

İletişim / Correspondence:

¹ Yıldız Teknik Üniversitesi
saadeta99@gmail.com

² Prof. Dr/Prof. Dr
Yıldız Teknik Üniversitesi
svarli@yildiz.edu.tr
ORCID:0000-0002-1786-6869

Geliş Tarihi: 11.03.2022
Kabul Tarihi: 04.19.2022

Received Date: 11.03.2022
Accepted Date: 19.04.2022

Anahtar Kelimeler:
Veri artırma; Bölütleme;
U-Net

Keywords:
Data augmentation;
Segmentation; U-Net

DOI:10.54537/tusebdergi
si.1083833

Mixup Veri Artırma Yöntemi ile Retina Damar Bölütlemesi

Saadet Aytaç ARPACI¹, Songül VARLI²

Özet

Derin sinir ağı modellerinin aşırı uyum sorununun azaltılması için veri artırma yöntemlerine başvurulmaktadır. 2018 yılında bir veri artırma yöntemi olan mixup tanıtılmıştır ve devam eden yıllarda farklı organ ve görüntü modalitelerinde yapılan çalışmalar ile mixup yönteminin model bölütleme yeteneği üzerindeki etkisi incelenmiştir. Mixup yönteminin tarayıcı lazer oftalmoskop ile elde edilmiş fundus görüntülerinde retina damar bölütlemesi için kullanımına yönelik bir çalışmaya rastlanmamıştır. Bu çalışmanın amacı, IOSTAR veri kümesi görüntülerinde U-Net modeli ile gerçekleştirilen retina damar bölütlemesine mixup yönteminin etkisinin incelenmesidir. Bu doğrultuda yatay yansıtma, görüntünün rastgele bir alanını kırpmaya, çevirme gibi veri artırma işlemlerinin görüntülere uygulandığı bir geleneksel grup; geleneksel yöntem ile oluşturulmuş görüntülere ek olarak lambda 0,2 veya 0,5 değerlerine göre mixup yönteminin uygulandığı iki farklı grup; lambda 0,2 veya 0,5 değerlerine göre sadece mixup yönteminin uygulandığı iki farklı grup olmak üzere beş farklı veri grubu oluşturulmuştur. Doğruluk, duyarlılık, özgüllük, Dice ve Jaccard ölçütlerine göre değerlendirmeler yapılmıştır. Geleneksel veri artırma yöntemleriyle karşılaştırıldığında, U-Net modelinin retina damar bölütleme yeteneğine mixup veri artırma yönteminin iyileşme sağlamadığı görülmüştür.

Retinal Vessel Segmentation with the Mixup Data Augmentation Method

Saadet Aytaç ARPACI¹, Songül VARLI²

Abstract

Data augmentation methods are used to reduce the overfitting problem of deep neural network models. In 2018, mixup, a data augmentation method, was introduced, and in the following years, the effects of the mixup method on the model segmentation ability were examined in the studies carried out on different organs and image modalities. No study has been found on the use of the mixup method for retinal vessel segmentation on fundus images obtained with the scanning laser ophthalmoscope. The aim of this study is to investigate the effect of the mixup method on retinal vessel segmentation performed with the U-Net model on the IOSTAR dataset images. In this direction, 1) data augmentation operations such as horizontal flipping, rotation, and cropping of a random area of the image were applied to the images to create the traditional group; 2) the images that were created with the traditional method were added to the images that the mixup method was applied according to the lambda values of 0.2 or 0.5, and so two different groups were created; 3) two different groups were created with the images in which only the mixup method was applied according to the lambda values of 0.2 or 0.5. As a result, a total of five groups were examined in this study. Evaluations were made according to the accuracy, sensitivity, specificity, Dice, and Jaccard metrics. Compared to traditional data augmentation methods, the mixup data augmentation method was shown to have no positive effect on the U-Net model's ability to segment retinal vessels.

1. Giriş

Oftalmologlar, fundusdaki sorunların tespiti için renkli fundus görüntüleme ve tarayıcı lazer oftalmoskoplardan faydalanır. 1990 yılından beri klinik uygulamalara yardımcı olan tarayıcı lazer oftalmoskop, eksüdalara daha soluk ve optik diski daha koyu göstermesine rağmen son dönemdeki gelişmelerle beraber renkli fundus görüntülemeye göre oftalmologlara teşhisleri için daha fazla avantaj kazandırmaktadır. Örneğin, kornea opasiteleri veya katarakt olsa dahi midriyazis olmadan daha net ve iyi görüntü kalitesine sahip fundus görüntüleri elde edebilir, retinanın farklı derinlikleri için daha fazla bilgi sağlar ve oküler fundus alanının daha geniş açılı görüntülerini elde edebilir (Pachade, Porwal, Kokare, Giancardo ve Meriaudeau, 2020; Terasaki, Sonoda, Tomita ve Sakamoto, 2021).

