

Derin öğrenme ile pencere ayarlı görüntüler kullanılarak beyin inme segmentasyon performansının geliştirilmesi

Improving the performance of brain stroke segmentation using window-adjusted images with deep learning

Özlem POLAT*¹ , Mustafa Said KARTAL² 

¹Sivas Cumhuriyet Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, 58140, Sivas

²Sivas Cumhuriyet Üniversitesi, Tıp Fakültesi, 58140, Sivas

• Geliş tarihi / Received: 23.06.2023

• Kabul tarihi / Accepted: 18.09.2023

Öz

İnme çeşitli nedenlerle beyne kan akışının yavaşladığı veya kesildiği durumlarda ortaya çıkan serebrovasküler bir sağlık sorunudur. Beyin dokusu yeterli besin ve oksijeni alamadığı için beyin hücreleri dakikalar içinde ölmeye başlar ve inmenin olduğu bölgedeki fonksiyonlarda geçici ya da kalıcı hasarlar meydana gelir. Beyin inmesi çok ciddi tıbbi bir durumdur ve acil müdahale gerektirmektedir. İnmenin erken tespiti ve inme bölgesinin segmente edilmesi kalıcı hasarların önlenmesi açısından büyük önem arz etmektedir. Bu çalışmada Res2Net omurgalı U-Net derin öğrenme modeli kullanılarak beyin inme segmentasyonu yapılmıştır. Veri seti olarak 1093 hemorajik ve 1130 iskemik inme tipini içeren toplamda 2223 BT görüntüsü kullanılmıştır. Görüntüler pencereleme yöntemi ile ön işlemeden geçirilip sonrasında önerilen model ile eğitilip test edilmişlerdir. Pencereleme ayarı yapılmadan kullanılan görüntülerde ortalama IoU oranı 0.82 olarak elde edilmiş, ön işlemeden sonra bu oran 0.87'ye yükselmiştir; veri çoğaltma yönteminin de uygulanmasından sonra ortalama IoU 0.92'ye ulaşmıştır. Elde edilen test sonuçları görüntülerde uygun pencere ayarlarının kullanılmasının segmentasyon performansını artırdığını göstermiştir.

Anahtar kelimeler: Beyin inme segmentasyonu, Derin öğrenme, Görüntü pencereleme, U-Net

Abstract

Stroke is a cerebrovascular health problem that occurs when blood flow to the brain is slowed or interrupted for various reasons. Since the brain tissue cannot receive enough nutrients and oxygen, brain cells begin to die within minutes and temporary or permanent damage occurs in the functions in the area where the stroke occurred. Brain stroke is a very serious medical condition and requires urgent intervention. Early detection of stroke and segmentation of the stroke site are of great importance in terms of preventing permanent damage. In this study, brain stroke segmentation was performed using U-Net deep learning model with Res2Net backbone. A total of 2223 CT images including 1093 hemorrhagic and 1130 ischemic stroke types were used as dataset. The images were preprocessed with the windowing method and then trained and tested with the proposed model. While the IoU rate was 0.82 in the images used without windowing adjustment, this rate increased to 0.87 after preprocessing, when the data duplication method was added, the average IoU reached 0.92. The test results obtained showed that the use of appropriate window settings in the images increased the segmentation performance.

Keywords: Brain stroke segmentation, Deep learning, Image windowing, U-Net

* Özlem POLAT; ozlem.polat@cumhuriyet.edu.tr

1. Giriş

1. Introduction

Halk arasında inme ya da felç olarak bilinen hemipleji, ölüm nedenleri arasında ikinci sırada yer almaktadır. Gelişmekte olan ülkelerde hastalık olguları nüfusa oranla hızla artış göstermektedir. Ayrıca inmenin önde gelen etkileri sakatlık ve felçtir (Campbell vd., 2019a). İnme, bir hastalığa atfedilen nörolojik bir eksiklik olarak tanımlanır. Beyin, retina veya omurilik kordonunun vasküler bir nedenden dolayı akut fokal yaralanmasıdır (Campbell & Khatri, 2020). Çoğu inme genellikle arteriyel tıkanıklığından kaynaklanır. Arteriyel tıkanıklığından kaynaklanan inme, kan akışının azalması nedeniyle gelişen iskemik (tıkayıcı) inme tipidir. Diğer bir inme tipi, beyinde damar (serebral arter) yırtılmasından kaynaklanan hemorajik (kanayıcı) inmedir. Bölgesel epidemiyolojiye bağlı olarak inmelerin %10-40'ı hemorajik tip inmedir (Sacco vd., 2013). Sigara, diyabet, hiperlipidemi ve fiziksel hareketsizlik inmeye sebep olabilecek önemli risklerdir. 2019'da yayınlanan 2016 Küresel Hastalık Yüğü (Global Burden of Disease) verileri, her dört kişiden birinin felç geçirebileceğini göstermektedir (GBD Stroke Collaborators, 2019). Bu anlamda sakatlık ve ölümün önüne geçmek için inmede erken tanı çok önemlidir. Beyin dokusunun kurtarılabilmesi için hastada inmenin gelişimi ardından en geç 5-9 saat arasında teşhis konulmalıdır (Campbell vd., 2019b). İnme hastalarının değerlendirilmesinde radyolojik beyin görüntüleme bulguları çok önemli bir rol oynamaktadır. Beyin görüntülemeye daha çok bilgisayarlı tomografi (BT) tekniklerinden kontrastsız BT tercih edilir. Bununla beraber BT anjiyografi, BT perfüzyon ve manyetik rezonans görüntüleme (MRG) teknikleri de tercih edilmektedir. MRG giderek daha erişilebilir hale gelmesine rağmen, BT tabanlı tekniklerin uygulanması daha hızlıdır (Pulli vd., 2021). Ayrıca BT görüntüleme MRG'ye göre daha az maliyetli ve erişilebilirliğinin kolay olması dolayısıyla kullanımı daha yaygındır. Dolayısıyla erişilebilirliği ve kolaylığı açısından inme şüphesi olan hastalarda da kontrastsız beyin BT'si, başvuru ilk görüntüleme yöntemi olmaya devam etmektedir (Hollist vd., 2021). İnme tedavisinde radyolojik görüntüleme yöntemleri, inme tipinin belirlenmesi, arteriyel hemoraji ve iskemik bölgesinin tayini, inme nedeni ve mekanizmasının teşhisi için kullanılır. Dolayısıyla inme bulgusu gözlemlenen hastaların tedavi sürecinde BT ve MRG büyük rol oynar (Vilela & Rowley, 2017).

Yapay zekâ, bilgisayarların işlem kabiliyetinin artmasıyla son zamanlarda her alanda kullanılmaktadır. Yapay zekânın bir uygulama yöntemi olan derin öğrenme modellerinin geliştirilmesinin tıbbi görüntüleme için önemli etkileri vardır. Literatürde çeşitli organ ve doku türlerinde lezyon sınıflandırması, tespiti ve segmentasyonunun yapay zekâ ile yapıldığı çeşitli çalışmalar mevcuttur. Yapay zekânın radyolojide kullanımına yönelik araştırmalarda tedavi sürecinin hızlandığı görülmüştür (Zhou, 2020). İnme görüntülemeye de sonuç tahmini açısından başarılı olduğu gözlemlenmiştir (Abuzaid vd., 2021). Hızlı klinik tanı ve görüntüleme, inmelerle ilişkili morbidite ve mortaliteyi en aza indirmek için kritik öneme sahiptir.

İNME teşhisinde yapay zekâ araştırmaları yaygındır. Yapılan bir araştırmada yapay zekâ tekniklerinin, görüntü tabanlı teşhis ve tedavi süreci için çok önemli rol oynadığı gözlemlenmiştir (Yedavalli vd., 2021). Yapay zekâ yöntemlerinden özellikle transfer öğrenme ve derin öğrenme metotları sayesinde başarılı sonuçlar elde edilmiştir. Bazı araştırmalarda radyologlar ile yapay zekânın başarı oranları karşılaştırılmıştır. Bu araştırmalardan birinde yapay zekânın kıdemli radyologlara eş değer başarı verdiği görülmüştür (Li vd., 2020). Akut iskemik inme hastalarında BT perfüzyon kullanılarak tanı sürecinde yapay zekâ başarısı test edilmiştir. Bu araştırmada konvolüsyonel sinir ağları (convolutional neural networks-CNN) kullanılmıştır (Cleriques vd., 2019). Medikal görüntü segmentasyonu için geliştirilen U-Net modellemesi ile segmentasyon yapılmıştır. Modele verilen BT perfüzyon iskemik inme görüntüleri bazı ön işleme ve veri çoğaltma tekniklerine başvurularak geliştirilmiştir. Sonuçta yüksek bir başarı oranıyla inme bölgesinin segmente edildiği görülmüştür. MRG ve BT anjiyografinin de yapay zekâ destekli çalışmaları mevcuttur. Bu çalışmalardan elde edilen sonuçlara göre radyologlara eş değer bir doğruluğun yanında daha hızlı teşhis konulması sağlanmaktadır (Winzeck vd., 2018). İnmede yapay zekâ araştırmaları gün geçtikçe artmaktadır ayrıca BT görüntülerinde farklı ön işlemler ile daha yüksek başarılar elde etmek mümkündür.

