



Improvement proposals for lesion segmentation on dermoscopic images

Saadet Aytacı Arpacı^{1*}, Songül Varlı^{1,2}

¹Department of Computer Engineering, Faculty of Electrical and Electronics, Yıldız Technical University, 34220, Istanbul, Türkiye

²Türkiye Health Data Research and Artificial Intelligence Applications Institute, Health Institutes of Türkiye, 34718, Istanbul, Türkiye

Highlights:

- Automatic lesion segmentation on dermoscopic images
- Improvement of U-Net architecture
- Presenting the data augmentation method that increases the segmentation success of the improved model

Keywords:

- U-Net
- Segmentation
- Convolutional neural networks
- Dermoscopic lesion
- Mix data augmentation

Article Info:

Research Article

Received: 31.07.2023

Accepted: 23.02.2024

DOI:

10.17341/gazimmfd.1335533

Correspondence:

Author: Saadet Aytacı Arpacı
e-mail:

saadeta99@gmail.com

phone: +90 212 383 5730

Graphical/Tabular Abstract

In this article, a new design of the U-Net architecture (EnecaU-Net) is presented by improving the encoder part of the U-Net model, and we evaluate the segmentation success of the proposed architecture for lesion segmentation on dermoscopic images. Furthermore, in this article, the effect of a data augmentation method based on image mixing on the segmentation ability of the proposed model for lesion segmentation on dermoscopic images has been investigated (Figure A).




Figure A. General execution framework of the improvement proposal

Purpose:

The aim of this study is to present new proposals to improve the task of lesion segmentation on dermoscopic images. These proposals are aimed at the model that performs the segmentation and the data augmentation method that supports the model within the segmentation process.

Theory and Methods:

The implemented segmentation architecture (EnecaU-Net) has two encoder paths and one decoder section. The model we propose receives the same input samples at the same time through two encoder paths, the up-sampling process is used in the first encoder part of the model (in order to obtain a precise segmentation of the region of interest). In addition, the “Efficient Channel Attention” (ECA) module has also been added to the second encoder section to refine the dense information in the image and process useful information. The data augmentation method applied in this study is based on the principle of adding (combining, mixing) randomly selected samples from the “International Skin Imaging Collaboration” (ISIC-2016) training images according to the value $\lambda=0.4$. The obtained 2000 images were trained at 50 epochs with a size of 128×128 at the gray level. No pre-processing techniques were applied to the images before the training and testing processes in order to remove the factors that would complicate the segmentation process, such as skin hairs or air/oil bubbles, from the images.

Results:

Experimental evaluations' results show that the proposed model used together with the mix data augmentation method achieves high results after training and then for testing. The proposed model achieves training validation results with an accuracy of 97.36%, a sensitivity of 94.64%, a specificity of 98.16%, a Dice similarity coefficient of 94.11%, and a Jaccard index of 88.89% on the ISIC-2016 dataset; and the proposed model achieves test results with an accuracy of 94.19%, a sensitivity of 90.73%, a specificity of 94.78%, a Dice similarity coefficient of 88.05%, and a Jaccard index of 80.30% on the ISIC-2016 dataset.

Conclusion:

The segmentation success of the EnecaU-Net model applied for lesion segmentation on dermoscopic images is high, and the applied mix data augmentation method improves the segmentation success of the EnecaU-Net model.



Dermskopik görüntülerde lezyon bölütleme için iyileştirme önerileri

Saadet Aytaç Arpacı^{1*}, Songül Varlı^{1,2}

¹Yıldız Teknik Üniversitesi, Elektrik Elektronik Fakültesi, Bilgisayar Mühendisliği Bölümü, 34220, Esenler, İstanbul, Türkiye

²Türkiye Sağlık Veri Araştırmaları ve Yapay Zeka Uygulamaları Enstitüsü, Türkiye Sağlık Enstitüleri Başkanlığı, 34718, Kadıköy, İstanbul, Türkiye

ÖNEÇIKANLAR

- Dermskopik görüntülerde otomatik lezyon bölütleme
- U-Net mimarisinin iyileştirilmesi
- İyileştirilen modelin bölütleme başarısını yükselten veri artırma yönteminin sunulması

Makale Bilgileri

Araştırma Makalesi

Geliş: 31.07.2023

Kabul: 23.02.2024

DOI:

10.17341/gazimmfd.1335533

Anahtar Kelimeler:

Evrişimsel sinir ağı,
karıştırma veri artırma,
bölütleme,
dermskopik lezyon,
U-Net

ÖZ

Görüntülerde bölütleme görevini gerçekleştiren U-Net mimarisi tıp alanında da oldukça başarılı sonuçlar elde etmiştir. Fakat daha iyi sonuçlar için mimarinin iyileştirilmesine de gerek vardır. Bu makalede, U-Net modelinin kodlayıcı bölümü için bazı iyileştirme önerileri sunulmaktadır ve uygulanan mimarinin dermskopik görüntülerde lezyon bölütleme işlemi için bölütleme başarısı değerlendirilmektedir. Araştırma, PH2 ve "Uluslararası Cilt Görüntüleme İşbirliği" (ISIC-2016 ve ISIC-2017) veri kümeleri ile yapılmıştır. Geleneksel veri artırma yöntemi, seçilen PH2 veri kümesi örneklerine uygulanmıştır. Önerilen model (EnecaU-Net) ve U-Net modelinin PH2 veri kümesi ile elde edilen sonuçları karşılaştırılmıştır. Ayrıca bu makalede dermskopik görüntülerde lezyon bölütleme işlemi için modelin bölütleme başarısı üzerinde etki gösteren karıştırma veri artırma yöntemi de incelenmiştir. Bu inceleme, ISIC-2016 veri kümesi ile yapılmıştır ve veri artırma işlemi uygulanmayan aynı miktardaki ISIC-2017 veri kümesi ile yapılan inceleme sonuçları karşılaştırılmıştır. Değerlendirme aşamasında model başarısının ölçümü için öncelikle Dice ve Jaccard (IoU) ölçütlerini kullanmış olmakla beraber özgüllük, duyarlılık ve doğruluk ölçütlerinden de faydalanılmıştır. Elde ettiğimiz sonuçlara göre, dermskopik görüntülerde lezyon bölütleme işlemi için uygulanan EnecaU-Net modelinin bölütleme başarısı yüksektir ve uygulanan karıştırma veri artırma yöntemi, EnecaU-Net modelinin bölütleme başarısını iyileştirmektedir. Önerilen modelin ulaştığı ortalama test sonuçları, Dice ve Jaccard değerleri açısından sırasıyla ISIC-2016 için %88,05 ve %80,30 ve ISIC-2017 için %83,09 ve %74,54'tür.

Improvement proposals for lesion segmentation on dermoscopic images

HIGHLIGHTS

- Automatic lesion segmentation on dermoscopic images
- Improvement of the U-Net architecture
- Presenting the data augmentation method that increases the segmentation success of the improved model

Article Info

Research Article

Received: 31.07.2023

Accepted: 23.02.2024

DOI:

10.17341/gazimmfd.1335533

Keywords:

Convolutional neural
network,
mix data augmentation,
segmentation,
dermskopik lesion,
U-Net

ABSTRACT

The U-Net architecture, which performs segmentation on images, has also achieved very successful results in the medical field. However, there is also a need to improve the U-Net architecture for better results. In this article, some improvement proposals are presented for the U-Net model's encoder part, and the segmentation success of the implemented architecture for segmentation of dermoscopic image lesions is evaluated. The PH2 dataset and the "International Skin Imaging Collaboration" datasets (ISIC-2016 and ISIC-2017) were used for the research. The traditional data augmentation method was applied to the selected PH2 dataset samples. The results of the proposed model (EnecaU-Net) and the U-Net model obtained with the PH2 dataset were compared. Furthermore, in this article, the mix data augmentation method, which has an influence on the model's segmentation success, is examined for lesion segmentation on dermoscopic images. This investigation was made with the ISIC-2016 dataset, and its experimental results were compared with the same amount of the ISIC-2017 dataset that didn't apply data augmentation operations. Although, during the evaluation phase, Dice and Jaccard (IoU) metrics were used primarily to measure the success of the model, specificity, sensitivity, and accuracy criteria were also used. According to our results, the segmentation success of the EnecaU-Net model applied for lesion segmentation on dermoscopic images is high, and the applied mix data augmentation method improves the segmentation success of the EnecaU-Net model. The average test results achieved by the proposed model are 88.05% and 80.30% for ISIC-2016 and 83.09% and 74.54% for ISIC-2017 in terms of the Dice and Jaccard values, respectively.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *saadeta99@gmail.com, svarli@yildiz.edu.tr / Tel: +90 212 383 5730

1. Giriş (Introduction)

Semantik bölütleme, bir görüntü içinde aynı sınıfa ait pikselleri bir araya getirme işlemidir. Bu gruplandırılmış pikseller sayesinde istenilen bölge, sınırları ile birlikte elde edilir. Bu görev, günümüzde yapay sinir ağına dayalı yöntemlerle kolaylıkla gerçekleştirilmektedir. Tıbbi görüntülerin yüksek doğruluk oranı ile otomatik bölütlenmesi de bilgisayar destekli teşhisin gücünü artırmak için çok önemli bir işlemdir. Manuel bölütleme görevlerinin zorluğundan dolayı zamanla evrimsel sinir ağı gibi yaklaşımları kapsayan yapay sinir ağı yöntemleri oluşturulmuştur, diğer alanlarda olduğu gibi tıbbi alanda da bölütleme işlemlerini kolaylaştıran çok sayıda uygulama geliştirilmiştir. Bu sürecin içerisinde yerini alan evrimsel sinir ağı tabanlı U-Net mimarisi de [1] 2015 yılında önerilmiştir.

Bölütlenmesi istenilen bölge ile çevresi arasındaki kontrastın zayıflığı dolayısıyla bulanık sınır mevcudiyeti, farklı görüntü modaliteleri ile yapılan farklı tıbbi alanlara ait bölütleme çalışmalarında bölütleme işlemini zorlaştıran genel bir sorundur. Bu ve benzeri sorunları çözmek ve daha verimli bir bölütleme sonucu elde edebilmek için araştırmacıların başvurduğu yöntemlerden biri de dikkat (attention) mekanizmasıdır. Bu mekanizmalar sayesinde yoğun ve gereksiz bilgi rafine edilerek bölütlenmesi istenilen görüntü alanına ait en önemli ve belirgin özellikler elde edilir. “Verimli Kanal Dikkat” (Efficient Channel Attention, ECA-Net) [2] yöntemi de bu dikkat mekanizmalarından biridir. [3-5] çalışmaları ECA-Net modelini U-Net mimarisine entegre ederek kullanmıştır. Bu konudaki diğer örnekler ise [6, 7] çalışmalarıdır.

