



# Düzce Üniversitesi Bilim ve Teknoloji Dergisi

*Araştırma Makalesi*

## Beyin Tümör Tespiti İçin Derin Öğrenme Temelli Bilgisayar Destekli Tanı Sistemi

 Tarıkcın DOĞANAY<sup>a,\*</sup>,  Oktay YILDIZ<sup>a</sup>

<sup>a</sup> Sağlık Bilişimi, Bilişim Enstitüsü, Gazi Üniversitesi, Ankara, TÜRKİYE

\* Sorumlu yazarın e-posta adresi: taarikdoganay@gmail.com

DOI:10.29130/dubited.1005401

### Öz

Beyin MR segmentasyonu klinik uygulamalarda önem arz etmektedir. Beyin analizi çeşitli yaklaşımlarla bulgular ve anatomik bölgelerin doğru segmentasyonuna dayanır. Beyin MRI analizi, epilepsi, şizofreni, alzheimer, kanser ve bulaşıcı dejeneratif hastalıklar gibi beyin bozukluklarının tedavisi için yaygın bir şekilde kullanılmaktadır. Hasta MRI görüntülerinin doktorlar tarafından manuel segmentasyonu görüntülerin dilim dilim ana hatlarının çıkarılmasını gerektirir. Ancak manuel segmentasyonun uzman görüşü ve teknolojik kısıtları nedeniyle bazı dezavantajları vardır. Bununla birlikte görüntü yorumlama son derece zaman alan bir işlemdir. Tecrübeye bağlı olarak hata yapma oranı da yüksektir. Bu çalışmada, beyin MR görüntülerinden otomatik tümör tespiti için uçtan uca Çok Ölçekli Çok Düzeyli Ağ (Multi-Scale Multi-Level Network MM-Network) modeli önerilmiştir. Gerçekleştirilen çalışmada, UNet'teki evrişimli ağ seviyesinde çoklu uzamsal ölçeklerin küresel bağlamsal özelliklerini birleştirerek, ağlar boyunca özellik haritalarının boyutuna bağlı olarak alıcı alanın farklı oranlarda genişlemesini sağlayan genişletilmiş evrişim modülünden yararlanılmıştır. Yapılan deneysel çalışmalarda önerilen model ile yüksek doğrulukta tümör tespiti sağlanmıştır.

**Anahtar Kelimeler:** Derin öğrenme, Bilgisayar destekli tanı sistemi, Segmentasyon

## Deep Learning Based Computer Aided Diagnostic System for Brain Tumor Detection

### ABSTRACT

Brain MRI segmentation is important in many clinical applications. Brain analysis is based on various approaches, findings, correct segmentation of anatomical regions. Brain MRI quantitative analysis has been used commonly for characterization of brain disorders such as epilepsy, schizophrenia, Alzheimer's disease, cancer, and infectious degenerative diseases. In this study, an end-to-end deep learning segmentation method called Multi-Scale Multi-Level Network MM-Network has been developed. The main idea is to combine the global contextual features of multiple spatial scales at the convolutional network level in UNet. In addition, the extended convolution module is used, which allows the receptive field to expand at different rates depending on the size of the feature maps throughout the networks. The MM-Network model apply in this study was used for tumor segmentation in brain MR images, and successful results were obtained.

**Keywords:** Deep learning, Computer aided diagnosis system, Segmentation

# I. GİRİŞ

Tıbbi görüntüleme, vücudun iç kısımlarını görsel temsil oluşturarak tıbbi analiz ve müdahale için kullanılan tekniktir. Bu işlem, Manyetik Rezonans Görüntüleme (MRI), Bilgisayarlı Tomografi (CT), X-ray, Ultrason (US), endoskop, oftalmoskopi ve dermoskopi modaliteleri gibi noninvaziv olarak uygulanır. Görüntüleme modeliteleri hasta tanı, analizi, tedavi planı için önemlidir. Bilgisayar Destekli Tanı (Computer Aided Diagnosis - CAD) sistemi, radyolojik yorumlamalarda örneğin MR görüntülerinde beyin tümörü, tomografi görüntülerinde karaciğer nodülleri, mamografi görüntülerinde meme nodülleri gibi tıbbi görüntülerde var olan tümörlerin ortaya çıkmasını sağlar.

Tıbbi görüntü yorumlama ve teşhis için klinisyenlere yardımcı olmayı amaçlayan bir araçtır [1]. Tümör tanımlanmasına ulaşmak için CAD sistemleri üç ana aşamada gerçekleştirilir: Özellik çıkarma, Seçim ve Sınıflandırma. Bu üç adımın ayrı ayrı ele alınması ve ardından CAD performans ayarı için birlikte entegre edilmesi gerekir. Giriş görüntülerdeki şüpheli tümörleri lokalize etmek tespit aşamasında, tümör sınırlarını belirlemek ise segmentasyon aşamasında tanımlanır. Görüntü analiz uygulamalarında tıbbi görüntü segmentasyonu CAD sistemi için ön adımdır.