Diyabetik retinopati, hipertansiyon, kardiyovasküler rahatsızlıklar, retina arter / ven tıkanıklığı gibi hastalıklar retina damar yapısında çentiklenme, daralma, genişleme veya kıvrımlar oluşturarak retina damarında çeşitli değişikliklere neden olur ve sonuçta görme bozuklukları meydana gelir. Damar yapısındaki bu değişimlerin erken tespiti görme bozukluğunun tedavisi ve körlüğün önlenmesi açısından önemlidir. Hastalıklar nedeniyle retinadaki damar yapısı değişimleri yapılan damar bölütleme işlemi ile gözlenmeye çalışılır. Geleneksel olarak, eğitimli uzmanlar tarafından gerçekleştirilen manuel bölütleme işlemi, yoğun ve ince damarlar nedeniyle zaman alıcı olan bir süreçtir. Dolayısıyla günümüzde uzmanlara destek olmak amacıyla retina damarlarının elde edilmesi için otomatik tekniklerin geliştirilmesi devam etmektedir (Khan ve diğ., 2019; Pachade ve diğ., 2020).

Evrişimsel sinir ağı yüksek performans ile görüntüdeki önemli özellikleri çıkarabilme kapasitesine sahiptir. Evrişimsel sinir ağı kökenli U-Net (Ronneberger, Fischer ve Brox, 2015), tıbbi görüntülerin analizinde birçok derin öğrenme

modelinin temelini oluşturan verimli bir mimaridir (Arpacı ve Varlı, 2020; Arpacı ve Varlı, 2021a; Cai, Li, Gao ve Guo, 2019; Cheng ve diğ., 2020; Li, Fan ve Chen, 2019; Xiao, Lian, Luo ve Li, 2018). Retina damar yapısının bölütlenmesine yönelik çalışmalar, ulaşılabilir kamuya açık veri kümelerinin daha fazla olması nedeniyle çoğunlukla renkli fundus görüntüleme cihazları ile elde edilen görüntüler üzerinde gerçekleştirilmiştir. Kamuya açık olarak tarayıcı lazer oftalmoskop ile elde edilen görüntülerin sunulduğu veri kümeleri ise oldukça azdır ve IOSTAR veri kümesi de en çok bilinenidir. Meyer, Costa, Galdran, Mendonça ve Campilho (2017), bu veri kümesine ait görüntüleri 128 × 128 piksellik üst üste binen yamalara bölerek U-Net modeli ile retina damar bölütlemesi yapmak için kullanmıştır. Guo, Szemenyei, Yi, Xue, Zhou ve Li (2020), görüntü boyutunu değiştirmeden Res-Net, Dense-Net ve U-Net (He, Zhang, Ren ve Sun, 2016; Huang, Liu, Maaten ve Weinberger, 2017; Ronneberger ve diğ., 2015) modellerine dayalı bir mimari yaklaşım sunarak aynı veri kümesi görüntüleri ile retina damar bölütlemesini gerçekleştirmiştir. Bir veri kümesi üzerinde eğitim yapıldığında test görüntülerinin de aynı veri kümesinden olmasının modelin bölütleme başarısını yükselteceği konusunu Brea, Jesus, Klein ve Walsum (2020), genişleterek incelemiştir. Brea ve diğerleri (2020), renkli fundus görüntüleme cihazları ile elde edilmiş görüntüler üzerinde eğitilmiş U-Net modelinin tarayıcı lazer oftalmoskop görüntüleri üzerinde test edilebilirliğini, yani farklı veri kümeleri arasında da yararlı yönde bilgi aktarımının olabileceğini göstermiştir. Geleneksel evrişimsel sinir ağlarında kullanılan filtrelerin genellikle boyutunun küçük olması nedeniyle orijinal görüntüdeki her bir özelliğe karşılık gelen alan da sınırlı olur ve genel bilgi tam olarak dikkate alınmaz. Ağ katmanlarının sayısı arttıkça da, bölütleme sonucuna faydalı bazı özellikler göz ardı edilebilir. Bu durum, özellikle retina kan damarlarının küçük yapıları için daha da büyük önem taşır. Damar bölütlemesi için oluşan bu tür dezavantajların üstesinden

gelebilmek amacıyla Li, Jiang, Li ve Yin (2021), U-Net modeline üç aşamalı bir dikkat modülü eklemiştir. Hu, Shen ve Sun (2018) yazarlarının önerdiği SE-Net modülü de Arpacı ve Varlı (2021b) tarafından U-Net modeline dayalı bir mimaride kullanılarak retina damar bölütlemesi gerçekleştirilmiştir.