U-Net modeli geliştirildiği yıllarda verimli bir bölütleme başarısı göstermiştir. Günümüze kadar U-Net mimarisi, bölütleme araştırmalarında geniş bir kullanım alanı bulmuştur hatta çok sayıda yeni modelin geliştirilmesinde temel bir yapıtaşı olmuştur. U-Net modeli temelinde geliştirilen ve U-Net yöntemine göre daha iyi performans gösteren IterNet [8], W-Net [9, 10] gibi bazı varyant modeller de zaman içerisinde sunulmuştur [11-13]. Bu tür varyant modellerin oluşturulmasında, iki veya daha fazla U-Net mimarisi, yapılan araştırmaya göre değişen belirli bağlantı yollarıyla birleştirilir. Özetle, U-Net tasarımı N kez uygulanarak tek bir bölütleme modeli oluşturulur ($N = \text{U-Net mimarisinin miktarı}$). Bu araştırmalar doğrultusunda, bu araştırmanın motivasyonu, U-Net modelinin verimliliğini artırmak için çok miktarda U-Net modelini ağ içinde kullanmak yerine daha az karmaşık ve verimli bir mimari tasarım geliştirmektir. Bu çabamızı Khanna vd. [14] nin yaptığı çalışmaya dayanarak sunarız. Akciğer bölgesinin bölütlenmesi için U-Net modeline artık bağlantıyı uygulayan Khanna vd. [14], daha derin ağı etkisini gözlemlemek için ResNet34 ve ResNet50'ye dayalı U-Net mimarileri ile deneyler yaptı. Zorlu görüntülere sahip HUG-ILD veri kümesinde, birinci model için %96,28 ve ikinci model için %97,39 ortalama Jaccard metrik değerleri çalışmalarında elde edilmiştir [14]. Bu bulgulara göre katman sayısının artırılması örtüşme (overlap) oranında yaklaşık %1'lik bir artış sağlamıştır. Bu sonuçların işaret ettiği durum ise: işlevselliği olan, çok fazla (aşırı miktarda) olmayan, yeterli miktardaki katmanlarla kurulan bölütleme mimarilerine olan ihtiyaçtır. Böylece gereksiz olan işlemsel sürecin azaltılması ile modelin donanım birimleri üzerindeki yükü de hafifler.

Bu çalışmadaki amacımız, U-Net mimarisi temelinde, daha az miktarda katmanın daha etkin kullanımı ile kurulan iyileştirilmiş temel bir bölütleme mimari çerçevesi sunmaktır. Bu doğrultuda, U-Net modelinin iyileştirilmesine yönelik daha önceki çalışmalardan [2, 15, 16] edinilen bazı bilgileri kullanıyoruz. Modeldeki en temel unsurlar, iki ayrı kodlayıcı bölümü sayesinde giriş görüntü örneklerinin aynı anda ayrı yollardan alınması [15], bölütleme detaylarını iyileştirmek için yukarı örnekleme (up-sampling)

işleminin kodlayıcı bölüm içerisinde kullanılması [16], faydalı bilginin elde edilmesi için bir dikkat mekanizması çeşidi olan ECA-Net modülünün [2] kullanılması. Halka açık üç veri kümesi ile yapılan değerlendirme sonuçları, önerilen EnecaU-Net modelinin dermoskopik lezyon bölütlemesi için yüksek bölütleme başarısına ulaştığını gösteriyor. Makalenin başlıca katkıları aşağıda özetlenmektedir:

- U-Net mimarisinin kodlayıcı yolu için bazı iyileştirme önerileri sunulur. Aynı anda aynı giriş görüntülerini iki ayrı kodlayıcı yol vasıtasıyla alan bölütleme mimarisinin birinci kodlayıcı bölümü içerisinde yukarı örnekleme işleminin uygulanması ve her iki kodlayıcı bölümden elde edilen özelliklerin kodlayıcı bölüme ait diğer bir işlem olan ECA-Net modülünden geçirilmesi, bu öneriler arasındadır.
- Yeni bir bölütleme model önerisi (EnecaU-Net) farklı dermoskopik görüntülerdeki lezyon bölütleme işlemi için uygulanır.
- Bu çalışmada uygulanan veri artırma yöntemlerinin etkisi, EnecaU-Net modeli ile dermoskopik görüntülerde lezyon bölütleme işlemi için incelenir.
- EnecaU-Net modeli, PH2, ISIC-2016 ve ISIC-2017 olmak üzere kamuya açık üç farklı dermoskopik veri kümesi ile değerlendirilir.

Bu makalenin devamı 5 başlık altında ilerler: Bölüm 2’de, literatürdeki ilgili çalışmalar; Bölüm 3’te, önerilen mimari, veri kümesi ve değerlendirme ölçütleri hakkında bilgiler; Bölüm 4’te, deneysel bulgular ve tartışma; Bölüm 5’te, sonuçlar bölümü.

2. İlgili Çalışmalar (Related Works)

U-Net ve türetilmiş U-Net varyasyonları, dermoskopik lezyon bölütleme görevleri için geniş bir uygulama alanına sahiptir. Konuyla ilgili yapılan son araştırmalardan bazıları yazının devamında sunulmuştur. Dermoskopik lezyon bölütleme işlemi [17] için U-Net modelinin kullanıldığı bir çalışmada, yazarlar “Uluslararası Cilt Görüntüleme İşbirliği” (ISIC) veri kümesinden elde edilen görüntülere Gauss filtreleme yöntemini uygulamıştır, bu görüntüleri ve orijinal görüntüleri model eğitiminde kullanmışlardır. Yapılan değerlendirmeler sonucunda %95 doğruluk oranına ulaşılmıştır. U-Net’in bir varyantı olan W-Net mimarisi, dermoskopik lezyon bölütleme işlemi için referans [18] araştırmasında önerilmiştir. Birbirine bağlı iki U-Net mimarisinden oluşan W-Net modeli [18], her iki ayrı U-Net mimarisi kodlayıcı bölümünden giriş görüntülerini almaktadır. Zou ve Wu [19] yakın zamanda SwinE-U-Net3+ modelini önermiştir. Modelin kodlayıcı bölümünde özellikleri çıkarmak için iki ardışık “Swin Transformer” bloğu kullanılır. Kod çözücü bölümünde, yukarı örnekleme işlemini gerçekleştirebilmek için “Conv2DTranspose” işlemi ve yukarı örnekleme işleminden sonra kod çözücü bilgilerini ve atlama bağlantısı yoluyla kodlayıcı bölümden gelen bilgileri bir araya getirmek için evrişim işlemi kullanılmıştır. Diğer çalışmada [20] ise modifiye bir mimari oluşturularak ikili odak kaybı işlevine ve Dice kaybı işlevine dayalı yeni bir birleşik kayıp işlevi modelde uygulanmıştır. ISIC 2016 ve ISIC 2017 veri kümeleri ile yapılan deneye göre doğruluk sonuçları sırasıyla % 95 ve % 91 olarak elde edilmiştir.

Dermoskopik lezyon bölütleme işlemi gerçekleştirmek için U-Net tasarımında artık bağlantı yapısının [21] kullanımına birçok çalışmada rastlanmıştır. Bu artık bağlantıları U-Net mimarisine uygulayan [22, 23] araştırmacıları, yüksek doğruluk ve örtüşme oranları elde etmiştir. Bu referanslarda olduğu gibi [24]’ün yazarları, U-Net modelinde dermoskopik lezyon bölütleme işlemi için artık bağlantıları kullanmışlardır. Yazarlar [24] tarafından U-Net modelini geliştirmek için “çift yönlü evrişimli uzun kısa süreli bellek” (Bi-directional Convolutional Long Short Term Memory) tekniği de kullanılmıştır.

Referans [25] yazarları, dermoskopik görüntülerde farklı yaklaşımlarla elde edilen renk kanallarının daha iyi U-Net bölütleme performansı için kritik olduğunu gözlemledi. [26] makalesinde “tamamen evrişimli ağ” ve U-Net mimarilerine dayalı olarak dermoskopik lezyon bölütleme işlemi için yeni bir model sunulmuştur. Alhudhaif vd. [27], U-Net, ResNet ve V-Net mimarilerine dayalı yeni bir bölütleme mimarisi sunmuştur. Beeche vd. [28], önerdikleri modelde dermoskopik lezyon bölütleme işlemi için ortalama 0,877 Dice katsayı değeri elde etmiştir. Başka bir çalışmada ise [29], U-Net modelinde dikkat mekanizması ve artık bağlantılar kullanılarak, ISIC 2018 veri kümesinde Dice katsayısı için %89,14 ve Jaccard metriği için %81,16 değerleri elde edilmiştir. U-Net mimarisine dayanan diğer bir modeldeki [30] kodlayıcı bölüm, artık bağlantı blokları ile oluşturulmuştur, modelin köprü bölümü “uyarlanabilir bir bağlam füzyon” (adaptive context fusion) modülü içermektedir. Modelde genişletilmiş evrişim ve dikkat mekanizmasının avantajları birleştirilmiştir, uzamsal bilgi kaybını azaltarak kodlayıcı ve kod çözücü bölümler arası füzyon sürecinde geçersiz bilgileri bastırarak için atlama mimarisine “geçişli artık füzyon modülü” (GRF) eklenmiştir. ISIC 2016 ve ISIC 2017 veri kümeleri üzerinde yöntemin verdiği sonuçlar doğruluk ve örtüşme oranını artırdığı yönündedir. Diğer bir çalışmada ise [31], yerel ve küresel bağlamsal bilgileri yakalamak için, kodlayıcı bölümün farklı aşamalarında artık bağlantı ve dikkat mekanizmasından faydalanılan bloklar, [31] makalesinde önerilen mimaride kullanılmıştır. Mimarinin son aşamasında, cilt lezyonu bölütleme işleminin sonuçlarını iyileştirmek için farklı kod çözücülerin özellik haritalarını birleştiren bir yeniden şekillendirilmiş kod çözücü füzyon modülü kullanılmıştır.

Dermoskopik görüntülerde lezyon bölütleme işleminde mimarilerine ECA modülünü ekleyen çalışmalara da rastlanmaktadır. “Geçitli eknesel dikkat özellik çıkarma modülü” (Gated Axial-Attention Feature Extraction Module) ve ECA modülü ile oluşturdukları iki kodlayıcı bölüm ve bir kod çözücü bölümden oluşan bölütleme mimarisi ile yazarlar [32] farklı cilt lezyon veri kümelerinde elde ettikleri sonuçları sunmuşlardır. Yazarlar [33] araştırmasında, SE [34] ve ECA [2] modüllerine dayalı yeni bir dikkat modülünü U-Net mimarisinin köprü kısmına eklemiştir. Bu sayede ağır kodlayıcı yapısından daha fazla özellik elde edildiğini ifade etmektedirler. Dermoskopik lezyon bölütlemesi için kullanılan ISIC-2018 veri kümesinde %81,82 Dice ve %73,22 Jaccard katsayı değerleri çalışmadan elde edilmiştir. Var olan çoğu yapay sinir ağı yöntemleri sıklıkla çok sayıda parametreye ve karmaşık algoritma yapılarına sahip olduğundan yüksek donanım gereksinimlerine ve uzun eğitim süresine ihtiyaç gösterir. Donanımdaki yükü azaltmak adına yaptığımız bu çalışmadaki temel nedenimizle uyumlu olarak Litao Yang vd. [35] nin yaptığı çalışmada ise yazarlar, ECA modülünü mimarinin kodlayıcı bölümünde uygular. Modelin kodlayıcı bölümünden alınan özellikler kod çözücü bölümün özellikleri ile ters dikkat özelliği etkileşim modülü üzerinden birleştirilir. Rastladığımız bir diğer çalışmada da [36] yine daha hafif ve güvenilir bir bölütleme modeli oluşturmaya yöneliktir. Bu tür araştırmalar bu araştırmadaki çabamızın hem destekleyicisidir hem de geleceğe yönelik daha fazla araştırma yapılacağı yönünde işaretçisidir. Yazarlar [36], giriş görüntülerinin uzamsal çözünürlüğünü azaltmak için bir kenar yumuşatma katmanı ve evrişim bloğunu kodlayıcı bölümde kullanır. Kod çözücü bölümde, her kanaldaki belirgin özellikleri yakalamak için bir dikkat bloğu ve kod çözücü modülü kullanılır.