Son zamanlarda tıbbi görüntüleme teknikleri, beyin tümörü, Alzheimer hastalığı ve hafif bilişsel bozukluk teşhisi için kullanılmıştır. Bu tür tıbbi uygulamaların manuel olarak yorumlanması, karmaşık bir organ anatomisi ön bilgisi gerektirdiğinden zorlu bir süreçtir [2]. Ayrıca öznel, hataya açık ve zaman alıcıdır. Daha doğru, hızlı analiz ve teşhis için klinik uygulamalarda otomatik segmentasyon algoritmalarına ihtiyaç duyulmaktadır. Son yıllarda daha düşük maliyet ve daha az kullanıcı müdahalesi ile otomatikleştirilmiş anlamsal bölümlenme yöntemleri sağlamak için sayısız gelişmelere tanık olunsada birçok tıbbi görüntüleme bölümlenme görevinde hala zorluklar mevcuttur. Daha spesifik olarak düşük kontrast, karmaşık geometri, düzensiz sınırlar, yüksek sınıflar arası veya sınıf içi varyasyonların yanı sıra bazı görüntüleme modalitelerinde gürültü ve artefakt varlığı, biyomedikal segmentasyon görevlerine ekstra engeller ekler [3]. Bununla birlikte görüntü kalitesi de önemlidir.

Bilgisayar Destekli Tanı sistemlerinde derin öğrenme, görüntü segmentasyon ve sınıflandırma, nesne algılama yöntemleri sıklıkla kullanılmaktadır. Bununla birlikte çoklu tıbbi görüntü segmentasyonu için de literatürde bazı çalışmalar yer almaktadır. Mohammed A. Al-masni ve arkadaşları [4], “Derin Öğrenme Yolu Tabanlı CAD Sistemi Aracılığıyla Dijital Mamogramlarda Meme Kitlelerinin Eş Zamanlı Tespiti ve Sınıflandırılması” adlı çalışmasında meme kitlelerin otomatik tespiti ve sınıflandırılması yapılarak radyologlara karar destek sistemi geliştirmişlerdir. Bu çalışmada ilgi bölge (ROI) tabanlı evrişimsel sinir ağı uygulanarak tümör tespiti ve sınıflandırılma yapılmıştır. Zhao ve arkadaşları [5] yapmış oldukları “Piramit Ayrıştırma Ağı (PSPNET)” adlı çalışma ile literatürde yapılan diğer çalışmaları karşılaştırmışlar ve önerilen PSPNET ile doğruluk oranı %99,38 olan yüksek bir başarı elde etmişlerdir. Al-Masni ve Dong-Hyun Kim tarafından yapılan çalışmada [6], CMM-Ağ mimarisi ile dermoskopi görüntülerinden cilt lezyonları, retinal kan damarları segmentasyonu ve BraTS 2018 MR taramalarından beyin glioma segmentasyonu gerçekleştirilmiş, yapılan deneysel çalışmalarda UNet, DeepLabv3+, Ce-Net, UNet++ algoritmaları ile karşılaştırma yapılmış ve birçok kriterde yüksek performans elde etmişlerdir. Yıldız 2019 [7] yılında yapmış olduğu “Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study” adlı çalışmasında cilt kanseri türü olan melanom için otomatik tanı koyabilecek bir sistem önermiş, melanom tanısı için tasarlanan C4Net derin sinir ağ modeli ile beraber literatürde ön plana çıkmış AlexNet, GoogLeNet, ResNet, VGGNet derin öğrenme modelleri ve Yapay sinir ağları, En yakın komşu algoritması ve Destek vektör makinesi gibi geleneksel makine öğrenme yöntemlerini de kapsayan detaylı bir deneysel çalışma yapmıştır. Çalışmada önerilen C4Net derin sinir ağ modeli ile %96,94 doğrulukta melanom tanısı konulabilmektedir. Harun Bingöl ve Bilal Alataş [8] “Derin Öğrenme Yöntemleri Kullanılarak Beyin Tümörü Görüntülerinin Sınıflandırılması” çalışmada, derin öğrenme tekniklerinde sık kullanılan Alexnet, GoogLeNet ve Resnet50 mimarilerini kullanmışlar, Resnet50 mimarisi ile %85,71 başarı oranı elde etmişlerdir.

Gerçekleştirilen bu çalışmada, ağlar boyunca özellik haritalarının boyutuna bağlı olarak farklı oranlarda alıcı alanın genişlemesini sağlayan genişletilmiş evrişim modülü kullanılmıştır. Bu da minimum çözünürlük kaybıyla çok ölçekli bağlamsal bilgilerin yoğun tahminlerini üretmeyi sağlar. Literatürde birçok çalışma olmasına rağmen bu yöntem NIFTI formatındaki kaliteli, yüksek çözünürlüklü veriler ve 18750 veri sayısı ile segmentasyon açısından yüksek oranda doğruluk sağlanmıştır.

## **II. TEMEL KAVRAMLAR**

### **A. MANYETİK REZONANS GÖRÜNTÜLEME (MRI)**

MRI, güçlü manyetik alanlar kullanarak vücuttaki fizyolojik süreçlerin, organların ve dokuların görüntülerini oluşturmak için kullanılan bir görüntüleme tekniğidir. MRI, vücudun kemikli olmayan kısımlarını veya yumuşak dokularını görüntülemek için kullanılır. BT taramalarından temel farkı, x-ışınlarının iyonlaştırıcı radyasyonunu kullanmasıdır. Diz ve omuz yaralanmaları, MRI taramalarında hem röntgen hem de BT taramalarına kıyasla daha iyi çözünürlükle görülebilir. Beyinde, MRI taramaları gri ve beyaz maddeyi ayırt etmek için kullanılabilir ve bu da anevrizma ve tümörlerin belirlenmesine yardımcı olur [9].