Derin öğrenme modellerinin eğitim verileriyle gösterdiği performansı test verileriyle de sağlaması beklenir ve bu denge model mimarisinin iyileştirilmesi, bırakma, yığın normalizasyon, transfer öğrenme, ön eğitim gibi düzenleme işlemleriyle sağlanmaya çalışılır. Gerek renkli fundus görüntüleme cihazları gerekse tarayıcı lazer oftalmoskop ile elde edilmiş kamuya açık veri kümeleri az sayıda örnek görüntü içerirler ve bu nedenle yapay sinir ağı modelleri gibi aşırı uyum sorunundan kaçınmak için daha fazla örneğe ihtiyaç gösteren uygulamalarda bir kısıt oluştururlar. Bu aşamada da veri artırma yöntemlerine başvurulur.

2018 yılında ICLR konferansında mixup veri artırma yöntemi tanıtılmıştır (Zhang, Cisse, Dauphin ve Lopez-Paz, 2018). Bu veri artırma yöntemini Gazda ve diğerleri (2021) böbrek, Nishio, Noguchi ve Fujimoto (2020) pankreas, Noguchi, Nishio, Yakami, Nakagomi ve Togashi (2020) kemik gibi bazı organ görüntülerinin bölütlemesi için kullanmıştır. Literatürde bildiğimiz kadarıyla IOSTAR veri kümesi ile retina damar bölütlemesi için mixup yönteminin kullanımına rastlanmamıştır. Bu çerçevede çalışmamızın katkıları aşağıdaki gibidir:

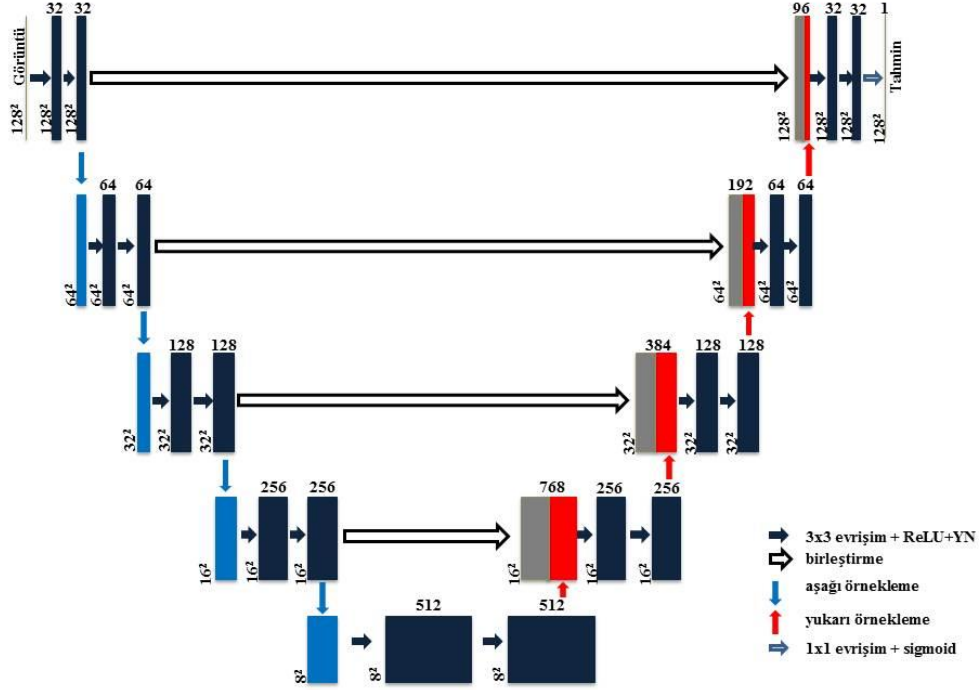
- Mixup yönteminin tarayıcı lazer oftalmoskop ile elde edilmiş fundus görüntülerinde retina damar bölütlemesi için kullanılması.
- Çalışmada kullanılan U-Net modelinin retina damar bölütleme performansına, mixup yönteminin sağladığı faydanın belirlenmesi.

