



Sadeleştirilmiş U-Net mimarisi ile beyin tümörü segmentasyonu Brain tumor segmentation with simplified U-Net architecture

Özlem Polat^{1,*} 

¹ Sivas Cumhuriyet Üniversitesi, Mekatronik Mühendisliği Bölümü, 58140, Sivas Türkiye

Öz

Kafatası içinde yer alan beyin tümörleri ciddi sonuçlara neden olan sağlık sorunları arasındadır. Beyin tümörünün hızlı ve doğru bir şekilde tespit edilip tümör bölgesinin segmentasyonunun yapılması hastanın erken dönemde uygun tedavi almasını sağlayarak hastanın iyileşme ve hayatta kalma şansını artıracaktır. Literatürde birçok segmentasyon yöntemi bulunmaktadır. Düşük segmentasyon doğruluğu ve kullanılan ağ yapısının çok büyük olması mevcut yöntemlerin ana dezavantajıdır. Bu çalışmada beyin tümörlerinin MR görüntüleri üzerinde segmentasyonu için sadeleştirilmiş U-Net derin öğrenme modeli önerilmektedir. Model, 233 hastadan alınan ve yaygın beyin tümörlerinden gliom, menenjiom ve hipfiz tümörünü içeren 3064 MR görüntüsü üzerinde eğitilip test edilmiştir. Sonuç olarak ortalama 0.86 dice benzerlik katsayısı, 0.76 IoU skoru, 0.85 hassasiyet değeri ve 0.99 piksel doğruluk değeri elde edilmiştir. Önerilen model beyin tümörü segmentasyonunu hızlı ve yüksek doğrulukla gerçekleştirdiğinden hastalığın tanısında ve uygun tedavinin belirlenmesinde uzmanlara yardımcı olması açısından umut vaat etmektedir.

Anahtar kelimeler: Beyin tümörü, Segmentasyon, Derin öğrenme, U-Net

1 Giriş

Beyin insan vücudundaki en önemli ve karmaşık organlardan biridir ve milyarlarca hücre ile çalışır. Beyin tümörü, beyin içindeki veya çevresindeki anormal hücre gruplarının kontrolsüz bölünmesi ve çoğalmasından kaynaklanır. Bu hücre grubu, beyin aktivitesinin işlevselliğini etkileyebilir ve sağlıklı hücreleri yok edebilir [1]. Beyin tümörleri temel olarak iyi huylu (düşük dereceli, I ve II) ve kötü huylu (yüksek dereceli, III ve IV) olarak sınıflandırılabilir ve ciddi sonuçlara yol açabilen sağlık sorunları arasında yer alır. Beyin tümörleri kadın ve erkeklerde dünyada 10. [2] ve Türkiye’de 8. [3] önde gelen ölüm nedeni olarak raporlanmıştır. Beyin tümörlerinin segmentasyon ile sınırlarının ve sınıflama ile türlerinin doğru tahmin edilmesi, tedavinin planlanmasında kilit rol oynamaktadır.

Tümörlerin tespitinde tıbbi görüntüleme teknikleri kullanılmaktadır; ayrıca tıbbi görüntülemenin kanser tipi sınıflandırmasında kullanılan en yaygın ve güvenilir teknik olduğu düşünülmektedir. Bu yöntemin noninvaziv olması bu tekniği daha da önemli kılmaktadır [4]. Tıbbi görüntüleme

Abstract

Brain tumors located in the skull are among the health problems that cause serious consequences. Rapid and accurate detection of the brain tumor and segmentation of the tumor region will increase the patient's chance of recovery and survival by ensuring that the patient receives appropriate treatment in the early period. There are many segmentation methods in the literature. The low segmentation accuracy and the very large network structure used are the main disadvantages of the existing methods. In this study, a simplified U-Net deep learning model is used for segmentation on MR images of brain tumors. The model was trained and tested on 3064 MR images from 233 patients, which included the common brain tumors glioma, meningioma, and pituitary. As a result, average 0.86 dice similarity coefficient, 0.76 IoU score, 0.85 sensitivity value and 0.99 pixel accuracy value were obtained. Since the proposed model performs brain tumor segmentation quickly and with high accuracy, it promises to help specialists in the diagnosis of the disease and in determining the appropriate treatment.

Keywords: Brain tumor, Segmentation, Deep learning, U-Net

tekniklerinden biri olan manyetik rezonans görüntüleme (MRI) tekniği, beyin tümörlerinin sınıflandırılmasında ve segmente edilmesinde özellikle beyin dokusunun yüksek çözünürlüklü görüntülerini sağladığı için tercih edilmektedir.

