayılmıştır. Birincil beyin tümörü kötü huylu (kanseri) veya iyi huylu (kanseri olmayan) olabilir. Gliomalar, birincil beyin tümörlerinin en yaygın türüdür. Gliomalar yetişkinlerde birincil beyin tümörlerinin dörtte üçünü oluştururlar [2].

Düşük dereceli gliomlarda (Low Grade Glioma, LGG) büyüme hızı nispeten yavaştır, düşük dereceli bir kötü huylu tümör çeşididir ve hastalığın iyileşme öngörüsü daha iyidir. Yüksek dereceli gliomlarda (High Grade Glioma, HGG) büyüme hızlıdır, hastalığın iyileşme öngörüsü zayıf olup; teşhis konulduktan sonra sağkalım ise ortalama 15 aydır [3].

Son yıllarda tıbbi görüntülerin analizinde derin öğrenme yöntemleri klasik segmentasyon yöntemlerinden daha iyi performans gösterdiği için giderek daha fazla kullanılmaktadır. Kullanılan derin öğrenme yöntemleri içerisinde evrişimli sinir ağları en başarılı performans değerleri elde eden modellerin başında gelmektedir. Görüntü analizi için kullanılan popüler evrişimli sinir ağları AlexNet, VGG, ResNet ve U-net'dir. U-net tıbbi görüntü segmentasyonunda elde ettiği başarılar sonucunda literatürde evrişimli sinir ağı eğitimi gerçekleştirilirken sıklıkla tercih edilen bir yöntem haline gelmiştir [4].

Bu çalışmada; evrişimli sinir ağı modeli U-Net modeli kullanarak toplam 335 yüksek ve düşük dereceli MR görüntüsünden oluşan Brats19 veri seti üzerinde tam tümör segmentasyonu için ağı eğitimi ve test işlemleri gerçekleştirilerek elde edilen bulgular raporlanmıştır. Makalenin ikinci bölümü olan Literatür Özeti'nde bu çalışma kapsamında yapılan yayınlar bulunmaktadır, üçüncü bölüm olan Materyal ve Metot kısmında geliştirilen ağı model ve veri kümesi verilmiştir. Bir sonraki başlıkta eğitilen ve test işlemleri gerçekleştirilen ağı elde etmiş olduğu performans değerleri detaylı bir şekilde sunularak yorumlanmıştır. Son bölümünde ise genel bir değerlendirme yapılarak sonuçlar ve öneriler verilmiştir.

## 2. Literatür Özeti

Vaanathi Sundersan vd. Brats20 veri seti üzerinde tam tümör, nekroz ve genişleyen tümör bölgelerinin tespit etmeye çalışmışlardır. U-Net modeli ile eğittikleri ağlarında tam tümörün (WT), nekroz (TC, tümör çekirdeği) ve genişleyen (ET) tümör bölgelerine ait sırasıyla 0.89, 0.84 ve 0.81 benzerlik oranı (dice coefficient) değerlerine ulaşılmıştır [5].

Jianxin Zhang vd. Brats17 veri seti üzerindeki 57 MRI taraması ve Brats18 veri seti 66 MRI taraması ile U-Net, AResU-Net modelleri ile eğitim gerçekleştirilmiş eğitim sonuçları ResU-Net, Esemble Net, 3DU-Net, TTA ve MCC modellerinin değerlendirme sonuçları ile kıyaslanmıştır [6].

Zeyu Jiang vd. Brats19 veri seti üzerinde iki basamaklı bir U-Net modeli kullanarak yaptıkları çalışmayı 405 kez eğiterek tam tümörün, nekroz ve genişleyen tümör bölgelerine ait sırasıyla 0.88796, 0.83697, ve 0.83267 benzerlik oranı değerlerine ulaşılmıştır [7].

W Chen ve arkadaşları Brats18 veri seti üzerinde 2018 yılında yaptıkları çalışmada; 3D U-Net modeli kullanarak yaptıkları çalışma ile tam tümörün, nekroz ve genişleyen tümör bölgelerine ait sırasıyla 0.89353, 0.83093 ve 0.74932 benzerlik oranı değerlerine ulaşılmıştır [8].

W Cheng ve arkadaşları Brats19 veri seti üzerinde 2019 yılında yaptıkları çalışmada; 3D U-Net modeli kullanarak yaptıkları çalışma ile tam tümörün, nekroz ve genişleyen tümör bölgelerine ait sırasıyla 0.902, 0.824 ve 0.777 benzerlik oranı değerlerine ulaşılmıştır [9].


