

Beyin Tümörü Bölütleme ve Algılamada Yeni Çekişmeli Üretken Ağ Kullanılması

Using a New Generative Adversarial Network in Brain Tumor Segmentation and Detection

Sara ALTUN GÜVEN*¹ , M. Fatih TALU² 

^{1,2}Bilgisayar Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

(sara.altun@inonu.edu.tr, fatihaltu@gmail.com)

Received:Sep.08,2022

Accepted:Sep.16,2022

Published:Oct.10,2022

Özetçe— Tıbbi görüntülerden beyin tümörünün algılanması araştırmacılar için aktif araştırma alanıdır. Tümör dokusunun çeşitliliği ve tümörün karmaşıklığı süreci zorlu hale getirmektedir. Bu çalışmada üç ayrı beyin tümörü veri kümesi oluşturulmuştur. Oluşturulan veri kümeleri iki boyutludur. Birinci veri kümesi 3 boyutlu görüntülerden 2 boyutlu görüntülere hiçbir değişiklik yapmadan dönüştürülen beyin tümörü veri kümesidir. İkinci veri kümesi birinci veri kümesindeki beyin harici kısımların yok edilmesiyle elde edilmiştir. Üçüncü veri kümesi ise beyin tümörünü daha iyi algılayabilmek için ikinci veri kümesi üzerinde görüntüyü keskinleştirip Gauss Filtresi ekleyerek elde edilmektedir. Buradaki amaç veri kümelerinin eğitim ve test sonuçlarına etkisini gözlemleyebilmektir. Bu çalışmada, beyin tümörü bölütlenirken ve algılanırken yeni Çekişmeli Üretken Ağ önerilmiştir. Önerilen yöntem beyin tümörünü manuel olarak değil otomatik bir şekilde yapabildiği için avantajlıdır. Önerilen yöntem SSimDCL (Supervised Similarity Dual Contrastive Learning) olarak adlandırılmıştır. Önerilen yöntem günümüzde derin öğrenme mimarileri arasında en iyi sonucu veren nnU-Net ile kıyaslanmaktadır. Kıyaslama yapılırken LPIPS ve PSNR yöntemleri tercih edilmiştir. Yapılan deneysel çalışmalar sonucunda önerilen yöntemin veri kümesi iyileştikçe daha iyi sonuçlar verdiği gözlemlenmiştir. nnU-Net yöntemi metrik olarak daha iyi olmasına rağmen görsel sonuçlar duyuşsal olarak kıyaslandığında önerilen yöntemin daha iyi olduğu görülmüştür.

Anahtar Kelimeler: Görüntü bölütleme, derin öğrenme, evrişimsel sinir ağı, çekişmeli üretken ağlar, karşılaştırmalı öğrenme

Abstract— Brain tumor detection from medical images is an active area of research for researchers. The diversity of tumor tissue and the complexity of the tumor makes the process challenging. In this study, three separate brain tumor datasets were created. The generated datasets are two-dimensional. The first dataset is the brain tumor dataset, which is converted from 3D images to 2D images without any changes. The second dataset was obtained by eliminating the non-brain parts in the first dataset. The third dataset is obtained by sharpening the image on the second dataset and adding a Gaussian Filter to better detect the brain tumor. The aim here is to observe the effect of datasets on training and test results. In this study, the new Generative Adversarial Network is proposed when segmenting and detecting brain tumors. The proposed method is advantageous as it can make the brain tumor automatically, not manually. The proposed method is named SSimDCL (Supervised Similarity Dual Contrastive Learning). The proposed method is compared with nnU-Net, which gives the best results among deep learning architectures today. While comparing, LPIPS and PSNR methods were preferred. As a result of the experimental studies, it has been observed that the proposed method gives better results as the dataset improves. Although the nnU-Net method is better metrically, it was seen that the proposed method was better when the visual results were compared sensorially.

Keywords: Image segmentation, deep learning, convolutional neural network, adversarial generative networks, contrastive learning

1.Giriş

Manyetik rezonans görüntüleme (MRI) ile beyin tümörünün algılanması gibi tıbbi görüntülerde inceleme ve analiz oldukça zordur. Bu süreci tümörün karmaşıklığı ve dokusunun çeşitliliği daha da zorlu hale getirmektedir. Buna benzer sorunlar tümör algılama metodlarının ihtiyacını arttırmaktadır.

Hem hasta hakkında bilgi edinmede hem de klinik tanı koymada beyin tümörü görüntülerinin analizi büyük bir öneme sahiptir. Beyin tümörü, beyindeki hücrelerin normalinden daha farklı boyut ve şekillerde büyümesi olarak bilinir. Beynin içerisinde istenmeyen hücre kümeleri de beyin tümörü olarak ifade edilmektedir. Tümörler genel olarak iyi huylu ve kötü huylu olarak ikiye ayrılmaktadır. Meme ve akciğer gibi diğer vücut kısımlarından başlayıp beyne geçen tümör kötü huylu olarak bilinir.