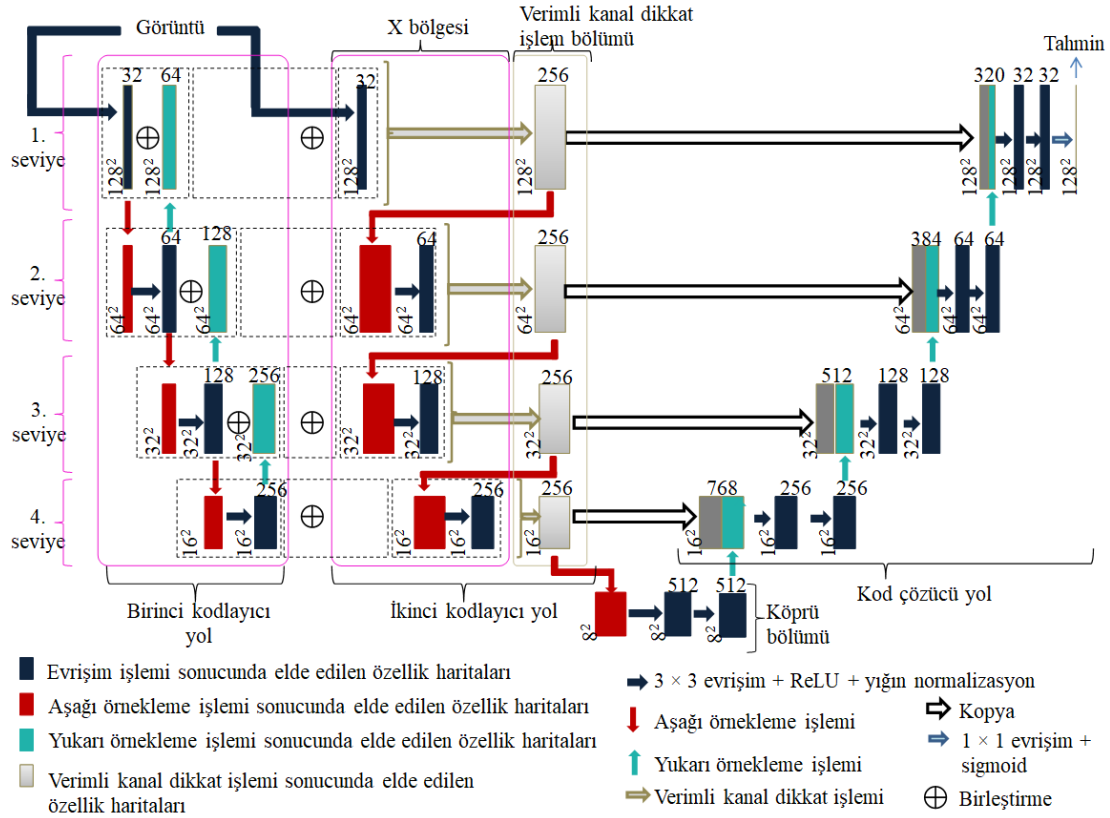
3. Deneysel Metot (Experimental Method)

Bu çalışma, üç farklı dermoskopik veri kümesi ile görüntülerdeki lezyon alanlarının bölütlenmesi işlemini önerilen bir bölütleme modeli vasıtasıyla gerçekleştirmektedir. Çalışmada kullanılan her veri kümesi için farklı bir süreç işletilerek önerilen model

değerlendirilmiştir. İlk aşamada EnecaU-Net modeli U-Net modeli ile karşılaştırılmıştır. EnecaU-Net modelinin sonuçlarının karşılaştırıldığı U-Net mimarisi [16]’da kullanılan (karşılaştırılan) mimariyle aynıdır. Çalışmanın bu aşamasında her iki model geleneksel veri artırma yöntemi uygulanmış PH2 veri kümesi görüntüleri ile eğitilmiştir, eğitim ve test sonuçları elde edilmiştir. Çalışmada uyguladığımız karıştırma veri artırma tekniğine dayalı yöntemin EnecaU-Net modelinin bölütleme başarısına olan etkisi çalışmanın ikinci süreci içerisinde incelenmiştir. İkinci aşamada görüntülerin karıştırılmasına dayalı bir yöntemle veri artırma işlemi, ISIC-2016 veri kümesi için gerçekleştirilmiştir. Çalışmanın üçüncü aşamasında veri artırma yöntemi uygulanmasına ihtiyaç göstermeyen ISIC-2017 veri kümesi ile EnecaU-Net mimarisi değerlendirilmiştir.

3.1. Önerilen Bölütleme Modeli (Proposed Segmentation Model)

Şekil 1 önerilen modelin (EnecaU-Net) tasvirini sunmaktadır. Modele “EnecaU-Net” isimlendirmesinin yapılmasının nedeni mimarisinde EncU-Net ve ECA-Net modellerinden faydalanılmış olumasıdır. Çizimde (Şekil 1) gösterildiği gibi, EnecaU-Net modelinin iki kodlayıcı yolu ve bir kod çözücü bölümü vardır. EnecaU-Net modelinde, aynı giriş görüntüleri iki kodlayıcı yolunda aynı anda işleme alınır. Kodlayıcı ve kod çözücü yolları, yukarıdan aşağıya 4 seviyede, bloklardan oluşur. Birinci ve ikinci kodlayıcı bölümlerinin her seviyesindeki her blok içerisinde evrişim işlemi bir kez gerçekleşir. Aynı seviyedeki kod çözücü bölümü bloklarında ise evrişim işlemi iki kez gerçekleşir. Yukarı örnekleme işlemi, ilgilenilen bölgenin belirgin bir bölütleme alanını elde etmek için modelin ilk kodlayıcı bölümünde kullanılır. İkinci kodlayıcı yolu, “X bölgesi” olarak tanımladığımız evrişim işlemi gerçekleştiren bir bölüm ve ECA işlemini gerçekleştiren ikinci bir bölümden oluşur. Birinci kodlayıcı bölümünün her bir seviyesindeki blok çıkışları, aynı seviyede karşılık gelen ikinci kodlayıcı bölümünün “X bölgesi” alt bölümündeki blok çıkışları ile “concatenate” işlemi aracılığıyla birleştirilir. Devamında elde edilen özellik haritalarına ECA işlemi uygulanır. Birinci ve ikinci kodlayıcı bölümündeki işlemler sonucunda elde edilen nihai çıktılar, U-Net modelinde olduğu gibi kod çözücü bölümünde karşılık gelen katmanlarla birleşir. Modeldeki köprü ve kod çözücü bölümü mimarisi, U-Net modelindekiyle aynı mimari kurulumu korudu, ancak özellik haritalarındaki kanal sayısı azaltıldı. Modelin tamamında evrişim işleminden (3×3) sonra toplu normalleştirme işlemi uygulanmış ve aktivasyon fonksiyonu olarak ReLU kullanılmıştır. EnecaU-Net mimarisinde kullanılan ECA-Net modülünde [2] yazarlar, kanal başına ortalama piksel değerini elde etmek için yöntemde “global ortalama havuzlama” yaklaşımı kullanır. Öznitelikler elde edildikten sonra, kanaldaki etkin bilgiyi öğrenmek için 1 boyutlu evrişim işlemi gerçekleşir. Birinci kodlayıcı bölümünde evrişim işlemi ve ikinci kodlayıcı bölümünde ECA yöntemini uyguladıktan sonra, özellik haritalarını aşağı örnekleme için maxpooling işlemi (2×2) kullanıldı. Kod çözücü bölümünde ise ikinci evrişim işleminden sonra çift doğrusal enterpolasyon yöntemi ile yukarı örnekleme görevi yapılmıştır. Aynı seviyedeki birinci kodlayıcı ve ikinci kodlayıcı bölümündeki “X bölge” bloklarında bir evrişim işlemi yapılırken, köprü ve kod çözücü bölüm bloklarında arka arkaya iki evrişim işlemi gerçekleştirilir. Önerilen ağ, her iki kodlayıcı bölümü için birinci seviyedeki ham görüntüden evrişim yoluyla 128×128 ve 32 kanal boyutunda özellik haritaları üretmektedir. Birinci kodlayıcı bölümünde her aşağı örnekleme işleminden sonra uygulanan evrişim işlemi ile özellik haritalarının kanal miktarı iki katına çıkar ve boyutları yarıya iner, ikinci kodlayıcı bölüm bloklarında evrişim işlemi sonrası elde edilen özellik haritalarının kanal sayısı ve boyutları, karşılık gelen birinci kodlayıcı bölüm bloklarında evrişim işlemi sonucunda elde edilen özellik haritaları ile aynıdır. Adam tekniği [37] ve ikili çapraz entropi kaybı sırasıyla önerilen modelin optimizasyonu algoritması (0,001 öğrenme oranıyla başlayan) ve kayıp fonksiyonu olarak kullanıldı. Çıkışta $1 \times$



Şekil 1. EnecaU-Net modeli (EnecaU-Net model)

1 evrişim katmanı (sigmoid aktivasyon fonksiyonu ile) kullanıldı. Modelin performansı, 50 eğitim döneminin ardından ölçülmüştür. Bu araştırmayı yürütmek için arka uçta TensorFlow [38] çerçevesini kullanan Keras kütüphanesi [39] kullanılmıştır.

3.2. Veri kümeleri ve Ön işlem (Datasets and Preprocessing)

Dermoskopik görüntülerde lezyon bölütleme işlemi için uygulanan EnecaU-Net modeli üç farklı veri kümesi ile değerlendirilmiştir. İlk veri kümesi olan PH2 [40] dermoskopik görüntüleri, Portekiz'deki "Pedro Hispano Hastanesi"nden elde edilmiştir. Bu görüntüler (koşulların aynı olmasına dikkat edilerek) 20x büyütmede "Tuebinger Mole Analyzer" ekipmanı ile elde edilmiştir. 8 bit RGB renkli görüntüler, 768 x 560 piksel çözünürlüğe sahiptir. Yaygın (80 adet), atipik (80 adet) nevüs ve melanom (40 adet) olmak üzere bu veri kümesinin içerisinde toplamda 200 adet dermoskopik lezyon görüntüsü bulunmaktadır. Görüntüler ve ayrıca uzmanlar tarafından sağlanan gerçek referans görüntüleri web sitesinden [41] elde edilebilir. Araştırmanın ön değerlendirme süreci olan bu ilk aşaması için kullanacağımız veri grubu PH2 veri kümesinden hazırlanırken lezyon bölütleme işlevini engelleyen saç faktörünün bulunmadığı görüntüler seçilerek veri grubuna dahil edilmiştir. 2 boyutlu görüntülerden oluşan veri grubunun üçte biri test için ayrılmıştır; yani, PH2 veri grubunun 20 görüntüsü. Eğitim görüntülerine (40 adet) veri artırma yöntemleri uygulanmıştır. PH2 veri grubu için geleneksel veri artırma yöntemleri uygulanarak veri miktarının artırılması sağlanmıştır. Bu amaçla eğitim görüntülerine yatay-dikey yansıtma, görüntüyü maksimum 10° sağa ve sola çevirme gibi veri artırma işlemleri uygulanmıştır. "Augmentor" kütüphanesi [42] veri artırma işlemi için kullanılmıştır ve sonuç olarak eğitimde kullanmak amacıyla dermoskopik lezyon bölütleme işlemi için 270 renkli görüntü elde edilmiştir, görüntüler 128 x 128 piksel çözünürlüğe yeniden boyutlandırılarak 50 iterasyon ile eğitilmiştir.

