

**FUNDUS GÖRÜNTÜLERİNİN DİYABETİK RETİNOPATİ
DEĞERLENDİRMESİNE YÖNELİK OLARAK
BÖLÜTLENMESİ**

**SEGMENTATION OF FUNDUS IMAGES FOR DIABETIC
RETINOPATHY EVALUATION**

ADEM GÜNESEN

DOÇ. DR. SENİHA ESEN YÜKSEL ERDEM

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim - Öğretim ve Sınav Yönetmeliği'nin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı İçin Öngördüğü

YÜKSEK LİSANS TEZİ

olarak hazırlanmıştır.

2024

ÖZET

FUNDUS GÖRÜNTÜLERİNİN DİYABETİK RETİNOPATİ DEĞERLENDİRMESİNE YÖNELİK OLARAK BÖLÜTLENMESİ

Adem Günesen

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği

Danışman: Doç. Dr. Seniha Esen Yüksel Erdem

Ocak 2024, 120 sayfa

En yaygın hastalıklardan biri olan diyabet çeşitli komplikasyonlara yol açmaktadır. Bunlardan biri olan diyabetik retinopati yetişkinlerde kalıcı körlüğün birinci sebebidir. Bu hastalığın düzenli taranması hem hastaların daha az görü kaybını sağlamaktadır hem de erken teşhis sayesinde sağlık sistemine olan maliyeti düşürmektedir. Verimli bir halk sağlığı tarama sistemi oluşturulabilmesi için doktorların üzerine düşen iş yükünün azaltılması gerekmektedir. Diyabetik retinopati kontrollerin otomatize edilmesi son yıllarda bu nedenle revaçta olan bir konudur.

Diyabetik retinopatinin tespitini sağlayan bir sistemin örtülü ya da açık bir şekilde hastalığa dair bulguları öğrenmesi gerekmektedir. Bu tez kapsamında hastalığın sınıflandırılması için gereken lezyonların doğrudan segmentasyonu üzerine çalışılmıştır. Bunun için dört önemli lezyon türü olan mikroanevrizma, hemoraji, eksudat ve yumuşak eksudat için oluşturulmuş IDRİD veri kümesi kullanılmıştır.

Bu çalışmada veri kümesinin sınırlı sayıda görüntüden ve lezyondan oluşmasının yol açtığı sorunların üzerine gidilmiştir. Bu amaçla veri kümesi odaklı aşağıdaki yöntemler geliştirilmiştir:

- Retina lezyonlarının belirgin olmasını sađlayan ön iřleme yöntemi
- Sađlıklı görüntüleme lezyon eklenmesiyle veri artırımı yöntemi
- Üç aşamalı aktarmalı öğretim yöntemi

Bu yöntemlerin de yardımıyla çeşitli parametreler ve diđer yöntemlerin kombinasyonları taranarak literatürdeki en yüksek ikinci performans deđeri yakalanmıřtır. Listelenen yöntemlerin pozitif etkileri test edilerek sunulmuřtur.

Keywords: segmentasyon, diyabetik retinopati, veri artırma, derin öğrenme, yapay zeka, görüntü iřleme, gürültü giderme

ABSTRACT

SEGMENTATION OF FUNDUS IMAGES FOR DIABETIC RETINOPATHY EVALUATION

Adem Günesen

Master of Science, Electrical and Electronics Engineering

Supervisor: Doç. Dr. Seniha Esen Yüksel Erdem

January 2024, 120 pages

Diabetes, one of the most common diseases, leads to various complications. One of these complications, diabetic retinopathy, is the leading cause of permanent blindness in adults. Regular screening for this disease not only reduces the risk of vision loss for patients but also lowers healthcare costs through early diagnosis. To establish an efficient public health screening system, it is essential to reduce the workload on doctors. Therefore, automating diabetic retinopathy checks has become a popular topic in recent years.

A system that enables the detection of diabetic retinopathy must learn to recognize signs of the disease, whether they are explicit or hidden. In this thesis, we focused on the direct segmentation of lesions required for classifying the disease. For this purpose, we used the IDRiD dataset, which includes four important lesion types: microaneurysms, hemorrhages, exudates, and soft exudates.

In this study, we addressed the challenges arising from the limited number of images and lesions in the dataset. To achieve this, the following dataset-focused methods were developed:

- Pre-processing methods to enhance the visibility of retinal lesions.
- Data augmentation method by adding lesions to healthy images.
- A three-stage transfer learning method.

With the help of these methods, various parameters and combinations of other techniques were tested, resulting in achieving the second-highest performance value in the literature. The positive effects of the listed methods were tested and presented.

Keywords: segmentation, diabetic retinopathy, data augmentation, deep learning, artificial intelligence, image processing, denoising

TEŐEKKÜR

En baŐta uzun zaman boyunca siren bu alıŐma boyunca sabırla ve anlayıŐla bana yon gosteren tez danıŐmanım Seniha Esen Yüksel Erdem'e fikirleri ve emekleri için teŐekkür ederim.

En yakın arkadaŐım aĐlar Güher'e hem dostluĐu hem de bu alıŐma için verdiĐi sayısız destek ve katkı için en içten Őekilde teŐekkür ederim. aĐlar'ın gerek teknik desteĐi gerek yaratıcı fikirleri, en ok da zor zamanlarımda saĐladıĐı motivasyon desteĐi bu alıŐmanın en unutulmayacak kısmı oldu.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
TABLolar	x
ŞEKİLLER	xii
SİMGELER VE KISALTMALAR	xvii
1. GİRİŞ	1
1.1. Tezin Kapsamı	2
1.2. Katkılar	2
1.3. Tezin Akışı	2
2. PROBLEM TANIMI	3
2.1. Diyabetik Retinopati	3
2.1.1. Mikroanevrizmalar	7
2.1.2. Hemorajiler	7
2.1.3. Eksudatlar	8
2.1.4. Damarlar	9
2.1.5. Diyabetik Retinopatinin Aşamaları	9
2.2. Biyomedikal Görüntülerde Kullanılan Bölütleme Modelleri	11
2.2.1. Unet	11
2.2.2. DeepLab	12
2.2.3. FCN	13
2.2.4. Mask R-CNN	13
2.2.5. UNet++	14
2.2.6. Attention U-Net	15
2.2.7. ResUNet	15
2.3. Bölütleme Problemlerinde Kullanılan Metrikler	16

2.3.1. Piksel Doğruluğu (Pixel Accuracy)	16
2.3.2. Kesinlik (Precision) ve Duyarlılık (Recall)	16
2.3.3. F1 Skoru	17
2.3.4. IoU (Intersection over Union)	17
2.3.5. Dice Katsayısı (Dice Coefficient)	17
2.3.6. Alıcı İşletim Karakteristiği (ROC) Grafiğinin Altında Kalan Alan	18
2.3.7. Kesinlik (Precision) Duyarlılık (Recall) Grafiğinin Altında Kalan Alan	18
3. LİTERATÜRDEKİ VERİ KÜMELERİ VE ÇALIŞMALAR	19
3.1. Veri Kümeleri	19
3.1.1. Sınıflandırma Veri Kümeleri	19
3.1.2. Bölütleme Veri Kümeleri	20
3.1.3. Lezyon Lokalizasyon Veri Kümeleri	21
3.2. Diyabetik Retinopati Lezyonlarının Bölütlemesi	22
3.2.1. ISBI-2018 "Diabetic Retinopathy – Segmentation and Grading" Çalışmaları	23
3.2.1.1. VRT (Jaemin Son ve ark.)	23
3.2.1.2. IFLYTEK-MIG (Fengyan Wang ve ark.)	23
3.2.1.3. PATech (Liu lihong ve ark.)	23
3.2.1.4. SOONER (Yunzhi Wang ve ark.)	24
3.2.1.5. LzyUNCC (Zhongyu Li ve ark.)	24
3.2.1.6. SAIHST (Yoon Ho Choi ve ark.)	24
3.2.1.7. SDNU (Xiaodan Sui ve ark.)	24
3.2.2. Diğer Çalışmalar	25
3.2.3. Literatürdeki Çalışmaların Karşılaştırılması	31
4. ÖNERİLEN YÖNTEM	31
4.1. Ön İşleme	31
4.1.1. Ben'in Ön İşleme Yöntemi	31
4.1.2. Önerilen Ön İşleme	35
4.1.2.1. Ampute Gauss Filtresi	36
4.2. Gürültü Giderme	41
4.3. Kırpma	44

4.4. Kayan Pencere Yöntemi	45
4.5. PBDA Yöntemi	48
4.5.1. Poisson Görüntü Düzenleme	49
4.6. PBDA Yöntemiyle Sağlıklı Verilerin Eklenmesi	52
4.7. Veri Artırımı	54
4.8. Model ve Eğitim Yöntemi	54
5. DENEYSEL SONUÇLAR	56
5.1. Mikroanevrizma Sınıfına Ait Sonuçlar	59
5.1.1. Kırpmanın Etkisi	59
5.1.2. Örtüşmeli Kırpmanın Etkisi	66
5.1.3. Önişleme Tekniğinin Etkisi	68
5.1.4. Gürültü Giderme Tekniğinin Etkisi	70
5.1.5. PBDA Yönteminin Etkisi	71
5.1.6. Sağlıklı Verilerin Etkisi	73
5.2. Eksudat Sınıfına Ait Sonuçlar	76
5.2.1. Kırpmanın Etkisi	76
5.2.2. Örtüşmeli Kırpmanın Etkisi	76
5.2.3. Önişleme Tekniğinin Etkisi	78
5.2.4. Gürültü Giderme Tekniğinin Etkisi	79
5.2.5. PBDA Yönteminin Etkisi	80
5.2.6. Sağlıklı Verilerin Etkisi	80
5.3. Hemoraji Sınıfına Ait Sonuçlar	81
5.3.1. Kırpmanın Etkisi	81
5.3.2. Örtüşmeli Kırpmanın Etkisi	81
5.3.3. Önişleme Tekniğinin Etkisi	82
5.3.4. Gürültü Giderme Tekniğinin Etkisi	82
5.3.5. PBDA Yönteminin Etkisi	82
5.3.6. Sağlıklı Verilerin Etkisi	83
5.4. Yumuşak Eksudat Sınıfına Ait Sonuçlar	83
5.4.1. Kırpmanın Etkisi	84

5.4.2. Örtüşmeli Kırpmanın Etkisi	84
5.4.3. Önişleme Tekniğinin Etkisi.....	85
5.4.4. Gürültü Giderme Tekniğinin Etkisi	85
5.4.5. PBDA Yönteminin Etkisi	86
5.4.6. Sağlıklı Verilerin Etkisi	86
5.5. Bütün Sınıflara Ait Sonuçlar ve Literatürle Karşılaştırılması	87
6. DEĞERLENDİRME.....	89

TABLolar

	<u>Sayfa</u>
Tablo 3.1 Literatürdeki diğer yöntemlerin IDRiD veri kümesi üzerinde karşılaştırması.	31
Tablo 4.1 Örnek bir model için kenarda ve merkezdeki performans oranları.....	47
Tablo 4.2 Lezyon koleksiyonunda toplanan lezyonların tipi ve sayısı.	48
Tablo 4.3 IDRiD sınıflandırma veri kümesinde bulunan seviyeler ve bu seviyelere ait görüntü sayıları.	53
Tablo 4.4 1. 2. ve 3. veri kümelerinin özellikleri	55
Tablo 5.1 Farklı boyutlarda kırılan görüntülerin model performansına etkileri. ..	60
Tablo 5.2 Örtüşmeli kırma yönteminden önceki ve sonraki performans değerleri. 67	67
Tablo 5.3 Ön işleme tekniğinin öncesi ve sonrasına ait performans değerleri.	69
Tablo 5.4 Gürültü giderme yönteminin öncesi ve sonrasına ait performans değerleri.....	70
Tablo 5.5 PBDA yönteminin öncesi ve sonrasına ait performans değerleri.....	72
Tablo 5.6 PBDA ile sağlıklı veri ekleme yönteminin öncesi ve sonrasına ait performans değerleri.	74
Tablo 5.7 Kırma boyutu 576x576 ve 1152x1152 piksel olan modellerin karşılaştırması.	76
Tablo 5.8 Örtüşmeli kırma yönteminden önceki ve sonraki performans değerleri. 76	76
Tablo 5.9 576 kırma boyutu için ön işleme algoritmasının sonrası ve öncesine ait performans değerleri.	78
Tablo 5.10 1152 kırma boyutu için gürültü giderme işleminin öncesi ve sonrası. .	80
Tablo 5.11 576 kırma boyutu için gürültü giderme işleminin öncesi ve sonrası....	80
Tablo 5.12 PBDA yönteminin öncesi ve sonrasına ait performans değerleri.....	80
Tablo 5.13 Sağlıklı verilerin dahil edilmesinin performansa etkisi.	80
Tablo 5.14 Farklı kırma büyüklükleri için elde edilen performans değerleri.	81
Tablo 5.15 Örtüşmeli kırmanın etkisi.	81

Tablo 5.16	Ön işleme tekniğinin öncesi ve sonrasına ait performans değerleri.	82
Tablo 5.17	Gürültü giderme tekniğinin öncesi ve sonrasına ait performans değerleri.	82
Tablo 5.18	PBDA yönteminin öncesi ve sonrasına ait performans değerleri.....	83
Tablo 5.19	PBDA yönteminin öncesi ve sonrasına ait performans değerleri.....	83
Tablo 5.20	Farklı kırpma boyutları için elde edilen performans değerleri.	84
Tablo 5.21	Örtüşen kırpma yönteminin öncesi ve sonrasında elde edilen performans değerleri.	84
Tablo 5.22	Ön işleme tekniğinin farklı iki model üzerindeki etkileri.....	85
Tablo 5.23	Gürültü giderme yönteminin öncesi ve sonrasına ait performans değerleri.....	86
Tablo 5.24	PBDA yönteminin öncesi ve sonrasına ait performans değerleri.....	86
Tablo 5.25	Sağlıklı verileri eklemenin öncesi ve sonrasına ait performans değerleri.	86
Tablo 5.26	Bütün sınıflara ait sonuçların toplu gösterimi. EX: eksudatlar, HE: hemorajiler, MA: mikroanevrizmalar, SE: yumuşak eksudatlar anlamına gelmektedir.....	87
Tablo 5.27	Önerilen yöntemin literatürdeki diğer yöntemlerle IDRiD veri kümesi üzerinde karşılaştırması. EX: eksudatlar, HE: hemorajiler, MA: mikroanevrizmalar, SE: yumuşak eksudatlar anlamına gelmektedir.	89

ŞEKİLLER

	<u>Sayfa</u>
Şekil 2.1	Uzman görüşleri arasındaki tutarlılığı gösteren şekil [1]. 5
Şekil 2.2	Diyabetik retinopatinin evrelerinin sınıflandırılması için kullanılan kıstaslar [2]. 6
Şekil 2.3	Sağlıklı bir retinaya ait fundus görüntüsü [3]. 6
Şekil 2.4	Mikroanevrizma içeren örnek bir retina görüntüsü. (a) Orjinal fundus görüntüsü ve beyaz dikdörtgenle işaretlenmiş mikroanevrizma. (b) Dikdörtgen içerisindeki mikroanevrizmanın büyütülmüş görüntüsü [4]. 7
Şekil 2.5	Örnek bir hemoraji görüntüsü [5]. 8
Şekil 2.6	Sert eksudat, yumuşak eksudat ve diğer lezyonları gösteren bir görüntü [6]. 9
Şekil 2.7	UNet mimarisi [7]. 12
Şekil 2.8	Genleşmiş evrişimsel katman yapısı [8]. 13
Şekil 2.9	UNet++ iç içe geçmiş ağlar yapısı [9]. 14
Şekil 2.10	Attention U-Net yapısı ve dikkat kapıları [10]. 15
Şekil 3.1	Öne sürülen model mimarisi [11]. 27
Şekil 4.1	Örnek bir retina görüntüsü. 33
Şekil 4.2	Ben'in ön işleme yöntemi ve dış çeperlerin karartılması. 33
Şekil 4.3	σ parametresinin örnek bir fotoğraftaki etkisi. (a) $\sigma = 12$ olduğu durumda G filtresinin çıktısı. (b) $\sigma = 90$ olduğu durumda G filtresinin çıktısı. (c) $\sigma = 360$ olduğu durumda G filtresinin çıktısı. (d) $\sigma = 12$ olduğu durumda ön işleme yönteminin çıktısı. (e) $\sigma = 90$ olduğu durumda ön işleme yönteminin çıktısı. (f) $\sigma = 360$ olduğu durumda ön işleme yönteminin çıktısı. 34

Şekil 4.4	σ parametresinin örnek bir fotoğraftaki etkisi. (a) $\sigma = 12$ olduğu durumda G filtresinin çıktısı. (b) $\sigma = 90$ olduğu durumda G filtresinin çıktısı. (c) $\sigma = 360$ olduğu durumda G filtresinin çıktısı. (d) $\sigma = 12$ olduğu durumda ön işleme yönteminin çıktısı. (e) $\sigma = 90$ olduğu durumda ön işleme yönteminin çıktısı. Yumuşak eksudatlar kırmızı elipslerle gösterilmiştir. (f) $\sigma = 360$ olduğu durumda ön işleme yönteminin çıktısı.	35
Şekil 4.5	Sol üst köşede NaN (kırmızı X'le gösterilmiştir) değerlerini içeren astronomik bir görüntü görülmektedir. Sağ üst köşede Scipy kütüphanesinin Gauss filtresinin çıktısı verilmiştir. Sol alt köşede NaN değerleri 0'a eşitlendikten sonraki Scipy çıktısı verilmiştir. Sağ alt köşede ise Astropy kütüphanesinin Gauss filtresi çıktısı gösterilmiştir.	37
Şekil 4.6	Ampute görüntünün aradeğerleme yoluyla yeniden inşası. Solda NaN değerleri (kırmızı X'lerle gösterilmiştir) içeren görüntü bulunmaktadır. Sağda NaN piksellerinin aradeğerleme yoluyla düzeltilmiş hali görülmektedir.	37
Şekil 4.7	Sırasıyla literatürdeki ön işleme tekniğinin çıktısı ve geliştirilen ön işleme tekniğinin çıktısı. Örnek olarak eksudatların çevresindeki kararmaların ortadan kalktığı görülmektedir.	38
Şekil 4.8	Sırasıyla literatürdeki ön işleme tekniğinin çıktısı ve geliştirilen ön işleme tekniğinin çıktısı (kırpılmış görüntüler). Eksudatların çevresindeki kararmaların kalktığı görülmektedir.	38
Şekil 4.9	(a) Orijinal görüntü. (b) Gauss filtresinden geçirilmiş görüntü. (c) Fark görüntüsü.	39
Şekil 4.10	(a) Fark görüntüsü. (b) Uzaklık görüntüsü. (c) Orjinal görüntüdeki ekstrem olmayan piksellerin oluşturduğu görsel.	39
Şekil 4.11	(a) Ampute Gauss filtresinde kullanılacak piksellerin görselleştirilmesi. (b) Ampute Gauss filtresinin çıktısı. (c) Normal olan Gauss filtresinin çıktısı.	40

Şekil 4.12	(a) Ampute Gauss filtresinin çıktısı. (c) Ön işleme yönteminin çıktısı.	40
Şekil 4.13	Orijinal görüntünün kanallarının ve parlaklık dönüşümüyle elde edilen gri kanalının histogramı	41
Şekil 4.14	Önerilen yöntemle ön işlenmiş görüntünün kanallarının ve parlaklık dönüşümüyle elde edilen gri kanalının histogramı	42
Şekil 4.15	Kullanılan başlıca gürültü giderme yöntemlerinin çıktıları. a) RRDB yöntemi [12] b) ESRGAN yöntemi [12] c) RealESRGAN yöntemi [13] d) BSRGAN yöntemi [14].	43
Şekil 4.16	Gürültü giderme adımının ardından üretilen retina görüntüsü.	43
Şekil 4.17	Gürültü giderme adımının sırasıyla öncesine ve sonrasına ait kırılmış görseller.	44
Şekil 4.18	Siyah bölgelerin kırılması ve kare elde edilmesi.	45
Şekil 4.19	Görüntünün 576 x 576'lık pencerelere kırılması.	46
Şekil 4.20	Gürültüsü giderilmiş görüntünün 1152x1152'lik pencerelere kırılması.	47
Şekil 4.21	a) Kırmızı alan merkezi, turuncu alan kenarı temsil etmektedir. b) Merkez lezyonuna (sarı alan) örnek. c) Kenar lezyonuna (sarı alan) örnek.	48
Şekil 4.22	Lezyon koleksiyonunda bulunan çeşitli eksudatlar ve maskeleri.	49
Şekil 4.23	Poisson Harmanlama Yöntemi [15].	50
Şekil 4.24	PBDA yöntemi ile bir fotoğrafın üzerinden üretilen yeni görüntüler. Farklı bölgelere farklı eksudatların (sarı dokular) yapılandırıldığı görülmektedir.	53
Şekil 5.1	Veri kümelerinin oluşturulmasına dair blok diyagram	57
Şekil 5.2	Model eğitiminin farklı aşamalarına dair blok diyagram.....	58
Şekil 5.3	Kırılmamış bir retina görüntüsü.	60
Şekil 5.4	1152x1152'lik alanlara kırılmış bir retina görüntüsü.....	61
Şekil 5.5	1152x1152'lik alanlara kırılmış bir retina görüntüsü üzerinde yapılan tahminler.	62

Şekil 5.6	1152x1152'lik alanlara kırılmış bir retina görüntüsü üzerinde yapılan tahminlerin renklendirilmiş hali. Yeşil renkler doğru pozitif, kırmızı renkler yanlış negatif, mavi renkler ise yanlış pozitif ifade etmek için kullanılmıştır.	63
Şekil 5.7	288x288lik alanlara kırılmış bir retina görüntüsü. Sadece orta bölge bulunan görüntüler verilmiştir.	64
Şekil 5.8	288x288'lik alanlara kırılmış bir retina görüntüsü üzerinde yapılan tahminler.	65
Şekil 5.9	288x28'lik alanlara kırılmış bir retina görüntüsü üzerinde yapılan tahminlerin renklendirilmiş hali. Yeşil renkler doğru pozitif, kırmızı renkler yanlış negatif, mavi renkler ise yanlış pozitif ifade etmek için kullanılmıştır.	66
Şekil 5.10	Örtüşme olmaksızın kırılan görüntülerin eğitilen modellerde neden olduğu problemi gösteren görsel	68
Şekil 5.11	(a) Orijinal görüntüden bir kesit (b) Orjinal görüntüyle eğitilmiş modelin çıktısı (c) Aynı kesitin ön işlenmiş görüntüsü (d) İlgili modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir.	69
Şekil 5.12	(a) Ön işlenmiş görüntüden bir kesit (b) Ön işlenmiş görüntüyle eğitilmiş modelin çıktısı (c) Aynı kesitin gürültüsü giderilmiş görüntüsü (d) İlgili modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir.	71
Şekil 5.13	(a) Gürültüsü giderilmiş görüntüden bir kesit (b) PBDA yöntemi öncesi eğitilmiş modelin çıktısı (c) Gürültüsü giderilmiş görüntüden alınan aynı kesit (d) PBDA yöntemi sonrası eğitilmiş modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir.	73

- Şekil 5.14 (a) Gürültüsü giderilmiş görüntüden bir kesit (b) Sağlıklı verilerin öncesi eğitilmiş modelin çıktısı (c) Gürültüsü giderilmiş görüntüden alınan aynı kesit (d) Sağlıklı verilerin eklenmesi sonrası eğitilmiş modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir. 75
- Şekil 5.15 (a) Orijinal görüntüden bir kesit (b) Örtüşmeli kırpma öncesi eğitilmiş modelin çıktısı (c) Orijinal görüntüden alınan aynı kesit (d) Örtüşmeli kırpma sonrası eğitilmiş modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir. 77
- Şekil 5.16 (a) Orijinal görüntüden bir kesit (b) Orijinal görüntüyle eğitilmiş modelin çıktısı (c) Aynı kesitin ön işlenmiş görüntüsü (d) İlgili modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir. 79
- Şekil 5.17 Toplu sonuçlara ait görseller. Her bir satır farklı bir retina görüntüsüne ait lezyon çıktılarını göstermektedir. 88

SİMGELER VE KISALTMALAR

CNN	: Evrişimsel Sinir Ağı
RCNN	: Bölgeye Dayalı Evrişimsel Sinir Ağı
MA	: Mikroanevrizma
HE	: Hemoraji
EX	: Sert Eksudat
SE	: Yumuşak Eksudat
PBDA	: Poisson Blending Data Augmentation
DR	: Diyabetik Retinopati
PDR	: Proliferatif Diyabetik Retinopati
NPDR	: Non-Proliferatif Diyabetik Retinopati
TP	: Doğru pozitif
FP	: Yanlış pozitif
TN	: Doğru negatif
FN	: Yanlış negatif
TPR	: Hassasiyet oranı
FPR	: Yanlış alarm oranı
PR	: Kesinlik (Precision) Duyarlılık (Recall)
AUC_PR	: Kesinlik (Precision) Duyarlılık (Recall) Grafiğinin Altında Kalan Alan
ROC	: Alıcı İşletim Karakteristiği
AUROC	: Alıcı İşletim Karakteristiği (ROC) Grafiğinin Altında Kalan Alan
IoU	: Birleşim Üzerinden Kesişim
NaN	: Not a Number

1. GİRİŞ

Sanayi devrimine benzer bir şekilde dünyadaki iş kollarının hızla deęiştii bir döneme girmektedir. Fiziksel işleri makinelere devredip bilişsel işlere yöneldiğimiz bir dönemi geçirdik. Ve sonunda son yıllarda yapay zeka alanında yaşanan atılımlar bilişsel işleri de makinelere devredebileceğimiz bir dönemi mümkün kılmaktadır. Dolayısıyla bu yeni fırsat, yani bilişsel işlerin otomatize edilmesi, çoęu sektörün faydalanmaya çalıştığı bir konu olmuştur. Derin öğrenme algoritmalarının en büyük ihtiyacı olan yüksek ve kaliteli veriye ise talep artmaktadır. Sağlık sektörü özelinde ise bu veriler hem nadir hem de işaretleme pahalı verilerdir. Var olan veri kümelerinin verimli kullanılabilmesi medikal alanda daha yüksek bir önem arz etmektedir. Bu çalışmanın doğuşuna sebep olan etmenlerin en başında var olan verilerin en efektif şekilde kullanılması hedefi gelmektedir.

Medikal veri kümeleri üzerinde zaman zaman yarışmalar düzenlenmiş veya algoritmaların test edilebileceği açık veri kümeleri yayınlanmıştır. Bu sayede geliştirilen algoritmaların, tekniklerin birbiri ile karşılaştırılması daha olanaklı hale gelmiştir. Bu çalışmada da böyle bir veri kümesi kullanılmış, çeşitli teknikler denenmiş ve literatürdeki diğer çalışmalarla karşılaştırma yapılmıştır.

Bu çalışmada spesifik olarak diyabetik retinopati olarak adlandırılan bir hastalığa ait lezyonların bölütlemesi üzerine yöntemler geliştirilmiştir. Bilindiği gibi diyabet günümüzün yaygın hastalıklarındandır. Diyabetik retinopati ise buna baęlı bir komplikasyondur. Özellikle son yıllarda diyabetik retinopatinin otomatik taranması üzerine çeşitli sistemler geliştirilmeye başlanmıştır. Donanım teknolojisinde ve yapay zeka alanında yapılan atılımlar bu hastalığın yakın zamanda yaygın biçimde, ucuza ve herkes tarafından erişilebilir bir biçimde taranmasının önünü açmıştır. Geleneksel tespit yöntemlerinin yerini alması için bu sistemlerin sahip olması gereken bazı önemli kıstaslar vardır. Bunlar yalnızca performansa dair deęil aynı zamanda karar destek mekanizmalarının açıklanabilir olmasına da dair kıstaslardır. Siyah kutu bir sınıflandırma modelinin doktorlar tarafından benimsenerek

kullanılması bir bölütleme modeline göre daha zordur. Bu nedenle bu çalışmanın sektörün ihtiyacına uygun bir noktada konumlandığı söylenebilir.