Beyin tümörü segmentasyonu, farklı tümör dokularının (tümör, ödem ve nekroz) normal beyin dokularından (gri madde, beyaz madde ve beyin omurilik sıvısı) ayrılmasını ifade etmektedir. Beyin tümörü çalışmalarında anormal dokuların varlığı çoğu zaman kolaylıkla saptanabilmektedir. Bununla birlikte, anormalliklerin doğru bir şekilde segmente edilmesi ise kolay değildir [5]. Çünkü bu tümörler görünüm olarak heterojen yapıdadırlar ve beynin farklı yerlerinde sınırları düzensiz olduğundan farklı şekillerde meydana gelebilirler. Ayrıca MR görüntülemeye kullanılan voksel değerlerinin ölçek değerleri standart olmadığından tümörlü dokuların görünümü kurumdan kuruma da değişiklik gösterebilir [6]. Beyin tümörlerinin manuel olarak segmente edilmesi uzun zaman almaktadır ve görüntü sayısının çok fazla olması durumunda uygulanabilir değildir. Beyin tümörü segmentasyonu, uzun yıllardır araştırmacılar tarafından incelenmiş ve makine öğrenimi teknikleri

kullanılarak otomatikleştirilmiştir. Son yıllarda sıklıkla kullanılan ve başarısı kanıtlanmış olan derin öğrenme teknikleri bu alanda da yoğun olarak kullanılmaktadır.

Literatürde beyin tümörünün sınıflandırılması [7-10] ve segmente edilmesi [11-14] ile ilgili birçok çalışma mevcuttur. Son yıllarda bilgisayar teknolojilerinin gelişmesi ile, görüntüdeki özelliklerin otomatik olarak çıkarıldığı derin öğrenmenin, özelliklerin manuel olarak çıkarıldığı modellerden daha iyi performans göstermesi nedeniyle sınıflama ve segmentasyon işlemlerinde sıklıkla kullanılmaya başlanmıştır [15]. Sobhaninia vd. [11] kademeli çift ölçekli LinkNet derin öğrenme modelini kullanarak beyin tümörü segmentasyonu yapmışlardır. Modeli 3064 beyin MR görüntüsünden oluşan Figshare veriseti [16] üzerinde eğitip test etmişlerdir. Kaldera vd. [12] beyin tümörlerinden gliomların segmentasyonu için hızlı bölge tabanlı konvolüsyonel sinir ağı (fast R-CNN) ve kenar tespit teknikleri kullanmışlardır. Maas vd. tarafından yapılan çalışmada [13] segmentasyon işlemi, bir darboğaz katmanıyla ayrılmış yoğun katmanlar içeren 4 kodlayıcı ve 4 kod çözücünden oluşmuş bir derin öğrenme modeli ile gerçekleştirilmiştir. Kullanılan modelde son katman, Softmax'lı bir sınıflandırıcı bloktur. Mimari, U-Net mimarisine benzer şekilde, aynı uzaysal çözünürlüğe sahip tüm kodlayıcı ve kod çözücü blokları arasında atlamalı bağlantılar içermektedir. Derin öğrenmenin kullanıldığı farklı bir çalışma da Diaz-Pernas vd. tarafından yapılmıştır [14]. Yazarlar kullandıkları modelin konvolüsyon katmanlarını 3 uzaysal ölçek şeklinde oluşturmuşlar ve sonrasında bu ölçeklerden elde edilen çıktıları birleştirerek öznetelik haritasını elde etmişlerdir.