2. Literatür özeti

2. Literature review

Son yıllarda popüler olan ve günden güne yeni modeller oluşturulan derin öğrenme yüksek başarımlı sonuçlar elde edilmesinden dolayı farklı bilim alanlarında yaygın olarak kullanılmaktadır. Tıp alanında beyinde inmenin tespit edilmesi, inme tipinin belirlenmesi ve inme bölgesinin segmente edilmesi gibi çalışmalarda da kullanımı tercih edilmektedir.

Yahiaoui ve Bessaid (2016) iskemik inme içeren BT görüntülerini öncelikle ön işlemeden geçirmişler ve sonrasında çok ölçekli dönüşümlerden biri olan Laplace Piramitlerini kullanarak geliştirmişlerdir. Sonrasında Bulanık C-Ortalama kümeleme algoritmasını kullanarak iskemik lezyon bölgesini segmente etmişlerdir.

Bu çalışmada yeni geliştirilmiş bir derin öğrenme modeli olan Res2Net (**Gao vd., 2019**) omurgalı U-Net (**Ronneberger vd., 2015**) modeli kullanılarak beyin inme segmentasyonu yapılmıştır. Veriseti olarak 1093 hemorajik ve 1130 iskemik inme tipini içeren toplamda 2223 beyin BT görüntüsü kullanılmıştır. Çalışma görüntüye uygulanan görüntü pencereleme ön işlemi açısından yeniliğe sahiptir. BT cihazları tarafından oluşturulan DICOM görüntüler beyin dokusunu gösterecek şekilde sabit pencere aralıklarında oluşturulmaktadır. Bu çalışmada beyin dokusunu, kemik dokusunu ve yumuşak dokuyu gösterecek şekilde pencere aralıkları ayarlanmış ve oluşturulan bu üç görüntü birleştirilerek kullanılmıştır. Ön işlemeden geçirilen görüntüler sonrasında önerilen model ile eğitilip test edilmişlerdir. Pencereleme ayarı yapılmadan kullanılan görüntülerde IoU oranı 0.82 olarak elde edilmiş, ön işlemeden sonra bu oran 0.87'ye yükselmiştir. Elde edilen test sonuçları görüntülerde uygun pencere ayarlarının kullanılmasının ve üç kanallı görüntülerin birleştirilmesinin segmentasyon performansını artırdığını göstermiştir. Veri çoğaltma tekniklerinin kullanılmasından sonra yapılan testlerde ise 0.92 IoU değerine ulaşılmıştır.

Ajam vd. (2019) BT beyin görüntülerinden iskemik inmeyi saptamak ve segmentlere ayırmak için bir algoritma önermişlerdir. Önerdikleri yöntemde öncelikle BT görüntülerinden kafatası kemiği sıyırma ve metin çıkarma içeren bir ön işleme adımı uygulanmış ardından da görüntüler medyan filtre ve histogram eşitleme kullanılarak geliştirilmiştir. Sonrasında iskemik inmeyi saptamak için havza segmentasyonu ve İşaretçi Kontrollü havza yöntemleri uygulanmıştır. Yapılan deneyler BT görüntüsünün gürültüsünden kaynaklanan aşırı segmentasyon nedeniyle, İşaretçi kontrollü havza yönteminin havza segmentasyon yönteminden daha iyi olduğunu göstermiştir. Yapılan çalışmada aşırı segmentasyon problemi çözülmüştür.

Subudhi vd. (2020) iskemik inme içeren beyin MR görüntülerini kullanarak parsiyel anteriyor sirkülasyon sendromu, laküner sendrom ve total anteriyor sirkülasyon infarktı olmak üzere üç sınıfa ayırmışlardır. Önce görüntülerdeki inme içeren kısımlar beklenti maksimizasyon algoritması kullanılarak segmente edilmiş ve Fraksiyonel Düzen Darwinci Parçacık Sürü Optimizasyonu ile iyileştirme sağlanmıştır. Farklı morfolojik ve istatistiksel özellikler çıkarılarak öznitelik kümesi oluşturulmuş, Destek Vektör Makinaları (SVM) ve Rasgele Orman (RF) yöntemleri ile sınıflama yapılmış ve RF ile %93.4 başarımla elde edilmiştir.

Gautam ve Raman (2021) beyin BT görüntülerini kullanarak önce iskemik inme ve hemorajik inme olarak ikili sınıflama sonra da normal, iskemik ve hemorajik olarak çoklu sınıflama yapmışlardır. BT görüntülerinin kalitesini artırmak amacıyla Dörtlü Ağaç tabanlı görüntü füzyonu ön işleme aşamasını gerçekleştirmişlerdir. 13 katmanlı CNN modeli oluşturup bu modeli ön işleme yapılmış görüntüler üzerinde eğitip test etmişlerdir. Deneyler sonucunda ikili sınıflandırmada %98.77 ve üçlü sınıflandırmada % 93.33 başarımla ulaşılmıştır.

Yalçın ve Vural (2022) beyinde inmenin tespit edilmesi, inme tipinin belirlenmesi ve inme bölgelerinin segmentasyonu için, geliştirilmiş bir U-Net modeli önermişlerdir ve modeli D-UNet (developed U-Net) olarak isimlendirmişlerdir. Yapılan çalışmada önce beyinde inme olup olmadığı tespit edilmiş, inme olması durumunda ise inmenin hemorajik mi yoksa iskemik mi olduğu belirlenmiş ve sonrasında ise inme bölgesinin segmentasyonu gerçekleştirilmiştir. Veri seti olarak Türkiye Sağlık Bakanlığı tarafından paylaşılan ve 6650 BT görüntüsünden oluşan bir veri seti kullanılmışlardır. Veri çoğaltma ile görüntü sayısı artırılan çalışmada önerilen model ile inmenin varlığının tespitinde ve inme tipinin sınıflandırılmasında sırasıyla %98.9, %98.5 başarımla ve inme bölgesinin segmente edilmesinde %95.2 IoU değeri elde etmişlerdir.

Alhatemi ve Savaş (2022) beyin MR görüntülerini kullanarak inme var ve inme yok şeklinde ikili sınıflama yapmışlardır. Yapılan çalışmada klasik derin transfer öğrenme modellerinden DenseNet121, ResNet50, Xception, VGG16, MobileNet ve EfficientNetB2'yi önermişlerdir. Kullandıkları MR veri seti üzerinde veri çoğaltma ve ön işleme yapmışlardır ve en iyi sınıflandırma başarımlarını EfficientNetB2 ile elde etmişlerdir.

Aboudi vd. (2022) beyindeki iskemik inme lezyonlarını segmente etmek amacıyla U-Net mimarisini kullanmışlardır. U-Net tabanlı kodlayıcı-kod çözücü mimarisini artık birim ile birleştiren bir yaklaşım önermişlerdir. MR görüntülerinden oluşan ISLES 2015 veri setini veri çoğaltma yaparak kullanmışlar ve önerdikleri bu yaklaşımla ortalama %55.77 dice değerine ve %99.96 doğruluk değerine ulaşılmıştır.

[Alquhayz vd. \(2022\)](#) beyindeki iskemik inme lezyonlarının segmentasyonu için çok seviyeli sınıflama ağı (MCN) ve modifiye edilmiş rezidüel U-Net modelini kullanmışlardır. MCN, kademeli üç ayrı ağdan oluşmaktadır. Birinci ağda tüm dilim seviyesi sınıf dengesizliğini azaltmak amacıyla inme lezyonları MRI görüntülerinden çıkarılır ve yamalar oluşturulur. İkinci ağ oluşturulan yamaları sınıflandırır. Üçüncü ağ olan U-Net ikinci ağdaki yamalardan inme lezyonlarını ayırır. Oluşturulan ağ ATLAS veri seti üzerinde eğitilip test edilmiştir ve deneyler sonucunda ortalama 0.754 dice skoru elde etmişlerdir.

[Karataş vd. \(2022\)](#) çalışmalarında [Koç vd. \(2022\)](#) tarafından oluşturulan normal, iskemik ve hemorajik olarak etiketlenmiş BT görüntüleri içeren veri setini kullanmışlardır. İki aşamalı olarak yaptıkları çalışmanın birinci aşamasında görüntüleri inme yok veya inme var olarak sınıflandırmışlardır. İkinci aşamada ise yalnızca inme içeren görüntüleri kullanarak iskemik ya da hemorajik olarak sınıflama yapmışlardır. Altı farklı transfer öğrenme modeli kullandıkları çalışmada en yüksek başarıyı birinci aşama ve ikinci aşama için sırasıyla %99.72 doğruluk ile ResNet50 modelinden ve %99.51 doğruluk ile Inception-v3 modelinden elde etmişlerdir.

[Yang vd. \(2023\)](#) çalışmalarında kontrastsız BT görüntülerinde otomatik iskemik inme lezyonu segmentasyonu için bir kodlayıcı-kod çözücü evrişimli sınır ağı olan IS-Net'i önermişlerdir. IS-Net yapısı hiyerarşik omurga, omurganın çok aşamalı özelliklerini bir araya getirmek için Piramit Özellik Toplama (PFA) modülü, yerel olmayan paralel kod çözücü, sınır işaretlerini tam olarak çıkarmak için kenar kısıtlama şeması ve segmentasyon kısmından oluşmaktadır. Önerilen IS-Net, 1004 vakadan (toplam 9020 görüntü) oluşan, manuel olarak etiketlenmiş kontrastsız BT veri seti üzerinde değerlendirilmiş ve 56.7 ± 0.5 IoU(%) değerine ulaşılmıştır.