2. Gereç ve Yöntemler

2.1. Model

Bu çalışmada uyguladığımız U-Net ağ mimarisinde (Şekil 1) evrişim işlemi 32 filtre ile başlamaktadır. Aşağı örnekleme ve yukarı örnekleme işlemleri için sırasıyla 2×2 'lik maksimum havuzlama ve çift yönlü doğrusal enterpolasyon (bilinear interpolation) kullanılmıştır. Modelde 3×3 'lük evrişim katmanı sonrası yığın normalizasyon (YN) işlemi uygulanmıştır. Uygulanan modelin aktivasyon fonksiyonu için ReLU ve optimizasyon algoritması için Adam yöntemi (Kingma ve Ba, 2015) başlangıç öğrenme oranı 0,001 olacak şekilde uygulanmıştır. 100 iterasyonla eğitilen modelin çıkış katmanında 1×1 'lik evrişim ve sigmoid aktivasyon işlevi çalıştırılmıştır. Bölütleme araştırmamız için, TensorFlow ve Keras kütüphanelerinden faydalanılmıştır. U-Net mimarisi ile ilgili daha geniş bilgi (Arpacı ve Varlı, 2021b; Ronneberger ve diğ., 2015) referanslarında mevcuttur.

Şekil 1. U-Net mimarisi, Ronneberger ve diğerleri (2015) referansı temelinde yeniden düzenlenerek çizilmiştir




2.2. Mixup Veri Artırma Yöntemi

Uygulamalarda kullanılan modelin genelleme yeteneğini sağlayabilmek için ölçekleme, yansıtma, çevirme gibi geleneksel yöntemlerle veri artırma işlemi yapılarak eğitim görüntülerine benzer ek sanal görüntüler oluşturulabilir. Aynı sınıfın paylaşımına dayalı oluşturulan bu tür veri artırma yöntemlerine karşılık farklı sınıf örnekleri arasındaki doğrusal etkileşimi modelleyebilmek amacıyla mixup adında yeni bir veri artırma yöntemi tanıtılmıştır (Zhang ve diğ., 2018). Mixup yöntemi sınıftan sınıfa doğrusal geçiş yapan karar sınırlarına yol açmakta ve daha yumuşak bir belirsizlik tahmini sağlamaktadır.

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

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

Denklem (1) ve (2) de x_i, x_j ham girdi vektörleri ve y_i, y_j etiketleri temsil etmektedir buna göre (x_i, y_i) ve (x_j, y_j) eğitim veri kümesinden rastgele seçilen iki görüntüyü ifade eder. Mixup yönteminde iki örneği ve bunlara karşılık gelen etiketleri ağırlıklandırmak için lambdaya (λ) bağlı bir değer kullanılır, bu değer $\lambda \in [0, 1]$ aralığında seçilir. Bu çalışmada fundus görüntülerinin $\lambda=0,2$ değerine göre mixup yöntemiyle oluşturulmuş örnek görüntüleri mixup ($\lambda=0,2$) grubu ve geleneksel+mixup ($\lambda=0,2$) grubu olarak incelendi. Çalışmada $\lambda=0,5$ değerine göre mixup yöntemiyle oluşturulmuş örnek görüntüleri ise mixup ($\lambda=0,5$) grubu ve geleneksel+mixup ($\lambda=0,5$) grubu olarak incelendi. Şekil 2'de $\lambda=0,5$ değerine göre oluşturulmuş örnek sunulmaktadır.

Şekil 2. Veri artırma yöntemleri ile elde edilmiş örnek görüntüler

2.3. Veri Kümesi, Ön İşlem, Son İşlem

Bu araştırmada IOSTAR veri kümesi kullanılmıştır. Tarayıcı lazer oftalmoskop ile oluşturulmuş veri kümesindeki görüntüler, 45° FOV ile 1024 × 1024 piksel çözünürlüğe sahiptir. Veri kümesi içerisinde 30 adet görüntü bulunur. Gerçek referans görüntüler de uzmanlar tarafından oluşturulmuş ve veri kümesine dahil edilmiştir. Görüntüler ".jpg" ve ".tif" formatında sunulmuştur. Veri kümesi hakkında daha fazla bilgi (Sureshjani, Ockeloen, Zhang ve Ter Haar Romeny, 2015; Zhang ve diğ., 2016) referanslarında mevcuttur.

Görüntülerde damar kalınlıklarındaki değişiklikler, damarlardaki geçişler ve çatallanmalar, ince damarlar için damar ve arka plan arasındaki düşük karışıklık farkı bölütlemeyi zorlaştıran sorunlar arasındadır ve daha fazla damar detayı elde ederek bölütlemeyi gerçekleştirebilmek için U-Net ile yapılan çalışmalarda (Cai ve diğ., 2019; Cheng ve diğ., 2020; Li ve diğ., 2019; Xiao ve diğ., 2018) farklı ön işleme teknikleri uygulanmıştır. Bu çalışmada da (Arpacı ve Varlı, 2021b) makalesinde uygulanan yöntem IOSTAR veri kümesi görüntülerinin ön işlem aşaması için kullanılmıştır. Bu işlemde, ilk aşamada görüntüler HSV renk uzayına dönüştürülmüş ve "V" kanalına gama doğrulama işlemi uygulanarak parlaklık ayarlanmıştır. Daha sonra görüntüler HSV renk uzayından RGB renk uzayına dönüştürülmüştür. İkinci aşamada, görüntüler RGB renk uzayından LAB renk uzayına