Rehman, M.U. ve arkadaşları Brats17 ve Brats18 veri setleri üzerinde 2020 yılında yaptıkları çalışmada: BU-Net modeli ile eğittikleri ağlarında be kullanılarak performans analizi yapılmıştır [10].

Eker ve arkadaşı Brats20 veri setleri üzerinde 2021 yılında yaptıkları çalışmada; T1ce MR görüntüsü üzerinde tümörlü bölgenin 64\*64 piksel kesitini alarak eğittikleri U-Net ağlarında 0.86 dice benzerlik puanı almıştır [11].

### 3. Materyal ve Metot

#### 3.1. Materyal

Bu çalışmada Perelman Sağlık Okulu tarafından derlenen 259 yüksek dereceli glioma ve 76 düşük dereceli glioma hastasından olmak üzere 335 adet MR görüntüsü ve bu görüntülerin uzmanlar tarafından etiketlenmiş tümör görüntülerinden oluşan Brats19 isimli veri seti kullanılmıştır. Veri setinde bulunan her bir MR görüntü aksiyel, koronal ve segital olmak üzere 3 ayrı ekseninde alınarak ve NIFTI formatında kütüphane şekline getirilmiştir [12-14].




**Şekil 1.** Flair, T1, T1ce, T2 kontrastlı Beyin MRI görüntüleri ve Uzmanlar tarafından MRI görüntüleri baz alınarak yapılan Tumor segmentasyonu (mavi nekroz, yeşil ödem ve sarı genişleyen tümör)

Veri seti Flair, T1, T1 kontrastlı (T1ce) ve T2 ağırlıklı olmak üzere her hastanın multimodel MR görüntülerini içerir ayrıca, tümörün uzmanlar tarafından tanımlanarak alt bölgeleri bölümlere ayrılmış görüntüsünü içerir. Ayrıca, nöroradyologlar tarafından her eğitim verisi etiketlenerek açıklanmıştır. Beyin tümörü segmentasyonunda dört etiket olup; tümör olmayan alan 0, nevroitik ve güçlenmeyen tümör çekirdeği (Core Tumor, CT) 1, ödem (Edema, ED) 2, genişleyen tümör (Enhancing Tumor, ET) 4 olarak etiketlenmiştir. Sıfırdan farklı olarak etiketlenen bölgelere tam tümör (Whole Tumor, WT) denir. Şekil 1’de MR görüntüleri ve uzmanlar tarafından etiketlenen tümör bölgeleri gösterilmektedir.

Genellikle, Flair görüntüleri ödem bölgesini, T1 görüntüleri sağlıklı dokuları ayırt etmek için kullanırken T2 görüntüleri görüntü üzerindeki parlak sinyal üreten ödem bölgesini tanımlamak için kullanılır. T1ce görüntülerinde tümör sınırı tümör dokusunun aktif hücre bölgesinde biriken maddenin parlak sinyali ile ayırt edilebilir.

Tümörlü beyin görüntüleri uzmanlar tarafından nekroz, genişleyen tümör ve ödem olmak üzere 3 başlık altında etiketlenmiş olup bu etiketlerin birleşimi tümör bölgesini ifade etmektedir. Şekil 2’de nekroz, genişleyen ve ödem bölgeleri ile bunların birleşimi tüm tümör bölgesi gösterilmektedir.



**Şekil 2.** Tümörlü bölgeleri (Tümör Çekirdeği, Genişleyen Tümör, Ödem) ve Tüm Tümör

## 3.2. Metot

### 3.2.1. Ön İşleme Adımı

Brats19 veri kümesinin her bir MR verisi için 240\*240 piksel boyutunda 155 görüntü mevcut olup; literatürde yapılan çalışmalarda MR görüntü boyutlarının genel olarak 128\*128 piksel olarak belirlendiği ancak bir hastaya ait MR görüntü kümesinden kaç adet görüntü üzerinde çalışma yapıldığına dair veriye rastlanılmadığı görülmüştür.

Bu çalışmada kullanılan MR görüntü boyutları  $256 \times 256$  piksel boyutlarında ayarlanmış ayrıca beyin dokusu ve tümör etiketlemesinin belirgin olarak gözlemlendiği aralıktaki kısıtlı sayıda görüntü alınmıştır.