1.1. Tezin Kapsamı

Bu tezin amacı diyabetik retinopati hastalığının bulgularından olan lezyonların bölütlenmesidir. Bu hedefle çeşitli teknikler geliştirilmiş ve test edilmiştir. Veri kümesi olarak bir yarışmayla ortaya çıkmış olan ve diyabetik retinopatinin bulgularından olan dört farklı lezyonun işaretlendiği bir küme kullanılmıştır. Bu lezyonlar sırasıyla mikroanevrizmalar, eksudatlar, hemorajiler ve yumuşak eksudatlardır. Bu lezyonların bölütlenmesi için yapay sinir ağları derin öğrenme yöntemiyle eğitilmiştir. Bu amaçla çeşitli yöntemler geliştirilmiş ve çeşitli parametreler, yöntemler ve bunların kombinasyonları test edilerek literatürdeki çalışmalar arasında ikinci yüksek sıralamadaki performans seviyesi elde edilmiştir. Diyabetik retinopatinin erken evrede tespiti için en kritik lezyon olan mikroanevrizmalarda ise literatürdeki en başarılı sonuç elde edilmiştir.

1.2. Katkılar

Bu çalışmada veri kümesinin sınırlı sayıda görüntüden ve lezyondan oluşmasının yol açtığı sorunların üzerine gidilmiştir. Bu amaçla aşağıdaki veri kümesi odaklı yöntemler geliştirilmiştir:

- Retina lezyonlarının belirgin olmasını sağlayan ön işleme yöntemi
- Sağlıklı görüntülere lezyon eklenmesiyle veri artırımı yöntemi
- Üç aşamalı aktarmalı öğretim yöntemi

1.3. Tezin Akışı

2. Bölüm'de, diyabetik retinopati ve ona ait bulgulara ve daha sonra hastalığın evrelerine dair bilgiler verilmiştir. Yine 2. Bölüm'de bölütleme problemlerinde kullanılan bazı modeller ve

metrikler verilmiştir. 3. Bölüm’de literatürde bulunan veri kümeleri sunulmuş ve ardından bu alanda yapılan çalışmaların başlıcaları özetlenmiştir. 4. Bölüm’de ise öne sürülen yöntem ve aşamaları anlatılmıştır. Sırasıyla ön işleme, gürültü giderme, kırpma, kayan pencereler, PBDA, sağlıklı veri ekleme, veri artırımı, model seçimi ve eğitim yöntemi açıklanmıştır. 5. Bölüm’de bu aşamaların hepsine ait sonuçlar sunulmuş ve karşılaştırmaları yapılmıştır. Son olarak 6. Bölüm’de elde edilen sonuçlar değerlendirilmiştir.

2. PROBLEM TANIMI

2.1. Diyabetik Retinopati

Diyabetik retinopati (DR), gözde meydana gelen ve diyabet kaynaklı bir tıbbi soruna verilen isimdir. Retina tabakasında meydana gelen dokusal hasarların sonucunda körlüğe yol açan bir hastalık olarak bilinmektedir. Diyabet dünyada 400 milyondan fazla insanı etkilemekte olup, diyabetik retinopati ise bu hastaların hepsinin karşı karşıya olduğu bir risktir [16]. Yetişkinler arasında geri döndürülemez körlüğün birinci sebebi diyabetik retinopatidir. Dahası, 1990 ve 2010 yılları arasında gerçekleştirilen çalışmalara göre körlüğün %27 oranında arttığı görülmektedir [17]. Değişen beslenme alışkanlıkları nedeniyle bu sayıların daha da artacağı öngörülmektedir.

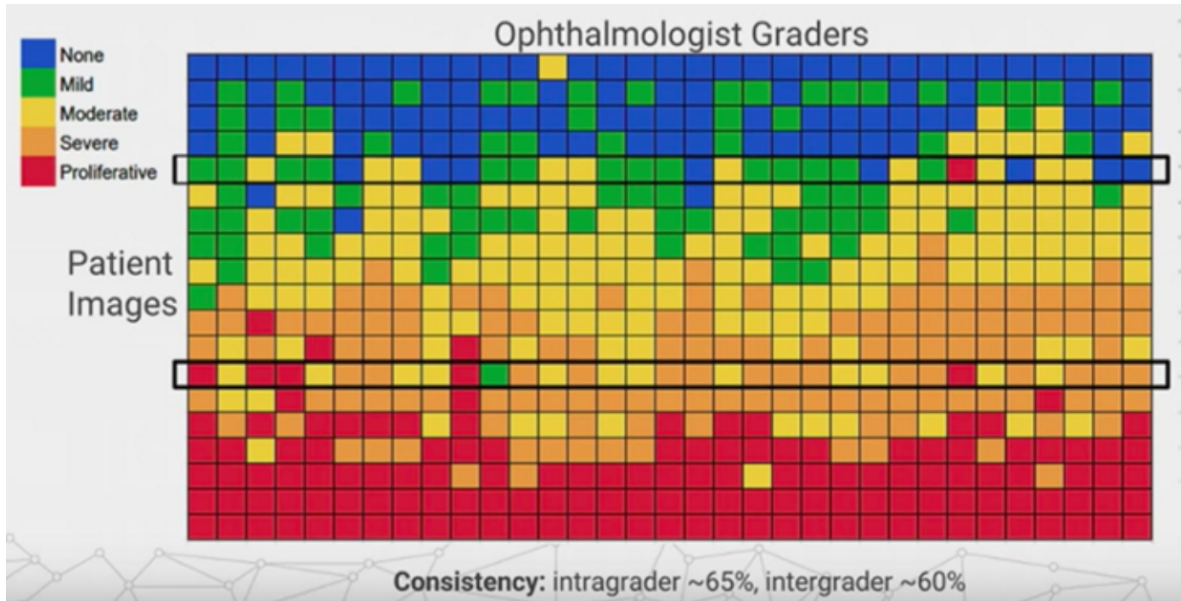
Diyabet, metabolizma tarafından kan şekerinin yeterince düzenlenememesi nedeniyle sağlık sorunlarına yol açar. Bu nedenle çeşitli organlar zarar görürken gözde de özellikle retina tabakasında bir dizi doku sorunu baş gösterir. Hastalığın seyriyle doğru orantılı olarak lezyonların sayısı, çeşidi ve büyüklüğü artar. Diyabetik retinopatinin teşhisi de bu dokuların gözlemlenmesi yoluyla yapılmaktadır. Farklı evreleri olan hastalığın başlangıç evrelerinde tedaviye alınması hasta için büyük avantaj oluştururken sağlık sistemine maliyeti de daha düşüktür. Hastalığın geç evrelerinde görme, geri döndürülemez hasarlar alır ve nihayetinde tam körlük gerçekleşir. Tüm bu nedenlerle, erken teşhisin önemi yüksektir.

Hastalığın seyri sırasında meydana gelen deęişimler ve doku türleri, doktorların hastalığın aşamasını takip etmekte kullandıkları en önemli bulgulardır. Aşağıdaki alt başlıklarda sınıflandırma işleminin temelini oluşturan dokular listelenmiştir.

Diyabetik retinopatinin teşhisinde fundus görüntüleme tekniklerinden faydalanılır. Her ne kadar floresan anjiyografi cihazlarından da yardım alınsa da bu cihazlar hastaya daha fazla invazif işlem yapılmasını gerektirir. Floresan anjiyografi yönteminde damarların içerisine belirli bir dalga boyundaki ışık altında geri ışımaya yapan özel kimyasallar zerk edilir. Daha sonra görüntüleme cihazı kimyasalın etkisi tükenmeden küçük bir zaman aralığında fotoğrafları kaydeder. Kanın retinadaki dolaşımını görmek, retinadaki damar tıkanıklıklarını ve kanamaları yakalamak için etkili olsa da kullanımına dair zorluk çıkaran nedenler bu yöntemi bir halk sağlığı tarama programında olmaktan alıkoyar. Literatürde FFA yöntemiyle elde edilen görüntülerden elde edilmiş veri kümeleri olsa da bunlar bu çalışmanın kapsamı dışında tutulmuştur. Bunun yerine diyabetin yaygınlığının gerektirdiği gibi geniş kullanım alanı olan ve daha pratik bir yöntem olan fundus görüntüleme cihazları kullanılır. Bu cihazların işlevi retinanın fotoğrafını çekmektir. Retina dışarıdan görebildiğimiz bir yapı değildir. Özel optik sistemlerle görüntülenebilen retinanın bir de dışarıdan aydınlatılması gerekmektedir. Görüntü almak ve içeriği aydınlatmak için göz bebeği açıklığının sağladığı 3 - 4 milimetrelik çapta bir optik yol vardır. Bu açıklık bir göz damlası yardımıyla hastanın iris kaslarının uyuşturulması suretiyle büyütülebilmektedir. 8 milimetreye kadar büyütülebilen bu optik açıklık literatürdeki veri kümelerinin kalitesinde en büyük farkı yaratan etmendir. Veri kümeleri ikiye ayrılacak olursa midriyatik olmayan görüntüleme ve midriyatik görüntüleme olarak ayrılabilirler. Burada ya görüntü kalitesinden ya da görüntüleme süresi ve hasta konforundan ödün verilmektedir. Neyse ki donanım alanında son yıllarda yaşanan gelişmelerle aydınlatma tekniklerinin deęişmesine baęlı olarak bu ikilem yıkılmak üzeredir. Bu noktada ilerleyen yıllarda kaliteli görüntüler hızlı ve yaygın bir şekilde elde edilebileceklerdir. Etkin bir halk sağlığı tarama sisteminin mümkün olabilmesi için geriye doktorlara binen iş yükünün azaltılması ve taramanın standardize edilmesi kalmaktadır.

Doktorlara binen iş yükünün azaltılması ve taramanın standardize edilebilmesi için


literatürde gerek yapay zeka tabanlı gerek görüntü işleme tabanlı çeşitli yöntemler denenmiştir. Bunların amacı doktorlar için karar destek mekanizması oluşturmak veya doğrudan karar verici olmaktır. Doktorların yaptığı işi bir raddeye kadar otomatize etmek her iki grubun da hedefidir. Bir doktorun elde edilen fundus görüntüsünü aldıktan sonra yaptığı iş belirli olguların varlığını yakalamak ve bunlara dayanarak hastalığın seviyesini tespit etmektir. Eğer herhangi bir hastalıklı lezyon gözlenmezse hasta bir yıl sonra tekrar taramak üzere bırakılır. Aksi takdirde hastalığın seviyesine göre tedavi planları uygulanır. Tedavinin erken aşamada uygulanması sağlık sistemine olan maliyeti ve hastaya olan zararı en aza indirir. Buna rağmen bu tespitler gerek iş yükünün çokluğu gerek diğer etmenler nedeniyle tutarlı yapılamamaktadır. Şekil 2.1’de farklı sütunlar farklı doktorları, farklı satırlar farklı hastaları temsil etmektedir. Kutucukların rengi ise o sütuna ait doktorun o satıra ait hastaya verdiği derecelendirmeyi temsil etmektedir. Mavi tamamen sağlıklı anlamına gelirken kırmızıya gittikçe hastalığın ileri dereceleri ifade edilmektedir. Şekilden doktorların birbirleri arasındaki tutarlılığın mükemmel olmadığı görülmektedir. Hatta aynı hastaya bir doktorun en ileri derecede hasta diğerininse tamamen sağlıklı dediği görülmektedir.



Şekil 2.1 Uzman görüşleri arasındaki tutarlılığı gösteren şekil [1].

Uzmanlar arası tutarsızlığın bir diğer sebebi de hastalık sınıflandırmada kullanılan kıstasların yeterince spesifik olmamasıdır. Farklı evrelerin nasıl sınıflandırıldığına dair kıstaslar Şekil

2.2’de verilmiştir.



Şekil 2.2 Diyabetik retinopatinin evrelerinin sınıflandırılması için kullanılan kıstaslar [2].


Sağlıklı bir retina görüntüsünde optik disk, makula ve damarlar görünür. Şekil 2.3’te böyle bir retinaya ait fundus görüntüsü sunulmuştur.



Şekil 2.3 Sağlıklı bir retinaya ait fundus görüntüsü [3].

2.1.1. Mikroanevrizmalar

Mikroanevrizmalar hastalığın ilk ortaya çıkan belirtileridir. Küçük, yuvarlak, koyu kırmızı noktalar olarak görünmektedirler. Boyutları 125 mikrometreye kadar erişebilir [18], bu da en kalın damardan daha ince oldukları anlamına gelmektedir. Görsel olarak kanamalarla karıştırılması mümkün olan keseciklerdir. Şekil 2.4'te örnek bir mikroanevrizma görüntüsü sunulmuştur.



Şekil 2.4 Mikroanevrizma içeren örnek bir retina görüntüsü. (a) Orjinal fundus görüntüsü ve beyaz dikdörtgenle işaretlenmiş mikroanevrizma. (b) Dikdörtgen içerisindeki mikroanevrizmanın büyütülmüş görüntüsü [4].

2.1.2. Hemorajiler

Hemorajiler, mikroanevrizmaların veya kan damarlarının duvarlarının yırtılmasıyla meydana gelen kanama sebepli belirtilerdir. Genellikle boyut olarak mikroanevrizmalardan büyük olup, şekil olarak da çeşitlilik göstermektedirler. Mikroanevrizmaların aksine keskin sınırları veya renkleri olmayabilir. Mikroanevrizmalar kesecik halinde bulduklarından özel bir yansımaya da sebep olabilirken hemorajilerde bu görünmez [18]. Şekil 2.5'te örnek bir hemoraji görüntüsü verilmiştir. Kırmızı yuvarlak, noktalı kanamalar veya alev formunda kanamalar gibi çeşitlere sahiptir.



Şekil 2.5 Örnek bir hemoraji görüntüsü [5].


2.1.3. Eksudatlar

Retinal hastalıklar bağlamında, eksudat, retinanın kan damarlarından sızan sıvılar, proteinler ve diğer maddelerin çevre dokulara sızması demektir. Genellikle retina içinde sarı veya beyaz birikintiler olarak gözlenirler ve retinal patolojiyi gösteren önemli bir klinik belirtidir. Retinal hastalıklar bağlamında çeşitli eksudat türleri bulunmaktadır:

Sert Eksudatlar: Retinal hastalıklarda görülen eksudatların en yaygın türüdür ve genellikle küçük, sarımsı-beyaz birikintiler olarak ortaya çıkarlar. Sert eksudatlar, zarar görmüş kan damarlarından sızan lipitler (yağlar) ve proteinlerin birikmesi sonucu oluşur. Şekil 2.6'da örnekleri sunulmuştur.

Pamukçuk Lekeleri: Yumuşak eksudatlar olarak da adlandırılmaktadırlar. Pamukçuk lekeleri, retinada bulutumsu, tüylü (görünüş olarak), beyaz veya gri lezyonlar olarak görülür. Bunlar, retinal atar damarlarda tıkanma vb. durumlar sonucunda sinir lif tabakası

infarktüsüne neden olan durumlar sonucunda oluşur. Pamukçuk lekeleri genellikle diyabetik retinopati ve hipertansif retinopati gibi durumlarda bulunurlar. Şekil 2.6'da diğer lezyonlarla birlikte örneği verilmiştir.



Şekil 2.6 Sert eksudat, yumuşak eksudat ve diğer lezyonları gösteren bir görüntü [6].

2.1.4. Damarlar

Diyabetik retinopatide, yüksek kan şekeri seviyelerine sürekli maruz kalma, retinanın iskemi (oksijen eksikliği) geliştirmesine neden olabilir. Bu durumda vücut, yeni kan damarlarının büyümesini teşvik etmeye çalışır, ancak bu yeni damarlar genellikle kırılındır ve göz içinde kanamalara yol açabilir, bu da görme sorunlarına neden olur [19]. Bu nedenle göz hastalıklarında neovaskülarizasyonun kontrolü ve tedavisi, bu tür hastalıkların ilerlemesini durdurmak ve görme kaybını önlemek için önemlidir.

2.1.5. Diyabetik Retinopatinin Aşamaları

Diyabetik retinopati iki ana seviyeye ayrılır; bunlar proliferatif ve non-proliferatif olarak tanımlanır. Non-proliferatif ise kendi içinde 3 seviyeye ayrılmaktadır. Dolayısıyla hastalığın derecelerini toplam 4 aşamayla ifade etmek mümkündür. Bunlar sırasıyla aşağıda verilmiştir.

Hafif Non-Proliferatif Diyabetik Retinopati (Hafif NPDR): Bu başlangıç aşamasında, retinanın damarlarında hafif hasarlar ve şişlikler bulunur. Mikroskobik düzeyde kan damarları genişlemiş ve mikroanevrizmalar meydana gelmiştir. Hastalar genellikle belirgin görme sorunları yaşamazlar. Ancak, bu aşamada tedavi gerekmebilir. Göz doktorları, hastanın durumunu yakından takip eder ve diyabet kontrolünün iyileştirilmesini önerir.

Orta Dereceli Non-Proliferatif Diyabetik Retinopati (Orta Dereceli NPDR): Bu aşamada, damar hasarı daha belirgindir. Mikroanevrizmaların yanı sıra damarlar daha fazla daralabilir ve retina yüzeyinde döküntüler (eksudatlar) görülebilir. Gözde kan sızıntıları ve şişmeleri daha sık görülür. Görme bulanıklığı, renk değişiklikleri veya parlamalar gibi semptomlar daha yaygın hale gelir. Tedavi, göz doktorunun izlemesi ve diyabet kontrolünün sağlanmasının yanı sıra lazer fotokoagülasyon gibi prosedürleri içerebilir.

Ağır Non-Proliferatif Diyabetik Retinopati (Ağır NPDR): Ağır NPDR'de damar hasarı ciddi boyutlara ulaşır. Retina damarlarının daha fazla daralması ve sızıntılarının artması, gözün beslenmesini ciddi şekilde engeller. Bu aşamada, gözdeki kanamalar ve retina yüzeyinde sarı lekeler (sert eksudatlar) daha belirgindir. Görme sorunları hızla ilerleyebilir ve tedavi edilmezse kalıcı olabilir. Tedavi, lazer tedavisi veya ilaç enjeksiyonları gibi girişimsel yöntemleri içerebilir.

Proliferatif Diyabetik Retinopati (PDR): PDR, diyabetik retinopatinin en ciddi aşamasıdır. Bu aşamada, retina damarları ciddi şekilde zarar görmüş ve anormal yeni damarlar (neovaskülarizasyon) oluşmuştur. Bu damarlar retina yüzeyinden uzanır ve normalden daha zayıf ve sızıntıya yatkındır. PDR, acil tıbbi müdahale gerektirebilecek ciddi komplikasyonlara yol açabilir. Göz içi kanamalar, retinanın yırtılması ve göz tansiyonunun yükselmesi gibi sorunlar görülebilir. Tedavi genellikle lazer fotokoagülasyon veya ilaç enjeksiyonları gibi cerrahi veya medikal prosedürler içerir. Yukarıda tanımları verilen aşamaların sınıflandırılması için Şekil 2.2'de verilen tablo referans alınabilir.

2.2. Biyomedikal Görüntülerde Kullanılan Bölütleme Modelleri

Literatürde gerek diyabetik retinopati için gerekse diğer medikal görüntüler için sıkça kullanılan bölütleme modelleri bulunmaktadır. Geniş yelpazedeki veri kümelerinde gösterdiği performans nedeniyle bu model mimarileri yaygın olarak benimsenmiştir. Bu bölümde bu mimarilerden UNet, DeepLab, FCN, Mask R-CNN, UNet++, Attention U-Net ve ResUNet incelenmiştir.

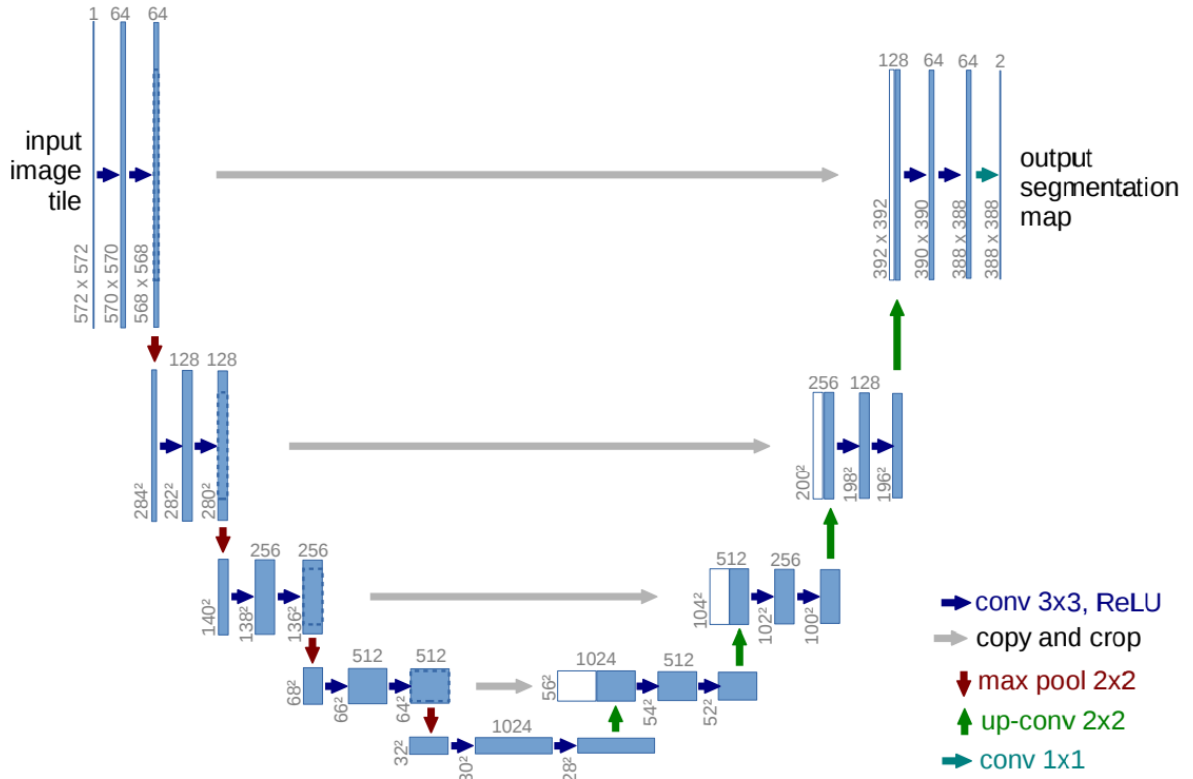
2.2.1. Unet

UNet [7] mimarisi ismini kodlayıcı çözücü yapısından oluşan şeklinden almaktadır. İlk bileşen olan çözücü yapısı ardışık evrimsel ve havuzlama katmanlarından oluşur. İlk bloktan son bloğa doğru ilerledikçe verinin eni ve boyu küçülürken kanal sayısı da artar. Böylece çözücü bloğu girdi görüntüden hiyerarşik öznitelikleri yakalamayı sağlar.

UNet mimarisinin ikinci bileşeni ise çözücü yapısıdır. Kodlayıcı gibi evrimsel katmanlardan oluşur fakat havuzlama katmanları yerine tam tersini barındırır. Çözücünün blokları arasında ileriye doğru gidildikçe verinin eni ve boyu büyür, kanal sayısı ise azalır. Kodlayıcının tersi yönde çalışarak girdi ve çıktı görüntülerinin aynı boyut olmasını sağlar.

UNet mimarisini otokodlayıcılardan ayıran önemli bir özellik ise kestirme bağlantılarıdır. Kodlayıcı ve çözücünün birbirine denk büyüklükteki katmanları arasında doğrudan bağlantılar kurulmuştur. Bu sayede ilk katmanlarda bulunan ilkel detaylı öznitelikler kaybolmayıp yüksek hiyerarşideki özniteliklere eklenmişlerdir. Bu da doğruluk oranının artmasını mümkün kılmıştır. Şekil 2.7’de UNet mimarisi görülmektedir.

Unet mimarisinin son katmanı tipik olarak aktivasyon fonksiyonu softmax olan evrimsel katmandır. Bu katman bölütleme maskesini üretmeye yaramaktadır ve bu katmandaki her piksel bir sınıfa ait olasılık değerini temsil eder.




Şekil 2.7 UNet mimarisi [7].

2.2.2. DeepLab

DeepLab [8] mimarisi birkaç farklı versiyondan oluşan bir aileyi temsil eder. Orjinal olarak Liang-Chieh Chen, George Papandreou ve diğerleri tarafından öne sürülen mimari daha sonraki yıllarda geliştirilerek DeepLabv3 ve DeepLabv3+ mimarilerine evrilmiştir.

Bu mimarinin en önemli özelliği genişmiş evrişimsel katman adı verilen yapıdır. Bu yapı sayesinde daha fazla parametre kullanılmadan algı alanı artırılmıştır. Bu da global ve lokal verinin beraber yakalanabilmesine olanak sağlamaktadır. DeepLab çoklu ölçekte öznetelik piramitlerini kullanır. Resnet ya da MobileNet omurgalarının farklı katmanlarına çeşitli oranlarda genişmiş evrişim uygulanarak farklı çoklu ölçek bilgileri yakalanır. Şekil 2.8'de genişmiş evrişimsel katman yapısı sunulmuştur.

DeepLabv3 versiyonunda ise farklı oranlardaki genişmiş evrişimlerin kombinasyonu kullanılmıştır. DeepLabv3+ sisteme kodlayıcı çözücü bloklarını da dahil ederek detayların



Şekil 2.8 Genleşmiş evrişimsel katman yapısı [8].

korunmasını sağlar.

2.2.3. FCN

FCN [20] mimarisi tamamıyla evrişimsel katmanlardan oluşan bir bölütleme mimarisidir. Son katmana kadar her blok evrişimsel olduğu için uzamsal bilgi korunmuş olur. UNet'e benzer şekilde kodlayıcı ve çözücü bileşenleri olsa da kestirme bağlantılar yoktur.

2.2.4. Mask R-CNN

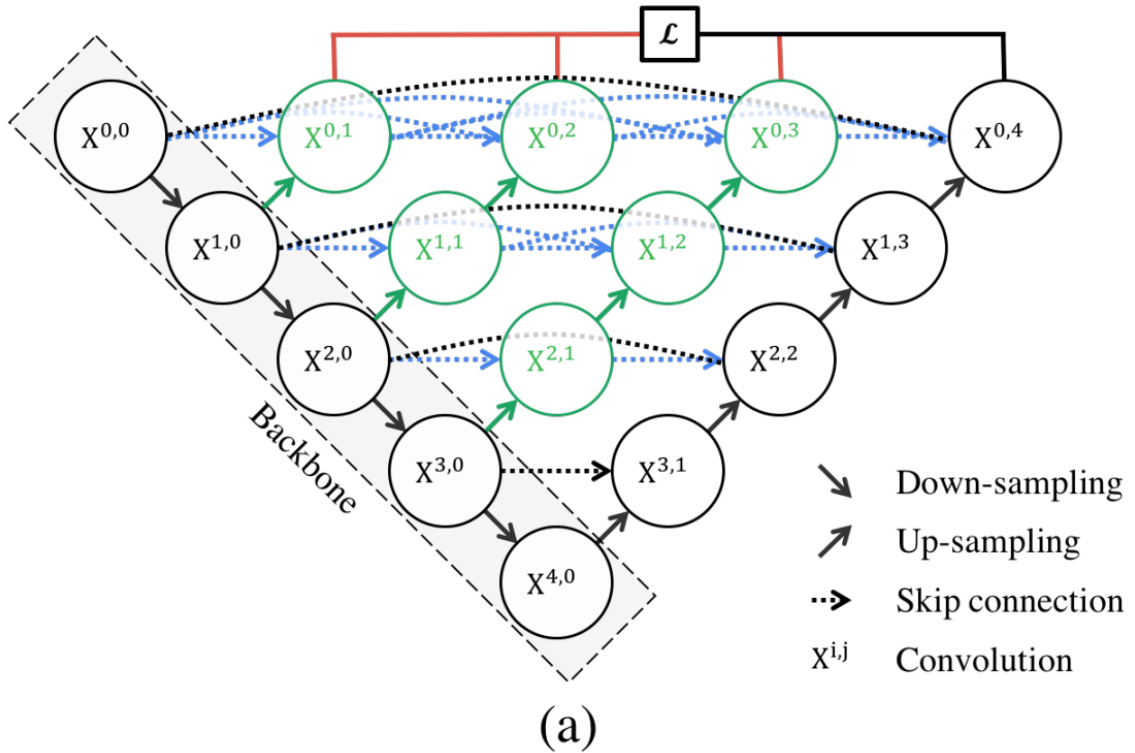
Bu mimari yalnızca obje tespiti için değil aynı zamanda piksel seviyesinde bölütleme için de kullanılmaktadır [21]. Kendinden önceki obje tespiti mimarilerinin üzerine bu objelerin bölütlemesini de amaçlayan bir çerçeve olarak sunulmuştur.