dönüştürülmüş ve damar kontrastını artırmak için L kanalına kontrast sınırlı adaptif histogram eşitleme (CLAHE) işlemi uygulanmıştır. Görüntü piksel değerleri [0-1] aralığına normalleştirilmiştir ve görüntüler 128 × 128'e yeniden boyutlandırılmıştır. Görüntülerin ön işlemesi sırasında OpenCV kütüphanesi kullanılmıştır. Test için IOSTAR veri kümesindeki son 10 görüntü kullanılmıştır. İlk 20 görüntüye veri artırma işlemi uygulanmıştır. Mixup veri artırma yönteminin model verimliliğine katkısını incelemek amacıyla 5 farklı veri grubu oluşturulmuştur.

(1) Geleneksel: Augmentor kütüphanesi kullanılarak yatay yansıtma, görüntünün rastgele bir alanını kırpma, görüntüyü sola ve sağa maksimum 10° çevirme gibi veri artırma işlemleri uygulanmıştır. Şekil 2'de örnek görüntüler sunulmaktadır. Bu işlemlerin sonucunda 300 görüntü elde edilmiştir.

(2) Mixup: IOSTAR veri kümesindeki 20 adet görüntüye rastgele görüntü seçimleriyle mixup yöntemi uygulanarak toplamda 300 görüntü elde edilmiştir. $\lambda=0,2$ ve $\lambda=0,5$ için 2 farklı veri grubu oluşturulmuştur.

(3) Geleneksel + mixup: IOSTAR veri kümesindeki 20 görüntüye Augmentor kütüphanesi kullanılarak yatay yansıtma, görüntünün rastgele bir alanını kırpma, görüntüyü sola ve sağa maksimum 10° çevirme gibi veri artırma işlemleri ile 150 adet görüntü elde edilmiştir. Bu görüntülere ek olarak diğer 150 adet görüntü ise IOSTAR veri kümesindeki 20 adet

görüntüye rastgele görüntü seçimleriyle mixup yöntemi uygulanarak elde edilmiştir. $\lambda=0,2$ ve $\lambda=0,5$ için 2 farklı veri grubu oluşturulmuştur.

Görüntülerin %20'si doğrulama için kullanılmıştır. Son işlem aşamasında 0,5 eşik değerine göre ikili eşikleme işlemi uygulanmıştır.

2.4. Değerlendirme Ölçütleri

Bu çalışmada doğruluk (denklem 3), duyarlılık (denklem 4), özgüllük (denklem 5), Dice (denklem 6) ve Jaccard (denklem 7) değerleri ölçülmüştür. DP, DN, YP, YN sırayla doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif piksel miktarlarıdır. Ölçütlerle ilgili açıklayıcı bilgi (Arpacı ve Varlı, 2021b) referansında mevcuttur.

$$\text{Doğruluk} = \frac{DN+DP}{DN+DP+YN+YP} \quad (3)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (4)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (5)$$

$$\text{Dice} = \frac{2DP}{2DP+YN+YP} \quad (6)$$

$$\text{Jaccard} = \frac{DP}{DP+YN+YP} \quad (7)$$

3. Bulgular

Mixup veri artırma yönteminin kullanımıyla U-Net'in tarayıcı lazer oftalmoskop ile elde edilmiş

görüntülerde retina damar bölütlemesi için performansının incelendiği bu çalışmada değerlendirme, doğruluk, duyarlılık, özgüllük, Dice ve Jaccard (IoU) ölçütlerine göre gerçekleştirilmiştir. Değerlendirme 5-kat çapraz doğrulama tekniği ile elde edilmiş ortalama sonuç değerleri üzerinden yapılmıştır. Tablo 1 çalışmada kullanılan veri gruplarına göre U-Net modelinin eğitimde ulaştığı ölçüt değerlerini yüzdesel olarak sunmaktadır. Tablo 1'e göre sadece mixup veri artırma yönteminin uygulandığı gruplarda belirgin olarak duyarlılık, Dice ve Jaccard ölçüt değerlerinin yükseldiği görülmektedir. $\lambda=0,2$ değeri uygulanan mixup yönteminin geleneksel veri artırma yöntemi ile birlikte kullanıldığı grupta da belirgin olmamakla birlikte sadece geleneksel veri artırma yöntemi uygulanan görüntü grubuna göre özgüllük hariç diğer ölçütler için eğitim aşamasında değer artışı sağladığı görülmektedir, bu etki geleneksel veri artırma yöntemi ve $\lambda=0,5$ değeri uygulanan mixup yönteminin birlikte kullanımında gözlenmemiştir. U-Net modelinin eğitim sonuçları dikkate alındığında sadece mixup yönteminin uygulanmasının bu aşama için güçlü bir fayda sağladığı ifade edilebilir.