Beyin tümörünün doğru bir şekilde bölütlenmesi, tıbbi araştırmalardaki tanı, tedavi ve ilerleyişinin gözlenmesi bakımından önemlidir. Beyin tümörünün konum, boyut ve şekil açısından heterojen olması bölütleme işlemini zorlaştırmaktadır. Aynı zamanda kendini beyin dokusunun içerisine gizlediği için de fark edilmesi güçtür. Genelde yapılan tümör bölütlemeleri manuel olarak bir uzman tarafından anatomik anormallikler incelenerek yapılmaktadır.

Manuel bölütleme yapılırken daha detaylı bilgi elde edinebilmek için çoklu MRI görüntülerine T1, T1 karşıt (T1c), T2 ve FLAIR gibi veriler entegre edilmiştir. Manuel bölütleme bu gibi sebeplerden ötürü gözlemciler arasında ön yargıya sebebiyet verir ve zaman alıcıdır. Bu gibi zorluklardan dolayı klinik mekânlarda faydalı olması açısından beyin tümöründe otomatik işlemlerin kullanılması önem arz etmektedir.

Araştırmaların kolaylıkla inceleme yapıp yeni yöntemler üretebilmesi için açık kaynak kodlu Beyin Tümörü Bölütlemesi (BraTS) veri kümesi mevcuttur (BraTS, 2019). Bu veri kümesi çoğunlukla ameliyat öncesindeki beyin tümörü görüntülerini barındırmaktadır. Beyin tümör kısmı; tam tümör, güçlendirici çekirdek ve tümör çekirdeğine bölünür.

Bir çok alanda bölütleme yapılırken otomatikleştirme temel alınmıştır. Vasilakos ve arkadaşları 2016 yılında tıbbi uygulamalarda bölütleme (Vasilakos vd., 2016), Kooi ve arkadaşları 2017 yılında memedeki lezyonların bilgisayar destekli tanınması (Kooi vd., 2017), Cheng ve arkadaşları 2016 yılında meme lezyonlarının ve pulmoner nodüllerin tanımlanması (Cheng vd., 2016) ve Litjens ve arkadaşları tarafından 2016 yılında histopatolojik saptama (Litjens vd., 2016) olarak da uygulanmıştır.

Beyin tümörünü otomatik hale getirebilmek için birçok çalışma yapılmıştır. Chen ve arkadaşları 2009 yılında beyin tümörü bölütlemesi gerçekleştirirken proton yoğunluğu içeren ve üstün kontrasta hakim T1 görüntüler kullanmışlardır (Chen vd., 2009). Saoluli ve arkadaşları 2018 yılında beyin tümörü bölütlenmesi işleminde utan uça artımlı Evrişimli Sinir Ağı mimarisindeki tam otomatik yaklaşımları kullanan, toplu öğrenimi benimseyen ve sonuç olarak doğru sonuç, verimli performans ve optimize edilmiş mimari gibi avantajları tanıtmışlardır(Saouli vd., 2018).

Chen ve arkadaşları 2018 yılında 3 boyutlu ayrılabilir U-Net kullanan S3D-UNet bölütleme yöntemini önermişlerdir (Chen vd., 2018). S3D-UNet, beyin tümörünü otomatik olarak sentezleme görevini gerçekleştirmektedir. Önerdikleri mimari, temel U-Net yapısını kullanan sagittal, koronal ve eksenel olmak üzere paralel bir şekilde üç branş içermektedir.

Çekişmeli Üretken Ağlar; nesne tanıma, görüntüleri sınıflandırma, yüksek çözünürlüklü görüntü oluşturma ve birçok alanda ilgi odağıdır. ÇÜA'lar tıbbi görüntü bölütleme sonuçlarını sürekli hale getirmektedir. Aynı zamanda görüntünün bölütleme sonuçlarını manuel değil de otomatik şekilde çözmesi bakımından avantajlıdır.

Luc ve arkadaşlarının 2016 yılında yazdığı "Zararlı Ağları Kullanarak Anlamsal Bölütleme" başlıklı makalesi çekişmeli ağ kullanarak görüntü bölütleme işlemi uygulayan ilk ÇÜA çalışmasıdır (Luc vd., 2016). 2017 yılında Li ve diğerleri beyin tümörlerini ÇÜA tabanlı yöntemleri beyin tümörlerini etkili şekilde bölütlemeye kullanılmıştır (Li vd., 2017). Xue ve arkadaşları 2018 yılında beyin tümörlerinin direk ve etkili bölütleme yapılabilmesi için çok ölçekli L1 kaybı önermiştir (Xue vd., 2018). Bunu

yaparken ÇÜA'nın temel yapıtaşlarından olan U-net kısmını kullanmışlardır (Xue vd., 2018). Conte ve arkadaşları 2021 yılında ÇÜA'ları eksik MRI dizilerini bölütlerken kullanmışlardır. ÇÜA sonucunda oluşturulan görüntülerin diğer derin öğrenme modellerine göre bölütleme yapılırken daha etkili bir şekilde yardımcı olabileceğini kanıtlamışlardır (Conte vd., 2021).