Faster R-CNN mimarisinde olduğu gibi Mask R-CNN mimarisi de omurga olarak evrişimsel sinir ağlarını kullanır. Genellikle Resnet veya ResNext gibi omurgalar girdi görüntülerinden öznitelik elde etmek için benimsenmiştir. Mask R-CNN mimarisi Faster R-CNN mimarisinde olduğu gibi bölge öneri ağı (Region Proposal Network) bulundurmaktadır. Bu

kısım potansiyel obje bölgelerine dair kutucuk önerisi ve skoru üretir. Bölge hizalama ve maskeleme yapılarını da kullanarak hassas bölütleme maskesini üretir.

2.2.5. UNet++

UNet++, UNet mimarisinde olduğu gibi kodlayıcı ve çözücü bloklarından oluşmuştur. UNet mimarisinden temel farkı yalnızca bir grup kestirme bağlantısı yerine iç içe geçmiş kestirme bağlantısı gruplarına sahip olmasıdır. Bu iç içe geçmiş bağlantıların üzerinde farklı çözünürlük seviyelerindeki özniteliklerin birbiriyle füzyonunu sağlayan katmanlar bulunmaktadır [9]. Şekil 2.9’da bu yapılar ve bağlantıları görülmektedir.



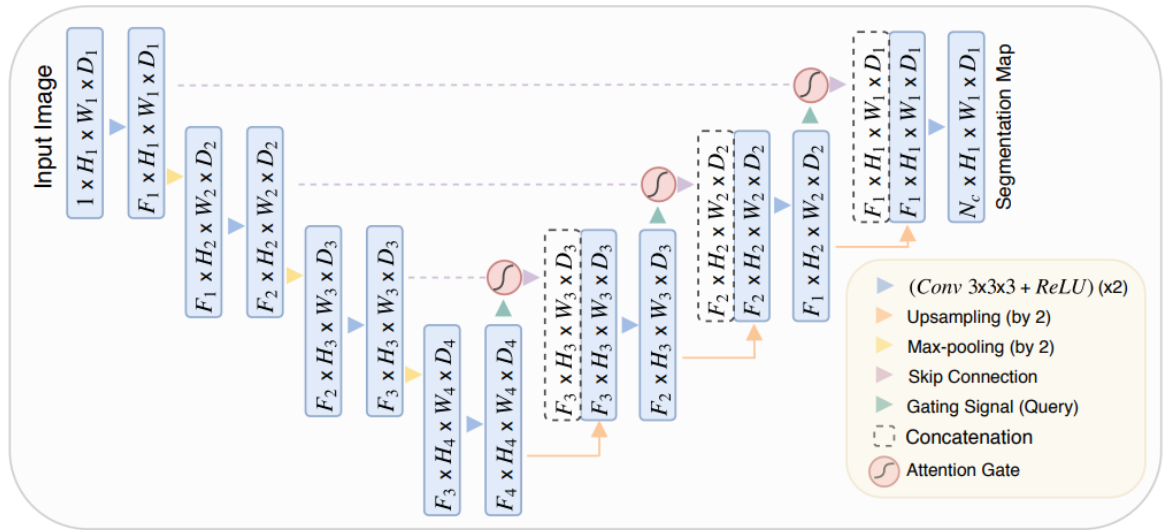
Şekil 2.9 UNet++ iç içe geçmiş ağlar yapısı [9].

UNet++ mimarisinin öne çıkan yanı farklı ölçeklerdeki özniteliklerin ilişkilerini yakalayabilmesidir. Şekil 2.9’da gösterilen \mathcal{L} bloğu kayıp fonksiyonunu ifade etmektedir. Siyahla gösterilen bloklar UNet ile ortak olan bloklardır. Şekilde UNet’ten farklı olarak kayıp fonksiyonu 4 farklı modeli eğitiyor gibidir. Bu nedenle \mathcal{L} bloğu 4 farklı çıktıyı aynı maskeye

bölütleyecek şekilde tanımlanmıştır. Çözücü blokları ise yalnızca ilgili kodlayıcı bloğundan değil $X^{i,j}$ ile ifade edilen ara bloklardan da kestirme bağlantılar almaktadır.

2.2.6. Attention U-Net

Attention U-Net [10] mimarisi U-Net mimarisinde görünen kodlayıcı-çözücü yapısına sahiptir. Önemli farkı ise sahip olduğu dikkat mekanizmasıdır. Dönüştürücü yapılarında da görülen çok kafalı dikkat mekanizması tipik olarak kullanılır. Bu mekanizmalar sayesinde görüntünün herhangi bir bölgesine odaklanmak mümkün kılınmıştır. Bu odaklama modülleri her seviyedeki kestirme bağlantılarına dahil ederek bu özniteliklerin çeşitli bölgelerinin öne çıkmasını sağlayan skorları hesaplar. Şekil 2.10'da bu yapı ve modülleri görülmektedir.



Şekil 2.10 Attention U-Net yapısı ve dikkat kapıları [10].

2.2.7. ResUNet

ResUNet [22] temelde UNet mimarisini ResNet mimarisiyle harmanlayan bir mimaridir. Tipik bir Unet modelinde olduğu gibi kodlayıcı ve çözücü bloklarından oluşmaktadır. Önemli fark ise ResNet'lerde bulunan artık (residual) bağlantı yöntemini benimsemiş olmasıdır.

2.3. Bölütleme Problemlerinde Kullanılan Metrikler

Bölütleme problemleri pikseller çapında sınıflandırma olarak ifade edildiğinde sınıflandırma için kullanılan metrikler bölütleme için de anlamlı hale gelmektedir. Bunun yanı sıra bölütlenen alanlara dair hesaplamalar devreye girdiğinde bu kez bölütlemeye özgü metrikler elde edilmektedir. Bu bölümde bölütlemeye özgü olan ve olmayan her iki türden metriklere de yer verilmiştir.

2.3.1. Piksel Doğruluğu (Pixel Accuracy)

Bu metrik, tüm piksellerin doğru bir şekilde sınıflandırılma oranını ölçer. Eşitlik 1’de verildiği gibi toplam doğru piksel sayısının toplam piksel sayısına oranı olarak hesaplanır. Genellikle dengesiz sınıf dağılımına sahip veri kümelerinde yanıltıcı olabilir. Eşitlik 1’de TP doğru pozitif sayısını, TN doğru negatif sayısını, FP yanlış pozitif sayısını ve FN yanlış negatif sayısını ifade etmektedir.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

2.3.2. Kesinlik (Precision) ve Duyarlılık (Recall)

Kesinlik, tahmin edilen pozitiflerin gerçek pozitiflere oranını temsil ederken, duyarlılık gerçek pozitiflerin tahmin edilen pozitiflere oranını temsil eder. Bu metrikler, belirli sınıf bazında performansı değerlendirmek için kullanılır. Eşitlik 2’de kesinlik için ve Eşitlik 3’te duyarlılık için formül verilmiştir.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

2.3.3. F1 Skoru

F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasını alarak bir denge puanı sağlar. Dengesiz sınıf dağılımları için kullanışlıdır. Eşitlik 4'te F1 skoru için formül verilmiştir.

$$F1 = \frac{2 * Precision * Recall}{Precision + Recall} \quad (4)$$

2.3.4. IoU (Intersection over Union)

IoU, özellikle nesne algılama ve bölütleme problemlerinde sıkça kullanılan bir metriktir. IoU, tahmin edilen sınırlayıcı kutu veya bölge ile gerçek sınırlayıcı kutu veya bölge arasındaki kesişim alanının, birleşim alanına oranını hesaplar. Yüksek IoU değerleri daha iyi bölütleme sonuçlarını temsil eder. Eşitlik 5'te bölgelerin alanları üzerinden, Eşitlik 6'da ise piksellerin sayıları üzerinden IoU formülleri verilmiştir. Eşitlik 5'te *Tahmin* bir algoritmanın pozitif olarak tahmin ettiği bölgeyi ifade ederken *Gerçek* veri kümesinde pozitif olarak işaretli olan bölgeyi ifade etmektedir.

$$IoU = \frac{Alan(Tahmin \cap Gercek)}{Alan(Tahmin \cup Gercek)} \quad (5)$$

$$IoU = \frac{TP}{TP + FP + FN} \quad (6)$$

2.3.5. Dice Katsayısı (Dice Coefficient)

Dice katsayısı, benzer bir şekilde bölütlemenin doğruluğunu ölçer. IoU gibi, gerçek ve tahmin edilen alanların benzerliğini ölçer ve 0 ile 1 arasında bir değer üretir. Daha yüksek Dice katsayısı daha iyi bir eşleşmeyi temsil eder. Eşitlik 7'de bölgelerin alanları üzerinden, Eşitlik 8'de ise piksellerin sayıları üzerinden dice katsayısı formülleri verilmiştir.

$$Dice = \frac{2 \cdot \text{Alan}(\text{Tahmin} \cap \text{Gercek})}{\text{Alan}(\text{Tahmin}) + \text{Alan}(\text{Gercek})} \quad (7)$$

$$Dice = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \quad (8)$$

2.3.6. Alıcı İşletim Karakteristiği (ROC) Grafiğinin Altında Kalan Alan

AUROC, Alıcı İşletim Karakteristiği (Receiver Operating Characteristic) (ROC) eğrisinin altındaki alanı ifade eder. ROC eğrisi, bir sınıflandırma modelinin hassasiyet (true positive rate - TPR) ile yanlış alarm oranı (false positive rate - FPR) arasındaki ilişkiyi gösterir. TPR, gerçek pozitiflerin toplam pozitifler içindeki oranını, FPR ise gerçek negatiflerin toplam negatifler içindeki oranını temsil eder. AUROC, modelin farklı kesim noktalarına göre hassasiyet ve özgüllük arasındaki performans değişikliklerini ölçer. Genellikle, 0 ile 1 arasında bir değere sahiptir; 1 mükemmel bir sınıflandırma performansını temsil ederken 0.5 rastgele bir sınıflandırmayı temsil eder.

2.3.7. Kesinlik (Precision) Duyarlılık (Recall) Grafiğinin Altında Kalan Alan

AUPRC, Kesinlik-Duyarlılık (Precision-Recall) (PR) eğrisinin altındaki alanı ifade eder. PR eğrisi, kesinlik (precision) ile duyarlılık (recall) arasındaki ilişkiyi gösterir. Kesinlik, tahmin edilen pozitiflerin gerçek pozitiflere oranını, duyarlılık ise gerçek pozitiflerin toplam pozitifler içindeki oranını temsil eder. AUPRC, modelin farklı kesim noktalarına göre kesinlik ve duyarlılık arasındaki performans değişikliklerini ölçer. Genellikle, 0 ile 1 arasında bir değere sahiptir; 1 mükemmel bir sınıflandırma performansını temsil ederken, 0 rastgele bir sınıflandırmayı temsil eder.

3. LİTERATÜRDEKİ VERİ KÜMELERİ VE ÇALIŞMALAR

3.1. Veri Kümeleri

Literatürde DR sınıflandırılması için birden fazla veri kümesi kullanılmıştır. DR 4 farklı aşamaya ayrıldığı için sağlıklı durumu da dahil edince toplam 5 sınıflı bir veri kümesi yapısı kullanılmaktadır. Bazı durumlarda ise 2 sınıflı bir yapıya indirgenerek oluşturulan veri kümeleri kullanılmıştır. Literatürde çalışılan bir diğer veri kümesi çeşidi ise bölütleme veri kümeleridir. Son olarak da lezyonların lokalizasyonu üzerine hazırlanmış veri kümeleri literatürde çalışılmıştır.

3.1.1. Sınıflandırma Veri Kümeleri

MESSIDOR, DR hastalığının sınıflandırılması için hazırlanmış araştırma amaçlı bir veri kümesidir. 2004 yılından beri oldukça fazla makalede kullanılmıştır. Genelden farklı olarak, 5 sınıflı standart sınıflandırma yerine 4 sınıflı bir yapıya sahiptir. Üç farklı kamera kullanılarak çekilen 1200 retina fotoğrafından oluşmaktadır. Ortalamaya göre düşük orta çözünürlüklü fotoğraflardan oluşmaktadır.

MESSIDOR 2, bir öncekinin devamı olarak hazırlanmış olup ortak fotoğraflar içermektedir. Veri kümesine ait ikili sınıflandırma etiketleri ulaşım ve araştırma amaçlı kullanıma açıktır. Toplam 1748 fotoğraftan oluşmaktadır.

EYEPACS, 2015 yılında Kaggle üzerinden yapılan bir yarışmada kullanılan, dolayısıyla oldukça yaygın referans verilen bir veri kümesidir. 10 binlerce hasta üzerinden elde edilen 88,702 retina fotoğrafından oluşmaktadır. Bunların 35,126'sı eğitim kümesinde ve kalan 53,576'sı test kümesinde olup, standart 5 sınıflı bir etiketlemeye sahiptir. Sınıflar arası veri dağılımında büyük dengesizlik vardır. Fakat en fazla veri sayısına ve en fazla çeşitte kamera tipine sahip olan veri kümesi yine EYEPACS'tır.

IDRiD (grading), standart 5 sınıflı etiketlemeye sahiptir. IDRiD veri kümesinin üç ana parçasından biridir. Bu veri kümesi oldukça yüksek çözünürlüklü ve kaliteli 413 eğitim, 103 test verisi bulundurmaktadır.

DDR, görece yeni bir veri kümesi olup, 2016-2018 yılları arasında Çin'deki çeşitli hastanelerden toplanan 9,598 hastanın 13,673 fundus görüntüsünü içermektedir. DDR fundus görüntüleri çeşitli kamera tipleri kullanılarak elde edilmiş, ancak tutarlı bir teknik kullanılmıştır. Veri kümesi normal (6,266 veri), hafif NPDR (630 veri), orta dereceli NPDR (4,477 veri), şiddetli NPDR (236 veri), PDR (913 veri) ve sınıflandırılmayan, kalitesi düşük olan görüntüler (1,151 veri) olmak üzere altı kategoriye ayrılmıştır. DDR veri kümesinde önemli bir sınıf dengesizliği olduğuna dikkat edilmelidir.

APTOS 2019 veri kümesi ise 3,662 fotoğraftan oluşup yine Kaggle üzerindeki bir yarışmada kullanılmıştır. Standart 5 sınıflı etiketlemeye sahip veri kümesi EYEPACS ile birlikte en yaygın kullanılan veri kümesidir. Diğerinin aksine, sınıf dağılımı dengelidir.

ODIR, bir retina veri kümesi olup birden fazla hastalığın sınıflandırılması için toplanmıştır. DR için olan etiketleri ise ikili olarak verilmiştir. 7,000 fotoğraftan oluşan bu veri kümesi düşük kalitede ve çözünürlüktedir.

RFMID, bir önceki veri kümesiyle benzer şekilde birden fazla retina hastalığı için hazırlanmış bir veri kümesidir. Benzer şekilde ikili sınıflandırma veri kümesi olup, diğerinin aksine yüksek çözünürlükte ve kaliteli fotoğraflardan oluşmaktadır.

FGADR grading ise yine standart 5 sınıflı etiketlemeye sahip olan 1,000 fotoğraftan oluşan yüksek çözünürlüklü bir veri kümesidir. Kısıtlı olarak kullanılmıştır ve erişimi daha fazla mümkün değildir.

3.1.2. Bölütleme Veri Kümeleri

DRIVE, bir kan damarı bölütleme veri kümesi olup 40 adet retina fotoğrafı ve bu fotoğraflara ait bölütleme maskelerinden oluşmaktadır. Literatürde en çok kullanılan 2 damar bölütleme

veri kümesinden biri olup oldukça eskidir, dolayısıyla düşük çözünürlüklüdür.

STARE, literatürdeki diğer en fazla kullanılan damar bölütleme veri kümesidir. Bu veri kümesi 20 göz örneğinden oluşup yine düşük çözünürlüklüdür.

CHASE-DB1, bir diğer kan damarı bölütleme veri kümesi olup 28 fotoğraftan oluşmaktadır.

REVIEW, kan damarı kalınlığını ölçmek üzere tasarlanmış olup 16 iyi kalitede ve çözünürlükte fotoğraftan oluşmaktadır.

High-Resolution Fundus (HRF) Image Database ise, kan damarı bölütlemesi için hazırlanmış oldukça yüksek kaliteli ve çözünürlüklü fotoğrafların bulunduğu 45 fotoğraflık bir veri kümesidir.

DR HAGIS, oldukça yüksek çözünürlüklü bir kan damarı bölütleme veri kümesi olup 39 fotoğraf içermektedir.

IDRiD (segmentation), lezyon bölütleme için hazırlanmış olan bu veri kümesi 54 eğitim ve 27 test fotoğrafından oluşmaktadır. Bölütleme maskeleri bulunan lezyonlar ise mikroanevrizmalar, hemorajiler, yumuşak ve sert eksudatlardır. Yüksek çözünürlük ve kaliteye sahiptir.

FGADR (segmentation), 1842 fotoğraftan oluşsa da sınırlı olarak kullanılmıştır ve erişim daha fazla mümkün değildir. Yüksek kalite ve çözünürlükte fotoğraflar içerip yardımcı lezyonlarla birlikte 8 çeşit lezyonun maskelerini içermektedir.

3.1.3. Lezyon Lokalizasyon Veri Kümeleri

DIARET-DB0, 130 farklı fotoğraftan oluşmaktadır. Bunların 20 tanesi herhangi bir hastalık emaresi içermemekte olup, kalanlar ise kabaca çizilmiş poligonlarla işaretlenmiş lezyonları içermektedir. Düşük kaliteli fotoğraflara sahiptir.

DIARET-DB1, bir önceki versiyonun eksikliklerini gidermek amacıyla hazırlanmıştır. Daha iyi kaliteye sahip 89 fotoğraf içermektedir. Bunlardan 5 tanesi yine hastalık emaresi içermeyen normal retina görüntüleridir.

HEI-MED, 169 yüksek çözünürlüklü fotoğrafın bir uzman tarafından işaretlenmesiyle oluşturulmuş yüksek kaliteli görüntüler içeren bir lezyon lokalizasyon veri kümesidir.

ARIA, düşük çözünürlüklü bir veri kümesi olup 143 fotoğraftan oluşmaktadır.

ROC, mikroanevrizma ve hemorajilerin konumlarının işaretlendiği bir veri kümesi olup 50 fotoğraflık eğitim ve 50 fotoğraflık da test verisinden oluşmaktadır.

3.2. Diyabetik Retinopati Lezyonlarının Bölütlemesi

Diyabetik retinopatinin analizinde temel olarak dikkat edilen bulgular lezyonların varlığı, tipi ve sıklığıdır. Bu nedenle doğru tanı koymanın en önemli aşaması lezyonların doğru olarak tespit edilmesinden geçmektedir. Diyabetik retinopatinin sınıflandırılması için yapılan çalışmalarda bölütleme maskelerinin ara çıktı olarak kullanılması modelin veya algoritmanın açıklanabilirlik seviyesini artırmak için kullanılabilir. Bu sayede sahada kullanıma geçildiğinde doktorlar algoritmanın ne zaman güvenilir ne zaman hataya yatkın olduğunu anlayabilirler. Bir algoritmanın açıklanabilir olmasının yararları medikal alanda iyice ön plana çıkmaktadır. Bu nedenle literatürde de bölütleme üzerine geliştirilen çeşitli veri kümeleri, yarışmalar ve çalışmalar bulunmaktadır. Bunlardan bu tezin kapsamında önemli yere sahip olan başlıcaları 3.2.2. başlığında incelenmiştir. Bunun dışında ISBI-2018’de düzenlenen “Diabetic Retinopathy – Segmentation and Grading” yarışması bu çalışmanın ana veri kümesi olan IDRiD veri kümesinde gerçekleştirilmiştir. Bu yarışma kapsamında gerçekleştirilen çalışmalara ise 3.2.1. başlığında değinilmiştir. Literatürdeki çalışmaların toplu olarak karşılaştırması için 3.2.3. başlığında bir tablo sunulmuştur.

3.2.1. ISBI-2018 ”Diabetic Retinopathy – Segmentation and Grading” Çalışmaları

Bu yarışma [23] 2018 yılında IEEE International Symposium on Biomedical Imaging tarafından düzenlenmiş ve bu bölümde dereceye giren çalışmalar verilmiştir.

3.2.1.1. VRT (Jaemin Son ve ark.) Bu çalışmada U-Net mimarisinin bir türevini oluşturarak lezyon boyutlarına uygun değişikliklere gidilmiştir. Ana fikir olarak ilk katmanların ve üst boyuta şekillendirilen katmanların eşit öneme sahip olması gerektiği kullanılmıştır. Çalışmada maksimum-havuzlama katmanı sayıları her lezyona özgü olarak değiştirilmiştir. En büyük alana sahip olan lezyonun en derin katmanda 1 pikselle ifade edilebileceği kadar sayıda maksimum havuzlama operasyonu kullanılmıştır. Böylece bu derin katman lezyonun bütününe algılayabilecek kadar görü alanına sahip olmuştur. Mikroanevrizmalar için piksel karma yönteminden faydalanılmıştır.

3.2.1.2. IFLYTEK-MIG (Fengyan Wang ve ark.) Bu çalışmada U-Net tabanlı kademeli (cascade) bir CNN yöntemi geliştirildi. Bu yöntemle maskelerin bölütlenmesi için geçtikleri üç aşama tasarlanmıştır. İlk aşamada maskeler için kaba bölütleme modeli kullanılmıştır. İkinci aşamada yanlış pozitif azaltma için kademeli sınıflandırıcı kullanılmıştır. Bu aşama retinadaki ilgili bölgede lezyon olup olmadığını tespit etmeye yaramaktadır. Eğer lezyon olmadığı yönünde sınıflandırılırsa bir sonraki aşamaya geçmeden o bölgeye tamamıyla arka plan değeri atanmıştır. Böylece oluşabilecek yanlış pozitiflerin (FP) önüne geçilmiştir. Son aşama ise kademeli CNN modelinin lezyon var olarak sınıflandırmasıyla geçilen aşamadır. Bu aşamada kaba bölütleme maskesi ince bir hale getirilmiştir. Bu çok aşamalı yaklaşım, lezyon bölütlemenin doğruluğunu kademeli olarak iyileştirmeye yardımcı olmuştur.

3.2.1.3. PATech (Liu lihong ve ark.) Bu çalışmada DenseNets ve genişleme bloklarını U-Net mimarisi ile birleştiren kırılmış görüntü tabanlı bir CNN modeli öne sürülmüştür. Bu model, farklı ölçeklerdeki lezyonlara hitap ederek daha fazla bağlam bilgisi ve çok ölçekli

özellikleri yakalar. Veri kümesinde lezyon piksellerinin dağılımındaki dengesizliğe çözüm olarak zar (dice) fonksiyonu kayıp fonksiyonuna dahil edilmiştir. Yani kullanılan kayıp fonksiyon kategorik çapraz entropi ve zar (dice) fonksiyonunun bir kombinasyonudur.

3.2.1.4. SOONER (Yunzhi Wang ve ark.) Bu çalışma U-Net mimarisi kullanmış ve 380x380 piksel fundus görüntü yamasını girdi olarak almıştır. Farklı lezyon türleri için üç aşamalı bir eğitim süreci uygulanmıştır. İlk aşamadaki eğitim yalnızca lezyon var olan ve olmayan bölgeleri bölütlemek üzerinedir. İkinci aşamada ise devreye lezyonların tipleri girmektedir. Son aşamada ise modelin yanlış pozitif sayısını düşürmek hedeflenmiştir. Birinci eğitim aşamasında görülen yanlış pozitif bölgeler özellikle seçilerek model biraz daha eğitilmiştir. Böylece modelin bu duruma karşı da gürbüz olması sağlanmıştır.

3.2.1.5. LzyUNCC (Zhongyu Li ve ark.) Eksudatların ve yumuşak eksudatların bölütlemesi için FCN'ye DLA yapısı gömülerek bir yöntem geliştirilmiştir. Lezyonlar dağınık ve düzensiz olarak yerleştiğinden, DLA yapısının FCN ile birleştirilmesi, lokal ve global düzeyde semantik ve mekânsal bilgilerin daha iyi birleştirilmesini sağlayarak lezyonların tanınmasını artırmıştır. Kayıp fonksiyonunda ön plan piksellerinin ağırlıklarını kontrol etmek için farklı ceza değerleri denenmiştir. Ayrıca e-OPHTA veri kümesinden de faydalanılmıştır.

3.2.1.6. SAIHST (Yoon Ho Choi ve ark.) Bu çalışmada yalnızca eksudatlar üzerine çözüm üretilmiştir. Normal bir UNet mimarisinin evrimsel katmanlarını DenseNet mimarisinde gördüğümüz Dense blokları ile değiştirmek öne sürülmüştür. Bu yaklaşım, ayrıntılı piksel seviyesinde tahmin haritaları üretme yeteneğini geliştirmiştir. Eğitim için fundus görüntülerinin yeşil kanalı kullanılmıştır ve CLAHE ile ön işleme yapılmıştır. İkili çapraz entropi kayıp hesaplaması için kullanılmıştır.

3.2.1.7. SDNU (Xiaodan Sui ve ark.) Fundus görüntülerinden lezyonları bölütlemek için Mask R-CNN tabanlı bir yöntem önerilmiştir. Mask R-CNN, farklı nesnelere aynı

anda tespit ederken örnek bölütleme maskeleri üretebilmektedir. İkili çapraz entropi kayıp fonksiyonu olarak kullanılmıştır.

3.2.2. Diğer Çalışmalar

L-Seg: An end-to-end unified framework for multi-lesion segmentation of fundus images

Bu çalışma [24] IDRiD veri kümesi üzerinde yapılan erken çalışmalardan biridir. Çalışmanın temel yeniliği bir model mimarisi sunmaktır. Omurga olarak VGG16 kullanılan çalışmada VGG16 modelinin ilk 5 katmanının öğrendiği öznitelikleri uygun bir şekilde kombine eden bir modül kullanılmıştır. İlk 5 katmanın her biri farklı boyutlara sahiptir. İlk katmandan derine doğru gidildikçe öznitelik katmanlarının boyu ve eni daralmaktadır. Fakat bölütlenmek istenen görüntü en yüksek boyuta sahiptir, dolayısıyla çıktı da bu boyuta sahiptir. Çalışmada çözüm olarak bu farklı boyutlardaki özniteliklerin yeniden boyutlandırılarak birbirleriyle eş boyutta olması sağlanmıştır. Bu boyutlandırma işlemi yapan bloklar aynı zamanda kanal sayısını da düşürüp eşitlemektedir. Böylece 5 ana öznitelik kanalı çıktısı elde edilmiştir. Daha sonra bu 5 katmanın füzyonu ve çıktıyı üreten kanallara sahip katman eklenmiştir. Bu model en ilkel katmanları ve ileri katmanları bir arada kullanarak avantaj sağlamıştır.