### **B. GÖRÜNTÜ SEGMENTASYONU**

Görüntü segmentasyonu görüntü tanıma, makine öğrenmesi ve tıbbi görüntü işleme alanlarında sıklıkla kullanılmaktadır. Görüntü ayrıştırma teknikleri, genelde MR görüntülerinin gri tondaki histogram bilgilerini kullanır. RGB formatındaki renkli MR görüntüleri [0, 255] aralığındaki gri tonlara (Gray Scale) dönüştürülerek kullanılır. Genellikle MR görüntülerinde bulunan tümör bölgesi arka plana göre oldukça küçük bir orana sahiptir. Bu durum tümörün tespitini zorlaştırmaktadır. Bu amaçla ROI (Region of Interest) ile olası tümör bölgesi konveks bir alan içerisine alınarak inceleme yapılır [10].

### **C. UNet MİMARİSİ**

Yapay zeka, insan zekasının karar verme ve problem çözme yeteneklerini taklit etmek için bilgisayar ve makinelerden yararlanır. Makine öğrenimi ya da yapay öğrenme, bilgisayarların örnek veri ya da geçmiş deneyimi kullanarak bir ölçüte göre başarımlarını artıracak biçimde programlanmasındır. Böylece, zamanla gelişen ölçülebilir bir performansla bilinçli kararlar verilebilir [7]. Regresyon, kümeleme, destek vektör makinesi, sığ sınıflandırıcılar gibi geleneksel makine öğrenme teknikleri, tıbbi görüntülemede on yıllardır kullanılmaktadır. Sinir Ağları, beyindeki birbirine bağlı nöronlardan ve karmaşık bilişsel görevleri yerine getirmek için çalışma işlevinden yararlanır. Bir sinir ağı, girdi, gizli ve çıktı katmanlarından oluşur. Giriş katmanı işlenecek verileri alırken, çıkış katmanı istenen görevin sonuçlarını sağlar. Giriş ve çıkış katmanları arasındaki sinir ağına birden fazla gizli katman dahil edilir. Bu nedenle, derin öğrenme genellikle çok sayıda gizli katman içeren derin bir yapıyı ifade eder. Bu mimarinin benzersiz özellikleri, esnekliği ve ölçeklenebilirliğidir [11].

UNet, geliştirilmiş tam evrişimli bir ağ modeli ve yapısı U şekline benzer. Diğer evrişimli sinir ağları ile karşılaştırıldığında, UNet daha az eğitim seti gerektirir ve daha yüksek segmentasyon doğruluğuna sahiptir. Ara katmanın simetri eksenini ile simetrik olan kodlayıcı ve kod çözücünden oluşur [12]. Kodlayıcı, görüntü özelliklerini evrişimli alt örnekleme havuzlama (down-sampling pooling) katmanları aracılığıyla çıkarır. Karşılaştırıldığında, kod çözücü özellik görüntülerinin yukarı örnekleme (up-sampling) katmanı ile gerçekleştirir ve karşılık gelen kodlayıcı ve kod çözücü katmanları arasında üst örnekleme katmanı, görüntünün ayrıntılarını kurtarmasına yardımcı olabilecek çapraz katman (cross-layer) bağlantıları vardır.

Genişletilmiş evrim modülü, ardışık havuzlama katmanları kullanmak yerine çok ölçekli bağlamsal özellikleri bir araya getirebilen dalgacık ayrıştırmasından esinlenmiştir. Filtrelerin alıcı alanını genişleterek bilgilerin çözülmesini kontrol eder.  $F[x]$ 'in ayrık bir girdi ve  $w[x]$ 'in ayrık bir filtre olduğu düşünülürse [6]; Standart uzaysal evrişim Eş. 1'deki gibi tanımlanır:

$$f[x] * w[x] = \sum_{k=-\infty}^{+\infty} f[k].w[x - k]. \quad (1)$$

Burada '\*' ve '.' sırasıyla evrişim ve çarpma işlemlerini gösterir. Daha sonra, genişleme oranı  $r$  olan genişlemiş evrişim Eş. 2'deki gibi tanımlanır:

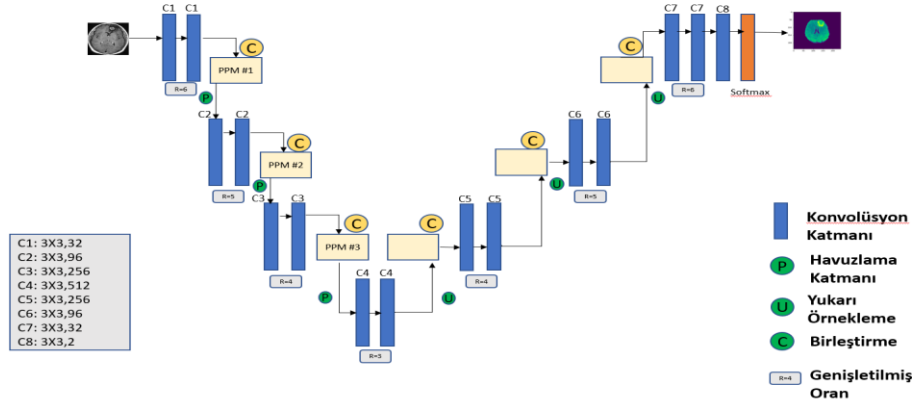
$$f[x] *_r w[x] = \sum_{k=-\infty}^{+\infty} f[k].w[r(x - k)]. \quad (2)$$

Genişleme hızı arttığında, sonuçtaki alıcı alanın katlanarak genişlediğine dikkat edilmelidir. Bu ilişki şu şekilde formüle edilebilir:  $(2^{r+1} - 1) \times (2^{r+1} - 1)$ ,  $r = 1$  olduğunda standart evrişim ile aynı hale gelir [13]. Böylece, genişletilmiş evrişim, öğrenme parametrelerinin sayısının doğrusal olarak arttığı bağlamsal bilginin çözünürlüğünü kontrol edilir [6].