Çalışmada kullandığımız ikinci veri kümesi "Uluslararası Cilt Görüntüleme İşbirliği" (ISIC) topluluğu tarafından 2016 yılında genel erişime açılan dermoskopik görüntülerdir [43]. Görüntüler uluslararası klinik merkezlerde kullanılan çeşitli cihazlardan alınmış ve tanınmış melanom uzmanları tarafından incelenmiştir. Veri kümesi, alanına yönelik klinik olarak ilgili temsili örnekleri içermektedir. Farklı çözünürlük seviyelerinde 900 adet renkli (8 bit RGB) eğitim görüntüsü ikili gerçek referans görüntüleriyle birlikte veri kümesinde sunulmaktadır [44]. Çalışmanın ikinci aşamasında Zhang vd. [45] nden esinlenen bir veri artırma süreci gerçekleştirilmiştir. Bu yöntemle sınıflar arasındaki yumuşak geçiş alanlarının dermoskopik görüntülerde lezyon bölütleme üzerindeki etkisi araştırılmıştır. Bu amaçla eğitim için Eş. 1 ve Eş. 2 temel denklemleri üzerinde $\lambda=0,4$ değerine göre 2000 görüntüden oluşan bir veri grubu hazırlanmıştır.

$$\tilde{x} = \lambda x_i + (1 - \lambda)x_j \quad (1)$$

$$\tilde{y} = \lambda y_i + (1 - \lambda)y_j \quad (2)$$

Eş. 1 ve Eş. 2 denklemlerinde, x_i ve x_j ham girdi görüntülerini ve y_i ve y_j gerçek referans görüntüleri temsil eder. Veri artırma için uyguladığımız karıştırma işlemine giren örnekler, tüm görüntülerden rastgele örnekler seçilerek oluşturulmuştur. EnecaU-Net modeli, gri seviyeye dönüştürülmüş 128 x 128 boyutlu görüntülere sahip bu veri grubu üzerinde 50 iterasyon ile eğitilmiştir.

"Uluslararası Cilt Görüntüleme İşbirliği" topluluğu tarafından 2017 yılında erişime sunulan dermoskopik görüntüler ise çalışmamızın üçüncü aşamasında kullanacağımız veri kümesidir [46]. ISIC-2016 veri kümesiyle benzer özelliklere sahip ISIC-2017 veri kümesinde eğitim için 2000 adet görüntü ikili gerçek referans görüntüleriyle

birlikte sunulur [47]. Çalışmanın üçüncü aşamasında, kullanılan örnek miktarının veri artırma işlemine ihtiyaç göstermeyecek bir seviyede olması nedeniyle sunulan 2000 adet görüntü gri seviyede 128×128 boyut ile 50 iterasyonda eğitilmiştir.

Tüm veri grupları için doğrulama işlemi, veri kümesi görüntülerinin %20'sinde gerçekleştirilmiştir.

3.3. Değerlendirme Ölçütleri (Evaluation Metrics)

Doğruluk (Eş. 3), duyarlılık (Eş. 4) ve özgülük (Eş. 5) referans [16] makalesi ile aynı şekilde ölçülmüştür. Metrikler hakkında açıklayıcı bilgiler [16]'da bulunabilir. Piksel düzeyinde "Doğru Pozitif" (D_P), "Doğru Negatif" (D_N), "Yanlış Pozitif" (Y_P) ve "Yanlış Negatif" (Y_N) miktarlarına göre çalışmada uygulanan eşitlikler aşağıda tanımlanmaktadır.

$$\text{Doğruluk} = \frac{D_N + D_P}{D_N + D_P + Y_N + Y_P} \quad (3)$$

$$\text{Duyarlılık} = \frac{D_P}{D_P + Y_N} \quad (4)$$

$$\text{Özgüllük} = \frac{D_N}{D_N + Y_P} \quad (5)$$

Dice benzerlik katsayısı ve Jaccard indeksi (IoU), bölütleme görevleri için en yaygın kullanılan iki ölçümdür. Dice benzerlik katsayısı, gerçek referans alan (X) ve tahmin edilen alan (Y) kesişim alanının bu alanların toplamına bölümüdür. Jaccard benzerlik katsayısı olarak bilinen ölçüt, gerçek referans alan (X) ile tahmin edilen alanın (Y) kesişiminin, gerçek referans alan (X) ve tahmin edilen alan (Y) birleşimine bölümü olarak tanımlanır [48]. Dice (Eş. 6) ve Jaccard (Eş. 7) katsayılarını genel olarak şu şekilde tanımlarız:

$$\text{Dice} = \frac{2|X \cap Y|}{|X| + |Y|} \quad (6)$$

$$\text{Jaccard} = \frac{|X \cap Y|}{|X \cup Y|} \quad (7)$$

Bu çalışmada, Dice (Eş. 8) ve Jaccard benzerlik (Eş. 9) katsayılarının D_P, Y_P ve Y_N değerlerine dayalı olarak aşağıdaki denklemler kullanılarak hesaplandığına dikkat çekiyoruz.

$$\text{Dice} = \frac{2D_P}{2D_P + Y_N + Y_P} \quad (8)$$

$$\text{Jaccard} = \frac{D_P}{D_P + Y_N + Y_P} \quad (9)$$

Tüm metrik değerler 0 ile 1 arasında hesaplanırken, "4. Sonuçlar ve Tartışmalar" bölümü yüzde karşılıklarını gösterir (%0 - 100). Metrik değerleri arttıkça önerilen modelin metriğin amacı kapsamında daha iyi olduğu kararlaştırılır.

4. Sonuçlar ve Tartışmalar (Results and Discussions)

Dermoskopik görüntülerde lezyon bölütleme işlemi için önerilen modelin başarısı bu çalışmada beş değerlendirme ölçütü ile ölçülmüştür. Tablo 1, PH2 veri kümesi üzerinde modellerin eğitiminden elde edilen ortalama ölçüt değerlerini göstermektedir, bu aşamada EnecaU-Net modelinin U-Net mimarisine göre elde ettiği ölçüt sonuçları karşılaştırmalı olarak görülmektedir. 5 kat çapraz doğrulama tekniğinin uygulanması sonucu elde edilen ortalama eğitim sonuç değerleri Tablo 1'de gösterilmektedir. Tablo 2'de ise PH2 veri kümesinden analiz için ayrılan test örneklerinin ortalama test sonuçları sunulmaktadır.

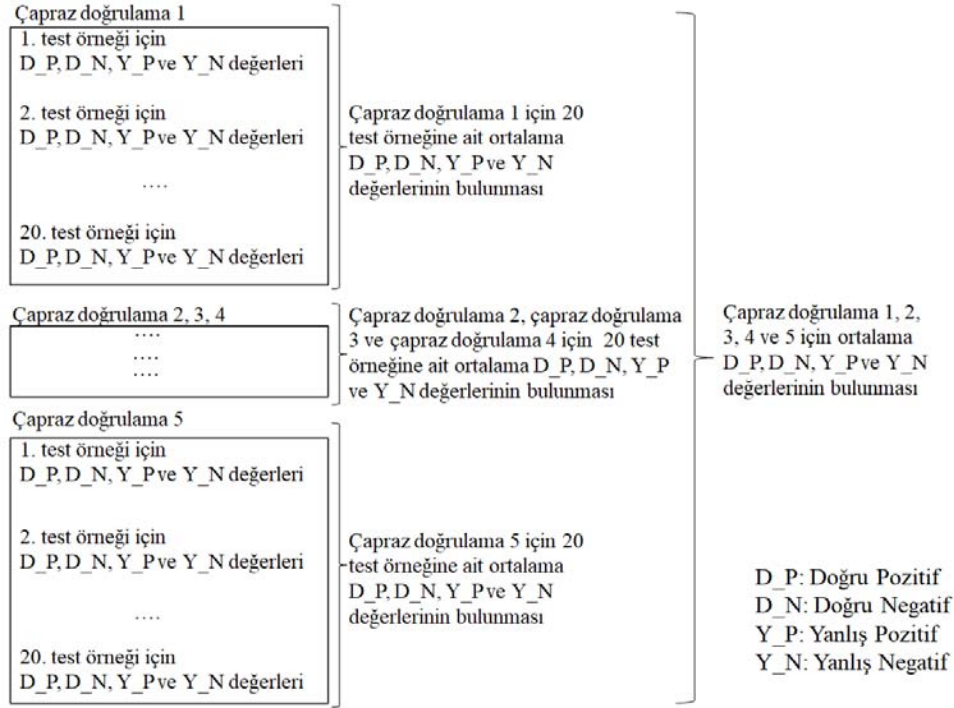
Şekil 3'te her iki model için PH2 veri kümesi test örneklerinden elde edilen bir karışıklık matrisi, D_P, D_N, Y_P ve Y_N değerlerine göre gösterilmektedir, test örnekleri için karışıklık matrisi değerlerinin elde edilmesinde "scikit-learn" kütüphanesinden faydalanılmıştır. Her çapraz doğrulama aşamasının ağırlık sonucuna göre 20 test örneğinin D_P, D_N, Y_P ve Y_N değerleri elde edilip ortalamaları alınmıştır. Devamında çapraz doğrulamanın her bir aşaması dikkate alınarak ortalama bir değer D_P, D_N, Y_P ve Y_N' in her biri için elde edilmiştir. Şekil 2'de bu işleme ait açıklayıcı bir şema sunulmaktadır. Değerlerin ortalamaları alınarak oluşturulan Şekil 3'teki karışıklık matrisinde virgül sonrası değerler yuvarlatılmıştır. Yapılan işlem sonucu D_P, D_N, Y_P ve Y_N değerleri EnecaU-Net için sırasıyla 14228, 32909, 1127, 887'dir ve U-Net için sırasıyla 13965, 27585, 6451, 1151'dir (Şekil 3). PH2 veri kümesi için örnek görüntü, gerçek referans karşılıkları ve her iki model ile elde edilen görsel bölütleme sonuçları Şekil 4'te görülmektedir. Şekil 5'teki görsel, önerilen modelin U-Net mimarisine göre daha az bir iterasyon süreci ile eğitim aşamasını gerçekleştirebileceğini gösterir. Şekil 5'teki grafikler, 50 ve 100 iterasyonun bir sonucu olarak PH2 veri kümesi üzerinde eğitilen modellerin elde ettiği doğruluk eğrilerini göstermektedir. Önerilen modelde kullanılan ek dikkat mekanizması nedeniyle önerilen modelin eğitim süresinin U-Net'e göre uzadığı her iki model için eşit iterasyon miktarı ile yapılan değerlendirmelerde gözlemlendi. Deneysel bir karşılaştırma yapabilmek amacıyla her iki model için iterasyon miktarları eşit tutulmuştur ve önerilen modelin daha düşük bir iterasyon miktarı ile de yakınsama yeteneğini sürdüreceği Şekil 5'te de görülmektedir. Daha az iterasyon miktarının da önerilen modelin eğitim süresini kısaltacağını düşünüyoruz. Bu doğrultuda en uygun iterasyon miktarı ve eğitim süresinin karşılaştırılmasına yönelik gelecekte daha detaylı bir incelemenin yapılmasında fayda görüyoruz.