Tümör çekirdeğinin tespiti için Flair ve T1ce ağırlıklı MR görüntülerinden her bir hastaya ait 16'şar görüntü alınıp birleştirilerek 2 kanallı bir giriş değeri elde edilmiştir. Toplamda 335 hasta için 5.360 görüntü elde edilmiştir.

Genişleyen tümör ve tüm tümör bölgelerinin tespiti için T1ce ağırlıklı MR görüntülerinden her bir hastaya ait 50 görüntü alınmıştır. Tümör bölgesine odaklanılarak  $128 \times 128$  piksel boyutlarında görüntü kesitleri alınmış 335 hasta için 16.750 görüntü elde edilmiştir.

### 3.2.2. Evrişimli Sinir Ağları ve U-Net Modeli

Evrışimli sinir ağları genellikle resim, resim sınıflandırma, video tanıma, tıbbi görüntü analizi ve benzeri görsel bilginin analiz edilmesi alanında kullanılmaktadır. Standart bir evrişimli sinir ağında girdi, evrişim katmanı, aktivasyon katmanı, havuzlama katmanı, tam bağlantı katmanı ve çıktı bulunmaktadır.

Bu çalışmada; Ronneberger vd. tarafından 2015 yılında görüntülerin hızlı ve hassas bölümlere ayrılması için tasarlanan evrişimli bir ağ mimarisi olan U-Net Modeli kullanılarak vaka tahminlemeleri gerçekleştirilmiştir. Şekil 3'de U-Net Modeli gösterilmektedir.



Şekil 3. U-Net Modeli [15]

Tıbbi görüntüleme alanında yaygın olarak kullanılan derin öğrenme tabanlı yöntemlerden biri U-Net'tir. U-Net mimarisi U şeklinde simetrik bir yapıya sahip olup; sol taraf kodlayıcı görevini sağ taraf kod çözücü görevini gerçekleştirir.

### 3.2.3 Eğitim Adımı

U-Net ağının eğitimi için görüntülerin %80'i eğitim, %20 test için ayrılarak 100 kez eğitildi. Minimum kayıp farkının sabitlenmesi durumunda erken durdurma 20 iterasyondan sonra devreye girerek, eğitimden otomatik olarak çıkarılır. Eğitim için kullanılan hiperparametreler Tablo 1'de gösterilmektedir.

**Tablo 1. Eğitim Hiperparametreleri**

İsim	Değer
Giriş Boyutu (Input Size)	2*256*256
Optimizer	Adam
Learning Rate	1e-4
Batch Size	3
Eğitim Sayısı (Epoch)	100
Kayıp Fonksiyonu (Loss Function)	$L_{Dice\ loss}$

### 3.2.4 Değerlendirme Ölçütleri

Araştırmacılar tarafından görüntü segmentasyonunda performans sonuçlarını doğrularak diğer çalışmalar ile kıyaslamak için çeşitli objektif teknikler kullanılmaktadır. Bu çalışmada, performans sonuçlarını doğrulamak için değerlendirme indeksleri olarak Dice coefficient, Intersection Over Union, Presicion (Keskinlik) ve Recall(Hassasiyet) kullanılmıştır.

Dice Coefficient uzmanlar tarafından etiketlenen tümör görüntüsü ile tahmin edilen görüntü arasında piksel bazlı karşılaştırma yapar. Benzerlik artarsa sonuç 1'e azalır 0'a yaklaşır. Hesaplama formülü Denklem 1'de gösterilmektedir.

$$Dice\ Coef(X, Y) = \frac{2|X \cap Y|}{|X| + |Y|} \quad (1)$$

Intersection Over Union iki görüntünün kesiştikleri alanın aynı iki görüntünün birleşimlerinden oluşan alana bölümü ile hesaplanır. Hesaplama formülü Denklem 2'de gösterilmektedir.

$$IoU(X, Y) = \frac{|X \cap Y|}{|X \cup Y|} \quad (2)$$

Keskinlik, pozitif olarak tahmin edilen ve doğru çıkan değerlerin sayısını verir. Hesaplama formülü Denklem 3'te gösterilmekte olup, TP pozitif tahmin edilerek doğru çıkanların sayısını, FP pozitif tahmin edilerek yanlış çıkanların sayısını göstermektedir.

$$Presicion = \frac{TP}{TP + FP} \quad (3)$$

Hassasiyet gerçekte doğru örneklerin başarı bir şekilde pozitif olarak tahmin edilme oranını verir. Hesaplama formülü Denklem 4'te gösterilmekte olup, TP pozitif tahmin edilerek doğru çıkanların sayısını, FN negatif tahmin edilerek yanlış çıkanların sayısını göstermektedir.

$$Recall = \frac{TP}{TP+FN} \quad (4)$$


#### 4. Bulgular ve Tartışma

Yapılan çalışmada kullanılan model Python ile kodlanmıştır. Çalışma 64 GB RAM, i5 işlemci, 12 Gb grafik kartına sahip donanım üzerinde gerçekleştirilmiştir.