[Kaya ve Önal \(2023\)](#) yaptıkları çalışmada kontrastsız BT görüntüleri kullanarak ilk olarak inme tipini iskemik veya hemorajik olarak sınıflandırmışlardır. İkinci olarak inme bölgesini segmente etmişlerdir. Segmentasyon için derin öğrenme modellerinden U-Net'i kullanmışlardır. Gerçek veri seti üzerinde yaptıkları deneylerde sınıflandırma modeli için % 95.06 doğruluk değeri elde etmişlerdir. Segmentasyon sonucu deneylerden elde ettikleri IoU katsayısı değerleri hemorajik ve iskemik inme için sırasıyla %92.01 ve %82.22'dir.

Beyin inme segmentasyonu ile ilgili en güncel çalışmalardan biri [Uçkun vd. \(2023\)](#) tarafından yapılmıştır. [Uçkun vd. \(2023\)](#), [Koç vd. \(2022\)](#) tarafından oluşturulan veri setinde yalnızca iskemik olarak etiketlenmiş görüntüleri kullanmışlardır. İskemik inme segmentasyonunun yapıldığı çalışmada U-Net, U-Net VGG16, U-Net VGG19, Attention U-Net ve ResU-Net modelleri eğitilip test edilmiştir. Yapılan deneyler sonucunda %96.95 IoU değeri elde edilmiştir.


3. Önerilen metodoloji

3. Proposed methodology

3.1 Görüntü pencereleme

3.1 Image windowing

Sir Godfrey Hounsfield tarafından ortaya atılan Hounsfield birimi (HU), BT görüntülerinin yorumlanmasında radyologlar tarafından kullanılan radyo yoğunluğunun göreceli nicel bir ölçü birimidir. Buna göre her bir dokunun farklı HU değeri bulunmaktadır, bu değerlere BT sayısı da denilmektedir. HU değerlerinin bulunduğu Hounsfield skalası da denilen cetvelde damıtılmış su (standart sıcaklık ve basınçta) sıfır noktası olarak tanımlanmıştır. Şekil 1'de görüldüğü gibi +1000 ile -1000 arasında uzanan bu skalada hava -1000 HU olarak tanımlanırken yoğun kemikler ve metaller +1000 HU olarak tanımlanır. HU değeri koklea gibi yoğun kemikler için 2000, çelik veya gümüş gibi metaller için 3000'den fazla olabilir ([DenOtter & Schubert, 2023](#)). BT görüntülerinde pencereleme ayarı HU ile yapılır.



Şekil 1. Hounsfield skalası (Osborne vd., 2016)

Figure 1. Hounsfield scale (Osborne vd., 2016)

Gri seviye haritalama, kontrast germe, histogram modifikasyonu veya kontrast geliştirme olarak da bilinen pencereleme, bir BT görüntüsünün gri tonlamalı bileşeninin HU değerleri aracılığıyla manipüle edildiği süreçtir. BT görüntüsünde mevcut olan 4096 gri renk tonunu insan gözünün ayırt edebilmesi imkânsızdır, en iyi ihtimalle 30-40 gri renk tonunu ayırt edebilir (Jung, 2021). İlgilenilen dokunun BT görüntüsünde ayırt edilebilmesi için gri ölçeğin değerlerinin dokunun görüntülediği değerlerin bulunduğu alana dağıtılması gerekmektedir. Pencereleme olarak bilinen bu işlem ile insan gözünün algılayamadığı birçok yapı görünür hale gelmektedir, bu demek oluyor ki belirli yapıları vurgulamak için yapılan pencereleme ile resmin görünümünü değiştirecektir. Pencerelemede görüntünün parlaklığı pencere seviyesi (WL=window level) aracılığıyla ayarlanırken, kontrast pencere genişliği (WW=window width) aracılığıyla ayarlanır.

Pencere genişliği, bir görüntünün içerdiği BT sayıları aralığının ölçüsüdür. Şöyle ki gri renk tonlarının yayılmasını istediğimiz BT sayı aralığı olarak da ifade edilmektedir. Pencere seviyesi ise bu BT sayı aralığının tam orta noktasını ifade etmektedir. Pencereleme ile ortaya çıkarılmak istenen dokuya ilişkin Hounsfield değerleri gri renk tonlarında görünürken bu aralık dışında kalan alanlar BT görüntüsünde siyah ya da beyaz görüntülenecektir.

İlgilenilen dokuya ilişkin WW ve WL değerleri sunulduğunda, gri seviyelerin üst ve alt sınırları Denklem 1 ve 2'deki gibi hesaplanabilir. BT görüntüsünde üst gri seviye üzerindeki değerler beyaz ve alt gri seviye altındaki değerler siyah olacaktır.

$$\text{Üst gri seviye} = WL + \left(\frac{WW}{2}\right) \quad (1)$$

$$\text{Alt gri seviye} = WL - \left(\frac{WW}{2}\right) \quad (2)$$


Örneğin, bir beyin W:80 L:40 pencere ayarlarında görüntülenebilmektedir. Beyin için üst gri seviye 80, alt gri seviye de 0 olarak hesaplanır. Bu nedenle 80'in üzerindeki tüm değerler beyaz, 0'ın altındaki tüm değerler ise siyah olacaktır.

Barros vd. (2020) yaptıkları çalışmada pencerelemenin önemi ortaya koymuş ve pencereleme sayesinde kemik bölgesini de segmente etmişlerdir. İskemik tip inme segmentasyonunu amaçladıkları çalışmalarında gözlem sırasında pencere genişliği 30 HU ve pencere seviyesi 30 HU olarak belirlenmiştir. Ayrıca 160 HU üzeri kemik olarak ele alınıp dışlanması sağlanmıştır. Bu ayarlar sonucunda 0.78 dice skoru almayı başarmışlardır. Bir başka çalışmada pencere seviyesi 30 HU, pencere genişliği 60 HU alındıktan sonra normalizasyon işlemi yapılmıştır. İki aşamalı derin öğrenme modelinin kullanıldığı bu çalışmada %42 duyarlık elde edilmiştir (Nishio vd., 2020). İskemik inme segmentasyonu için yapılan bir diğer çalışmada iki farklı pencereleme ile segmentasyon yapılmıştır. Pencere genişliği 100 HU ve pencere seviyesi 35 HU ayarlanan görüntüler ile pencere genişliği 90 HU ve pencere seviyesi 40 HU olarak ayarlanan görüntülerle ayrı ayrı çalışılmıştır (Lo vd., 2021).

Yapılan çalışmalar göz önüne alındığında pencere ayarı yapay zekâ eğitimi için önemlidir. Beyin BT üzerindeki inme bölgesinin daha iyi bir performansla segmente edilebilmesi için yapay zekâ eğitiminde birden fazla pencere ayarı kullanılmış ve bu farklı pencere ayarları ile elde edilen görüntüler birleştirilerek derin öğrenme modelinin beyin dokusundaki değerleri daha iyi öğrenmesi sağlanmıştır. Bu çalışmada kullandığımız

pencere aralıkları daha önce literatürde inmenin tespit edilmesinde avantaj sağlayan pencere aralıklarının denenmesiyle elde edilmiştir. Yapay zekâ eğitiminde birden fazla farklı pencere aralıklı görüntülerin birleştirilmesiyle elde edilen görüntüler kullanılmış, böylece inme bölgesinin ön plana çıkarılması ve eğitimde başarının artması sağlanmıştır.


Çalışmada ön işleme olarak görüntülere farklı pencereleme araklıları uygulanmış ve elde edilen farklı pencere ayarlı görüntüler birleştirilerek kullanılmıştır. Buna örnek olarak Şekil 2’de üç kanallı görüntü elde etmek amacıyla pencere ayarı yapılmış üç farklı görüntü ve bunların birleşimi gösterilmektedir. Şekil 2’de WW: 35 HU WL: 30 HU, WW: 40 HU WL: 40 HU ve WW:80 HU WL: 250 HU pencere ayarlarıyla elde edilen görüntüler sırasıyla iskemik tip inme, kanama bölgesi ve yumuşak doku bölgelerinin ön plana çıkarılmasını sağlamaktadır. Farklı pencere ayarlarıyla elde edilen bu üç görüntünün birleşimiyle 3 Kanallı Görüntü oluşturulmuştur.



Şekil 2. Farklı pencere ayarlı görüntüler ve bunların birleşimini içeren BT görüntüsü

Figure 2. Images with different window settings and CT image containing their combination


BT üzerinde pencere ayarı ile kemik bölgesi de bulunabilmektedir. Çizdirilen kemik bölgesinin konturları alınarak asıl görüntüden silinmesi sağlanır, bu durum Şekil 3’te gösterilmektedir.