Tablo 1. PH2 veri kümesi ile eğitilen modellerin elde ettiği ortalama ölçüt değerleri
(The average metric values obtained by the models trained with the PH2 dataset)

| Model | Değerlendirme Ölçütleri (%) | | | | |
|------------|-----------------------------|------------|----------|-------|---------------|
| | Doğruluk | Duyarlılık | Özgüllük | Dice | Jaccard (IoU) |
| U-Net | 87,89 | 95,23 | 83,22 | 87,16 | 78,19 |
| EnecaU-Net | 97,57 | 96,80 | 97,99 | 97,02 | 94,22 |

Tablo 2. PH2 veri kümesine göre modellerin ortalama test sonuçları
(The average test results of the models according to the PH2 dataset)

| Model | Değerlendirme Ölçütleri (%) | | | | |
|------------|-----------------------------|------------|----------|-------|---------------|
| | Doğruluk | Duyarlılık | Özgüllük | Dice | Jaccard (IoU) |
| U-Net | 84,53 | 92,39 | 81,05 | 78,61 | 64,75 |
| EnecaU-Net | 95,90 | 94,13 | 96,69 | 93,39 | 87,60 |




Şekil 2. Şekil 3'te görülen D_P, D_N, Y_P ve Y_N değerlerinin elde edilme yolu
(The way to obtain the D_P, D_N, Y_P and Y_N values seen in Figure 3)

| | | EnecaU-Net | | U-Net | |
|--------------|---|---------------|----------------|---------------|----------------|
| | | Doğru Negatif | Yanlış Pozitif | Doğru Negatif | Yanlış Pozitif |
| Gerçek sınıf | 0 | 32909 | 1127 | 27585 | 6451 |
| | 1 | 887 | 14228 | 1151 | 13965 |
| | | 0 | 1 | 0 | 1 |
| | | Tahmin sınıfı | | Tahmin sınıfı | |

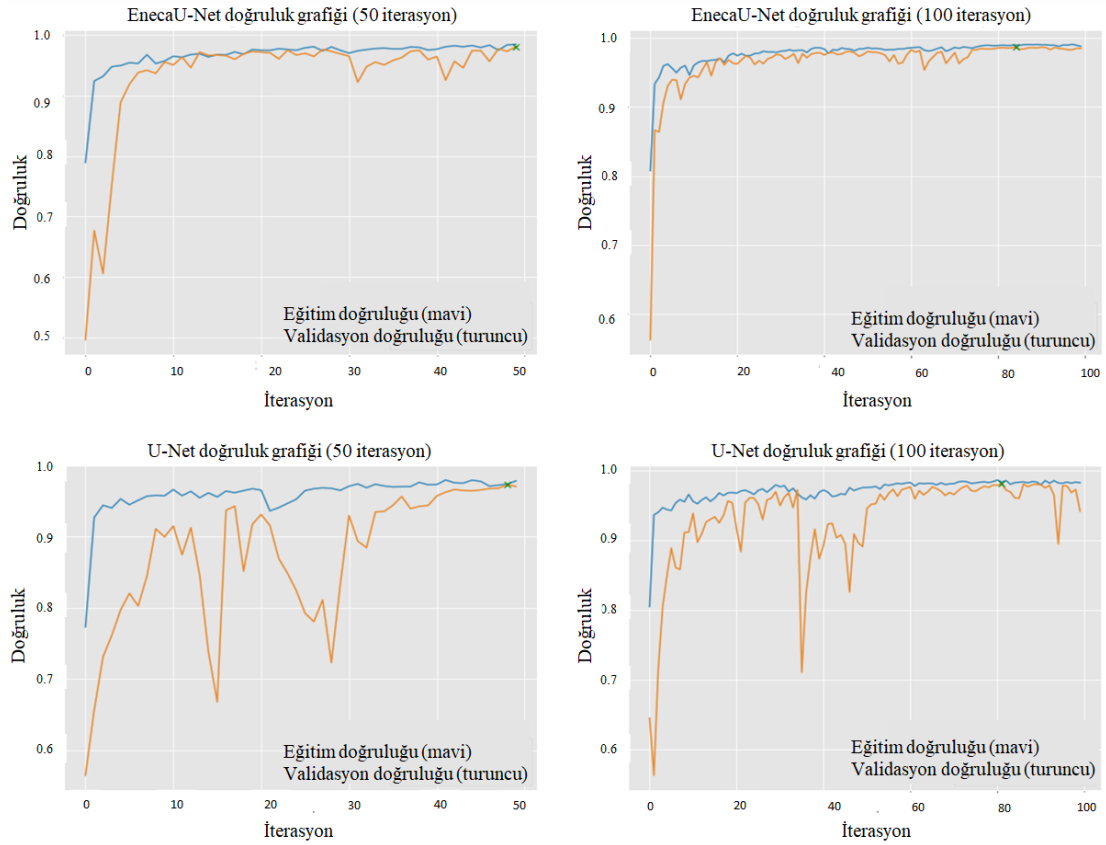
Şekil 3. PH2 veri kümeleri için modellerin karışıklık matrisleri (Confusion matrices of models for PH2 datasets)

Çalışmanın ikinci ve üçüncü aşamalarında birinci aşamaya göre daha yüksek veri miktarı ile EnecaU-Net modelinin başarısı incelenmiş ve bu aşamalarda görüntü karıştırma yöntemine dayalı uygulanan veri artırma yönteminin EnecaU-Net model başarısı üzerindeki etkisi gözlemlenmiştir. İkinci ve üçüncü aşamada ISIC-2016 ve ISIC-2017 veri kümelerinden faydalanılmıştır. Her iki veri kümesi için EnecaU-Net modelinin eğitiminden elde edilen ölçüt değerleri Tablo 3'te sunulmaktadır. ISIC-2016 ve ISIC-2017 test veri kümelerinden ayırdığımız 150'şer test görüntüsü için EnecaU-Net modelinin elde ettiği ortalama sonuçlar Tablo 4'te sunulmaktadır. Cilt kırıkları veya hava/yağ kabarcığı gibi bölütleme işlemi zorlaştıracak faktörleri görüntüden temizlemek için görüntülere eğitim ve test süreçleri öncesi herhangi bir ön işleme tekniği uygulanmamıştır. ISIC-2016 ve ISIC-2017 veri kümeleri için örnek görüntü (1. sütun), gerçek referans karşılıkları (2. sütun) ve EnecaU-Net modeli ile elde edilen görsel bölütleme sonuçları (3. sütun) Şekil 6'da görülmektedir. Bir bölütleme modelinin performansını belirlemek için en sık kullanılan parametrelerden biri doğruluktur. Duyarlılık, modelin gerçekte ilgilenilen bölgeye karşılık gelen alanları ne kadar iyi

tanımlayabildiğini ölçer. Özgüllük, modelin gerçekte arka plan alanına karşılık gelen alanları ne kadar iyi tanımlayabildiğini ölçer. Dice ve Jaccard katsayıları, tahmin edilen bölütleme sonucu ve gerçek referans arasındaki örtüşme oranını belirlemek için kullanılır. Çalışmanın birinci aşamasında yürütülen işlemler kapsamında, EnecaU-Net'in tüm değerlendirme kriterlerinde U-Net'i geride bıraktığı Tablo 1 ve Tablo 2 içerisinde görülmektedir. Birinci aşamada kullanılan eğitim veri miktarına göre çalışmanın ikinci ve üçüncü aşamalarında kullanılan eğitim veri miktarının artması ile birlikte modelden elde edilen sonuçlar Tablo 3 ve 4'te görülmektedir. Bu çalışmada uyguladığımız karıştırma yöntemine dayalı veri artırma yönteminin hem modelin görüntülerde tanımlayabildiği piksel miktarı açısından hem de modelin bölütleme başarısı açısından olumlu sonuçlar vermesine neden olduğu Tablo 3 ve Tablo 4'de görülmektedir. Her iki tabloda da doğruluk, duyarlılık, özgüllük, Dice ve Jaccard katsayı değerleri, aynı miktardaki hiç veri artırma yöntemi uygulanmayan veri grubuna (ISIC-2017) göre veri artırma yöntemi (karıştırma, ekleme) uygulanan veri grubu (ISIC-2016) için yükselmiştir.



Şekil 4. Her iki modelle elde edilen PH2 veri kümesi test görüntülerinin örnek görsel sonuçları ve gerçek referans eşdeğerleri (The sample visual results of the PH2 dataset test images obtained with both models, and their ground truth equivalents)




Şekil 5. PH2 veri kümesi ile eğitilen modellerin elde ettiği doğruluk grafikleri (The accuracy graphs obtained by the models trained with the PH2 dataset)

Tablo 3. EnecaU-Net modelinin ISIC (2016 ve 2017) veri kümeleri ile eğitiminden elde edilen ölçüt değerleri
(The metric values obtained from the training of the EnecaU-Net model with the ISIC (2016 and 2017) datasets)

| Veri Kümesi | Model | Değerlendirme Ölçütleri (%) | | | | |
|-------------|------------|-----------------------------|------------|----------|-------|---------------|
| | | Doğruluk | Duyarlılık | Özgüllük | Dice | Jaccard (IoU) |
| ISIC-2016 | EnecaU-Net | 97,36 | 94,64 | 98,16 | 94,11 | 88,89 |
| ISIC-2017 | EnecaU-Net | 95,95 | 87,23 | 97,99 | 89,00 | 80,30 |

Tablo 4. EnecaU-Net modelinin ISIC-2016 ve ISIC-2017 veri kümelerine göre test sonuçları
(The test results of the EnecaU-Net model according to the ISIC-2016 and ISIC-2017 datasets)

| Veri Kümesi | Model | Değerlendirme Ölçütleri (%) | | | | |
|-------------|------------|-----------------------------|------------|----------|-------|---------------|
| | | Doğruluk | Duyarlılık | Özgüllük | Dice | Jaccard (IoU) |
| ISIC-2016 | EnecaU-Net | 94,19 | 90,73 | 94,78 | 88,05 | 80,30 |
| ISIC-2017 | EnecaU-Net | 93,85 | 83,37 | 98,52 | 83,09 | 74,54 |

**Şekil 6.** ISIC (2016 ve 2017) veri kümeleri için EnecaU-Net modeli ile elde edilen örnek görsel sonuçlar (üçüncü sütun) ve gerçek referans eşdeğerleri (ikinci sütun) (The sample visual results (third column) obtained with the EnecaU-Net model for the ISIC (2016 and 2017) datasets and their ground truth equivalents (second column))

