

T.C.

TRAKYA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

**UZAMSAL GÖRÜNTÜ FİLTRELEME İLE YAPAY SİNİR AĞI TABANLI
RETİNA DAMAR BÖLÜTLENMESİNİN İYİLEŞTİRİLMESİ**

CEM YAKUT

YÜKSEK LİSANS TEZİ

HESAPLAMALI BİLİMLER ANABİLİM DALI

Tez Danışmanı: Dr. Öğr. Üyesi SEZER ULUKAYA

İkinci Tez Danışmanı: Dr. Öğr. Üyesi İLKAY ÖKSÜZ

EDİRNE-2021

Cem YAKUT' un hazırladığı “Uzamsal Görüntü Filtreleme İle Yapay Sinir Ağı Tabanlı Retina Damar Bölütlenmesinin İyileştirilmesi” başlıklı bu tez, tarafımızca okunmuş, kapsam ve niteliği açısından Hesaplamalı Bilimler Anabilim Dalında bir Yüksek lisans tezi olarak kabul edilmiştir.

Jüri Üyeleri (Ünvan, Ad, Soyad):

İmza

Dr. Öğr. Üyesi Sezer ULUKAYA

.....

Dr. Öğr. Üyesi Deniz TAŞKIN

.....

Dr. Öğr. Üyesi Görkem SERBES

.....

Tez Savunma Tarihi: 23 / 09 / 2021

Bu tezin Yüksek Lisans tezi olarak gerekli şartları sağladığımı onaylarım.

İmza

Dr. Öğr. Üyesi Sezer ULUKAYA
Tez Danışmanı

.....

Dr. Öğr. Üyesi İLKAY ÖKSÜZ
İkinci Tez Danışmanı

.....

Trakya Üniversitesi Fen Bilimleri Enstitüsü onayı

Prof. Dr. Hüseyin Rıza Ferhat KARABULUT

Fen Bilimleri Enstitüsü Müdürü

T.Ü.FEN BİLİMLERİ ENSTİTÜSÜ
HESAPLAMALI BİLİMLER ANABİLİM DALI YÜKSEK LİSANS PROGRAMI
DOĞRULUK BEYANI

Trakya Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında, tüm verilerin bilimsel ve akademik kurallar çerçevesinde elde edildiğini, kullanılan verilerde tahrifat yapılmadığını, tezin akademik ve etik kurallara uygun olarak yazıldığını, kullanılan tüm literatür bilgilerinin bilimsel normlara uygun bir şekilde kaynak gösterilerek ilgili tezde yer aldığını ve bu tezin tamamı ya da herhangi bir bölümünün daha önceden Trakya Üniversitesi ya da farklı bir üniversitede tez çalışması olarak sunulmadığını beyan ederim.

23 / 09 / 2021

Cem YAKUT

Yüksek Lisans Tezi

Uzamsal Görüntü Filtreleme ile Yapay Sinir Ağı Tabanlı Retina Damar Bölütlenmesinin
İyileştirilmesi

T.Ü. Fen Bilimleri Enstitüsü

Hesaplamalı Bilimler Anabilim Dalı

ÖZET

Retinografi, göz bozukluklarının tespitine yardımcı olan ve klinik tanıda sıklıkla kullanılan bir görüntüleme tekniğidir. Düşük zıtlık seviyesi ve/veya gürültü, retina fundus görüntülerini bozabilir. Bunun gibi etkenler, uzmanların retina görüntülerinde hastalıkları tespit etmesini ve hastalığı sınıflandırmasını zorlaştırır. Bu çalışmada, renkli fundus görüntülerinde retina damar örüntüsü segmentasyonu için hibrit bir yaklaşım önerilmektedir. Retina damar segmentasyonu için derin öğrenme U-Net mimarisi kullanılacaktır. Ayrıca, derin öğrenme U-Net mimarisinin başarısını arttırmak amacıyla eğitim fundus görüntü kümesi denetimsiz bir şekilde ön işlemden geçirilecek ve paralel kanal olarak derin öğrenme ağı beslenecektir. Ön işleme adımları sırasıyla; kırmızı-yeşil-mavi kanal ayrılması, gri dönüşüm, medyan filtreleme, Wiener filtreleme, kontrast sınırlı adaptif histogram eşitleme (KSAHE), matematiksel morfoloji işlemleri, Coye filtreleme ve bağlantılı bileşen analizi ve veri kümesi genişletme aşamalarından oluşmuştur. Önerilen denetimsiz ön işleme tabanlı yaklaşım, derin öğrenme U-Net modelinin eğitim süresini de anlamlı olarak düşürmüştür. Önerilen yaklaşım, araştırmacıların erişimine açık DRIVE ve HRF veri kümelerinde test edilmiştir.

Yıl : 2021

Sayfa Sayısı : 124

Anahtar Kelimeler : Retina fundus görüntüsü, Damar segmentasyonu, Paralel kanallı ağ, Sonuçları birleştirme, Denetimsiz görüntü ön işleme

Master's Degree Thesis

Improving Artificial Neural Network Based Retinal Vessel Segmentation with Spatial Image Filtering

Trakya University Institute of Natural Sciences

Computational Science Department

ABSTRACT

Retinography is a frequently used imaging technique that aids in clinical diagnosis of eye disorders. Low contrast and being exposed to noise are the primary factors in degraded retinal fundus images. These factors make it challenging for medical experts to diagnose and classify diseases in retinal images. This work proposes a hybrid approach for retinal vessel tree segmentation in color fundus images. We propose to use a deep convolutional neural network for the segmentation of retinal vessels. In addition, the training fundus images were be pre-processed in an unsupervised way for the purpose of increasing success of the deep U-Net architecture and fed into network as parallel channels. Preprocessing steps include the following stages; seperation of RGB channel, gray scale conversion, median filtering, CLAHE, mathematical morphology operations, Coye filtering, connected component analysis and data augmentation. The proposed approach was tested on publicly accessible DRIVE and HRF datasets.

Year : 2021

Number of Pages : 124

Keywords : Retinal fundus image, Vessel segmentation, Parallel channel network, Decision fusion, Unsupervised image preprocessing

ÖNSÖZ

Bu çalışmanın yürütülmesi sırasında bana yol gösterici olan ve desteklerini esirgemeyen değerli danışmanım Sayın Dr. Öğr. Üyesi SEZER ULUKAYA'ya,

Bilgi ve deneyimlerini tereddütsüz paylaşan ve her zaman yol gösteren değerli ikinci danışman hocam Sayın Dr. Öğr. İLKAY ÖKSÜZ'e teşekkür ve saygılarımı sunarım.

Her zaman yanımda olan ve motivasyonumu yüksek tutan eşim Ayça'ya ve aileme sonsuz teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ	xiii
KISALTMALAR DİZİNİ.....	xvi
BÖLÜM 1: GİRİŞ.....	1
BÖLÜM 2: GENEL BİLGİLER.....	5
2.1. Gözün Anatomik Yapısı.....	5
2.2. Retinal Hastalıklar ve Belirtileri	7
2.3. Dijital Retina Taraması	8
2.4. Veri Kümesi	9
2.4.1. DRIVE Veri Kümesi.....	9
2.4.2. HRF Veri Kümesi	10
2.5. Retina Damar Bölütlenmesi için Yapılan Çalışmalar	11
BÖLÜM 3: DENETİMSİZ ÖN İŞLEME VE DERİN ÖĞRENME YÖNTEMLERİ....	18
3.1. Denetimsiz Ön Hazırlık İşlemleri	18
3.1.1. Renk Uzayı Ayrılması.....	18
3.1.2. Gri Seviye Dönüşümü	20

3.1.3. Wiener Filtreleme.....	21
3.1.4. Medyan Filtreleme	22
3.1.5. Kontrast Sınırlı Adaptif Histogram Eşitleme (KSAHE).....	22
3.1.6. Veri Kümesi Genişletme	23
3.2. Matematiksel Morfoloji Kullanarak Retina Damar Bölütlenmesi	25
3.3. Coyer Filtreleme ve Bağlantılı Bileşen Analizi Kullanarak Retina Damar Bölütlenmesi	26
3.4. Derin Öğrenme U-Net Modeli Mimarisi	27
3.5. Sonuç Bütünleştirme	29
3.6. Değerlendirme Ölçütleri.....	31
3.6.1. Duyarlılık	31
3.6.2. Özgüllük.....	32
3.6.3. Doğruluk	32
3.6.4. Kesinlik	32
3.6.5. İşlem Süresi.....	33
BÖLÜM 4: DENEYSEL SONUÇLAR	34
4.1. Denetimsiz Retina Damar Bölütlenmesi.....	35
4.1.1. KSAHE Yönteminde Kontrast Üst Sınırın Belirlenmesi	35
4.1.2. Matematiksel Morfoloji Yöntemi Sonucu	37
4.1.3. Coyer Filtreleme ve Bağlantılı Bileşen Analizi Yöntemi Sonucu	43
4.1.4. Denetimsiz Sonuç Bütünleştirme	52
4.2. Derin Öğrenme Tabanlı Yaklaşımın Değerlendirilmesi	57
4.2.1. U-Net Modelinin Tek Kanallı Eğitimi Sonucu	57
4.2.2. U-Net Modelin Paralel Kanallı Eğitimi Sonucu	69
4.3. Hibrit Yöntemin Değerlendirilmesi	74
4.4. Önerilen Hibrit Yöntemin HRF Veri Kümesinde Değerlendirilmesi	78

4.4.1. HRF Eğitim ve Test Veri Kümelerinin Belirlenmesi.....	78
4.4.2. Denetimsiz Retina Damar Bölütlenmesi Sonuçları	78
4.4.3. Derin Öğrenme Tabanlı Yaklaşım Sonuçları	85
4.4.4. Hibrit Yöntem Sonuçları	91
BÖLÜM 5: SONUÇ VE TARTIŞMA.....	96
KAYNAKÇA.....	102
ÖZGEÇMİŞ.....	108



ŞEKİLLER DİZİNİ

Şekil 2.1. Gözün anatomik yapısı	6
Şekil 2.2. Fundus görüntüsünde retina anatomik yapılarının görünümü	8
Şekil 2.3. Dijital retina tarama görüntüleri.....	9
Şekil 2.4. DRIVE veri kümesinin 27. görüntüsü	10
Şekil 2.5. HRF veri kümesinin 8. görüntüsü.....	11
Şekil 3.1. DRIVE veri kümesi 27. renkli retina görüntüsü.....	19
Şekil 3.2. DRIVE veri kümesi 27. (a) kırmızı (b) yeşil (c) mavi kanal görüntüsü	19
Şekil 3.3. Veri kümesi genişletme uygulanmış (a) Orijinal (b) yatay eksen de yansıma (c) dikey eksen de yansıma (d) hem yatay hem de dikey eksen de yansıma (e) 30 ⁰ 'lik açısal döndürme (f) 60 ⁰ 'lik açısal döndürme görüntüsü	24
Şekil 3.4. Matematiksel morfoloji yöntemi akış şeması	26
Şekil 3.5. Coye filtreleme ve bağlantılı bileşen analizi yöntemi akış şeması	27
Şekil 3.6. Ayrıntılı derin U-net mimarisi	28
Şekil 3.7. Önerilen yöntemin akış şeması	30
Şekil 4.1. Kontrast üst sınırın doğruluğa etkisi.....	36
Şekil 4.2. (a) Renkli retina (b) referans (c) matematiksel morfoloji yöntemiyle elde edilen retina damar haritası görüntüsü.....	43
Şekil 4.3. Coye filtreleme yöntemiyle elde edilen retina damar örgüsü ikili görüntüsü.....	44
Şekil 4.4. Coye filtreleme ve bağlantılı bileşen analizi yöntemiyle elde edilmiş retina damar örgüsü.....	45

Şekil 4.5. (a) Renkli retina (b) referans (c) Coye – BBA yöntemiyle elde edilen retina damar haritası görüntüsü	51
Şekil 4.6. (a) Renkli retina (b) referans (c) denetimsiz sonuç bütünleştirme yöntemiyle elde edilen retina damar haritası görüntüsü	55
Şekil 4.7. (a) Renkli retina (b) referans (c) temel U-Net ile elde edilen retina damar haritası görüntüsü	61
Şekil 4.8. (a) Renkli retina (b) referans (c) ön işlenmiş eğitim kümesiyle eğitilmiş U-Net yöntemiyle elde edilen retina damar haritası görüntüsü	68
Şekil 4.9. (a) Renkli retina (b) referans (c) paralel kanal U-Net yöntemiyle elde edilen retina damar haritası görüntüsü	71
Şekil 4.10. (a) Renkli retina (b) referans (c) eğitim veri kümesi genişletilmiş paralel kanal U-Net yöntemiyle elde edilen retina damar haritası görüntüsü	73
Şekil 4.11. (a) Renkli retina (b) referans (c) matematiksel morfoloji yöntemi (d) Coye filtre ve BBA yöntemi (e) denetimsiz sonuç bütünleştirme (f) temel U-Net modeli tahmini (g) genişletilmiş paralel kanallı U-Net (h) hibrit yöntem sonuç görüntüsü	77
Şekil 4.12. (a) Renkli retina (b) referans (c) matematiksel morfoloji yöntemiyle elde edilen retina damar haritası görüntüsü	80
Şekil 4.13. (a) Renkli retina (b) referans (c) Coye – BBA yöntemiyle elde edilen retina damar haritası görüntüsü	82
Şekil 4.14. (a) Renkli retina (b) referans (c) denetimsiz sonuç bütünleştirme yöntemiyle elde edilen retina damar haritası görüntüsü	84
Şekil 4.15. (a) Renkli retina (b) referans (c) temel U-Net ile elde edilen retina damar haritası görüntüsü	86
Şekil 4.16. (a) Renkli retina (b) referans (c) veri kümesi genişletilmiş tek kanal U-Net yöntemiyle elde edilen retina damar haritası görüntüsü	88
Şekil 4.17. (a) Renkli retina (b) referans (c) veri kümesi genişletilmiş paralel kanal U-Net yöntemiyle elde edilen retina damar haritası görüntüsü	91
Şekil 4.18. (a) Renkli retina (b) referans (c) hibrit yöntemle elde edilen retina damar haritası görüntüsü	94

Şekil 4.19. (a) Renkli retina (b) referans (c) matematiksel morfoloji yöntemi (d) Coyer filtre ve BBA yöntemi (e) denetimsiz sonuç bütünleştirme (f) temel U-Net modeli tahmini (g) genişletilmiş paralel kanallı U-Net (h) hibrit yöntem görüntüsü.....95



ÇİZELGELER DİZİNİ

Çizelge 3.1. Sınıflandırıcı tahminine göre karmaşıklık matrisi	31
Çizelge 4.1. Ön işlemede Wiener filtrelemesiz ve son işlemede 3x3 Medyan filtreleme uygulanmasının sonuçları.....	37
Çizelge 4.2. Ön işlemede Wiener filtrelemesiz ve son işlemede 5x5 Medyan filtreleme uygulanmasının sonuçları.....	39
Çizelge 4.3. Ön işlemede Wiener filtreleme ve son işlemede 3x3 Medyan filtreleme uygulanmasının sonuçları.....	40
Çizelge 4.4. Ön işlemede Wiener filtreleme ve son işlemede 5x5 Medyan filtreleme uygulanmasının sonuçları.....	41
Çizelge 4.5. Matematiksel morfoloji yöntemi başarı özeti	42
Çizelge 4.6. Ön işlemede Wiener filtrelemesiz ve son işlemede 3x3 Medyan filtreleme uygulanmasının sonuçları.....	46
Çizelge 4.7. Ön işlemede Wiener filtrelemesiz ve son işlemede 5x5 Medyan filtreleme uygulanmasının sonuçları.....	47
Çizelge 4.8. Ön işlemede Wiener filtreleme ve son işlemede 3x3 Medyan filtreleme uygulanmasının sonuçları.....	48
Çizelge 4.9. Ön işlemede Wiener filtreleme ve son işlemede 5x5 Medyan filtreleme uygulanmasının sonuçları.....	49
Çizelge 4.10. Coyle filtreleme ve bağlantılı bileşen analizi yöntemi başarı özeti	50
Çizelge 4.11. Denetimsiz retina damar bölütlenmesi yöntemiyle bütünleştirilmiş ve 3x3 Medyan filtreleme uygulanmış yöntemin sonuçları.....	53

Çizelge 4.12. Denetimsiz retina damar bölütlenmesi yöntemiyle bütünleştirilmiş ve 5x5 Medyan filtreleme uygulanmış yöntemin sonuçları.....	54
Çizelge 4.13. Sonuç bütünleştirme başarı özeti	55
Çizelge 4.14. Denetimsiz yöntem sonuçlarının literatür ile karşılaştırması.....	56
Çizelge 4.15. U-Net Modelinin Ön Hazırlıksız ve Tek Kanallı Eğitim Sonuçları	58
Çizelge 4.16. U-Net Modelinin Ön Hazırlıksız ve Tek Kanallı Eğitim ve test kümesine KSAHE uygulanmış sonuçları	60
Çizelge 4.17. U-Net Modelinin Ön Hazırlıklı ve Tek Kanallı Eğitim Sonuçları.....	63
Çizelge 4.18. U-Net modelinin ön hazırlıklı ve tek kanallı eğitim ve test kümesine KSAHE uygulanmış sonuçları	65
Çizelge 4.19. U-Net Modelinin Ön Hazırlıklı Genişletilmiş ve Tek Kanallı Eğitim Sonuçları	67
Çizelge 4.20. U-Net Modelin Paralel Kanallı Eğitim Sonuçları.....	70
Çizelge 4.21. U-Net Modelinin Veri Kümesi Genişletme Uygulanmış Paralel Kanallı Eğitim Sonuçları	72
Çizelge 4.22. Derin öğrenme tabanlı hibrit yöntem sonuçlarının literatür ile karşılaştırılması	74
Çizelge 4.23. Önerilen hibrit yöntem değerlendirme sonuçları	75
Çizelge 4.24. Farklı yöntemler ile eğitilmiş U-Net mimarisi başarı özeti	76
Çizelge 4.25. HRF test kümesi matematiksel morfoloji sonuçları.....	79
Çizelge 4.26. HRF test kümesi Coye filtreleme ve bağlantılı bileşen analizi sonuçları ..	81
Çizelge 4.27. Denetimsiz tahmin bütünleştirme sonuçları	83
Çizelge 4.28. HRF test veri kümesi denetimsiz retina damar bölütlemesi sonuç özeti ..	84
Çizelge 4.29. HRF orijinal test kümesi tek kanallı eğitim sonuçları	85
Çizelge 4.30. HRF KSAHE uygulanmış test kümesi tek kanallı eğitim sonuçları	85
Çizelge 4.31. HRF orijinal test veri kümesi, ön hazırlıklı ve tek kanallı eğitim sonuçları	87

Çizelge 4.32. HRF KSAHE uygulanmış test veri kümesi, ön hazırlıklı ve tek kanallı eğitim sonuçları	87
Çizelge 4.33. HRF ön hazırlıklı ve veri kümesi genişletilmiş tek kanallı eğitim sonuçları	87
Çizelge 4.34. HRF veri kümesi paralel kanallı eğitim sonuçları	89
Çizelge 4.35. HRF veri kümesi genişletilmiş paralel kanallı eğitim sonuçları	90
Çizelge 4.36. Derin öğrenme tabanlı yöntem sonuçlarının literatür ile karşılaştırılması	90
Çizelge 4.37. HRF orijinal test veri kümesi hibrit yöntem sonuçları	92
Çizelge 4.38. HRF test veri kümesi sonuç özeti	93

KISALTMALAR DİZİNİ

Kisaltmalar	Açıklamalar
ADAM	: Uyarlanabilir moment tahmini (Adaptive Moment Estimation)
BBA	: Bağlantılı Bileşen Analizi
DRIVE	: Damar çıkarımı için dijital/sayısal retina görüntüleri (Digital Retinal Images for Vessel Extraction)
Fundus	: Renkli sayısal retina tarama görüntüsü
GN	: Gerçek negatif
GP	: Gerçek pozitif
HRF	: Yüksek çözünürlüklü fundus (High Resolution Fundus)
K	: Kırmızı
KSAHE	: Kontrast sınırlı adaptif histogram eşitleme
M	: Mavi
RGB	: Kırmızı – Yeşil – Mavi (Red – Green – Blue)
Sn	: Saniye
Y	: Yeşil
YN	: Yanlış negatif
YP	: Yanlış pozitif

BÖLÜM 1

GİRİŞ

Tıbbi görüntüleme, hastalıkların erken teşhisinden tedavi sürecinin izlenmesine kadar geniş bir uygulama alanını kapsamaktadır. Medikal görüntüler genellikle gürültü nedeniyle bozulur ya da düşük zıtlık sorunundan etkilenebilir. Bu durumun üstesinden gelmek ve hastalıkların daha iyi tespiti için tıbbi görüntü iyileştirme çalışmaları güncel ilgi alanlarından biridir. Tıbbi görüntü iyileştirmenin temel amacı, gürültü seviyesinin azaltılması, tıbbi görüntülerin zıtlığının iyileştirilmesi ve böylece uzmanlara yardımcı olarak hastalığın tespitinin kolaylaştırılmasıdır.

Bu tez çalışmasında konunun öneminin anlaşılabilmesi için kullanılan terminolojiyi tanımlamak ve araştırmanın arka planını açıklamak önemlidir. Retina, gözün arka duvarını kaplayan ve ışığa duyarlı fotoreseptör hücrelerini içeren ince ve sinir dokusundan özelleşmiş tabakadır. Gelen ışık demeti göz merceği yardımıyla retinaya düşürülür. Retina dokusundaki sinirler düşen ışığı görüntüye çevirir ve beyne iletimini sağlar, bu şekilde görme eylemi mümkün olur (İnan, 2014). Göz bozukluğu olarak bilinen ışığın kırılma kusurları, göze gelen görüntünün retina tabakasına odaklanamaması sonucu ortaya çıkar. Göz bozuklukları genel olarak yaşa ya da çevresel faktörlere bağlı olarak gelişebildiği gibi kalıtsal da olabilir. En sık karşılaşılan kırılma kusurları miyop, hipermetrop, astigmat ya da katarakt (lensin şeffaflığını kaybetmesi) gibi bozukluklar yaşa ya da çevresel koşullara bağlı gelişir. Ancak şaşılık, renk körlüğü ve görme tembelliği gibi göz bozuklukları kalıtsal olarak görülmektedir. Göz bozukluklarının

temelinde göz kaslarının gelişimsel eksikliği ya da geriatric fizyolojisi yatmaktadır. Göz bozuklukları ya da kırılma kusurları belirtileri sürekli. Bu belirtiler gözlük, kontakt lens gibi medikal çözümler veya lazer ve cerrahi yöntemler kullanılarak tamamen ortadan kaldırılabilir (Akman, 2021). Retinada meydana gelen kusurlar göz rahatsızlıkları ya da retina hastalıkları olarak tanımlanmaktadır. Retina hastalıklarının belirtileri ani ve kısa süreli görme kaybı, kırık ya da eğri görme, göz önünde uçan siyah noktalar, görüşün perdelenmesi ya da bulanıklaşması, ışık çakması ve görüş alanında karanlık bölge oluşmasıdır. Retina damar tıkanması, retina yırtıkları, doğumsal retina hastalıkları, retina tümörleri doğrudan retinada gelişen hastalıklardır. Kişinin ailesinde ya da kendisinde diyabet, hipertansiyon, yüksek kolesterol, kalp ve damar rahatsızlıkları gibi kronik hastalıklara bağlı olarak retina rahatsızlıkları da gelişebilmektedir. Diyabetik katarakt, glokom (göz tansiyonu), diyabetik retinopati, diyabetik makula ödemi, makula delikleri, vitreoretinal yüzey bozukluğu kronik hastalıklara bağlı retina hastalıklarıdır (Retinal Diseases, 2020).

Dijital retinografi, göz hastalıklarını taramak ve izlemek amacıyla yaygın olarak kullanılan girişimsel olmayan bir yöntemdir (Sahu, Singh, Ghrera ve Elhoseny, 2019). Tıbbi retina taraması (fundus) görüntüleri, retina hastalıklarının tespiti için klinik tanıda yaygın olarak kullanılmaktadır. Diyabetik ve / veya hipertansiyona bağlı göz hastalıkları retinada kılcal damar hasarına neden olmaktadır (Santos vd., 2020). Hastalığın tespitinde geç kalınması ya da fark edilmemesi kademeli olarak geçici görme kayıplarına ve kalıcı körlüğe neden olabilmektedir. Bu nedenle, kronik rahatsızlıklara bağlı göz hastalıklarının erken tespiti görme yetisi kaybını önlemede çok önemli bir aşamadır (Santos vd., 2020; Sahu vd., 2019).