Şekil 3. Kemik konturlarının silindiği BT görüntüsü

Figure 3. CT image with erasing bone contours

Farklı pencere ayarlarının birleştirilmesi ve kemik bölgesinin çıkarılmasıyla oluşturulan bir diğer görüntü de Şekil 4’te görülmektedir. Görüntüden de anlaşılacağı üzere inme bölgesi ön plana çıkmıştır. Şekil 4’te görülen ön işleme ayarı nihai ön işleme metodu olarak tercih edilmiştir. Burada beyin dokusunun görüntülemesinde tercih edilen WW: 40 HU WL: 80 HU pencere ayarı, iskemik ve kanama bölgelerinin daha net seçildiği WW:35 HU WL: 30 HU ve WW: 40 HU WL: 40 HU pencere ayarları kullanılarak üç kanallı görüntü oluşturulmuştur. Ayrıca kemik bölgesinin dışlanması için kemik bölgesini dokudan ayıran pencere ayarları ile ikili maske oluşturularak matris çarpımı ile bölgenin silinmesi sağlanmıştır.



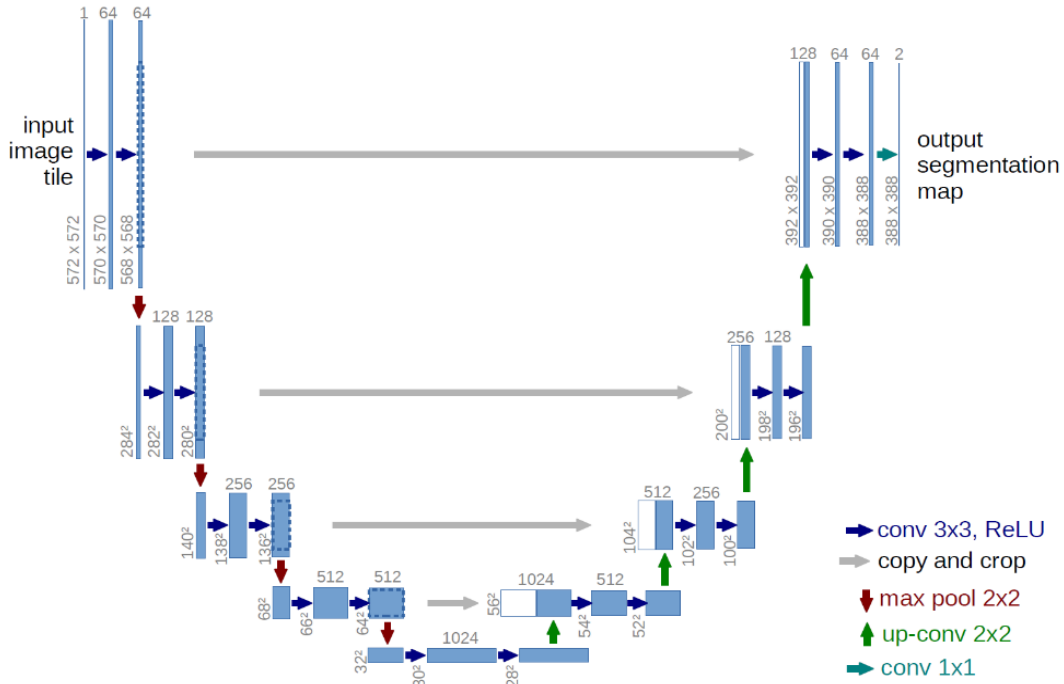
Şekil 4. Farklı pencere ayarlı, kemik dokusu içermeyen ve inme bölgesinin ön plana çıktığı BT görüntüsü

Figure 4. CT image with different window settings, bone tissue-free and stroke area prominent

3.2 Temel U-Net

3.2 Basic U-Net

Segmentasyon (bölütleme) bir görüntüyü farklı özelliklerin tutulduğu anlamlı bölgelere ayırma işlemidir. U-Net derin öğrenme modeli Almanya'daki Freiburg Üniversitesi Bilgisayar Bilimleri Bölümünde, biyomedikal görüntü segmentasyonu için geliştirilen bir konvolüsyonel sinir ağıdır (Ronneberger vd., 2015). U-Net ağına ilişkin mimari Şekil 5'te gösterilmektedir.



Şekil 5. U-Net ağ yapısı (Ronneberger vd., 2015)

Figure 5. U-Net network structure (Ronneberger vd., 2015)

U-Net mimarisi, genel olarak bir kodlayıcı ağ ve bir kod çözücü ağ olmak üzere iki temel bölüme oluşmaktadır. Kodlayıcı bölüme küçülme yolu, kod çözücü bölüme genişleme yolu da denilmektedir. Kodlayıcı kısımda standart konvolüsyon işlemleri gerçekleştirilirken kod çözücü kısımda bunun aksine ters konvolüsyon işlemleri gerçekleştirilmektedir. Kod çözücü kısım 4 tane standart konvolüsyon bloğundan oluşmaktadır. Her bir blokta 2 adet 3×3 filtre boyutlu konvolüsyon katmanı + ReLU aktivasyon fonksiyonu ve boyut azaltma amacıyla 2×2 havuzlama katmanı bulunmaktadır. Mimarinin kodlayıcı kısmında özellik haritalarının sayısı havuzlama işleminden sonar ikiye katlanmaktadır. Kodlayıcı kısmında amaç görüntünün uygun bir şekilde segmente edilebilmesi için gerekli olan görüntü içeriği bilgisini tutmaktır. Bu bilgi


sonrasında kısayol bağlantıları ile kod çözücü kısma aktarılmaktadır. Kod çözücü kısım da kodlayıcı kısım gibi 4 bloktan oluşur ve bu bloklarda sırasıyla ters konvolüsyon katmanı + kodlayıcı kısımda elde edilen özellik haritaları ile birleştirme + adet 3×3 filtre boyutlu konvolüsyon katmanı ve ReLU aktivasyon fonksiyonunu içermektedir. Son kısımda segmente edilmiş görüntüyü elde etmek için 1×1 filtre boyutlu konvolüsyon işlemi uygulanır. Kodlayıcı-kod çözücü mimari U harfine benzediği için U-Net olarak isimlendirilmiştir. Ağın eğitilmesi için çok fazla veriye ihtiyaç duyulmaması U-Net mimarisinin sahip olduğu üstünlüklerden biridir.

3.3 Omurga modeli: Res2Net

3.3 Backbone model: Res2Net

U-Net'in başarısı, büyük ölçüde kullanılan omurga modeline bağlıdır. Omurga modeli, U-Net'in kodlayıcı bölümünü oluşturur ve giriş görüntüsünün özelliklerini öğrenmekten sorumludur. Omurga modeli olarak genellikle önceden eğitilmiş bir derin öğrenme modeli kullanılır. Bu, modelin daha hızlı ve daha etkili bir şekilde eğitilmesini sağlar, çünkü model, önceden eğitilmiş ağırlıklarla başlar ve bu ağırlıklar genellikle genel görüntü özelliklerini öğrenmek için yeterlidir. Önceden eğitilmiş modeller arasında VGG, ResNet, DenseNet ve EfficientNet gibi popüler seçenekler bulunmaktadır. Bu çalışmada omurga model olarak daha güncel bir mimari olan Res2Net (Gao vd., 2019) modeli tercih edilmiştir.

Gao vd. (2019) tarafından önerilen Res2Net modülü basit ama verimli bir ölçekli işleme yaklaşımı içermektedir. Şekil 6'da sol tarafta modern omurga CNN mimarilerinin *örn.* ResNet (He vd., 2016) darboğaz yapısı görülmektedir. Şekil 6'da sağ tarafta ise darboğaz bloğunda 3×3 'lük filtre grupları kullanarak özellikleri çıkarmak yerine benzer hesap yüküne sahip daha güçlü ve çok ölçekli özellik çıkarma yeteneğine sahip olan Res2Net modülü görülmektedir. Mimari hiyerarşik rezidüel tarzda farklı filtre grupları bağlanırken, 3×3 filtre grupları daha küçük filtre grupları ile değiştirilmektedir. Mimari tek bir rezidüel blokta rezidüel tarzda bağlantılar içerdiğinden dolayı Gao vd. tarafından Res2Net olarak isimlendirilmiştir (Gao vd., 2019). CIFAR-100 ve ImageNet veri setleri üzerinde görüntü sınıflamada son teknoloji mimarilerden daha iyi performans gösteren Res2Net modülü son teknoloji modellere kolaylıkla entegre edilebilmektedir.