Anomaly segmentation in retinal images with poisson-blending data augmentation

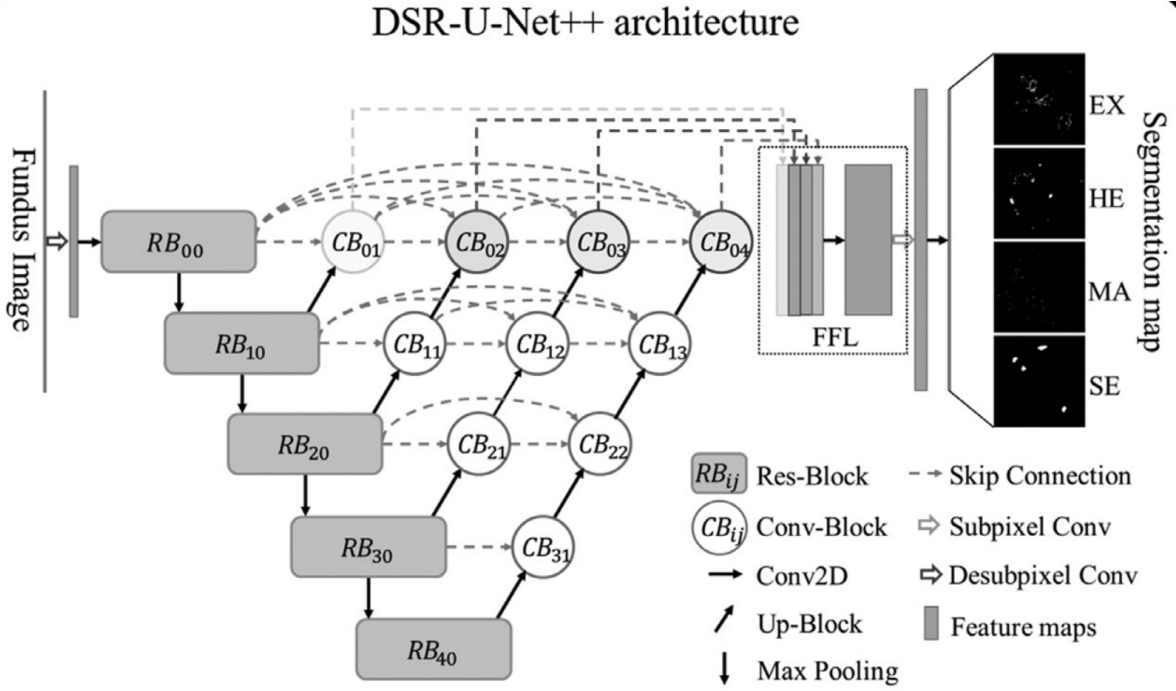
Çalışma [11] 3 ana parçadan oluşmakta olup literatürde IDRiD veri kümesinde en çok başarıyı elde eden makaledir. İlk ana parça veri kümesinin sentetik olarak büyütülmesidir. Bunu başarabilmek için var olan lezyonları görüntülerin farklı yerlerine yapıştırma yoluna gidilmiştir. Veri artırımındaki ilk adım, orijinal eğitim kümesinden bir lezyon kütüphanesi oluşturmaktır. Lezyon kütüphanesi lezyonların kırılmış görüntüleri ve bu görüntülere ait maskeleri ifade etmektedir. Lezyon kütüphanesinin oluşturulmasının ardından bu kütüphanedeki lezyonların görüntülerin farklı yerlerine yapıştırılması için hazırlıklar yapılır. Öncelikle retina üzerinde bulunan doğal dokulardan optik disk ve damarlar herhangi bir

lezyonun gözlemlenmediği alanlardır. Lezyonların yerleşim olarak doğal dağılıma yakın olması amacıyla lezyonların bu bölgelere yapılandırılmaması gözetilmiştir. Bu limitleri oluşturmak için optik disk bölütlemesi ve damar bölütlemesi yapan iki farklı model eğitilip optik disk ve damar için maskeler üretilmiştir. Lezyon dağılımı pozisyon kısıtlarına son olarak gözün dairesel alanının sınırları da dahil edilmiştir. Böylece gerçeğe daha yakın bir sentetik veri üretimi mümkün kılınmıştır. Ayrıca lezyon yapıştırma işleminin çevredeki dokulara uyumlu bir şekilde yapılabilmesi için Poisson harmanlama yöntemi kullanılmıştır. Poisson harmanlama yöntemi sayesinde kırılmış lezyon görüntüleri yapıştırıldıkları arka planla keskin sınırlar kalmayacak şekilde düzenlenir. Bu yapıştırma işlemi sırasında veri çeşitliliğini de mümkün kılmak amacıyla lezyonlar döndürülür, küçültülür büyütülür, yatay ve dikey ayna görüntüleri alınır.

Çalışmanın ikinci parçası yeni bir model mimarisinin tasarlanmasıdır. DSR-U-Net++ adı verilen mimari diyabetik retinopati lezyonlarının eş zamanlı bölütlemesi için modifiye edilmiş bir U-Net++ mimarisidir. Mimarinin değiştirilmesiyle üzerine gidilen sorunlar lezyonlar ve arka plan arasındaki sınıf dengesizliği, farklı lezyonların büyüklük çeşitliliği ve farklı lezyonlar arasındaki benzerliklerdir. Kodlayıcı - çözücü yapısını temel alan mimari Res-Block modüllerinden oluşmaktadır.

Çalışmanın son parçası ise kayıp fonksiyonunun tanımlanmasıdır. Modelin son katmanı her bir sınıf için softmax aktivasyonu çıktısı vermektedir. Kayıp fonksiyonu, zar kayıp (dice loss) ve kategorik çapraz entropi kayıp (categorical cross entropy loss) olarak literatüre geçen iki fonksiyonun kombine edilmesinden oluşmaktadır. Zar kayıp (dice loss) kullanılarak bölütleme problemlerinde sıklıkla görülen arka plan ve pozitif sınıf arasındaki dengesizlik sorununun üzerine gidilmiştir. Diğer yandan ise ağırlıklandırılmış kategorik çapraz entropi (categorical cross entropy) fonksiyonu, pozitif sınıflar arasında görülen denge sorununa yönelik ileri sunulmuştur.

Genel olarak, yöntem, retinal görüntülerdeki DR lezyonlarını bölütlemeye karşılaşılan özel zorlukları ele almak için görüntü sentezleme teknikleri ile özel bir sinir ağı mimarisini birleştirir.



Simultaneous Segmentation of Multiple Retinal Pathologies Using Fully Convolutional Deep Neural Network

Çalışma [25], tamamen evrişimli bir sinir ağı (FCN) mimarisi kullanarak eksudatlar, hemorajiler ve pamuk yünü lekeleri diye de tabir edilen yumuşak eksudatların eş zamanlı bölütlemesini kapsamaktadır. Semantik bölütleme problemi olarak ele alınan çalışma, öncelikle bir veri ön işleme yöntemi ile başlamaktadır. Ön işleme aşaması, retinanın arka planı ile anatomik yapılar arasındaki kontrastı artırmak ve parlaklığı normalize etmek amacıyla gerçekleştirilmektedir. Önce arka planın rengini hesaplamak amacıyla geniş bir aritmetik ortalama filtresi kullanılmıştır. Sonra hesaplanan arka plan görüntüsü, orijinal görüntüden çıkarılmıştır, böylece ön planda bulunan lezyonların vurgusu artmıştır. Ön işlemenin son aşaması olarak gölge düzeltme, parlaklık varyasyon azaltma ve kontrast artırma için global bir normalizasyon dönüşümü yapılmıştır.

Çalışmanın ana bölümü ise görüntülerin küçük kesitlere bölünerek öğrenme yapılmasıdır. Lezyonların boyutları retina görüntüsünün boyutlarının yanında oldukça küçük kalmaktadır.

Lezyonların ayırt edilebilmesi için görüntünün bütününe bakmaya gerek yoktur. Bu öngörü kullanılarak büyük retina görüntüleri $N \times N$ 'lik küçük parçalara kırılmıştır. Bu görüntü kesitleri birbiriyle %50 kesişecek oranda kırılmıştır. Yani kaydırma oranı $N/2$ olarak seçilmiştir. Kayan pencere tekniği kullanılarak resmin her bölgesinin modele beslenmesi sağlanmıştır.

Nöral ağ mimarisi olarak bir kodlayıcı-çözücü yapısı kullanılmıştır. Veri kümesi olarak ise MESSIDOR'dan faydalanılmıştır. Sınıflar arası dengeyi sağlamak için sınıflar ağırlıklandırılmıştır. Aşırı uyum sorununa tedbir olarak L2 düzenlemesi kullanılmıştır. Bunun dışında eğitim kümesinin %10'u doğrulama amacıyla ayrılmıştır. Kayıp fonksiyonu olarak categorical cross entropy kullanılmıştır. En iyileyici olarak ise momentumlu stokastik gradyan düşüşü (SGDM) seçilmiştir.

Learning Mutually Local-Global U-Nets for High-Resolution Retinal Lesion Segmentation in Fundus Images

Bu çalışma [26] yüksek çözünürlüklü görüntülerin semantik bölütlemesi sırasında yaşanan zorlukların üzerine gitmiştir. IDRiD veri kümesi üzerinde gerçekleştirilen çalışmada yeni bir mimari öne sürülmüş ve test edilmiştir. Yüksek çözünürlüklü fotoğraflardaki küçük ve dağınık lezyon bölgelerini bulmak iki ana çıkmaz nedeniyle zordur. Birincisi verilerin çok büyük boyutlara sahip olması pratik nedenlerden dolayı çözünürlüğün düşürülüp çalışılmasına sebep olmaktadır. İkinci alternatif ise çözünürlüğün düşürülmesi yerine görüntünün küçük parçalara kırılmasıdır. Birinci alternatif zaten küçük boyutlu olan lezyonların iyi detay kaybetmesine sebep olurken ikinci alternatif ise global bilginin kullanılmaması anlamına gelmektedir. U-Net gibi genel olarak kullanılan modellerde yapılan testlerde sorunun varlığı gözlemlenerek yeni bir mimari öne sürülmüştür. Öne sürülen yeni mimari iki farklı U-Net mimarisinin kombinasyonundan oluşmaktadır. Öncelikle bahsi geçen iki strateji de kullanılarak iki farklı U-Net modeli eğitilmiştir. Birinci U-Net modeli global görüntülerin çözünürlüğü düşürülerek eğitilmiş, GlobalNet olarak adlandırılmıştır. İkinci U-Net modeli ise resmin küçük parçaları üzerinde eğitilmiş, LocalNet olarak adlandırılmıştır. Daha sonra eğitilen iki model tek bir mimari altında bir

araya getirilmiştir. Mimarilerin birleştirilebilmesi için füzyon modülü adı verilen bir yapı kullanılmıştır. LocalNet yüksek çözünürlükte ve kırılmış bir görüntü alanında çalıştığı için GlobalNet modelinin son katmanından önceki özellik katmanı uygun bölgeden kırılıp uygun çözünürlüğe yeniden boyutlandırılmıştır. Böylece GlobalNet ve LocalNet'in özellik katmanları birbiriyle uyumlu hale getirilmiştir. Son olarak da bu katmanları birleştirip gerekli bölge için bölütleme çıktısını üreten füzyon modülü denen tam bağlantılı katman eklenmiştir.

Yeni tasarlanan mimarinin eğitimi sırasında ilk aşamada GlobalNet ve LocalNetin katmanları dondurularak yalnızca füzyon modülü eğitilmiştir. Daha sonra ise ince ayar yapılmak üzere bütün modellerin katmanları çözülüp düşük bir öğrenme hızı ile yeni mimari uçtan uca eğitilmiştir. Elde edilen yeni model mimarisi, kendisini oluşturan LocalNet ve GlobalNet modellerinden daha yüksek performans göstermiştir.

A Multi-stage Transfer Learning Framework for Diabetic Retinopathy Grading on Small Data

Bu çalışmada [27] aktarımlı öğrenme yöntemi diyabetik retinopati hastalığı için kullanılmıştır. Geleneksel aktarımlı öğrenme yöntemi yerine çok evreli bir aktarımlı öğrenme yöntemi ileri sürülmüştür. Geleneksel aktarımlı öğrenme yönteminde modeller ilk olarak büyük bir veri kümesi üzerinde ön eğitimden geçirilir. Genelde Imagenet gibi genel amaçlı veri kümeleri olsalar dahi veri sayısının çok olması modellerin bazı genel özellikleri daha iyi öğrenmesi mümkün olmaktadır. Geniş bir özellik yelpazesini öğrenen bu modeller daha sonra hedef problem olan daha küçük veri kümesinde bir kez daha ince ayarlı eğitilir.

Öne sürülen çok evreli aktarımlı öğrenme yönteminde ise geleneksel yöntemden farklı olmak üzere birkaç farklı veri kümesi ve eğitim evresi daha devreye alınmıştır. Bu veri kümeleri boyut ve genel geçerlilik olarak farklı olmaktadır. İlk veri kümesi olabildiğince yüksek sayıda veriye sahip ve genel kullanıma uygunken daha sonraki aşamalarda kullanılan veri kümeleri giderek daralan bir kullanım alanına ve aynı zamanda da giderek azalan veri sayısına sahiptir. Farklı veri kümeleri için farklı eğitim aşamaları kullanılmaktadır. İlk aşamalardaki eğitimler büyük ve genel geçer veri kümelerinde yapılarak nispeten daha genel geçer özelliklerin öğrenilmesini sağlamaktadır. Sonraki eğitim aşamaları ise daha küçük ama

spesifik veri kümelerinde yapılır. Böylece sonraki aşamalarda öğrenilen özellikler hedefe daha yönelik özellikler olmaktadır. Çok evreli aktarımlı öğrenmede farklı aşamalar için modelin farklı katmanlarının eğitilmesi yoluna gidilmiştir. İlk aşamalar ilk katmanların eğitilmesi için kullanılırken son aşamalarda ise daha derin katmanlar eğitilmiştir.

Bu yöntem büyük veri kümelerinden genel geçer özelliklerin öğrenilmesini ve aşamalı olarak daha dar veri kümelerinden ise probleme yönelik özelliklerin öğrenilmesini mümkün kılmıştır. Özellikle veri sayısının limitli olduğu IDRİD ver kümesinin sınıflandırılması probleminde faydalı olduğu görülmüştür.

Collaborative Learning of Semi-Supervised Segmentation and Classification for Medical Images

Bu çalışma [28] hastalık derecelendirmesi ve lezyon bölütlemesini iyileştirmek için yeni bir mimari ve teknik öne sürmüştür. İşbirlikçi Öğrenme Çerçevesi denilen yöntemde hastalık derecelendirmesi ve lezyon bölütlemesi eş zamanlı olarak birbirine katkı sağlayacak şekilde öğrenilmektedir. Yarı denetimli bir öğrenme yöntemi ileri sürülmüş ve bir dikkat mekanizmasından faydalanılmıştır.

İlk olarak bir bölütleme modeli bağımsız bir şekilde eğitilmiş ve her 4 lezyona ait maskenin üretilmesi mümkün kılınmıştır. Diğer yandan bağımsız bir şekilde sınıflandırma için bir model eğitilmiştir. Bu sınıflandırma modeli lezyon maskeleri ile çalışmaktadır. Son olarak da GAN mimarilerinde gördüğümüz ayırt edici model yapısı eğitilmiştir. Bu model bir maskenin belirli bir lezyona ait olup olmadığını ayırt etmek üzere eğitilmiştir. Bölütleme ve sınıflandırma modelleri seri bir şekilde bağlandıktan sonra bu iki modelin arayüzüne ayırt edici model de bağlanmıştır. Tüm bu birleştirmelerin ardından birleşik model hem sınıflandırma hem de bölütleme verileriyle tekrar eğitilmiştir. Ayırt edici model arayüzde bulunan özellik katmanının her zaman için lezyon maskeleri olmasını sağlamak görevi üstlenmiştir. Aksi takdirde ayırt edici modelin çıktısı kayıp fonksiyonuna katkıda bulunarak modeli cezalandırmaktadır. Özet olarak çalışma yarı denetimli bir öğrenme modeli sayesinde sınıflandırma ve bölütleme modellerinin birbirine katkıda bulunarak eğitilmesini mümkün kılmıştır.

3.2.3. Literatürdeki Çalışmaların Karşılaştırılması

IDRiD veri kümesi üzerinde yapılan çalışmaların sonuçları Tablo 3.1’de sunulmuştur. Tabloda verilen değerler kesinlik (precision) duyarlılık (recall) grafiğinin altında kalan alanlardır. Lezyon isimleri aşağıdaki gibi kısaltılmıştır:

- EX: sert eksudatları temsil etmektedir.
- HE: hemorajileri temsil etmektedir.
- MA: mikroanevrizmaları temsil etmektedir.
- SE: yumuşak eksudatları temsil etmektedir.

Ortalama sütunu ise 4 lezyonun sonuçlarının ortalaması alınarak hesaplanmıştır.

Çalışma /AUPR (%)	EX	HE	MA	SE	Ortalama
L-Seg	79.45	63.74	46.27	71.13	65.15
Local-Global UNets	88.90	70.30	52.50	67.90	69.90
VRT	71.27	68.04	49.51	69.95	64.69
PATech	88.50	64.90	47.40	–	–
iFLYTEK-MIG	87.40	55.88	50.17	65.88	64.84
PBDA	86.43	71.53	53.41	73.07	71.11
PBDA (UNet++)	81.04	64.08	49.17	68.88	65.48

Tablo 3.1 Literatürdeki diğer yöntemlerin IDRiD veri kümesi üzerinde karşılaştırması.

4. ÖNERİLEN YÖNTEM

4.1. Ön İşleme

4.1.1. Ben’in Ön İşleme Yöntemi

Retina görüntüleri üzerinde yapılan diğer çalışmalarda da denendiği gibi [29] görüntüler üzerinde ön işleme yapılarak lezyonların daha belirgin hale getirilmesi amaçlandı. Retina

görüntüleri turuncu kırmızı bir arka plan dokusu üzerine çeşitli renklerde ve büyüklüklerde lezyonlar tarafından oluşmuştur. Şekil 4.1’de IDRiD veri kümesinden örnek bir retina görüntüsü sunulmuştur. [29]’da kontrastın iyileştirilmesi amacıyla formülü Eşitlik 9’da verilen ön işleme tekniği kullanılmıştır.


$$I_{ce}(x, y; \sigma) = \alpha I(x, y) + \beta G(x, y; \sigma) * I(x, y) + \gamma \quad (9)$$

Eşitlik 9’da G Gaussian filtresini I görüntüyü temsil etmektedir. α β ve γ ise skalar katsayıları ifade etmektedir. Arka plan dokusunun rengi bir Gauss filtresi yardımıyla hesaplanıp bir arka plan görüntüsü oluşturulmuştur. Daha sonra bu arka plan görüntüsü fotoğrafın kendisinden çıkartılarak ön planda kalan görüntü elde edilmiştir. Ön planda kalan görüntüde damarlar ve eksudatlar başta olmak üzere çeşitli lezyonlar gözlemlenmektedir. Elde edilen ön plan görüntüsü -128 ila 128 arasında değişen ve ortalaması 0 olan piksel değerlerine sahiptir. Piksellerin değerleri skalar bir katsayıyla çarpılarak görüntüdeki kontrast daha da artırılmıştır. Daha sonra bütün piksellere 128 değeri eklenerek 0 ve 256 aralığının dışına çıkan değerler 0 ve 256 olacak şekilde limitlenmiştir. Ek olarak retinaya ait olmayan dışarıda kalan siyah alanlara tekrar 0 değeri verilmiştir, böylece o bölgelerin retina dokusunu içeren sınırların dışında kaldığı bilgisi görsel olarak korunmuştur. Elde edilen görüntü Şekil 4.2’de sunulmuştur.

Eşitlik 9’da G Gaussian filtresinin parametrelerinden biri olan σ değışintiyi (varyansı) ifade etmektedir. Bu parametre Gaussian filtresinin çıktısını Şekil 4.3.a, 4.3.b ve 4.3.c’de görüldüğü gibi etkilemektedir. Bir başka görüntü üzerindeki etkisi ise Şekil 4.4.a, 4.4.b ve 4.4.c’de görülmektedir. Bu parametrenin küçük seçilmesi Şekil 4.4.d’deki gibi geniş alanlı lezyonların daha az belli olmasına, büyük seçilmesi ise Şekil 4.3.f’de gözlemlenen soruna yol açmaktadır. Şekil 4.4.d’de verilen örnek durumda yumuşak eksudatların belirsiz halde olduğu diğer taraftan Şekil 4.4.e’de ve Şekil 4.4.f’de belirgin olduğu gözlemlenmektedir. Şekil 4.3.f’de verilen örnek durumda aydınlatmadan ve doku tonunun dağılımından kaynaklı olarak optik diski ve çevresinde bulunan damarları içeren alan daha açık renklidir. Bu açık renkli alan ilgi konusu olmamasına rağmen parametrenin çok büyük seçilmesi sonucu




Şekil 4.1 Örnek bir retina görüntüsü.




Şekil 4.2 Ben'in ön işleme yöntemi ve dış çerperlerin karartılması.

oldukça vurgulanmıştır. Bu parametrenin çok büyük ve çok küçük olmasının getirdiği sorunlar göz önüne alındığında çeşitli değerlerin görsel olarak etkisi incelendikten sonra dengeli bir değer seçilmiştir.



Şekil 4.3 σ parametresinin örnek bir fotoğraftaki etkisi. (a) $\sigma = 12$ olduğu durumda G filtresinin çıktısı. (b) $\sigma = 90$ olduğu durumda G filtresinin çıktısı. (c) $\sigma = 360$ olduğu durumda G filtresinin çıktısı. (d) $\sigma = 12$ olduğu durumda ön işleme yönteminin çıktısı. (e) $\sigma = 90$ olduğu durumda ön işleme yönteminin çıktısı. (f) $\sigma = 360$ olduğu durumda ön işleme yönteminin çıktısı.

Literatürde özellikle geleneksel görüntü işleme algoritmalarıyla çalışan yöntemlerde görüntünün yalnızca yeşil kanalının kullanıldığı da görülmektedir. Görüntünün yeşil kanalında retinanın yapıları oldukça belirgin olduğu için diğer kanalların içerdiği bilgileri silmek çok büyük bir kayba neden olmazken girdi boyutunu küçültme avantajını getirmektedir. Diğer yandan günümüzde ImageNet veri kümesi üzerinde renkli görüntüler üzerinde eğitilen hazır modeller aktarımlı öğrenme yöntemi sayesinde küçük eğitim kümelerinde bile başarılı sonuçlar elde edilmesini mümkün kılmıştır. Görüntüyü renksiz görüntüye çevirmek veya yalnızca bir kanalını kullanmak girdinin boyutunu düşürmek amacıyla yapılmaktadır. Fakat ImageNet ağırlıklarının kullanıldığı bir çalışmada girdi görüntüsünün 3 kanallı olması gerekmektedir. Bu çalışmada bu nedenle kırmızı ve mavi



Şekil 4.4 σ parametresinin örnek bir fotoğraftaki etkisi. (a) $\sigma = 12$ olduğu durumda G filtresinin çıktısı. (b) $\sigma = 90$ olduğu durumda G filtresinin çıktısı. (c) $\sigma = 360$ olduğu durumda G filtresinin çıktısı. (d) $\sigma = 12$ olduğu durumda ön işleme yönteminin çıktısı. (e) $\sigma = 90$ olduğu durumda ön işleme yönteminin çıktısı. Yumuşak eksudatlar kırmızı elipslerle gösterilmiştir. (f) $\sigma = 360$ olduğu durumda ön işleme yönteminin çıktısı.

kanalların görüntüden silinmesi tercih edilmemiştir. Herhangi bir amaca hizmet etmeyeceği gibi bilgi kaybına yol açacak bu aşama Bölüm 3.2.'de verilen çalışmalarda da atlanmıştır.

4.1.2. Önerilen Ön İşleme

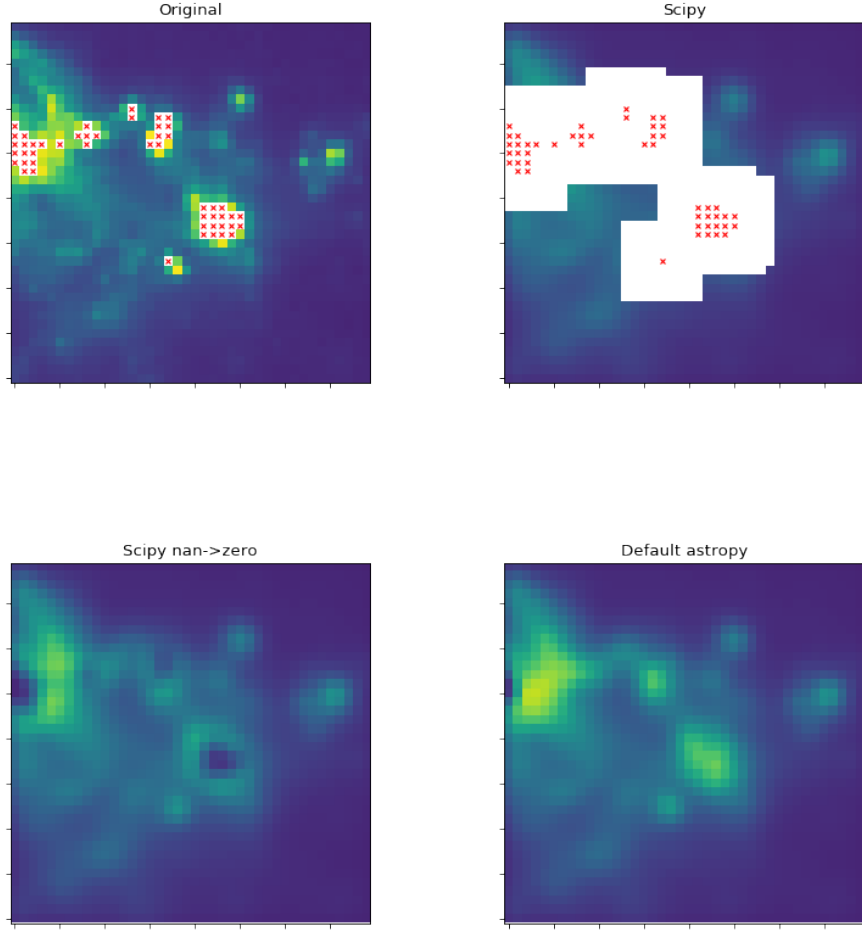
Literatürde kullanılan yöntem iyileştirme sağlıyor olsa da görsel olarak incelendiğinde bazı problemleri de beraberinde getirdiği görülmektedir. Bunlardan en başlıcası hemorajilerin ve mikroanevrizmaların yanlış pozitif sayısını artıran bir durum olarak karşımıza çıkmaktadır. Eksudatlar sarı veya beyaz tonlarında parlak, geniş ve parçacıklı şekillerden oluşmaktadır. Literatürdeki yöntem eksudatların parlaklığını artırırken eksudatların çevresini de karartarak kontrastı artırmaktadır. Bunun doğal sonucu olarak özellikle eksudatlar tarafından çevrelenen bazı alanlar arka plan dokusuna ait olmasına rağmen oldukça karanlık bir değer alabilmektedir. Hemoraji ve mikroanevrizmaların da karanlık renklerde olduğu göz önüne alındığında yanlış pozitiflerin sebeplerinden bir tanesinin ön işleme algoritmasından geldiği

çıkarılabilir. Bu sorunun üzerine gitmek amacıyla ön işleme algoritması [30] yöntemiyle güncellenmiştir.


Güncellenen algoritma arka plan görüntüsü hesaplama adımında değişiklik içermektedir. Eksudatların çevrelerini karartmalarının sebebi, onların arka plan rengini hesaplariken hesaba katılmasıdır. Böylece eksudatların çevresindeki bölgeler parlak arka plan tonuna sahip olarak hesaplanmış olmaktadır. Bu nedenle arka plan görüntüsünün hesaplanması işlemi değiştirilerek ekstrem değerlere sahip olan piksellerin arka plan hesabına etki etmesi engellenmiştir. Çalışmanın geri kalan bölümünde ön işleme olarak yalnızca bu ön işleme yöntemi kullanılmıştır.

4.1.2.1. Ampute Gauss Filtresi Ekstrem değerlere sahip olan piksellerin arka plan dokusu olmadığı, lezyon veya benzeri dokulardan olduğu varsayılmıştır. Bu ekstrem piksellere NaN değeri atanarak Gauss filtresi tarafından kullanılmaması sağlanmıştır. Normal bir Gauss filtresi fonksiyonu NaN değerleri karşısında hata vermekte ya da anormal çıktılar üretmektedir. Bu nedenle bu gibi durumlar için hazırlanmış Astropy [31] [32] [33] kütüphanesinin Gauss filtresi kullanılmıştır. Şekil 4.5'te NaN değerleri karşısında Scipy kütüphanesi ve Astropy kütüphanesinin örnek çıktıları sunulmuştur. Astropy kütüphanesinin çıktısı NaN değerleri, beyaz anomaliler ya da siyahlaşmış alanlar yaratmamaktadır. Bunun yerine doğal bir görünüm olan blurlanmış bir çıktı üretmektedir.