Bu çalışmada [11-14]'de olduğu gibi Figshare veriseti kullanılmıştır. Literatürde farklı verisetlerini kullanarak beyin tümörü segmentasyonu yapan çalışmalar da mevcuttur. Li vd. [17] U-Net mimarisini modifiye ederek ve tam konvolüsyonel bir ağ kullanılarak yeni bir uçtan uca beyin tümörü segmentasyon yöntemi geliştirilmiştir. Bilgi akışını geliştirmek için kodlama yolu ile kod çözme yolu arasında yukarı atlama bağlantısı olarak adlandırılan yenilikçi bir yapı önermişlerdir ve beyin tümörü alt bölgelerini sırayla segmentlere ayırmak için verimli bir kademeli eğitim stratejisi tanıtmışlardır. Toplamda 274 yüksek-seviyeli gliom ve düşük-seviyeli gliom tümörü içeren MR görüntüsü üzerinde model başarımı, 0.89 dice ve 0.90 hassasiyet değeri ile belirlenmiştir. Daimary vd. [18] görüntü segmentasyonunda sıklıkla tercih edilen CNN modellerinden U-Net ve SegNet5'i kullanarak hibrit bir model ortaya çıkarmışlardır. SegNet5, bir çift kodlayıcı ve kod çözücünden oluşmaktadır. Kodlayıcı yapısı VGG16'ya, kod çözücü yapısı ise VGG16'nın tersine benzemektedir; ancak SegNet5'in her konvolüsyon bloğunda bir konvolüsyon katmanı daha vardır. Önerilen modelde SegNet5, U-Net'te olduğu gibi ilk konvolüsyon bloklarına bir atlama bağlantısı eklenerek modifiye edilmektedir. Modelin değerlendirilmesinde 775 gliom tümörü içeren MR görüntüsü kullanılmıştır ve tümörler 0.73 mIoU ve 0.93 doğruluk değeri ile segmente edilmiştir. Derin öğrenme kullanılan başka bir çalışmada [19] bir konvolüsyonel sinir ağı destek vektör makine (DVM) algoritması ile birleştirilir

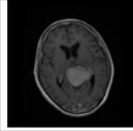
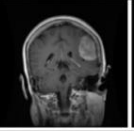
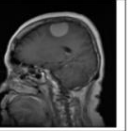
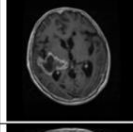
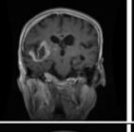

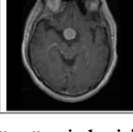
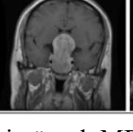
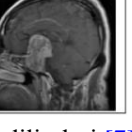
ve DCNN-F-SVM olarak isimlendirilir. Wu vd. tarafından önerilen bu modelde temel olarak üç aşama ile segmentasyon gerçekleştirilir. İlk aşamada, görüntü uzayından tümör işaret uzayına kadar olan haritalamayı öğrenmek için derin bir konvolüsyonel sinir ağı eğitilir. İkinci aşamada, bu eğitimden elde edilen etiketler, test görüntüleri ile birlikte entegre DVM sınıflandırıcısına giriş olarak verilir. Üçüncü aşamada ise önerilen modeli eğitmek için derin bir CNN ve entegre bir DVM seri olarak bağlanır. Önerilen model 543 gliom tümörü içeren MR görüntüsü üzerinde eğitilmiş ve test edilmiştir. Yapılan deneyler sonucunda 0.90 dice ve 0.92 hassasiyet değeri elde edilmiştir.

Bu çalışmada yaygın beyin tümörlerinden olan gliom, menenjiom ve hipofiz bezi tümörü içeren MR görüntüleri üzerinde beyin tümörleri, sadeleştirilmiş U-Net modeli kullanılarak segmente edilmektedir.

2 Materyal ve metod

2.1 Figshare beyin tümörü veriseti

Bu çalışmada, önerilen sadeleştirilmiş U-Net modelini eğitmek ve test etmek için Figshare isimli beyin MR görüntülerinden oluşan bir veriseti kullanılmıştır. Figshare veriseti literatüre ilk olarak 2015 yılında tanıtılmış ve verisetinin güncel versiyonu Cheng tarafından 2017'de sunulmuştur [16]. Erişime açık olan verisetindeki görüntüler, yaygın beyin tümörlerinden üçünü, gliom, menenjiom ve hipofiz tümörünü, içermektedir. 233 hastaya ait 3064 T1-CE MR görüntüsünü içeren verisetinde gliom, menenjiom ve hipofiz tümörlerini içeren görüntü sayısı sırasıyla 1426, 708 ve 930'dur. Bu görüntüler 2005 ve 2010 yılları arasında Çin Guangzhou Nanfang Hastanesi ve Çin Tianjian Tıp Üniversitesi Genel Hastanesi'nden alınmıştır. Tüm görüntüler sagittal, aksel ve koronal olmak üzere üç düzlemde toplanmıştır ve sırasıyla 1025, 994 ve 1045 görüntü içermektedir. Farklı düzlemlere sahip farklı tümör sınıflarından görüntü örnekleri Şekil 1'de gösterilmiştir. Orijinal görüntüler 512×512 çözünürlüğe ve 0.49×0.49mm² piksel boyutuna sahiptir. Görüntüler için dilim aralığı ve dilim kalınlığı sırasıyla 1 mm ve 6 mm'dir. Bu çalışma için görüntüler, önerilen modele girdi olarak verilmek üzere 128×128 piksel olarak yeniden boyutlandırılmıştır.