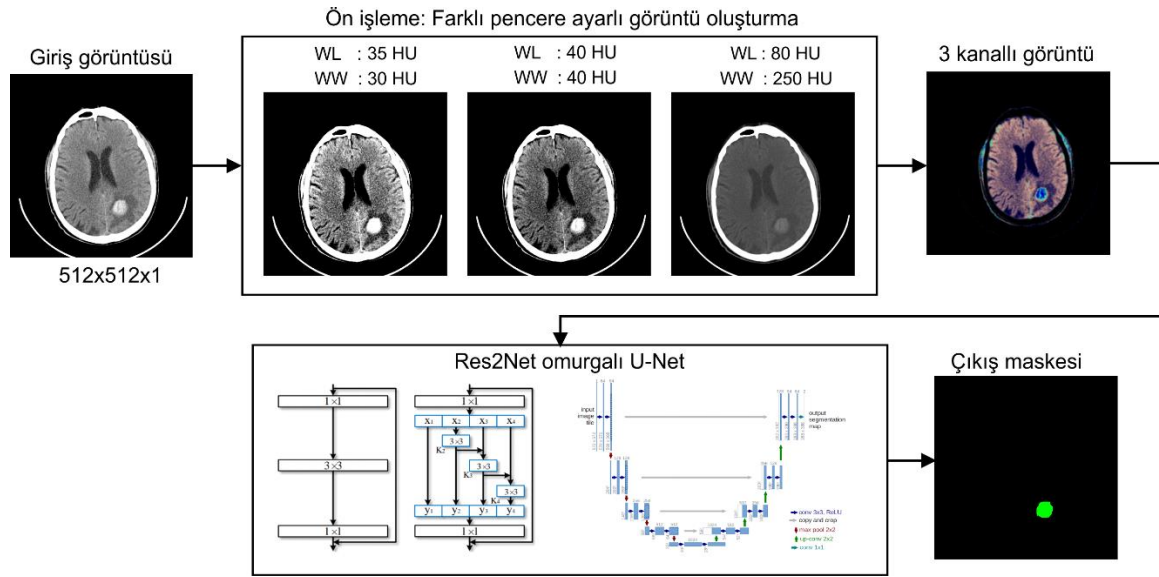


Şekil 6. Darboğaz bloğu ve ölçek boyutu $s = 4$ olan Res2Net modülünün karşılaştırılması (Gao vd., 2019)

Figure 6. Comparison of the bottleneck block and Res2Net module with scale size $s = 4$ (Gao vd., 2019)

Şekil 6 Res2Net bloğu ile darboğaz bloğu arasındaki farkı göstermektedir. Res2Net modülünde 1×1 konvolüsyondan sonra özellik haritaları, ölçek boyutu da denilen s adet x_i ile gösterilen özellik haritası alt kümesine ayrılmıştır. Burada $i \in \{1, 2, \dots, s\}$ olmaktadır. Her x_i özellik alt kümesi giriş özellik haritasıyla karşılaştırıldığında aynı uzamsal boyuta ancak $1/s$ kanal sayısına sahiptir. x_1 dışındaki her x_i , $\mathbf{K}_i()$ ile gösterilen 3×3 konvolüsyona sahiptir. $\mathbf{K}_i()$ konvolüsyon işleminin çıkış y_i ile gösterilmektedir. x_i özellik alt kümesi $\mathbf{K}_i()$ konvolüsyonunun çıkışı ile toplanır ve $\mathbf{K}_i()$ konvolüsyon işlemine giriş olarak verilir. s artarken parametreleri azaltmak amacıyla x_1 için 3×3 konvolüsyon işlemi ihmal edilir. Bu durumda y_i 'nin oluşturulması Denklem 3 ile ifade edilmektedir. Daha detaylı bilgi için referans (Gao vd., 2019) incelenebilir. Çalışmada inme segmentasyonu için kullanılan Res2Net omurgalı U-Net modeline ilişkin akış diyagramı Şekil 7'de gösterilmektedir.

$$y_i = \begin{cases} x_i & i = 1; \\ K_i(x_i) & i = 2; \\ K_i(x_i + y_{i-1}) & 2 < i \leq s; \end{cases} \quad (3)$$



Şekil 7. BT görüntülerinde inme segmentasyonuna ilişkin blok diyagram
Figure 7. Block diagram of stroke segmentation on CT images

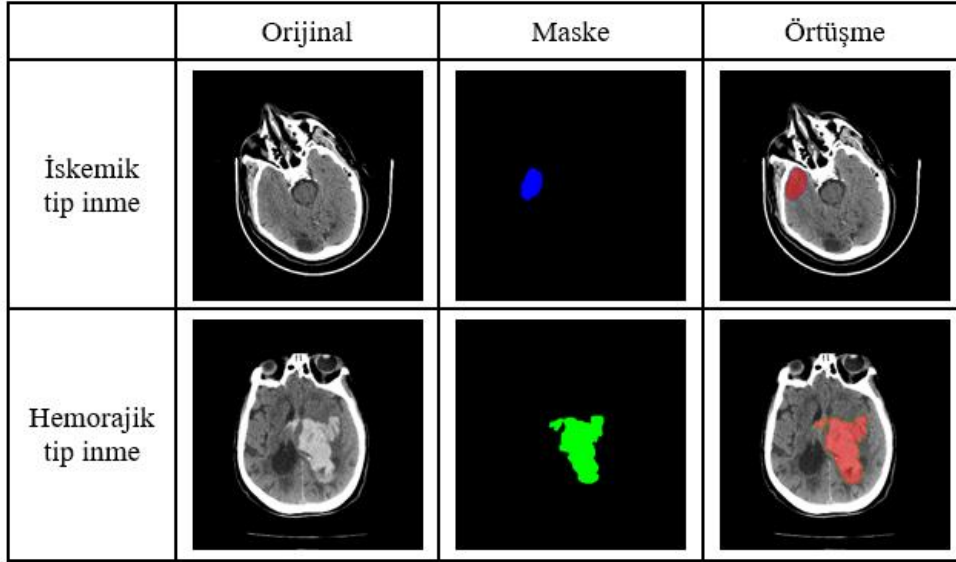
4. Deneysel analiz ve sonuçlar

4. Experimental analysis and results

4.1. Beyin BT Veri Seti

4.1 Brain CT Dataset

Bu çalışmada Türkiye Cumhuriyeti Sağlık Bakanlığına ait Koç vd. (2022) tarafından derlenen ve BT görüntülerinden oluşan gerçek bir veri seti kullanılmıştır. Veri setinin ticari olmayan amaçlarla kullanımına izin verilmektedir ve kullanılmasında herhangi bir engel bulunmamaktadır. Veri seti 4427 inme içermeyen ve 2223 inme içeren BT görüntüsünden oluşmaktadır. İnme içeren görüntülerin de 1130 tanesi iskemik tip ve 1093 tanesi hemorajik tip inme içermektedir. Bu çalışmada inme bölgelerinin segmentasyon problemi ele alındığı için yalnızca inme içeren BT görüntüleri ile çalışılmıştır. 2019 ve 2020 yıllarında kaydedilen veriler Türkiye Cumhuriyeti Sağlık Bakanlığı e-Nabız ve Teleradyoloji Sistemlerinden çeşitli kodlama ve filtreleme uygulanarak görselleştirilmiş ve veri seti oluşturulmuştur. Görüntüler 7 radyoloji uzmanı tarafından 6 haftalık bir süre içinde inme yok, iskemik inme ve hemorajik inme olarak etiketlenmiş, inme içeren görüntülerdeki inme bölgeleri işaretlenmiş ve kontrol edilmiştir. Sağlık Bakanlığı Sağlık Bilgi Sistemleri Genel Müdürlüğü tarafından paylaşılan veriler 512×512 piksel boyutunda DICOM ve PNG formatında olup orijinal görüntü, maske görüntü ve maske görüntünün orijinal görüntü üzerine bindirilmiş hali olarak paylaşılmaktadır. Çalışmada veri setine ilişkin DICOM görüntüleri 512×512 piksel formatında kullanılmıştır. Veri setine ait iskemi tipi ve hemorajik tip inme içeren görüntüler Şekil 8’de gösterilmektedir. Şekildeki renkli kısımlar inme bölgesini göstermektedir.



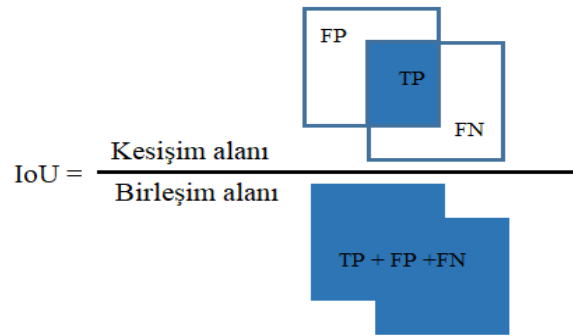
Şekil 8. İskemik ve hemorajik tip inme içeren orijinal BT görüntüleri, bu görüntülere ilişkin maske görüntüleri ve orijinal ile maskelerin örtüşme görüntüleri
Figure 8. Original CT images containing ischemic and hemorrhagic stroke, mask images of these images, and overlap images of the original and masks

4.2 Performans değerlendirme

4.2 Performance evaluation

Bu çalışmada inme bölgelerinin segmentasyon performansının hesaplanması için Jaccard indeksi de denilen IoU (Intersection over Union) metriği kullanılmıştır. Bu metriğin hesaplanabilmesi için öncelikle referans görüntülerin oluşturulması gerekmektedir. Temel gerçek de denilen referans görüntü ya da referans maske uzmanlar tarafından BT görüntüler üzerinde işaretlenmiş inme bölgelerini göstermektedir. Matematiksel ifadesi Denklem 4'teki gibi gösterilen piksel tabanlı metrik olan IoU, temel gerçek ile segmentasyon sonucu tahmin edilen bölgenin örtüşme alanının, temel gerçeğe segmentasyon sonucu tahmin edilen bölgenin birleşme alanına oranını göstermektedir. IoU piksel tabanlı bir metrik olduğu için örtüşme alanı ve birleşme alanı piksel cinsinden ifade edilmektedir. IoU değeri 0-1 arasında değişim gösterir. 0 örtüşme olmadığını ve 1 tahmin edilen ile temel gerçeğin tam olarak örtüştüğünü, sonuç olarak segmentasyon işleminin mükemmel olduğunu göstermektedir. IoU değerinin hesaplanmasına ilişkin görselleştirme Şekil 9'da görülmektedir. Segmentasyon problemlerinde karşılaşılan diğer bir metrik de mIoU'dur. Bu metrik ise çok sınıflı segmentasyon problemlerindeki ortalama IoU değerini belirtmektedir.