Bu makalede, hem kontrastlı ağ hem de ÇÜA'ları kullanan yeni bir mimari önerilmiştir. Önerilen mimari denetimlidir. Önerilen yöntem denetimli SimDCL (SSimDCL / Supervised SimDCL) olarak adlandırılmıştır. SSimDCL görüntü bölütlemeye ve nesne algılamada başarılı sonuçlar verdiği gözlemlenmiştir.

Bu çalışmada SSimDCL ayrıntılı bir şekilde açıklanmıştır. Beyin tümörü bölütlenirken günümüzde başarılı sonuçlar veren nnU-Net yöntemi ile SSimDCL kıyaslanmasına yer verilmiştir. Veri kümesi olarak üç ayrı beyin tümörü veri kümesi kullanılmıştır (Orijinal, fazlalıkları elimine edilmiş, çözünürlüğü artırılmış beyin MRI veri kümeleri). Sonuçlar görsel ve metriksel olarak incelenmiştir.

Bu makalenin temel katkısı, derin öğrenme mimarilerinden en iyi sonuç veren yöntemle (nnU-Net) önerilen yönteminin ne kadar başarılı elde ettiğini incelemektir. Sonuç olarak SSimDCL yönteminin beyin tümörü algılayabildiği gözlemlenmiştir.

Makalenin kalan organizasyonu şu şekilde ilerlemektedir: Bölüm 2'de kullanılan yöntemlere (SSimDCL, nnU-Net); Bölüm 3'te eğitim detaylarına; Bölüm 4'te kullanılan veri kümesine; Bölüm 6'da bu bölüm için kullanılan ölçüm metriklerine ve Bölüm 8.4'te yapılan deneysel çalışmalar ve sonuçlarına yer verilmiştir.

2. Yöntemler

2.1. SSimDCL (Önerilen Yöntem)

Önerilen yöntem görüntü sentezleme, bölütleme ve algılamada otomatik olarak kullanılabilir. SSimDCL yöntemi, karşılıklı bilgiyi artırıp üst seviyeye çıkarmak için iki ayrı gömülü sistem kullanmaktadır. Eğitim yapılırken DCLGAN (Han vd., 2021) mimarisinde eşlenmiş şekilde gelen görüntülerin yerine eşlenmiş görüntüler kullanılır.

SSimDCL yönteminde amaç mimarinin denetimli ve eşlenmiş bir şekilde çalışmasını sağlamaktır. Bu işlemi gerçekleştirebilmek için SSimDCL mimarisindeki gerçek ve oluşturulmuş sentetik görüntü arasına L_1 metriği eklenmiştir.

SSimDCL yöntemi, özdeşlik (Identity / $\mathcal{L}_{identity}$), tartışmalı (Adversarial) ve CUT (Park vd., 2020) yönteminde de kullanılan parçalı gürültü karşılaştırmalı tahminleme (PatchNCE / $\mathcal{L}_{PatchNCE}$) kaybını kullanır. Mod çökmesinin önüne geçmek için SimDCL (Han vd., 2021) yönteminde kullanılan benzerlik kaybını (\mathcal{L}_{sim}) kullanır.

Gerçek ve sentetik görüntü arasında L_1 kaybını kullanmış olması diğer yöntemlerden farklılığını sergilemektedir.

SSimDCL yönteminin eğitim sonuçları incelendiğinde özdeşlik sonucu oluşturulan görüntülerin çözünürlüğünün gerçek görüntülerde iyi olduğu gözlemlenmiştir. Denetimli ve eşlenmiş görüntüler üzerinde çalışan bu yöntemin gerçek görüntüye daha çok benzediği gözlemlenmiştir. Denetimli önerilen SSimDCL mimarisi Şekil 1'de açıkça gösterilmektedir.