Tümör tipleri	Örnek görüntüler		
Gliom			
Menenjiom			
Hipofiz tümörü			

Şekil 1. Beyin tümör tipleri için örnek MR dilimleri [7]

2.2 Segmentasyon

Bölütlemeye olarak da isimlendirilen segmentasyon en genel tanımı ile bir görüntüyü ortak özellikler içeren bölgelere ayırmaktır. Görüntüde her bir piksele bir sınıf değeri atanır, aynı sınıf değerine sahip pikseller ortak özelliklere sahip olduklarından dolayı görüntü segmente edilmiş olur. Beyin tümörü segmentasyon yöntemleri gerekli insan etkileşiminin derecesine göre üç gruba ayrılabilir [20]: manuel, yarı-otomatik ve tam otomatik segmentasyon.

Manuel segmentasyon beyin tümörlerinin sınırlarının manuel olarak çizilmesini ve görüntüdeki farklı anatomik yapıların farklı işaretlerle gösterilmesini ifade etmektedir. Manuel segmentasyonda, uzmanlar yalnızca görüntüde sunulan bilgileri kullanmakla kalmaz, aynı zamanda anatomi gibi ek bilgileri de kullanırlar. Manuel tanımlama, tümör içeren bölgelerin çizimini ve gösterimini kolaylaştırmak için gelişmiş grafik kullanıcı ara yüzlerine sahip yazılım araçları gerektirir. Manuel segmentasyonda tümör bölgesinin belirlenmesi ve sınırlarının çizilmesi zaman alıcı bir işittir.

Yarı otomatik beyin tümörü segmentasyonu üç aşamada insan müdahalesine ihtiyaç duymaktadır. Bu aşamalar segmentasyon yöntemini başlatmak, sonucun doğruluğunu kontrol etmek ve hatta segmentasyon sonucunu manuel olarak düzeltmektir [20]. Mevcut araştırmaların çoğu, insan etkileşimini en aza indirmeye çalışan beyin tümörlerinin yarı otomatik segmentasyonunu hedef almaktadır [21].


Tam otomatik yöntemlerde ise tümör segmentasyonu herhangi bir insan etkileşimi olmadan bilgisayarlar tarafından gerçekleştirilir. Bu yöntemler genellikle algoritmalarda insan zekâsını ve önceki bilgileri birleştirirler [21].

2.3 Sadeleştirilmiş U-Net modeli

U-Net mimarisi, Ronneberger vd. tarafından biyomedikal görüntü segmentasyonu için ortaya çıkartılmıştır [22]. Mimari, kodlayıcı ve kod çözücü olmak üzere iki yol içermektedir. İlk yol, kodlayıcı, görüntüdeki özellikleri yakalamak için kullanılan daraltma yoludur. Kodlayıcı, yalnızca geleneksel bir konvolüsyon katmanı, her konvolüsyon katmanından sonra uygulanan doğrultulmuş lineer birim fonksiyonu (ReLU) ve maksimum havuzlama katmanları içermektedir. İkinci yol, kod çözücü, transpoze konvolüsyonlar uygulayarak kesin lokalizasyonu sağlamak için kullanılan simetrik genişleyen bir yoldur. Herhangi bir tam bağlı katman içermeyip yalnızca konvolüsyon katmanları içerdiğinden uçtan uca tam konvolüsyonel bir ağ da denilebilir.

Orijinal U-Net modeli toplamda 23 konvolüsyon katmanı içermektedir. U-Net'e ilişkin mimari Şekil 2'de gösterilmiştir. Mimari U harfine benzediği için U-Net olarak isimlendirilmiştir. Sol taraf daraltma yolunu, sağ taraf da genişletme yolunu göstermektedir. Daraltma yolu yalnızca konvolüsyonel sinir ağlarından oluşmaktadır. Giriş görüntüsüne 3×3 boyutlu 64 tane filtre ile konvolüsyon işlemi uygulanır. Her bir konvolüsyon işleminden sonra oluşan özellik haritaları ReLU aktivasyon fonksiyonundan geçirilir. Sonrasında alt örnekleme için 2×2 boyutlu maksimum havuzlama işlemi uygulanır. Konvolüsyon+ReLU+maksimum havuzlama işlem döngüsü