Tablo 1. Eğitim değerlendirme sonuçları (%)

Uygulanan veri artırma yöntemleri	Doğruluk	Duyarlılık	Özgüllük	Dice	Jaccard (IoU)
Geleneksel	96,45	76,81	98,51	80,37	67,20
Mixup ($\lambda=0,2$)	98,33	92,56	98,77	88,86	79,96
Mixup ($\lambda=0,5$)	96,24	84,76	97,70	83,53	71,74
Geleneksel + mixup ($\lambda=0,2$)	96,71	79,73	98,34	80,84	68,08
Geleneksel + mixup ($\lambda=0,5$)	95,51	75,65	97,80	77,54	63,33

Tablo 2 IOSTAR veri kümesinin test için ayrılmış son 10 görüntüsüne ait ortalama ölçüt değerlerini yüzdesel olarak sunmaktadır. Duyarlılık, Dice ve Jaccard değerlerinin mixup veri artırma yöntemiyle geleneksel yöntemin birlikte

kullanıldığı görüntü grupları için test sonuçları, sadece mixup yöntemi uygulanan gruplara göre daha iyi sonuç vermiştir. Dice ve Jaccard ölçüt değerleri sadece geleneksel veri artırma yöntemi uygulanan görüntü grubunda diğer gruplara göre


test sonuçlarında iyileşme göstermiştir. U-Net modelinin test sonuçları dikkate alındığında mixup yönteminin kullanımının örtüşme oranlarını iyileştirmesi yönünde fayda

sağlamadığı ifade edilebilir. Şekil 3'te her gruba göre bir test örneği ile elde edilen bölütleme görüntüleri sunulmaktadır.

Tablo 2. Test değerlendirme sonuçları (%)

Uygulanan veri artırma yöntemleri	Doğruluk	Duyarlılık	Özgüllük	Dice	Jaccard (IoU)
Geleneksel	96,08	72,13	98,15	74,29	59,19
Mixup ($\lambda=0,2$)	95,74	65,13	98,39	70,60	54,63
Mixup ($\lambda=0,5$)	95,27	71,34	97,35	70,26	54,26
Geleneksel + mixup ($\lambda=0,2$)	96,10	68,01	98,53	73,26	57,94
Geleneksel + mixup ($\lambda=0,5$)	95,63	73,96	97,51	72,69	57,21

Şekil 3. Test örneği için bölütleme sonuç görüntüleri



4. Tartışma

Mixup veri artırma yönteminin retina damar bölütlemesi üzerindeki etkinliğinin incelendiği bu çalışmada oluşturulmuş beş farklı veri grubu ile eğitim yapılarak aynı test örnekleri için başarımlar elde edilmiştir. Görüntülere sadece mixup yönteminin uygulanması eğitim başarısını belirgin şekilde artırmaya rağmen test

örneklerinin örtüşme oranları açısından tüm gruplar içerisinde en düşük değerleri elde etmiştir. Sadece geleneksel veri artırma yönteminin uygulandığı grup test örneklerinin örtüşme oranları açısından daha yüksek değerleri elde etmiştir.

Semantik bölütleme için mixup yöntemini ilk defa Eaton-Rosen, Bragman, Ourselin ve Cardoso

(2018) uygulamıştır ve beyin gliomlarının çok modlu manyetik rezonans görüntüleme veri kümesinde (BraTS 2017) yöntemin etkinliği doğrulanmıştır. Isaksson ve diğerleri (2022), prostat kanserli hastaların manyetik rezonans görüntüleme (MRG) görüntülerinde geleneksel yöntemle birlikte kullandıkları mixup yönteminin U-Net'in eğitim bölütleme performansını artırdığını göstermişlerdir. Noguchi ve diğerleri (2020)'nin yaptıkları araştırmada ise kemik bölütlemesi için inceledikleri bilgisayarlı tomografi (BT) görüntülerinde sadece mixup yönteminin kullanımının veya mixup yönteminin kayma dönüşümü, çevirme, yakınlaştırma ve yatay yansıtma gibi geleneksel veri artırma yöntemleri ile birlikte kullanımının eğitim ve test sonuçlarını iyileştirmediğini rapor etmişlerdir. Nishio ve diğerleri (2020) yaptıkları çalışmanın sonucu olarak, RICAP ve mixup yönteminin birlikte kullanımının pankreas BT görüntüleri için bölütleme doğruluğunu artıracığını belirtmektedir. Buna karşılık mixup yönteminin fayda sağlamadığını gözlemleyen Noguchi ve diğerleri (2020), geleneksel veri artırma yöntemine ek olarak RICAP yönteminin uygulanmasını önermektedir.