Fundus görüntü analizinde retina kan damarlarının otomatik bölütlenmesi (segmentasyonu) önemli bir konudur. Fundus görüntülerinde kan damarlarının bölütlenmesi; vasküler yapıların, fovea ve optik disk gibi diğer anatomik yapılardan ve patolojik unsurlardan ayrılması anlamına gelmektedir (Santos vd., 2020). Damar bölütlenmesi, görüntü işlemedeki en zor alanlardan biridir. Düşük zıtlıklı, gürültülü ve aydınlatma farklılıkları içeren ve kılcal yapıları ayırt etme sürecini engelleyen düşük kaliteli fundus görüntüleriyle daha da karmaşıklaşır. Sonuç olarak, bu görüntülerde vasküler yapıların otomatik olarak tanımlanması süregelen bir sorundur.

Literatürde retina damar bölütlenmesi için Gauss türevi ile eşleştirme filtresi (Zhang, Zhang, Zhang ve Karray, 2010), radyal projeksiyon ve yönlendirilebilir dalgacıklar yöntemi (You, Peng, Yuan, Cheung ve Lei, 2011), Gauss türevi filtresi ve morfolojik üst-hat operatörü (Fraz vd., 2012), 2-B Gabor dalgacık yöntemi (Zhao, Wang, Wang ve Shih, 2014), Gauss filtresi ve kayan fark kombinasyonu (Azzopardi, Strisciuglio, Vento ve Petkov, 2015), bulanık c-araçları ve yapay koloni optimizasyonu (Hassanien, Emary ve Zawbaa, 2015), Frangi ve Gabor dalgacıkları yöntemlerinin birleştirilmesi (Oliveira, Teixeira, Ren, Cavalcanti ve Sijbers, 2016), ikinci dereceden türevlenebilir Gauss ve Hessian matris yöntemi (Zhang, Dashtbozorg, Bekkers, Pluim ve Duits, 2016), düğüm noktası izleme ve çok ölçekli morfoloji yöntemi (Wang, Zhang, Wu ve Zhou, 2018), Hessian ve yoğunluk dönüşüm yaklaşımlarının kombinasyonu (Alhussein, Aurangzeb ve Haider, 2020) gibi çeşitli teknikler kullanılmıştır.

Hesaplama kapasitesindeki ilerlemeyle birlikte, son zamanlarda retina damar bölütlenmesi ve retina hastalığı tespit problemlerinde derin öğrenme tabanlı yöntemler kullanılmaktadır. Bir kodlayıcı-kod çözücü mimarisi olarak derin U-Net ağı (Ronneberger, Fischer ve Brox, 2015), özellik çıkarımındaki üstünlüklerinden dolayı retinadaki vasküler yapının çıkarılmasına uyarlanmış en popüler bölütlenme yöntemlerinden biridir. Literatürde, retina damar segmentasyonu için çok etiketli mimari (Zhang ve Chung, 2018), kayıplı seviye fonksiyonu (Yan, Yang ve Cheng, 2018), genelden özele çok ölçekli ağ mimarisi (Wu, Xia, Song, Zhang ve Cai, 2018), ağlar arası bağlantı takibi (Wu, Xia, Song, Zhang ve Cai, 2020), genelden özele denetimli mimari (Wang, Zhang, Huang, Wang ve Chen, 2020), çok ölçekli başlangıç ve ResNet blok mimarisi (Wu vd., 2019), çift kodlayıcı şeması (Wang, Qiu ve He, 2019), uzamsal aktivasyon modülü (Ma, Yu, Wang, Ding ve Zheng, 2019), tekrarlayan artık çerçeve mimarisi (Alom, Yakopcic, Hasan, Taha ve Asari, 2019), duyarlı derin denetim yolu (Mishra, Chen ve Hu, 2020) gibi çeşitli U-Net tabanlı modeller kullanılmaktadır.

Bu tez çalışmasında, derin öğrenme ağları ve denetimsiz görüntü işleme tabanlı iyileştirme kullanılarak retina damar bölütlenmesi için hibrit bir algoritma önerilmiştir. Bir uzman tarafından manuel damar bölütlenmesinin gerçekleştirildiği fundus görüntüleri (referans görüntüleri) kullanılarak derin öğrenme modeli eğitilmiştir. Derin öğrenme modelinin başarısını arttırmak amacıyla, manuel olarak damar bölütlenmesi yapılan fundus görüntüleri gürültü giderme ve kontrast arttırmak için Wiener filtreleme, Medyan

filtreleme, fark alma ve kontrast sınırlı adaptif histogram eşitleme (KSAHE) yöntemlerini kullanan ön işlem den geçirilmiştir. Bu işlemlerin hemen ardından referans ve elde edilen görüntüler; yansıma ve açıs al dönüş yöntemleri kullanılarak veri kümesi zenginleştirilmiştir. Son olarak, ön işlem den geçirilmiş ve genişletilmiş fundus görüntüleri kendilerine karşılık gelen referans görüntüleri ile derin öğrenme tabanlı modele paralel kanal olarak verilmiş ve modelin eğitimi yapılmıştır. DRIVE ve HRF veri kümeleri üzerinde gerçekleştirilen testler sonrası önerilen paralel kanallı ve denetimsiz görüntü işleme tabanlı hibrit sistemin performansı değerlendirilmiştir.

Çalışmanın katkıları şu şekilde özetlenebilir;

- i) Denetimsiz görüntü işleme tabanlı iyileştirme kullanılarak retina damar bölütlenmesi için toplu öğrenme tabanlı model geliştirilmesi
- ii) Derin öğrenme tabanlı model kullanılarak retina damar bölütlenmesi için paralel kanallı ve denetimsiz görüntü işleme tabanlı ağırlıklandırılmış hibrit bir algoritma geliştirilmesi
- iii) Geliştirilen hibrit modelin tahminlerinin ön ve son görüntü işleme adımlarıyla ve denetimsiz görüntü işleme tabanlı modelin tahminleriyle kaynaştırılması

Bu tez çalışmasında Bölüm 2' de, gözün anatomik yapısı, kullanılan veri kümelerinin detayları hakkında genel bilgiler, retina hastalıklarının fundus görüntüleriyle bağlantısı ve literatür bilgisi aktarılmaktadır. Bölüm 3' te kullanılan denetimsiz ön işleme ve derin öğrenme U-Net mimarisi hakkında bilgi verilmektedir ve uygulanan yöntemin detayları açıklanmaktadır. Yapılan testler ve elde edilen sonuçlar Bölüm 4' te belirtilmiştir. Sonuçların detaylı yorumlanmasına Bölüm 5' te yer verilmiştir.

BÖLÜM 2

GENEL BİLGİLER


2.1. Gözün Anatomik Yapısı

Boş bir küre şekline sahip olan göz; sert tabaka, damar tabaka ve ağ tabaka olmak üzere 3 kısımdan meydana gelir. Göz kapakları, kaslar, gözyaşı bezleri ve konjonktiva, gözü koruyan ve gözün fonksiyonlarını yerine getirmesine yardımcı olan yapılardır. Gözün arka kısmında yer alan, ışığı algılayan dokuya retina ismi verilir. Retina yüksek miktarda sinir içerir. Retinadan çıkan nöronlar beyinde oksipital kortekste sonlanır. Retinayı oluşturan temel yapılar retina pigment epiteli ve nörosensöriyel tabakadır. Retina pigment epiteli dış bir bariyer oluşturur ve A vitamini metabolizmasında görev alır. Ayrıca ışık emilimini sağlar. Melanin ve lipofuskin retina pigmentleridir. Melaninin antioksidan etkisi ile toksinleri tuttuğu bilinmektedir. Lipofuskin oluşumu ise yaşlanma ile birlikte artar, membran yapılarının oksidatif hasarı sonucu olduğu ileri sürülmektedir. Nörosensöriyel retina; fotoreseptörler, bipolar hücreler, ganglion hücreler, amakrin, horizontal hücreler ve destek hücrelerinden oluşur (İnan, 2014).

Retina koroid dolaşım ve santral retina arterlerinden beslenir. Santral retinal arter retina yüzeyel katmanlarını beslerken, derin katmanları koroidal dolaşım besler. Bahsi geçen 2 dolaşım da oftalmik arter dallarından oluşur. Oftalmik arter ise internal karotid arterden ayrılır. Retina damarları sinir liflerinin bulunduğu bölgelerde yer alırlar. Santral retina arteri optik sinirin ortasından geçer, retina içinde dallara ayrılır. Retina venleri

santral retina veni ile birleşir. Retinada; arteriyol ve venüller arasında kapiller damarlar bulunur (Willoughby vd., 2010). Retinal venlerdeki basıncın göz içi basınçla aynı olduğu bilinmektedir.

Retina damarlarında meydana gelebilecek bir hasar, retinal hastalıklar ile sonuçlanacağı için damar görüntüleme testleri tespit açısından oldukça önemlidirler.



Şekil 2.1. Gözün anatomik yapısı (<https://commons.wikimedia.org>)

Şekil 2.1’de retina tabakasının; fovea, optik disk ve makula gibi anatomik yapıları ve retina damarları gösterilmektedir.

2.2. Retinal Hastalıklar ve Belirtileri

Retina tabakası, görme organı olan gözün en önemli tabakalarından biridir. Retina tabakası bünyesinde yüksek miktarda kan damarı bulundurmaktadır. Vücuttaki diğer organlar gibi göz de ihtiyaç duyduğu besin ve oksijeni kandan karşılamaktadır. Vücutta oluşan travmatik durumlardan ya da kronik hastalıklardan retina tabakası da etkilenmektedir. Retina damar tıkanması, retina yırtıkları, retina tümörleri doğrudan retinada gelişen hastalıklardır. Kişinin ailesinde ya da kendisinde diyabet, hipertansiyon, yüksek kolesterol, kalp ve damar rahatsızlıkları gibi kronik hastalıklara bağlı olarak retina hastalıkları da gelişebilmektedir. Makula dejenerasyonu, retina yırtıkları, diyabetik retinopati, diyabetik glokom, makula deliği, retinal blastom, diyabetik makula ödemi retinada görülen hastalıklardır (Retinal Diseases, 2020).


Makula dejenerasyonu, yaşa bağlı olarak retina merkezi bozulmasıyla ortaya çıkar. Makula dejenerasyonu ilerledikçe görme kaybına yol açmaktadır. Retina yırtıkları, genel olarak gözde meydana gelen travma sonucu iç basınç artışına bağlı olarak gerçekleşmektedir. Diyabetik retinopati, kronik hastalık olan diyabetin zaman içerisinde retinaya zarar vermesiyle oluşmaktadır. Retinadaki kan damarları diyabete bağlı olarak kan ya da doku sıvısı sızdırmaktadır. Retinal blastom, retina da görülen bir kanser tipidir. Makula deliği ya da yırtıkları, doğrudan göz yaralanması sonucunda oluşmaktadır. Ayrıca makula deliği ya da yırtıkları diyabete ve hipertansiyona bağlı olarak gözün iç basıncının artması sonucunda da görülebilmektedir. Diyabetik glokom, yüksek göz tansiyonu sebebiyle retinadaki sinir ucu hasarıdır. Diyabetik makula ödemi, diyabete bağlı olarak retinadaki makula tabakasının su toplamasıdır (Retinal Diseases, 2020).

Retina hastalıklarının belirtileri ani ve kısa süreli görme kaybı, kırık ya da eğri görme, göz önünde uçuşan siyah noktalar, görüşün perdelenmesi ya da bulanıklaşması, ışık çakması ve görüş alanında karanlık bölge oluşmasıdır (Retinal Diseases, 2020). Retina hastalıklarında yukarıda tanımlanan belirtilerden biri ya da birkaçı görülmektedir. Retina hastalıklarının belirtileri neredeyse ortaktır. Bu sebepten dolayı hastalığın doğru tespiti sadece dijital retina taraması (retinografi) sonucunda belirlenir (Santos vd., 2020; Sahu vd., 2019).

2.3. Dijital Retina Taraması

Dijital retina taraması ya da retinografi, göz hastalıklarını taramak ve izlemek amacıyla yaygın olarak kullanılan girişimsel olmayan bir yöntemdir (Sahu vd., 2019). Tıbbi retina taraması (fundus) görüntüleri, retina hastalıklarının tespiti için klinik tanıda yaygın olarak kullanılmaktadır.

Dijital retinografi, bir bilgisayar sistemi ve retina görüntüleme üzerine özelleştirilmiş bir kameradan (fundus) oluşmaktadır. Fundus kamera aracılığıyla retina tabakası görüntülenmektedir. Dijital retina taraması sonucunda elde edilen görüntü, retina kan damar örüntüsü, damar çapı, fovea ve makula genişlikleri, optik disk ile ilgili yapısal bilgileri sağlamaktadır. Yapısal bilgiler birçok retina hastalığının taranması, tespiti ve değerlendirilmesi açısından önemlidir (Akbar, Sharif, Akram, Saba ve Mahmood, 2019).



Şekil 2.2. Fundus görüntüsünde retina anatomik yapılarının görünümü

Şekil 2.2’de DRIVE veri kümesindeki (27. görüntü) sağlıklı bireye ait retinografi görüntüsü verilmiştir. Retinografi görüntüsünde retina anatomik yapıları ve konumları belirtirmiştir.




Şekil 2.3. Dijital retina tarama görüntüleri (HRF veri kümesi işaretlenmiş 9. görüntüler)

Şekil 2.3'te HRF veri kümesindeki farklı bireylere ait dijital retina tarama görüntüsü gösterilmiştir. Birinci görüntüde diyabetik retinopati bulgusu ve ikinci görüntüde diyabetik glokom bulgusu mevcuttur. Üçüncü görüntü sağlıklı retina görüntüsüdür.

2.4. Veri Kümesi

2.4.1. DRIVE Veri Kümesi

DRIVE, İngilizce (Digital Retinal Images for Vessel Extraction) baş harflerini içeren cümlemin kısa ismidir. Türkçe karşılığı “Damar çıkarımı için dijital/sayısal retina görüntüleri” dir. DRIVE veri kümesi Staal ve arkadaşları tarafından 2004 yılında toplanmıştır. Yedisi patolojik bulgulu olmak üzere toplam 40 farklı görüntü içermektedir. DRIVE veri kümesi; her bir renkli retina görüntüsüne karşılık gelen yaklaşık 540 piksel boyutuna sahip maske görüntüsü ve kan damarları işaretlenmiş referans görüntüsü içermektedir. DRIVE veri kümesi, sağlayıcıları tarafından eşit sayıda test (20 adet) ve eğitim (20 adet) kümelerine bölünmüştür. Veri kümesindeki tüm görüntüler 565 x 584 piksel boyutunda renkli görüntülerden oluşmaktadır. DRIVE veri kümesi araştırmacıların erişimine açıktır (DRIVE: Digital Retinal Images for Vessel Extaction, 2012).




Şekil 2.4. DRIVE veri kümesinin sırasıyla 27. görüntüsü, maske ve referans görüntüsü

Şekil 2.4'te DRIVE veri kümesinin sağlayıcılar tarafından numaralandırılmış fundus görüntüsü ve ilgili görüntüsüne karşılık gelen maske ve referans görüntüsü gösterilmiştir.

2.4.2. HRF Veri Kümesi

HRF, İngilizce (High resolution fundus) baş harflerini içeren terimin kısa ismidir. Türkçe karşılığı “Yüksek çözünürlüklü fundus görüntüleri” dir. HRF veri kümesi Budai ve arkadaşları tarafından 2013 yılında toplanmıştır. HRF veri kümesi toplamda 45 farklı görüntü içermektedir. Görüntülerin 15 tanesi sağlıklı, 15 tanesi diyabetik retinopatili ve 15 tanesi de glokom (Göz tansiyonuna bağlı optik sinir ucu hasarı) bulgulu olarak sağlayıcılar tarafından işaretlenmiştir. HRF veri kümesi; her bir renkli retina görüntüsüne karşılık gelen maske görüntüsü ve kan damarları işaretlenmiş referans görüntüsü içermektedir. Veri kümesindeki tüm görüntüler 3504 x 2336 piksel boyutunda renkli görüntülerden oluşmaktadır. HRF veri kümesi araştırmacıların erişimine açıktır (High-Resolution Fundus (HRF) Database, 2013).



Şekil 2.5. HRF veri kümesinin sırasıyla 8. sağlıklı retina, maske ve referans görüntüsü

Şekil 2.5’te HRF veri kümesinin sağlayıcılar tarafından numaralandırılmış fundus görüntüsü ve ilgili görüntüsüne karşılık gelen maske ve referans görüntüsü gösterilmiştir.

2.5. Retina Damar Bölütlenmesi için Yapılan Çalışmalar

Fundus görüntü analizinde retina kan damarlarının otomatik bölütlenmesi (segmentasyonu) önemli bir konudur. Retina kan damarları segmentasyonu, düşük zıtlıklı, gürültülü ve aydınlatma farklılıkları içeren ve kılcal yapıları ayırt etme sürecini engelleyen düşük kaliteli fundus görüntüleriyle daha da karmaşıklaşır. Sonuç olarak, bu görüntülerde vasküler yapıların otomatik olarak tanımlanması süregelen bir sorun olarak araştırmacıların ilgisini çekmiştir.

Zhang ve arkadaşları retina kan damarlarının doğru şekilde çıkarılması amacıyla Gauss türevi ile eşleştirme filtresi yöntemini önermiştir. Önerilen yöntem oldukça basit ve hızlı bir yaklaşımdır. Retina damarlarının eşik değeri eşleştirme filtresi ile bulunmaktadır. Birinci dereceden Gauss türevi yöntemi ile eşleştirme filtresinden kaçan birçok ince damar yapılarını da algılamaktadır. Bütünleştirilmiş yöntem sadece resim başına 10 saniye gibi kısa bir sürede retinadaki vasküler yapıları ayrıştırabilmektedir (Zhang vd., 2010).

You ve arkadaşları ise yaptıkları çalışmada ince ve kalın damarları aynı anda tespit edebilmek amacıyla radyal projeksiyon ve yönlendirilebilir dalgacık yöntemini kullanmışlardır. Önerdikleri yöntemi, erişime açık 2 veri kümesinde test etmişlerdir. DRIVE veri kümesindeki test sonucunda doğruluk % 94.34, STARE veri kümesindeki test sonucunda ise doğruluk % 94.97 olarak hesaplanmıştır (You vd., 2011).

Bir başka retina damar bölütlenmesi çalışmasında Gauss türevi filtresi ve morfolojik üst-hat operatörü yöntemleri birleştirilerek kullanılmıştır. Gri dönüşüm uygulanmış fundus görüntülerinden retina damarlarının sınırları Gauss türevi filtresi kullanılarak çıkarılmıştır. Morfolojik üst-hat operatörü kullanılarak damarların sürekliliği sağlanmıştır. Önerilen yöntem erişime açık DRIVE, STARE ve MESSIDOR veri kümelerinde test edilmiştir. Elde edilen sonuçlar sırasıyla; doğruluk, duyarlılık ve özgüllük parametrelerine göre değerlendirilmiştir. DRIVE veri kümesinde ortalama doğruluk % 94.30, ortalama duyarlılık % 71.52 ve ortalama özgüllük % 97.69 olarak bulunmuştur. STARE veri kümesinde ortalama doğruluk % 94.41, ortalama duyarlılık % 73.10 ve ortalama özgüllük % 96.81 bulunmuştur. MESSIDOR veri kümesinde ortalama doğruluk % 95.73, ortalama duyarlılık % 75.40 ve ortalama özgüllük % 97.76 bulunmuştur (Faraz vd., 2012).

Zhao ve arkadaşları yaptıkları çalışmada; ilk olarak fundus görüntülerine kontrast sınırlı adaptif histogram eşitleme (KSAHE) ve 2B Gabor dalgacık dönüşümü yöntemini uygulayarak damarların kontrastını arttırmışlardır. Ardından görüntüyü yumuşatmak ve damar sınırlarını korumak için anizotropik filtre uygulanmıştır. Son olarak, damar örgüsünü elde etmek amacıyla bölge büyütme yöntemi ve aktif sınır modeli uygulanarak sonuçlar birleştirilmiştir. Deneysel sonuçlar DRIVE ve STARE veri kümelerinde test edilmiş ve sırasıyla % 94.77 ve % 95.09 ortalama doğruluk değerlerine ulaşmıştır (Zhao vd., 2014).

Azzopardi ve diğerleri retina damar bölütlenmesi için Gauss filtresi ve kayan fark kombinasyonu yöntemi üzerine çalışmışlardır. Önerilen yöntem, ağırlıklı geometrik ortalama kullanarak damarların başlangıç ve bitiş noktalarını tespit edebilmektedir. Bu çalışma DRIVE, STARE ve CHASE_DB1 veri kümelerinde sırasıyla duyarlılık ve özgüllük parametreleri kullanılarak test edilmiştir. DRIVE veri kümesinde ortalama duyarlılık % 76.55 ve ortalama özgüllük % 97.04 olarak bulunmuştur. STARE veri kümesinde ortalama duyarlılık % 77.16 ve ortalama özgüllük % 97.01 olarak bulunmuştur. CHASE_DB1 veri kümesinde ortalama duyarlılık % 75.85 ve ortalama özgüllük % 95.87 olarak bulunmuştur (Azzopardi vd., 2015).

Hassanien ve arkadaşları bulanık c-araçları ve yapay koloni optimizasyon yöntemlerini kullanarak retina damar bölütlenmesi çalışması gerçekleştirmişlerdir. Bulanık c-araçları ile ana damarları yakalamışlardır. Yapay koloni optimizasyonu yöntemi, önerilen yaklaşımda ince detayları yakalamak için kullanılmıştır. Önerilen yaklaşımın performansı DRIVE ve STARE veri kümelerinde test edilmiştir. DRIVE veri kümesinde ortalama doğruluk % 93.88, ortalama duyarlılık % 72.10 ve ortalama özgüllük % 97.10 sonuçlarına ulaşılmıştır. STARE veri kümesinde ortalama doğruluk % 94.67, ortalama duyarlılık % 64.90 ve ortalama özgüllük % 98.20 sonuçlarına ulaşılmıştır (Hassanien vd., 2015).

Oliveira ve arkadaşları eşleştirme filtresi, Frangi filtresi ve Gabor dalgacık dönüşümü yöntemlerini birleştiren bir çalışma yapmışlardır. Çalışmanın temel prensibi 3 farklı yöntemin sonuçlarını birleştirerek retina damar bölütlenmesinin başarısını arttırmaktır. Fundus görüntülerine medyan filtreleme işlemi uygulandıktan sonra kan damarlarının eşik değerleri hesaplanmıştır. Eşik değeri kullanılarak görüntüler bölümlere ayrılmıştır. Ağırlıklı ortalama yaklaşımını ve bulanık c-araçlarını kullanarak retina görüntülerinden kan damarları işaretlenmiştir. Önerilen yöntem DRIVE ve STARE veri kümelerinde test edilmiştir. DRIVE veri kümesinde en yüksek ortalama % 93.32 doğruluk oranına, STARE veri kümesinde en yüksek ortalama % 92.45 doğruluk oranına ulaşılmıştır (Oliveira vd., 2016).

Bir diğer retina damar segmentasyonu çalışmasında ikinci dereceden türevlenebilir Gauss ve Hessian matris yöntemi kullanılmıştır. Önerdikleri yaklaşımda Hessian matris yöntemini kullanarak ince damarların bölütlenme başarısı artırılmıştır. Zhang ve arkadaşları önerdikleri yaklaşımı sırasıyla; DRIVE, STARE, CHASE_DB1, HRF, IOSTAR ve RC-SLO veri kümelerinde test etmişlerdir. Yöntemin duyarlılık, özgüllük ve doğruluk sonuçlarını sırasıyla; DRIVE veri kümesinde % 83.29, % 98.34 ve % 96.56; STARE veri kümesinde % 83.17, % 97.92 ve % 96.09; CHASE_DB1 veri kümesinde % 86.43, % 96.23 ve % 95.46; HRF veri kümesinde % 79.35, % 97.11 ve % 95.37; IOSTAR veri kümesinde % 85.16, % 97.19 ve % 95.90; RC-SLO veri kümesinde % 81.90, % 96.92 ve % 94.90 elde etmişlerdir (Zhang vd., 2016).