Burada kullanılan teknik NaN değerlerine ait olan piksellerin önce çevredeki pikseller tarafından aradeğerleme yoluyla hesaplanmasıdır. Böylece NaN değerleri tarafından ampute edilen girdi değerleri tekrar kullanılabilir hale gelmektedir. Bu aradeğerlemenin etkisi, görüntünün inşası olarak da ifade edilebilir. Şekil 4.6'da görüntünün yeniden inşası adımı örneklendirilmiştir. Güncellenmiş arka plan hesaplama yöntemiyle üretilen yeni ön işlenmiş görüntüler ekstrem pikseller çevresinde daha az anomali göstermektedir. Şekil 4.7'de Ben'in ön işleme yöntemi ve yeni ön işleme algoritması arasındaki fark görülmektedir. Özellikle ekstrem piksellerin çevresinde oluşan anomalilerin giderildiği Şekil 4.8'de örneklendirilmiştir.




Şekil 4.5 Sol üst köşede NaN (kırmızı X'le gösterilmiştir) değerlerini içeren astronomik bir görüntü görülmektedir. Sağ üst köşede Scipy kütüphanesinin Gauss filtresinin çıktısı verilmiştir. Sol alt köşede NaN değerleri 0'a eşitlendikten sonraki Scipy çıktısı verilmiştir. Sağ alt köşede ise Astropy kütüphanesinin Gauss filtresi çıktısı gösterilmiştir.



Şekil 4.6 Ampute görüntünün aradeğerleme yoluyla yeniden inşası. Solda NaN değerleri (kırmızı X'lerle gösterilmiştir) içeren görüntü bulunmaktadır. Sağda NaN piksellerinin aradeğerleme yoluyla düzeltilmiş hali görülmektedir.




Şekil 4.7 Sırasıyla literatürdeki ön işleme tekniğinin çıktısı ve geliştirilen ön işleme tekniğinin çıktısı. Örnek olarak eksudatların çevresindeki karamaların ortadan kalktığı görülmektedir.




Şekil 4.8 Sırasıyla literatürdeki ön işleme tekniğinin çıktısı ve geliştirilen ön işleme tekniğinin çıktısı (kırpılmış görüntüler). Eksudatların çevresindeki karamaların kalktığı görülmektedir.

Bu bölümde anlatılan ilkelerden hareketle gerçekleştirilen görüntü işleme yönteminin aşamaları görselleştirilmiştir. Şekil 4.9’da görüldüğü üzere orijinal görüntüden Gauss filtresi uygulanmış görüntü çıkarılır. Bu işlem 3 kanallı görüntüler üzerinde yapıldığı için sonuç olarak elde edilen fark görüntüsü de renkli olmaktadır.




Şekil 4.9 (a) Orijinal görüntü. (b) Gauss filtresinden geçirilmiş görüntü. (c) Fark görüntüsü.

Bir sonraki aşama ise ekstrem değerlere sahip olan piksellerin belirlenmesidir. Bunun için bir kriter tanımlanarak kriterin dışında kalan pikseller ekstrem pikseller olarak değerlendirilmiştir. Fark görüntüsündeki değerler 3 kanallıdır. Öncelikle fark görüntüsü uzaklık görüntüsüne dönüştürülmüştür. Bir pikselin orjinal görüntüyle Gauss filtresinin çıktısı arasındaki farkı Öklid uzaklığı formülüyle uzaklığa dönüştürülmüştür. Böylece 3 kanaldan oluşan uzaydaki noktalar arasındaki uzaklıklar Şekil 4.10.b’de gösterildiği şekilde tek kanallı olarak görselleştirilmiştir. Ekstrem piksel olma kriteri de uzaklık görüntüsündeki değerlerin belli bir eşikten büyük olması olarak belirlenmiştir. Şekil 4.10.c’de bu eşığın üstünde kalan pikseller siyaha boyanarak yalnızca ekstrem olmayan piksellerin renkleri gösterilmiştir. Bu yalnızca bir görselleştirmedir, gerçekte siyaha boyanmamıştır.




Şekil 4.10 (a) Fark görüntüsü. (b) Uzaklık görüntüsü. (c) Orijinal görüntüdeki ekstrem olmayan piksellerin oluşturduğu görsel.

Yeni aşamada ekstrem pikseller NaN değeri verilerek hesap dışı tutulmuştur. Astropy kütüphanesinin ampute Gauss filtresi yardımıyla Gauss filtresi çıktısı yeniden hesaplanmıştır. Şekil 4.11’de bu aşamaya ait görsel sunulmuştur. Ben’in ön işleme yöntemindeki sıradan Gauss filtresi görüntüsü de karşılaştırma amacıyla aynı şekilde gösterilmiştir.

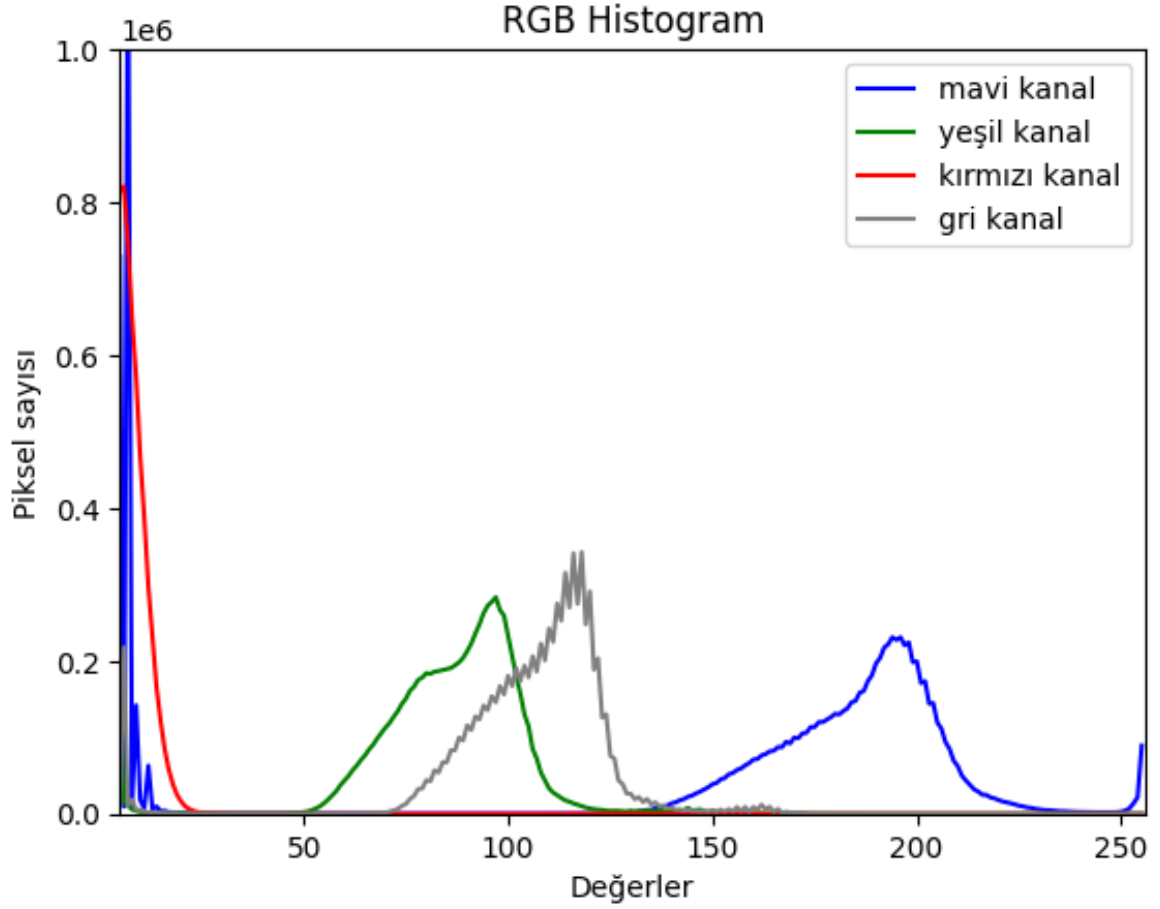


Şekil 4.11 (a) Ampute Gauss filtresinde kullanılacak piksellerin görselleştirilmesi. (b) Ampute Gauss filtresinin çıktısı. (c) Normal olan Gauss filtresinin çıktısı.

Son aşama Ben’in ön işleme yönteminin aynısını takip edip kontrast artırma aşamasıdır. Yeni Gauss çıktısı ile orjinal görüntü arasındaki fark skalar bir katsayı ile çarpılmış ve ön planda kalan yapıların belirginleşmesi sağlanmıştır. Bu aşamaya ait görselleştirme Şekil 4.12’de bulunmaktadır. Kontrast üzerindeki etkinin incelenmesi de Şekil 4.13 ve Şekil 4.14’te görülmektedir. Orijinal görüntü kullanılarak elde edilen Şekil 4.13’te bulunan piksel değerlerinin renkliden griye dönüştürüldüğünde standart sapması 50 çıkmaktadır. Önerilen ön işleme yönteminin sonucu olan görüntüden elde edilen Şekil 4.14’te ise aynı standart sapma hesabı 75 sonucunu vermektedir. Şekil 4.14’te kanalların ortalama ve standart sapma değerlerinin de ortaklaştığı gözlemlenmektedir.



Şekil 4.12 (a) Ampute Gauss filtresinin çıktısı. (b) Ön işleme yönteminin çıktısı.

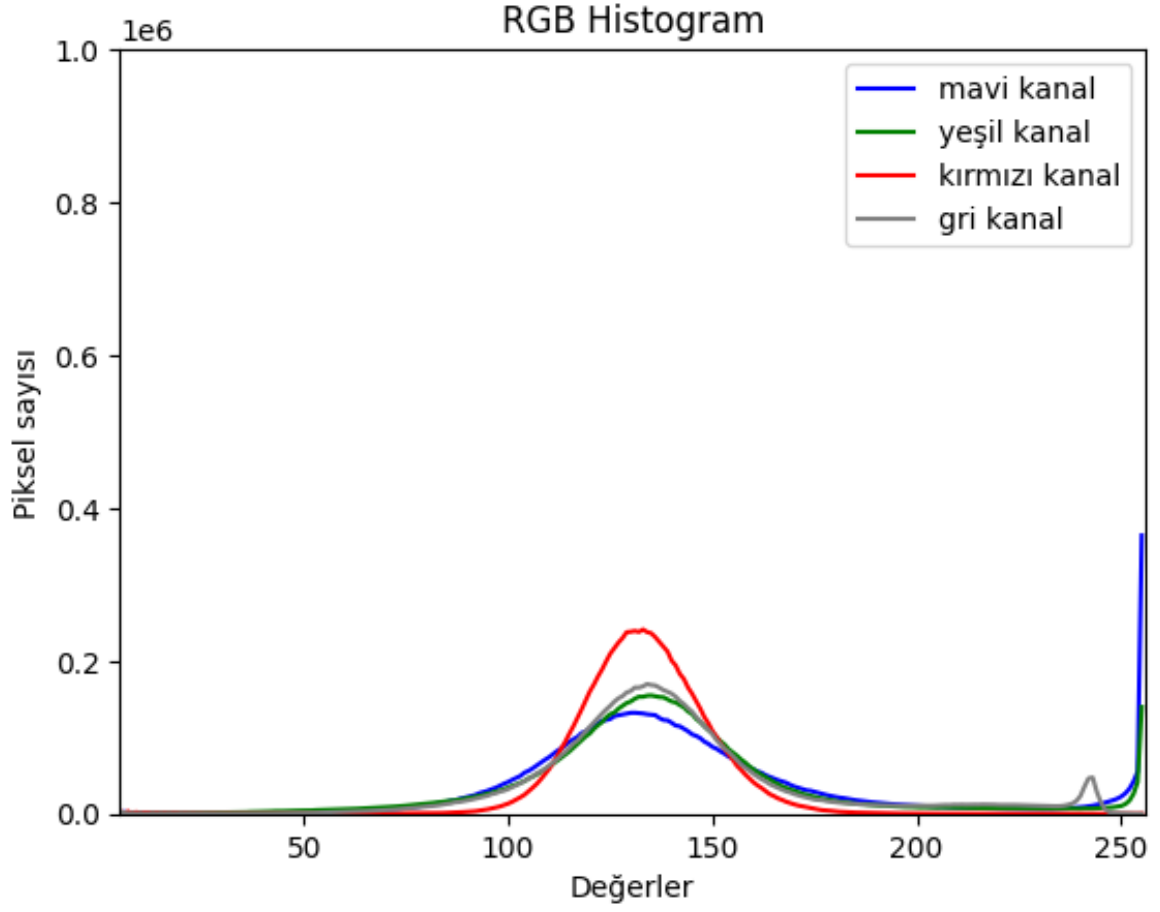


Şekil 4.13 Orijinal görüntünün kanallarının ve parlaklık dönüşümüyle elde edilen gri kanalının histogramı

4.2. Gürültü Giderme

Arka planı çıkartma ve kontrastı artırma işlemleri dolayısıyla görsellerde bulunan yüksek frekanslı öğeler baskın gelmeye başlamıştır. Resimlerin gürültü seviyesinin yükseldiği Şekil 4.8’de gözlemlenmektedir. Görüntüdeki gürültülerin yaratabileceği sorunların önüne geçebilmek amacıyla gürültü giderme yöntemleri kullanılmıştır. Geleneksel görüntü işleme yöntemleriyle önemli dokuları gürültüden ayırt etmek için bir kıstas bulunamamıştır. Bunun yerine literatürde bulunan bir dizi derin öğrenme temelli gürültü giderme modeli denenmiştir.


BSRGAN modeli [14] kullanılarak elde edilen görüntü çıktılarının yapılan karşılaştırmalar sonucunda kullanılmasına karar verilmiştir. Şekil 4.15’te modelin diğer yöntemlerle




Şekil 4.14 Önerilen yöntemle ön işlenmiş görüntünün kanallarının ve parlaklık dönüşümüyle elde edilen gri kanalının histogramı

karşılaştırmasını gösteren bir dizi görüntü örneği sunulmuştur. Bu çalışmada seçilen gürültü giderme yöntemi BSRGAN olmuştur ve çalışmanın devamı boyunca sadece BSRGAN kullanılmıştır.


Seçilen gürültü giderme yönteminin bir dizi parametresinden biri olan girdi alanı maksimum (4096 piksel) olacak şekilde seçilmiştir. En fazla işlemsel yükü gerektirmesine rağmen en verimli sonuçları üretmektedir. Bölgelerin görüntüsünü giderirken mümkün olan en büyük görüntü alanı kullanılmıştır. Şekil 4.16'da gürültü giderme modelinin ön işlenmiş bir retina fotoğrafına ürettiği çıktısı görülmektedir. Şekil 4.17'de ise daha küçük bir alanda gürültü giderme işleminin öncesi ve sonrası görünmektedir.



Şekil 4.15 Kullanılan başlıca gürültü giderme yöntemlerinin çıktıları. a) RRDB yöntemi [12] b) ESRGAN yöntemi [12] c) RealESRGAN yöntemi [13] d) BSRGAN yöntemi [14]



Şekil 4.16 Gürültü giderme adımının ardından üretilen retina görüntüsü.




Şekil 4.17 Gürültü giderme adımının sırasıyla öncesine ve sonrasına ait kırılmış görseller.

4.3. Kırpma

Herhangi bir bilgi içermediği gerekçesiyle retina fotoğraflarında bulunan doku dışı siyah alanlar kırılmıştır. Gereksiz alanların kırılmasından sonra modellerin tam boyutlu eğitimlerinde kullanılmak üzere kare görseller üretilmiştir. Bu nedenle IDRiD veri kümesi özelinde resmin üst ve altına ekstra boş alanlar eklenmiştir. Elde edilen kare görüntüler retinanın sığacağı minimum kare alana yakın görüntülerdir. Tam minimum kare alanın seçilmeme sebebi ise var olan yapay zeka kütüphanelerinin görüntü boyutu olarak 32 veya katlarını bekliyor olmasıdır. Bu nedenle 3456 x 3456 boyutunda görüntüler üretilmiştir. Hem 32'nin katı hem de olabilecek minimum gereksiz alana sahip olan kare görüntüler elde edilmiştir. Şekil 4.18'de bahsedilen kare görüntü elde etme işlemi örneklenmiştir.

Medikal veri kümelerinde sıklıkla görüldüğü gibi işaretli görüntü sayısı retina veri kümelerinde de limitleyici faktördür. Bu soruna çözüm olarak Badar ve diğerleri [25] görüntünün küçük boyutlara kırılarak çoğaltılması yoluna gitmişlerdir. Görüntülerin küçük karelere kırılması yoluyla veri sayısı artarken girdinin boyutu da küçültülmüş olmaktadır.




Şekil 4.18 Siyah bölgelerin kırılması ve kare elde edilmesi.

Daha küçük boyutlara sahip veri daha küçük modellerle öğrenilebilir hale gelmektedir. Veya aynı kapasitedeki model için daha yüksek verimde bir eğitim süreci elde edilmektedir. Girdi boyutunun küçülmesi optimizasyon uzayının da küçülmesi dolayısıyla problemin basitleşmesi anlamına gelmektedir [34]. Bir diğer yandan da görüntü ne kadar küçük parçalara ayrılırsa içeriği de o kadar azalmaktadır. Modelin algılayabildiği alanın sınırları daraldıkça da kaybettiği bilgi miktarı da artmaktadır. Kırılan alanların büyüklüğü bu iki limitleyici faktörü de göz önüne alınarak seçilmiştir. Lezyonlardan daha küçük boyutta karelere kırmak modelin lezyonun bütününe algılamasına büyük engel teşkil etmektedir. Bu nedenle 576 x 576 piksel ve 1152 x 1152 piksel olarak iki görüntü kırma büyüklüğü üzerinde çalışılmıştır. Şekil 4.19'da 576x576 alana kırılmış retina görüntüsü görülmektedir. Bir diğer alternatif olan 1152 x 1152 piksellik görüntüler ise resmi 9 parçaya bölmeye tekabül etmektedir. Şekil 4.20'de bu versiyon gösterilmiştir.

4.4. Kayan Pencere Yöntemi


Kırma yöntemiyle artırılan veri miktarı kayan pencere (sliding window) tekniği kullanılarak daha da artırılabilir. Kırılan pencereler birbiriyle örtüşecek şekilde ayarlanırsa daha fazla kırılmış görüntü elde edilir. Kırma miktarı 576 ve kayma miktarı 288 olarak seçildiğinde ardışık her iki pencere arasında %50 oranında bir örtüşme görülmektedir.



Şekil 4.19 Görüntünün 576 x 576'lık pencerelere kırılması.

Kırpma yönteminin bir dezavantajı ise sınırda kalan bölgelerin performansdır. Kırpılan görüntülerin kenarlarında kalan lezyonlar farklı görüntülere parçalanmış olmaktadır. Görüntünün merkezinde kalan lezyonlar hem bütün kalabilirken hem de kenarda kalan lezyonlara göre daha fazla çevresel bilgiyle birlikte modele verilmiş olmaktadır. Tüm bu nedenlerden dolayı modellerin performansı merkezde kalan lezyonlar ve kenarda kalan lezyonlar için aynı olmamaktadır. Lezyonların bulunduğu konuma göre modelin performansını çizdirdiğimizde Tablo 4.1 elde edilmiştir. Eğer lezyonları merkez lezyonları ve kenar lezyonları diye iki kategoriye ayıracak olsaydık merkez lezyonlarının başarısı daha yüksek olacaktı. Şekil 4.21'de merkez ve kenar lezyonları kategorilerinin tanımı görülmektedir.

Kenarda kalan lezyon sorununu gidermek için birbiriyle kesişen pencereleri kırmak yoluna gidilmiştir. Bu sayede her lezyon fotoğraflardan en az birinde merkezde kalmış olacaktır.



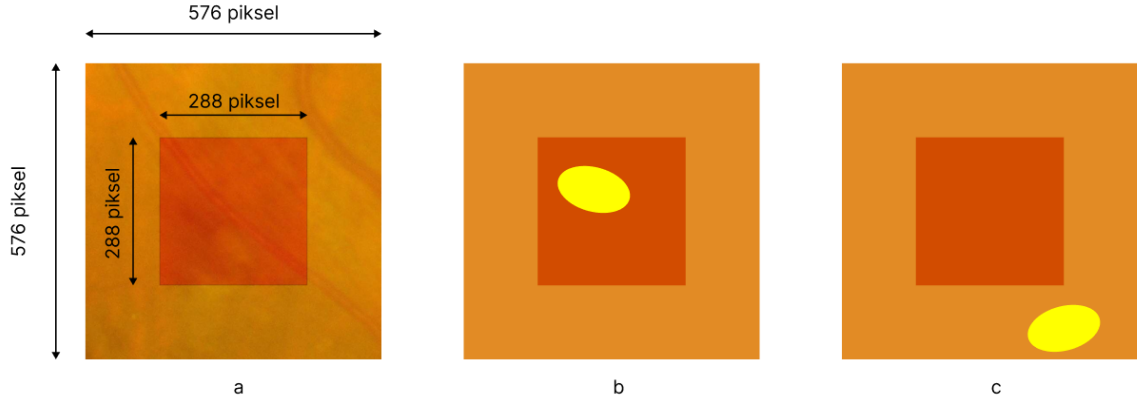
Şekil 4.20 Gürültüsü giderilmiş görüntünün 1152x1152'lik pencerelere kırılması.

Lezyon Konumu	Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	F1 Skoru	IoU
Merkezdekiler	0.80	0.58	0.43	0.49	0.34
Kenardakiler	0.81	0.57	0.39	0.46	0.33

Tablo 4.1 Örnek bir model için kenarda ve merkezdeki performans oranları.

Modelin farklı pencereler için çıktılarını üretirken örtüşen alanlar için birden fazla çıktı elde edilmektedir. Bu çıktıların değerleri kullanılarak ortak piksellerin nihai değerine karar verilmektedir. Piksellerin alacağı değere karar verilirken basit bir yöntem kullanılmıştır. Bir piksel hangi pencerede daha merkezdeyse o penceredeki atanmış değeri nihai değeri olarak kabul edilmiştir. Bu aşamada farklı pencerelerin sonuca farklı ağırlıklarla katkı sunması yoluna gidebilirdi. Fakat basit yöntem kullanıldığında efektif olarak her pencerenin merkezinde bulunan kareler seçilip birleştirilmiş olmaktadır.

Hem çıktı üretilirken gösterilen performansı iyileştirmesi hem de eğitim veri kümesindeki



Şekil 4.21 a) Kırmızı alan merkezi, turuncu alan kenarı temsil etmektedir. b) Merkez lezyonuna (sarı alan) örnek. c) Kenar lezyonuna (sarı alan) örnek.

Lezyon tipi	Lezyon sayısı
Eksudat	2504
Hemoraji	1068
Mikroanevrizma	2082
Yumuşak Eksudat	84


Tablo 4.2 Lezyon koleksiyonunda toplanan lezyonların tipi ve sayısı.

veri sayısını çoğaltması bakımından bu yöntem tercih edilmiştir. Ardışık pencerelerin örtüşme oranı olarak ise %50 seçilmiştir. Bu orandan daha fazlası için anlamlı bir performans artırımını gözlemlenmediği halde işlem yükü artmaktadır.

4.5. PBDA Yöntemi

Literatür kısmında da bahsedildiği üzere PBDA (Poisson Blending Data Augmentation) yöntemi [11] kullanılarak veri sayısını daha da artırma yoluna gidilmiştir. İlk adım olarak retinada bulunan lezyonların küçük resimleri kesilip bir koleksiyona kaydedilmiştir. Aynı zamanda bu lezyonların bölütleme maskeleri de aynı şekilde kesilerek koleksiyona eklenmiştir. Koleksiyonun içeriğinden bir dizi örnek Şekil 4.22’de verilmiştir. Tablo 4.2’de oluşturulan lezyon koleksiyonundaki lezyonların türleri ve bu türlere ait lezyon sayıları verilmiştir.

Bir sonraki adımda ise bu lezyonlar eğitim veri kümesinde bulunan retina fotoğraflarının çeşitli yerlerine yapıştırılmıştır. Bu yapıştırma işlemi kritik bir önem arz etmektedir.




Şekil 4.22 Lezyon koleksiyonunda bulunan çeşitli eksudatlar ve maskeleri.

Yapıştırma işlemi doğrudan piksellerin kopyalanması yoluyla yapıldığında yapıştırılan nesne yapıştığı arka plana uyumsuzluk gösterecektir. Parlaklık seviyesi, renk tonu, gürültü seviyesi gibi çeşitli özellikler nesnenin görüntüye monte edildiğini ele vermektedir. Nesnenin çevresine uyum sağlayarak yapıştırılması için literatürde bulunan yöntemlerden Poisson harmanlama yönteminden [15] faydalanılmıştır.

4.5.1. Poisson Görüntü Düzenleme

Poisson Görüntü Düzenleme başlıklı makale [15], Poisson Denklemi kullanarak dijital görüntü işlemedeki interpolasyon sorunlarını çözmeyi hedefler. Bu yöntem, bir görüntünün seçilen bir bölgesinde sorunsuz klonlama ve düzenleme yapmak için önemlidir. Yöntem, bölgedeki nesnelerin dokusunu, aydınlatmasını ve rengini düzenler. Sorunsuz harmanlama, klonlanan bölgenin gradyanının (uzamsal türevlerin) hedef görüntünün çevresindeki bölgenin gradyanı ile eşleştirilmesi sayesinde sağlanır.

Kaynak görüntü ve hedef görüntü olarak lezyon fotoğrafları ve retina fotoğrafları kullanılmıştır. Oluşturulan koleksiyonda bulunan lezyonlar aynı zamanda maskelere de sahiptir. Bu maskeler kullanılarak lezyonların sınırları ifade edilir. Lezyonların maskeleri genişletilerek belli bir kalınlıkta genişletilmiştir. Bu sayede lezyonların ait olduğu arka planın bir kısmı da kaynak görüntü içerisine dahil edilmiştir. Şekil 4.23'te de görüldüğü üzere nesnenin çevresinde pay bırakılacak şekilde kesmek bu yöntem için daha efektif sonuçlar doğurmaktadır.



Şekil 4.23 Poisson Harmanlama Yöntemi [15].

Bu yöntemde kaynak görüntüdeki seçilen bölge içindeki gradyan alanı hesaplanır. Bu hem yatay hem de dikey yönde piksel değerlerinin farklarını hesaplamayı içerir. Bir sonraki aşama bu yöntemi ana adımı olan Poisson denklemlerini (Eşitlik 10) çözmektir.

$$\Delta f = \text{div } \mathbf{v} \quad (10)$$

Eşitlik 10'da:

- Δ , Laplace işlemini temsil eder.
- f , çözülmesi amaçlanan bilinmeyen görüntü fonksiyonudur (yani, harmanlamadan sonra görüntünün piksel değerleri).
- $\text{div } \mathbf{v}$, kaynak görüntüden hesaplanan gradyan alanı olan \mathbf{v} 'nin vektör alanının dalgalanmasını ifade eder.

Bu denklemin sağlanması gereken sınır koşulu ise; bölgenin sınırındaki f değerleri ile hedef görüntünün piksel değerlerine eşitlenmesidir. Bu denklemler her renk kanalı için

Gauss-Seidel iterasyonu gibi nümerik yöntemler sayesinde çözülür. Böylece klonlanacak nesnenin piksel değerleri hesaplanmış olur. Bu yöntem kullanılarak lezyon koleksiyonundan herhangi bir lezyonun herhangi bir retina bölgesine harmanlanarak yapıştırılması mümkün kılınmıştır.

Lezyonların görüntülere yapıştırılması aşamasında çeşitliliği artırabilmek amacıyla bir dizi rastgele işleme başvurulmuştur. Bu sayede modelin lezyonların görünümünü ezberlemesinin önüne geçilmeye çalışılmıştır. Her bir lezyon için izlenen adımlar aşağıdaki gibidir:

- Lezyonun yapıştırılacağı yer rastgele seçilir. Bu sayede lezyonlar farklı arka plan görüntüsüne sahip olurlar.
- Lezyon 0 ila 360 derece arasında rastgele bir açıyla döndürülür.
- Lezyonun %50 ihtimalle yatay ayna görüntüsü alınır.
- Lezyonun %50 ihtimalle dikey ayna görüntüsü alınır.
- Lezyonun boyutu %10 oranından yüksek olmamak kaydıyla rastgele değiştirilir.
- Lezyona belirlenmiş limitleri aşmayacak derecede rastgele bir afin dönüşüm (affine transform) uygulanır.