bu şekilde 3 kez daha tekrar edilir. Daraltma yolundaki her alt örnekleme adımında, filtre sayısı iki katına çıkmaktadır. Modelin ilk kısmında azalan boyutun modelin ikinci kısmı olan genişletme yolunda artırılması amaçlanmaktadır. Bunu yaparken çıktının çözünürlüğünün de artırılması hedeflenmektedir. Bu amaçla genişletme yolunda 2×2'lik yukarı konvolüsyon işlemi uygulanır ve filtre sayısı yarıya indirilir. Sonrasında daraltma yolundan uygun şekilde kırılmış özellik haritası kopyalanarak genişletme yolunda elde edilen çıktı birleştirilir ve arka arkaya 2 kez 3×3'lük konvolüsyon işlemi uygulanır. Bu kısımda da her bir konvolüsyon işleminden sonra ReLU aktivasyon fonksiyonu uygulanmakta ve bahsedilen sıralı işlemler 3 kez daha tekrar etmektedir. Son katmanda, 64 bileşenli özellik vektörünü istenen sayıda sınıfa eşlemek için 1×1'lik konvolüsyon işlemi kullanılır [22].



Şekil 2. Orijinal U-Net mimarisi [22]

Bu çalışmada önerilen modelde U-net sadeleştirilmiş haliyle kullanılmaktadır. Sadeleştirilmiş U-Net modelinde daraltma ve genişletme yollarındaki katman sayıları değişmezken (orijinal U-Net ile aynı sayıda), bu katmanlarda kullanılan filtre sayıları $\frac{3}{4}$ oranında azaltılmıştır. Örneğin giriş katmanındaki konvolüsyon işlemlerinde kullanılan filtre sayısı orijinal U-Net'te 64 iken, sadeleştirilmiş U-Net'te 16'ya düşürülmüştür. Bu şekilde her katmandaki filtre sayıları azaltılmıştır. Böylelikle beyin tümörlerinin segmentasyonu için hesaplanan parametre sayısı önemli ölçüde azaltılmıştır.

2.4 Değerlendirme metrikleri

Beyin tümörlerinin MR görüntüleri üzerinde segmente edilmesinde önerilen sadeleştirilmiş U-Net modelinin değerlendirilmesi için, literatürde segmentasyon problemlerinde sıklıkla kullanılan Dice benzerlik sabiti (1), birleşimlerin kesişim değeri (IoU) (2), hassasiyet (3) ve piksel doğruluğu (4) metrikleri kullanılmıştır.

Segmentasyon problemlerinde sıklıkla kullanılan ölçütlerin başında Dice benzerlik sabiti gelmektedir.

Denklem 1'de gösterildiği gibi ifade edilmektedir.

$$\text{Dice benzerlik sabiti} = \frac{2TP}{2TP+FP+FN} \quad (1)$$

Denklem 2’de belirtilen IoU piksel tabanlı bir değerlendirme ölçütüdür. Uzmanlar tarafından işaretlenmiş tümörlü alanları gösteren, maske olarak da isimlendirilen, referans görüntü ya da referans maske (ground-truth) ile model tarafından ortaya çıkarılan maskedeki tümör sınıfına ait örtüşen piksel oranını göstermektedir. mIoU ise, çok sınıflı segmentasyon problemlerinde sınıflara ilişkin ortalama IoU değerini belirtmek için kullanılmaktadır.

$$\text{IoU} = \frac{TP}{TP+FP+FN} \quad (2)$$

Hassasiyet, model çıktısında doğru tahmin edilen tümörlü bölgelerin referans görüntüdeki tümörlü bölgelere olan oranını göstermektedir ve Denklem 3’teki gibi ifade edilmektedir.

$$\text{Hassasiyet} = \frac{TP}{TP+FN} \quad (3)$$

Denklem 4 ile belirtilen piksel doğruluğu, görüntüdeki (hem tümör hem de arka plan sınıfına ait) doğru sınıflanmış piksellerin tüm piksellere oranını belirtmektedir.

$$\text{Piksel doğruluğu} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

MR görüntülerindeki tümör içeren piksel sınıfını P (pozitif), tümör içermeyen arka plan piksellerinin sınıfını da N (negatif) ile belirtelim. Bu durumda Denklem 1-4’te kullanılan

- TP, gerçekte P sınıfına ait ve model tarafından da P olarak sınıflandırılan piksellerin sayısını,
- TN, gerçekte N sınıfına ait ve N olarak sınıflandırılan piksellerin sayısını,
- FP, gerçekte N sınıfına ait ancak model tarafından P olarak sınıflandırılan piksel sayısını
- FN, gerçekte P sınıfına ait ancak model tarafından N olarak sınıflandırılan piksel sayısını göstermektedir.