Alhussein ve arkadaşları yaptıkları çalışmada Hessian ve yoğunluk dönüşüm yöntemini birleştirerek kullanmışlardır. İlk olarak fundus görüntülerine KSAHE ve bağlamsal bölge optimizasyonu yöntemlerini uygulamışlardır. İşlenmiş fundus görüntülerindeki gürültüyü gidermek amacıyla morfolojik işlemler ve Wiener filtreme yapılmıştır. Fundus görüntülerindeki ince ve kalın damarları çıkarmak için ayrı ayrı Hessian matrisinden yararlanmışlardır. Kalın damarların daha iyi belirlenebilmesi amacıyla Otsu yöntemini kullanarak damar yapılarının yerel eşik değerlerini hesaplamışlardır. Hessian matris yöntemi sonucu elde edilen ince damar yapıları ile yerel eşikleme işlemi sonucu elde edilen kalın damar yapıları birleştirilmiştir. Önerilen yöntem DRIVE ve CHASE_DB1 veri kümelerinde test edilmiştir. DRIVE veri kümesinde % 78.51 duyarlılık ve % 95.59 doğruluk sonuçlarına ulaşmışlardır. CHASE_DB1 veri kümesinde % 77.76 duyarlılık ve % 95.05 doğruluk sonuçlarına ulaşmışlardır (Alhussein vd., 2020).

Hesaplama kapasitesindeki ilerlemeyle birlikte, son zamanlarda retina damar bölütlenmesi ve retina hastalığı tespit problemlerinde derin öğrenme tabanlı yöntemler uygulanmaya başlanmıştır. Bir kodlayıcı-kod çözücü mimarisi olarak derin U-Net ağı (Ronneberger vd., 2015), öznetelik çıkarımındaki üstünlüklerinden dolayı retinadaki vasküler yapının çıkarılmasına uyarlanmış en popüler bölütlenme yöntemlerinden biridir.

Zhang ve arkadaşları retina damar bölütlenmesi için çok etiketli mimari U-Net modelini kullanmışlardır. Çok etiketli mimari sayesinde oluşturulan sistem ince ve kalın damarların başlangıç ve bitiş noktalarını daha iyi bir performansla tespit edebilmektedir. Önerilen U-Net modeli DRIVE, STARE ve CHASE_DB1 veri kümelerinde eğitilmiş ve test edilmiştir. DRIVE veri kümesinde eğri altında kalan alan (AUC) % 97.99, STARE veri kümesinde % 98.82 AUC ve CHASE_DB1 veri kümesinde % 99.00 AUC değerine ulaşmışlardır (Zhang vd., 2018).

Bir diğer denetimli retina damar bölütlenmesi çalışmasında kayıp seviye fonksiyonlu U-Net modeli kullanılmıştır. Yan ve arkadaşları önerdikleri modeli DRIVE, STARE ve CHASE_DB1 veri kümelerinde eğitmiş ve test etmiştir. Önerilen yöntem ile DRIVE veri kümesinde % 76.53 duyarlılık, % 98.18 özgüllük, % 95.42 doğruluk ve % 97.52 AUC sonuçları elde edilmiştir. STARE veri kümesinde % 75.81 duyarlılık, % 98.46 özgüllük, % 96.12 doğruluk ve % 98.01 AUC sonuçları elde edilmiştir. CHASE_DB1

veri kümesinde % 76.33 duyarlılık, % 98.09 özgüllük, % 96.10 doğruluk ve % 97.81 AUC sonuçları elde edilmiştir. Kayıp seviye fonksiyonu kullanılmasıyla derin ağ mimarisini önemli ölçüde değiştirmeden performans iyileştirilmiştir (Yan vd., 2018).

Wu ve arkadaşları tarafından yapılan bir diğer çalışmada genelden özele çok ölçekli ağ mimarisi içeren U-Net modeli kullanılmıştır. Önerilen modelde, fundus görüntülerini çok katmanlı örneklerle ayırmışlardır. Damar bölütlenme sonucuna ulaşmak için üretilen çok katmanlı örneklerin olasılıksal ortalamaları alınmıştır. Wu ve arkadaşları tasarladıkları modeli DRIVE ve CHASE_DB1 veri kümelerinde test etmişlerdir. DRIVE veri kümesinde, ortalama doğruluk % 95.67, ortalama özgüllük % 98.19, ortalama duyarlılık % 78.44 ve AUC % 98.07 sonuçlarına ulaşmışlardır. CHASE_DB1 veri kümesinde, ortalama doğruluk % 96.37, ortalama özgüllük % 98.47, ortalama duyarlılık % 75.38 ve AUC % 98.25 sonuçlarına ulaşmışlardır (Wu vd., 2018).

Wu ve arkadaşları retina damar bölütlenmesi için yaptıkları diğer bir çalışmada ağlar arası bağlantı takibi U-Net tabanlı model önermişlerdir. Eğitim kümesine genişletme uygulanmıştır. Önerilen modelde, genişletilmiş görüntülerde sığ katmanlardan derin katmanlara doğru bağlantı takibi yapılarak model eğitilmiştir. Damar bölütlenme sonucuna ulaşmak için üretilen çok katmanlı örneklerin olasılıksal ortalamaları alınmıştır. Wu ve arkadaşları çalışmalarını DRIVE, STARE ve CHASE_DB1 veri kümelerinde test etmişlerdir. Önerilen modelin eğitimi 30 tekrarlamaya ile yapılmıştır. DRIVE veri kümesinde eğitimin süresi her döngü için 3200 saniye, test süresi her döngü için 80 saniye sürmektedir. STARE veri kümesinde eğitimin süresi her döngü için 2700 saniye, test süresi her döngü için 96 saniye sürmektedir. CHASE_DB1 veri kümesinde eğitimin süresi her döngü için 4400 saniye, test süresi her döngü için 200 saniye sürmektedir. DRIVE veri kümesinde, ortalama doğruluk % 95.82, ortalama özgüllük % 98.13, ortalama duyarlılık % 79.96 ve AUC % 98.30 sonuçlarına ulaşılmıştır. STARE veri kümesinde, ortalama doğruluk % 96.72, ortalama özgüllük % 98.63, ortalama duyarlılık % 79.63 ve AUC % 98.75 sonuçlarına ulaşılmıştır. CHASE_DB1 veri kümesinde, ortalama doğruluk % 96.88, ortalama özgüllük % 98.80, ortalama duyarlılık % 80.03 ve AUC % 98.94 sonuçlarına ulaşılmıştır (Wu vd., 2020).

Bir diğ er retina damar b l tlenmesi  alıřmasında genelden  zele denetimli mimari U-Net modeli kullanılmıřtır. Model  zetle y ksek olasılıkları kullanarak retina damar haritasını tahmin etmektedir. Ayrıca eđitim k mesine  zellik b y tme mod l  uygulanmıřtır.  nerilen y ntemin DRIVE, STARE ve CHASE_DB1 veri k meleriyle performansı deđerlendirilmiřtir. DRIVE veri k mesinde ortalama dođruluk % 95.67, ortalama  zg ll k % 98.13, ortalama duyarlılık % 78.49 ve AUC % 97.88 sonu larına ulařılmıřtır. CHASE_DB1 veri k mesinde ortalama dođruluk % 96.48, ortalama  zg ll k % 98.42, ortalama duyarlılık % 79.48 ve AUC % 98.47 sonu larına ulařılmıřtır. STARE veri k mesinde ortalama dođruluk % 98.49, ortalama  zg ll k % 99.34, ortalama duyarlılık % 90.24 ve AUC % 99.60 sonu larına ulařılmıřtır (Wang vd., 2020).

Wu ve arkadařları  ok  l ekli bařlangı  ve ResNet blok mimarisi y ntemi kullanarak U-Net tabanlı bir model  nermiřlerdir.  nerilen modelde retina g r nt lerindeki ince damarları ve kılcal yapıları dođru bir řekilde b l tleyerek bařarımı arttırmak ama lanmıřtır. Wu ve arkadařları tarafından geliřtirilen y ntem DRIVE ve CHASE_DB1 veri k meleri  zerinde umut verici sonu lar vermiřtir.  nerilen y ntemle, DRIVE veri k mesinde % 95.78 dođruluk, % 98.02  zg ll k, % 80.38 duyarlılık ve AUC % 98.21 sonu ları elde edilmiřtir. CHASE_DB1 veri k mesinde % 96.61 dođruluk, % 98.14  zg ll k, % 81.32 duyarlılık ve AUC % 98.60 sonu ları elde edilmiřtir (Wu vd., 2019).

Bir diğ er retina b l tlenmesi  alıřmasında U-Net tabanlı uzamsal aktivasyon mod l   nerilmiřtir. Ma ve arkadařları tarafından  nerilen y ntem ile fundus g r nt lerine  n iřlem uygulanmaksızın t m retina atardamar, toplardamar ve kılcal yapıları tek seferde  ıkarılabilmektedir.  nerilen denetimli y ntem DRIVE ve INSPIRE-AVR veri k melerinde test edilmiřtir. DRIVE veri k mesinde % 94.5 dođruluk, % 93.4 duyarlılık ve % 95.5  zg ll k sonu larına ulařılmıřtır. INSPIRE-AVR veri k mesinde ise % 91.6 dođruluk, % 92.4 duyarlılık ve % 91.3  zg ll k deđerleri bulunmuřtur (Ma vd., 2019).

Alom ve arkadaşları tarafından U-Net mimarisinin kullanım alanları üzerine bir derleme çalışması yapılmıştır. Derin öğrenme tabanlı bölütleme çalışmalarında U-Net ve türevlerinin en yüksek başarı oranını yakaladığı görülmüştür. U-Net tabanlı modeller özellikle tıbbi görüntülerde sınıflandırma, bölütleme ve tespit görevleri açısından popüler hale gelmiştir. Tıbbi görüntülerden damar bölütlenmesi için U-Net tabanlı tekrarlayan artık çerçeve mimari modeli en umut verici yaklaşım olmuştur (Alom vd., 2019).

Son olarak; Mishra ve arkadaşları tarafından retina damar segmentasyonu için U-Net tabanlı duyarlı denetim yolu mimari modeli uygulanmıştır. Önerilen model ile retinadaki ince damar yapılarının bölütleme başarısı arttırılmıştır. Çalışmalarını DRIVE, CHASE_DB1 ve STARE veri kümelerinde test etmişlerdir. DRIVE veri kümesinde % 95.40 doğruluk, % 96.01 özgüllük, % 89.16 duyarlılık ve AUC % 97.24 sonuçları elde edilmiştir. CHASE_DB1 veri kümesinde % 96.01 doğruluk, % 96.51 özgüllük, % 88.05 duyarlılık, AUC % 97.63 sonuçları elde edilmiştir. STARE veri kümesinde % 95.71 doğruluk, % 96.34 özgüllük, % 87.71 duyarlılık ve AUC % 97.42 sonuçları elde edilmiştir (Mishra vd., 2020).

BÖLÜM 3

DENETİMSİZ ÖN İŞLEME VE DERİN ÖĞRENME


YÖNTEMLERİ

3.1. Denetimsiz Ön Hazırlık İşlemleri


3.1.1. Renk Uzayı Ayrılması

Renkli sayısal görüntüleri oluşturan en küçük yapı birimine piksel denir. Her piksel kırmızı, yeşil ve mavi olmak üzere 3 kanaldan oluşmaktadır. Her kanal adını aldığı ana renkleri temsil etmektedir. Görüntüyü oluşturan her bir pikselin insan gözü tarafından algılanan rengi, o pikseli oluşturan kanalların farklı kombinasyonlarıyla sağlanmaktadır. DRIVE veri kümesinin 27. renkli retina görüntüsü Şekil 3.1’de gösterilmiştir.

Aynı retina görüntüsünün kırmızı – yeşil – mavi kanallara ayrılmış hali Şekil 3.2’de gösterilmiştir.



Şekil 3.1. DRIVE veri kümesi 27. renkli retina görüntüsü



(a)

(b)

(c)

Şekil 3.2. DRIVE veri kümesi 27. (a) kırmızı (b) yeşil (c) mavi kanal görüntüsü

Sayısal görüntülerin renk değerleri ana renklerin (kırmızı, yeşil ve mavi) farklı ton değerleri ile kombinasyonu sonucunda ara renkler (sarı, turuncu, mor, turkuaz ve beyaz) elde edilmektedir.

Renkli retina görüntülerinde, kırmızı ve mavi kanal görüntünün parlaklığını belirlemektedir. Retina damar örgüsü bilgisi ve arka plan zıtlığı yeşil kanal üzerinde tutulmaktadır. Renkli retina görüntülerine kanal ayırma işlemi uygulanması görüntüde meydana gelen aydınlatma kusurlarını ve gürültüyü azaltmada etkili ve basit bir yöntemdir.

Kırmızı – yeşil – mavi kanal ayrılma işlemi renkli retina fundus görüntülerine Matlab yazılım platformunda kodlanarak yapılmıştır.

3.1.2. Gri Seviye Dönüşümü

Gri seviye dönüşümü uygulanmış bir görüntü, yalnızca renklerin gri tonlarının olduğu bir görüntüdür. Gri görüntü, Red-Green-Blue (RGB) renk uzayında kırmızı-yeşil-mavi kanalların tamamının eşit yoğunluğa sahip olduğu bir görüntüdür. Bu sebeple, gerekli olan 3 yoğunluk değeri yerine her bir piksel değerine yalnızca tek bir yoğunluk değeri atamak yeterlidir. Gri tonlama yoğunluğu 0 ile 255 arasında değerler almaktadır. Gri tonlama da 0 değeri siyah rengi ve 255 değeri ise beyaz rengi ifade etmektedir. Gri tonlanmış görüntüler, görüntü işleme çalışmalarında bazı problemler için görüntü hakkında yeterli bilgiyi sağlamaktadır. Ayrıca gri tonlanmış görüntü üzerinde işlem yapmak renkli görüntüye kıyasla daha hızlıdır.

Bir renkli görüntüyü gri tonlamalı görüntüye çevirmek için ortalama yöntem veya ağırlıklı yöntem kullanılmaktadır. Ortalama yöntemde gri tonlama değeri; kırmızı (K), yeşil (Y) ve mavi (M) değerlerin ortalamasını alarak belirlenir.

$$Gri\ Tonlama = (K + Y + M)/3 \quad (3.1)$$

Ortalama yöntemi basit olsa da beklenildiği kadar iyi çalışmamaktadır, çünkü üç renk dağılımında farklı ağırlıklara sahip olmalıdır. Parlaklık yöntemi olarak da adlandırılan ağırlıklı yöntemde gri tonlama değeri; kırmızı (K), yeşil (Y) ve mavi (M) dalga boylarının ağırlıklı hesaplamasına göre belirlenir.

$$Gri\ Tonlama = [(0,299 * K) + (0,587 * Y) + (0,114 * M)] \quad (3.2)$$

Renkli retina fundus görüntülerine ağırlıklı yöntem kullanılarak gri seviye dönüşümü yapılmıştır.

3.1.3. Wiener Filtreleme

Wiener filtreleme, görüntüdeki gürültü seviyesini azaltmak amacıyla olasılıksal yaklaşıma dayanan, doğrusal ve alçak geçirgen filtreleme yöntemidir. Sayısal görüntü işlemede sabit güç eklemeli gürültü ile bozulmuş görüntülerde parazit giderme yöntemi olarak sıklıkla tercih edilmektedir (Alhussein vd., 2020, Santos vd., 2020).

Wiener filtreleme yönteminin genel prensibi tahmini görüntü ile orijinal görüntü arasındaki hatayı en aza indirmektir. Wiener filtreleme komşuluğun ortalamasını ve varyansını hesaplar. Varyans değeri yüksek olduğunda zayıf seviyeli yumuşatma ya da varyans değeri düşük olduğunda daha güçlü seviyeli yumuşatma işlemini adaptif olarak uygulamaktadır. Wiener filtreleme işlemi uygulanırken orijinal görüntünün bilinmesine gerek duyulmamaktadır, fakat “gürültü ve görüntü bağlantılı değildir”, “gürültü ve görüntü ortalaması sıfırdır” ve “tahmin edilen görüntüdeki yoğunluk seviyesi doğrusal bir fonksiyon tarafından ifade edilir” gibi 3 adet varsayıma dayanmaktadır (Santos vd., 2020). Kısaca gürültülü görüntü üzerinde işlem yapılır ve bozulmamış görüntü tahmin edilebilmektedir.

Retina fundus görüntülerine Wiener filtreleme, 2x2 boyutunda ve 0,015 gürültü gücüyle uygulanmıştır. Wiener filtreleme işleminin parametre değerleri literatürdeki etkililiği kanıtlanmış değerler göz önüne alınarak seçilmiştir (Alhussein vd., 2020, Santos vd., 2020, Sahu vd., 2019).

3.1.4. Medyan Filtreleme

Medyan filtreleme, doğrusal olmayan uzamsal filtre yöntemidir. Medyan filtreleme işlemi görüntüdeki gürültüyü gidermek amacıyla yaygın olarak kullanılmaktadır. Medyan filtrelemede $M \times M$ boyutuna sahip bir maske, görüntü üzerinde kaydırılır. Görüntünün maske içinde kalan merkez piksel ve komşu piksel değerleri küçükten büyüğe sıralanır. Bu sıralama işleminde ortadaki değer merkez piksele atanır.

Retina fundus görüntülerine denetimsiz ön hazırlık işlemi basamağında 3×3 boyutunda medyan filtreleme uygulanmıştır. Ayrıca, son işleme olarak elde edilen retina damar haritasına 3×3 ve 5×5 boyutlarında medyan filtreleme işlemi de uygulanmıştır.

3.1.5. Kontrast Sınırlı Adaptif Histogram Eşitleme (KSAHE)

Histogram, bir görüntüdeki renk değerlerinin sıklığını gösteren grafikdir. Zıtlık ise görüntüdeki belirli bir nesneyi diğer nesnelerden ayırt edilebilir kılmaktır. Histogram eşitleme, görüntülerdeki zıtlığı iyileştirmek amacıyla yaygın olarak kullanılan görüntü işleme tekniğidir. Bir başka deyişle, resimdeki renk değerlerinin belirli yerlerde yığılmasından kaynaklanan renk dağılım bozukluğunu gidererek zıtlığı artırma yöntemidir. Ancak histogram eşitleme, görüntüdeki piksel değerlerinin dağılımı görüntü boyunca benzer olduğunda başarılı olmaktadır. Adaptif histogram eşitleme, histogram eşitleme yönteminin eksikliklerini gidermek amacıyla bir görüntü için birden çok histogram hesaplama algoritmasıdır. Hesaplanan her histogram görüntünün belirli bir bölgesine karşılık gelmektedir. Adaptif histogram eşitleme yöntemiyle görüntüdeki ilgilenilen nesnenin zıtlığı daha da artırılabilir. Bununla birlikte adaptif histogram eşitleme algoritması yeni bir sorunu ortaya çıkarmaktadır. Adaptif histogram eşitleme yöntemiyle işlenmiş yüksek gürültü içeren medikal görüntülerde zıtlığın aşırı artırılması görüntünün belirli bölgelerindeki gürültünün de artmasına sebep olmaktadır. Kontrast sınırlı adaptif histogram eşitleme (KSAHE) yöntemi ise yükseltilmiş gürültüyü azaltmak amacıyla kontrastı üst sınır değeriyle sınırlamaktadır. Histogramın üst sınırını aşan kısmını görüntünün tüm histogramlarına eşit olarak dağıtır. Bunun sonucunda,


görüntüdeki ilgilenilen nesnenin kontrastlık seviyesi artarken, özellikle medikal görüntüdeki gürültü seviyesi artışı engellenmektedir.

Sayısal retina görüntülerine ön işlem olarak 8x8 karo boyutunda KSAHE yöntemi uygulanmıştır. Kontrast üst sınırı 0,001 ile 0,040 değerleri arasında uygulanmıştır.

3.1.6. Veri Kümesi Genişletme

Veri kümesi genişletme işleminin ilk basamağında, eğitim kümesinin orijinal fundus görüntüleriyle denetimsiz ön hazırlık işlemlerinden elde edilen sonuçlar sırasıyla; KSAHE sonuçları, matematiksel morfoloji işlemi sonuçları, Coye filtreleme ve bağlantılı bileşen analizi işlemi sonuçları birleştirilmiştir. Bu aşamada eğitim kümesinin fundus görüntüleri ile zıtlığı arttırılmış ve aydınlatma farklılıkları giderilmiş ve toplamda 80 adet fundus (her 20 adette bir kendini tekrar eder) görüntüsü elde edilmiştir. Bu aşamada gerçek referans görüntülerine herhangi bir işlem uygulanmamıştır. Bu veri kümesi “Ön işlenmiş eğitim veri kümesi” olarak isimlendirilmiştir.

Veri kümesi genişletme işleminin ikinci basamağında, ön işlenmiş eğitim veri kümesindeki retina görüntüleri ve gerçek referans görüntülerine sırasıyla; sadece yatay ekseninde yansıma, sadece dikey ekseninde yansıma, hem yatay hem dikey ekseninde yansıma ve açısal döndürme işlemi uygulanmıştır. Açısal döndürme işlemindeki açı değerleri; 30⁰ ve 60⁰ olarak uygulanmıştır. Veri kümesi genişletme işlemi sonucunda eğitim kümesi 5 katına çıkarılmıştır. Veri kümesi genişletme işlemi sonucunda elde edilen görüntüler Şekil 3.3’te gösterilmiştir.



Şekil 3.3. Veri kümesi genişletme uygulanmış (a) Orijinal (b) yatay eksende yansıma (c) dikey eksende yansıma (d) hem yatay hem de dikey eksende yansıma (e) 30^0 'lik açısal döndürme (f) 60^0 'lik açısal döndürme görüntüsü


Veri kümesi genişletme işlemi, derin öğrenme modelinin başarısını arttırmak amacıyla Matlab yazılım platformunda kodlanarak uygulanmıştır.

3.2. Matematiksel Morfoloji Kullanarak Retina Damar Bölütlenmesi

Matematiksel morfoloji kullanılarak retinadaki vasküler yapının ayrılması için renkli fundus görüntüleri RGB kanal ayrıştırma, gri seviye dönüşümü, Wiener filtreleme ve KSAHE ön işlemlerinden geçirilmiştir. Ön işlem sonucunda görüntüdeki gürültü seviyesi azaltılmış ve görüntünün zıtlığı arttırılmıştır. Matematiksel morfoloji yöntemine başlamadan önce elde edilen gri seviyeli görüntülere negatif dönüşüm uygulanmıştır. Negatif dönüşüm; gri tonlanmış görüntüdeki her bir piksel değerinden 255 çıkarılıp elde edilen sonucun mutlak değerinde tekrar o piksele atanmasıyla gerçekleştirilir. Başka bir deyişle, gri tonlu görüntüde siyah piksel beyaza, beyaz piksel ise siyaha dönüştürülür. Negatif dönüşüm işlemi matematiksel morfoloji kullanılarak elde edilen damar haritasında damar örgüsünü ikili görüntüde beyaz renkte elde etmek amacıyla uygulanmıştır.

Matematiksel morfoloji kullanılarak retinadaki vasküler yapının ayrılması iki adımda yapılmıştır. İlk olarak, negatif dönüşüm uygulanmış retina görüntüsüne sırasıyla $2B - 9 \times 9$ Gauss ve $2B - 9 \times 9$ Laplacian filtreleri uygulanarak görüntüler bulanıklaştırılmıştır. Filtreleme işlemlerinin sonucu, negatif dönüştürülmüş retina görüntülerinden sırasıyla matematiksel olarak çıkarılmıştır. Son olarak, fark alma işlemi sonucunda retina görüntüsündeki temel vasküler yapılar elde edilmiştir. Fark alma işlemi sonucunda görüntülerdeki gürültü erozyon işlemi kullanılarak giderilmeye çalışılmıştır. Damar örgüsündeki olası kayıpları engellemek amacıyla da genişletme işlemi uygulanmıştır. Şekil 3.4'te matematiksel morfoloji yönteminin akış şeması verilmiştir. Bu sayede, temel vasküler yapıları içeren görüntüde 10 pikselden küçük yapılar silinmiş ve 180 pikselden büyük yapılar da kalınlaştırılmıştır. Fark alma işleminden dolayı gürültüler giderilmiş ve vasküler yapının sürekliliği sağlanmıştır.