Bahsedilen bu işlem grubuna temel lezyon artırma aşamaları adı verelim. Temel lezyon artırma aşamalarının gerçekçi retina görüntüleri üretmede karşılaştığı başlıca sorunlar vardır. Lezyonların rastgele seçilen pozisyonlara yapıştırılması gerçeğe uygun olmayan bazı görüntülere sebep olmaktadır. Lezyonlar retina dokusu üzerinde oluşur, retina etrafında kalan siyah bölgelere lezyon yapıştırılması gerçekten uzak bir görüntü yaratır. Lezyonlar retinanın anatomisi gereği optik disk üzerinde oluşmazlar. Buraya lezyon yapıştırılması gerçek dışı bir durum yaratır. Lezyonlar damarların üzerinde oluşmaz. Lezyonlar diğer lezyonlarla üst üste olamazlar. Bu pozisyon kısıtlamalarının gözetildiği bir işlem grubu ise PBDA yazarları tarafından kullanılmıştır [11]. Bu işlem grubuna pozisyon kısıtlamalı lezyon artırma adı verelim.

Pozisyon kısıtlamalı lezyon artırma işlemlerinin yapılabilmesi için optik disk, damarlar ve retina alanını gösteren maskelere ihtiyaç duyulmaktadır. Optik disk maskeleri IDRiD veri kümesinde hazır bulunurken damarlar için benzer çalışmada [30] kullanılan damar bölütleme modelinin çıktıları kullanılmıştır. Damar modeli düşük başarıya sahip olmasına rağmen sonuca etkisinin limitli olacağı düşünülerek problemleri ihmal edilmiştir. Retinanın alanının sınırları ise geleneksel görüntü işleme yöntemleri kullanılarak çıkartılmıştır. Buna göre ilk aşamada resim gri resme çevrilerek belirli parlaklık eşiğinin altında kalan yerler retina dışı, üstünde kalan yerler retina içi olarak atanmıştır. Retinanın kapladığı alan resmin neredeyse tamamına yakın dairesel bir bölgedir. Bir dizi morfolojik operasyon yapılarak bu dairenin içindeki veya dışındaki küçük problemler de giderilmiştir. Örnek bir görüntü üzerinden elde edilen yeni retina görüntüleri Şekil 4.24'te görülebilir.

4.6. PBDA Yöntemiyle Sağlıklı Verilerin Eklenmesi

PBDA yöntemi sayesinde aynı retina fotoğrafı üzerinde çeşitli pozisyonlara lezyon eklemek eğitim veri kümesini sınırsız sayıda büyütmeyi mümkün kılmıştır. Fakat eğitim veri kümesi temelde yalnızca 54 fotoğraftan oluşmaktadır. Bu 54 fotoğrafın sınırsız sayıda çoğaltılması bir noktadan sonra anlamlı bir kazanç yaratmamaktadır. Modeller sınırlı sayıdaki arka plan resmini ezberledikten sonra o resimlerdeki değişiklikleri kolayca ayırt edebilir fakat test esnasında yeni bir resimde bu işe yaramaz. Bu çalışmanın kapsamında arka plan resimlerinin sayısındaki limiti de genişletmek hedeflenmiştir. IDRiD veri kümesi 3 alt daldan oluşmaktadır. Bölütleme veri kümesi 54 eğitim ve 27 testten oluşurken, sınıflandırma veri kümesi 413 eğitim ve 103 test verisi bulundurmaktadır. Diyabetik retinopatinin sınıflandırılması için hazırlanan bu veri kümesindeki sınıfların dağılımı Tablo 4.3'te gösterilmiştir.

Bu veri kümesi kullanılarak yeni görüntüler PBDA yoluyla üretilmiştir. Bu veri kümesinde lezyon maskeleri bulunmadığı için lezyon barındırmayan görüntülerin seçilmesi yoluna gidilmiştir. Sağlıklı olarak işaretlenen 168 görüntüde lezyon bulgusu saptanmamış olmalıdır. Bu nedenle bu görüntüler seçilerek temel düzeyde yani pozisyon kısıtlamaları uygulamadan



Şekil 4.24 PBDA yöntemi ile bir fotoğrafın üzerinden üretilen yeni görüntüler. Farklı bölgelere farklı eksudatların (sarı dokular) yapıştırıldığı görülmektedir.

Seviye	Görüntü sayısı
Sağlıklı	168
Hafif NPDR	25
Orta NPDR	168
Ağır NPDR	93

Tablo 4.3 IDRİD sınıflandırma veri kümesinde bulunan seviyeler ve bu seviyelere ait görüntü sayıları.

PBDA yöntemi çalıştırılmıştır. Böylece arka plan görüntüsü sayısı 54 çeşitten 222 çeşide çıkarılmıştır.

4.7. Veri Artırımı

4.5. Bölüm ve 4.6. Bölüm’de bahsedilen veri kümesindeki görüntü sayısını artırma işlemlerinin yanı sıra modellerin eğitimi sırasında uygulanan veri artırma yöntemlerinden de faydalanılmıştır. Eğitim sırasında modele verilen her görüntü bir dizi rastgelelik içeren işlemde geçirilmiştir.

- Görüntüler 0 ila 360 arasında rastgele bir açıda olacak şekilde dondurulmuştur.
- Fotoğrafların %50 ihtimalle dikey ayna görüntüsü alınmıştır.
- Fotoğrafların %50 ihtimalle yatay ayna görüntüsü alınmıştır.
- Görüntüler %10’luk oranı aşmayacak şekilde rastgele bir yöne kaydırılmışlardır.
- %10 oranı aşmayacak şekilde rastgele bir oranda büyütülmüş veya küçültülmüşlerdir.

4.8. Model ve Eğitim Yöntemi

Model mimarisi olarak bölütleme mimarilerinden FPN, DeepLabV3, Unet ve UnetPlusPlus modelleri denenmiştir. En yüksek performans UNetPlusPlus ile elde edildiğinden dolayı deneylerin devamı bu mimari ile gerçekleştirilerek tamamlanmıştır.

Çalışma kapsamında birden fazla model birden fazla yöntemle eğitilmiş ve bu yöntemlerin karşılaştırmalı sonuçları elde edilmiştir. Modeller Imagenet üzerinde eğitilmiş modellerin ağırlıkları kullanılarak oluşturulmuşlardır. Eğitim işlemi için önceki bölümlerde de bahsedildiği üzere veriler çeşitli ön işlemlere tutulmuş ve çeşitli yöntemlerle çoğaltılmış veri kümeleri hazırlanmıştır. Bu veri kümelerinden orijinal olanı en az sayıda veriye fakat gerçek görüntülere sahiptir. Pozisyon kısıtlanmalı PBDA yöntemiyle oluşturulmuş veri kümesi gerçek görüntüler olmasa bile gerçeğe yakın dağılım gösteren verilere sahiptir ve

daha fazla veri barındırır. Son olarak sağlıklı retina görüntülerinin üzerinde temel düzeyde PBDA algoritması kullanılarak üretilen 3. veri kümesi en büyük veri sayısına sahiptir fakat gerçekte mümkün olmayan durumları da içinde barındırmaktadır. Veri kümelerinin veri sayısı ve özellikleri Tablo 4.4'te özet olarak sunulmuştur.

Veri Kümesi	Veri Sayısı	Pozisyon Limitleri	Gerçekçilik
1) IDRiD	54	-	Gerçek
2) PBDA	216	Var	Gerçeğe uygun
3) Sağlıklılarda PBDA	672	Yok	Düşük

Tablo 4.4 1. 2. ve 3. veri kümelerinin özellikleri

Verilerden mümkün olduğunca verim alabilmek için hepsini kullanmaya yönelik [27] benzeri bir strateji geliştirilmiştir. İlk aşamada çok gerçekçi olmayan 3. veri kümesi kullanılmıştır. Daha sonra eğitilen model 2. veri kümesi üzerinde daha gerçekçi verilerle eğitilmiş böylece büyük veri kümesinden öğrenilen hatalı bilgiler azaltılmıştır. Son olarak da aynı model gerçek veri kümesi üzerinde eğitmeye devam edilmiş ve böylece büyük veri kümelerinde öğrenilen gerçek dışı durumlar minimize edilmiştir. Bir başka bakış açısıyla aktarma öğrenme (transfer learning) yöntemi kullanılarak Imagenet ağırlıklarından faydalanılmış, tekrar aktarma öğrenme kullanılarak 3. veri kümesinden faydalanılmış ve son bir aktarma öğrenme ile de 2. veri kümesinden faydalanılmıştır. Her aşamada veri sayısı düşerken çözülmesi gereken probleme daha yaklaşılmıştır.

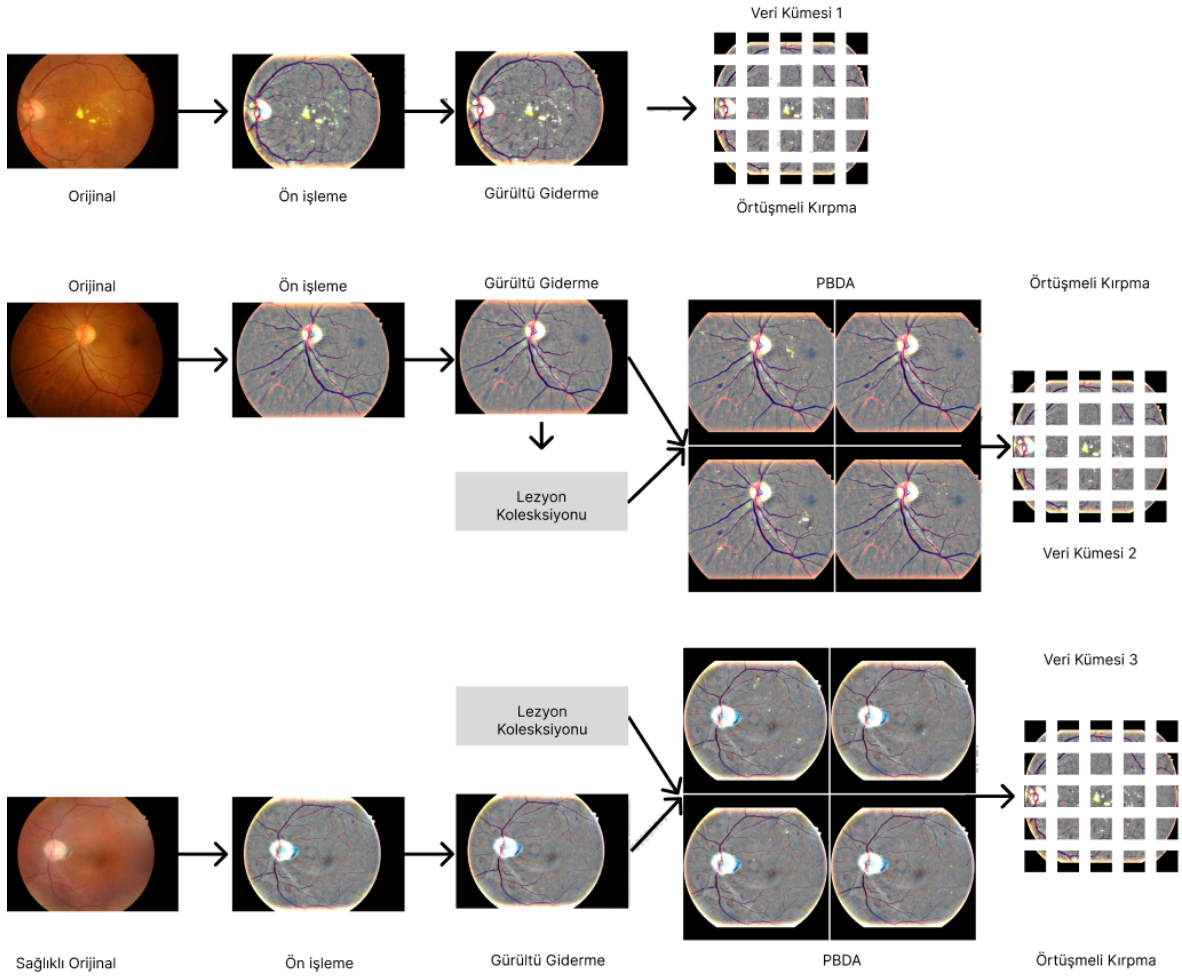
Eğitilen modeller UNetPlusPlus mimarisinde olup kodlayıcı bölümünde omurga olarak VGG19'un ilk 5 katmanı kullanılmaktadır. UNetPlusPlus modelinin iç içe geçmiş katmanlar yapısı da çözücü kısmını oluşturmaktadır. Modelin çıktısında aktivasyon fonksiyonu olarak sigmoid kullanılmaktadır. Bunun dışında model mimarisinde herhangi bir değişiklik yapılmadan eğitilmektedir.

Modellerin eğitimi sırasında Adam optimizasyon algoritması kullanılmış, kayıp fonksiyonu olarak kategorik çapraz entropi seçilmiş, öğrenme hızı otomatik olarak zamanlanmış, performans belirli bir süre değişmeyince öğrenme hızı 10 kat düşürülmüştür. Kırpma büyüklüğü 576x576 piksel olan görüntüler küme boyutu (batch size) 4 olarak kullanılmıştır.

5. DENEYSEL SONUÇLAR

Çalışma sırasında önceki bölümlerde açıklanmış olan yöntemler ayrı ayrı denenip izole deneylerle test edilmişlerdir. Bunun yanı sıra her 4 lezyon türü de bağımsız olarak test edilip sonuçları sunulmuştur. Her bir lezyon için kırpmanın, örtüşmeli kırpmanın, ön işleme tekniğinin, gürültü giderme tekniğinin, PBDA yönteminin ve sağlıklı fotoğrafların kullanılmasının etkisi listelenmiştir. Deney sonuçları aşağıdaki metrikler üzerinden sunulmuştur: Doğruluk (accuracy), duyarlılık (recall), kesinlik (precision), F skoru, IoU, kesinlik duyarlılık eğrisi altında kalan alan (auc_pr).

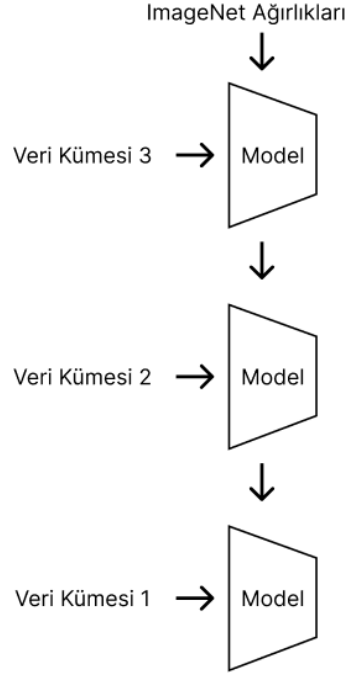
Üretilen veri setlerine ait blok diyagram Şekil 5.1’de görülürken, 3 aşamalı model eğitime ait blok diyagram ise Şekil 5.2’de gösterilmiştir. Veri kümelerinden ilk önce en temel olanı hazırlanmış, daha sonra PBDA yöntemiyle üretilmiş olan veriler kullanılarak ikinci veri kümesi hazırlanmıştır. İkinci veri setinin hazırlanması sırasında lezyon koleksiyonu da oluşturulmuştur. Daha sonra bu lezyon koleksiyonu sayesinde sağlıklı yani lezyon bulundurmeyen görüntülere de lezyon eklenmiş ve üçüncü veri seti oluşturulmuştur.



Şekil 5.1 Veri kümelerinin oluşturulmasına dair blok diyagram

Modeller farklı zamanlarda farklı donanımlar üzerinde eğitilmiştir. Bunlardan ilki aşağıdaki özelliklere ve zamanlamaya sahiptir.

Yalnızca görüntü işleme ve gürültü giderme adımlarının model başarısına etkisinin test edildiği küçük çaplı eğitimler için ayrı bir donanım kullanılmıştır. 8 GB görüntü belleğine sahip NVIDIA GeForce RTX 2070 GPU kartı ve 6 çekirdekli 2.6 GHz Intel Core i7-9750H CPU'ya sahip bir donanımdır. Görüntü işleme fonksiyonları bu donanımda geliştirilip veri kümesinin işlenmesi tamamlanmıştır. Diğer donanımlarda ise kayıt edilmiş olan bu veriler kullanılmıştır. Yine aynı amaçla 8 GB görüntü belleğine sahip NVIDIA GeForce RTX 3070 Ti GPU kartı ve AMD Ryzen 5 5600X CPU içeren donanım da kullanılmıştır.



Şekil 5.2 Model eğitiminin farklı aşamalarına dair blok diyagram

Asıl modeller aşağıdaki donanım üzerinde eğitilip verilen zaman maliyetine sahiptir. 16 GB görüntü belleğine sahip Tesla V100-SXM2 GPU kartı, 40 çekirdekli 2.20GHz çalışma frekansında Intel(R) Xeon(R) CPU'ya sahip donanım kullanılmaktadır. Kırpma büyüklüğü 576x576 piksel olan görüntüler küme boyutu (batch size) 4 olarak kullanıldığında her eğitim döngüsü (epoch) 2.5 dakika sürmektedir. Herhangi bir veri kümesi çoğaltma yöntemi kullanılmadan toplam eğitim süresi 60 döngü için 2.5 saate tekabül etmektedir. Eğer örtüşmeli kırpma kullanılırsa veri sayısının artmasından dolayı her döngü 10 dakika sürmektedir ve 42 döngü için toplam 7 saat eğitim süresi gerekmektedir. Bu görüntülerden hiç lezyon barındırmayanlar elendiğinde eğitim süresi 5 saate düşürülebilmektedir. PBDA yöntemiyle veri sayısı çoğaltıldığında uygulanan çoğaltma miktarına bağlı olarak döngü süresi artmaktadır. Fakat daha az döngüde model stabil hale ulaşmaktadır. Bu nedenle eğitim süresi yine 5 ila 6 saat aralığında kalmaktadır. Sağlıklı verilerde PBDA yönteminin kullanılmasıyla elde edilen veri kümesi en büyük veri kümesidir. Bu veri kümesinin kullanıldığı her döngü 2 saat sürmektedir, toplamda 5 döngü eğitildiğinde 10 saatlik eğitim süresi görülmektedir. Tüm bu veri kümelerinin arka arkaya kullanılmasıyla eğitilen aşamalar birbirine eklendiğinde toplamda 18 saate yakın bir eğitim süresi gerektirmektedir. Son olarak

modeller bulut tabanlı bir servis olan Google Colab üzerinde eğitilmiştir. Google Colab'ın sunduğu farklı uç birimler ve bu birimlere ait eğitim süreleri aşağıdaki gibi olmuştur. 16 GB görüntü belleğine sahip Tesla V100-SXM2 GPU kartı, 8 çekirdekli 2.0GHz çalışma frekansında Intel(R) Xeon(R) CPU'ya sahip donanım kullanılmıştır. Kırpma büyüklüğü 576x576 piksel olan görüntüler küme boyutu (batch size) 4 olarak kullanıldığında her eğitim döngüsü (epoch) 2.5 dakika sürmüştür. Dolayısıyla zamanlamalar yukarıda verilen donanımla aynı olmuştur.

40 GB görüntü belleğine sahip NVIDIA A100-SXM4 GPU kartı, 12 çekirdekli 2.20GHz çalışma frekansında Intel(R) Xeon(R) CPU'ya sahip donanım kullanılmıştır. Kırpma büyüklüğü 576x576 piksel olan görüntüler küme boyutu (batch size) 4 olarak kullanıldığında her eğitim döngüsü (epoch) 1.5 dakika sürmüştür. Herhangi bir veri kümesi çoğaltma yöntemi kullanılmadan toplam eğitim süresi 60 döngü için 1.5 saate tekabül etmiştir. Diğer bütün deneyler de yukarıda anlatılan sürelerle orantılı olarak gerçekleşmiştir. Günlük 1000 TL olan maliyeti nedeniyle tüm aşamaları içeren bir deney bu donanımda yapılmamıştır.

5.1. Mikroanevrizma Sınıfına Ait Sonuçlar

5.1.1. Kırpmanın Etkisi

Tablo 5.1'de farklı kırpma büyüklükleri için eğitilen modellerin performans değerleri verilmiştir. İlk satır 288x288, ikinci satır 576x576 ve son satır da 1152x1152 piksellik kırpma boyutlarını temsil etmektedir. Bu boyutlar orijinal resmi sırasıyla 18x18, 9x9 ve 3x3 küçük resimlere bölmeye tekabül etmektedir. En yüksek performans veren 3 boyut Tablo 5.1'deki gibidir. Çok büyük boyutlar düşük performans verdiği gibi çok küçük boyutlar da sadece lokal bilgiyle sınırlı kaldığından iyi performans verememektedirler. Her iki ekstrem uçtan da kaçınılması gerektiği görülmüştür. Bu deneyde optimum boyutun 576x576 olduğu gözlemlenmiştir.

Şekil 5.3'te kırılmamış bir fundus görüntüsü bulunmaktadır. Şekil 5.4'te ve 5.7'de farklı boyutlara kırılmış görüntüler bulunmaktadır. Bu görüntülere ait model çıktıları Şekil 5.5


kırpma boyutu	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
288	0.6707	0.4729	0.3096	0.4846	0.4616	0.4670
576	0.7331	0.4985	0.3432	0.55439	0.4528	0.4948
1152	0.7670	0.4691	0.3077	0.5682	0.3995	0.3650

Tablo 5.1 Farklı boyutlarda kırılan görüntülerin model performansına etkileri.


ve 5.8’de verilmiştir. Şekil 5.6 ve 5.9’da ise bu kırılmış çıktıların tekrar birleştirilmesiyle oluşan tam boyutlu çıktılar ve bu çıktıların etiketlerle karşılaştırılması verilmiştir.




Şekil 5.3 Kırılmamış bir retina görüntüsü.




Şekil 5.4 1152x1152'lik alanlara kırılmış bir retina görüntüsü.




Şekil 5.5 1152x1152'lik alanlara kırılmış bir retina görüntüsü üzerinde yapılan tahminler.




Şekil 5.6 1152x1152'lik alanlara kırpılmış bir retina görüntüsü üzerinde yapılan tahminlerin renklendirilmiş hali. Yeşil renkler doğru pozitif, kırmızı renkler yanlış negatif, mavi renkler ise yanlış pozitif ifade etmek için kullanılmıştır.



Şekil 5.7 288x288lik alanlara kırılmış bir retina görüntüsü. Sadece orta bölge bulunan görüntüler verilmiştir.



Şekil 5.8 288x288'lik alanlara kırılmış bir retina görüntüsü üzerinde yapılan tahminler.



Şekil 5.9 288x28'lik alanlara kırılmış bir retina görüntüsü üzerinde yapılan tahminlerin renklendirilmiş hali. Yeşil renkler doğru pozitif, kırmızı renkler yanlış negatif, mavi renkler ise yanlış pozitif ifade etmek için kullanılmıştır.

5.1.2. Örtüşmeli Kırpmanın Etkisi


Tablo 5.2'de iki farklı modele ait deney sonuçları sunulmuştur. İlk satırdaki deneyde 576x576 boyutunda kırılan görüntülerle bir model eğitilmiştir. Modelin sonuçları test edilirken ise görüntüler birbiriyle örtüşecek şekilde verilmiştir. Böylece daha test sırasında kayan pencereler yoluyla örtüşmenin kazanımlarından faydalanılmıştır. İkinci satırla sunulan

deneyde ise tamamen aynı yöntemler uygulanmış olup yalnızca modelin eğitilmesi sırasında bir farklılık vardır. Çünkü yalnızca test sırasında değil eğitim sırasında da örtüşen görüntüler kullanılmıştır. Elde edilen sonuçlara göre kırılan görüntülerin birbiriyle örtüşen kısımlarının bulunmasının daha iyi performans sağladığı görülmüştür.

kırpma boyutu	kaydırma	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
576	576	0.7331	0.4985	0.3432	0.5543	0.4528	0.4948
576	288	0.7443	0.5068	0.3508	0.5703	0.4560	0.5120

Tablo 5.2 Örtüşmeli kırpma yönteminden önceki ve sonraki performans değerleri.

Modelin görüntünün kenarlarından kötü etkilendiğini göstermek için Şekil 5.10'da bulunan görsel oluşturulmuştur. Bu görsel modelin gerçek çıktısı değildir. Örtüşmeli kırpma olmaksızın birleştirilen görüntü üzerinden oluşturulmuştur. Modelin çıktısındaki aktivasyon değerlerinden belli bir aralıkta kalan kısmının görselleştirilmesi yapılmıştır. Modelin görüntünün kenarlarındaki alanlarda daha fazla tepki verdiği belli olmuştur. Görüntüdeki 9 farklı bölgenin sınırları gözlemlenebilmektedir.



Şekil 5.10 Örtüşme olmaksızın kırılan görüntülerin eğitilen modellerde neden olduğu problemi gösteren görsel


5.1.3. Önışleme Tekniğinin Etkisi

Önışleme tekniği mikroanevrizmalarda performansın artmasını sağlamıştır. Ön işleme tekniğinin elde edilen performans metriklerine yansması Tablo 5.3'te verilmiştir. Bir önceki aşamada seçilen en iyi modele uygulanmıştır.

ön işleme	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
Yok	0.7443	0.5068	0.3508	0.5703	0.4560	0.5120
Var	0.7853	0.4983	0.3538	0.6072	0.4225	0.5239

Tablo 5.3 Ön işleme tekniğinin öncesi ve sonrasına ait performans değerleri.

Ön işleme algoritmasının sonuca etkisine görsel bir örnek Şekil 5.11’de verilmiştir. Üst sırada orijinal görüntü ve ilgili modelin çıktısı verilirken alt sırada ön işlenmiş görüntüye ait görseller verilmiştir. Görselde orijinal görüntüde model tarafından tespit edilemeyen bir mikroanevrizmanın ön işlenmiş görüntüde tespit edildiği görülmektedir.



Şekil 5.11 (a) Orijinal görüntüden bir kesit (b) Orjinal görüntüyle eğitilmiş modelin çıktısı (c) Aynı kesitin ön işlenmiş görüntüsü (d) İlgili modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir.


5.1.4. Gürültü Giderme Tekniğinin Etkisi

Gürültü giderme tekniği hali hazırda ön işleme yapılmış görüntülere uygulanmıştır. 5.1.3. Bölüm’de seçilen en iyi modele uygulanan tekniğin sonuçları Tablo 5.4’te görülmektedir. Tablodaki ilk satır 5.1.3. Bölüm’de seçilen en iyi modelin performans değerlerini listelerken ikinci satır ise diğer her şey aynı kalmak koşuluyla gürültüsü giderilmiş görüntüler üzerinden eğitilmiş ikinci bir modelin performans değerlerini listeler. Gürültü giderme yönteminin bu durumda iyi sonuçlar verdiği görülmüştür.

gürültü giderme	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
yok	0.7853	0.4983	0.3538	0.6072	0.4225	0.5239
var	0.8253	0.4819	0.3586	0.6451	0.3845	0.5297

Tablo 5.4 Gürültü giderme yönteminin öncesi ve sonrasına ait performans değerleri.

Gürültü giderme algoritmasının sonuca etkisine görsel bir örnek Şekil 5.12’de verilmiştir. Üst sırada ön işlenmiş görüntü ve ilgili modelin çıktısı verilirken alt sırada gürültüsü giderilmiş görüntüye ait görseller verilmiştir. Görselde ön işlenmiş görüntüde model tarafından tespit edilemeyen bir mikroanevrizmanın gürültüsü giderilmiş görüntüde tespit edildiği görülmektedir. Aynı görselde gürültü gidermenin negatif bir etkisi olarak yanlış pozitiflerin arttığı da gözlemlenmektedir. Gürültü giderme bazı durumlarda ise lezyonu silerek yanlış negatifleri de artırabilmektedir. Tüm bunlara rağmen yine de toplamda pozitif etkiye yol açmıştır.



Şekil 5.12 (a) Ön işlenmiş görüntüden bir kesit (b) Ön işlenmiş görüntüyle eğitilmiş modelin çıktısı (c) Aynı kesitin gürültüsü giderilmiş görüntüsü (d) İlgili modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir.