Bu araştırma makalesi farklı dermoskopik veri kümeleri için EnecaU-Net modeli ile yapılan lezyon bölütleme işlemini ve uygulanan veri artırma yöntemlerine göre değerlendirmeyi ilk olarak bu çalışmayla sunmaktadır. Önerilen model, çoklu kodlayıcı yol ve dikkat mekanizmaları gibi temel yapıtaşlarını kullanımı açısından bazı araştırmalar ile ortak özelliğe sahiptir. Bununla birlikte literatürdeki bilgilerimiz dahilinde, EnecaU-Net modeli ile yeni bir mimari tasarım önerisi sunulmaktadır. Önerilen model tek görüntü kaynağını çoklu kodlayıcı yollar vasıtasıyla aynı anda işler. Çoklu giriş veya çoklu kodlayıcı yolu kullanan ağ örneklerine literatürde de rastlanmaktadır [15, 49, 50, 51]. Dermoskopik görüntülerde lezyon bölütleme işlemi için çoklu kodlayıcı yolunu U-Net temelinde uygulayan [15] yazarları, RGB ve LAB renk uzaylarından elde ettikleri yeşil ve L kanal görüntülerinin, oluşturdukları modelin (EncU-Net) kodlayıcı yollarında aynı anda ayrı ayrı işlenmesini sağlamıştır. Modelin kodlayıcı yollarında belirli evrişim, aktivasyon fonksiyonu (ReLU), yığın normalizasyon, aşağı örneklem (maxpooling) uygulamaları ile süreç yürütülmüştür. Birinci kodlayıcı bölümünün tüm seviyelerinden oluşan özellik haritaları, ikinci kodlayıcı bölümün karşılık gelen seviyelerindeki özellik haritaları ile birleştirilmiştir. Daha sonra

yapılan benzer bir çalışmada [52] ise çoklu kodlayıcı yollara sahip modifiye U-Net modelleri ile dermoskopik görüntüler farklı renk uzaylarına göre değerlendirilmiş ve lezyon bölütlemesi yapılmıştır. Önerilen DICU-Net modelinde [52] iki kodlayıcı yol arası bağlantı her seviyede elde edilen maksimum havuzlama sonuç çıktılarının eklenmesine dayanmaktadır. Ayrıca bir dikkat ağı ile de model güçlendirilmiştir. Dikkat modülü kullanan çoklu kodlayıcı yola sahip diğer bir U-Net varyantı [50] ise histolojik görüntülerdeki çekirdek bölütlemesi için kullanılmıştır. Bu çalışma [50] modelinde her seviye kodlayıcı blokları ayrı olarak dikkat modülüne bağlanmıştır. EnecaU-Net modelinde kodlayıcı bölümlerin her seviyesindeki ilgili blok sonuçlarının "concatenate" işlemine alınması ile kodlayıcı yollar birleştirilir. Elde edilen çıktı her seviyede dikkat mekanizmasına beslenir. Araştırmamız, kullandığımız ECA dikkat modülü ile belirtilen çalışmalara göre bir fark oluştursa da, genel olarak diğer çalışmalara göre farkını yukarı örnekleme işleminin kodlayıcı bölümdeki kullanım biçimiyle gösterir. Bu kullanım biçimi sayesinde W-Net modeli gibi çoklu ve sıralı varyant U-Net modellerinde bulunan kod çözücü bölümün miktarının azaltılması sağlanır. Yukarı örnekleme işlemini U-Net modelinin kodlayıcı bölümünde

kullanılmasına dair daha önce [16] makalesinde yapılan öneriden farklı olarak bu çalışmada daha etkin bir kullanım yolu sunulmaktadır. W-Net vb. modellerdeki kod çözücü bölüm miktarını azaltmanın yanı sıra önerilen modelin kodlayıcı bölümünde yukarı örnekleme işleminin kullanılmasındaki diğer fayda ise ilgi alanına ait daha belirgin bir bilginin çıkarılmasıdır.

PH2 veri kümesini kullanan son zamanda yapılmış bazı araştırmaların bulguları, Tablo 5'te bu araştırmanın sonuçlarıyla karşılaştırılmıştır. Aynı şekilde ISIC-2016 ve ISIC-2017 veri kümeleri ile yapılan araştırmaların sonuçlarının karşılaştırılması da sırasıyla Tablo 6 ve Tablo 7'de sunulmaktadır. Tablo 5, 6 ve 7'de EnecaU-Net modelinin eğitimi sonucu elde edilen değerler karşılaştırılır. PH2 veri kümesi ile elde edilen değerlerin yüksekliği veri kümesi miktarı veya cilt kılları, hava/yağ kabarcıkları gibi lezyon bölütlenmesini engelleyen faktörleri içermeyen görüntülerin oluşturduğu veri kümesi ile ilişkilendirilebilir. Daha fazla miktarda örnek içeren ve lezyon bölütlenmesini engelleyen faktörler için bu çalışmada görüntülere herhangi bir ön işlem uygulanmamasına rağmen önerilen modelin ISIC-2016 ve ISIC-2017 veri kümeleri için verdiği sonuçlar aynı veri kümeleri üzerinde son zamanda yapılan diğer çalışmalara yakındır. Bu çalışmada uygulanan, görüntülerin karıştırma yöntemiyle yeniden oluşturulmasına dayalı veri artırma yönteminin model başarısı üzerine etkisi ise Tablo 3, 4 ve 6'da görülmektedir. Bu sonuçlar doğrultusunda EnecaU-Net modelinin dermoskopik görüntülerde lezyon bölütleme başarısını uygulanan karıştırma veri artırma yöntemi artırmıştır.

4.1. Gelecek Çalışmalar (Future Studies)

Yüksek miktarda veri, sistem için yük oluşturur. Oliveira vd. [61] de U-Net ile retina damar bölütlemesi yaparken sonuca ulaştıran en etkin ve yeterli görüntü miktarını belirlemeyi amaçlamıştır. Bu çalışmada kullanılan ISIC-2016 ve ISIC-2017 veri kümeleri uluslararası önde gelen klinik merkezlerdeki çeşitli cihazlardan alınan yüzlerce görüntünün klinik olarak ilgili temsili bir örneğini içerir. Bu nedenle

de dermoskopik görüntülerde lezyon bölütlemesi için genel hastalık olasılıklarına projeksiyon tutmaktadır. Elde ettiğimiz sonuçlar doğrultusunda çalışılan veri miktarı dermoskopik görüntülerde lezyon bölütleme amacı için yeterli olmakla birlikte gelecekte daha yüksek miktarda görüntüler ile de EnecaU-Net modeli incelenebilir.

Dermoskopik görüntülerde bölütleme sınırlarının oluşturulmasını zorlaştıran lezyon ve çevresi arasındaki düşük kontrast, cilt kılları, hava/yağ kabarcığı vb. birçok istenmeyen faktör uzmanlar arası uyuşma derecesini de orta seviyede tutar [62]. Tüm denetimli makine öğrenimi modellerinin eğitimi uzmanlar tarafından elde edilmiş bu gerçek referans verilere bağlı olduğu için Ribeiro vd.[62]'e göre dermoskopik görüntü bölütlemesinde lezyon kenarı ince detaylarının işleme alınmasına gerek yoktur. Bu doğrultuda önerdiğimiz modelin ince kenar ayrıntılarını detaylandıramamış olması bu tür dermoskopik görüntülerin bölütlenmesi için belki yeterli olabilir fakat ince kenar detayı gerektiren diğer tıbbi görevler için bir kısıt teşkil eder. Bu nedenle ileri çalışmalarda daha ayrıntılı sınır bilgisini yakalayan bölütleme araştırmalarına modelin ihtiyacı vardır.

Görüntü kalitesini ve modelin vereceği performans cevabını değiştirebilme riski nedeniyle görüntüye uygulanan ön işlem, modeller açısından olumlu yönde veya olumsuz yönde bir etki yaratır. Bu etkiyi gözlemek genişletilmiş ek çalışmalara ihtiyaç gösterir. Cilt kılları gibi dermoskopik görüntülerde lezyon bölütleme işlemini zorlaştıran faktörlerin kullandığımız görüntülerde ön işlem ile temizlenmesi yapılmamıştır. Cilt kılları, yağ kabarcığı vb. faktörlerin veya görüntülerin bölütlenmesi için belki yeterli olabilir fakat model performansını iyileştirici yönde olumlu etki sağlayan ön işlem uygulamaları ile önerilen modelin değerlendirilmesi ileri çalışmalar için düşünülebilir.

Veri artırma yöntemleri, bölütlemenin başarısını etkileyen diğer bir faktördür. U-Net modelinde de [1] sınırlı miktarda veriden daha iyi yararlanmak için veri artırma yöntemi kullanılır. Yapay sinir ağı

Tablo 5. Bu araştırma ile aynı PH2 veri kümesini kullanan bazı yeni yayınların bulguları
(The findings of some recent publications that used the same PH2 dataset as this research)

| Araştırma | Değerlendirme Ölçütleri (%) | | | | |
|----------------------------|-----------------------------|------------|----------|-------|---------------|
| | Doğruluk | Duyarlılık | Özgüllük | Dice | Jaccard (IoU) |
| Ramadan ve Aly (2022) [52] | 93,23 | 93,47 | 93,12 | 89,90 | 81,65 |
| Zhao vd. (2022) [53] | - | - | - | - | 80,14 |
| Anand vd. (2022) [54] | 97,70 | - | - | - | 97,60 |
| Zhang vd. (2022) [55] | 96,10 | - | - | 94,35 | 89,82 |
| Song vd. (2022) [56] | 95,93 | 97,17 | 94,30 | 92,62 | 85,76 |
| Araujo vd. (2022) [57] | 96,30 | 90,50 | 98,20 | 92,30 | 85,80 |
| Gu vd. (2022) [58] | 97,09 | 97,44 | 96,14 | 94,86 | 90,52 |
| Aghdam vd. (2022) [59] | 96,85 | 94,39 | 95,76 | 95,04 | - |
| Hafhouf vd. (2022) [60] | 93,77 | 97,01 | 92,72 | 90,52 | 83,33 |
| Bu çalışma | 97,57 | 96,80 | 97,99 | 97,02 | 94,22 |

Tablo 6. Bu araştırma ile aynı ISIC-2016 veri kümesini kullanan bazı yeni yayınların bulguları
(The findings of some recent publications that used the same ISIC-2016 dataset as this research)

| Araştırma | Değerlendirme Ölçütleri (%) | | | | |
|----------------------------|-----------------------------|------------|----------|-------|---------------|
| | Doğruluk | Duyarlılık | Özgüllük | Dice | Jaccard (IoU) |
| Song vd. (2022) [56] | 96,56 | 93,39 | 96,86 | 92,89 | 86,54 |
| Gu vd. (2022) [58] | 96,48 | 94,53 | 96,18 | 92,84 | 87,40 |
| Sun vd. (2022) [30] | 95,10 | 94,30 | - | 92,30 | - |
| Hafhouf vd. (2022) [60] | 96,21 | 93,11 | 96,76 | 92,33 | 86,39 |
| Kaur ve Ranade (2023) [20] | 95,35 | 92,92 | 96,23 | 90,75 | 84,27 |
| Yu vd. (2023) [31] | 95,90 | 91,80 | 94,30 | 91,90 | 85,50 |
| Fan vd. (2023) [32] | 97,40 | 93,33 | - | - | 87,41 |
| Yang vd. (2023) [35] | 97,38 | - | - | 93,03 | 87,45 |
| Bu çalışma | 97,36 | 94,64 | 98,16 | 94,11 | 88,89 |