Matematiksel morfoloji işleminin sonucunda elde edilen damar örgüsüne; ikili görüntüye çevirme ve $2B - 3 \times 3$, $2B - 5 \times 5$ medyan filtreleme olarak son işlemler Matlab yazılım platformunda kodlanarak uygulanmıştır.



Şekil 3.4. Matematiksel morfoloji yöntemi akış şeması


3.3. Coye Filtreleme ve Bağlantılı Bileşen Analizi Kullanarak Retina Damar Bölütlenmesi

Coye filtreleme işlemi, Tyler L. Coye tarafından 2015 yılında tasarlanmıştır. Coye filtreleme işlemi dört adımda yapılmaktadır. İlk olarak, renkli retina görüntülerine; RGB kanal ayrıştırma, gri seviye dönüşümü, Wiener filtre ve KSAHE gibi ön işlemler uygulanmıştır. Ön işlem sonucunda görüntüdeki gürültü seviyesi azaltılmış ve görüntünün zıtlığı artırılmıştır. İkinci olarak, ön işlem sonucunda elde edilen görüntülere $2B - 9 \times 9$ ‘ortalama filtre’ uygulanarak retina görüntüleri bulanıklaştırılmıştır. Üçüncü adımda, bulanıklaştırılan retina görüntüsü ile ön işleme sonucunda elde edilen gri seviyeli retina görüntüsü birbirinden matematiksel olarak çıkarılmıştır. Bu işlem sonunda retinadaki vasküler yapıların sınırları belirlenmiştir. Şekil 3.5’te Coye filtreleme ve bağlantılı bileşen analizi yönteminin akış şeması verilmiştir. Coye filtreleme işleminin esas amacı, her retina görüntüsüne göre adaptif eşik değeri belirlemektir. Belirlenen eşik değeri, vasküler yapının eşik değeridir. Bu sayede retinadaki ince vasküler yapılar daha iyi tespit edilebilmektedir.

Coye filtreleme işlemi sonunda elde edilen görüntü ikili görüntüye dönüştürülmüştür. Elde edilen ikili görüntüye $2B -$ Medyan filtreleme uygulanmış ve sonuçlar karşılaştırılmıştır.

Bağılantılı bileşen analizi, düşük aydınlatmalı ya da parlak ışık gürültüsü olan retina görüntülerindeki vasküler yapıyı içine alan daire şeklindeki gürültünün yok edilmesi amacıyla kullanılmıştır. Bu işlemlerden sonra elde edilen görüntü ‘Coye – BBA’ olarak isimlendirilmiştir.


Coye filtreleme ve bağlantılı bileşen analizi Matlab yazılım platformunda kodlanarak uygulanmıştır.



Şekil 3.5. Coye filtreleme ve bağlantılı bileşen analizi yöntemi akış şeması

3.4. Derin Öğrenme U-Net Modeli Mimarisi

Hesaplama kapasitesindeki ilerlemeyle birlikte, son zamanlarda retina damar haritası çıkarımı ve retina hastalığı tespit problemlerinde derin öğrenme tabanlı yöntemler yaygın olarak uygulanmaktadır. Bu tez çalışmasında, bir kodlayıcı-kod çözücü mimarisi olarak derin U-Net ağı özellik çıkarımındaki üstünlüklerinden dolayı kullanılmıştır. Ayrıntılı U-Net ağ mimarisi Şekil 3.6’da verilmiştir.



Şekil 3.6. Ayrıntılı derin U-net mimarisi

Derin U-Net mimarisi kodlayıcı ağı ve kod çözücü ağı olmak üzere 2 temel bileşenden oluşmaktadır. Kodlayıcıda 16 katmanlı 3x3 konvolüsyonunu bir ReLU aktivasyonu ve bir 2x2 boyutunda en yüksek eşleşme katmanı izlemektedir. Kodlayıcıda her adım sonunda toplam katman sayısı iki katına çıkmaktadır.

Kod çözücü mimarisinde tüm aşamalarda 3x3' lük konvolüsyon uygulanmaktadır. Kod çözücü bileşenindeki her aşamada katman sayısı yarıya indirilmektedir. Son katmanda, toplam kanalları sınıf sayısına (Toplam 2 sınıftan oluşmaktadır; arka plan ve damar haritası) indirmek için 1x1'lik konvolüsyon uygulanmıştır.

Derin U-Net mimarisi, ikili çapraz entropi kaybıyla eğitilmiştir. Derin öğrenme modelinin teorik yaklaşımı Denklem 3.3' te verilmiştir.

$$L(y, \hat{y}) = -\frac{1}{M} \sum_{j=0}^M \sum_{i=0}^N (y_{ij} \log(\hat{y}_{ij})) \quad (3.3)$$

Derin öğrenme U-Net mimarisinde, rastgele seçilen her 20 görüntüde 16 adet görüntü modelin eğitime kullanılırken geriye kalan diğer 4 adet görüntü ise modelin eğitim başarısını doğrulamak üzere kullanılmıştır. Ayrıca, eğitim modeli 0,01 öğrenme oranıyla ve rastgele optimizasyon yöntemi (ADAM) algoritmasıyla gerçekleştirilmiştir.

Derin U-Net model mimarisinin eğitimi ve testi ücretsiz erişime imkân sağlayan Google Colab platformunun 12 GB'lık GPU'larında Keras kütüphanesinin Tensorflow fonksiyonlarıyla kodlanarak gerçekleştirilmiştir.

3.5. Sonuç Bütünleştirme


Çalışma kapsamında önerilen algoritma 3 paralel kolda ilerlemektedir. Her aşamanın dahil edilme nedeni farklıdır.

Matematiksel morfoloji yöntemi, retina damar bölütlenmesindeki temel vasküler yapıların sürekliliklerini sağlamak amacıyla kullanılmıştır. Bu işlem sonrasında çıkan damar haritası 'Sonuç 1' olarak isimlendirilmiştir.

“Coye – BBA” işlemi, retina damar bölütlenmesindeki ince vasküler yapıların haritasını çıkarmak için kullanılmıştır. Bu işlem sonrasında çıkan damar haritası 'Sonuç 2' olarak isimlendirilmiştir.

Derin öğrenme U-Net modeli ise retinadaki vasküler yapıyı diğer anatomik yapılar ve patolojik bulgulardan başarılı bir şekilde ayırmak için kullanılmıştır. Bu işlem sonrasında çıkan damar haritası 'Sonuç 3' olarak isimlendirilmiştir.

Elde edilen sonuçlar Matlab yazılım platformunda mantıksal VEYA (OR) işlemi kullanılarak bütünleştirilmiştir. Birleştirme işlemi sonrasında çıkan sonuç 'Retina Vasküler Damar Haritası' olarak isimlendirilmiştir. Önerilen yöntemin akış şeması Şekil 3.7'de verilmiştir.



Şekil 3.7. Önerilen yöntemin akış şeması

3.6. Değerlendirme Ölçütleri

Denetimsiz retina damar bölütlenmesi ve derin öğrenme mimarisinin başarısını değerlendirmek amacıyla kullanılan çeşitli yöntemler mevcuttur. Bu yöntemlerde elde edilen örneklerin doğru veya yanlış tahmin edilme durumları incelenmektedir. Önerilen hibrit yöntem, elde edilen retina damar haritasındaki vasküler yapıları pozitif olarak tahmin ettiyse örnek gerçek pozitif (GP) olarak ifade edilir. Aynı örnek, hibrit yöntem tarafından negatif olarak tahmin edilirse yanlış pozitif (YP) olarak değerlendirilir. Önerilen yöntem negatif sınıftaki örneği negatif tahmin ederse gerçek negatif (GN), pozitif belirlerse yanlış negatif (YN) olarak tanımlanmaktadır.

Çizelge 3.1. Sınıflandırıcı tahminine göre karmaşıklık matrisi

TAHMİN	GERÇEK		
		Pozitif	Negatif
	Pozitif	Gerçek Pozitif (GP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Gerçek Negatif (GN)

Çizelge 3.1.'de hata matrisinde yer alan değerler sunulmuştur. Bu değerlerle yapılacak işlemler sonucunda değerlendirme parametrelerinden duyarlılık, özgüllük, doğruluk, kesinlik ölçütleri hesaplanacaktır ve algoritma işlem süresi verilecektir.

3.6.1. Duyarlılık

Duyarlılık parametresi, doğru sınıflandırılmış pozitif örneklerin istatistiksel olarak gösterilmesidir. Çalışmamızda kullanılan veri kümelerindeki her bir retina görüntüsü için doğru tahmin edilen vasküler yapıya ait piksel sayısının toplam pozitif piksel sayısına oranını ifade etmektedir.

$$Duyarlılık = \frac{GP}{GP+YN} \quad (3.4)$$

3.6.2. Özgüllük

Özgüllük parametresi, doğru sınıflandırılmış negatif örneklerin istatistiksel olarak gösterilmesidir. Çalışmamızda kullanılan veri kümelerindeki her bir retina görüntüsü için doğru tahmin edilmiş vasküler yapı içermeyen piksel sayısının toplam negatif piksel sayısına oranını ifade etmektedir.

$$\text{Özgüllük} = \frac{GN}{GN+YP} \quad (3.5)$$

3.6.3. Doğruluk

Doğruluk; ikili sınıflandırma sonucu ulaşılan doğru sınıflandırılmış örnek sayısının veri kümesindeki eleman sayısına oranı olarak tanımlanır. Tez çalışmamızda kullandığımız veri kümelerindeki her bir görüntü için doğruluk parametresiyle retina damar haritasının piksel sayısının ne kadarının gerçek pozitif (GP) ve gerçek negatif (GN) tahmin edilebildiği anlaşılmaktadır.

$$\text{Doğruluk} = \frac{GP+GN}{GP+GN+YP+YN} \quad (3.6)$$

3.6.4. Kesinlik

Kesinlik parametresi; pozitif olarak sınıflandıran değerlerin gerçek pozitif (GP) sayısını ifade etmektedir. Çalışmamızda kullanılan veri kümelerindeki her bir retina görüntüsünde vasküler yapıyı içeren piksel sayısının değerini belirlemektedir. Bir başka deyişle, kesinlik ölçütü retina görüntülerinin kalitesini ifade etmektedir. Gürültü ve aydınlatma kusurları içermeyen ya da başarılı ön işlemde geçirilmiş retina görüntülerindeki vasküler yapılar daha başarılı bir şekilde gerçek pozitif (GP) olarak işaretlenebilmektedir.

$$\text{Kesinlik} = \frac{GP}{GP+YP} \quad (3.7)$$

3.6.5. İşlem Süresi

İşlem süresi; denetimsiz görüntü ön işleme tabanlı işlemlerin ve derin öğrenme tabanlı yaklaşımın eğitim aşamasında her bir görüntü için devir başına geçen süreyi ifade etmektedir. Bir başka ifadeyle, işlem süresi derin öğrenme tabanlı yöntemin hesaplama yükü olarak tanımlanmaktadır. İşlem süresi saniye (sn) olarak ifade edilmektedir.



BÖLÜM 4

DENEYSEL SONUÇLAR

Bu tez çalışmasının amacı, araştırmacıların erişimine açık olan DRIVE ve HRF veri kümelerindeki hasta ve sağlıklı katılımcılardan elde edilen retina fundus görüntülerinden retina damar haritasının yüksek başarımla elde edilmesidir. Bu amaçla, farklı retina fundus görüntülerine denetimsiz ve derin öğrenme tabanlı yöntemler uygulanarak ince ve kalın vasküler yapıların bölütlenme başarıları incelenmiştir. Ayrıca söz konusu yöntemler hem ayrı ayrı hem de birlikte kullanıldıklarında elde edilen retina damar haritası sonuçlarının literatüre göre başarıları değerlendirilmiştir.

Denetimsiz ve derin öğrenme tabanlı yaklaşımda kullanılan yöntemlerin sırası ve parametre değerleri DRIVE veri kümesi üzerinde belirlenmiştir. DRIVE veri kümesinden elde edilen anlamlı bulgular doğrultusunda, önerilen hibrit yaklaşımın başarıları HRF veri kümesi üzerinde değerlendirilmiştir.

Tez çalışması süresince fundus görüntülerinin ön ve son işlenmesi, veri kümesi genişletme işlemleri ve sonuçların karşılaştırılması Matlab yazılım platformunda yapılmıştır. Ayrıca derin öğrenme mimarisinin eğitim ve test aşamaları Google COLAB platformunda gerçekleştirilmiştir.


4.1. Denetimsiz Retina Damar Bölütlenmesi

Bu bölümde, çalışma kapsamında retina fundus görüntülerine denetimsiz uygulanacak işlemlerde uygun parametre değerlerinin tespiti, işlem sırası ve yöntemin başarısı değerlendirilmiştir. Fundus görüntülerine gürültü gidermek için yapılan RGB kanal ayrışması, 3x3 – Medyan filtreleme, Wiener filtreleme gibi ön işlemlerin retina damar haritası çıkarımındaki etkinliği değerlendirilmiştir. Ayrıca retina görüntülerindeki damar – doku zıtlığını arttırmak amacıyla denetimsiz uygulanan KSAHE yöntemindeki uygun kontrast üst sınır değeri araştırılmıştır. Son olarak, elde edilen ikili görüntülere uygulanan 3x3 ve 5x5 maske boyutuna sahip Medyan filtrelemenin sonuçlara etkisi incelenmiştir.

4.1.1. KSAHE Yönteminde Kontrast Üst Sınırın Belirlenmesi

Kontrast sınırlı adaptif histogram eşitleme (KSAHE), tıbbi görüntülerdeki kontrastı iyileştirmek ve ilgilenilen doku görünürlüğünü arttırmak amacıyla yaygın olarak kullanılan denetimsiz görüntü işleme yöntemidir. KSAHE yönteminde uygun kontrast üst sınır değerinin kullanılması, yöntemin başarısını arttırmaktadır.

DRIVE veri kümesinin eğitim kümesi (21 - 40) kullanılarak uygun kontrast üst sınır değeri belirlemek amacıyla, kontrast üst sınır değerinin doğruluk ölçütü üzerindeki değişimi incelenmiştir. Uygun kontrast üst sınır değerini tespit etmek için DRIVE'nin eğitim kümesindeki (21 – 40) her bir görüntüsüne sırasıyla yeşil kanal ayrışması, gri seviye dönüşümü, KSAHE, adaptif retina damar eşik değeri hesaplama ve ikili görüntü dönüşümü uygulanmıştır. Fundus görüntülerine sıralanan işlemler dışında herhangi bir yöntem uygulanmamıştır. Retina görüntülerine 8x8 karo boyutunda KSAHE yöntemi uygulanmıştır. Yöntemdeki kontrast üst sınır değeri 0,001'den başlayarak 0,040'a kadar 0,001'lik artış miktarıyla DRIVE eğitim kümesindeki (21 – 40) tüm görüntülere uygulanmıştır. Her bir kontrast üst sınır değerine karşılık 20 görüntü için ortalama doğruluktaki değer değişimi incelenmiştir.



Şekil 4.1. Kontrast üst sınırın doğruluğa etkisi

Şekil 4.1’de KSAHE yöntemindeki kontrast üst sınır değerinin DRIVE eğitim kümesindeki (21 – 40) fundus görüntülerinin ortalama doğruluk değerine etkisi gösterilmiştir. Kontrast üst sınır değerinin 0,001 ile 0,017 arasındaki değişimi, ortalama doğrulukta artış eğilimi görülmesini sağlamıştır. Ortalama doğruluk en yüksek % 96.63 sonucuna 0,017 kontrast üst sınır değeriyle ulaşmıştır. Ortalama doğrulukta kontrast üst sınırın 0,017 değerinden itibaren azalma eğilimi gözlenmiştir. Denetimsiz öğrenmenin sağlanması için en iyi çalışan parametre değeri DRIVE eğitim kümesinde (21 - 40) incelenmiştir. KSAHE yöntemindeki en başarılı kontrast üst sınır değeri DRIVE test kümesi (1 – 20) ve HRF kümesinde kullanılmıştır. Anlamlı bulgular doğrultusunda, denetimsiz retina damar bölütlenmesi için KSAHE yönteminin 8x8 karo boyu ve 0,017 kontrast üst sınır değeriyle kullanılması uygun görülmüştür.

4.1.2. Matematiksel Morfoloji Yöntemi Sonucu

Matematiksel morfoloji yöntemini kullanarak, retina damar bölütlenme işleminin başarıyla yapılabilmesi için DRIVE veri kümesindeki 21 ile 40 arasında numaralandırılmış renkli retina görüntülerine yeşil kanal ayrışması ve gri seviye dönüşümü uygulanmıştır. Gri tonlanmış retina görüntülerinin gürültüsünü gidermek amacıyla 3x3 maske boyutuna sahip Medyan filtreleme ve literatürde de doğruluğu kanıtlanmış 2x2 maske boyutunda ve 0.015 gürültü gücüyle Wiener filtreleme işlemi uygulanmıştır (Alhussein vd., 2020, Santos vd., 2020, Sahu vd., 2019). Gürültüsü giderilmiş gri tonlu retina görüntülerindeki damar – doku zıtlığını arttırmak amacıyla kontrast üst sınır değeri 0,017 olarak belirlenmiş 8x8 karo boyutunda KSAHE uygulanmıştır. KSAHE işlemi ardından gereken matematiksel morfoloji işlemi tamamlanmıştır. Morfolojik işlem sonrasında elde edilen damar görüntülerindeki vasküler yapıların eşik değeri her görüntü için adaptif olarak hesaplanarak ikili görüntüye ulaşılmıştır.

Elde edilen görüntüdeki kusurları gidermek ve damar sürekliliğini sağlamak amacıyla ikili görüntülere son işlem olarak 3x3 ve 5x5 maske boyutuna sahip Medyan filtreleme işlemi uygulanmıştır.

Çizelge 4.1, Çizelge 4.2, Çizelge 4.3 ve Çizelge 4.4’ te görüldüğü üzere hem her görüntü için ayrı ayrı hem de ortalama duyarlılık, özgüllük, doğruluk ve kesinlik değerlerine ulaşılmıştır.

Çizelge 4.1. Ön işlemede Wiener filtrelemesiz ve son işlemede 3x3 Medyan filtreleme uygulamasının sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
21.	0.6702	0.9903	0.9663	0.8471
22.	0.5344	0.9957	0.9539	0.9239
23.	0.6666	0.9482	0.9296	0.4752
24.	0.5768	0.9954	0.9468	0.9423
25.	0.3080	0.9994	0.9329	0.9794
26.	0.6494	0.9838	0.9558	0.7850
27.	0.5375	0.9962	0.9557	0.9307
28.	0.5991	0.9930	0.9545	0.9024
29.	0.6503	0.9870	0.9586	0.8202
30.	0.6156	0.9879	0.9586	0.8119
31.	0.5162	0.9970	0.9679	0.9164
32.	0.6672	0.9898	0.9634	0.8532
33.	0.6494	0.9909	0.9632	0.8621
34.	0.4488	0.9876	0.9348	0.7967
35.	0.6900	0.9900	0.9639	0.8675
36.	0.4896	0.9973	0.9420	0.9560
37.	0.6592	0.9875	0.9587	0.8345
38.	0.7245	0.9833	0.9609	0.8034
39.	0.7150	0.9821	0.9591	0.7895
40.	0.6940	0.9892	0.9667	0.8399
ORTALAMA	0.6031	0.9886	0.9547	0.8469

Çizelge 4.2. Ön işlemede Wiener filtrelemesiz ve son işlemede 5x5 Medyan filtreleme uygulamasının sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
21.	0.6326	0.9927	0.9657	0.8741
22.	0.5010	0.9972	0.9523	0.9459
23.	0.6513	0.9538	0.9338	0.4981
24.	0.5527	0.9966	0.9451	0.9550
25.	0.2701	0.9996	0.9295	0.9861
26.	0.6329	0.9864	0.9568	0.8092
27.	0.4742	0.9977	0.9514	0.9503
28.	0.5620	0.9952	0.9528	0.9261
29.	0.6428	0.9892	0.9600	0.8445
30.	0.6032	0.9902	0.9598	0.8396
31.	0.4738	0.9977	0.9660	0.9272
32.	0.6495	0.9917	0.9636	0.8740
33.	0.6255	0.9931	0.9633	0.8877
34.	0.4147	0.9897	0.9333	0.8124
35.	0.6547	0.9922	0.9628	0.8878
36.	0.4404	0.9981	0.9374	0.9653
37.	0.6280	0.9904	0.9586	0.8617
38.	0.7016	0.9862	0.9615	0.8266
39.	0.6866	0.9855	0.9597	0.8160
40.	0.6585	0.9911	0.9658	0.8573
ORTALAMA	0.5728	0.9907	0.9540	0.8673

Çizelge 4.3. Ön işlemede Wiener filtreleme ve son işlemede 3x3 Medyan filtreleme uygulamasının sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
21.	0.7060	0.9838	0.9631	0.7791
22.	0.5271	0.9938	0.9516	0.8936
23.	0.6462	0.9465	0.9267	0.4597
24.	0.5904	0.9912	0.9447	0.8976
25.	0.3396	0.9983	0.9351	0.9543
26.	0.6296	0.9834	0.9538	0.7757
27.	0.5561	0.9925	0.9540	0.8773
28.	0.5991	0.9890	0.9509	0.8549
29.	0.6675	0.9811	0.9547	0.7642
30.	0.6066	0.9874	0.9575	0.8034
31.	0.5936	0.9819	0.9679	0.8249
32.	0.6194	0.9893	0.9591	0.8380
33.	0.6695	0.9853	0.9598	0.8007
34.	0.5596	0.9768	0.9359	0.7231
35.	0.7020	0.9881	0.9633	0.8488
36.	0.5383	0.9947	0.9451	0.9254
37.	0.6599	0.9872	0.9586	0.8317
38.	0.7493	0.9807	0.9607	0.7856
39.	0.7519	0.9771	0.9578	0.7556
40.	0.7376	0.9856	0.9668	0.8076
ORTALAMA	0.6291	0.9876	0.9559	0.8311


Çizelge 4.4. Ön işlemede Wiener filtreleme ve son işlemede 5x5 Medyan filtreleme uygulamasının sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
21.	0.6783	0.9875	0.9644	0.8147
22.	0.4931	0.9953	0.9500	0.9129
23.	0.6283	0.9523	0.9309	0.4813
24.	0.5692	0.9928	0.9438	0.9124
25.	0.2971	0.9989	0.9315	0.9654
26.	0.6156	0.9862	0.9553	0.8030
27.	0.5185	0.9947	0.9527	0.9044
28.	0.5725	0.9915	0.9506	0.8791
29.	0.6613	0.9841	0.9569	0.7922
30.	0.5941	0.9895	0.9585	0.8283
31.	0.5587	0.9934	0.9672	0.8448
32.	0.6058	0.9910	0.9595	0.8577
33.	0.6575	0.9878	0.9611	0.8257
34.	0.5203	0.9800	0.9350	0.7379
35.	0.6702	0.9906	0.9628	0.8708
36.	0.4941	0.9956	0.9411	0.9325
37.	0.6252	0.9895	0.9577	0.8514
38.	0.7256	0.9834	0.9612	0.8052
39.	0.7364	0.9802	0.9593	0.7779
40.	0.7142	0.9875	0.9668	0.8244
ORTALAMA	0.5968	0.9852	0.9533	0.8101

Çizelge 4.5. Matematiksel morfoloji yöntemi başarı özeti

Yöntem Adı	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
Wiener Filtresiz – Medyan 3 x 3	0.6031	0.9886	0.9547	0.8469
Wiener Filtresiz – Medyan 5 x 5	0.5728	0.9907	0.9540	0.8673
Wiener Filtreli – Medyan 3 x 3	0.6291	0.9876	0.9559	0.8311
Wiener Filtreli – Medyan 5 x 5	0.5968	0.9852	0.9533	0.8101

Çizelge 4.5’te verilen özet sonuçlardan anlaşıldığı üzere gürültü gidermek amacıyla uygulanan Wiener filtreleme ve son işlem olarak uygulanan 3x3 maske boyutuna sahip Medyan filtreleme işlemiyle elde edilen ortalama duyarlılık % 62.91 ve ortalama doğruluk % 95.59 diğerlerine göre daha başarılı bulunmuştur. Literatür ile karşılaştırıldığında elde edilen ortalama özgüllük % 98.76 ve ortalama kesinlik % 83.11 değerleri de kabul edilebilir başarı göstermiştir. Son olarak, retina görüntülerine matematiksel morfoloji yöntemi uygulanarak gerçekleştirilen retina damar bölütleme işlemi görüntü başına ortalama 1,3369 sn sürmüştür.