5.1.5. PBDA Yönteminin Etkisi

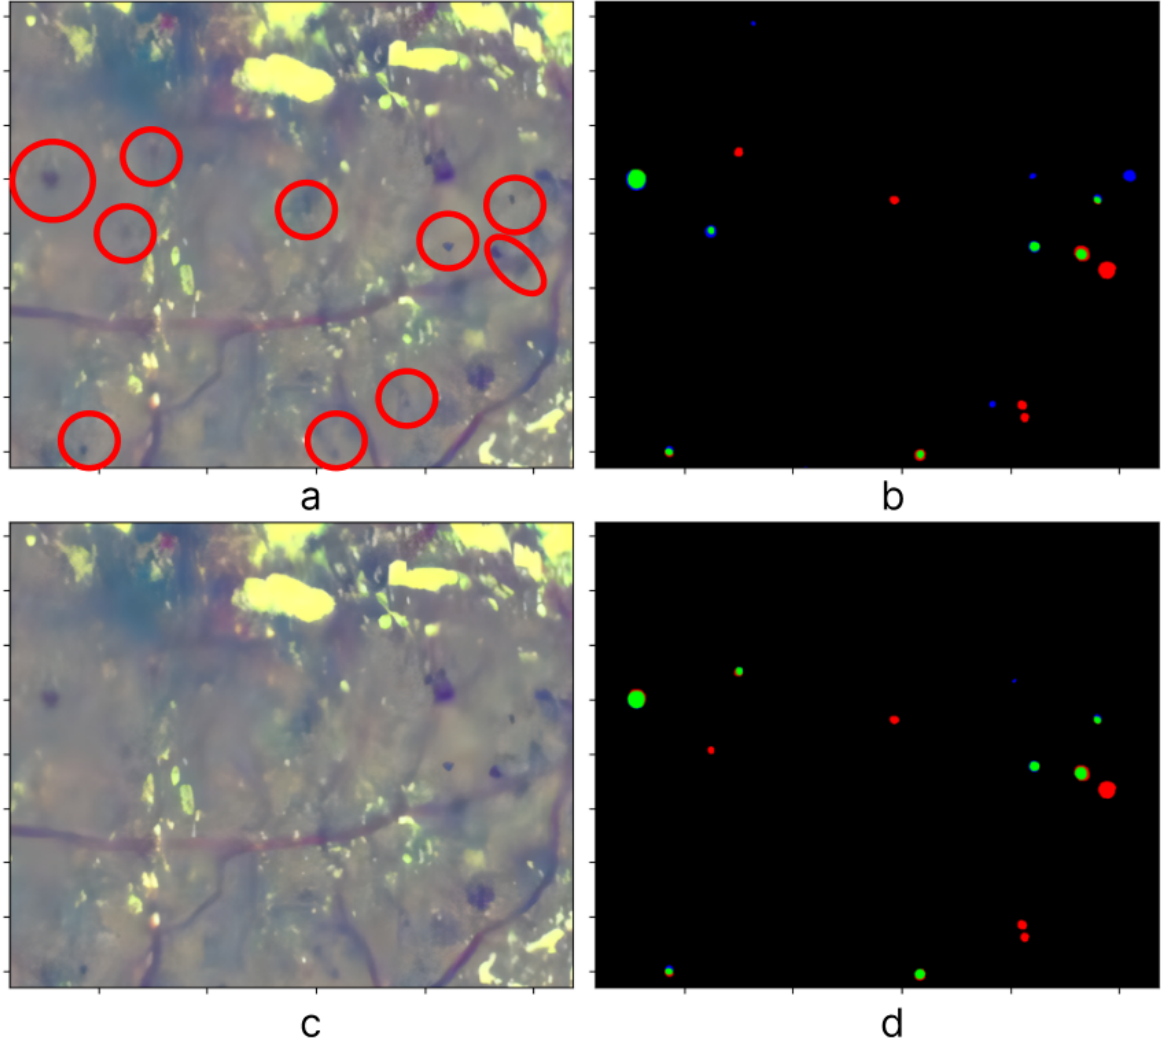
PBDA yöntemiyle çoğaltılan veri kümesi kullanılarak bir model eğitilmiştir. PBDA yönteminin elde edilen performans metriklerine yansımaları Tablo 5.5'te verilmiştir. Aslında

F skorunda bir artış görülmemesine rağmen modelin daha kendinden emin tahminler ürettiği PR eğrisinin altında kalan alan metriğinden anlaşılmaktadır.

pbda	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
Yok	0.8253	0.4819	0.3586	0.6451	0.3845	0.5297
Var	0.8331	0.4764	0.3238	0.6521	0.3752	0.5454

Tablo 5.5 PBDA yönteminin öncesi ve sonrasına ait performans değerleri.

PBDA yönteminin sonuca etkisine görsel bir örnek Şekil 5.13'te verilmiştir. Üst sırada gürültüsü giderilmiş görüntü ve ilgili modelin çıktısı verilmiştir. Alt sırada ise girdi olarak yine gürültüsü giderilmiş görüntü fakat çıktı olarak PBDA yönteminin sonucunda elde edilen görsel verilmiştir. Görselde üst sıradaki çıktıda maviyle belirtilen yanlış pozitiflerin olduğu görülmüştür. Alt sırada ise tabloda da görüldüğü gibi keskinliğin arttığı yani mavi noktaların azaldığı görülmektedir.



Şekil 5.13 (a) Gürültüsü giderilmiş görüntüden bir kesit (b) PBDA yöntemi öncesi eğitilmiş modelin çıktısı (c) Gürültüsü giderilmiş görüntüden alınan aynı kesit (d) PBDA yöntemi sonrası eğitilmiş modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir.

5.1.6. Sağlıklı Verilerin Etkisi

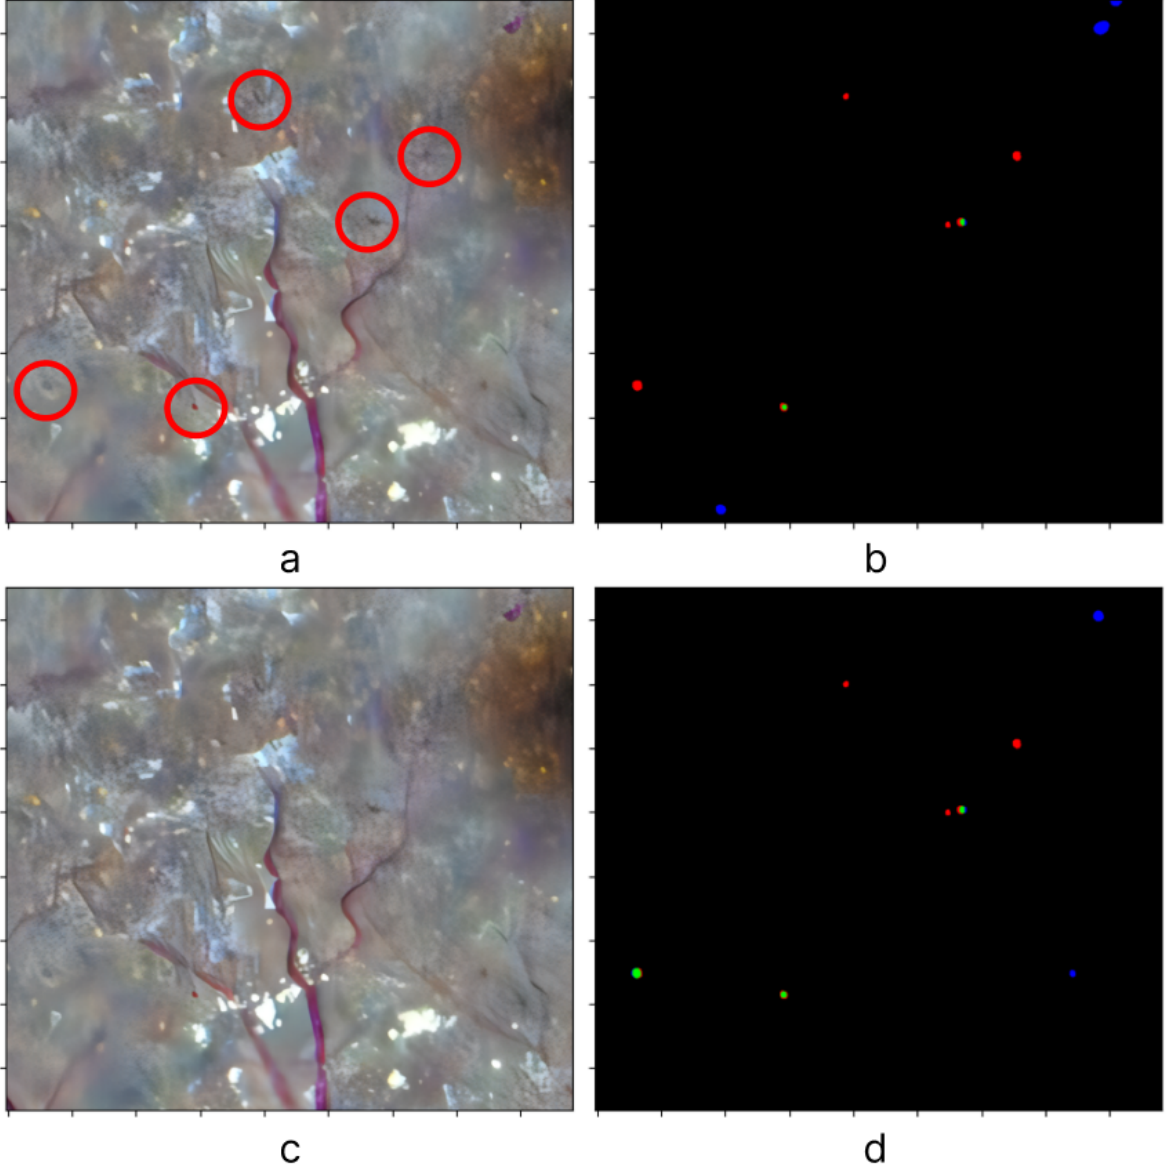
Sağlıklı retina görüntülerinin kullanımıyla daha da fazla veri üretimi imkânı oluşmuştur. PBDA yöntemi yalnızca 54 adetten oluşan veri kümesine uygulanmak yerine 168 adet yeni veriye de uygulanmıştır. Bu sağlıklı verilerin sayısı fazla olmasına rağmen üretilen veriler gerçekçi değildir. Bu nedenle önce sağlıklı verilerin çoğaltılmasıyla oluşturulan veri kümesiyle eğitilen model, daha sonra sırasıyla PBDA yöntemiyle elde edilen veri kümesinde

ve son olarak gürültüsü giderilmiş 54 orijinal veri üzerinde eğitilmiştir. Tablo 5.6’da bu işlemin performansa etkisi gösterilmiştir. Bütün metriklerde bir iyileşme görülmüştür.

deney	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
pbda	0.8331	0.4764	0.3238	0.6521	0.3752	0.5454
pbda + sağlıklı	0.8376	0.4831	0.3298	0.6623	0.3802	0.5646

Tablo 5.6 PBDA ile sağlıklı veri ekleme yönteminin öncesi ve sonrasına ait performans değerleri.

Sağlıklı verilerin eklenmesi yönteminin sonuca etkisine görsel bir örnek Şekil 5.14’te verilmiştir. Üst sırada gürültüsü giderilmiş görüntü ve ilgili modelin çıktısı verilmiştir. Alt sırada ise girdi olarak yine gürültüsü giderilmiş görüntü verilmiştir. Fakat çıktı olarak PBDA yönteminin sonucunda elde edilen görsel verilmiştir. Görselde genel olarak mavi noktaların ve kırmızı noktaların sayısının azaldığı yani yanlış pozitif ve yanlış negatiflerin azaldığı örneklenmiştir. Girdi olan görsellere dikkatli bakıldığında gürültü giderme yöntemi nedeniyle bazı mikroanevrizmaların artık anlaşılabilir hale geldiği de gözlemlenmektedir. Dolayısıyla bu yöntemin de limitlerine ulaşıldığı öngörülmektedir.



Şekil 5.14 (a) Gürültüsü giderilmiş görüntüden bir kesit (b) Sağlıklı verilerin öncesi eğitilmiş modelin çıktısı (c) Gürültüsü giderilmiş görüntüden alınan aynı kesit (d) Sağlıklı verilerin eklenmesi sonrası eğitilmiş modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir.

5.2. Eksudat Sınıfına Ait Sonuçlar

5.2.1. Kırpmanın Etkisi

Farklı kırpma boyutları arasında en iyi 2 tanesinin karşılaştırması Tablo 5.7’de sunulmuştur. 576x576 boyutları mikroanevrizmalarda olduğu gibi eksudatlarda da optimum performans değerlerini göstermiştir.

kırpma boyutu	auc_pr	f skoru	doğruluk	kesinlik	duyarlılık	iou
576	0.8902	0.7998	0.9021	0.8719	0.7386	0.6664
1152	0.8231	0.7399	0.8761	0.8258	0.6701	0.6015

Tablo 5.7 Kırpma boyutu 576x576 ve 1152x1152 piksel olan modellerin karşılaştırması.

5.2.2. Örtüşmeli Kırpmanın Etkisi


Tablo 5.8’de iki farklı modele ait deney sonuçları sunulmuştur. İlk satırdaki deneyde 576x576 boyutunda kırılan görüntülerle bir model eğitilmiştir. Modelin sonuçları test edilirken ise görüntüler birbiriyle örtüşecek şekilde verilmiştir. Böylece daha test sırasında örtüşmenin kazanımlarından faydalanılmıştır. İkinci satırla sunulan deneyde ise tamamen aynı yöntemler uygulanmış olup yalnızca modelin eğitilmesi sırasında bir farklılık vardır. Çünkü yalnızca test sırasında değil eğitim sırasında da örtüşen görüntüler kullanılmıştır. Elde edilen sonuçlara göre kırılan görüntüler birbiriyle örtüşen kısımlarının bulunmasının daha iyi performans sağladığı görülmüştür.

kaydırma	auc_pr	f skoru	doğruluk	kesinlik	duyarlılık	iou
576	0.8902	0.7998	0.9021	0.8719	0.7386	0.6664
288	0.8944	0.8121	0.8697	0.8399	0.7861	0.7433

Tablo 5.8 Örtüşmeli kırpma yönteminden önceki ve sonraki performans değerleri.

Örtüşmeli kırpmanın sonuca etkisine görsel bir örnek Şekil 5.15’te verilmiştir. Üst sırada orijinal görüntü ve ilgili modelin çıktısı verilmiştir. Alt sırada ise girdi olarak yine orijinal görüntü verilmiştir. Fakat çıktı olarak örtüşmeli kırpma yönteminin sonucunda elde edilen görsel verilmiştir. Görseldeki üst sırada kırılan alanların birleştiği yerler kolayca

seçilebilmektedir. Kırpılan alanların kenarlarında modelin performansının kötü olduğu görülmektedir. Alt satırda ise bu sorunun ortadan kalktığı, görüntülerin birleşme yerlerinin belli bile olmadığı gözlemlenmektedir.



Şekil 5.15 (a) Orijinal görüntüden bir kesit (b) Örtüşmeli kırpma öncesi eğitilmiş modelin çıktısı (c) Orijinal görüntüden alınan aynı kesit (d) Örtüşmeli kırpma sonrası eğitilmiş modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir.


5.2.3. Ön İşleme Tekniğinin Etkisi

Ön işleme tekniği mikroanevrizmalardaki gibi eksudat lezyonunda da performansın artmasını sağlamıştır. Ön işleme tekniğinin elde edilen performans metriklerine yansımaları Tablo 5.9'da verilmiştir.

ön işleme	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
yok	0.7998	0.9021	0.8719	0.7386	0.6664	0.8902
var	0.8132	0.8823	0.8535	0.7766	0.6852	0.8972

Tablo 5.9 576 kırpma boyutu için ön işleme algoritmasının sonrası ve öncesine ait performans değerleri.

Ön işlemenin sonuca etkisine görsel bir örnek Şekil 5.16'da verilmiştir. Üst sırada orijinal görüntü ve ilgili modelin çıktısı verilmiştir. Alt sırada ise girdi olarak ön işlenmiş görüntü verilmiştir. Çıktı olarak ise ilgili modelin eğitilmesi sonucunda elde edilen görsel verilmiştir. Görseldeki ön işleme öncesi ve sonrası çıktılar karşılaştırıldığında büyük oranda iyileşme gözlemlenmektedir. Fakat yine görsellerde ön işleme nedeniyle retina alanının kenarlarının ağardığı gözlemlenmektedir. Ön işlemenin çıktısının bu bölgeye yakın kısımda daha kötü performansa sebep olduğu gözlemlenmektedir.



Şekil 5.16 (a) Orijinal görüntüden bir kesit (b) Orjinal görüntüyle eğitilmiş modelin çıktısı (c) Aynı kesitin ön işlenmiş görüntüsü (d) İlgili modelin çıktısı. Çıktılardaki yeşil renk doğru pozitif, mavi renk yanlış pozitif, kırmızı renk ise yanlış negatif temsil etmektedir.

5.2.4. Gürültü Giderme Tekniğinin Etkisi

Gürültü giderme tekniği farklı kırpma büyüklükleri için farklı etkilere yol açmıştır. Tablo 5.10'da görüldüğü üzere 1152x1152 kırpma büyüklüğü için performansı artırırken Tablo 5.11'de ise 576x576 kırpma büyüklüğü için performansın düşmesine yol açmıştır.

gürültü giderme	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
yok	0.7399	0.8761	0.8258	0.6701	0.6015	0.8231
var	0.7645	0.8607	0.8162	0.7189	0.6341	0.8497

Tablo 5.10 1152 kırpma boyutu için gürültü giderme işleminin öncesi ve sonrası.

gürültü giderme	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
yok	0.7998	0.9021	0.8719	0.7386	0.6664	0.8902
var	0.7983	0.8519	0.8177	0.7798	0.6643	0.8810

Tablo 5.11 576 kırpma boyutu için gürültü giderme işleminin öncesi ve sonrası.

5.2.5. PBDA Yönteminin Etkisi

PBDA yöntemi eksudatlardaki performansın artmasını sağlamıştır. Tablo 5.12’de performans üzerindeki etkisi görülmektedir.

deney	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
normal	0.7998	0.9021	0.8719	0.7386	0.6664	0.8902
pbda	0.8174	0.8800	0.8520	0.7855	0.7526	0.9019

Tablo 5.12 PBDA yönteminin öncesi ve sonrasına ait performans değerleri.

5.2.6. Sağlıklı Verilerin Etkisi

Sağlıklı verilerin kullanımı modelin performansında kayda değer bir gelişme yaratmadığı gibi ortalama performansı da düşürmüştür. Tablo 5.13’te bu yöntemin etkisinin sonuçları sunulmuştur.

deney	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
pbda	0.8174	0.8800	0.8520	0.7855	0.7526	0.9019
sağlıklı	0.8042	0.9060	0.8774	0.7423	0.7345	0.8959

Tablo 5.13 Sağlıklı verilerin dahil edilmesinin performansa etkisi.

5.3. Hemoraji Sınıfına Ait Sonuçlar

5.3.1. Kırpmanın Etkisi

288x288, 576x576, 1152x1152 kırpma büyüklükleriyle yapılan deneylerde 576x576 boyutunun diğerlerine karşı bariz bir üstünlük sağladığı görülmüştür. Eksudat ve Mikroanevrizmalarda da görüldüğü üzere 576x576'nın optimum boyut olduğu keşfedilmiştir. Tablo 5.14'te bu deneyler ve elde edilen sonuçlar listelenmiştir.

kırpma boyutu	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
288	0.4753	0.5864	0.4298	0.5316	0.3117	0.3945
576	0.5292	0.7395	0.5801	0.4865	0.3598	0.5620
1152	0.3626	0.5469	0.3283	0.4049	0.2311	0.3680

Tablo 5.14 Farklı kırpma büyüklükleri için elde edilen performans değerleri.

5.3.2. Örtüşmeli Kırpmanın Etkisi

Tablo 5.15'te 3 farklı durum için elde edilen sonuçlar listelenmiştir. İlk satır 5.3.1. Bölüm'de listelenmiş olan normal 576x576 piksel boyutlarda kırılmış veri kümesine ait sonuçları içermektedir. İkinci satır ise yine tamamıyla aynı modele aittir. Fakat bu kez modelin tahminleri kesişmeyen pencereler üzerinden değil kesişen pencereler üzerinden oluşturulmuştur. Böylece yeni bir model eğitilmeden sonuçlar iyileştirilmiştir. Son satırda ise yeni bir model kesişen pencerelerin olduğu bir veri kümesiyle eğitilmiştir. Yani son aşamada hem eğitim hem de test sırasında örtüşen pencerelerden faydalanılmıştır. Böylece performansta iyileşmeler sağlandığı gösterilmiştir.

kırpma boyutu	kaydırma	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
576	576	0.5292	0.7395	0.5801	0.4865	0.3864	0.5620
576	576	0.5604	0.7520	0.6108	0.5176	0.4128	0.6047
576	288	0.5874	0.7902	0.6647	0.5263	0.4352	0.6322

Tablo 5.15 Örtüşmeli kırpmanın etkisi.

5.3.3. Ön İşleme Tekniğinin Etkisi

Öne sürülen ön işleme tekniği diğer lezyonların aksine hemoraji lezyonunda performansın bir miktar düşmesine neden oldu. Tablo 5.16’da 5.3.2. Bölüm’de verilen en iyi modelin ön işleme tekniği uygulanınca gösterdiği performans verilmiştir.

ön işleme	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
yok	0.5874	0.7902	0.6647	0.5263	0.4352	0.6322
var	0.5760	0.7838	0.6518	0.5161	0.4131	0.6119

Tablo 5.16 Ön işleme tekniğinin öncesi ve sonrasına ait performans değerleri.

5.3.4. Gürültü Giderme Tekniğinin Etkisi

Ön işleme tekniğinin hemoraji başarısını düşürdüğü 5.3.3. Bölüm’de görülmüştür. Bunun üzerine görüntülere gürültü gidermenin de uygulanmasıyla performans genel olarak daha da düşerek kötüleşmiştir. Fakat IoU skorunda kayda değer bir iyileşme görülmüştür. Tablo 5.17’de gürültü giderme yönteminin performansa etkisi görülmüştür.

gürültü giderme	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
yok	0.5760	0.7838	0.6518	0.5161	0.4131	0.6119
var	0.5736	0.7166	0.5866	0.5263	0.4611	0.6037

Tablo 5.17 Gürültü giderme tekniğinin öncesi ve sonrasına ait performans değerleri.

5.3.5. PBDA Yönteminin Etkisi

Ön işleme ve gürültü giderme yöntemlerinin bu lezyon için olumsuz etkileri olduğu gözlemlendiği için bu bölümde gerçekleştirilen deneyler verilerin orijinal halleri üzerinden yapılmıştır. Görüntülerin işlenmemiş halleriyle gerçekleştirilen eğitime ait sonuçlar Tablo 5.18’de verilmiştir. Tabloda ilk satırda herhangi bir işleme tabi tutulmamış verilerle eğitilen modelin performans metrikleri, ikinci satırda ön işlemeden geçirilmiş görüntülerle eğitilmiş modelin performans metrikleri, üçüncü satırda bir aşama daha işlenip gürültüsü giderilen modelin performans metrikleri, son satırda ise tıpkı ilk satırdaki gibi herhangi bir işleme tabi

tutulmamış görüntülerle eğitilen modelin performans metrikleri verilmiştir. Son satırdaki modelin ilk satırdaki modelden farkı PBDA yöntemi kullanılarak sentezlenen yeni verileri de eğitim kümesinde bulundurmasıdır.

deney	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
orjinal	0.5874	0.7902	0.6647	0.5263	0.4352	0.6322
ön işleme	0.5760	0.7838	0.6518	0.5161	0.4131	0.6119
gürültü giderme	0.5736	0.7166	0.5866	0.5263	0.4611	0.6037
orjinal + PBDA	0.5999	0.8180	0.7019	0.5238	0.4372	0.6441

Tablo 5.18 PBDA yönteminin öncesi ve sonrasına ait performans değerleri.

5.3.6. Sağlıklı Verilerin Etkisi

Sağlıklı verilerin eklenmesi hemoraji lezyonlarının daha iyi tespit edilmesini sağlamıştır. Tablo 5.19’da bu yönetime ait sonuçlar önceki durumlarla karşılaştırmalı olarak verilmiştir. Tabloda ilk satırda ve ikinci satırda verilen modeller 5.3.5. Bölüm’de verilen işlenmemiş görüntülerle eğitilen ve işlenmemişin yanında sentetik görüntülerle eğitilen modellere ait sonuçlardır. Son satır ise sağlıklı görüntülerin de sentezde kullanılmasıyla eğitilen modele ait sonuçlardır.

deney	f skoru	doğruluk	kesinlik	duyarlılık	iou	auc_pr
orjinal	0.5874	0.7902	0.6647	0.5263	0.4352	0.6322
orjinal + PBDA	0.5999	0.8180	0.7019	0.5238	0.4372	0.6441
orjinal + PBDA + sağlıklı	0.6156	0.8223	0.6998	0.5410	0.4518	0.6587

Tablo 5.19 PBDA yönteminin öncesi ve sonrasına ait performans değerleri.

5.4. Yumuşak Eksudat Sınıfına Ait Sonuçlar

Yumuşak eksudatlar bir diğer lezyon tipi olup pamukçuk lekeleri olarak da adlandırılmaktadır. Bunlar bir eksudat tipi olsa da görünüm olarak sert eksudat ve yumuşak eksudatlar farklıdır. Yumuşak eksudatlar diğer eksudatların aksine keskin doku sınırlarına sahip değildir. Renk olarak ise daha silik bir tona sahiplerdir. Veri kümesinde en az sayıda örneği bulunan lezyon yumuşak eksudatlardır.

5.4.1. Kırpmannın Etkisi

Farklı kırpma boyutları için orijinal veri kümesinde elde edilen sonuçlar Tablo 5.20’de verilmiştir. Tablodan görüldüğü üzere en iyi sonuçlar 288x288 boyutları kullanıldığında elde edilmiştir. Fakat diğer tüm lezyonlarda 576x576 boyutu en iyi çıkmıştır. Bu nedenle bu lezyon için de 576x576 piksellik boyutların kullanılmasına karar verilmiştir. Bu lezyon için daha sonraki bölümlerde verilen sonuçlar yine 576x576 piksellik kırpma kullanılarak oluşturulmuştur.

kırpma boyutu	batch	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
288	16	0.2220	0.2529	0.1447	0.1569	0.6518	0.3572
576	4	0.1922	0.2192	0.1230	0.1322	0.6402	0.2995
1152	1	0.2954	0.2143	0.1219	0.1455	0.4064	0.2613

Tablo 5.20 Farklı kırpma boyutları için elde edilen performans değerleri.

5.4.2. Örtüşmeli Kırpmannın Etkisi

Diğer lezyonlarda olduğu gibi yumuşak eksudatlarda da kırpılan görüntülerin birbiriyle örtüşecek şekilde olması performansı artırmıştır. Tablo 5.21’de iki farklı modele ait deney sonuçları sunulmuştur. İlk satırdaki deneyde 576x576 boyutunda kırpılan görüntülerle bir model eğitilmiştir. Modelin sonuçları test edilirken ise görüntüler birbiriyle örtüşecek şekilde verilmiştir. İkinci satırla sunulan deneyde ise tamamen aynı yöntemler uygulanmış olup sadece modelin eğitilmesi sırasında bir farklılık vardır. Çünkü yalnızca test sırasında değil eğitim sırasında da örtüşen görüntüler kullanılmıştır.

kırpma boyutu	kaydırma	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
576	576	0.1876	0.2191	0.1327	0.1315	0.6556	0.2982
576	288	0.3527	0.3192	0.2060	0.2269	0.5385	0.3214

Tablo 5.21 Örtüşen kırpma yönteminin öncesi ve sonrasında elde edilen performans değerleri.

5.4.3. Ön İşleme Tekniğinin Etkisi

5.4.2. Bölüm’de verilen iki modelin ön işleme tekniği kullanıldıktan sonraki performansları Tablo 5.22’de sunulmuştur. Ön işleme tekniği her iki model için de sonuçları bariz bir şekilde iyileştirmiştir.

kırpma	kaydırma	ön işleme	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
576	576	yok	0.1876	0.2191	0.1327	0.1315	0.6556	0.2982
576	576	var	0.3531	0.3668	0.2395	0.2577	0.6359	0.4503
576	288	yok	0.3527	0.3192	0.2060	0.2269	0.5385	0.3214
576	288	var	0.6743	0.4856	0.3375	0.4961	0.4756	0.4903

Tablo 5.22 Ön işleme tekniğinin farklı iki model üzerindeki etkileri.