Eğitim verileri kullanılarak uzmanlar tarafından etiketlenmesi yapılarak ortaya çıkan tümör görüntüsüne modelin tahmini ile ulaşılmaya çalışılmıştır. Modelin tahmin ettiği tümör görüntüsü uzmanların etiketlemesini yaptığı görüntüler ile karşılaştırılmış ve benzerlik oranlarının ortalaması üzerinden sistem başarısı yorumlanmıştır.

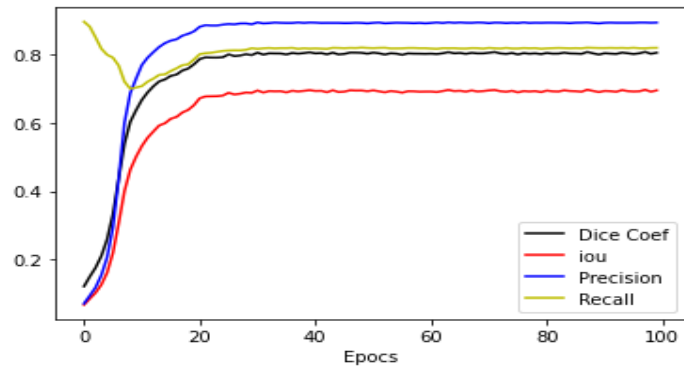
Beyin tümörlerinin en yaygın türü olan 259 yüksek dereceli 76 düşük dereceli olmak üzere toplam 335 hastaya ait glioma tümör görüntülerinin %80'inin eğitime tabi tutulmuştur. Eğitilen modelin tümör tahminlemesi ile etiketlenen tümör görüntülerini karşılaştırarak benzerlik değerleri belirlenmiştir.

Şekil 4'te 100 dönem boyunca eğitilen modelin tüm tümör bölgesi için değerlendirme indekslerinden aldığı sonuçlar gösterilmektedir.



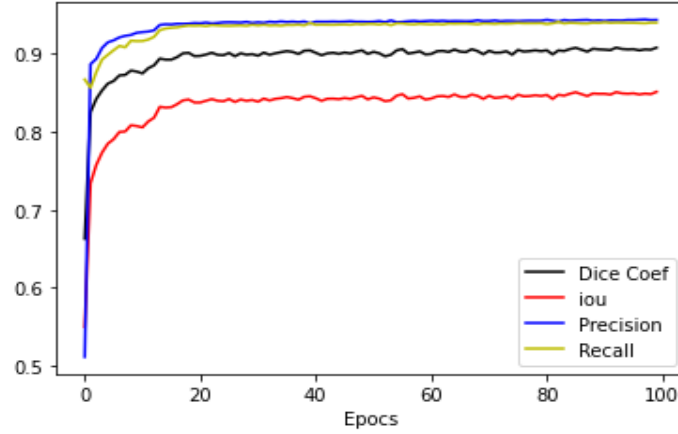
Şekil 4. Değerlendirme indekslerinin WT üzerindeki skorları

Şekil 5'de 100 dönem boyunca eğitilen modelin tümör çekirdeği bölgesi için değerlendirme indekslerinden aldığı sonuçlar gösterilmektedir.




Şekil 5. Değerlendirme indekslerinin CT üzerindeki skorları

Şekil 6’da 100 dönem boyunca eğitilen modelin genişleyen tümör bölgesi için değerlendirme indekslerinden aldığı sonuçlar gösterilmektedir.



Şekil 6. Değerlendirme indekslerinin ET üzerindeki skorları


Şekil 7’de hastaya ait Flair ağırlıklı MR görüntüsü, uzmanlar tarafından etiketlenen tümör bölgesi ve geliştirilen model tarafından tespit edilen tüm tümör bölgesi gösterilmektedir.