Tablo 7. Bu araştırma ile aynı ISIC-2017 veri kümesini kullanan bazı yeni yayınların bulguları
(The findings of some recent publications that used the same ISIC-2017 dataset as this research)

| Araştırma | Değerlendirme Ölçütleri (%) | | | | |
|----------------------------|-----------------------------|--------------|--------------|--------------|---------------|
| | Doğruluk | Duyarlılık | Özgüllük | Dice | Jaccard (IoU) |
| Ramadan ve Aly (2022) [52] | 92,49 | 85,38 | 94,79 | 84,77 | 73,56 |
| Zhao vd. (2022) [53] | - | - | - | - | 88,36 |
| Zhang ve Wang (2022) [55] | 95,1 | - | - | 87,80 | 78,9 |
| Song vd. (2022) [56] | 94,29 | 88,13 | 96,59 | 86,55 | 78,63 |
| Gu vd. (2022) [58] | 94,50 | 88,04 | 96,59 | 87,92 | 80,53 |
| Aghdam vd. (2022) [59] | 96,56 | 92,46 | 97,94 | 92,40 | - |
| Sun vd. (2022) [30] | 94,70 | 85,70 | - | 85,70 | - |
| Hafhouf vd. (2022) [60] | 93,75 | 87,45 | 96,21 | 86,01 | 77,89 |
| Zou ve Wu (2023) [19] | - | - | - | 88,47 | 79,33 |
| Kaur ve Ranade (2023) [20] | 91,63 | 88,16 | 95,84 | 80,54 | 72,91 |
| Yu vd. (2023) [31] | 93,70 | 84,20 | 96,80 | 85,50 | 77,10 |
| Yang vd. (2023) [35] | 96,61 | - | - | 91,48 | 85,36 |
| Bu çalışma | 95,95 | 87,23 | 97,99 | 89,00 | 80,30 |

modellerinin eğitim veri kümesi dışındaki örneklerle iyi bir şekilde genellenmesi için görüntülere rastgele yansıtma, kırpmaya, öteleme, döndürme ve deformasyon gibi geleneksel veri artırma teknikleri uygulanır [1, 14, 20, 65]. Bu çalışmada da, PH2 veri kümesi için çoğu çalışmada temel uygulama alanı bulunmuş geleneksel veri artırma yaklaşımları kullanılmıştır. Geleneksel veri artırma yöntemlerini, eğitim için seçilen PH2 örneklerine uyguladığımız bir görüntü grubunun incelenmesinin yanı sıra rastgele görüntü seçimi ile görüntülerin karıştırılma işlemine tabi tutulması temelinde ISIC-2016 veri kümesi ile oluşturduğumuz ikinci bir ayrı görüntü grubu çalışmamızda incelenmiştir. Karıştırma yöntemi görüntülerde yumuşak geçiş alanlarının oluşmasına neden olur. Bu tür geçiş alanlarının varlığı modelin bölütleme yeteneği üzerinde olumlu veya olumsuz yönde etki oluşturabilmektedir. Farklı veri kümelerinde görüntü karıştırmaya dayalı veri artırma yöntemini uygulayan çalışmalarda da [66-69] bölütleme yapan modelin başarısında farklı sonuçlara ulaşılmıştır. Yaptığımız çalışma kapsamında elde ettiğimiz bulgular neticesinde, görüntü karıştırma yoluyla yapılan veri artırma yönteminin modelin dermoskopik görüntülerde lezyon bölütleme görevini iyileştirdiği gözlenmiştir. Gelecekteki çalışmalarda klasik bilgisayarlı görü tabanlı veri artırma uygulamaları veya daha yeni uygulama alanları bulan derin öğrenme tabanlı veri artırma yöntemleri de EnecaU-Net modeli üzerinde değerlendirilebilir.

Bu çalışmada özellikle dermoskopik görüntülerde lezyon bölütleme işlemine odaklanılmış olunmasına rağmen önerilen EnecaU-Net modeli ile fetal kafatası [70], beyin tümör bölütlemesi [71], metal çatlaklarının belirlenmesi [72], omur bölütlemesi [73] vb. diğer farklı bölütleme görevleri de değerlendirilebilir. Ayrıca bu vb. farklı görevler için EnecaU-Net bölütleme modeli, uyguladığımız karıştırma veri artırma yöntemi ile birlikte incelenebilir.

5. Sonuçlar (Conclusions)

Bu çalışmanın amacı dermoskopik görüntülerde lezyon bölütleme görevini iyileştirmek için yeni öneriler sunmaktır. Bu öneriler bölütleme işlemi yapan model ve bölütleme süreci içerisindeki veri artırma yöntemi kapsamındadır. U-Net temelinde geliştirilen bölütleme mimarisinde iki kodlayıcı yolu ve bir kod çözücü bölüm bulunur. Önerdiğimiz model, iki kodlayıcı yolu aracılığıyla aynı girdi örneklerini aynı anda alır, modelin birinci kodlayıcı bölümünde yukarı örnekleme işlemi kullanılır, ayrıca görüntüdeki yoğun bilgilerin rafine edilmesi ve faydalı bilgilerin işlenmesi için "Verimli Kanal Dikkat" (ECA) modülü ikinci kodlayıcı bölümüne eklenmiştir. Önerilen modeli değerlendirmek için deneyler PH2 ve "Uluslararası Cilt Görüntüleme İşbirliği" (ISIC-2016 ve ISIC-2017) veri kümeleri ile yapılmıştır. Üç aşamada yapılan değerlendirmenin ilk aşamasında

EnecaU-Net modeli U-Net modeli ile karşılaştırılmıştır, bu aşamada her iki model geleneksel veri artırma yöntemi uygulanmış PH2 veri kümesi görüntüleri ile eğitilmiştir, eğitim ve test sonuçları elde edilmiştir. Çalışmanın ikinci aşamasında, dermoskopik görüntülerde lezyon bölütleme işlemi için modelin bölütleme başarısı üzerinde etki gösteren görüntü karıştırma (birleştirme, ekleme) veri artırma yöntemi incelenmiştir. İnceleme ISIC-2016 veri kümesi ile yapılmıştır. Çalışmanın üçüncü aşamasında veri artırma yöntemi uygulanmasına ihtiyaç göstermeyen ISIC-2017 veri kümesi ile EnecaU-Net mimarisini değerlendirilmiştir. Çalışmanın ikinci ve üçüncü aşama sonuçları karşılaştırılmıştır. Doğruluk, duyarlılık, özgüllük, Dice, Jaccard (IoU) ölçüt değerlerine göre çalışmadaki tüm değerlendirmeler yapılmıştır. Elde ettiğimiz sonuçlara göre, dermoskopik görüntülerde lezyon bölütleme işlemi için uygulanan EnecaU-Net modelinin bölütleme başarısı yüksektir ve uygulanan karıştırma veri artırma yöntemi, EnecaU-Net modelinin bölütleme başarısını iyileştirmektedir. Gelecekte dermoskopik görüntü lezyon bölütleme işlemi için bu çalışmada kullanılan veri artırma yöntemleri haricindeki veri artırma metodları ile de önerilen modelin değerlendirme ve incelemesi yapılabilir. EnecaU-Net modeli gelecekte farklı veri kümeleri üzerinde de değerlendirilebilir.

Teşekkür (Acknowledgement)

Yazarlar, PH2 ve uluslararası cilt görüntüleme işbirliği veri kümelerinin sağlayıcılarına teşekkür eder.

Kaynaklar (References)

- Ronneberger O., Fischer P., Brox T., U-Net: Convolutional networks for biomedical image segmentation, Medical Image Computing and Computer-Assisted Intervention, Munich-Germany, 234-241, 2015.
- Wang Q., Wu B., Zhu P., Li P., Zuo W., Hu Q., ECA-Net: Efficient channel attention for deep convolutional neural networks, IEEE/CVF 2020 Conference on Computer Vision and Pattern Recognition (CVPR), Seattle- WA-USA, 11531-11539, 2020.
- Yu J., Yang D., Zhao H., FFANet: Feature fusion attention network to medical image segmentation, Biomedical Signal Processing and Control, 69, 102912, 2021.
- Zhang Z., Jiang Y., Qiao H., Wang M., Yan W., Chen J., SIL-Net: A Semi-Isotropic L-shaped network for dermoscopic image segmentation, Computers in Biology and Medicine, 150, 106146, 2022.
- Zhang J., Pan W., Wang B., Chen Q., Cheng Y., Multi-scale aggregation networks with flexible receptive fields for melanoma segmentation, Biomedical Signal Processing and Control, 78, 103950, 2022.
- Guo Z., Zhao L., Yuan J., Yu H., MSANet: Multiscale aggregation network integrating spatial and channel information for lung nodule detection, IEEE Journal of Biomedical and Health Informatics, 26 (6), 2547-2558, 2022.