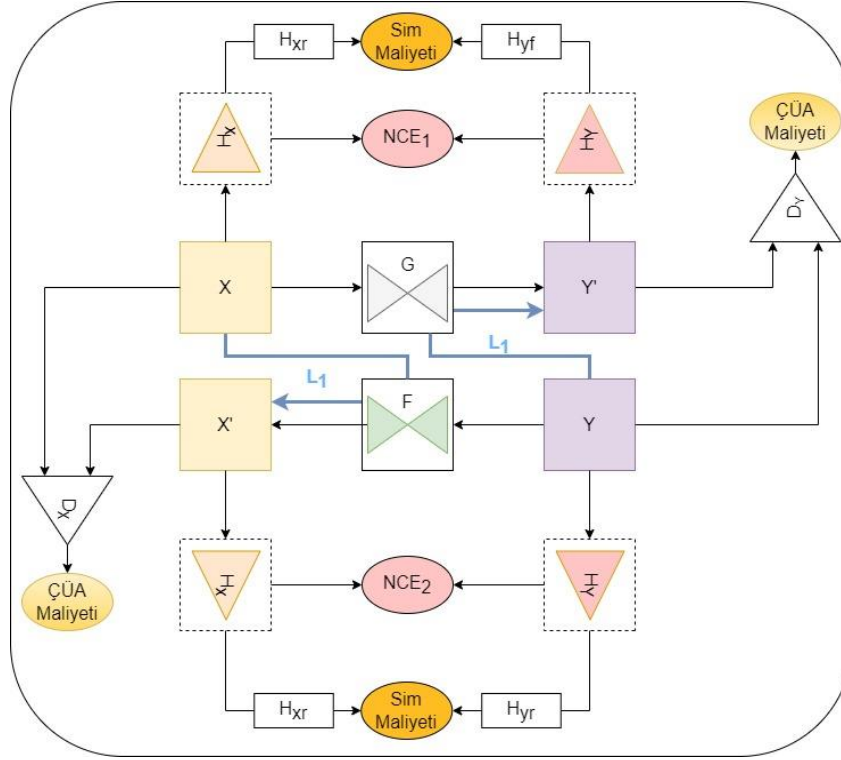
L_1 loss. Denetimsiz olan sistemi denetimli hale getirebilmek için gerçek görüntü ile oluşturulan görüntü arasında hesaplanmaktadır. Eşitlik 1'de L_1 loss'un nasıl hesaplandığına yer verilmiştir.

SSimDCL yöntemin amaç fonksiyonu Denklem 1'de verilmiştir.

$$\begin{aligned}
G^*, F^* = \underset{G, F, D_X, D_Y}{\operatorname{argmin}} \max \mathcal{L}(G, F, D_X, D_Y, H_X, H_Y) \\
= \lambda_{GAN} \left(\mathcal{L}_{GAN}^G(G, D_Y, X, Y) + \mathcal{L}_{GAN}^F(F, D_X, Y, X) \right) \\
+ \lambda_{NCE} \left(\mathcal{L}_{PatchNCE_X}(G, H_X, H_Y, X) + \lambda_{NCE} \mathcal{L}_{PatchNCE_Y}(F, H_X, H_Y, Y) \right) \\
+ \lambda_{sim} \mathcal{L}_{sim}(G, F, H_X, H_Y, H_{xr}, H_{xf}, H_{yr}, H_{yf}) \\
+ \lambda_{idt} \left(\mathcal{L}_{identity}(G, F) + \mathcal{L}_{identity}(G, F, X, Y) \right)
\end{aligned} \tag{1}$$

Burada $\lambda_{GAN} = 1$, $\lambda_{NCE} = 2$ ve $\lambda_{sim} = 10$ ve $\lambda_{idt} = 1$ olarak alınmıştır.

Şekil 1’de ise SSimDCL (önerilen yöntem) mimarisine yer verilmiştir. SSimDCL, $\mathcal{L}_{identity}(G, F)$ kaybı ile sentetik görüntülerdeki piksel kaybının daha az gözlemlenmiştir. Aynı zamanda oluşturulan görüntülerin gerçek görüntülere göre çözünürlüğü daha iyi çıkmaktadır. Çözünürlüğü daha iyi olduğu için önerilen yöntemin eğitilmesi sonucunda $\mathcal{L}_{identity}(G, F)$ kaybı ile oluşturulan görüntülerle yeni veri kümesi elde edilmiştir. SSimDCL yönteminde; iki üretici, iki ayrıştırıcı ve dört özellik çıkarıcı ağ bulunmaktadır.



Şekil 1. Beyin MRI bölütleme için önerilen yöntemin mimarisini

2.2. nnU-Net

Isense ve arkadaşları tarafından 2021 yılında derin öğrenme tabanlı nnU-Net yöntemi önerilmiştir. Yapılan çalışmada, bölütleme görevi için ağ mimarisini, ön işleme, son işleme ve eğitim de dahil olmak üzere bu işlemleri otomatik olarak gerçekleştirebilen nnU-Net’i geliştirmişlerdir (Isense vd., 2021).

nnU-Net yöntemi, 23 açık kaynaklı veri kümesinde yapılan uluslararası biyomedikal bölütleme yarışmalarında mevcut yaklaşımların son derece uzmanlaşmış olan yöntemler de dahil olmak üzere çoğunu geride bırakmıştır.

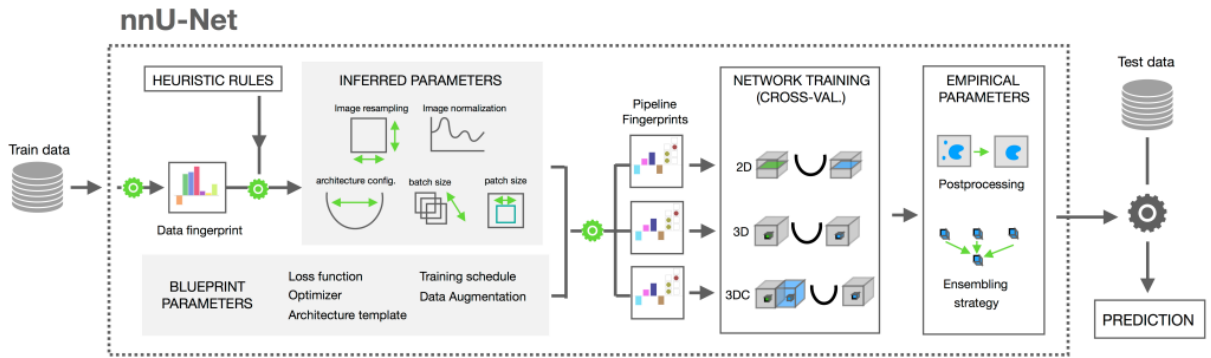
nnU-Net yöntemi ne uzman bilgisine ne de bilgi işlem kaynaklarına gerek duymadan son teknoloji bölütlemesini gerçekleştirmektedir. nnU-Net, hazır bir araç olarak herkese açık halde görüntü