Şekil 4.2. (a) Renkli retina (b) referans (c) matematiksel morfoloji yöntemiyle elde edilen retina damar haritası görüntüsü

Matematiksel morfoloji yöntemi kullanılarak DRIVE veri kümesinin 21. renkli retina görüntüsünden elde edilen retina damar haritası, Şekil 4.2’de referans görüntüsüyle karşılaştırılmalı olarak verilmiştir. Elde edilen görüntü (Şekil 4.2.(c)) dikkatlice incelendiğinde, retinadaki kalın vasküler yapılar rahatlıkla tespit edilebilmesine rağmen ince vasküler yapılarda kayıp olduğu görülmektedir.

4.1.3. Coye Filtreleme ve Bağlantılı Bileşen Analizi Yöntemi Sonucu


Coye filtreleme ve bağlantılı bileşen analizi yöntemini kullanarak retina damar bölütlemesi yapabilmek için DRIVE veri kümesinin 21 ile 40 arasında numaralandırılmış renkli retina görüntülerine RGB kanal ayrıştırılması uygulanmış ve yeşil kanal tercih edilmiştir. Yeşil kanal tercih edilerek görüntülerdeki gürültü ve aydınlatma kusurları rahatlıkla giderilmiş ve ön işlem olarak Wiener filtreye ihtiyaç duyulmamıştır, fakat olası küçük boyutlu gürültüler için 3x3 maske boyutunda Medyan filtre uygulanmıştır. Veri kümesindeki yeşil kanallı görüntüler gri seviye dönüşümü ve 0,017 kontrast üst sınır değeriyle 8x8 karo boyutunda KSAHE uygulanarak işleme devam edilmiştir. Coye filtreleme yöntemi sonrasında elde edilen damar görüntülerindeki vasküler yapıların eşik değeri her görüntü için adaptif olarak hesaplanarak ikili (siyah-beyaz) görüntü elde edilmiştir.



Şekil 4.3. Coye filtreleme yöntemiyle elde edilen retina damar örgüsü ikili görüntüsü

Coye filtreleme işlemi sonucunda DRIVE veri kümesi 21. görüntüsü için elde edilen ikili görüntü Şekil 4.3'te verilmiştir. Coye filtreleme yöntemi ince vasküler yapıları tespit etmede daha başarılı bulunmuştur. Yöntemin başarısına rağmen, ikili görüntülerde retina damar örgüsünü içine alan hare şeklinde yansımalar (retina sınırı) belirmiştir.

Herhangi bir damar bilgisi içermeyen hare şeklinde yansımayı ikili görüntüden kaldırmak amacıyla görüntü işlemede sıklıkla tercih edilen bağlantılı bileşen analizi yöntemi uygulanmıştır. DRIVE veri kümesindeki her bir fundus görüntüsüne karşılık gelen ikili görüntülerde adaptif olarak piksel numaraları belirlenmiştir. Belirlenen piksel numaralarının takip ettiği en büyük çapa sahip ve değeri 1 olan piksellerin değerleri 0 ile değiştirilmiştir. Bağlantılı bileşen analizi sonucunda, ikili görüntülerdeki istenmeyen hare şeklindeki yapı başarıyla yok edilerek damar örgüsü bütünlüğü korunmuştur.



Şekil 4.4. Coye filtreleme ve bağlantılı bileşen analizi yöntemiyle elde edilmiş retina damar örgüsü

Şekil 4.4'te görüldüğü üzere DRIVE veri kümesi 21. görüntüsü için Coye filtreleme ve bağlantılı bileşen analizi yöntemi kullanılarak retina damar örgüsü elde edilmiştir. Coye filtreleme yöntemi ince vasküler yapıları daha iyi tespit edebilirken, kalın vasküler yapıların sürekliliklerinde bozulmalar meydana gelmiştir. Damar sürekliliğini sağlamak amacıyla ikili görüntülere 3x3 ve 5x5 maske boyutuna sahip Medyan filtreleme uygulanmıştır.

Çizelge 4.6, Çizelge 4.7, Çizelge 4.8 ve Çizelge 4.9'da görüldüğü üzere hem her görüntü için ayrı ayrı hem de ortalama duyarlılık, özgüllük, doğruluk ve kesinlik değerlerine ulaşılmıştır.

Çizelge 4.6. Ön işlemede Wiener filtrelemesiz ve son işlemede 3x3 Medyan filtreleme uygulamasının sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
21.	0.6573	0.9915	0.9664	0.8611
22.	0.5015	0.9972	0.9526	0.9457
23.	0.7206	0.9318	0.9178	0.4265
24.	0.4646	0.9992	0.9372	0.9869
25.	0.6219	0.9618	0.9291	0.6332
26.	0.6194	0.9815	0.9511	0.7523
27.	0.5785	0.9932	0.9565	0.8904
28.	0.5728	0.9935	0.9523	0.9046
29.	0.7047	0.9580	0.9366	0.6060
30.	0.6236	0.9878	0.9591	0.8123
31.	0.6615	0.9838	0.9643	0.7236
32.	0.6502	0.9890	0.9612	0.8399
33.	0.6469	0.9918	0.9638	0.8735
34.	0.5934	0.9642	0.9278	0.6423
35.	0.6712	0.9908	0.9630	0.8727
36.	0.6070	0.9911	0.9493	0.8926
37.	0.6121	0.9932	0.9598	0.8952
38.	0.6468	0.9908	0.9610	0.8683
39.	0.7266	0.9858	0.9635	0.8275
40.	0.7517	0.9813	0.9638	0.7668
ORTALAMA	0.6320	0.9864	0.9551	0.8217

Çizelge 4.7. Ön işlemede Wiener filtrelemesiz ve son işlemede 5x5 Medyan filtreleme uygulamasının sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
21.	0.5681	0.9957	0.9636	0.9128
22.	0.4321	0.9988	0.9475	0.9720
23.	0.6704	0.9417	0.9237	0.4473
24.	0.4005	0.9995	0.9301	0.9904
25.	0.5774	0.9754	0.9371	0.7129
26.	0.5844	0.9871	0.9534	0.8049
27.	0.4888	0.9967	0.9515	0.9257
28.	0.4954	0.9968	0.9477	0.9420
29.	0.6662	0.9708	0.9451	0.6768
30.	0.5764	0.9918	0.9591	0.8563
31.	0.6060	0.9867	0.9637	0.7448
32.	0.6089	0.9930	0.9613	0.8819
33.	0.5841	0.9948	0.9615	0.9076
34.	0.5201	0.9729	0.9285	0.6749
35.	0.5946	0.9939	0.9592	0.9017
36.	0.5457	0.9938	0.9450	0.9148
37.	0.5388	0.9957	0.9557	0.9227
38.	0.5786	0.9937	0.9578	0.8959
39.	0.6657	0.9896	0.9617	0.8568
40.	0.6941	0.9874	0.9651	0.8178
ORTALAMA	0.5698	0.9878	0.9509	0.8380

Çizelge 4.8. Ön işlemede Wiener filtreleme ve son işlemede 3x3 Medyan filtreleme uygulamasının sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
21.	0.6698	0.9872	0.9635	0.8088
22.	0.5069	0.9950	0.9509	0.9102
23.	0.6705	0.9481	0.9298	0.4764
24.	0.5142	0.9957	0.9399	0.9398
25.	0.6143	0.9745	0.9400	0.7191
26.	0.6645	0.9660	0.9408	0.6404
27.	0.5547	0.9915	0.9530	0.8632
28.	0.5576	0.9910	0.9487	0.8704
29.	0.6506	0.9782	0.9507	0.7330
30.	0.6336	0.9835	0.9560	0.7653
31.	0.6516	0.9776	0.9579	0.6512
32.	0.6396	0.9857	0.9574	0.7991
33.	0.6510	0.9872	0.9600	0.8174
34.	0.5990	0.9623	0.9268	0.6330
35.	0.6538	0.9899	0.9608	0.8606
36.	0.6012	0.9884	0.9463	0.8630
37.	0.6013	0.9920	0.9579	0.8785
38.	0.7001	0.9852	0.9606	0.8171
39.	0.7250	0.9846	0.9623	0.8159
40.	0.7383	0.9839	0.9653	0.7901
ORTALAMA	0.6299	0.9824	0.9514	0.7826


Çizelge 4.9. Ön işlemede Wiener filtreleme ve son işlemede 5x5 Medyan filtreleme uygulamasının sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
21.	0.6166	0.9913	0.9633	0.8519
22.	0.4490	0.9968	0.9473	0.9333
23.	0.6288	0.9549	0.9335	0.4959
24.	0.4634	0.9971	0.9353	0.9543
25.	0.5885	0.9807	0.9431	0.7644
26.	0.6419	0.9734	0.9457	0.6874
27.	0.4950	0.9943	0.9503	0.8938
28.	0.5093	0.9939	0.9466	0.9009
29.	0.6252	0.9828	0.9527	0.7697
30.	0.6035	0.9870	0.9570	0.7986
31.	0.6198	0.9805	0.9587	0.6706
32.	0.6111	0.9887	0.9579	0.8285
33.	0.6121	0.9900	0.9594	0.8428
34.	0.5481	0.9697	0.9284	0.6621
35.	0.6042	0.9925	0.9589	0.8848
36.	0.5576	0.9908	0.9437	0.8812
37.	0.5489	0.9939	0.9550	0.8962
38.	0.6466	0.9886	0.9591	0.8429
39.	0.6753	0.9877	0.9609	0.8380
40.	0.6962	0.9873	0.9653	0.8181
ORTALAMA	0.5871	0.9861	0.9511	0.8108

Çizelge 4.10. Coye filtreleme ve bağlantılı bileşen analizi yöntemi başarı özeti

Yöntem Adı	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
Wiener Filtresiz – Medyan 3x3	0.6320	0.9864	0.9551	0.8217
Wiener Filtresiz – Medyan 5x5	0.5698	0.9878	0.9509	0.8380
Wiener Filtreli – Medyan 3x3	0.6299	0.9824	0.9514	0.7826
Wiener Filtreli – Medyan 5x5	0.5871	0.9861	0.9511	0.8108

Çizelge 4.10’da verilen özet sonuçlardan anlaşıldığı üzere, yeşil kanal tercih edilerek görüntülerdeki gürültü ve aydınlatma kusurları rahatlıkla giderilmiştir. Vasküler yapıların sürekliliğini sağlamak amacıyla son işlem olarak uygulanan 3x3 maske boyutuna sahip Medyan filtreleme işlemiyle elde edilen ortalama duyarlılık % 63.20 ve ortalama doğruluk % 95.51 diğerlerine göre daha başarılı bulunmuştur. Literatür ile karşılaştırıldığında elde edilen ortalama özgüllük % 98.64 ve ortalama kesinlik % 82.17 değerleri de kabul edilebilir başarı göstermiştir. Son olarak, retina görüntülerine Coye filtreleme ve bağlantılı bileşen analizi yöntemi uygulanarak gerçekleştirilen retina damar bölütlenmesi işlemi görüntü başına ortalama 1,2914 sn sürmüştür.



Şekil 4.5. (a) Renkli retina (b) referans (c) Coye – BBA yöntemiyle elde edilen retina damar haritası görüntüsü

Coye filtreleme ve bağlantılı bileşen analizi yöntemi kullanılarak 21. renkli retina görüntüsünden elde edilen retina damar haritası, Şekil 4.5'te gerçek damar örgüsüyle karşılaştırılmalı olarak verilmiştir. Elde edilen görüntü (Şekil 4.5.(c)) dikkatlice incelendiğinde, matematiksel morfoloji yaklaşımına kıyasla retinadaki ince vasküler yapılar daha başarılı bir şekilde tespit edilmiştir.

4.1.4. Denetimsiz Sonuç Bütünleştirme

Renkli retina görüntülerinden retina damar örgüsünü çıkarmak amacıyla matematiksel morfoloji ve Coyer filtreleme ve bağlantılı bileşen analizi yöntemlerinin başarıları ayrı ayrı değerlendirilmiştir. Her iki yaklaşımın da avantajlı olduğu durumlar mevcuttur. Matematiksel morfoloji yönteminde kalın vasküler yapılar sürekli iken, Coyer filtreleme ve bağlantılı bileşen analizi yönteminde ince vasküler yapılar kolaylıkla tespit edilebilmiştir. Anlamlı bulgular doğrultusunda, hem vasküler yapıların sürekliliğini sağlamak hem de ince vasküler yapıları tespit etmek amacıyla her iki yöntemde en başarılı sonuçları veren işlemlerin bulguları birleştirilmiştir. Sonuçların birleştirilmesinden sonra elde edilen ikili görüntüye son işlem olarak, olası küçük gürültüleri kaldırmak amacıyla, 3x3 ve 5x5 maske boyutuna sahip Medyan filtreleme işlemi uygulanmış ve bulgular değerlendirme ölçütlerine göre karşılaştırılmıştır.

Çizelge 4.11 ve Çizelge 4.12’de görüldüğü üzere hem her görüntü için ayrı ayrı hem de ortalama duyarlılık, özgüllük, doğruluk ve kesinlik değerlerine ulaşılmıştır.

Çizelge 4.11. Denetimsiz retina damar bölütlenmesi yöntemiyle bütünleştirilmiş ve 3x3 Medyan filtreleme uygulanmış yöntemin sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
21.	0.7714	0.9814	0.9657	0.7705
22.	0.6199	0.9917	0.9581	0.8815
23.	0.7684	0.9138	0.9042	0.3857
24.	0.6611	0.9914	0.9531	0.9093
25.	0.5890	0.9867	0.9485	0.8243
26.	0.7499	0.9634	0.9455	0.6512
27.	0.6718	0.9882	0.9603	0.8464
28.	0.6869	0.9855	0.9564	0.8370
29.	0.7450	0.9692	0.9503	0.6894
30.	0.6934	0.9805	0.9580	0.7520
31.	0.7216	0.9797	0.9641	0.6948
32.	0.7249	0.9821	0.9610	0.7826
33.	0.7346	0.9834	0.9633	0.7960
34.	0.6630	0.9553	0.9267	0.6165
35.	0.7586	0.9770	0.9580	0.7578
36.	0.6553	0.9890	0.9527	0.8787
37.	0.7346	0.9808	0.9592	0.7853
38.	0.8163	0.0309	0.9559	0.7139
39	0.8065	0.9691	0.9577	0.7299
40.	0.7966	0.9779	0.9642	0.7471
ORTALAMA	0.7012	0.9808	0.9560	0.7525


Çizelge 4.12. Denetimsiz retina damar bölütlenmesi yöntemiyle bütünleştirilmiş ve 5x5 Medyan filtreleme uygulanmış yöntemin sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
21.	0.7558	0.9789	0.9623	0.7435
22.	0.5809	0.9918	0.9547	0.8757
23.	0.7283	0.9270	0.9139	0.4129
24.	0.6296	0.9897	0.9479	0.8886
25.	0.6264	0.9742	0.9408	0.7205
26.	0.7251	0.9593	0.9397	0.6184
27.	0.6309	0.9879	0.9565	0.8349
28.	0.6385	0.9862	0.9522	0.8334
29.	0.7317	0.9694	0.9494	0.6874
30.	0.7003	0.9778	0.9560	0.7285
31.	0.6958	0.9746	0.9578	0.6375
32.	0.6901	0.9822	0.9583	0.7756
33.	0.7222	0.9811	0.9602	0.7710
34.	0.6737	0.9520	0.9247	0.6033
35.	0.7420	0.9837	0.9628	0.8124
36.	0.6458	0.9868	0.9498	0.8569
37.	0.7016	0.9840	0.9593	0.8079
38.	0.7988	0.9751	0.9598	0.7516
39.	0.8116	0.9718	0.9580	0.7301
40.	0.8043	0.9790	0.9658	0.7588
ORTALAMA	0.6917	0.9756	0.9515	0.7424

Çizelge 4.13. Sonuç bütünleştirme başarı özet

Yöntem Adı	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
Bütünleştirme – Medyan 3x3	0.7012	0.9808	0.9560	0.7525
Bütünleştirme – Medyan 5x5	0.6917	0.9756	0.9515	0.7424

Çizelge 4.13'te özet tablodan anlaşıldığı üzere bütünleştirilmiş sonuçlara son işlem olarak uygulanan 3x3 maske boyutuna sahip Medyan filtreleme işlemi ortalama duyarlılıkta % 70.12, ortalama özgüllükte % 98.08, ortalama doğrulukta % 95.60 ve ortalama kesinlikte % 75.25 ile değerlendirme ölçütleri açısından daha başarılı bulunmuştur. Son olarak, sonuç bütünleştirme işlemi görüntü başına ortalama 2,0908 sn sürmüştür.



Şekil 4.6. (a) Renkli retina (b) referans (c) denetimsiz sonuç bütünleştirme yöntemiyle elde edilen retina damar haritası görüntüsü

Sonuç bütünleştirme kullanılarak 21. renkli retina görüntüsünden elde edilen retina damar haritası, Şekil 4.6'da gerçek damar örgüsüyle karşılaştırılmalı olarak verilmiştir. Hem elde edilen görüntü hem de değerlendirme sonuçları göz önüne alındığında, iki denetimsiz yöntemin sonuçlarının belirli bir kurala göre kaynaştırılması, retina damar bölütleme başarısını arttırmıştır.

Çizelge 4.14. Denetimsiz yöntem sonuçlarının literatür ile karşılaştırması

Çalışma	Duyarlılık	Özgüllük	Doğruluk
Gözlemci	0.7763	0.9723	0.9470
Zhang vd. (2010)	0.7120	0.9724	0.9382
You vd. (2011)	0.7410	0.9751	0.9434
Fraz vd. (2012)	0.7152	0.9759	0.9430
Zhao vd. (2014)	0.7354	0.9789	0.9477
Azzopardi vd. (2015)	0.7655	0.9704	0.9442
Hassanien vd. (2015)	0.7210	0.9710	0.9388
Oliveira vd. (2016)	0.8644	0.9556	0.9464
Zhang vd. (2016)	0.7743	0.9725	0.9476
Wang vd. (2020)	0.7236	0.9810	0.9449
Alhussein vd. (2020)	0.7851	0.9724	0.9559
Saroj, Kumar ve Singh (2020)	0.7307	0.9761	0.9544
Matematiksel Morfoloji	0.6291	0.9876	0.9559
Coye ve BBA	0.6320	0.9864	0.9551
Denetimsiz Sonuç Bütünleştirme	0.7012	0.9808	0.9560

Çizelge 4.14'te denetimsiz yöntemler uygulanarak elde edilen sonuçlar denetimsiz çalışmalara ait literatür ile kıyaslanmıştır. Matematiksel morfoloji ortalama özgüllükte % 98.76 sonucuyla ve Coye filtreleme ve bağlantılı bileşen analizi yaklaşımı ortalama özgüllükte % 98.64 değeriyle en başarılı yöntem olmuştur. Denetimsiz sonuç bütünleştirme yaklaşımı ise ortalama doğrulukta % 95.60 değeriyle en başarılı yöntem olmuştur. Sonuç bütünleştirme duyarlılık sonuçlarına gözle görülür katkı sağlamıştır.

4.2. Derin Öğrenme Tabanlı Yaklaşımın Değerlendirilmesi

Bu bölümde, renkli retina görüntülerine derin öğrenme U-Net tabanlı yaklaşım uygulanarak retina damar bölütleme başarısı değerlendirilmiştir. DRIVE veri kümesinin 21 ile 40 arasında numaralandırılmış renkli retina görüntüleri U-Net mimarisini eğitmek amacıyla kullanılmıştır. Geriye kalan 1 ile 20 arasında numaralandırılmış renkli retina görüntüleri ise U-Net mimarisinin test başarısını değerlendirmek için kullanılmıştır. Ayrıca, eğitim kümesi (21 – 40) üzerine uygulanan ön hazırlık ve veri kümesi genişletme işlemlerinin derin öğrenme modeli tahmin başarısına etkisi incelenmiştir. Son olarak, U-Net mimarisinin tek kanal ve paralel kanal ile eğitilmesinin sonuçlara etkisi araştırılmıştır.

4.2.1. U-Net Modelinin Tek Kanallı Eğitimi Sonucu

Derin öğrenme mimarisi tabanlı U-Net modeli kurulduktan sonra; model eğitimi DRIVE veri kümesinin eğitim bölümüyle (21 – 40) yapılmıştır. Model, eğitim kümesi görüntülerine karşılık gelen referans görüntüleriyle birlikte tek kanal üzerinden eğitilmiştir. U-Net modelinin eğitimi 20 görüntü için ortalama 12 sn'de tamamlanmıştır. U-Net modeli eğitildikten sonra modele DRIVE veri kümesinin test bölümü (1 – 20) verilmiştir.

Çizelge 4.15'te temel U-Net modelinin test kümesindeki her bir görüntü için ayrı ayrı ve ortalama duyarlılık, özgüllük, doğruluk ve kesinlik değerlerine ulaşılmıştır.

Çizelge 4.15. U-Net Modelinin Ön Hazırlıksız ve Tek Kanallı Eğitim Sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.7300	0.9805	0.9581	0.7854
2.	0.7419	0.9868	0.9617	0.8649
3.	0.5813	0.9906	0.9498	0.8732
4.	0.7124	0.9879	0.9625	0.8562
5.	0.6321	0.9917	0.9580	0.8877
6.	0.6382	0.9899	0.9556	0.8718
7.	0.6975	0.9830	0.9569	0.8053
8	0.6329	0.9863	0.9559	0.8132
9.	0.5837	0.9934	0.9602	0.8864
10.	0.7324	0.9840	0.9633	0.8040
11.	0.6906	0.9838	0.9575	0.8073
12.	0.6564	0.9887	0.9600	0.8464
13.	0.6905	0.9875	0.9585	0.8571
14.	0.7364	0.9830	0.9631	0.7923
15.	0.7098	0.9819	0.9624	0.7510
16.	0.6676	0.9849	0.9563	0.8147
17.	0.5928	0.9913	0.9577	0.8625
18.	0.7256	0.9837	0.9632	0.7926
19.	0.8204	0.9753	0.9625	0.7504
20.	0.7583	0.9791	0.9628	0.7418
ORTALAMA	0.6865	0.9857	0.9593	0.8232


Sonuç Çizelgesi 4.15'ten anlaşılacağı üzere; düşük sayıda eğitim kümesi ile gerçekleştirilen eğitim, denetimsiz retina damar bölütlemesi yaklaşımları ile benzer başarı oranıyla tamamlanmıştır.



Çizelge 4.16. U-Net Modelinin Ön Hazırlıksız ve Tek Kanallı Eğitim ve test kümesine KSAHE uygulanmış sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.8828	0.9081	0.9058	0.4848
2.	0.8637	0.9325	0.9254	0.5934
3.	0.8145	0.8970	0.8888	0.4669
4.	0.7849	0.9328	0.9192	0.5420
5.	0.8032	0.9404	0.9275	0.5820
6.	0.7986	0.9337	0.9205	0.5649
7.	0.8230	0.9121	0.9039	0.4849
8	0.8006	0.9238	0.9132	0.4973
9.	0.8009	0.9299	0.9194	0.5018
10.	0.8112	0.9301	0.9203	0.5099
11.	0.8269	0.9144	0.9056	0.4870
12.	0.8529	0.9068	0.9021	0.4636
13.	0.8005	0.9281	0.9157	0.5469
14.	0.8871	0.8923	0.8919	0.4202
15.	0.8655	0.9001	0.8976	0.4004
16.	0.8587	0.9269	0.9208	0.5384
17.	0.8475	0.9156	0.9098	0.4806
18.	0.8903	0.9193	0.9170	0.4869
19.	0.9033	0.9141	0.9132	0.4874
20.	0.8926	0.9258	0.9234	0.4886
ORTALAMA	0.8404	0.9192	0.9121	0.5014

Çizelge 4.16’da temel U-Net modeli eğitimi 20 fundus görüntüsü ile gerçekleştirilmiştir. U-Net modelinin eğitimi tamamlandıktan sonra test kümesindeki görüntülere sadece KSAHE işlemi uygulanarak retina damar örgüsü tahmin sonuçları elde edilmiştir. Çizelge 4.16’da görüldüğü üzere, ortalama duyarlılık % 84.04 değerine ulaşmasına rağmen, ortalama kesinlik % 50.14 ve ortalama özgüllük % 91.92 değerleri ile bu yaklaşımın etkili olmadığı görülmüştür.