3 Deneysel sonuçlar ve tartışma

Beyin tümörlerinin MR görüntüleri üzerinde segmentasyonu amacıyla önerilen sadeleştirilmiş U-Net modeli, Google Colab platformunda Python programlama dili kullanılarak analiz edilmiştir. Modelin değerlendirilmesinde en yüksek sonuçlar veren parametre değerleri paket boyutu için 16 ve epok sayısı için 50 olarak belirlenmiştir. Öğrenme algoritması olarak 0.001 öğrenme oranı ile Adam tercih edilmiştir. Görüntülerin %70’i eğitim ve %30’u test amacıyla kullanılmıştır. Yapılan deneylere ilişkin gliom, menenjiom ve hipofiz tümörü segmentasyon sonuçları ve ortalama sonuçlar Tablo 1’de gösterilmektedir.


Verisetinde gliom içeren MR görüntülerinin sayısı diğerlerinden fazla olmasına rağmen Tablo 1’e bakıldığında bu tümöre ilişkin segmentasyon başarımlarının diğerlerinden daha düşük olduğu görülmektedir.

Tablo 1. Beyin tümörü segmentasyonu test sonuçları


	Dice katsayısı	IoU	Hassasiyet	Piksel doğruluğu
Gliom	0.77	0.62	0.73	0.98
Menenjiom	0.93	0.86	0.90	0.99
Hipofiz tümörü	0.89	0.81	0.92	0.99
Ortalama	0.86	0.76	0.85	0.99

Gliom tümörleri doğası gereği ilerledikçe ve büyüdükçe MR üzerindeki görünüşleri her ilerleme aşamasında değişir. Diğer tümör sınıfları olan menenjiom ve hipofiz tümörü ise ilerleme sürecinde daha tutarlı kalarak MR üzerinde çok fazla değişim göstermezler. Yani gliom tümörlerinin yoğunlukları tümörün ilerlemesi durumunda değişim göstermektedir. Bu da gliom tümörlerin MR üzerindeki segmentasyon başarımının düşük olmasını açıklamaktadır [13,23,24].

Beyin tümörlerinin segmentasyonuna ilişkin görsel sonuçlar Şekil 3 ve 4’te gösterilmektedir. Şekil 3’te gliom, menenjiom ve hipofiz tümörü içeren MR görüntüleri, bu görüntülere ilişkin tümörlerin yerini gösteren uzmanlar tarafından oluşturulmuş referans maske ve model tarafından tahmin edilen maske gösterilmektedir. Şekil 4’te ise Şekil 3’teki görüntülere ilişkin modelin başarımı MR görüntüleri üzerinde gösterilmekte, ayrıca her bir görüntüye ilişkin segmentasyon sonucu IoU cinsinden belirtilmektedir. Buna göre model tarafından sarı ile işaretlenmiş pikseller gerçekte tümör içeren ve tümör alanı olarak tahmin edilen (TP) pikselleri göstermektedir. Kırmızı işaretli pikseller gerçekte tümör içermeyen ancak model tarafından tümör alanı olarak tahmin edilen (FP) pikselleri, yeşil işaretli pikseller ise gerçekte tümör içeren ancak model tarafından tümörsüz alan olarak tahmin edilen (FN) pikselleri göstermektedir.



Şekil 3. Beyin tümör tiplerine ilişkin referans maske ve sadeleştirilmiş U-Net modeli tarafından üretilen maske.



Şekil 4. Şekil 3'teki görüntülerin segmentasyonuna ilişkin başarımların görselleştirilmesi.

Beyin tümörlerinin segmentasyonuna ilişkin yapılan çalışma, literatürde aynı verisetini kullanan çalışmalar ile karşılaştırılmıştır. Buna ilişkin karşılaştırma sonuçları dice metriği cinsinden **Tablo 2**'de gösterilmektedir. **Tablo 2**'deki çalışmaların bazıları başarımları tümör sınıfı bazında verirken, bazıları sadece ortalama başarımları vermiştir. **Tablo 2**'ye bakıldığında sadeleştirilmiş U-Net modelinin aynı verisetini kullanan çoğu çalışmadan daha başarılı olduğu görülmektedir. Yalnızca [12]'deki dice benzerlik katsayısı bu çalışmada elde edilen başarımdan daha yüksektir. Eksenel düzlemde elde edilen görüntüler, sagittal ve koronal düzlemde elde edilen görüntülere göre daha yüksek çözünürlüklü ve daha az gürültülü olduğundan dolayı, [12]'de yalnızca eksenel düzlemde elde edilen MR görüntülerinin kullanıldığını belirtmek gerekmektedir.