bölütlemeye ve nesne algılamada kullanılabilir. nnU-Net, 13 ek veri kümesinde otomatik olarak ayarlanabildiği gösterilmektedir. Bu yöntemde toplamda 53 adet bölütleme sonucu analiz edilmiştir. Yapılan analizler sonucunda nnU-Net'in çoğu yöntemi geride bıraktığı gözlemlenmiştir.

nnU-Net yöntemi, Antonelli ve diğerleri tarafından 2021 yılında sunulan Medical Segmentation Decathlon (Antonelli vd., 2021) tarafından sağlanan on veri kümesi üzerinde geliştirilmiş ve doğrulanmıştır.

nnU-Net, herhangi bir veri kümesi için otomatik yapılandırmayı gerçekleştirebilir. nnU-Net yöntemi işlemlerin basit bir şekilde ilerletilmesini ve sadece birkaç deneysel seçimin yapılmasını içermektedir. Çoğu görevi hızlı bir şekilde gerçekleştirmektedir. Model eğitiminin ötesinde neredeyse hiç hesaplama kaynağı gerektirmez.

Sonuç olarak nnU-Net yöntemi, veri açısından verimlidir. Geniş ve farklı türde veri havuzuna dayanan kısımlarda ve sınırlı eğitim verisine sahip veri kümelerinde de verimli sonuçlar verdiği gözlemlenmiştir (Isense vd., 2021).



Şekil 2. nnU-Net mimarisi (Isense vd., 2021)

Şekil 2’de nnU-Net’in genel mimarisine yer verilmiştir. Bu mimarinin ilk aşamasında veri kümesindeki özellikler önemli özelliklerine göre özetlenir (“Şekil 2’deki data fingerprint (veri parmak izi) kısmı”). İşlem hattının verilere göre hiperparametrelerini çıkarmada bir dizi buluşsal kural çalışır (Şekil 2’deki HEURISTIC RULES öncesindeki Data fingerprint (parmak izi) birleştirilir). Verilerden bağımsız bir şekilde seçenekleri olan plan parametreleriyle tamamlanır (INFERRED ve BLUEPRINT PARAMETERS). 5 katlı doğrulama yapılarak üç mimari eğitilir (5-fold cross validation). Son aşamada ise nnU-Net bu mimarilerin en uygun grubunu otomatik olarak seçer ve gerekirse son işlemeyi gerçekleştirir. Sonuç olarak, nnU-Net mimarisi için bölütleme işlemi gerçekleştirilmiştir.


3. Deneysel Sonuçlar

3.1. Eğitim detayları

SSimDCL yöntemi eğitilirken DCLGAN (Han vd., 2021) yönteminin ayarları örnek alınmıştır. $\beta_1 = 0.5$ ve $\beta_2 = 0.999$ ile Adam optimizasyonu (Diederik ve Jimmy, 2014) kullanılmıştır. SSimDCL ve nnU-Net yöntemi, 100 iterasyon eğitilmiş ve sonuç alınmıştır. Öğrenme oranı 0.0001 olarak alınmıştır. Kaiming ve diğerleri tarafından 2016 yılında önerilen ResNet (Kaiming vd., 2016) tabanlı üretici ağ ve Isola ve arkadaşları tarafından 2017 yılında önerilen PatchGAN (Isola vd., 2017) ayrıştırıcı ağ kullanılmıştır. Parça boyutu olarak 1 alınmıştır. Örnek normalleştirme (Instance normalization) kullanılmıştır. Eğitilecek veri kümesindeki görüntülerin boyutları 256x256 boyutundadır.