Piramit Havuzlama Modülü (PPM) arka plan bilgilerini toplamak için kullanılır. Düzleştirilmiş ve birleştirilmiş çok seviyeli özellikleri sınıflandırma görevlerinde F-CNN'ye geçiren Uzamsal Piramit Havuzu (Spatial Pyramid Pooling) aksine, PPM çeşitli alt düzeyler arasındaki bilgi kaybı azaltılır ve etkili hiyerarşik küresel temsilleri çıkarılır [6]. PPM, kıvrımlı özelliklerin farklı ölçeklerle dört paralel piramit seviyesine alt örneklenmesiyle başlar. Daha büyük havuzlama faktörü, daha kaba özellikler üretirken daha ince temsiller daha küçük havuzlama faktörleriyle çıkarılır. Ardından,  $1 \times 1$  evrişim kullanan darboğaz katmanı, bağlam boyutunu  $1/N$  indirerek hesaplama yeteneğini geliştirmek için havuzlanmış her özellikten sonra doğrudan uygulanır; burada  $N$ , piramidin seviye boyutunu gösterir. Örneğin, havuzlama piramidinin seviye boyutu  $N=4$  ise (bu çalışmadaki gibi), o zaman her seviyenin özellik haritaları  $1/4$  faktörü kadar azaltılacaktır [6]. Piramidin hemen önündeki orijinal özellik haritalarına geri dönmek için havuzlama, çift doğrusal enterpolasyon yoluyla yukarı örnekleme, her piramit düzeyine uygulanır. Sonunda, küresel bağlam özelliklerini birleştirmek için tüm yukarı örneklenmiş özellik haritalarının orijinal özellik haritasıyla birleştirilmesi gerçekleştirilir.


### **III. DENEYSEL ÇALIŞMA**

Bu çalışmada, derin öğrenme UNet algoritması temel alınarak beyin tümör tanısı için yeni ve etkin, uçtan uca bir segmentasyon ağı kullanılmıştır. Önerilen model UNet mimarisine dayanmakta, genişleyen ve daralan yollardan, kodlayıcı (encoder) ve kod çözücü (decoder) olmak üzere iki ağıdan oluşmaktadır. Daralan yol, hiyerarşik özellikleri yakalamaktan sorumlu olan sıralı evrişim ve alt örnekleme katmanlarını içerir. Bu çalışmada UNet evrişimsel ağ yolunda sekiz evrişim ve üç havuzlama katmanı ve yedi yukarı evrişim, üç yukarı örnekleme ve genişleyen yolda tek bir softmax katmanı dahil olmak üzere dört ana seviyeden oluşur. Tümör tespiti için kullanılan mimarinin detayları Şekil 1'de görülmektedir.



Şekil 1. Beyin tümör tespiti için UNet mimarisi

Şekil 1’de görüldüğü gibi UNet mimarisi, kodlayıcı (encoder) ağındaki her seviyede (PPM #1, 2 ve 3) tekrar tekrar bağlanmasıyla gerçekleştirilir. Böylece, yeniden tasarlanan sık piramit havuzlama ağı, çok uzamli küresel bilgilerin çıkarılmasına ve öğrenilmesine ve bunların kodlayıcı ve kod çözücü ağlar arasında paylaşılmasına olanak tanır. Bununla birlikte, iç içe evrişim blokları veya yoğun bağlantılar kullanarak kodlayıcıyı kod çözücü boşluğu güçlendirilmiş ve orijinal UNet’ten farklılaştırılmıştır. Önerilen çalışma, kullanılan bileşenlerin yani genişletilmiş evrişim ve PPM çeşitli uzamsal ölçeklerin yakalanmasına yol açan her ağ katmanı aracılığıyla küresel çok ölçekli bağlamsal bilgiden tam olarak yararlanmak için yeniden tasarlanma şekline dayanır ve böylece giriş çözünürlüğü kaybını en aza indirir. Daha spesifik olarak PPM #1 ve 2’de olduğu gibi erken kodlayıcı düzeyinde PPM’nin uygulanması küresel ince taneli ve yapısal ayrıntıların öğrenilmesine ve ayrıca PPM kodlayıcının tepesindeyken giriş çözünürlüğünün (PPM #3) korunmasına neden olur. Şekil 2’de beyin tümör tespiti için blok diyagram verilmiştir.