$$IoU = \frac{\text{Doğru Pozitif (TP)}}{\text{Doğru Pozitif (TP)} + \text{Yanlış Negatif (FN)} + \text{Yanlış Pozitif (FP)}} \quad (4)$$



Şekil 9. IoU metriğinin hesaplanmasına ilişkin görsel
Figure 9. Visual of calculating the IoU metric

Burada BT görüntülerindeki inme içeren piksellerin ait olduğu sınıf P (pozitif) sınıfı, inme içermeyen arka plandaki piksellerin ait olduğu sınıf da N (negatif) sınıfı olsun. Bu durumda Denklem 4'te ve Şekil 8'de belirtilen

- TP, gerçekte P sınıfından olup modelin de P olarak sınıflandırdığı piksel sayısını,
- TN, gerçekte N sınıfından olup modelin de N olarak sınıflandırdığı piksel sayısını
- FN, gerçekte P sınıfından olup modelin N olarak sınıflandırdığı piksel sayısını
- FP, gerçekte N sınıfından olup modelin P olarak sınıflandırdığı piksel sayısını göstermektedir.

4.3 İnme segmentasyon sonuçları

4.3 Stroke segmentation results

Beyin BT görüntülerinde iskemik ve hemorajik tip inme bölgelerinin segmente edildiği çalışmada Sağlık Bakanlığı Açık Veri Portalında paylaşılan gerçek görüntüler kullanılmıştır. Kullanılan veriseti 1130 iskemik tip ve 1093 hemorajik tip inme bulgusu içeren BT görüntülerinden oluşmaktadır. İnme bölgesi segmentasyonunda nihai sonuçlara ulaşmadan önce, test edilecek modelin farklı hiper parametreler kullanılarak ve BT görüntülerine de farklı ön işlemler uygulanarak eğitildiği bir dizi deney yapılmıştır. Her deneyde, modelin performansını değerlendirmek için IoU metriği kullanılmıştır. Deneylerde kullanılan kombinasyonlar Tablo 1'de gösterilmiştir. Model olarak temel U-Net modeli Res2Net omurgası ile kullanılmış ve BT görüntüleri ile model eğitilip test edilmiştir. Veriseti %90 ve %10 olmak üzere iki parçaya ayrılmış, %90'lık kısmı ile model eğitilirken, kalan kısım ile de model test edilmiştir. Kodlamalar python programlama dili kullanılarak yapılmıştır. Önerilen modelin eğitiminde ve testinde en iyi sonuçlara paket boyutu 16, optimizasyon algoritması Adam ve öğrenme oranı 0.0001 olduğu şartlarda ulaşılmıştır.

Tablo 1. Beyin inme segmentasyonunda kullanılan modellerin performanslarının karşılaştırılması
Table 1. Comparison of the performances of the models used in brain stroke segmentation

Model	Kayıp fonksiyonu	Veri	Ortalama IoU	IoU-0	IoU-1	IoU-2
Temel U-Net	Categorical C.	ham veri	0.67	0.97	0.32	0.72
Temel U-Net	Categorical C.	wset (beyin)	0.73	0.98	0.43	0.80
Temel U-Net	Dice	wset (beyin)	0.76	0.98	0.45	0.83
U-Net + Res2Net	Dice	wset (beyin)	0.82	0.98	0.67	0.84
U-Net + Res2Net	Dice	wset3C	0.87	0.99	0.80	0.88
U-Net + Res2Net	Dice	wset3C + veri çoğaltma	0.92	0.99	0.84	0.94

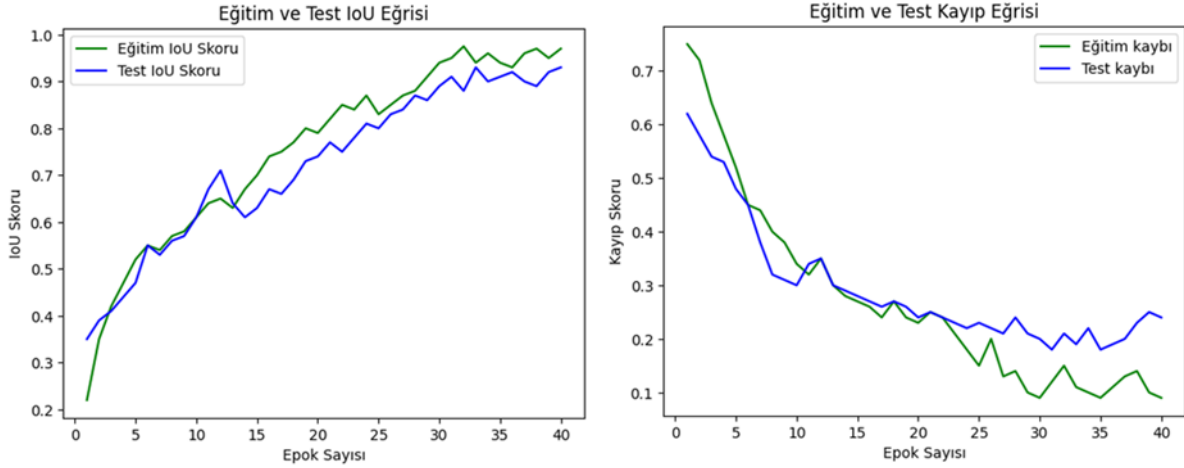
Deneyler yapılırken öncelikle Temel U-Net modeli kullanılmış, kayıp fonksiyonu olarak Categorical Crossentropy tercih edilmiş ve model hem ham görüntülerle hem de beyin pencere ayarlı görüntülerle (wset) test edilmiştir. Tablo 1'in 1. ve 2. satırından görüleceği üzere beyin pencere ayarlı görüntülerin kullanılmasıyla daha iyi bir sonuç elde edilmiştir. Tabloda IoU-0 görüntüdeki inme dışında kalan arka planın, IoU-1 iskemik tip inme bölgesinin ve IoU-2 hemorajik tip inme bölgesinin segmentasyon başarımını ifade etmektedir. Mean IoU ise ortalama segmentasyon başarımını göstermektedir.

Sonraki deneyde Temel U-Net modeli Dice kayıp fonksiyonu ile kullanılmış ve beyin pencere ayarlı görüntülerle test edilmiştir. Tablo 1'in 2. ve 3. satırından görüleceği üzere Dice kayıp fonksiyonu Categorical Crossentropy kayıp fonksiyonundan daha iyi sonuçlar vermiştir, bunun üzerine sonraki deneylere Dice kayıp fonksiyonu ile devam edilmiştir.

Segmentasyon başarımını artırmak amacıyla U-Net modeli Res2Net omurgasıyla eğitilip test edilmiştir ve Tablo 1'in 3. ve 4. satırına bakıldığında başarımın arttığı görülmüştür. Sonrasında 3.1 Görüntü Pencereleme kısmında anlatılan ön işleme yöntemi ile oluşturulan görüntüler birleştirilmiş ve BT görüntülerinin üç kanallı

görüntüleri (wset3C) oluşturularak kullanılmıştır. Yapılan deneylerde başarımın daha da arttığı gözlemlenmiştir.


Son olarak üç kanallı görüntü oluşturma ön işleme metoduna ek olarak veri çoğaltma da uygulanarak deneylere dâhil edilmiştir. Veri çoğaltma amacıyla görüntülere rotasyon, iki eksende yansıtma, Gaussian blur, kaydırma ve kırpm gibi çeşitli işlemler uygulanarak eğitim veri setinin dört katına çıkması sağlanmıştır. Buna ilişkin deney sonucu da Tablo 1'in son satırında görülmektedir. En iyi segmentasyon başarımının bu koşullarda elde edilmiştir. En iyi segmentasyon performansı elde edilen modele ilişkin IoU ve kayıp grafiği Şekil 10'da gösterilmektedir.



Şekil 10. Res2Net omurgalı U-Net segmentasyon modeline ilişkin eğitim ve test kümelerinin IoU ve kayıp eğrileri

Figure 10. IoU and loss curves of training and test sets for U-Net segmentation model with Res2Net backbone

Şekil 10'daki grafiklere bakıldığında IoU değerinin epok süresince arttığı ve öğrenmenin düzgün bir şekilde gerçekleştiği görülmektedir. Kayıp grafiğinde ise eğitim ve test kümesi için kayıp beklendiği gibi azalmaktadır. Ayrıca Şekil 11'de iskemik tip ve hemorajik tip inme sınıflarına ait segmentasyon sonucu tahmin edilen maske ile gerçek maskenin karşılaştırılması görülmektedir.