3.2. Veri Kümesi

Veri kümesi olarak Antonelli ve arkadaşlarının 2021 yılında önerdiği Medical Segmentation Decathlon içerisinde bulunan beyin tümörü veri kümesi görüntüleri üzerinde çalışmalar yapılmış ve sonuçlar elde edilmiştir. Normal şartlarda beyin tümörü veri kümesi 4 boyutlu verilerden oluşmaktadır. nnU-Net öncelikle bu veri kümesini 4 boyutludan 3 boyutlu hale getirir. Eğitim aşamasında 33 beyin tümörü maskesi ve görüntüsü kullanılmıştır. Test aşamasında ise 10 adet beyin tümörü maskesi ve görüntüsü kullanılmıştır. SSIMDCL yöntemi için 3 boyutlu görüntüler 2 boyutlu görüntülere çevrilerek kullanılmıştır. 2 boyutlu görüntüye çevrim işlemi Matlab 2019b ortamı kullanılmıştır. Oluşturulan görüntülerin hepsi $256 \times 256 \times 3$ boyutundadır. İlk aşamada oluşturulan veri kümesi 3 boyutludan doğrudan iki boyutluya dönüştürülerek kullanılmıştır. Birinci aşamada oluşturulan verilerin örnekleri Şekil 3’de gösterilmiştir.



Şekil 3. Orijinal Veri Kümesi (a) Tüm beyin (b) a'dan elde edilen beyin tümörü


İkinci kısımda oluşturulan veri kümesi 2 boyuta dönüştürülen beyin MRI görüntülerinin (Örneğin, Şekil 3) beyin görüntüsünün dışarısında kalan siyah kısımlarının kırılıp görüntünün özelliğini koruyarak tekrardan 256×256 boyutunda görüntülerden oluşmaktadır. Burada amaç sadece beyin görüntülerinin kalmasıdır. Fazlalıklarının elimine edildiği beyin MRI veri kümeleri Matlab 2019 ortamında oluşturulmuştur. Maske görüntüleri gerçek görüntüleri indis olarak tümörlü kısmın görüntüdeki aynı piksellere denk geleceği şekilde kırılmıştır. Şekil 4’te bu görüntülere yer verilmiştir.



Şekil 4. Fazlalıkları Elimine Edilmiş Veri Kümesi (a) Tüm beyin (b) a'dan elde edilmiş beyin tümörü


Üçüncü kısımda oluşturulan veri kümesi ikinci kısımda oluşturulan veri kümesindeki görüntülerin özelliklerinin iyileştirilmesi ile elde edilmiştir. Oluşturulan görüntülerin çözünürlüğü diğer veri kümelerindeki görüntülere göre daha yüksektir. Beyin MRI görüntüleri üzerinden iyileştirme yapılırken Matlab 2019b ortamı kullanılmıştır. Görüntü iyileştirilmesi yapılırken ilk aşamada görüntünün ışık

ayarlaması ve keskinleştirilmesi yapılmıştır. İkinci ve son aşamasında ise Gauss Filtresi uygulanmıştır. Gauss Filtresi'ndeki standart sapma 0.2 alınmıştır. Bu işlemler bir görüntü üzerinde aşamalı şekilde uygulanarak beyin tümörü ve maskesinin iyileştirilmesi sağlanmış ve çözünürlüğü artırılmış veri kümesi oluşturulmuştur. Şekil 5'te çözünürlüğü artırılmış beyin MRI görüntülerine yer verilmiştir.



Şekil 5. Çözünürlüğü Arttırılmış Veri Kümesi (a) Tüm beyin (b) a'dan elde edilen beyin tümörü

Şekil 6'da bahsi geçen üç veri kümesinin aşamalı değişimleri kısaca gösterilmiştir.



Şekil 6. Veri Kümeleri (a) Orjinal (b) Fazlalıkları elimine edilmiş (c) Çözünürlüğü arttırılmış


3.3. Yöntemlerin Uygulanması

Bu bölümde önerilen yöntem (SSimDCL) ile güncel en iyi sonuç veren yöntemlerin kıyaslanmasıdır. Kıyaslama yapılırken beyin MRI tümör görüntüleri üzerinde volBrain (), nnU-Net () ve SSimDCL yöntemleri karşılaştırılmıştır. volBrain yönteminin sadece dokusal bölütleme yaptığından nesne algılamada yani beyin tümörü bölütlemesinde başarılı olmadığı gözlemlenmiştir. Bundan dolayı sadece nnU-Net ile SSimDCL yönteminin deneysel sonuçlarına yer verilmiştir.

Kıyaslama yapılırken aynı özellikler temel alınarak 2 boyutlu beyin MRI tümör görüntüleri üzerinde test sonuçları değerlendirilmiştir. Beyin MRI tümörü bölütlemesi uygulanırken üç adet veri kümesi kullanılmıştır. Oluşturulan veri kümeleri Bölüm 3.2'de detaylı bir şekilde açıklanmıştır.


Yapılan birinci çalışmada normal veri kümesi üzerinden nnU-Net ve önerilen yöntemin beyin tümörü bölütlemedeki başarımı hem görsel hem de tablosal olarak yorumlanmıştır.

Şekil 7’de nnU-Net ve önerilen yöntemin (SSimDCL) orjinal veri kümesine beyin tümörü bölütlemeye görsel sonuçları gösterilmektedir.




Şekil 7. nnU-Net ve önerilen yöntemin (SSimDCL) orijinal veri kümesine göre kıyaslanması

Şekil 8’de nnU-Net ve önerilen yöntemin (SSimDCL) fazlalıkları elimine edilmiş veri kümesine göre beyin tümörü bölütlemeye görsel sonuçları gösterilmektedir.