Şekil 2. Beyin tümör tespiti için blok diyagram

## A. DEĞERLENDİRME KRİTERLERİ

Önerilen model, duyarlılık (Sensitivity), özgüllük (Specificity), doğruluk (Accuracy), Zar benzerlik katsayısı (Dice Similarity Coefficient), Jaccard indeksi ve Matthew korelasyon katsayısı dahil olmak üzere çeşitli performans değerlendirme ölçütleri kullanılarak değerlendirilmiştir. Duyarlılık (Eş. 3), yüksek duyarlılığa sahip bir testte negatif sonuç, hastalığı ekarte etmek için yararlıdır. Yüksek duyarlılık testi, sonucu negatif olduğunda güvenilirdir. Özgüllük (Eş. 4), yüksek özgüllüğe sahip bir testte pozitif bir sonuç, hastalıkta karar vermek için yararlıdır. Doğruluk (Eş. 5), yüksek doğruluğa sahip bir test pozitif sonuç verir. Zar benzerlik katsayıları (Eş. 6) olarak da bilinen, Sørensen-Zar indeksi veya sadece zar katsayısı, iki veri kümesi arasındaki benzerliği ölçen istatistiksel bir araçtır. Bu indeks, oluşturulan görüntü segmentasyon algoritmalarının doğrulanmasında en yaygın kullanılan araçtır. Jaccard benzerlik katsayısı (Eş. 7) ya da Jaccard indeksi, kümeler arasındaki benzerliği istatistiksel olarak değerlendirir. Matthew (Eş. 8), çok sınıflı duruma doğal bir uzantıyla makine öğrenimi için standart bir performans analizidir [14].

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

$$\text{Özgüllük (SPE)} = \frac{TN}{TN + FP} \quad (4)$$

$$\text{Doğruluk (ACC)} = \frac{TP + TN}{TP + FN + TN + FP} \quad (5)$$

$$\text{Zar Benzerlik Katsayısı (DSC)} = \frac{2 \cdot TP}{(2 \cdot TP) + FP + FN} \quad (6)$$

$$\text{Jaccard İndeksi (JAC)} = \frac{TP}{TP + FN + FP} \quad (7)$$


$$\text{Matthew (MCC)} = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FN)(TP + FN)(TN + FP)(TN + FN)}} \quad (8)$$

Burada;

TP Doğru Pozitif (True Positive), TN Doğru Negatif (True Negative), FP Yanlış Pozitif (False Positive) ve FN Yanlış Negatiftir (False Negative).


## B. VERİ KÜMESİ

Multimodal Brain Tumor Segmentation Challenge (BraTS), beyin tümörleri ile ilgili yapılan çalışmalarda en büyük veriyi sağlayan kamuya açık veri kümesidir [15]. BraTS 2020 veri kümesi kullanılmıştır. Bu veri kümesi ile eğitim verisi için 18750 görüntü, doğrulama test veri işlemleri için 4650 görüntü kullanılmıştır. Şekil 3’de ham görüntüler sırası ile coronal, sagittal, axial kesitler verilmiştir.



*Şekil 3. (a) Coronal (b) Sagittal ve (c) Axial ham görüntü kesitleri*


Şekil 4’de deneyler sırasında kullanılan veri seti iki kısma ayrılır. Birinci kısım sağlıklı (tümör olmayan) ikinci kısım ise sağlıklı (tümör olan) hasta görüntülerinden oluşmaktadır.



*Şekil 4. Beyin MRI görüntüleri*


Veri kümesi beynin 3 boyutlu olarak çekilmiş MR görüntülerinden oluşmaktadır. Bu veri kümesindeki her görüntü,  $240 \times 240 \times 155$  voksel boyutunda. Bu görüntüler T2 Fluid Attenuated Inversion

Recovery (FLAIR), Kontrastlı T1 ağırlıklı (T1CE), T1 ve T2 olarak adlandırılan 3D MR modalitesini içerir. Şekil 4'te veri kümesinin görselleştirilmiş hali verilmiştir.



Şekil 5. Veri kümesi

Tümör bölgesi T2 ve Flair görüntüsünde belirginlik gösterir. Radyoloji de tümörün ödem kısmı T2 görünümünden çekilir. Flair görünümü ise ödemin beyindeki diğer sıvı dolu yapılardan ayrımını yapmak için kullanılır. Bu çalışmada beyin tümörü tespit edilirken Flair ve T2 görüntüleri beraber incelenir ve eğitime alınır. Flair ve T2 görüntülerin birleştirilmiş durumu Şekil 5'te gösterilmiştir.



Şekil 6. Flair + T2



## C. ÇOK ÖLÇEKLİ ÇOK DÜZEYLİ AĞ İLE BEYİN TÜMÖR TESPİTİ

DeneySEL çalışmalar, NVIDIA GeForce GTX 1050 ekran kartı bulunan bir bilgisayar üzerinde, Python TensorFlow ve Keras kütüphaneleri kullanılarak gerçekleştirilmiştir. Veri kümesi olarak NIFTI formatındaki yüksek çözünürlüklü 18750 örneklem kullanılmıştır. Bu veri kümesinde 18750 örnek eğitim aşamasında 4650 örnek ise modelin test edilmesi aşamasında kullanılmıştır.

Model eğitilirken veri setinde bulunan tüm verileri aynı anda işlemesi bilgisayar donanım gücüne bağlı olarak zaman ve bellek açısından problem oluşturabilir. Batch\_size değeri GPU belleğine uygun kullanmak için 2'nin katları şeklinde belirlenmiştir. Batch\_size değerindeki değişiklikler model başarısında yüksek etkiye sahiptir. Bu çalışmada Tablo-1 ve Tablo-2'de de görüldüğü gibi Batch\_size 16 ve Epoch 30 için en uygun değer %99,45 ile Adam belirlenmiştir.