7. Shu X., Gu Y., Zhang X., Hu C., Cheng K., FCRB U-Net: A novel fully connected residual block U-Net for fetal cerebellum ultrasound image segmentation, *Computers in Biology and Medicine*, 148,105693, 2022.
8. Li L., Verma M., Nakashima Y., Nagahara H., Kawasaki R., IterNet: Retinal image segmentation utilizing structural redundancy in vessel networks, In: 2020 IEEE Winter Conference on Applications of Computer Vision (WACV), Snowmass- CO- USA, 3645-3654, 2020.
9. Xu L., Tetteh G., Mustafa M., Lipkova J., Zhao Y., Bieth M., Christ P., Piraud M., Menze B., Shi K., W-Net for whole-body bone lesion detection on 68Ga-Pentixafor PET/CT imaging of multiple myeloma patients, 5th International Workshop on Computational Methods for Molecular Imaging (CMMI), Québec-Canada, 23-30, 2017.
10. Chen W., Zhang Y., He J., Qiao Y., Chen Y., Shi H., Wu E.X., Tang X., Prostate segmentation using 2D bridged U-net, 2019 International Joint Conference on Neural Networks (IJCNN), Budapest- Hungary, 1-7, 2019.
11. Das S., Deka A., Iwahori Y., Bhuyan M.K., Iwamoto T., Ueda J., Contour-aware residual W-Net for nuclei segmentation, 23rd International Conference on Knowledge-Based and Intelligent Information & Engineering Systems, Budapest-Hungary, 1479–1488, 2019.
12. Singh K.R., Sharma A., Singh G.K., W-Net: Novel deep supervision for deep learning-based cardiac magnetic resonance imaging segmentation, *IETE Journal of Research*, 1-18, 2022.
13. Mohan S., Bhattacharya S., Ghosh S., Attention W-Net: Improved skip connections for better representations, 26th International Conference on Pattern Recognition (ICPR), Montréal Québec- Canada, 1-6, 2022.
14. Khanna A., Londhe N.D., Gupta S., Semwal A., A deep residual U-Net convolutional neural network for automated lung segmentation in computed tomography images, *Biocybernetics and Biomedical Engineering*, 40 (3), 1314-1327, 2020.
15. Arpacı S.A., Varlı S., EncU-Net: A modified U-Net for dermoscopic image segmentation, 29th Signal Processing and Communications Applications Conference (SIU), Istanbul-Turkey, 1-4, 2021.
16. Arpacı S.A., Varlı S., LUPU-Net: A new improvement proposal for encoder-decoder architecture, *International Advanced Researches and Engineering Journal*, 5 (3), 352-361, 2021.
17. Ünlü E.I., Çınar A., Segmentation of benign and malign lesions on skin images using U-Net, 2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT), Zallaq-Bahrain, 165-169, 2021.
18. Khoulood S., Ahlem M., Fadel T., Amel S., W-net and inception residual network for skin lesion segmentation and classification, *Applied Intelligence*, 52, 3976–3994, 2022.
19. Zou P., Wu J.S., SwinE-UNet3+: swin transformer encoder network for medical image segmentation, *Progress in Artificial Intelligence*, 12, 99–105, 2023.
20. Kaur R., Ranade S.K., Improving accuracy of convolutional neural network-based skin lesion segmentation using group normalization and combined loss function, *International Journal of Information Technology*, 15, 2827–2835, 2023.
21. He K., Zhang X., Ren S., Sun J., Deep residual learning for image recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas- USA, 770-778, 2016.
22. Zafar K., Gilani S.O., Waris A., Ahmed A., Jamil M., Khan M.N., Sohail Kashif A., Skin lesion segmentation from dermoscopic images using convolutional neural network, *Sensors*, 20 (6),1601, 2020.
23. Iranpoor R., Mahboob A.S., Shahbandegan S., Baniasadi N., Skin lesion segmentation using convolutional neural networks with improved U-Net architecture, 2020 6th Iranian Conference on Signal Processing and Intelligent Systems (ICSPIS), Mashhad-Iran, 1-5, 2020.
24. Badshah N., Ahmad A., ResBCU-Net: Deep learning approach for segmentation of skin images, *Biomedical Signal Processing and Control*, 71, 103137, 2022.
25. Kumar A., Hamarneh G., Drew M.S., Illumination-based transformations improve skin lesion segmentation in dermoscopic images, 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Seattle- WA-USA, 3132-3141, 2020.
26. Adegun A.A., Viriri S., Ogundokun R.O., Deep learning approach for medical image analysis, *Computational Intelligence and Neuroscience*, 2021, 1-9, 2021.
27. Alhudaif A., Ocal H., Barisci N., Atacak İ., Nour M., Polat K., A novel approach to skin lesion segmentation: Multipath fusion model with fusion loss, *Computational and Mathematical Methods in Medicine*, 2022, 1-12, 2022.
28. Beeche C., Singh J.P., Leader J.K., Gezer N.S., Oruwari A.P., Dansingani K.K., Chhablani J., Pu J., Super U-Net: A modularized generalizable architecture, *Pattern Recognition*, 128, 1-12, 2022.
29. Rehman A., Butt M.A., Zaman M., Attention Res-UNet: Attention residual UNet with focal tversky loss for skin lesion segmentation, *International Journal of Decision Support System Technology (IJDSST)*, 15 (1), 1-17, 2023.
30. Sun J., Xi W., Bai G., Liu X., Yu F., Zhang C., ACFNet: An adaptive context fusion network for skin lesion segmentation, *International Joint Conference on Neural Networks (IJCNN)*, Padua-Italy, 1-8, 2022.
31. Yu Z., Yu L., Zheng W., Wang S., EIU-Net: Enhanced feature extraction and improved skip connections in U-Net for skin lesion segmentation, *Computers in Biology and Medicine*, 162, 1-10, 2023.
32. Fan C., Yang L., Lin H., Qiu Y., DFE-Net: Dual-branch feature extraction network for Enhanced segmentation in skin lesion, *Biomedical Signal Processing and Control*, 81, 1-12, 2023.
33. Liu L., Wang G., Wu Y., Wang H., Li Y., PCCA-Model: an attention module for medical image segmentation, *Biomedical Optics Express*, 14 (4), 1428-1444, 2023.
34. Hu J., Shen L., Sun G., Squeeze-and-excitation networks, *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City-UT-USA, 7132-7141, 2018.
35. Yang L., Fan C., Lin H., Qiu Y., Rema-Net: An efficient multi-attention convolutional neural network for rapid skin lesion segmentation, *Computers in Biology and Medicine*, 159, 1-13, 2023.
36. Le P.T., Pham B., Chang C., Hsu Y. Tai T., Li Y., Wang J., Anti-aliasing attention U-net model for skin lesion segmentation, *Diagnostics*, 13 (8),1460, 2023.
37. Kingma D.P., Ba J.L., ADAM: A method for stochastic optimization. <https://arxiv.org/pdf/1412.6980.pdf>. Güncelleme tarihi Ocak 30, 2017. Erişim tarihi Haziran 6, 2023.
38. Tensorflow platform. <https://www.tensorflow.org>. Erişim tarihi Haziran 6, 2023.
39. Keras platform. <https://keras.io>. Erişim tarihi Haziran 6, 2023.
40. Mendonça T., Ferreira P.M., Marques J.S., Marcal A.R.S., Rozeira J., PH2 - a dermoscopic image database for research and benchmarking, In: 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Osaka- Japan, 5437-5440, 2013.
41. PH2 veri kümesi. <https://www.fc.up.pt/addi/ph2%20database.html>. Erişim tarihi Haziran 6, 2023.
42. Bloice M.D., Stocker C., Holzinger A., Augmentor: An image augmentation library for machine learning. <https://arxiv.org/abs/1708.04680>. Erişim tarihi Haziran 6, 2023.
43. Gutman D., Codella N.C. F., Celebi E., Helba B., Marchetti M., Mishra N., Halpern A., Skin lesion analysis toward melanoma detection: A challenge at the International Symposium on Biomedical Imaging (ISBI) 2016, hosted by the International Skin Imaging Collaboration (ISIC). <https://arxiv.org/abs/1605.01397>. Erişim tarihi Haziran 6, 2023.
44. ISIC-2016 veri kümesi. <https://challenge.isic-archive.com/data/#2016>. Erişim tarihi Haziran 6, 2023.
45. Zhang H., Cissé M., Dauphin Y., Lopez-Paz D., mixup: Beyond empirical risk minimization, 6th International Conference on Learning Representations (ICLR), Vancouver- BC-Canada, 1-13, 2018.
46. Codella N., Gutman D., Celebi M.E., Helba B., Marchetti M.A., Dusza S., Kallou A., Liopyris K., Mishra N., Kittler H., Halpern A., Skin lesion analysis toward melanoma detection: A challenge at the 2017 International Symposium on Biomedical Imaging (ISBI), Hosted by the International Skin Imaging Collaboration (ISIC). <https://arxiv.org/pdf/1710.05006.pdf>. Erişim tarihi Haziran 6, 2023.
47. ISIC-2017 veri kümesi. <https://challenge.isic-archive.com/data/#2017>. Erişim tarihi Haziran 6, 2023.
48. Divyarth L.G., Ahmad A., Saraswat D., A two-stage deep-learning based segmentation model for crop disease quantification based on corn field imagery, *Smart Agricultural Technology*, 3, 1-12, 2023.
49. Zhou T., Canu S., Vera P., Ruan S., A dual supervision guided attentional network for multimodal MR brain tumor segmentation, *Proceedings of 2021 International Conference on Medical Imaging and Computer-Aided Diagnosis (MICAD)*, Birmingham-United Kingdom, 1-9, 2021.
50. Vahadane A., B A., Majumdar S., Dual encoder attention U-net for nuclei segmentation, 43rd Annual International Conference of the IEEE

- Engineering in Medicine & Biology Society (EMBC), Mexico, 3205-3208, 2021.
51. Zhao B., Chen X., Li Z., Yu Z., Yao S., Yan L., Wang Y., Liu Z., Liang C., Han C., Triple U-net: Hematoxylin-aware nuclei segmentation with progressive dense feature aggregation, *Medical Image Analysis*, 65, 1-11, 2020.
 52. Ramadan R., Aly S., CU-Net: A new improved multi-input color U-Net model for skin lesion semantic segmentation, *IEEE Access*, 10, 15539-15564, 2022.
 53. Zhao C., Shuai R., Ma L., Liu W., Wu M., Segmentation of skin lesions image based on U-Net++. *Multimedia Tools and Applications*, 81, 8691–8717, 2022.
 54. Anand V., Gupta S., Koundal D., Nayak S.R., Barsocchi P., Bhoi A.K., Modified U-Net architecture for segmentation of skin lesion, *Sensors*, 22 (3), 867, 2022.
 55. Zhang G., Wang S., Dense and shuffle attention U-Net for automatic skin lesion segmentation, *Int J Imaging Syst Technol*, 32 (6), 2066-2079, 2022.
 56. Song Z., Luo W., Shi Q., Res-CDD-Net: A network with multi-scale attention and optimized decoding path for skin lesion segmentation, *Electronics*, 11 (17), 2672, 2022.
 57. Araújo R.L., Araújo F.H.D., Silva R.R.V., Automatic segmentation of melanoma skin cancer using transfer learning and fine-tuning, *Multimedia Systems*, 28, 1239–1250, 2022.
 58. Gu R., Wang L., Zhang L., DE-Net: A deep edge network with boundary information for automatic skin lesion segmentation, *Neurocomputing*, 468, 71-84, 2022.
 59. Aghdam E.K., Azad R., Zarvani M., Merhof D., Attention swin U-Net: Cross-contextual attention mechanism for skin lesion segmentation. <https://arxiv.org/abs/2210.16898>. Yayın tarihi Ekim 30, 2022. Erişim tarihi Haziran 6, 2023.
 60. Hafhouf B., Zitouni A., Megherbi A.C., Sbaa S., An Improved and Robust Encoder–Decoder for Skin Lesion Segmentation, *Arabian Journal for Science and Engineering*, 47, 9861–9875, 2022.
 61. Oliveira A., Pereira S., Silva C.A., Augmenting data when training a CNN for retinal vessel segmentation: How to warp?, 2017 IEEE 5th Portuguese Meeting on Bioengineering (ENBENG), Coimbra-Portugal, 1-4, 2017.
 62. Ribeiro V., Avila S., Valle E., Less is more: Sample selection and label conditioning improve skin lesion segmentation, *IEEE/CVF 2020 Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Seattle- WA-USA, 3182-3191, 2020.
 63. Akyel C., Arıcı N., LinkNet-B7: Noise removal and lesion segmentation in images of skin cancer, *Mathematics*, 10 (5), 736, 2022.
 64. Thapar P., Rakhra M., Cazzato G., Hossain S., A novel hybrid deep learning approach for skin lesion segmentation and classification, *Journal of Healthcare Engineering*, 2022, 1-21, 2022.
 65. Arpacı S.A., Varlı S., Retinal vessel segmentation with differentiated U-Net network, 28th Signal Processing and Communications Applications Conference, Gaziantep-Turkey, 1-4, 2020.
 66. Arpacı S.A., Varlı S., Retinal vessel segmentation with the mixup data augmentation method, *Journal of Health Institutes of Türkiye*, 5 (1), 41-50, 2022.
 67. Arpacı S.A., Varlı S., Semantic segmentation with the mixup data augmentation method, 30th Signal Processing and Communications Applications Conference (SIU), Safranbolu-Turkey, 1-4, 2022.
 68. Nishio M., Noguchi S., Fujimoto K., Automatic pancreas segmentation using coarse-scaled 2D model of deep learning: Usefulness of data augmentation and deep U-Net, *Applied Sciences*, 10 (10), 3360, 2020.
 69. Noguchi S., Nishio M., Yakami M., Nakagomi K., Togashi K., Bone segmentation on whole-body CT using convolutional neural network with novel data augmentation techniques, *Computers in Biology and Medicine*, 121, 2020.
 70. Konur U., Semi-automatic heuristic segmentation of fetal skull images, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38 (2), 679–692, 2022.
 71. Eker A.G., Pehlivanoğlu M.K., İnce İ., Duru N., Deep learning and transfer learning based brain tumor segmentation, 8th International Conference on Computer Science and Engineering (UBMK), Burdur-Türkiye, 163-168, 2023.
 72. Çekiç İ., Çavdar K., Detection of the cracks in metal sheets using convolutional neural network (CNN), *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38 (1), 153–162, 2022.
 73. Türkmen M., Orman, Z., İnsan omurgasına ait bilgisayarlı tomografi görüntülerinin iyileştirilmesi ve omur segmentasyonu, *Avrupa Bilim ve Teknoloji Dergisi*, 52, 95-103, 2023.