Şekil 4.7. (a) Renkli retina (b) referans (c) temel U-Net ile elde edilen retina damar haritası görüntüsü

Şekil 4.7’de temel U-Net modelinin ön işlemlerle test kümesindeki 15. renkli retina görüntüsü için retina damar örgüsü tahmini, gerçek referans damar örgüsüyle karşılaştırılmalı olarak verilmiştir. Görsel bulgular (Şekil 4.7.(c)) dikkatlice incelendiğinde, düşük sayıda veriyle eğitilmiş U-Net modeli özellikle ince vasküler yapıları tahmin etmede yetersiz kalmıştır.

Ronneberger ve arkadaşlarına (2016) göre derin öğrenme tabanlı sistemlerin tahmin başarısını yükseltmenin tek yolu eğitim kümesinin eleman sayısını arttırmaktır. Bir başka deyişle, U-Net modeli tahminde bulunacağı nesneyi ne kadar çok çeşitli görürse test aşamasında daha başarılı çıkarımda bulunacaktır. Derin öğrenme mimarisinin başarısını arttırmak amacıyla renkli retina görüntülerinin eğitim kümesine denetimsiz ön hazırlık işlemleri uygulanmıştır. Uygulanan işlem sonucunda eğitim kümesi toplamda 80 adet (20’si orijinal, 20’si KSAHE, 20’si matematiksel morfoloji ve 20’si Coyer Filtreleme)

görüntüye ulaşmıştır. U-Net mimarisinin eğitimi 80 retina görüntüsü ve bu görüntülere karşılık gelen referans görüntüleriyle tamamlanmıştır. Eğitilmiş U-Net modeline DRIVE veri kümesinin test grubu (1 – 20) verilmiştir.

Çizelge 4.17’de görüldüğü üzere test kümesinin her görüntüsü için ayrı ayrı ve ortalama duyarlılık, özgüllük, doğruluk ve kesinlik sonuçlarına ulaşılmıştır.



Çizelge 4.17. U-Net Modelinin Ön Hazırlıklı ve Tek Kanallı Eğitim Sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.7298	0.9779	0.9557	0.7637
2.	0.7419	0.9815	0.9569	0.8205
3.	0.6113	0.9872	0.9498	0.8413
4.	0.6937	0.9856	0.9588	0.8300
5.	0.6520	0.9883	0.9568	0.8523
6.	0.6702	0.9851	0.9544	0.8289
7.	0.6927	0.9842	0.9576	0.8154
8.	0.6745	0.9828	0.9563	0.7872
9.	0.6405	0.9869	0.9588	0.8119
10.	0.7318	0.9820	0.9614	0.7849
11.	0.6922	0.9794	0.9537	0.7679
12.	0.6981	0.9828	0.9582	0.7931
13.	0.6874	0.9845	0.9554	0.8273
14.	0.7706	0.9764	0.9598	0.7420
15.	0.7554	0.9797	0.9636	0.7412
16.	0.7273	0.9800	0.9572	0.7832
17.	0.6891	0.9829	0.9581	0.7875
18.	0.7728	0.9761	0.9600	0.8356
19.	0.8096	0.9781	0.9641	0.8696
20.	0.7638	0.9773	0.9616	0.8278
ORTALAMA	0.7102	0.9819	0.9579	0.7906

Çizelge 4.17'deki sonuçlardan anlaşılabacağı üzere; eğitim kümesinin eleman sayısının artırılması U-Net modelinin tahmin başarısını anlamlı olarak yükseltmesine rağmen, modelin eğitim süresi 80 görüntü için ortalama 26 sn sürmektedir.

Çizelge 4.18'de ise eğitim kümesinin eleman sayısı ön hazırlık yöntemleriyle artırılmış U-Net modeline sadece KSAHE işlemi uygulanmış test veri kümesinin retina damar örgüsü tahmin sonuçları verilmiştir.



Çizelge 4.18. U-Net modelinin ön hazırlıklı ve tek kanallı eğitim ve test kümesine KSAHE uygulanmış sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.7152	0.9767	0.9534	0.7506
2.	0.7149	0.9831	0.9556	0.8285
3.	0.6044	0.9858	0.9478	0.8252
4.	0.6684	0.9862	0.9569	0.8305
5.	0.6439	0.9885	0.9562	0.8522
6.	0.6428	0.9855	0.9521	0.8270
7.	0.6762	0.9846	0.9564	0.8154
8.	0.6427	0.9843	0.9549	0.7937
9.	0.6317	0.9865	0.9577	0.8045
10.	0.6942	0.9831	0.9593	0.7867
11.	0.6672	0.9805	0.9524	0.7705
12.	0.6634	0.9825	0.9549	0.7815
13.	0.6815	0.9819	0.9525	0.8030
14.	0.7318	0.9793	0.9593	0.7568
15.	0.7441	0.9792	0.9624	0.7341
16.	0.7130	0.9816	0.9573	0.7934
17.	0.6705	0.9833	0.9569	0.7875
18.	0.7589	0.9796	0.9621	0.7615
19.	0.7863	0.9782	0.9623	0.7655
20.	0.7749	0.9779	0.9642	0.7305
ORTALAMA	0.6913	0.9824	0.9567	0.7899

Çizelge 4.18 bulguları göz önüne alındığında, test kümesine uygulanan KSAHE işleminin U-Net modelinin retina damar örgüsü tahminine pozitif katkı yapmadığı sonucuna varılmıştır.


Derin öğrenme tabanlı U-Net mimarisinin retina damar örgüsü tahminini arttırmak amacıyla eğitim kümesinin (21 – 40) orijinal görüntülerine denetimsiz ön işlemeye ek olarak sadece yatay ekseninde yansıma, sadece dikey ekseninde yansıma, yatay – dikey ekseninde yansıma, 30^0 ve 60^0 derece döndürme işlemleri uygulanarak eğitim veri kümesi 5 katına çıkarılmıştır. Eğitim kümesinin eleman sayısı denetimsiz ön işleme ve genişletme işlemi sonucunda 180 adet olmuştur.

Çizelge 4.19’da görüldüğü üzere test kümesinin her görüntüsü için ayrı ayrı ve ortalama duyarlılık, özgüllük, doğruluk ve kesinlik sonuçlarına ulaşılmıştır.

Çizelge 4.19. U-Net Modelinin Ön Hazırlıklı Genişletilmiş ve Tek Kanallı Eğitim Sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.7823	0.0262	0.9567	0.7541
2.	0.7564	0.0196	0.9575	0.8153
3.	0.6549	0.0174	0.9500	0.8069
4.	0.7183	0.0164	0.9592	0.8160
5.	0.6899	0.0145	0.9578	0.8312
6.	0.6907	0.0162	0.9553	0.8216
7.	0.7290	0.0185	0.9585	0.7989
8.	0.6867	0.0190	0.9557	0.7728
9.	0.7038	0.0169	0.9604	0.7855
10.	0.7466	0.0217	0.9593	0.7555
11.	0.7519	0.0239	0.9561	0.7560
12.	0.7494	0.0219	0.9583	0.7638
13.	0.7347	0.0192	0.9567	0.8054
14.	0.7824	0.0248	0.9596	0.7348
15.	0.7925	0.0231	0.9637	0.7256
16.	0.7121	0.0203	0.9592	0.7866
17.	0.7241	0.0199	0.9585	0.7707
18.	0.7977	0.0257	0.9603	0.7275
19.	0.8405	0.0261	0.9628	0.7445
20.	0.8094	0.0272	0.9608	0.7026
ORTALAMA	0.7427	0.9791	0.9583	0.7738

U-net modelin eğitim süresi 180 görüntü için ortalama 42 sn sürmektedir. Çizelge 4.19'a göre eğitim kümesinin eleman sayısının arttırılması U-Net modelinin tahmin başarısını anlamlı olarak yükseltse de, modelin eğitim süresi uzamaktadır.



Şekil 4.8. (a) Renkli retina (b) referans (c) ön işlenmiş eğitim kümesiyle eğitilmiş U-Net yöntemiyle elde edilen retina damar haritası görüntüsü

Şekil 4.8’de U-Net modelinin ön hazırlıklı genişletilmiş ve tek kanallı eğitimi sonucunda, test kümesindeki 15. renkli retina görüntüsü için retina damar örgüsü tahmini, gerçek referans damar örgüsüyle karşılaştırılmalı olarak verilmiştir. Görsel bulgular dikkatlice incelendiğinde; eğitim veri kümesinin eleman sayısındaki artış, modelin tahmin başarısını yükseltmiş olmasına rağmen işlem süresini de 2 katına çıkarmıştır.

4.2.2. U-Net Modelin Paralel Kanallı Eğitimi Sonucu


Derin öğrenme tabanlı yaklaşımın eğitim süresini kısaltmak amacıyla U-Net modelin eğitimi paralel kanal olarak tasarlanmıştır. Bu yaklaşımı gerçekleştirmek üzere DRIVE veri kümesinin eğitim kısmı (21 – 40) denetimsiz olarak ön işlemden geçirilmiştir. Eğitim kümesinde her görüntüye sırasıyla KSAHE, matematiksel morfoloji ve Coyer filtreleme ve bağlantılı bileşen analizi işlemleri uygulanmıştır. Derin öğrenme tabanlı yaklaşımın eğitimi için; eğitim veri kümesinin (21 – 40) orijinal görüntülerine ek olarak, denetimsiz ön işlenmiş görüntüler ve bunlara karşılık gelen referans damar örgüsü paralel kanal aracılığıyla U-Net modeline verilmiştir.

Çizelge 4.20’de görüldüğü üzere test kümesinin her görüntüsü için ayrı ayrı ve ortalama duyarlılık % 76.35, özgüllük % 98.50, doğruluk % 96.18 ve kesinlik % 82.32 sonuçlarına ulaşılmıştır.

Çizelge 4.20. U-Net Modelin Paralel Kanallı Eğitim Sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.8223	0.9781	0.9611	0.7790
2.	0.8059	0.9842	0.9635	0.8496
3.	0.7088	0.9888	0.9546	0.8649
4.	0.7408	0.9882	0.9624	0.8588
5.	0.7058	0.9918	0.9611	0.8931
6.	0.7001	0.9898	0.9575	0.8740
7.	0.7435	0.9840	0.9584	0.8156
8.	0.7017	0.9892	0.9597	0.8494
9.	0.6827	0.9921	0.9620	0.8733
10.	0.7598	0.9864	0.9645	0.8263
11.	0.7530	0.9831	0.9596	0.8075
12.	0.7451	0.9865	0.9610	0.8287
13.	0.7537	0.9864	0.9598	0.8505
14.	0.8174	0.9806	0.9645	0.7800
15.	0.8120	0.9794	0.9645	0.7428
16.	0.7681	0.9832	0.9605	0.8118
17.	0.7254	0.9878	0.9613	0.8361
18.	0.8236	0.9799	0.9648	0.7714
19.	0.8623	0.9797	0.9676	0.7882
20.	0.8383	0.9804	0.9669	0.7630
ORTALAMA	0.7635	0.9850	0.9618	0.8232

Elde edilen sonuçlar göz önüne alındığında paralel kanallı eğitim yaklaşımında U-Net modeli toplamda 20 görüntüyle eğitilmiş olsa da modelin tahmin başarısı temel U-Net modeline kıyasla yükselmiştir. Ayrıca, modelin eğitim süresi 20 görüntü için ortalama 89 sn’de tamamlanmıştır.



Şekil 4.9. (a) Renkli retina (b) referans (c) paralel kanal U-Net yöntemiyle elde edilen retina damar haritası görüntüsü


U-Net modelinin test kümesindeki 15. renkli retina görüntüsünün retina damar örgüsü tahmini, gerçek referans damar örgüsüyle karşılaştırılmalı olarak Şekil 4.9’da verilmiştir. Görsel bulgular dikkatlice incelendiğinde; U-Net model eğitiminin paralel kanal ile denetimsiz ön işleme uygulanmış retina görüntüleri ile yapılması modelin tahmin başarısını yükseltirken, damar kayıplarını azaltmıştır.

Çalışmanın 4.2.1. bölümünde, eğitim kümesindeki eleman sayısını arttırmanın, U-Net modelinin tahmin başarısına olumlu katkı sağladığı ifade edilmiştir. Bu anlamlı bulgudan yola çıkarak, eğitim kümesinin (21 – 40) orijinal görüntülerine denetimsiz ön işlemeye ek olarak sadece yatay ekseninde yansıma, sadece dikey ekseninde yansıma, yatay – dikey ekseninde yansımaya ek olarak 30^0 ve 60^0 derece döndürme işlemleri uygulanarak eğitim veri kümesi 5 katına çıkarılmıştır. Veri kümesi genişletme işlemi sonucunda eğitim kümesinin eleman sayısı 100 adet olmuştur. Derin öğrenme tabanlı U-Net modelinin eğitimi paralel kanal üzerinden ve toplamda 100 farklı retina görüntüsüyle gerçekleştirilmiştir.

Çizelge 4.21. U-Net Modelinin Veri Kümesi Genişletme Uygulanmış Paralel Kanallı Eğitim Sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.8300	0.9788	0.9655	0.7931
2.	0.8028	0.9847	0.9661	0.8569
3.	0.7174	0.9904	0.9578	0.8823
4.	0.7420	0.9892	0.9664	0.8742
5.	0.7004	0.9912	0.9640	0.8920
6.	0.6844	0.9910	0.9611	0.8909
7.	0.7567	0.9853	0.9644	0.8377
8	0.7317	0.9858	0.9639	0.8288
9.	0.7663	0.9845	0.9668	0.8132
10.	0.7882	0.9825	0.9665	0.8014
11.	0.7704	0.9804	0.9616	0.7947
12.	0.8058	0.9809	0.9658	0.7995
13.	0.7639	0.9832	0.9618	0.8316
14.	0.8328	0.9786	0.9668	0.7742
15.	0.8425	0.9786	0.9689	0.7524
16.	0.8130	0.9807	0.9656	0.8073
17.	0.8056	0.9843	0.9658	0.8180
18.	0.8566	0.9757	0.9663	0.7520
19.	0.8890	0.9773	0.9700	0.7799
20.	0.8670	0.9763	0.9682	0.7436
ORTALAMA	0.7883	0.9830	0.9652	0.8162

Çizelge 4.21’de görüldüğü üzere test kümesindeki her görüntü için ayrı ayrı ve ortalama duyarlılık % 78.83, özgüllük % 98.30, doğruluk % 96.52 ve kesinlik % 81.62 açısından en başarılı sonuçlara ulaşılmıştır. Modelin eğitim süresi 100 görüntü için ortalama 105 sn’de tamamlanmıştır.



Şekil 4.10. (a) Renkli retina (b) referans (c) eğitim veri kümesi genişletilmiş paralel kanal U-Net yöntemiyle elde edilen retina damar haritası görüntüsü

U-Net modelinin test kümesindeki 15. renkli retina görüntüsünün retina damar örgüsü tahmini, gerçek referans damar örgüsüyle karşılaştırılmalı olarak Şekil 4.10’da verilmiştir. Görsel bulgular dikkatlice incelendiğinde; U-Net modelin veri kümesi genişletme uygulanmış ve paralel kanallı eğitimi, değerlendirme ölçütlerine göre en yüksek performansa ulaşmıştır.

Çizelge 4.22. Derin öğrenme tabanlı hibrit yöntem sonuçlarının literatür ile karşılaştırılması

Çalışma	Duyarlılık	Özgüllük	Doğruluk
Dos Santos vd. (2020)	0.7564	0.9696	0.9505
Aurangzeb vd. (2021)	0.8315	0.9750	0.9620
Genişletilmiş paralel kanal	0.7883	0.9830	0.9652

Çizelge 4.22’de derin öğrenme tabanlı hibrit yöntemler (denetimsiz ön işleme destekli) uygulanarak elde edilen sonuçlar literatür ile kıyaslanmıştır. Veri kümesi genişletilmiş paralel kanallı U-Net modeli ortalama özgüllükte % 98.30 sonucuyla ve ortalama doğrulukta % 96.52 değeriyle en başarılı yöntem olmuştur.

4.3. Hibrit Yöntemin Değerlendirilmesi

Bu bölümde, uzamsal görüntü filtreleme ile sinir ağı tabanlı retina damar bölütlenmesi yaklaşımı değerlendirilmiştir. Önerilen yaklaşım 3 basamakta yapılmaktadır. İlk olarak, sayısal retina görüntülerine denetimsiz ön işlemler uygulanmıştır. Söz konusu denetimsiz ön hazırlık yaklaşımları bölüm 4.1’de en başarılı bulguları sağlayan parametre ve işlem sırasıyla yapılmıştır. DRIVE veri kümesinin test için ayrılan ilk 20 görüntüsüne sırasıyla matematiksel morfoloji ve Coyer filtreleme ve bağlantılı bileşen analizi yaklaşımları uygulanmıştır. Elde edilen sonuçlar birleştirilmiştir. İkinci olarak; U-net mimarisinin eğitimi, DRIVE veri kümesinin eğitim kümesine (21 – 40) ön işleme ve veri kümesi genişletme uygulanarak paralel kanal üzerinden tamamlanmıştır. Son olarak, denetimsiz retina damar bölütlemesi yapılan test kümesinin sonuçları ile U-Net modelinin sonuçları birleştirilmiştir.

Çizelge 4.23. Önerilen hibrit yöntem değerlendirme sonuçları


Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.8927	0.9824	0.9561	0.6990
2.	0.8540	0.9850	0.9626	0.7956
3.	0.7833	0.9712	0.9525	0.7510
4.	0.7878	0.9836	0.9656	0.8299
5.	0.7738	0.9835	0.9639	0.8292
6.	0.7507	0.9837	0.9610	0.8320
7.	0.7751	0.9793	0.9606	0.7898
8.	0.7886	0.9819	0.9570	0.7608
9.	0.8009	0.9850	0.9609	0.7387
10.	0.8183	0.9727	0.9600	0.7291
11.	0.7859	0.9744	0.9575	0.7511
12.	0.8391	0.9802	0.9588	0.7265
13.	0.7811	0.9765	0.9574	0.7830
14.	0.8606	0.9875	0.9589	0.6997
15.	0.8682	0.9874	0.9613	0.7724
16.	0.8379	0.9862	0.9637	0.8777
17.	0.7990	0.9886	0.9635	0.7750
18.	0.8925	0.9866	0.9602	0.8932
19.	0.9001	0.9897	0.9640	0.8291
20.	0.9089	0.9848	0.9607	0.8720
ORTALAMA	0.8249	0.9740	0.9603	0.8167

Çizelge 4.23’de önerilen hibrit yaklaşımın test kümesindeki her görüntü için ayrı ayrı ve ortalama % 82.49 duyarlılık, % 97.40 özgüllük, % 96.03 doğruluk ve % 81.67 kesinlik sonuçlarına ulaşılmıştır. Ayrıca, önerilen hibrit yöntem denetimsiz ön işlemler de dahil olmak üzere 20 görüntü için ortalama 107,1908 sn’de tamamlanmıştır.

Çizelge 4.24. Farklı yöntemler ile eğitilmiş U-Net mimarisi başarı özeti

U-Net Yöntemi	Duyarlılık	Özgüllük	Doğruluk
20 / 20 Orijinal	0.6865	0.9857	0.9593
20 / 20 KSAHE	0.8404	0.9192	0.9121
80 / 20 Orijinal	0.7102	0.9819	0.9579
80 / 20 KSAHE	0.6913	0.9824	0.9567
180 / 20 Orijinal	0.7427	0.9791	0.9583
Paralel kanallı	0.7635	0.9850	0.9618
Paralel kanallı Veri genişletme uygulanmış	0.7883	0.9830	0.9652
Hibrit Yöntem	0.8249	0.9740	0.9603

Çizelge 4.24’te önerilen hibrit yöntemin retina damar haritası tahmin başarı özeti verilmiştir. Elde edilen bulgular ışığında, önerilen hibrit yöntem özellikle ortalama duyarlılığı anlamlı olarak yükseltmiştir. Önerilen hibrit yöntem, temel ve tek kanallı U-Net mimarisiyle karşılaştırıldığında ortalama duyarlılık ve doğruluk değerlerinde anlamlı artış sağlamıştır. Önerilen hibrit yöntem, paralel kanallı ve veri kümesi genişletme uygulanmış U-Net mimarisiyle karşılaştırıldığında, ortalama duyarlılıkta en başarılı yaklaşım olmuştur. Her ne kadar ortalama doğruluk değerinde azalma tespit edilse de % 96.03 değeri kabul edilebilir seviyededir. Ayrıca hibrit yöntemin, derin öğrenme tabanlı sistemler arasında sağladığı başarıya kıyasla en az işlem yükü gerektirdiği belirlenmiştir.



Şekil 4.11. (a) Renkli retina (b) referans (c) matematiksel morfoloji yöntemi (d) Coye filtre ve BBA yöntemi (e) denetimsiz sonuç bütünleştirme (f) temel U-Net modeli tahmini (g) genişletilmiş paralel kanallı U-Net (h) hibrit yöntem sonuç görüntüsü

Şekil 4.11’de DRIVE veri kümesindeki test kümesinin 20. renkli retina görüntüsü, gerçek referans damar haritası ve önerilen hibrit yaklaşım ile her basamak için elde edilen retina damar haritası gösterilmiştir. Coye – BBA yöntemi ince vasküler yapıları tespit etmede matematiksel morfoloji yöntemine kıyasla daha başarılıdır. Bu durum Şekil 4.11.(c) ve Şekil 4.11.(d)’deki görüntülerde retinanın fovea kısmında ve alt ana damarın uç dallanma yapısından görülebilmektedir. Genişletilmiş paralel kanallı U-Net modeli, temel U-Net modeline kıyasla üstün performans göstermiştir. Bu durum Şekil 4.11.(g)’deki ince vasküler yapıların sürekliliği Şekil 4.11.(f)’den daha belirgindir. Hibrit yöntem ile elde edilen damar örgüsü (Şekil 4.11.(h)) neredeyse gerçek referans görüntüsüyle örtüşmektedir.

4.4. Önerilen Hibrit Yöntemin HRF Veri Kümesinde Değerlendirilmesi

4.4.1. HRF Eğitim ve Test Veri Kümelerinin Belirlenmesi

Bölüm 2.4.2’de belirtildiği üzere HRF veri kümesi Budai ve arkadaşları tarafından 2013 yılında toplanmıştır. HRF veri kümesi toplamda 45 farklı görüntü içermektedir. Görüntülerin 15 tanesi sağlıklı, 15 tanesi diyabetik retinopatili ve 15 tanesi de glokom bulgulu olarak sağlayıcılar tarafından etiketlenmesine rağmen, eğitim ve test kümesi olarak bir ayırım yapılmamıştır. HRF veri kümesinin derin öğrenme tabanlı U-Net modelinde kullanılabilmesi için eğitim ve test kümesi olarak ayrılması gerekmektedir. Önerilen hibrit yaklaşımı doğru şekilde değerlendirmek amacıyla HRF veri kümesinin eğitim kümesi 30 farklı retina görüntüsü içerecek şekilde belirlenmiştir. HRF veri kümesinde eğitim kümesi için sağlıklı olarak işaretlenen görüntülerin ilk 10 tanesi, diyabetik retinopatili görüntülerin ilk 10 tanesi ve glokom bulgulu görüntülerin ilk 10 tanesi, bu görüntülere karşılık gelen referans görüntüleri ile birlikte seçilmiştir. HRF veri kümesi test grubu; sağlıklı olarak işaretlenen görüntülerin son 5 tanesi, diyabetik retinopatili görüntülerin son 5 tanesi ve glokom bulgulu görüntülerin son 5 tanesiyle toplamda 15 görüntü olacak şekilde belirlenmiştir.