Mixup veri artırma yönteminin değerlendirildiği üst paragrafta belirtilen çalışmalar genel olarak tıbbi görüntüler için mixup yönteminin bölütleme performansına olumlu etki sağladığına yönelik net bir sonuca ulaşılamamaktadır. Çalışmalardaki farklı sonuçlar BT veya MRG gibi farklı modalitelere ait görüntülerin kullanımıyla ilgili olabilir. Bu nedenle mixup yönteminin beyin, retina, pankreas vb. her tıbbi çalışma alanı için ayrı olarak değerlendirilmesi gerekebilir. Bu çalışmada kullanılan mixup yönteminin parametreye bağımlı olması nedeniyle veri kümesine en uygun parametre değerlerinin uygulanması sonuçları değiştirebilir. Bu aşamada tarayıcı lazer oftalmoskop ile elde edilmiş görüntülerden otomatik retina damar bölütlemesinin yapılmasında uygulanan ön işlem, model ve

parametreler kapsamında mixup veri artırma yöntemi model performansını iyileştirmedi.

5. Sonuç

Bu makale mixup veri artırma yönteminin retina damar bölütlemesi için U-Net modelinin bölütleme yeteneğine etkisini inceler. Uygulamalar ön işlem yapılmış IOSTAR veri kümesi görüntüleri ile gerçekleştirildi. Parametre değişimlerine bağlı olan mixup yönteminin bu çalışmada uygulanan diğer değişkenlerle birlikte retina damar bölütlemesi için olumlu katkı sağlamadığı görüldü. Yatay yansıtma, görüntünün rastgele bir alanını kırpma, görüntüyü çevirme gibi geleneksel veri artırma yöntemleri bu aşamada daha verimli sonuçlar oluşturmuştur. Gelecekte mixup yönteminin farklı parametre değerlerine göre incelenmesi ve farklı veri artırma yöntemleri ile birlikte değerlendirilmesi yapılabilir.

6. Kaynaklar

- Arpacı, S. A., & Varlı, S. (2020, Ekim). Farklılaştırılmış U-Net ağı ile retina damar bölütlemesi. Sözel bildiri, 2020 28. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU), Gaziantep, Türkiye.
- Arpacı, S. A., & Varlı, S. (2021a, Haziran). EncU-Net: Dermoskopik görüntü bölütlemesi için modifiye edilmiş U-Net. Sözel bildiri, 2021 29. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU), İstanbul, Türkiye.
- Arpacı, S. A. & Varlı, S. (2021b). LUPU-Net: a new improvement proposal for encoder-decoder architecture. International Advanced Researches and Engineering Journal, 5 (3), 352-361. doi: 10.35860/iarej.939243
- Brea, L.M., Jesus, D.A., Klein, S., & Walsum, T.V. (2020, July). Deep learning-based retinal vessel segmentation with cross-modal evaluation. Poster, Third Conference on Medical Imaging with Deep Learning (MIDL), Montreal, QC, Canada.
- Cai, Y., Li, Y., Gao, X., & Guo, Y. (2019, October). Retinal vessel segmentation method based on improved deep U-Net. Sözel bildiri, Chinese

Conference on Biometric Recognition, Zhuzhou, China.

Cheng, Y., Ma, M., Zhang, L., Jin, C., Ma, L., & Zhou, Y. (2020). Retinal blood vessel segmentation based on densely connected U-net. *Mathematical Biosciences and Engineering*, 17 (4), 3088-3108. doi:10.3934/mbe.2020175

Eaton-Rosen, Z., Bragman, F.J., Ourselin, S., & Cardoso, M.J. (2018, July). Improving data augmentation for medical image segmentation. Sözel bildiri, International Conference on Medical Imaging with Deep Learning, Amsterdam, Netherlands.

Gazda, M., Bugata, P., Gazda, J., Hubacek, D., Hresko, D. J., & Drotar, P. (2021). Mixup augmentation for kidney and kidney tumor segmentation. <https://openreview.net/forum?id=GvUsPesMtmC> adresinden elde edildi.