Şekil 11. BT görüntüsünde inme bölgesini gösteren gerçek maske ve segmentasyon sonucu tahmin edilen maske a) İskemik tip b) Hemorajik tip

Figure 11. Actual mask showing the stroke area on the CT image and the mask estimated from the segmentation a) Ischemic type b) Hemorrhagic type

Model eğitimi ve testi sırasında AMD Ryzen 9 5900HX işlemcisine sahip NVIDIA GeForce RTX 3080 Mobil GPU kullanılmıştır. Sonuçlar, derin öğrenme modelinin beyin BT görüntülerindeki iskemik ve hemorajik inme

bölgelerini etkili bir şekilde segmente edebildiğini, ayrıca görüntü pencereleme ön işlemi ile de segmentasyon performansının artırıldığını göstermiştir. Elde edilen segmentasyon sonuçları literatürle karşılaştırılabilecek seviyededir.

5. Tartışma ve Sonuçlar

5. Discussions and Conclusions

İnmenin erken tespiti ve inme bölgesinin doğru bir şekilde segmente edilmesi hayati önem taşımaktadır. Bu çalışmada iskemik tip ve hemorajik tip inme içeren beyin BT görüntülerinde inme bölgesinin segmentasyonu gerçekleştirilmiştir. Yapılan deneylerde Res2Net omurgalı U-Net modelinin (0.82) Temel U-Net modelinden (0.76) daha iyi sonuçlar verdiği gözlemlenmiştir. Ayrıca önerilen modelde farklı pencere ayarları ile üç kanallı oluşturulan görüntülerin kullanılmasıyla da segmentasyon başarımı artmıştır (0.87). Üç kanallı görüntülere veri çoğaltma uygulanarak test edildiğinde ise daha iyi bir başarıma ulaşılmıştır (0.92). Sonuçlar, derin öğrenme tabanlı bu yaklaşımın, beyin BT görüntülerinde inme bölgesini otomatik olarak yüksek başarımla segmente edebileceğini göstermektedir. İnme segmentasyonu için önerilen model, geniş ve çeşitli bir veri setinde başarılı bir şekilde eğitilmiş ve test edilmiştir. Model, hem iskemik hem de hemorajik inmeleri etkili bir şekilde belirlemiştir.

Bu çalışmada kullanılan veri seti literatürde farklı araştırmacılar tarafından da kullanılmıştır (Karataş vd., 2022; Yalçın & Vural, 2022; Uçkun vd., 2023). Karataş vd. (2022) BT görüntülerini inme var veya inme yok ve hemorajik veya iskemik olarak sınıflandırma üzerine çalışmışlardır. Yalçın ve Vural (2022) veri seti üzerinde hem sınıflama hem de segmentasyon yapmışlardır ve inme segmentasyonundan %95.2 IoU değeri elde etmişlerdir. Bu değer önerilen çalışmada elde edilen değerden daha yüksektir. Yalçın ve Vural çalışmalarında ön işleme, standartlaştırma, normalizasyon ve veri çoğaltma tekniklerini uygulayarak başarımlarını artırmışlardır. Ön işleme olarak giriş görüntüsünün iki kopyası üzerinde kontrast ayarı ve görüntü filtreleme yaparak iki farklı görüntü elde etmiş ve bu görüntüleri birleştirerek kullanmışlardır. Hemorajik ve iskemik sınıftaki verileri yatay çevirme ve %20 döndürme tekniklerini kullanarak iki katına çıkarmışlardır. Yapılan tüm bu işlemler görüntülerden daha anlamlı özellikler çıkarılmasını sağlayarak başarımları artırmıştır. Uçkun vd. (2023) iskemik inme bölgesinin segmentasyonunda %96.95 IoU değeri elde etmiştir. Bu değer önerilen çalışmada iskemik inme segmentasyonu için elde edilen %84 IoU değerinden yüksektir. Uçkun vd. (2023) inme bölgelerinin segmentasyonunda yüksek başarımla elde etmek amacıyla görüntü üzerinde hem ön işleme hem de veri çoğaltma teknikleri uygulamışlardır. Ön işleme olarak parlaklık değiştirme, Gaussian ve bulanıklık filtreleri uygulama, tuz&karabiber ve Gauss gürültüsü ekleme gibi yaklaşımlar kullanmışlardır. Ayrıca segmentasyon başarımını yükseltmek amacıyla kullandıkları mimarinin son katmanından sonra genişletme evrişim katmanı eklemiştirler. İskemik BT görüntü sayısını 1130'dan 5628'e yükselterek kullanmışlar, ancak veri çoğaltmayı hangi küme (eğitim-test) üzerinde yaptıklarını belirtmemişlerdir. Veri çoğaltma tekniklerinin yalnızca eğitim kümesi üzerinde uygulanması modelin segmentasyon doğruluğunun güvenilirliğini göstermektedir.

Kaya ve Önal (2023) gerçek CT görüntülerinden oluşan farklı bir veri seti üzerinde yaptıkları segmentasyon çalışmasında iskemik ve hemorajik inme için sırasıyla %82.22 ve %92.01 IoU değeri elde etmişlerdir. Önerilen çalışmada ise elde edilen IoU değerleri iskemik ve hemorajik inme için sırasıyla %84 ve %94 olarak elde edilmiş ve daha iyi bir segmentasyon başarımına ulaşılmıştır.

Sonuç olarak, Res2Net omurgalı temel U-Net derin öğrenme modeli, beyin BT görüntülerinden otomatik inme segmentasyonu için etkili yöntemdir. Ayrıca görüntülere uygulanan pencereleme yönteminin istenilen dokuları ön plana çıkarmasından dolayı, farklı pencere ayarlı görüntülerin birleştirilmesiyle oluşan üç kanallı görüntüler model başarımını artırmıştır. Başarımın daha da artırılması için pencereleme işlemi yapıldıktan sonra oluşan üç kanallı görüntüye Uçkun vd. (2023) ve Yalçın ve Vural (2022) tarafından kullanılan ön işleme teknikleri uygulanabilir. Bu çalışmanın sonuçları, otomatik inme segmentasyonunun tıbbi görüntü analizi alanında önemli bir uygulama olduğunu doğrulamaktadır. Bu tür bir sistem, radyologların inme vakalarını daha hızlı ve daha etkin bir şekilde belirlemesine yardımcı olabilir. Böylece, hastaların hızlı ve doğru bir şekilde tedaviye yönlendirilmesi sağlanabilir.

Yazar katkısı*Author contribution*

Tüm yazarlar makaleye eşit katkıda bulunmuşlardır. Çalışmanın planlanması, verilerin analize hazır hale getirilmesi, analizlerin yapılması, sonuçların değerlendirilmesi ve makalenin yazılmasında her iki yazar da eşit katkı sunmuşlardır.

Etik beyanı*Declaration of ethical code*

Bu makalenin yazarları, bu çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve / veya yasal-özel izin gerektirmediğini beyan etmektedir.

Çıkar çatışması beyanı*Conflicts of interest*

Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder.

Kaynaklar*References*

- Aboudi, F., Drissi, C., & Kraiem, T. (2022). Efficient U-Net CNN with data augmentation for MRI ischemic stroke brain segmentation. *In 2022 8th IEEE International Conference on Control, Decision and Information Technologies (CoDIT)* (ss. 724-728), İstanbul.
- Abuzaid, M.M., Elshami, W., Tekin, H., & Issa, B. (2021). Assessment of the willingness of radiologists and radiographers to accept the integration of artificial intelligence into radiology practice. *Academic Radiology*, 29(1), 87-94. <https://doi.org/10.1016/j.acra.2020.09.014>
- Ajam, M., Kanaan, H., Ayache, M., & el Khansa, L. (2019). Segmentation of CT brain stroke image using marker controlled watershed. *In 2019 Fifth IEEE International Conference on Advances in Biomedical Engineering (ICABME)* (ss. 1-4), Tripoli.
- Alhatemi, R.A.J., & Savaş, S. (2022). Transfer learning-based classification comparison of stroke. *Computer Science, IDAP-2022*, 192-201. <https://doi.org/10.53070/bbd.1172807>
- Alquhayz, H., Tufail, H. Z., & Raza, B. (2022). The multi-level classification network (MCN) with modified residual U-Net for ischemic stroke lesions segmentation from ATLAS. *Computers in Biology and Medicine*, 151, 106332.
- Barros, R.S., Tolhuisen, M.L., Boers, A.M., Jansen, I., Ponomareva, E., Dippel, D.W., van der Lugt, A., van Oostenbrugge, R.J., van Zwam, W.H., Berkhemer, O.A., & Goyal, M. (2020). Automatic segmentation of cerebral infarcts in follow-up computed tomography images with convolutional neural networks. *Journal of NeuroInterventional Surgery*, 12(9), 848-852. <https://doi.org/10.1136/neurintsurg-2019-015471>
- Campbell, B.C.V., De Silva, D.A., Macleod, M.R., Coutts, S.B., Schwamm, L.H., Davis, S.M., & Donnan, G.A. (2019a). Ischaemic stroke. *Nature Reviews Disease Primers*, 5(1), 70. <https://doi.org/10.1038/s41572-019-0118-8>
- Campbell, B.C.V., & Khatri, P. (2020). Stroke. *The Lancet*, 396, 129-142. [https://doi.org/10.1016/S0140-6736\(20\)31179-X](https://doi.org/10.1016/S0140-6736(20)31179-X)
- Campbell, B.C.V., Ma, H., Ringleb, P.A., Parsons, M.W., Churilov, L., Bendszus, M., Levi, C.R., Hsu, C., Kleinig, T.J., Fatar, M., Leys, D., Molina, C., Wijeratne, T., Curtze, S., Dewey, H.M., Barber, P.A., Butcher, K.S., De Silva, D.A., Bladin, C.F., Yassi, N., Pfaff, J. A. R., Sharma, G., Bivard, A., Desmond, P.M., Schwab, S., Schellinger, P.D., Yan, B., Mitchell, P.J., Serena, J., Toni, D., Thijs, V., Hacke, W., Davis, S.M., & Donnan, G.A. (2019b). Extending thrombolysis to 4·5-9 h and wake-up stroke using perfusion imaging: a systematic review and meta-analysis of individual patient data. *The Lancet*, 394(10193), 139-147. [https://doi.org/10.1016/S0140-6736\(19\)31053-0](https://doi.org/10.1016/S0140-6736(19)31053-0)
- Clérigues, A., Valverde, S., Bernal, J., Freixenet, J., Oliver, A., & Lladó, X. (2019). Acute ischemic stroke lesion core segmentation in CT perfusion images using fully convolutional neural networks. *Computers in Biology and Medicine*, 115, 103487. <https://doi.org/10.1016/j.combiomed.2019.103487>