Şekil 8. nnU-Net ve önerilen yöntemin (SSimDCL) fazlalıkları elimine edilmiş veri kümesine göre kıyaslanması

Beyin tümörünün daha iyi algılanıp bölütlenmesi için görüntülerin keskinleştirilip Gauss Filtresi eklendikten sonraki nnU-Net ve önerilen yöntemin kıyaslama sonuçlarına Şekil 9’da yer verilmiştir.



Şekil 9. İyileştirilen veri kümesine göre nnU-Net ve önerilen yöntemin görsel kıyaslanması

Şekil 7, Şekil 8 ve Şekil 9 duyuşal analiz yapılarak incelenmiştir. Önerilen yöntemin iyileştirilmiş görüntüler üzerindeki sonuçlarının (Şekil 9) nnU-Net'e göre başarılı olduđu ve hatta orijinal beyin tümörü bölütlenirken gerçek maskesinden daha yumuşak çizgileri olduđu gözlemlenmiştir.

Tablo 1'de sırasıyla orijinal veri kümesi, fazlalıkları elimine edilmiş veri kümesi ve çözünürlüğü artırılmış veri kümesinin önerilen yöntem ve nnU-Net üzerindeki LPIPS ve PSNR metriksel sonuçlarına yer verilmiştir. Kalın biçimde verilen sonuçlar en iyi yöntemi, altı çizili şekilde verilen sonuçlar ikinci iyi çıkan yöntemi göstermektedir.

Orijinal beyin MRI tümör veri kümesi için 0.043 LPIPS ve 43.882 PSNR ile nnU-Net yöntemi başarılıdır. Fazlalıkları elimine edilmiş veri kümesinde 0.095 LPIPS ve 38.883 PSNR ile nnU-Net yöntemi başarılıdır. Fakat orijinal veri kümesi ile fazlalıkları elimine edilmiş veri kümesindeki sonuçlar önerilen yöntemin sonuçlarını iyi yönde değiştirmiştir ve nnU-Net ile aralarındaki farkta azalma

gözlemlenmiştir. Son olarak çözünürlüğü artırılmış veri kümesine bakıldığında 0.095 LPIPS ve 38.510 PSNR ile nnU-Net yöntemi birinci, 0.096 LPIPS ve 38.556 PSNR ile önerilen yöntem ikinci sıradadır. Çözünürlüğü artırılmış veri kümesi sonuçları incelendiğinde önerilen yöntemin nnU-Net yöntemine çok yakınlaştığı gözükmektedir.

Tablo 1. Önerilen yöntem ve nnU-Net yönteminin metriksel kıyaslanması

Orijinal veri kümesi	LPIPS ↓	PSNR ↑
Önerilen Yöntem (SSimDCL)	<u>0.092</u>	<u>41.288</u>
nnU-Net	0.043	43.882
Fazlalıkları elimine edilmiş veri kümesi		
Önerilen Yöntem (SSimDCL)	<u>0.119</u>	<u>38.792</u>
nnU-Net	0.095	38.883
Çözünürlüğü artırılmış veri kümesi		
Önerilen Yöntem (SSimDCL)	<u>0.096</u>	<u>38.556</u>
nnU-Net	0.095	38.510

4. Sonuç

Bu makalede yapılan çalışmada önerilen yöntemin ve nnU-Net yönteminin beyin tümörü bölütlemeye üç ayrı veri kümesi üzerindeki verimliliği incelenmiştir. Beyin MRI tümör veri kümesinin birinci aşamasındaki orijinal verilerin direk alınıp biriktirilmesiyle oluşturulmuştur. İkinci kısımda oluşturulan veri kümesi, birinci aşamada elde edilen beyin MRI tümör görüntülerinin fazlalıklarının elimine edilmesiyle elde edilmiştir. Üçüncü kısımdaki veri kümesi ise görüntüler üzerinde keskinleştirme ve görüntü ayarlaması yapıldıktan sonra gauss filtresi eklenen çözünürlüğü artırılmış beyin MRI tümörü görüntüleridir. Bahsedilen veri kümeleri belirlenen sırayla 100 iterasyon eğitilmiştir. Eğitim sonuçları görsel ve tablosal olarak sunulmuştur. Sırasıyla Şekil 6 orijinal veri kümesi ve Şekil 7 fazlalıkları elimine edilmiş veri kümesi üzerinde nnU-Net ve önerilen yöntem kıyaslandığında nnU-Net yönteminin başarılı olduğu gözlemlenmiştir. Şekil 9'daki çözünürlüğü artırılmış veri kümesi üzerinde ise önerilen yöntemin nnU-Net yöntemine kıyasla daha iyi sonuç verdiği gözlemlenmiştir. Tablo 1'de sırasıyla veri kümelerine göre nnU-Net ve önerilen yöntemin LPIPS ve PSNR metriksel benzerlik sonuçlarına yer verilmiştir. Görüntüler iyileştikçe önerilen yöntemin daha başarılı sonuçlar verdiği gözlemlenmiştir. Bu çalışmada sonuç olarak, nnU-Net yönteminin başarılı bir beyin tümörü bölütleyicisi olduğu gözlemlenmiştir. Önerilen yöntemin ise görüntü iyileştirildikçe nnU-Net'e neredeyse benzer sonuçlar ürettiği gözlemlenmiştir. Gelecek çalışmalarda önerilen yöntemin geliştirilmesi amaçlanmaktadır.