Şekil 7. Hastaya ait Flair görüntüsü, Uzmanlar tarafından etiketlenen WT tümör bölgesi, Modelimiz tarafından tespit edilen WT tümör bölgesi


Şekil 8’de hastaya ait T1ce ağırlıklı MR görüntü kesiti, uzmanlar tarafından etiketlenen tümör bölgesi kesiti ve geliştirilen model tarafından tespit edilen genişleyen tümör bölgesi kesiti gösterilmektedir.





**Şekil 8.** Hastaya ait T1ce görüntü kesiti, Uzmanlar tarafından etiketlenen ET tümör bölgesi, Modelimiz tarafından tahmin edilen ET tümör bölgesi

Şekil 9’de hastaya ait T1ce ağırlıklı MR görüntü kesiti, uzmanlar tarafından etiketlenen tümör bölgesi kesiti ve geliştirilen model tarafından tespit edilen tümör çekirdeği bölgesi kesiti gösterilmektedir.



**Şekil 9.** Hastaya ait T1ce görüntü kesiti, Uzmanlar tarafından etiketlenen CT bölgesi, Modelimiz tarafından tahmin edilen CT bölgesi

Literatürdeki benzer çalışmalar ve bu çalışmada elde edilen benzerlik oranları karşılaştırmalı bir şekilde Tablo 3’de sunulmuştur.

**Tablo 3.** BraTs veri seti üzerinde benzerlik skorlarının karşılaştırılması

Metot	Dice Skoru		
	WT	CT	ET
MECU-Net [9]	0.902	0.824	0.777
U-Net [5]	0.890	0.840	0.810
AresU-Net [6]	0.892	0.853	0.825
3D U-Net [8]	0.893	0.830	0.749
RD2A 3D U-Net [16]	0.903	0.844	0.781
BU-Net [10]	0.901	0.837	0.788
Two-stage cascaded U-Net [7]	0.887	0.836	0.832
MIRAU-Net [17]	0.885	0.879	0.818
ReSoU-Net [18]	0.876	0.782	0.717
U-Net [11]	0.860	-	-
<b>U-Net</b>	<b>0.908</b>	<b>0.807</b>	<b>0.877</b>

Bu çalışmada geliştirilen U-Net modeli tüm tümör, tümör çekirdeği ve genişleyen tümör üzerinde sırasıyla 0.908, 0.807 ve 0.877 Benzerlik oranı elde etmiştir. Veri setindeki görüntülerde beyin dokusu ve tümör etiketlemesi belirgin olanların eğitime alınarak modelin hafifletilmesi ve görüntü çözünürlük oranlarının diğer çalışmalara oranla yüksek tutularak daha net görüntüler üzerinde çalışılmasının başarıyı artırdığı görülmüştür.

## 5. Sonuç ve Öneriler

Beyindeki tümör bölgesinin sınırlarını belirlemeyi hedefleyen bu çalışmada U-Net modeline dayalı bir görüntü segmentasyon yöntemi önerilmiştir. Bu çalışmada MR görüntüleri 256\*256 piksel boyutlarında ayarlanıp eğitim verisindeki modelin eğitimi için beyin dokusu ve tümör etiketlemesinin belirgin olarak gözlemlendiği aralıktaki görüntüler alınarak literatürdeki çalışmalara alternatif bir yöntem önerilmiştir. Ayrıca, tümör çekirdeği ve genişleyen tümör görüntüleri ön işlem ile tümör bölgesine odaklanılmış 128\*128 piksel kesitler halinde eğitime tabi tutularak literatürdeki benzerlik oranları yakalanmıştır. Tüm tümör, tümör çekirdeği ve genişleyen tümör bölgeleri için ayrı ayrı yapılan eğitimler sonucu sırasıyla 0.908, 0.807 ve 0.877 benzerlik oranları elde edilmiştir. Geliştirilen ağı eğitimi için 2D görüntü dilimlerini kullanması uzmanlar tarafından yapılan segmentasyonun ise 3D görüntülerden faydalanarak yapması sebebiyle daha fazla benzerlik oranında düşüşe yol açmıştır. Gelecekte yapılması planlanan çalışmalarda daha başarılı segmentasyon sonuçları elde etmek için U-Net modelinin 3D verilerle çalışabilmesi için güncellenmesi planlanmaktadır. Ayrıca performans iyileştirmesi için verinin farklı görüntü işleme ve özellik çıkarma tekniklerinden yararlanması planlanmaktadır.