4.4.2. Denetimsiz Retina Damar Bölütlenmesi Sonuçları


Bölüm 4.1.2’de elde edilen bulgulara göre matematiksel morfoloji yöntemini kullanarak, retina damar bölütlenme işleminin başarıyla yapılabilmesi için HRF test veri kümesindeki 1 ile 15 arasında numaralandırılmış renkli retina görüntülerine RGB kanal ayrıştırma işleminin ardından yeşil kanala gri seviye dönüşümü uygulanmıştır. Gri tonlanmış retina görüntülerinin gürültüsünü gidermek amacıyla 3x3 maske boyutuyla Medyan filtreleme ve 2x2 maske boyutunda ve 0,015 gürültü gücüyle Wiener filtreleme işlemi uygulanmıştır. Gürültüsü giderilmiş gri tonlu retina görüntülerindeki damar – doku zıtlığını arttırmak amacıyla kontrast üst sınır değeri 0,017 olarak belirlenmiş 8x8 karo boyutunda KSAHE uygulanmıştır. KSAHE işlemi ardından gereken matematiksel morfoloji işlemi tamamlanmıştır. Morfolojik işlem sonrasında elde edilen damar görüntülerindeki vasküler yapıların eşik değeri her görüntü için adaptif olarak hesaplanarak ikili görüntüye ulaşılmıştır. Elde edilen görüntüdeki kusurları gidermek ve

damar sürekliliğini sağlamak amacıyla ikili görüntülere son işlem olarak 3x3 maske boyutuna sahip Medyan filtreleme işlemi uygulanmıştır.

Çizelge 4.25. HRF test kümesi matematiksel morfoloji sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.4850	0.9907	0.9248	0.8868
2.	0.5485	0.9867	0.9236	0.8737
3.	0.6056	0.9589	0.9092	0.7066
4.	0.4784	0.9882	0.9189	0.8642
5.	0.5153	0.9878	0.9131	0.8883
6.	0.4997	0.9891	0.9113	0.8967
7.	0.4670	0.9959	0.9155	0.9533
8.	0.4673	0.9809	0.9106	0.7952
9.	0.5724	0.9900	0.9204	0.9201
10.	0.4761	0.9890	0.9222	0.8664
11.	0.5066	0.9916	0.9221	0.9101
12.	0.5150	0.9700	0.9029	0.7486
13.	0.5079	0.9899	0.9200	0.8952
14.	0.5568	0.9896	0.9104	0.8569
15.	0.5384	0.9927	0.9336	0.9169
ORTALAMA	0.5160	0.9855	0.9172	0.8653

Çizelge 4.25’te matematiksel morfoloji yöntemini kullanarak HRF test kümesindeki her görüntü için ayrı ayrı ve ortalama % 51.60 duyarlılık, % 98.55 özgüllük, % 91.72 doğruluk ve % 86.53 kesinlik sonuçlarına ulaşılmıştır. Ayrıca, retina görüntülerine matematiksel morfoloji yöntemi uygulanarak gerçekleştirilen retina damar bölütleme işlemi görüntü başına ortalama 1,3419 sn sürmüştür.



Şekil 4.12. (a) Renkli retina (b) referans (c)matematiksel morfoloji yöntemiyle elde edilen retina damar haritası görüntüsü

Matematiksel morfoloji yöntemi kullanılarak HRF test veri kümesinin 1. renkli retina görüntüsünden elde edilen retina damar haritası, Şekil 4.12’de referans görüntüsüyle karşılaştırılmalı olarak verilmiştir. Elde edilen görüntü dikkatlice incelendiğinde, retinadaki kalın vasküler yapılar rahatlıkla tespit edilebilmesine rağmen ince (kılcal) vasküler yapılarda kayıp olduğu görülmektedir.


Bölüm 4.1.3’te elde edilen bulgulara göre Coye filtreleme ve bağlantılı bileşen analizi yöntemini kullanarak retina damar bölütlemesi yapabilmek için HRF test veri kümesinin 1 ile 15 arasında numaralandırılmış renkli retina görüntülerine RGB kanal ayrıştırılması uygulanmış ve yeşil kanal tercih edilmiştir. Yeşil kanaldaki olası gürültüleri gidermek için 3x3 maske boyutunda Medyan filtre uygulanmıştır. HRF test veri kümesindeki yeşil kanallı görüntülere gri seviye dönüşümü ve 0,017 kontrast üst sınır değeriyle 8x8 karo boyutunda KSAHE uygulanarak işleme devam edilmiştir. Coye filtreleme yöntemi sonrasında elde edilen damar görüntülerindeki vasküler yapıların eşik değeri her görüntü için adaptif olarak hesaplanarak ikili görüntü elde edilmiştir. Herhangi bir damar bilgisi içermeyen hare şeklinde yansımayı ikili görüntüden kaldırmak amacıyla bağlantılı bileşen analizi yöntemi önerilmiştir. Elde edilen görüntüdeki kusurları

gidermek ve damar sürekliliğini sağlamak amacıyla ikili görüntülere son işlem olarak 3x3 maske boyutuna sahip Medyan filtreleme işlemi uygulanmıştır.

Çizelge 4.26. HRF test kümesi Coyle filtreleme ve bağlantılı bileşen analizi sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.4517	0.9980	0.9268	0.9716
2.	0.5053	0.9952	0.9247	0.9468
3.	0.5355	0.9913	0.9272	0.9094
4	0.5248	0.9979	0.9200	0.9694
5.	0.5401	0.9962	0.9082	0.9561
6.	0.5186	0.9972	0.9084	0.9668
7.	0.5008	0.9995	0.9175	0.9928
8.	0.5293	0.9947	0.9201	0.9310
9.	0.5900	0.9997	0.9114	0.9967
10.	0.4777	0.9954	0.9280	0.9401
11.	0.5510	0.9987	0.9202	0.9833
12.	0.5284	0.9877	0.9199	0.8814
13.	0.5477	0.9995	0.9194	0.9923
14.	0.5958	0.9884	0.9308	0.8610
15.	0.5921	0.9995	0.9335	0.9926
ORTALAMA	0.5326	0.9959	0.9211	0.9528

Çizelge 4.26’da Coye filtreleme ve bağlantılı bileşen analizi yöntemini kullanarak HRF test kümesindeki her görüntü için ayrı ayrı ve ortalama % 53.26 duyarlılık, % 99.59 özgülük, % 92.11 doğruluk ve % 95.28 kesinlik sonuçlarına ulaşılmıştır. Ayrıca, retina görüntülerine Coye filtreleme ve bağlantılı bileşen analizi yöntemi uygulanarak gerçekleştirilen retina damar bölütlenmesi işlemi görüntü başına ortalama 1,2816 sn sürmüştür.



Şekil 4.13. (a) Renkli retina (b) referans (c) Coye – BBA yöntemiyle elde edilen retina damar haritası görüntüsü


Coye filtreleme ve bağlantılı bileşen analizi yöntemi kullanılarak 1. renkli retina görüntüsünden elde edilen retina damar haritası, Şekil 4.13’te gerçek damar örgüsüyle karşılaştırılmalı olarak verilmiştir. Elde edilen görüntü dikkatlice incelendiğinde, matematiksel morfoloji yaklaşımına kıyasla retinadaki ince vasküler yapılar daha iyi tespit edilmiştir.

Bölüm 4.1.4’teki anlamlı bulgular doğrultusunda, hem vasküler yapıların sürekliliğini sağlamak hem de ince vasküler yapıları tespit etmek amacıyla her iki yöntemin bulguları birleştirilmiştir. Sonuçların birleştirilmesinden sonra elde edilen ikili görüntüye son işlem olarak, olası gürültüler kaldırmak amacıyla, 3x3 maske boyutuna sahip Medyan filtreleme işlemi uygulanmış ve bulgular değerlendirme ölçütlerine göre Çizelge 4.27’de verilmiştir.

Çizelge 4.27. Denetimsiz tahmin bütünleştirme sonuçları

Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.5453	0.9898	0.9319	0.8891
2.	0.6180	0.9843	0.9316	0.8687
3.	0.6597	0.9559	0.9143	0.7100
4.	0.6342	0.9870	0.9255	0.8663
5.	0.6659	0.9858	0.9194	0.8825
6.	0.6548	0.9876	0.9188	0.8943
7.	0.6591	0.9956	0.9293	0.9581
8.	0.6427	0.9786	0.9189	0.8007
9.	0.6941	0.9899	0.9289	0.9252
10.	0.5677	0.9861	0.9316	0.8596
11.	0.6669	0.9909	0.9301	0.9124
12.	0.6980	0.9641	0.9130	0.8487
13.	0.6674	0.9896	0.9284	0.9027
14.	0.6810	0.9561	0.9152	0.8629
15.	0.6800	0.9924	0.9426	0.9226
ORTALAMA	0.6490	0.9822	0.9253	0.8736

Çizelge 4.27’de denetimsiz sonuç bütünleştirme yöntemini kullanarak HRF test kümesindeki her görüntü için ayrı ayrı ve ortalama % 64.90 duyarlılık, % 98.22 özgüllük, % 92.53 doğruluk ve % 87.36 kesinlik sonuçlarına ulaşılmıştır. Ayrıca, denetimsiz sonuç bütünleştirme yöntemi uygulanarak gerçekleştirilen retina damar bölütlenmesi işlemi görüntü başına ortalama 2,2008 sn sürmüştür.



Şekil 4.14. (a) Renkli retina (b) referans (c) denetimsiz sonuç bütünleştirme yöntemiyle elde edilen retina damar haritası görüntüsü

Sonuç bütünleştirme kullanılarak HRF test veri kümesindeki 1. renkli retina görüntüsünden elde edilen retina damar haritası, Şekil 4.14'te gerçek referans damar örgüsüyle karşılaştırılmalı olarak verilmiştir. Hem elde edilen görüntü hem de değerlendirme sonuçları göz önüne alındığında, iki denetimsiz yöntemin belirli bir kurala göre birleştirilmesi, retina damar bölütlenmesi başarısını arttırmıştır.

Çizelge 4.28. HRF test veri kümesi denetimsiz retina damar bölütlemesi sonuç özeti

Yöntem	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
Matematiksel Morfoloji	0.5160	0.9855	0.9172	0.8653
Coye Filtreleme - BBA	0.5326	0.9959	0.9211	0.9528
Denetimsiz Sonuç Bütünleştirme	0.6490	0.9822	0.9253	0.8736

Çizelge 4.28’te HRF test veri kümesine denetimsiz retina damar bölütlenmesi uygulama sonuçları verilmiştir. Önerilen denetimsiz yöntem, belirlenen değişken değerleri ve işlem sırasıyla HRF veri kümesi üzerinde test edilmiştir. HRF veri kümesinde elde edilen anlamlı bulgular önerilen denetimsiz yöntemin retina damar tahmin başarısını arttırdığını bir kez daha göstermiştir.

4.4.3. Derin Öğrenme Tabanlı Yaklaşım Sonuçları

Bölüm 4.2.1’deki bulgular doğrultusunda ilk olarak, U-Net model eğitimi HRF veri kümesinin orijinal eğitim grubuyla yapılmıştır. U-Net Modeli, eğitim kümesi görüntülerine karşılık gelen referans görüntüleriyle birlikte tek kanal üzerinden eğitilmiştir. U-Net modelinin eğitimi 30 görüntü için ortalama 13 sn’de tamamlanmıştır. U-Net modeli eğitildikten sonra modele HRF veri kümesinin renkli ve KSAHE işlemi uygulanmış test kümesi görüntüleri verilmiştir.

Çizelge 4.29’da renkli test kümesi için retina damar tahmini ve Çizelge 4.30’da KSAHE ile işlenmiş HRF test kümesinin ortalama duyarlılık, özgüllük, doğruluk ve kesinlik sonuçlarına ulaşılmıştır.


Çizelge 4.29. HRF orijinal test kümesi tek kanallı eğitim sonuçları

Yöntem	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
30 / 15 Orijinal	0.6561	0.9813	0.9584	0.7509

Çizelge 4.30. HRF KSAHE uygulanmış test kümesi tek kanallı eğitim sonuçları

Yöntem	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
30 / 15 KSAHE	0.5799	0.9804	0.9472	0.6431

Çizelge 4.29'daki bulgulardan anlaşılabacağı üzere; düşük sayıda eğitim kümesi kullanılarak gerçekleştirilen retina damar haritası tahmini, denetimsiz retina damar bölütlenmesi yaklaşımları ile benzer sürede tamamlanmasına rağmen denetimsiz yöntemlere kıyasla özellikle ortalama özgüllük ve ortalama kesinlik açısından yetersiz olmuştur. Ayrıca Çizelge 4.29 ve Çizelge 4.30'daki sonuçlar birlikte incelendiğinde, U-Net modeline eğitim aşamasında KSAHE ile ön işlenmiş görüntüler verilmediği sürece, test görüntülerinin KSAHE ile işlenmesinin modelin tahmin başarısını düşürdüğü tespit edilmiştir.



Şekil 4.15. (a) Renkli retina (b) referans (c) temel U-Net ile elde edilen retina damar haritası görüntüsü

Şekil 4.15'te temel U-Net modelinin ön işlemez HRF test kümesindeki 1. renkli retina görüntüsü için retina damar örgüsü tahmini, gerçek referans damar örgüsüyle karşılaştırılmalı olarak verilmiştir. Görsel bulgular dikkatlice incelendiğinde, düşük sayıda veriyle eğitilmiş U-Net modeli özellikle ince vasküler yapıları tahmin etmede yetersiz kalmıştır.

Derin öğrenme mimarisinin başarısını arttırmak amacıyla renkli retina görüntülerinin eğitim kümesine denetimsiz ön hazırlık işlemleri uygulanmıştır. Uygulanan işlem sonucunda eğitim kümesi 120 adet (30'u orijinal, 30'u KSAHE, 30'u matematiksel morfoloji ve 30'si Coye filtreleme) görüntüye ulaşmıştır. U-Net mimarisinin eğitimi 120 retina görüntüsü ve bu görüntülere karşılık gelen referans görüntüleriyle tek kanal üzerinden tamamlanmıştır. Eğitilmiş U-Net modeline HRF veri kümesinin orijinal test kümesi (1 – 15) ve KSAHE işlemi uygulanmış test kümesi verilmiş ve bulgular karşılaştırılmıştır. Ek olarak, ön işlemden geçirilmiş eğitim kümesi sırasıyla

yatay ekseninde yansıma, dikey ekseninde yansıma, hem yatay hem dikey ekseninde yansıma, 30^0 ve 60^0 döndürme işlemleri uygulanarak eğitim kümesi eleman sayısı 270'e yükseltilmiştir. U-Net mimarisinin eğitimi 270 retina görüntüsü ve bu görüntülere karşılık gelen referans görüntüleriyle tek kanal üzerinden tamamlanmıştır. Eğitilmiş U-Net modeline HRF veri kümesinin orijinal test kümesi (1 – 15) verilerek sonuçlar kıyaslanmıştır.

Çizelge 4.31'de U-net modelinin orijinal test kümesi ve Çizelge 4.32'de ise KSAHE işlemi uygulanmış test kümesi için retina damar tahmini ortalama sonuçlarına ulaşılmıştır. Çizelge 4.33'de de genişletilmiş eğitim veri kümesiyle eğitilen modelin tahmin başarısı değerlendirilmiştir.

Çizelge 4.31. HRF orijinal test veri kümesi, ön hazırlıklı ve tek kanallı eğitim sonuçları

Yöntem	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
120 / 15 Orijinal	0.7119	0.9825	0.9642	0.7469


Çizelge 4.32. HRF KSAHE uygulanmış test veri kümesi, ön hazırlıklı ve tek kanallı eğitim sonuçları

Yöntem	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
120 / 15 KSAHE	0.7204	0.9811	0.9635	0,7349

Çizelge 4.33. HRF ön hazırlıklı ve veri kümesi genişletilmiş tek kanallı eğitim sonuçları

Yöntem	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
270 / 15 Orijinal	0.7544	0.9801	0.9638	0.7321

Hem DRIVE veri kümesi üzerinde gerçekleştirilen deneylerin bulgularından hem de Çizelge 4.31 ve Çizelge 4.32’deki HRF veri kümesi sonuçlarından anlaşılabacağı üzere; eğitim kümesinin eleman sayısının arttırılması U-Net modelinin tahmin başarısını anlamlı olarak yükseltmesine rağmen, modelin eğitim süresi 120 görüntü için ortalama 29 sn’de tamamlanmıştır. Ayrıca, model eğitimi, ön işlemlerden geçirilerek eleman sayısı arttırılmış eğitim kümesiyle tamamlandığında test kümesindeki görüntülere KSAHE işlemi uygulanması sadece ortalama duyarlılığı anlamlı olarak yükseltmiştir. Genişletilmiş veri kümesiyle eğitilmiş U-Net modelinin orijinal test görüntüleri için retina damar örgüsü tahmin sonuçları Çizelge 4.33’de verilmiştir. Eğitim veri kümesinin eleman sayısının arttırılması U-Net modelinin tahmin başarısını ortalama duyarlılık ve doğruluk açısından doğrudan etkilemesine rağmen, bu yaklaşımda da eğitim süresi 270 görüntü için ortalama 47 sn’de tamamlanmıştır.



Şekil 4.16. (a) Renkli retina (b) referans (c) veri kümesi genişletilmiş tek kanal U-Net yöntemiyle elde edilen retina damar haritası görüntüsü

Şekil 4.16’da U-Net modelinin ön hazırlıklı, genişletilmiş ve tek kanallı eğitimi sonucunda, HRF orijinal test kümesindeki 1. renkli retina görüntüsü için retina damar örgüsü tahmini, gerçek referans damar örgüsüyle karşılaştırılmalı olarak verilmiştir. Görsel bulgular dikkatlice incelendiğinde; eğitim veri kümesinin eleman sayısındaki artış, modelin tahmin başarısını yükseltmiş olmasına rağmen işlem süresini de neredeyse 4 katına çıkarmıştır.

Derin öğrenme tabanlı yaklaşımın eğitim süresini kısaltmak amacıyla U-Net modelin eğitimi paralel kanal olarak tasarlanmıştır. Bu yaklaşımı gerçekleştirmek üzere HRF veri kümesinin eğitim kümesi denetimsiz olarak ön işleminden geçirilmiştir. Eğitim

kümesinde her görüntüye sırasıyla KSAHE, matematiksel morfoloji ve Coyer filtreleme ve bağlantılı bileşen analizi işlemleri uygulanmıştır. Derin öğrenme tabanlı yaklaşımın eğitimi için; eğitim veri kümesinin orijinal görüntülerine ek olarak, denetimsiz ön işlenmiş görüntüler ve karşılık gelen referans görüntüleri paralel kanal aracılığıyla U-Net modeline verilmiştir.

Çizelge 4.34’de görüldüğü üzere HRF test kümesinde ortalama duyarlılık % 77.31, özgüllük % 98.17, doğruluk % 96.43 ve kesinlik % 73.26 sonuçlarına ulaşılmıştır.

Çizelge 4.34. HRF veri kümesi paralel kanallı eğitim sonuçları

Yöntem	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
Paralel kanal	0.7731	0.9817	0.9643	0.7326

Elde edilen sonuçlar göz önüne alındığında paralel kanallı eğitim yaklaşımında U-Net modeli toplamda 30 farklı görüntüyle eğitilmiş olsa da modelin tahmin başarısı temel U-Net modeline kıyasla yükselmiştir. Ayrıca, modelin eğitim süresi 30 görüntü için ortalama 93 sn’de tamamlanmıştır. U-Net model eğitiminin paralel kanal ile denetimsiz ön işlem uygulanmış retina görüntüleri ile yapılması modelin tahmin başarısını yükseltirken, işlem yükünü de arttırmıştır.

Çalışmanın 4.2.1. bölümünde, eğitim kümesindeki eleman sayısını arttırmanın, U-Net modelinin tahmin başarısına olumlu katkı sağladığı görülmüştür. Bu anlamlı bulgudan yola çıkarak, eğitim kümesinin orijinal görüntülerine; sadece yatay eksende yansıma, sadece dikey eksende yansıma, yatay – dikey eksende yansıma ek olarak 30⁰ ve 60⁰ derece döndürme işlemleri uygulanarak eğitim veri kümesi 5 katına çıkarılmıştır. Veri kümesi genişletme işlemi sonucunda eğitim kümesinin eleman sayısı 180 adet olmuştur. Derin öğrenme tabanlı U-Net modelinin eğitimi paralel kanal üzerinden ve toplamda 180 farklı orijinal ve ön işlenmiş retina görüntüsüyle gerçekleştirilmiştir.

Çizelge 4.35. HRF veri kümesi genişletilmiş paralel kanallı eğitim sonuçları


Yöntem	Duyarlılık	Özgüllük	Doğruluk	Keskinlik
Genişletilmiş veri kümesi – Paralel kanal	0.7916	0.9828	0.9644	0.7446

Çizelge 4.35’te görüldüğü üzere HRF test kümesinde ortalama duyarlılık % 79.16, özgüllük % 98.28, doğruluk % 96.44 ve keskinlik % 74.46 açısından en başarılı sonuçlara ulaşılmıştır. Modelin eğitim süresi 180 görüntü için ortalama 107 sn’de tamamlanmıştır.

Çizelge 4.36. Derin öğrenme tabanlı yöntem sonuçlarının literatür ile karşılaştırılması

Yöntem	Duyarlılık	Özgüllük	Doğruluk	Keskinlik
Panda, Puan ve Panda (2015)	0.8159	0.9525	0.9420	-
Li, Li, Li ve Zhou (2019)	0.8303	-	-	0.8043
Soomro, Afifi, Gao (2019)	0.8290	0.9610	0.9620	-
Islam, Poly, Walter, Yang ve Li (2020)	0.8100	0.9200	-	-
Zhao, Li ve Cheng (2020)	0.7809	0.9818	-	-
Jena, Singla ve Batmanghelich (2021)	-	-	0.9496	-
Genişletilmiş veri kümesi – Paralel kanal	0.7916	0.9828	0.9644	0.7446

Çizelge 4.36’da HRF veri kümesine derin öğrenme tabanlı yöntemler uygulanarak elde edilen sonuçlar literatür ile kıyaslanmıştır. Veri kümesi genişletilmiş paralel kanallı U-Net modeli ortalama özgüllükte % 98.28 sonucuyla ve ortalama doğrulukta % 96.44 değeriyle en başarılı yöntem olmuştur.



Şekil 4.17. (a) Renkli retina (b) referans (c) veri kümesi genişletilmiş paralel kanallı U-Net yöntemiyle elde edilen retina damar haritası görüntüsü

U-Net modelinin HRF test kümesindeki 1. renkli retina görüntüsünün retina damar örgüsü tahmini, gerçek referans damar örgüsüyle karşılaştırılmalı olarak Şekil 4.17’de verilmiştir. Görsel bulgular dikkatlice incelendiğinde; U-Net modeli veri kümesi genişletme uygulanmış ve paralel kanallı eğitimi, değerlendirme ölçütlerine göre en yüksek performansı sağlamıştır.

4.4.4. Hibrit Yöntem Sonuçları

Bu bölümde, HRF veri kümesi kullanılarak U-Net tabanlı hibrit retina damar bölütlenmesi yaklaşımı değerlendirilmiştir. Önerilen yaklaşım 3 basamakta yapılmaktadır. İlk olarak, sayısal retina görüntülerine denetimsiz ön işlemler uygulanmıştır. Söz konusu denetimsiz ön hazırlık yaklaşımları bölüm 4.1’de en başarılı bulguları sağlayan parametre ve işlem sırasıyla yapılmıştır. HRF veri kümesinin test için ayrılan 15 görüntüsüne sırasıyla matematiksel morfoloji ve Coyer filtreleme ve bağlantılı bileşen analizi yaklaşımları uygulanmıştır. Elde edilen sonuçlar birleştirilmiştir. İkinci olarak; U-net mimarisinin eğitimi, HRF veri kümesinin eğitim kümesine (30 adet) ön işleme ve veri kümesi genişletme uygulanarak paralel kanal üzerinden tamamlanmıştır.

Son olarak, denetimsiz retina damar bölütlenmesi yapılan test kümesinin sonuçları ile U-Net modelinin tahmin sonuçları birleştirilmiştir.