Tablo 2. Aynı veri setini kullanan çalışmalar ile dice benzerlik katsayısı cinsinden karşılaştırma

Çalışma	Gliom	Menenjiom	Hipofiz T.	Ortalama
Sobhaninin vd. [11]	n.i.	n.i.	n.i.	0.80
Kaldera vd. [12]	n.i.	n.i.	n.i.	0.91
Maas vd. [13]	0.63	0.85	0.83	0.74
Díaz-Pernas vd. [14]	0.78	0.89	0.91	0.83
Önerilen	0.77	0.93	0.89	0.86

n.i.: Bilgi yok

4 Sonuçlar

Beyin tümörlerinin tespiti, sınıflandırılması ve segmentasyonu tıbbi müdahalelerde büyük bir öneme sahiptir. Bu çalışmada yaygın beyin tümörlerinden olan gliom, menenjiom ve hipofiz tümörünün MR görüntüleri üzerinde segmente edilmesi amaçlanmıştır. Parametre sayısı azaltılmış olan sadeleştirilmiş U-Net modeli, 3064 T1 ağırlıklı MR görüntüsü üzerinde eğitilmiş ve test edilmiştir. Yapılan deneyler sonucunda ortalama dice benzerlik katsayısı, IoU, hassasiyet ve piksel doğruluğu cinsinden sırasıyla 0.86, 0.76, 0.85 ve 0.99 segmentasyon başarımına

ulaşmıştır. Elde edilen sonuçlar önerilen sadeleştirilmiş U-Net modelinin, beyin tümörlerinin MR görüntüleri üzerinde segmentasyonunda başarılı olduğunu göstermektedir ve uzmanlara teşhis ve tedavi aşamasında karar vermelerinde yardımcı olması açısından umut vaat edicidir.

Çıkar çatışması

Yazar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): % 10

Kaynaklar

- [1] H. Mohsen, E.A. El-Dahshan, E.M. El-Horbaty ve A.M. Salem, Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3 (1), 68-71, 2018. <https://doi.org/10.1016/j.fcij.2017.12.001>.
- [2] G.S. Tandel, A. Balestrieri, T. Jujaray, N.N. Khanna, L. Saba ve J.S. Suri, Multiclass magnetic resonance imaging brain tumor classification using artificial intelligence paradigm. *Computers in Biology and Medicine*, 122, 103804, 2020. <https://doi.org/10.1016/j.compbimed.2020.103804>.
- [3] Types of cancer, Brain Tumor: Statistics. <https://www.cancer.net/cancer-types/brain-tumor/statistics> Accessed 28 April 2022.
- [4] K. Usman ve K. Rajpoot, Brain tumor classification from multi-modality MRI using wavelets and machine learning. *Pattern Analysis and Applications*, 20, 871-881, 2017. <https://doi.org/10.1007/s10044-017-0597-8>
- [5] N. Gordillo, E. Montseny ve P. Sobrevilla, State of the art survey on MRI brain tumor segmentation. *Magnetic Resonance Imaging*, 31 (8), 1426-1438, 2013. <https://doi.org/10.1016/j.mri.2013.05.002>.
- [6] A. Baştuğ Koç ve D. Akgün, U-net mimarileri ile glioma tümör segmentasyonu üzerine bir literatür çalışması. *Avrupa Bilim ve Teknoloji Dergisi*, 26, 407-414, 2021. <https://doi.org/10.31590/ejosat.959590>.
- [7] Ö. Polat, C. Güngen, Classification of brain tumors from MR images using deep transfer learning. *Journal of Supercomputing*, 77, 7236-7252, 2021. <https://doi.org/10.1007/s11227-020-03572-9>.
- [8] G. Xiao, H. Wang, J. Shen, Z. Chen, Z. Zhang ve X. Ge, Synergy factorized bilinear network with a dual suppression strategy for brain tumor classification in MRI. *Micromachines*, 13 (1), 2022. <https://doi.org/10.3390/mi13010015>.
- [9] B.V. Isunuri ve J. Kakarla, Three-class brain tumor classification from magnetic resonance images using separable convolution based neural network. *Concurrency and Computation: Practice and Experience*, 34, e6541, 2022. <https://doi.org/10.1002/cpe.6541>.
- [10] J. Kakarla, B.V. Isunuri, K.S. Doppalapudi ve K.S.R. Bylapudi, Three-class classification of brain magnetic resonance images using average-pooling convolutional neural network. *International Journal of Imaging Systems and Technology*, 31 (3), 1731-1740, 2021. <https://doi.org/10.1002/ima.22554>.