*Tablo 1. Parametre karşılaştırma*

Batch_Size	Epoch	Acc
4	10	90,50%
4	20	92,60%
4	30	93,20%
8	10	94,50%
8	20	95,20%
8	30	95,80%
16	10	96,90%
16	20	98,20%
16	30	99,45%

*Tablo 2. Optimizer karşılaştırma*

Optimizer	Acc
Adam	99,45%
SGD	89,60%
RMSprop	98,60%
Adagrad	90,70%
Adadelta	92,80%

Şekil 8'de Flair, T2, T1ce, UNet ve UNet++. Önerilen yöntem, veri görselleştirilmiş durumu verilmiştir. Tümör bölgesinin yüksek derece benzerliği ile başarılı bir sonuç vermiştir.




*Şekil 7. Tümör Segmentasyon*

Bu çalışmada 18750 beyin MRI görüntü üzerinde deneysel çalışma yapılmıştır. 14690 tümör olan (pozitif) örneklem ile tümör olmayan 4060 örneklem kullanıldı. Veri kümesinin büyüklüğü modeli daha başarılı hale getirdiği gözlemlendi. Modelin karışıklık matrisi (confusion matrix) değerleri Tablo-3'de verilmiştir.

**Tablo 3.** *Karışıklık Matrisi (Confusion Matrix)*


	<b>Tahmin (Negatif)</b>	<b>Tahmin (Pozitif)</b>
<b>Gerçek (Negatif)</b>	3995	65
<b>Gerçek (Pozitif)</b>	40	14650

Model 30 epoch değeri ile eğitilmiş, Dice coefficient değerleri sırası ile 0,9873 ve 0,9851 olarak bulunmuştur. Genişleyen tümör görüntüsünün iç kısmında bulunan küçük Nekroz alanları dahi daha başarılı bir şekilde tespit edilebilmiştir. Şekil 8'de epoch adımları sırasında eğitim ve geçerleme süreçlerindeki dice coefficient grafik görüntüsü verilmiştir.



*Şekil 8. Dice - Coefficient grafiği*

Şekil 9'da epoch adımları sırasında eğitim ve test süreçlerindeki hata oranı (model loss) grafik görüntüsü verilmiştir. Eğitim sırasında hata oranının düşük olması eğitimin başarılı bir yol izlediğini gösterir.



*Şekil 9. Model kayıp eğrisi*

## **IV. SONUÇ VE DEĞERLENDİRME**

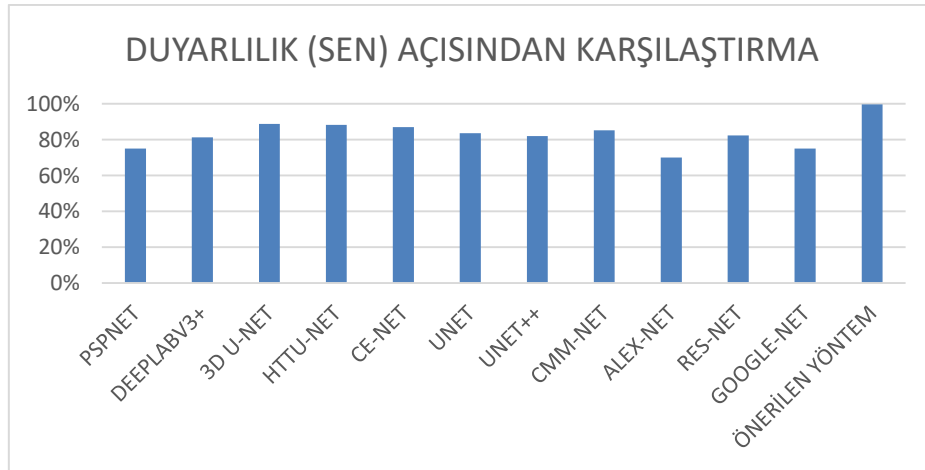
Gerçekleştirilen çalışmada, derin öğrenme UNet algoritması temel alınarak beyin tümör tanısı için yeni ve etkin bir uçtan uca bir segmentasyon ağı kullanılmıştır. Tanı modeli çıkarımında, UNet'in kodlayıcı ağına hem genişletilmiş evrişim hem de piramit havuzlama modüllerinden yararlanılmıştır. Önerilen segmentasyon yöntemi, son derin öğrenme yaklaşımlarına kıyasla beyin tümörleri tespiti üzerinde üstün performans göstermiştir. Ağlar boyunca özellik haritalarının boyutuna bağlı olarak farklı oranlarda alıcı alanın genişlemesini sağlayan genişletilmiş evrişim modülü kullanılır, bu da minimum çözünürlük kaybıyla çok ölçekli bağlamsal bilgilerin yoğun tahminlerini üretmeye yol açar. Kodlayıcı ağıdaki her düzeyde eklenen bloklar, uygun piramit temsillerini içerir. Bu durum uygulanan diğer yöntemlerden farklılığını gösterir. Bu piramit temsiller sayesinde görüntü segmentasyonu diğer mimariler ile karşılaştırıldığında çok daha iyi sonuçlar vermektedir. Gerçekleştirilen deneysel çalışmalarda BraTS 2020 veri kümesinden 18750 örneklem model çıkarımı için kullanılmıştır. 4650 örneklem üzerinde yapılan testte %99,45 doğrulukta tümör tanısı gerçekleştirilmiştir.