Teşekkür

Bu çalışma İnönü Üniversitesi Bilimsel Araştırma ve Koordinasyon birimi tarafından "FDK-2021-2675" proje numarası ile finanse edilmiştir. İnönü Üniversitesi'ne teşekkürlerimizi sunarız.

Kaynaklar

BRATS. (erişim: 20.05.2022). Bmultimodal brain tumor segmentation challenge 2019. 2019. <http://braintumorsegmentation.org/>

- Chen, P. F., Steen, R. G., Yezzi, A., & Krim, H. (2009, April). Brain MRI T1-Map and T1-weighted image segmentation in a variational framework. In 2009 IEEE International Conference on Acoustics, Speech and Signal Processing (pp. 417-420). IEEE.
- Vasilakos, A. V., Tang, Y., & Yao, Y. (2016). Neural networks for computer-aided diagnosis in medicine: a review. *Neurocomputing*, 216, 700-708.
- Kooi, T., Litjens, G., Van Ginneken, B., Gubern-Mérida, A., Sánchez, C. I., Mann, R., ... & Karssemeijer, N. (2017). Large scale deep learning for computer aided detection of mammographic lesions. *Medical image analysis*, 35, 303-312.
- Cheng, J. Z., Ni, D., Chou, Y. H., Qin, J., Tiu, C. M., Chang, Y. C., ... & Chen, C. M. (2016). Computer-aided diagnosis with deep learning architecture: applications to breast lesions in US images and pulmonary nodules in CT scans. *Scientific reports*, 6(1), 1-13.
- Litjens, G., Sánchez, C. I., Timofeeva, N., Hermsen, M., Nagtegaal, I., Kovacs, I., ... & Van Der Laak, J. (2016). Deep learning as a tool for increased accuracy and efficiency of histopathological diagnosis. *Scientific reports*, 6(1), 1-11.
- Saouli, R., Akil, M., & Kachouri, R. (2018). Fully automatic brain tumor segmentation using end-to-end incremental deep neural networks in MRI images. *Computer methods and programs in biomedicine*, 166, 39-49.
- Chen, W., Liu, B., Peng, S., Sun, J., & Qiao, X. (2018, September). S3D-UNet: separable 3D U-Net for brain tumor segmentation. In *International MICCAI Brainlesion Workshop* (pp. 358-368). Springer, Cham.
- Luc, P., Couprie, C., Chintala, S., & Verbeek, J. (2016). Semantic segmentation using adversarial networks. *arXiv preprint arXiv:1611.08408*.
- Li, Z., Wang, Y., & Yu, J. (2017, September). Brain tumor segmentation using an adversarial network. In *International MICCAI brainlesion workshop* (pp. 123-132). Springer, Cham.
- Xue, Y.; Xu, T.; Zhang, H.; Long, L.R.; Huang, X. (2018). SegAN: Adversarial Network with Multi-scale L1 Loss for Medical Image Segmentation. *Neuroinformatics*, 16, 383–392.
- Conte, G. M., Weston, A. D., Vogelsang, D. C., Philbrick, K. A., Cai, J. C., Barbera, M., ... & Erickson, B. J. (2021). Generative adversarial networks to synthesize missing T1 and FLAIR MRI sequences for use in a multisequence brain tumor segmentation model. *Radiology*, 299(2), 313-323.
- Isensee, F., Jaeger, P. F., Kohl, S. A., Petersen, J., & Maier-Hein, K. H. (2021). nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature methods*, 18(2), 203-211.
- Antonelli, M., Reinke, A., Bakas, S., Farahani, K., Landman, B. A., Litjens, G., ... & Cardoso, M. J. (2021). The medical segmentation decathlon. *arXiv preprint arXiv:2106.05735*.
- Han, J., Shoeiby, M., Petersson, L., & Armin, M. A. (2021). Dual Contrastive Learning for Unsupervised Image-to-Image Translation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 746-755).
- Diederik P Kingma and Jimmy Ba. (2014). Adam: A method for stochastic optimization. *International Conference on Learning Representations (ICLR)*.
- Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, and Alexei A Efros. (2017) Image-to-image translation with conditional adversarial networks. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. (2016). Deep residual learning for image recognition. In *IEEE Conference on Computer vision and pattern recognition (CVPR)*, pages 770–778.
- Park, T., Efros, A. A., Zhang, R., & Zhu, J. Y. (2020, August). Contrastive learning for unpaired image-to-image translation. In *European Conference on Computer Vision* (pp. 319-345). Springer, Cham.