Guo, C., Szemenyei, M., Yi, Y., Xue, Y., Zhou, W., & Li, Y. (2020, May). Dense residual network for retinal vessel segmentation. Poster, 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Barcelona, Spain.

He, K., Zhang, X., Ren, S., & Sun, J. (2016, June). Deep residual learning for image recognition. Sözel bildiri, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA.

Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017, July). Densely connected convolutional networks. Sözel bildiri, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, Hawaii.

Hu, J., Shen, L., & Sun, G. (2018, June). Squeeze-and-excitation networks. Sözel bildiri, 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City, USA.

Isaksson, L. J., Summers, P., Raimondi, S., Gandini, S., Bhalerao, A., Marvaso, G., et. al. (2021). Mixup (sample pairing) can improve the performance of deep segmentation networks. *Journal of Artificial Intelligence and Soft Computing Research*, 12 (1), 29-39. doi:10.2478/jaiscr-2022-0003

Khan, K. B., Khaliq, A. A., Jalil, A., Iftikhar, M. A., Ullah, N., Aziz, M., ve diğerleri. (2018). A review of retinal blood vessels extraction techniques: Challenges, taxonomy, and future trends. *Pattern*

Analysis and Applications, 22 (3), 767-802. doi:10.1007/s10044-018-0754-8

Kingma, D., & Ba, J. (2015). Adam: A method for stochastic optimization. <https://arxiv.org/abs/1412.6980v5> adresinden elde edildi.

Li, Q., Fan, S., & Chen, C. (2019). An intelligent segmentation and diagnosis method for diabetic retinopathy based on improved U-NET network. *Journal of Medical Systems*, 43 (9), 304. doi:10.1007/s10916-019-1432-0

Li, X., Jiang, Y., Li, M., & Yin, S. (2021). Lightweight attention convolutional neural network for retinal vessel image segmentation. *IEEE Transactions on Industrial Informatics*, 17 (3), 1958-1967. doi:10.1109/tii.2020.2993842

Meyer, M. I., Costa, P., Galdran, A., Mendonça, A. M., & Campilho, A. (2017). A deep neural network for vessel segmentation of scanning laser ophthalmoscopy images. https://link.springer.com/content/pdf/10.1007%2F978-3-319-59876-5_56.pdf adresinden elde edildi.

Nishio, M., Noguchi, S., & Fujimoto, K. (2020). Automatic pancreas segmentation using coarse-scaled 2D model of deep learning: Usefulness of data augmentation and deep U-Net. *Applied Sciences*, 10 (10), 3360. doi:10.3390/app10103360

Noguchi, S., Nishio, M., Yakami, M., Nakagomi, K., & Togashi, K. (2020). Bone segmentation on whole-body CT using convolutional neural network with novel data augmentation techniques. *Computers in Biology and Medicine*, 121, 103767. doi:10.1016/j.combiomed.2020.103767

Pachade, S., Porwal, P., Kokare, M., Giancardo, L., & Meriaudeau, F. (2020). Retinal vasculature segmentation and measurement framework for color fundus and SLO Images. *Biocybernetics and Biomedical Engineering*, 40 (3), 865-900. doi:10.1016/j.bbe.2020.03.001

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. <https://arxiv.org/abs/1505.04597> adresinden elde edildi.

Sureshjani, S., Ockeloen, I., Zhang, J., & Ter Haar Romeny, B. (2015, July). Biologically-inspired

supervised vasculature segmentation in SLO retinal fundus images. Sözel bildiri, 12th International Conference, ICIAR 2015, Niagara Falls, Canada.

Terasaki, H., Sonoda, S., Tomita, M., & Sakamoto, T. (2021). Recent advances and clinical application of color scanning laser ophthalmoscope. *Journal of Clinical Medicine*, 10 (4), 718. doi:10.3390/jcm10040718

Xiao, X., Lian, S., Luo, Z., & Li, S. (2018, October). Weighted Res-UNet for high-quality retina vessel segmentation. Sözel bildiri, 2018 9th International Conference on Information Technology in Medicine and Education (ITME), Hangzhou, China.

Zhang, J., Dashtbozorg, B., Bekkers, E., Pluim, J. P., Duits, R., & Ter Haar Romeny, B. M. (2016). Robust retinal vessel segmentation via locally adaptive derivative frames in orientation scores. *IEEE Transactions on Medical Imaging*, 35 (12), 2631-2644. doi:10.1109/tmi.2016.2587062

Zhang, H., Cissé, M., Dauphin, Y., & Lopez-Paz, D. (2018, April). mixup: Beyond empirical risk minimization. Poster, 6th International Conference on Learning Representations (ICLR), Vancouver, BC, Canada.