Literatürde BraTS 2020 veri kümesini kullanan çalışmalar ile çok düzeyli çok ölçekli ağ modeli ile gerçekleştirilen deneysel çalışma karşılaştırması Tablo-4’de verilmiştir.

**Tablo 4. Tümör segmentasyon performansı**

METHOD	SEN	SPE	ACC	DSC
PSPNET [5]	%74,94	%99,73	%99,38	%76,89
DEEPLABV3+ [16]	%81,30	%99,30	%99,03	%82,86
3D U-NET [17]	%88,70	%99,50	-	%88,90
HTTU-NET [18]	%88,30	%99,90	-	%86,50
CE-NET [20]	%86,91	%99,28	%99,11	%82,90
UNET [21]	%83,63	%98,27	%98,16	%71,28
UNET++ [22]	%82,03	%98,31	%98,10	%83,05
CMM-NET [6]	%85,19	%99,55	%99,35	%83,95
ALEX-NET [8]	%70	%86,21	%79,59	-
RES-NET [8]	%82,35	%87,50	%85,71	-
GOOGLE-NET [8]	%75	%89,66	%83,67	-
<b>ÖNERİLEN YÖNTEM</b>	<b>%99,72</b>	<b>%98,39</b>	<b>%99,45</b>	<b>%99,28</b>


Tablo-4’de görüldüğü gibi; Önerilen çok düzeyli çok ölçekli ağ modelinin literatürde yapılan çalışmalar [5,6,8,16,17,18,20,21,22] ile kıyaslandığında daha iyi sonuçlar verdiği gözlemlenmiştir. Önerilen yöntemin Duyarlılık (SEN) açısından yüzdelerle kıyaslaması Şekil 10’da verilmiştir.



**Şekil 10. Duyarlılık karşılaştırması**

Şekil 6’da görüldüğü gibi; Önerilen yöntem, PSPNET, DEEPLABV3+, 3D U-NET, HTTU-NET, CE-NET, UNET, UNET++, CMM-NET, ALEX-NET, RES-NET, GOOGLE-NET karşılaştırıldığında sırasıyla %33,06, %22,65, %12,42, %12,93, %14,73, %19,23, %21,56, %17,05, %42,45, %21,09 ve %32,95 SEN sonuçları önemli bir artış göstermiştir.

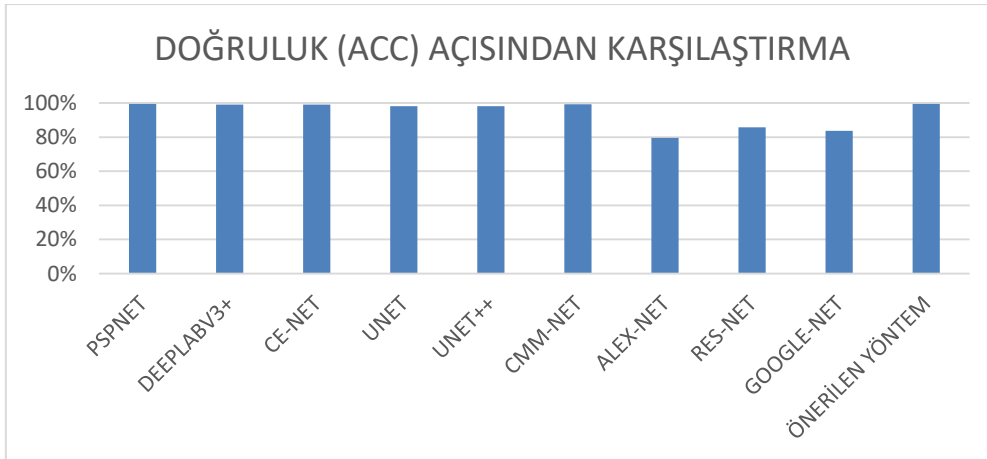
Önerilen yöntemin Özgüllük (SPE) açısından yüzdelerle kıyaslaması Şekil 11’de verilmiştir.



*Şekil 11. Zar benzerlik katsayısı karşılaştırması*

Şekil 11’de görüldüğü gibi; Önerilen yöntem, UNET, UNET++, ALEX-NET, RES-NET, GOOGLE-NET karşılaştırıldığında sırasıyla %0,12, %0,08, %14,12, %12,44 ve %9,73 SPE sonuçları önemli bir artış göstermiştir.

Önerilen yöntemin Doğruluk (ACC) açısından yüzdelerle kıyaslaması Şekil 12’de verilmiştir.



*Şekil 12. Doğruluk karşılaştırması*

Şekil 12’de görüldüğü gibi; Önerilen yöntem, PSPNET, DEEPLABV3+, CE-NET, UNET, UNET++, CMM-NET, ALEX-NET, RES-NET, GOOGLE-NET karşılaştırıldığında sırasıyla %0,07, %0,42, %0,34, %1,31, %1,37, %0,10, %24,95, %16,03 ve %18,85 ACC sonuçları önemli bir artış göstermiştir.