Bu çalışmada gerçekleştirilen çalışmanın beyin tümörü segmentasyonun otomatik olarak yapması ve ön tanıda bulunarak uzmanların değerlendirme hızı ve kalitesini artıracığı öngörülmektedir. Geliştirilen ağı şu an ki doğruluk değerleri ile uzman destek sistemi olarak uygulanması mümkün olsa da beyin tümörü teşhisinin hassas bir konu olması nedeni ile daha başarılı ve benzerlik değeri yüksek ağların geliştirilmesi ihtiyacı devam etmektedir.

## Teşekkür

Bu proje, Burdur Mehmet Akif Ersoy Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından 0786-YL-21 proje numarası ile desteklenmiştir. Bu çalışmanın ortaya çıkmasında verdiği destekten ötürü Bilimsel Araştırma Projeleri Birimine teşekkür ederiz.

## Çıkar Çatışması

Her dört yazar da makalenin son halini okudu ve onayladı.

Yazarlar, çıkar çatışması olmadığını beyan eder.

## Kaynaklar

- [1]. Işın, A., Direkoğlu, C., and Şah, M., Review of MRI-based brain tumor image segmentation using deep learning methods, *Procedia Comput. Sci.*, 2016, 317–324.
- [2]. Tüzün, E., Hanağası, F., Sabancı, P, A., Akman, Demir, G., and Yazıcı, J., Nöro-Onkoloji, <http://www.itfnoroloji.org/onkoloji/onkoloji.htm> (Son Erişim: 10.05.2022)
- [3]. Zhang, C., et al., ErbB2/HER2-Specific NK Cells for Targeted Therapy of Glioblastoma, *JNCI J. Natl. Cancer Inst.*, 2016.

- [4]. Siddique, N., Paheding, S., Elkin, C, P., and Devabhaktuni, V., U-net and its variants for medical image segmentation: A review of theory and applications, *IEEE Access*, 2021.
- [5]. Sundaresan, V., Griffanti, L., and Jenkinson, M., Brain tumour segmentation using a triplanar ensemble of U-Nets on MR images, *International MICCAI Brainlesion Workshop*, 2020, 340–353.
- [6]. Zhang, J., Lv, X., Zhang, H., and Liu, B., AResU-Net: Attention residual U-Net for brain tumor segmentation, *Symmetry*, 2020, 721.
- [7]. Jiang, Z., Ding, C., Liu, M., and Tao, D., Two-stage cascaded U-Net: 1st place solution to BraTS challenge 2019 segmentation task, *International MICCAI brainlesion workshop*, 2019, 231–241.
- [8]. Chen, W., Liu, B., Peng, S., Sun, J., and Qiao, X., S3D-UNet: Separable 3D U-Net for Brain Tumor Segmentation, *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, Cham, 2019, 358–368.
- [9]. Cheng, X., Jiang, Z., Sun, Q., and Zhang, J., Memory-efficient cascade 3D U-Net for brain tumor segmentation, *International Miccai Brainlesion Workshop*, 2019, 242–253.
- [10]. Rehman, M, U., Cho, S., Kim, J, H., and Chong, K, T., Bu-net: Brain tumor segmentation using modified u-net architecture, *Electronics*, 2020.
- [11]. Eker, A, G., and Duru, N., Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları, *Acta Infologica*, 2021.
- [12]. Menze, B, H., et al., The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS), *IEEE Trans. Med. Imaging*, 1993–2024, 2015.
- [13]. Bakas, S., et al., Advancing The Cancer Genome Atlas glioma MRI collections with expert segmentation labels and radiomic features, *Sci. Data*, 2017.
- [14]. Bakas, S., et al., Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge, *ArXiv Prepr. ArXiv181102629*, 2018.
- [15]. Ronneberger, O., Fischer, P., and Brox, T., U-Net: Convolutional Networks for Biomedical Image Segmentation, *ArXiv150504597 Cs*, May 2015, Accessed: May 01, 2021.
- [16]. Ahmad, P., Jin, H., Qamar, S., Zheng, R., and Saeed, A., RD2A: densely connected residual networks using ASPP for brain tumor segmentation, *Multimed. Tools Appl.*, 2021, 27069–27094.
- [17]. AboElenein, N, M., Piao, S., Noor, A., and Ahmed, P, N., MIRAU-Net: An improved neural network based on U-Net for gliomas segmentation, *Signal Process. Image Commun.*, 2022, 116553.
- [18]. Sheng, N., et al., Second-order ResU-Net for automatic MRI brain tumor segmentation, *Math. Biosci. Eng.*, 2021, 4943–4960.