5.4.4. Gürültü Giderme Tekniğinin Etkisi

Bu bölümde gürültü giderme yönteminin etkisi incelenmiştir. Önceki bölümlerde alınan sonuçlar literatürdeki çalışmaların gerisinde kaldığı için gürültü gidermeden önce başka yöntemlerle performansın iyileştirilmesi denenmiştir. Buna yönelik bir çözüm olarak veri kümesindeki yumuşak eksudat sınıfının dengeli olarak dağıtılması sağlanmıştır. Yumuşak eksudatlar boyut olarak büyük olsalar da sayıca çok azlardır. Bu nedenle veri kümesinde yeterince temsil edilmedikleri hipotezi üzerine ilerlenmiştir. Veri kümesinde arka plan olan yani hiçbir lezyonu barındırmayan alanlar diğer alanlardan çok daha fazladır. Bu nedenle herhangi bir lezyon barındırmayan bütün kırılmış görüntüler veri kümesinden çıkarılmıştır. Tablo 5.23’te böyle bir veri kümesiyle eğitilmiş iki modele ait sonuçlar listelenmiştir. Bu modeller 5.4.3. Bölüm’deki modellere göre daha yüksek performansa sahiplerdir. Tablonun ilk satırı orijinal görüntülerle eğitilen modelin performansını ortaya koyarken ikinci satırı ise gürültüsü giderilmiş görüntüler üzerinde eğitilen modelin performansını ortaya koymaktadır. Diğer lezyonlardaki durumun aksine bu lezyon için gürültü giderme yöntemi performansın düşmesine sebep olmuştur.

gürültü giderme	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
yok	0.8797	0.5127	0.3680	0.7414	0.3918	0.5559
var	0.6715	0.5365	0.3855	0.5274	0.5459	0.5380

Tablo 5.23 Gürültü giderme yönteminin öncesi ve sonrasına ait performans değerleri.

5.4.5. PBDA Yönteminin Etkisi

Gürültü giderme kullanılmamıştır. Tablo 5.24'te PBDA yönteminin öncesi ve sonrasına ait performans değerleri verilmiştir.

deney	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
Normal	0.8797	0.5127	0.3680	0.7414	0.3918	0.5559
PBDA	0.6570	0.6049	0.4644	0.5584	0.6600	0.6327

Tablo 5.24 PBDA yönteminin öncesi ve sonrasına ait performans değerleri.

5.4.6. Sağlıklı Verilerin Etkisi

Önce sağlıklı verilerin çoğaltılmasıyla oluşturulan veri kümesiyle eğitilen model, daha sonra sırasıyla PBDA yöntemiyle elde edilen veri kümesinde ve son olarak ön işlemeden geçirilmiş 54 orijinal veri üzerinde eğitilmiştir. Tablo 5.25'te bu işlemin performansa etkisi gösterilmiştir. Normal verilerle eğitilen modelle karşılaştırma yapıldığında f skoru, IoU ve AUC_PR metriklerinde bir iyileşme görülmüştür. Kesinlik ve duyarlılık metriklerinde birbirine zıt yönde büyük hareketler görülmüştür. PBDA yöntemi ile karşılaştırma yapıldığında ise bütün metriklerde iyileşme sağlandığı görülmektedir.

deney	doğruluk	f skoru	iou	kesinlik	duyarlılık	auc_pr
Normal	0.8797	0.5127	0.3680	0.7414	0.3918	0.5559
PBDA	0.6570	0.6049	0.4644	0.5584	0.6600	0.6327
PBDA + sağlıklı	0.6766	0.6259	0.4879	0.5848	0.6733	0.6813

Tablo 5.25 Sağlıklı verileri eklemenin öncesi ve sonrasına ait performans değerleri.


5.5. Bütün Sınıflara Ait Sonular ve Literatürle Karşılaştırılması

Bütün lezyonların birleştirilmiş sonuçları tablolarda sunulmuştur. Yarışmanın formatına uyularak hepsi PR grafiğinin altında kalan alan cinsinden verilmiştir. Tablo 5.26'da bütün lezyonların performans değerleri verilmiş, Tablo 5.27'de ise diğer çalışmalarla karşılaştırılması verilmiştir. Birinci sırada olanlar kalın ikinci sırada olanlar altı çizili olarak gösterilmiştir.

Lezyon Tipi	EX	HE	MA	SE	Ortalama
auc_pr	0.9019	0.6587	0.5646	0.6813	0.7016

Tablo 5.26 Bütün sınıflara ait sonuçların toplu gösterimi. EX: eksudatlar, HE: hemorajiler, MA: mikroanevrizmalar, SE: yumuşak eksudatlar anlamına gelmektedir.

Bütün lezyonlara ait sonuçların görselleştirilmesi Şekil 5.17'de verilmiştir. Sırasıyla orijinal resim, eksudat, hemoraji, mikroanevrizma ve yumuşak eksudat sütunları sunulmuştur. Her bir satır farklı bir test kümesi verisine aittir.



Şekil 5.17 Toplu sonuçlara ait görseller. Her bir satır farklı bir retina görüntüsüne ait lezyon çıktılarını göstermektedir.

Metod /AUPR (%)	EX	HE	MA	SE	Ortalama
L-Seg	79.45	63.74	46.27	71.13	65.15
Local-Global UNets	88.90	70.30	52.50	67.90	69.90
VRT	71.27	68.04	49.51	69.95	64.69
PATech	88.50	64.90	47.40	–	–
iFLYTEK-MIG	87.40	55.88	50.17	65.88	64.84
PBDA	86.43	71.53	53.41	73.07	71.11
PBDA (UNet++)	81.04	64.08	49.17	68.88	65.48
Önerilen Yöntem	90.19	65.87	56.46	68.13	<u>70.16</u>

Tablo 5.27 Önerilen yöntemin literatürdeki diğer yöntemlerle IDRiD veri kümesi üzerinde karşılaştırması. EX: eksudatlar, HE: hemorajiler, MA: mikroanevrizmalar, SE: yumuşak eksudatlar anlamına gelmektedir.

6. DEĞERLENDİRME

Bu çalışma kapsamında Diyabetik Retinopati hastalığında görülen lezyonların retina görüntülerinden bölütleme yoluyla işaretlenmesi gerçekleştirilmiştir. Bu lezyonlar hastalığın evresinin belirlenmesinde kullanılmaktadır ve doktorlar tarafından düzenli olarak incelenmektedir. Yakın zamanda doktorların bu inceleme işlemine harcadığı mesaiyi azaltmak ve insan kaynaklı hataları minimuma indirmek için yapay zekâ temelli hastalık sınıflandırma sistemleri geliştirilmeye başlanmıştır. Bu sistemler temelde 4 ana lezyon olan mikroanevrizma, eksudat, hemoraji ve yumuşak eksudatı tespit edip kullanmalıdırlar. Kimi sistemler uçtan uca bir sınıflandırma modeli eğitip bu lezyonların örtülü bir şekilde öğrenilmesini hedeflemişlerdir kimi sistemler ise doğrudan bu lezyonları tespit eden veya bölütleyen mekanizmalar kullanmışlardır. Literatürde de bu hastalığın çalışılabilmesi amacıyla yarışmalar düzenlenip veri kümeleri oluşturulmuştur. Bunların en yaygın kullanılanı ve en kapsamlı olanı IDRiD veri kümesidir. Bu çalışma kapsamında literatürde sıklıkla kullanılan IDRiD veri kümesi üzerinde test edilen yöntemler öne sürülmüştür.

Hastalığın doğası gereği ilk ortaya çıkan bulgular mikroanevrizmalardır. Mikroanevrizmaların efektif bir şekilde bölütlenmesi hastalığın ilk evresinin efektif bir şekilde tespit edilmesi anlamını taşımaktadır. Sağlıklı bir insan ile DR başlangıcı olan insan arasındaki bu hassas fark en önem arz eden lezyonun mikroanevrizma olduğunu

göstermektedir. Her ne kadar en önemli lezyon olsa dahi literatürdeki çalışmalarda diğer lezyonlar arasında en düşük skorlara sahip olan yine mikroanevrizmalardır. Bunun ana sebebi mikroanevrizmaların boyut olarak çok küçük olmasıdır. Bu hem düşük çözünürlüklerde yok olmalarına hem de yüksek çözünürlük olsa dahi çok az pozitif piksel bulunması sebebiyle veri dağılımı dengesizliğine sebep olmaktadır. Literatürde bu sorunların üzerinden gelmek için çeşitli ön işleme teknikleri, modeller ve eğitim yöntemleri kullanılmıştır.

Bu çalışma kapsamında IDRİD veri kümesi üzerinde mikroanevrizmalar ana hedef olmak üzere bütün lezyonların bölütlenmesi gerçekleştirilmiştir. Öne sürülen yöntem literatürdeki ön işleme tekniklerinin geliştirilmesi adımıyla başlamaktadır. Daha sonra ön işleme yönteminin devamı olarak gürültü giderme aşaması eklenmiştir. Literatürde de denenilen kayan pencereler yöntemi kullanılarak görüntüler kırılmış, bu sayede veri sayısı artırılmıştır. En önemlisi literatürdeki yeni veri türetme yöntemi olan PBDA yönteminden faydalanılmıştır. Bu yöntem bir adım ileriye götürülerek sağlıklı retina görüntülerinden de veri türetilmiştir. Daha sonra aktarmalı öğrenme yöntemi kullanılarak modeller 3 aşamada eğitilmiştir.

Yapılan deneyler sonucunda görüntülerin 576x576 piksel boyutlarında kırılmasının sonuçları iyileştirdiği görüldü. Kayan pencereler yönteminin de işe yaradığı gösterildi. Ön işleme yönteminin hemoraji lezyonları hariç sonuçları iyileştirdiği gösterildi. Gürültü giderme yönteminin ise mikroanevrizmalarda iyileşme sağladığı görüldü. Yine gürültü işleme yönteminin eksudatların bazı modelleri için işe yaradığı görüldü. Diğer lezyonlar için ise sonuçları kötüye götürdü. Bunun temel sebebi gürültü gidermenin bazı lezyon bölgelerini belirginleştirirken bazılarını silmesidir. Keskin sınırları olmayan yumuşak eksudat gibi yapıların bazı durumlarda kayıp olmasına sebep olmaktadır. PBDA yöntemi bütün lezyonların performansını artırmıştır. Sağlıklı görüntülerin veri türetmede kullanılması ise eksudatlar hariç bütün lezyonlarda işe yaramıştır. PBDA çalışmasında veri üretmenin dışında yeni model de geliştirilmiştir. Bu çalışmada ise geliştirilen model kullanılamamıştır, onun yerine UNet++ modeli kullanılarak sonuçlar elde edilmiştir. PBDA çalışması şu ana kadar en iyi skor ortalamasını elde eden çalışmadır. Bu çalışmada öne sürülen

yöntem mikroanevrizma ve eksudatlarda PBDA çalışmasından daha başarılı sonuçlar elde etmiştir. Çalışma kapsamında kullanılan UNet++ modeli ise bütün metriklerde PBDA çalışmasındaki muadili olan modeli geçmiştir. Öne sürülen yöntemler bu çalışma içerisinde gösterilmemesine rağmen özellikle kapasitesi düşük modellerde daha da belirgin farklar yaratmıştır.

Sonuç olarak öne sürülen yöntem genel olarak başarıyla çalışmış ve bazı modellerde en güncel makalenin önüne geçecek seviyeye gelmiştir. UNet++ modeli ile elde edilen en iyi sonuç olmuştur. En iyi mikroanevrizma ve en iyi eksudat modeli olmuştur. En önemlisi de erken teşhiste kritik rol oynayan mikroanevrizmalarda en başarılı sonucun elde edilmiş olmasıdır. Daha gelişmiş modellerle de karşılaştırılınca ortalamada ikinci sırayı almıştır. Dahası başka alanlara da uygulanabilecek yöntemler geliştirilmiştir. Son olarak kullanılan gürültü giderme işleminin çıktısının potansiyeli üzerine gidilebilir. Son yıllarda çıkan SAM (Segment Anything Model) [35] gibi evrensel modeller görüntü işaretlemek için kolaylıklar sunmaktadır. Bu çalışmadaki gürültüsü giderilmiş görüntüler keskin sınırlara ve belirgin alanlara sahiptir. Bu da görüntüleri SAM gibi modellerin çok daha başarılı bölütleyebileceği hale sokmuştur. İlerideki çalışmalarda bu fırsat değerlendirilebilir. İlerideki çalışmalarda üzerine gidilebilecek bir nokta ise global bilginin kullanılmasıdır. Literatürdeki en başarılı bir diğer çalışma [26] bundan faydalanmıştır. Bu çalışmadaki mimari LocalNet GlobalNet [26] çiftinden örnek alınarak geliştirilebilir.

KAYNAKLAR

- [1] Borys Tymchenko, Philip Marchenko, and Dmitry Spodarets. Deep learning approach to diabetic retinopathy detection. *arXiv preprint arXiv:2003.02261*, **2020**.
- [2] James Rice. Screening for diabetic retinopathy. *Continuing Medical Education, Vol 31, No 4*, **2013**.

- [3] Safal Khanal, Pinakin Gunvant Davey, Lyne Racette, and Madhu Thapa. Comparison of retinal nerve fiber layer and macular thickness for discriminating primary open-angle glaucoma and normal-tension glaucoma using optical coherence tomography. *Clinical and Experimental Optometry*, 99(4):373–381, **2016**.
- [4] Atsushi Mizutani, Chisako Muramatsu, Yuji Hatanaka, Shinsuke Suemori, Takeshi Hara, and Hiroshi Fujita. Automated microaneurysm detection method based on double ring filter in retinal fundus images. In *Medical Imaging 2009: Computer-Aided Diagnosis*, volume 7260, pages 487–494. SPIE, **2009**.
- [5] The University of Iowa. The coms grading scheme: Graded features retinal hemorrhage, **2006**.
- [6] Prasanna Porwal, Samiksha Pachade, Ravi Kamble, Manesh Kokare, Girish Deshmukh, Vivek Sahasrabuddhe, and Fabrice Meriaudeau. Indian diabetic retinopathy image dataset (idrid): a database for diabetic retinopathy screening research. *Data*, 3(3):25, **2018**.
- [7] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18*, pages 234–241. Springer, **2015**.
- [8] Liang-Chieh Chen, George Papandreou, Florian Schroff, and Hartwig Adam. Rethinking atrous convolution for semantic image segmentation. *arXiv preprint arXiv:1706.05587*, **2017**.
- [9] Zongwei Zhou, Md Mahfuzur Rahman Siddiquee, Nima Tajbakhsh, and Jianming Liang. U-net++: A nested u-net architecture for medical image segmentation. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th*

International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4, pages 3–11. Springer, **2018**.

[10] Ozan Oktay, Jo Schlemper, Loic Le Folgoc, Matthew Lee, Mattias Heinrich, Kazunari Misawa, Kensaku Mori, Steven McDonagh, Nils Y Hammerla, Bernhard Kainz, et al. Attention u-net: Learning where to look for the pancreas. *arXiv preprint arXiv:1804.03999*, **2018**.

[11] Hualin Wang, Yuhong Zhou, Jiong Zhang, Jianqin Lei, Dongke Sun, Feng Xu, and Xiayu Xu. Anomaly segmentation in retinal images with poisson-blending data augmentation. *Medical Image Analysis*, 81:102534, **2022**.

[12] Xintao Wang, Ke Yu, Shixiang Wu, Jinjin Gu, Yihao Liu, Chao Dong, Yu Qiao, and Chen Change Loy. Esrgan: Enhanced super-resolution generative adversarial networks. In *The European Conference on Computer Vision Workshops (ECCVW)*. **2018**.

[13] Xintao Wang, Liangbin Xie, Chao Dong, and Ying Shan. Real-esrgan: Training real-world blind super-resolution with pure synthetic data. In *International Conference on Computer Vision Workshops (ICCVW)*. **2021**.

[14] Kai Zhang, Jingyun Liang, Luc Van Gool, and Radu Timofte. Designing a practical degradation model for deep blind image super-resolution. In *IEEE International Conference on Computer Vision*, pages 4791–4800. **2021**.

[15] Patrick Pérez, Michel Gangnet, and Andrew Blake. Poisson image editing. In *Seminal Graphics Papers: Pushing the Boundaries, Volume 2*, pages 577–582. **2023**.

[16] WHO. Diabetes report. In *Diabetes Report*, volume TR 37.868, 11.0.0. **2011**.

[17] Leshner. <https://diabetesjournals.org/care/article/39/9/1643/37062/global-estimates-on-the-number-of-people-with-diabetes>. In *Diabetes Report*, volume TR 37.868, 11.0.0. **2011**.

- [18] Peter H. Scanlon. Diabetic retinopathy. *Medicine*, 38(12):656–660, **2010**. ISSN 1357-3039. doi:<https://doi.org/10.1016/j.mpmed.2010.08.010>. Diabetes Part 2 of 2.
- [19] Siti Syafinah Ahmad Hassan, David BL Bong, and Mallika Premsenthil. Detection of neovascularization in diabetic retinopathy. *Journal of digital imaging*, 25:437–444, **2012**.
- [20] Jonathan Long, Evan Shelhamer, and Trevor Darrell. Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3431–3440. **2015**.
- [21] Kaiming He, Georgia Gkioxari, Piotr Dollár, and Ross Girshick. Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision*, pages 2961–2969. **2017**.
- [22] Foivos I Diakogiannis, François Waldner, Peter Caccetta, and Chen Wu. Resunet-a: A deep learning framework for semantic segmentation of remotely sensed data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162:94–114, **2020**.
- [23] Prasanna Porwal, Samiksha Pachade, Manesh Kokare, Girish Deshmukh, Jaemin Son, Woong Bae, Lihong Liu, Jianzong Wang, Xinhui Liu, Liangxin Gao, et al. Idrid: Diabetic retinopathy–segmentation and grading challenge. *Medical image analysis*, 59:101561, **2020**.
- [24] Song Guo, Tao Li, Hong Kang, Ning Li, Yujun Zhang, and Kai Wang. L-seg: An end-to-end unified framework for multi-lesion segmentation of fundus images. *Neurocomputing*, 349:52–63, **2019**.
- [25] Maryam Badar, Muhammad Shahzad, and MM Fraz. Simultaneous segmentation of multiple retinal pathologies using fully convolutional deep neural network. In *Medical Image Understanding and Analysis: 22nd Conference, MIUA 2018*,

Southampton, UK, July 9-11, 2018, *Proceedings 22*, pages 313–324. Springer, **2018**.

- [26] Zizheng Yan, Xiaoguang Han, Changmiao Wang, Yuda Qiu, Zixiang Xiong, and Shuguang Cui. Learning mutually local-global u-nets for high-resolution retinal lesion segmentation in fundus images. In *2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)*, pages 597–600. IEEE, **2019**.
- [27] Lei Shi, Bin Wang, and Junxing Zhang. A multi-stage transfer learning framework for diabetic retinopathy grading on small data. In *ICC 2023-IEEE International Conference on Communications*, pages 3388–3393. IEEE, **2023**.
- [28] Yi Zhou, Xiaodong He, Lei Huang, Li Liu, Fan Zhu, Shanshan Cui, and Ling Shao. Collaborative learning of semi-supervised segmentation and classification for medical images. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 2079–2088. **2019**.
- [29] Mark J. J. P. van Grinsven, Bram van Ginneken, Carel B. Hoyng, Thomas Theelen, and Clara I. Sánchez. Fast convolutional neural network training using selective data sampling: Application to hemorrhage detection in color fundus images. *IEEE Transactions on Medical Imaging*, 35(5):1273–1284, **2016**. doi:10.1109/TMI.2016.2526689.
- [30] Elif K Çontar. *Segmentation of Multi Class Retinal Lesions from Fundus Images*. Master’s thesis, Middle East Technical University, **2022**.
- [31] Astropy Collaboration, T. P. Robitaille, E. J. Tollerud, P. Greenfield, M. Droettboom, E. Bray, T. Aldcroft, M. Davis, A. Ginsburg, A. M. Price-Whelan, W. E. Kerzendorf, A. Conley, N. Crighton, K. Barbary, D. Muna, H. Ferguson, F. Grollier, M. M. Parikh, P. H. Nair, H. M. Unther, C. Deil, J. Woillez, S. Conseil, R. Kramer, J. E. H. Turner, L. Singer, R. Fox, B. A. Weaver, V. Zabalza, Z. I. Edwards, K. Azalee Bostroem, D. J. Burke, A. R. Casey, S. M. Crawford, N. Dencheva, J. Ely, T. Jenness, K. Labrie, P. L. Lim,

F. Pierfederici, A. Pontzen, A. Ptak, B. Refsdal, M. Servillat, and O. Streicher. Astropy: A community Python package for astronomy. *aap*, 558:A33, **2013**. doi:10.1051/0004-6361/201322068.

- [32] Astropy Collaboration, A. M. Price-Whelan, B. M. Sipőcz, H. M. Günther, P. L. Lim, S. M. Crawford, S. Conseil, D. L. Shupe, M. W. Craig, N. Dencheva, A. Ginsburg, J. T. VanderPlas, L. D. Bradley, D. Pérez-Suárez, M. de Val-Borro, T. L. Aldcroft, K. L. Cruz, T. P. Robitaille, E. J. Tollerud, C. Ardelean, T. Babej, Y. P. Bach, M. Bachetti, A. V. Bakanov, S. P. Bamford, G. Barentsen, P. Barmby, A. Baumbach, K. L. Berry, F. Biscani, M. Boquien, K. A. Bostroem, L. G. Bouma, G. B. Brammer, E. M. Bray, H. Breytenbach, H. Buddelmeijer, D. J. Burke, G. Calderone, J. L. Cano Rodríguez, M. Cara, J. V. M. Cardoso, S. Cheedella, Y. Copin, L. Corrales, D. Crichton, D. D’Avella, C. Deil, É. Depagne, J. P. Dietrich, A. Donath, M. Droettboom, N. Earl, T. Erben, S. Fabbro, L. A. Ferreira, T. Finethy, R. T. Fox, L. H. Garrison, S. L. J. Gibbons, D. A. Goldstein, R. Gommers, J. P. Greco, P. Greenfield, A. M. Groener, F. Grollier, A. Hagen, P. Hirst, D. Homeier, A. J. Horton, G. Hosseinzadeh, L. Hu, J. S. Hunkeler, Ž. Ivezić, A. Jain, T. Jenness, G. Kanarek, S. Kendrew, N. S. Kern, W. E. Kerzendorf, A. Khvalko, J. King, D. Kirkby, A. M. Kulkarni, A. Kumar, A. Lee, D. Lenz, S. P. Littlefair, Z. Ma, D. M. Macleod, M. Mastropietro, C. McCully, S. Montagnac, B. M. Morris, M. Mueller, S. J. Mumford, D. Muna, N. A. Murphy, S. Nelson, G. H. Nguyen, J. P. Ninan, M. Nöthe, S. Ogaz, S. Oh, J. K. Parejko, N. Parley, S. Pascual, R. Patil, A. A. Patil, A. L. Plunkett, J. X. Prochaska, T. Rastogi, V. Reddy Janga, J. Sabater, P. Sakurikar, M. Seifert, L. E. Sherbert, H. Sherwood-Taylor, A. Y. Shih, J. Sick, M. T. Silbiger, S. Singanamalla, L. P. Singer, P. H. Sladen, K. A. Sooley, S. Sornarajah, O. Streicher, P. Teuben, S. W. Thomas, G. R. Tremblay, J. E. H. Turner, V. Terrón, M. H. van Kerkwijk, A. de la Vega, L. L. Watkins, B. A. Weaver, J. B. Whitmore, J. Woillez, V. Zabalza, and Astropy Contributors. The Astropy Project: Building

an Open-science Project and Status of the v2.0 Core Package. *aj*, 156(3):123, 2018. doi:10.3847/1538-3881/aabc4f.

- [33] Astropy Collaboration, Adrian M. Price-Whelan, Pey Lian Lim, Nicholas Earl, Nathaniel Starkman, Larry Bradley, David L. Shupe, Aarya A. Patil, Lia Corrales, C. E. Brasseur, Maximilian N’othe, Axel Donath, Erik Tollerud, Brett M. Morris, Adam Ginsburg, Eero Vaher, Benjamin A. Weaver, James Tocknell, William Jamieson, Marten H. van Kerkwijk, Thomas P. Robitaille, Bruce Merry, Matteo Bachetti, H. Moritz G’unther, Thomas L. Aldcroft, Jaime A. Alvarado-Montes, Anne M. Archibald, Attila B’odi, Shreyas Bapat, Geert Barentsen, Juanjo Baz’an, Manish Biswas, M’ed’eric Boquien, D. J. Burke, Daria Cara, Mihai Cara, Kyle E. Conroy, Simon Conseil, Matthew W. Craig, Robert M. Cross, Kelle L. Cruz, Francesco D’Eugenio, Nadia Dencheva, Hadrien A. R. Devillepoix, J’org P. Dietrich, Arthur Davis Eigenbrot, Thomas Erben, Leonardo Ferreira, Daniel Foreman-Mackey, Ryan Fox, Nabil Freij, Suyog Garg, Robel Geda, Lauren Glattly, Yash Gondhalekar, Karl D. Gordon, David Grant, Perry Greenfield, Austen M. Groener, Steve Guest, Sebastian Gurovich, Rasmus Handberg, Akeem Hart, Zac Hatfield-Dodds, Derek Homeier, Griffin Hosseinzadeh, Tim Jenness, Craig K. Jones, Prajwel Joseph, J. Bryce Kalmbach, Emir Karamehmetoglu, Mikolaj Kaluszy’nski, Michael S. P. Kelley, Nicholas Kern, Wolfgang E. Kerzendorf, Eric W. Koch, Shankar Kulumani, Antony Lee, Chun Ly, Zhiyuan Ma, Conor MacBride, Jakob M. Maljaars, Demitri Muna, N. A. Murphy, Henrik Norman, Richard O’Steen, Kyle A. Oman, Camilla Pacifici, Sergio Pascual, J. Pascual-Granado, Rohit R. Patil, Gabriel I. Perren, Timothy E. Pickering, Tanuj Rastogi, Benjamin R. Roulston, Daniel F. Ryan, Eli S. Rykoff, Jose Sabater, Parikshit Sakurikar, Jes’us Salgado, Aniket Sanghi, Nicholas Saunders, Volodymyr Savchenko, Ludwig Schwaradt, Michael Seifert-Eckert, Albert Y. Shih, Anany Shrey Jain, Gyanendra Shukla, Jonathan Sick, Chris Simpson, Sudheesh Singanamalla, Leo P. Singer, Jaladh Singhal, Manodeep Sinha, Brigitta M. SipHocz, Lee R. Spitler, David Stansby,

Ole Streicher, Jani Sumak, John D. Swinbank, Dan S. Taranu, Nikita Tewary, Grant R. Tremblay, Miguel de Val-Borro, Samuel J. Van Kooten, Zlatan Vasovi'c, Shresth Verma, Jos'e Vin'icius de Miranda Cardoso, Peter K. G. Williams, Tom J. Wilson, Benjamin Winkel, W. M. Wood-Vasey, Rui Xue, Peter Yoachim, Chen Zhang, Andrea Zonca, and Astropy Project Contributors. The Astropy Project: Sustaining and Growing a Community-oriented Open-source Project and the Latest Major Release (v5.0) of the Core Package. *apj*, 935(2):167, **2022**. doi:10.3847/1538-4357/ac7c74.

- [34] Visar Berisha, Chelsea Krantsevich, P Richard Hahn, Shira Hahn, Gautam Dasarathy, Pavan Turaga, and Julie Liss. Digital medicine and the curse of dimensionality. *NPJ digital medicine*, 4(1):153, **2021**.
- [35] Alexander Kirillov, Eric Mintun, Nikhila Ravi, Hanzi Mao, Chloe Rolland, Laura Gustafson, Tete Xiao, Spencer Whitehead, Alexander C Berg, Wan-Yen Lo, et al. Segment anything. *arXiv preprint arXiv:2304.02643*, **2023**.