Bilgisayar destekli tanı sistemi özellikle teşhis ve tanı da önemli rol oynamaktadır. Beyin analizi çeşitli yaklaşımlarla bulgular ve anatomik bölgelerin doğru sınıflandırılmasına dayanır. Bu çalışmada insan hayatını olumsuz yönde etkileyen bir hastalığın teşhisine yönelik yöntem geliştirilmiştir. Önerilmiş olan model %99,45 sonucu ile yüksek başarı performansına ulaşmıştır. Aynı model ile ileride tanı ve teşhis için medikal görüntüler üzerinden çalışma yapılabilir.

## **V. KAYNAKLAR**

- [1] H. Mohsen, E.S. El-Dahshan, E.S. El-Horbarty and A.B M.Salem, "Brain tumor type classification based on support vector machine in magnetic resonance images," *Annals of Dunarea de Jos University of Galati*, vol. Fascicle II, Year IX, 2017.
- [2] H. Chen, Q. Dou, L. Yu, J. Qin and P.A Heng, "VoxResNet: Deep voxelwise residual networks for brain segmentation from 3D MR images," *Neuroimage*, vol.170, pp.446-455, 2018.
- [3] S.S. Yadav and S.M. Jadhav, "Deep convolutional neural network based medical image classification for disease diagnosis," *Journal of Big Data*, vol.6, no.1, pp.113, 2019.
- [4] M. A. Al-masni, M. A. Al-antari, J.M Park, G. Gi, T.Y Kim, P.Rivera, E. Valarezo, M.T. Choi, S.M Han and T.S. Kim, "Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system," *Computer Methods and Programs in Biomedicine*, vol.157, pp.85-94, 2018.
- [5] Zhao, Hengshuang, Jianping Shi, Xiaojuan Qi, Xiaogang Wang and Jiaya Jia. "Pyramid Scene Parsing Network." *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp.6230-6239.
- [6] M.A. Al-masni and D.H. Kim, "CMM-Net: Contextual multi-scale multi-level network for efficient biomedical image segmentation," *Scientific Reports*, vol.11, no.1, pp. 10191, 2021.
- [7] O. Yıldız, "Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study," *Journal of the Faculty of Engineering and Architecture of Gazi University* , vol.34, no.4, pp.2241-2260, 2019.
- [8] H. Bingol ve B. Alatas , "Classification of brain tumor images using deep learning methods," *Turkish Journal of Science and Technology*, c. 16, sayı. 1, ss. 137-143, 2021.
- [9] I. Rizwan I Haque and J. Neubert, "Deep learning approaches to biomedical image segmentation," *Informatics in Medicine Unlocked*, vol.18, pp. 100297, 2020.
- [10] F. Bulut, İ. Kılıç ve F. İnce, "Beyin tümörü tespitinde görüntü bölütleme yöntemlerine ait başarımların karşılaştırılması ve analizi," *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, c. 20, ss. 173-186, 2018.
- [11] R. Kijowski, F.Liu, F. Caliva and V.Pedoi, "Deep learning for lesion detection, Progression, and Prediction of Musculoskeletal Disease," *J Magn Reson Imaging*, vol. 52, no. 6, pp.1607-1619, 2020.
- [12] Y. Hou, Z. Liu, T. Zhang and Y. Li, "C-UNet: Complement UNet for remote sensing road extraction," *Sensors (Basel, Switzerland)*, vol. 21, no. 6, pp. 2153, 2021.
- [13] Y.Fisher and K.Vladlen, "Multi-Scale context aggregation by dilated convolutions," *CoRR*, vol. 1511.07122, 2016.
- [14] M. A. Al-masni, M. A. Al-antari, M.T. Choi, S.M. Han and T.S. Kim, " Skin lesion segmentation in dermoscopy images via deep full resolution convolutional networks," *Comput Methods Programs Biomed.* vol.162, pp. 221-231, 2018.

- [15] S. Bakas, M. Reyes, A. Jakab, S. Bauer, M. Rempfler, A. Crimi, "Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge," 2018, arXiv:1811.02629.
- [16] Chen, L.Chieh and Zhu, Yukun and Papandreou, George and Schroff, Florian and Adam, Hartwig. "Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation." 2018, arXiv 1802.02611.
- [17] Isensee, F., Kickingereder, P., Wick, W., Bendszus, M. ve Maier-Hein, "No new-net.", *International MICCAI Brainlesion Workshop*, 2018, pp. 234–244.
- [18] N. M. Aboelenein, P. Songhao, A. Koubaa, A. Noor and A. Afifi, "HTTU-Net: hybrid two track U-Net for automatic brain tumor segmentation," *IEEE Access*, 2020, pp. 101406-101415.
- [19] J. Zhang, Z. Jiang, J. Dong, Y. Hou and B. Liu, "Attention Gate ResU-Net for Automatic MRI Brain Tumor Segmentation," in *IEEE Access*, vol. 8, pp. 58533-58545, 2020.
- [20] Gu, Zaiwang and Cheng, Jun and Fu, Huazhu and Zhou, Kang and Hao, "CE-Net: Context Encoder Network for 2D Medical Image Segmentation," in *IEEE Transactions on Medical Imaging*, vol. 38, no. 10, pp. 2281-2292, 2019.
- [21] R. Olaf and Fischer, P. Brox, Thomas," U-Net: Convolutional Networks for Biomedical Image Segmentation," in *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)*,2015, pp.234-241.
- [22] Z. Zhou, M. M. R. Siddiquee, N. Tajbakhsh and J. Liang. "UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation." *IEEE Transactions on Medical Imaging*, 2020, pp.1856-1867.