- [11] Z. Sobhaninia, S. Rezaei, N. Karimi, A. Emami ve S. Samavi, Brain Tumor Segmentation by Cascaded Deep Neural Networks Using Multiple Image Scales. 28th Iranian Conference on Electrical Engineering (ICEE), sayfa 1-4, Tabriz, Iran, 4-6 Ağustos 2020. <https://doi.org/10.1109/ICEE50131.2020.9260876>.
- [12] H.N.T.K. Kaldera, S.R. Gunasekara ve M.B. Dissanayake, MRI based glioma segmentation using deep learning algorithms. 2019 International Research Conference on Smart Computing and Systems Engineering (SCSE), sayfa 51-56, Colombo, Sri Lanka, 28-28 Mart 2019. <https://doi.org/10.23919/SCSE.2019.8842668>.
- [13] B. Maas, E. Zabehe ve S. Arabshahi, QuickTumorNet: Fast automatic multi-class segmentation of brain tumors. 10th International IEEE/EMBS Conference on Neural Engineering (NER), sayfa 81-85, Italy, 4-6 Mayıs 2021. <https://doi.org/10.1109/NER49283.2021.9441286>.
- [14] F.J. Díaz-Pernas, M. Martínez-Zarzuela, M. Antón-Rodríguez ve D. González-Ortega, A deep learning approach for brain tumor classification and segmentation using a multiscale convolutional neural network. *Healthcare (Basel)*, 9 (2), 153, 2021. <https://doi.org/10.3390/healthcare9020153>.
- [15] K. Kamnitsas, C. Ledig, V.F.J. Newcombe, J.P. Simpson, A.D. Kane, D.K. Menon, D. Rueckert ve B. Glocker, Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation. *Medical Image Analysis*, 36, 61-78, 2017. <https://doi.org/10.1016/j.media.2016.10.004>.
- [16] J. Cheng, Brain tumor dataset, figshare. 2017. <https://doi.org/10.6084/m9.figshare.1512427.v5>.
- [17] H. Li, A. Li and M. Wang, A novel end-to-end brain tumor segmentation method using improved fully convolutional networks. *Computers in Biology and Medicine*, 108, 150-160, 2019. <https://doi.org/10.1016/j.compbiomed.2019.03.014>.
- [18] D. Daimary, M.B. Bora, K. Amitab ve D. Kandar, Brain tumor segmentation from MRI images using hybrid convolutional neural networks. *Procedia Computer Science*, 167, 2419-2428, 2020. <https://doi.org/10.1016/j.procs.2020.03.295>.
- [19] W. Wu, D. Li, J. Du, X. Gao, W. Gu, F. Zhao, X. Feng and H. Yan, An intelligent diagnosis method of brain MRI tumor segmentation using deep convolutional neural network and SVM algorithm. *Computational and Mathematical Methods in Medicine*, 6789306, 2020. <https://doi.org/10.1155/2020/6789306>.
- [20] J.L. Foo, A survey of user interaction and automation in medical image segmentation methods. Iowa State University Human Computer Interaction Technical Report ISU-HCI-2006-02, 2006.
- [21] N. Gordillo, E. Montseny ve P. Sobrevilla, State of the art survey on MRI brain tumor segmentation. *Magnetic Resonance Imaging*, 31 (8), 1426-1438, 2013. <https://doi.org/10.1016/j.mri.2013.05.002>.
- [22] O. Ronneberger, P. Fischer, ve T. Brox, U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015. Lecture Notes in Computer Science, 9351. Springer, Cham. https://doi.org/10.1007/978-3-319-24574-4_28.
- [23] J. Liang, X. Lv, C. Lu, X. Ye, X. Chen, J. Fu, C. Luo ve Y. Zhao, Prognostic factors of patients with Gliomas - an analysis on 335 patients with glioblastoma and other forms of gliomas. *BMC Cancer*, 20 (1), 35, 2020. <https://doi.org/10.1186/s12885-019-6511-6>.
- [24] N. Sarbu, L. Oleaga, I. Valdivieco, T. Pujol ve J. Berenguer, Increased signal intensity in FLAIR sequences in the resection cavity can predict progression and progression-free survival in gliomas. *Neurocirugia (Astur)*, 27 (6), 269-276, 2016. <https://doi.org/10.1016/j.neucir.2016.04.002>.