- DenOtter, T.D., & Schubert, J. (2023). Hounsfield unit. [Updated 2023 Mar 6]. In: *StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing*; 2023 Jan-. Erişim adresi: <https://www.ncbi.nlm.nih.gov/books/NBK547721/>
- Gao, S. H., Cheng, M. M., Zhao, K., Zhang, X. Y., Yang, M. H., & Torr, P. (2019). Res2net: A new multi-scale backbone architecture. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(2), 652-662.
- Gautam, A. & Raman, B. (2021). Towards effective classification of brain hemorrhagic and ischemic stroke using CNN. *Biomedical Signal Processing and Control*, 63, 102178. <https://doi.org/10.1016/j.bspc.2020.102178>
- GBD (Global Burden of Diseases) 2016 Stroke Collaborators, 2019, Global, regional, and national burden of stroke, 1990-2016: a systematic analysis for the Global Burden of Disease Study 2016. *Lancet, Neurology*, 18(5), 439-458, [https://doi.org/10.1016/S1474-4422\(19\)30034-1](https://doi.org/10.1016/S1474-4422(19)30034-1)
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (ss. 770-778), Las Vegas.
- Hollist, M., Morgan, L., Cabatbat, R., Au, K., Kirmani, M.F., & Kirmani, B.F. (2021). Acute stroke management: Overview and recent updates. *Aging and Disease*, 12(4), 1000-1009. <https://doi.org/10.14336/AD.2021.0311>
- Jung, H. (2021). Basic physical principles and clinical applications of computed tomography. *Progress in Medical Physics*, 32(1), 1-17.
- Karataş, A. F., Doğan, V., & Kılıç, V. (2022). Artificial Intelligence-based Cerebrovascular Disease Detection on Brain Computed Tomography Images. *Avrupa Bilim ve Teknoloji Dergisi*, (41), 175-182.
- Kaya, B., & Önal, M. (2023). A CNN transfer learning-based approach for segmentation and classification of brain stroke from noncontrast CT images. *International Journal of Imaging Systems and Technology*.
- Koç, U., Sezer, E.A., Özkaya, Y.A., Yarbay, Y., Taydaş, O., Ayyıldız, V.A., Kızıloğlu, H.A., Kesimal, U., Çankaya, İ., Beşler, M.S., & Karakaş, E. (2022). Artificial intelligence in healthcare competition (Teknofest-2021): Stroke data set. *The Eurasian Journal of Medicine*, 54(3), 248. <https://doi.org/10.5152/eurasianjmed.2022.22096>
- Li, L., Chen, Y., Bao, Y., Jia, X., Wang, Y., Zuo, T., & Zhu, F. (2020). Comparison of the performance between Frontier ASPECTS software and different levels of radiologists on assessing CT examinations of acute ischaemic stroke patients. *Clinical Radiology*, 75(5), 358-365. <https://doi.org/10.1016/j.crad.2019.12.010>
- Lo, C.M., Hung, P.H., & Lin, D.T. (2021). Rapid assessment of acute ischemic stroke by computed tomography using deep convolutional neural networks. *Journal of Digital Imaging*, 34(3), 637-646. <https://doi.org/10.1007/s10278-021-00457-y>
- Nishio, M., Koyasu, S., Noguchi, S., Kiguchi, T., Nakatsu, K., Akasaka, T., Yamada, H., & Itoh, K. (2020). Automatic detection of acute ischemic stroke using non-contrast computed tomography and two-stage deep learning model. *Computer Methods and Programs in Biomedicine*, 196, 105711. <https://doi.org/10.1016/j.cmpb.2020.105711>
- Osborne, T., Tang, C., Sabarwal, K., & Prakash, V. (2016). How to interpret an unenhanced CT brain scan. Part 1: Basic principles of computed tomography and relevant neuroanatomy. *South Sudan Medical Journal*, 9(3), 67-69.
- Pulli, B., Heit, J.J., & Wintermark, M. (2021). Computed tomography-based imaging algorithms for patient selection in acute ischemic stroke. *Neuroimaging Clinics of North America*, 31(2), 235-250. <https://doi.org/10.1016/j.nic.2020.12.002>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18* (s. 234-241). Springer International Publishing.
- Sacco, R.L., Kasner, S.E., Broderick, J.P., Caplan, L.R., Connors, J.J., Culebras, A., Elkind, M.S., George, M.G., Hamdan, A.D., Higashida, R.T., Hoh, B.L., Janis, L.S., Kase, C.S., Kleindorfer, D.O., Lee, J.M., Moseley, M.E., Peterson, E.D., Turan, T.N., Valderrama, A.L., & Vinters, H.V. (2013). An updated definition of stroke for the 21st century: A statement for healthcare professionals from the American Heart Association/American Stroke Association. *Stroke*, 44(7), 2064-2089. <https://doi.org/10.1161/STR.0b013e318296aeca>

- Subudhi, A., Dash, M., & Sabut, S. (2020). Automated segmentation and classification of brain stroke using expectation-maximization and random forest classifier. *Biocybernetics and Biomedical Engineering*, 40(1), 277-289. <https://doi.org/10.1016/j.bbe.2019.04.004>
- Uçkun, S., Açarlı, M., & Kılıç, V. (2023). Deep Learning-Based Ischemic Stroke Segmentation on Brain Computed Tomography Images. *Avrupa Bilim ve Teknoloji Dergisi*, (50), 105-112.
- Vilela, P., & Rowley, H.A. (2017). Brain ischemia: CT and MRI techniques in acute ischemic stroke. *European Journal of Radiology*, 96, 162-172. <https://doi.org/10.1016/j.ejrad.2017.08>
- Winzeck, S., Hakim, A., McKinley, R., Pinto, J.A.A.D.S.R., Alves, V., Silva, C., Pisov, M., Krivov, E., Belyaev, M., Monteiro, M., Oliveira, A., Choi, Y., Paik, M.C., Kwon, Y., Lee, H., Kim, B.J., Won, J.H., Islam, M., Ren, H., Robben, D., Suetens, P., Gong, E., Niu, Y., Xu, J., Pauly, J.M., Lucas, C., Heinrich, M.P., Rivera, L.C., Castillo, L.S., Daza, L.A., Beers, A.L., Arbelaez, P., Maier, O., Chang, K., Brown, J.M., Kalpathy-Cramer, J., Zaharchuk, G., Wiest, R., & Reyes, M. (2018). ISLES 2016 and 2017-Benchmarking ischemic stroke lesion outcome prediction based on multispectral MRI. *Frontiers in Neurology*, 9, 679. <https://doi.org/10.3389/fneur.2018.00679>
- Yahiaoui, A. F. Z., & Bessaid, A. (2016). Segmentation of ischemic stroke area from CT brain images. *In 2016 IEEE International Symposium on Signal, Image, Video and Communications (ISIVC)* (ss. 13-17), Tunus.
- Yalçın, S. & Vural, H. (2022). Brain stroke classification and segmentation using encoder-decoder based deep convolutional neural networks. *Computers in Biology and Medicine*, 149, 105941. <https://doi.org/10.1016/j.compbimed.2022.105941>
- Yang, H., Huang, C., Nie, X., Wang, L., Liu, X., Luo, X., & Liu, L. (2023). IS-Net: Automatic Ischemic Stroke Lesion Segmentation on CT Images. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 7(5), 483-493.
- Yedavalli, V.S., Tong E., Martin, D., Yeom, K.W., & Forkert, N.D. (2021). Artificial intelligence in stroke imaging: Current and future perspectives. *Clinical Imaging*, 69, 246-254. <https://doi.org/10.1016/j.clinimag.2020.09.005>
- Zhou, X. (2020). Automatic segmentation of multiple organs on 3D CT images by using deep learning approaches. *Advances in Experimental Medicine and Biology*, 1213, 135-147. https://doi.org/10.1007/978-3-030-33128-3_9