Çizelge 4.37’de HRF veri kümesi üzerindeki hibrit yaklaşımın bulguları her görüntü için ayrı ayrı ve ortalama duyarlılık, özgüllük, doğruluk ve kesinlik değerleri verilmiştir.

Çizelge 4.37. HRF orijinal test veri kümesi hibrit yöntem sonuçları


Görüntü No	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
1.	0.8015	0.0160	0.9611	0.8162
2.	0.8142	0.0205	0.9623	0.8259
3.	0.8560	0.0127	0.9670	0.8292
4	0.7972	0.0175	0.9634	0.8411
5.	0.8422	0.0140	0.9682	0.8129
6.	0.8756	0.0132	0.9672	0.8248
7.	0.8158	0.0206	0.9617	0.8380
8.	0.8421	0.0131	0.9539	0.8620
9.	0.8462	0.0129	0.9675	0.8526
10.	0.8327	0.0292	0.9656	0.8081
11.	0.8369	0.0220	0.9679	0.8825
12.	0.8176	0.0101	0.9675	0.8602
13.	0.8018	0.0130	0.9682	0.8681
14.	0.8254	0.0189	0.9626	0.8243
15.	0.8978	0.0180	0.9670	0.8673
ORTALAMA	0.8335	0.9832	0.9637	0.8409

Çizelge 4.37’de önerilen hibrit yaklaşımın HRF test kümesindeki her görüntü için ayrı ayrı ve ortalama % 83.35 duyarlılık, % 98.32 özgüllük, % 96.37 doğruluk ve % 84.09 kesinlik sonuçlarına ulaşılmıştır. Ayrıca, önerilen hibrit yöntem denetimsiz ön işlemler de dahil olmak üzere görüntü başına ortalama 109,2008 sn’de tamamlanmıştır.

Çizelge 4.38. HRF test veri kümesi sonuç özeti


U-Net Yöntemi	Duyarlılık	Özgüllük	Doğruluk	Kesinlik
30 / 15 Orijinal	0.6561	0.9813	0.9584	0.7509
30 / 15 KSAHE	0.5799	0.9804	0.9472	0.6431
120 / 15 Orijinal	0.7119	0.9825	0.9642	0.7469
120 / 15 KSAHE	0.7204	0.9811	0.9635	0.7349
270 / 15 Orijinal	0.7544	0.9801	0.9638	0.7321
Paralel kanallı	0.7731	0.9817	0.9643	0.7326
Paralel kanallı Veri genişletme uygulanmış	0.7916	0.9828	0.9644	0.7446
Hibrit Yöntem	0.8335	0.9832	0.9637	0.8409

Çizelge 4.38’de önerilen hibrit yöntemin HRF veri kümesi retina damar haritası tahmin başarı özeti verilmiştir. Elde edilen bulgular ışığında, önerilen hibrit yöntemin özellikle ortalama duyarlılığı anlamlı olarak % 83.35 değerine ve ortalama doğruluğu % 96.37 değerine yükseltmiştir. Ortalama özgüllükte % 98.32 ve ortalama kesinlikte % 84.09 değerlerinin, HRF veri kümesiyle yapılan çalışmalarda en yüksek bulgular olduğu tespit edilmiştir. Ayrıca hibrit yöntem, hem DRIVE veri kümesi bulgularından hem de HRF veri kümesi bulgularından elde edilen sonuçlara göre derin öğrenme tabanlı sistemler arasında sağladığı başarıya kıyasla en az işlem yükü gerektirdiğini tekrar doğrulamıştır.



Şekil 4.18. (a) Renkli retina (b) referans (c) hibrit yöntemle elde edilen retina damar haritası görüntüsü

Şekil 4.18’de U-Net tabanlı hibrit modelin, HRF orijinal test kümesindeki 1. renkli retina görüntüsü için retina damar örgüsü tahmini, gerçek referans damar örgüsüyle karşılaştırılmalı olarak verilmiştir.



Şekil 4.19. (a) Renkli retina (b) referans (c) matematiksel morfoloji yöntemi (d) Coye filtre ve BBA yöntemi (e) denetimsiz sonuç bütünleştirme (f) temel U-Net modeli tahmini (g) genişletilmiş paralel kanallı U-Net (h) hibrit yöntem görüntüsü

Şekil 4.19’da HRF test veri kümesindeki 1. renkli retina görüntüsü, gerçek damar haritası ve önerilen hibrit yaklaşım ile her basamak için elde edilen retina damar haritası tahmini gösterilmiştir. Coye – BBA yöntemi ince vasküler yapıları tespit etmede matematiksel morfoloji yöntemine kıyasla daha başarılıdır. Bu durum Şekil 4.19.(c) ve Şekil 4.19.(d)’deki görüntülerde retinanın fovea kısmında ve alt ana damarın uç dallanma yapısından görülebilmektedir. Genişletilmiş paralel kanallı U-Net modeli, temel U-Net modeline kıyasla üstün performans göstermiştir. Bu durum Şekil 4.19.(g)’deki ince vasküler yapıların sürekliliği Şekil 4.19.(f)’den daha belirgindir. Hibrit yöntem ile elde edilen damar örgüsü (Şekil 4.19.(h)) neredeyse gerçek referans görüntüsüyle örtüşmektedir.

BÖLÜM 5

SONUÇ VE TARTIŞMA

Tıbbi görüntüleme, hastalıkların erken tespitinden tedavi sürecinin izlenmesine kadar geniş bir uygulama alanını kapsamaktadır. Medikal görüntüler genellikle gürültü nedeniyle bozulur ya da düşük kontrast/zıtlık sorunundan etkilenebilir. Bu durumun üstesinden gelmek ve hastalıkların daha iyi tespiti için tıbbi görüntü iyileştirme çalışmaları yükselen ilgi alanlarından biridir. Tıbbi görüntü iyileştirmenin temel amacı, gürültü seviyesinin azaltılması ve tıbbi görüntülerin zıtlığının iyileştirilerek ve uzmanlara yardımcı olarak hastalığa net tanı konulmasıdır.

Tıbbi retina tarama görüntüleri, retina bozukluklarının tespiti için klinik tanıda yaygın olarak kullanılmaktadır. Katarakt, glokom, diyabetik retinopati, diyabetik makula ödemi gibi diyabetik göz hastalıkları retinada kılcal damar hasarına neden olmaktadır. Hastalığın tespitinde geç kalınması ya da fark edilmemesi kademeli olarak geçici görme kayıplarına ve kalıcı körlüğe neden olabilmektedir. Bu nedenle, diyabetik göz hastalıklarının erken tespiti görme yetisi kaybını önlemede çok önemli bir adımdır. Fundus görüntü analizinde retina kan damarlarının otomatik bölütlenmesi önemli bir konudur. Fundus görüntülerinde kan damarlarının bölütlenmesi; vasküler yapıların, fovea ve optik disk gibi diğer anatomik yapılardan ve patolojik unsurlardan ayrılması anlamına gelmektedir. Damar bölütlenmesi, görüntü işlemedeki en zor alanlardan biridir. Retina damar bölütlenmesi, düşük kontrastlı, gürültülü ve aydınlatma farklılıkları içeren ve kılcal

yapıları ayırt etme sürecini engelleyen düşük kaliteli fundus görüntüleriyle daha da karmaşılaşır. Sonuç olarak, bu görüntülerde vasküler yapıların otomatik olarak tanımlanması süregelen bir sorundur.

Bu tezde, derin öğrenme ağları ve denetimsiz görüntü işleme tabanlı iyileştirme kullanılarak retina damar bölütlenmesi için hibrit bir sistem geliştirilmiştir.

Önerilen yöntemde kullanılan yaklaşımların sırası ve parametre değerleri DRIVE adlı araştırmacıların erişimine açık ve yedisi patolojik bulgulu olmak üzere toplam 40 farklı renkli retina görüntülerinden oluşan veri kümesi kullanılarak belirlenmiştir. Optimize edilen yöntemin genel geçerliliği, HRF veri kümesi üzerinde test edilmiştir. HRF veri kümesi; 15 tanesi sağlıklı, 15 tanesi diyabetik retinopatili ve 15 tanesi de glokom bulgulu olarak işaretlenmiş ve toplamda 45 farklı görüntü içermektedir. Tez çalışması süresince fundus görüntülerinin ön ve son işlenmesi, veri kümesi genişletme işlemleri ve sonuçların karşılaştırılması Matlab yazılım platformunda yapılmıştır. Ayrıca derin öğrenme mimarisinin eğitim ve test aşamaları Google COLAB platformunda tamamlanmıştır.

Matematiksel morfoloji yöntemi kullanılarak DRIVE veri kümesi üzerinde gerçekleştirilen retina damar bölütlenmesi ortalama duyarlılıkta % 62.91, ortalama özgüllükte % 98.76, ortalama doğrulukta % 95.59 ve ortalama kesinlikte % 83.11 değerleriyle literatürdeki denetimsiz yaklaşımlar ile kıyaslandığında en iyi özgüllük ve doğruluk bulgularını elde etmiştir. Coye filtreleme ve bağlantılı bileşen analizi yöntemi kullanılarak DRIVE veri kümesi üzerinde gerçekleştirilen retina damar bölütlenmesi için ortalama duyarlılıkta % 63.20, ortalama özgüllükte % 98.64, ortalama doğrulukta % 95.51 ve ortalama kesinlikte % 82.17 değerleri elde edilmiştir. İlgili yöntemde duyarlılık metriği dışında matematiksel morfoloji yaklaşımından daha düşük sonuçlar elde edilmiştir. Matematiksel morfoloji ve Coye filtreleme ve bağlantılı bileşen analizi yöntemlerinin tahminleri mantıksal veya işlemiyle birleştirilmiştir. Sonuç bütünleştirmeyeyle ortalama duyarlılıkta % 70.12, ortalama özgüllükte % 98.08, ortalama doğrulukta % 95.60 ve ortalama kesinlik % 75.25 değerleri elde edilmiştir. Sonuç bütünleştirmeyeyle elde edilen ortalama duyarlılık, sadece matematiksel morfoloji ya da sadece Coye filtreleme ve bağlantılı bileşen analizi yöntemleri kullanımına kıyasla

yaklaşık %7 artmıştır. Ayrıca, sonuç bütünleştirme yaklaşımı, önceki denetimsiz öğrenme çalışmalarına kıyasla en iyi ortalama doğruluğu elde etmiştir.

DRIVE veri kümesindeki orijinal görüntülerle eğitilmiş ve test edilmiş temel U-Net modelinde en düşük duyarlılık % 68.65 olarak tespit edilmiştir. Derin öğrenme U-Net modeli sadece KSAHE ön işlenmiş görüntülerle test edildiğinde, özgüllük ve doğruluk metriklerinde düşüş meydana gelirken, modelin duyarlılığı % 84.04’de yükselmiştir. Eğitim kümesi denetimsiz olarak KSAHE, matematiksel morfoloji ve Coyle filtreleme ve bağlantılı bileşen analizi yöntemleri kullanılarak genişletildiğinde, ortalama duyarlılık temel U-Net modeline kıyasla % 2.37 artarken, ortalama özgüllük % 0.38, ortalama doğruluk % 0.14 ve ortalama kesinlik % 3.26 miktarlarında azalma eğilimi göstermiştir. Aynı genişletilmiş eğitim kümesi, KSAHE ön işlem uygulanmış görüntülerle test edildiğinde önemli bir etki gözlemlenmemiştir. Ön işlenmiş görüntülerle büyütülmüş eğitim kümesine veri kümesi genişletme işlemleri uygulanarak eğitim grubu toplam 180 adede yükseltilmiştir. Bu konfigürasyon ortalama duyarlılıkta ve ortalama doğrulukta anlamlı bir artış sağlamıştır, fakat ortalama özgüllük ve ortalama kesinliği %1’in altında etkilemiştir. Veri kümesi genişletilmiş paralel kanal tabanlı U-Net konfigürasyonu uygulandığında en yüksek doğruluk sonucu sağlanmış ve temel U-Net modeline kıyasla duyarlılıktaki artış % 10.18 olarak tespit edilmiştir. Veri kümesi genişletilmiş paralel kanal tabanlı derin U-Net modelinin tahminleri ile denetimsiz ön işleme yaklaşımı sonuçları birleştirilmiştir. Önerilen hibrit modelin ortalama duyarlılığı % 82,49’a ulaşmıştır. Ayrıca, önerilen hibrit modelin ortalama özgüllük ve ortalama doğruluk metriklerinde önemli bir düşüşe neden olmamıştır.

Önerilen hibrit yöntemin genel geçerliliği HRF veri kümesi üzerinde test edilmiştir. HRF veri kümesi sağlayıcıları tarafından eğitim ve test kümelerine ayrılmamıştır. İlk olarak HRF veri kümesi, eğitim ve test kümelerine bölünmüştür. HRF veri kümesinde eğitim kümesi için sağlıklı olarak işaretlenen görüntülerin ilk 10 tanesi, diyabetik retinopati görüntülerin ilk 10 tanesi ve glokom bulgulu görüntülerin ilk 10 tanesi, bu görüntülere karşılık gelen referans görüntüleri ile birlikte toplamda 30 görüntü olacak şekilde seçilmiştir. HRF veri kümesi test kümesi ise sağlıklı olarak işaretlenen görüntülerin son 5 tanesi, diyabetik retinopati görüntülerin son 5 tanesi ve glokom bulgulu görüntülerin son 5 tanesiyle toplamda 15 görüntü olacak şekilde belirlenmiştir.

HRF test veri kümesindeki retina görüntülerine denetimsiz matematiksel morfoloji yaklaşımı kullanılarak; ortalama duyarlılıkta % 51.60, ortalama özgüllükte % 98.55, ortalama doğrulukta % 91.72 ve ortalama kesinlikte % 86.53 değerleri elde edilmiştir. Coye filtreleme ve bağlantılı bileşen analizi yöntemi kullanılarak HRF test veri kümesi üzerinde gerçekleştirilen retina damar bölütleme işlemi sonucunda ise ortalama duyarlılık % 53.26, ortalama özgüllük % 99.59, ortalama doğruluk % 92.11 ve ortalama kesinlik için % 95.28 değerleri elde edilmiştir. Coye filtreleme ve bağlantılı bileşen analizi yaklaşımı HRF test kümesinde, kullanım amacı doğrultusunda, ince damar yapılarını rahatlıkla tespit edebildiğinden dolayı yüksek başarı göstermiştir. Denetimsiz sonuç bütünleştirme işlemiyle de ortalama duyarlılıkta % 13.3, ortalama doğrulukta % 0.81 ve ortalama kesinlikte % 0.83 artış tespit edilmiştir. Denetimsiz sonuç bütünleştirme işlemi ortalama özgüllük metriğinde % 0.33'lik kabul edilebilir azalma göstermiştir.

HRF eğitim kümesindeki orijinal görüntülerle eğitilmiş ve HRF test kümesiyle test edilmiş temel U-Net modelinde duyarlılık % 65.61, özgüllük % 98.13, doğruluk % 95.84 ve kesinlik % 75.09 olarak tespit edilmiştir. Derin öğrenme U-Net modeli sadece KSAHE ön işlenmiş görüntülerle test edildiğinde, tüm metriklerde az miktarda bir düşüş meydana gelirken, modelin duyarlılığında % 57.99'a kadar düşüş gözlenmiştir. HRF eğitim kümesi denetimsiz olarak KSAHE, matematiksel morfoloji ve Coye filtreleme ve bağlantılı bileşen analizi yöntemleri kullanılarak genişletildiğinde (toplamda 120 adet), ortalama duyarlılık temel U-Net modeline kıyasla % 5.58 artarken, ortalama özgüllük % 0.12, ortalama doğruluk % 0.58 kadar yükselme eğilimi göstermiştir. Sadece ortalama kesinlikte % 0.4 kadar azalma tespit edilmiştir. Aynı genişletilmiş eğitim kümesiyle eğitilmiş model üzerinde KSAHE ön işlem uygulanmış görüntülerle test edildiğinde duyarlılık metriğinde sadece %0,85'lik artış gözlenmiştir. Ön işlenmiş görüntülerle büyütülmüş eğitim kümesine veri kümesi genişletme işlemleri uygulanarak eğitim kümesi toplamda 270 adede yükseltilmiştir. Bu konfigürasyon ortalama duyarlılıkta ve ortalama doğrulukta anlamlı bir artış sağlamıştır, fakat ortalama özgüllük ve ortalama kesinliği % 1'in altında etkilemiştir. Veri kümesi genişletilmiş paralel kanal tabanlı U-Net konfigürasyonu uygulandığında en yüksek duyarlılık sonucu sağlanmış ve temel U-Net modeline kıyasla duyarlılıktaki artış % 13.55 olarak tespit edilmiştir. Veri kümesi genişletilmiş paralel kanal tabanlı derin U-Net modelinin tahminleri ile denetimsiz ön işleme yaklaşımı sonuçları birleştirilmiştir. Önerilen hibrit modelin ortalama duyarlılığı

% 83.35'e ulaşmıştır. Ayrıca, önerilen hibrit modelde HRF test veri kümesi için ortalama özgüllükte % 98.32, ortalama doğrulukta % 96.37 ve ortalama kesinlikte % 84.09 değerleri elde edilmiştir.

Denetimsiz görüntü ön işleme ve derin öğrenme U-Net tabanlı çözümleri birleştiren hibrit yaklaşımlar, son zamanlarda kullanılmaya başlandığı için literatürde klasik yaklaşımlara kıyasla çok az çalışma bulunmaktadır. Veri büyütme ve denetimsiz görüntü ön işleme tabanlı yaklaşımla önerilen paralel kanal tabanlı U-Net modeli, literatürdeki ilgili çalışmalarla karşılaştırıldığında en iyi özgüllük, doğruluk ve karşılaştırılabilir duyarlılık ve kesinlik oranı elde etmiştir. Elde edilen sonuçlar göz önüne alındığında, retina damar bölütleme performansını daha da arttırmak için U-Net modelinin klasik görüntü işleme yaklaşımlarıyla birlikte kullanılabileceği de gösterilmiştir. Ayrıca önerilen hibrit yaklaşım son teknoloji yöntemlerle karşılaştırıldığında; ilave hesaplama süresi gerektirmeden doğruluk, özgüllük, duyarlılık ve kesinlik açısından üstün performans göstermiştir.

Sayısal patoloji görüntü analizine odaklanan güncel bir çalışmada; işlem sonrası bölütleme yaklaşımlarının, orijinal derin öğrenme çerçevesine kıyasla modelin performansını artırmaya yardımcı olabileceği bildirilmiştir (Salvi, Acharya, Molinari ve Meiburger, 2020). Bulgularımız bu yaklaşımı retina damar bölütlemesindeki başarısıyla doğrulamıştır. İleri dönemlerde algoritmamızı birden fazla merkezden gelen retinal fundus verileri ve çeşitli hastalık durumlarına sahip veriler üzerinde test etmeyi hedeflemekteyiz. Ayrıca, tekniğimiz BT görüntülerinde koroner arterler, X-ray'de kol damarları gibi benzer damar bölütlenme zorluklarında etkili olacaktır. Hedeflerimiz arasında; benzer durumlarda tekniğimizi doğrulamak da yer almaktadır. Filtreleme işlemi büyük veri kümelerinde ek doğrulama verilerine ihtiyaç duyduğu için; parametre sayısı algoritmamızı sınırlamaktadır. İlerideki çalışmalarımızda veri ve parametre sayımızı arttırarak algoritmamızı geliştirmeyi amaçlamaktayız.

Sonuç olarak çalışmamız; klasik görüntü işleme yaklaşımlarının derin öğrenme teknikleri ile başarılı bir şekilde bir araya getirilmesine önemli bir katkı sağlamaktadır. Günümüzde hastanelerde sayısal retinografi kullanımı oldukça artmıştır. Önerilen algoritmamız derin öğrenme yaklaşımının çıktılarını denetimsiz öğrenme çıktıları ile birleştirerek, daha doğru damar bölütlenmesine yardımcı olup hastalıkların tespiti gibi tıbbi konulara önemli katkı sağlayacaktır.



BÖLÜM 6

KAYNAKÇA

- Akbar S., Sharif M., Akram M.U., Saba T., Mahmood T. (2019). Automated techniques for blood vessels segmentation through fundus retinal images: A review. *Microscopy Research and Technique* 2019; 82 (2): 153-170.
- Akman, A. (2021). Göz Bozukluğu Çeşitleri. 3 Haziran 2021 tarihinde <https://www.drahmetakman.com/tr/goz-bozukluklari-ve-cesitleri> adresinden erişildi.
- Alhussein M., Aurangzeb K., Haider S.I. (2020). An unsupervised retinal vessel segmentation using Hessian and intensity based approach. *IEEE Access* 2020; 8: 165056-165070.
- Alom M.Z., Yakopcic C., Hasan M., Taha T.M., Asari V.K. (2019). Recurrent residual U-net for medical image segmentation. *Journal of Medical Imaging* 2019; 6 (1): 014006.
- Aurangzeb K., Aslam S., Alhussein M., Naqvi R.A., Arsalan M. ve Haider S.I. (2021). Contrast enhancement of fundus images by employing modified PSO for improving the performance of deep learning models. *IEEE Access* 2021; 9: 47930-47945.

- Azzopardi G., Strisciuglio N., Vento M., Petkov N. (2015). Trainable COSFIRE filters for vessel delineation with application to retinal images. *Medical Image Analysis* 2015; 19 (1): 46-57.
- Campos G.F.C., Mastelini S.M., Aguiar G.J., Mantovani R.G., De Melo L.F. ve Barbon S. (2019). Machine learning hyperparameter selection for contrast limited adaptive histogram equalization. *EURASIP Journal on Image and Video Processing* 2019; 2019 (1): 1-18.
- Datta N.S., Dutta H.S., De M., Mondal S. (2013). An effective approach: image quality enhancement for microaneurysms detection of non-dilated retinal fundus image. *Procedia Technology* 2013; 10: 731-737.
- DRIVE: Digital Retinal Images for Vessel Extaction. (2012). 12 Şubat 2021 tarihinde <https://drive.grand-challenge.org/> adresinden erişildi.
- Dos Santos J.C.M., Carrijo G.A., dos Santos Cardoso C.D.F., Ferreira J.C., Sousa P.M. ve Patrocinio AC. (2020). Fundus image quality enhancement for blood vessel detection via a neural network using CLAHE and Wiener Filter. *Research on Biomedical Engineering* 2020; 36: 107-119.
- Fraz M.M., Barman S.A., Remagnino P., Hoppe A., Basit A. Uyyanonvara B., Rudnicka AR. ve Owen CG. (2012). An approach to localize the retinal blood vessels using bit planes and centerline detection. *Computer Methods and Programs in Biomedicine* 2012; 108 (2): 600-616.
- Hassanien A.E., Emary E., Zawbaa H.M. (2015). Retinal blood vessel localization approach based on bee colony swarm optimization, fuzzy c-means and pattern search. *Journal of Visual Communication and Image Representation* 2015; 31: 186-196.
- High-Resolution Fundus (HRF) Database. (2013). 12 Şubat 2021 tarihinde <https://www5.cs.fau.de/research/data/fundus-images/> adresinden erişildi.

- Islam M. M., Poly T. N., Walter B. A., Yang H. C., Li Y. C. (2020). Artificial intelligence in ophthalmology: A meta analysis of deep learning models for retinal vessels segmentation. *Journal of Clinical Medicine* 2020; 9(4)-1018.
- İnan S. (2014). Retina Anatomisi. *Kocatepe Tıp Dergisi*. 2014;15(3):355-359.
- Jena R., Singla S., Batmanghelich K. (2021). Self-supervised vessel enhancement using flow-based consistencies. *Image and Video Processing* 2021; <https://arxiv.org/pdf/2101.05145v3.pdf> adresinden 4 Eylül 2021 tarihinde erişildi.
- Li R., Li M., Li J., Zhou Y. (2019). Connection sensitive attention u-net for accurate retinal vessel segmentation. *Computer Vision and Pattern Recognition* 2019; <https://arxiv.org/pdf/1903.05558.pdf> adresinden 4 Eylül 2021 tarihinde erişildi.
- Li T., Bo W., Hu C., Kang H., Liu H., Wang K. ve Fu H. (2021). Applications of deep learning in fundus images: A review. *Medical Image Analysis* 2021; 69: 101971.
- Lidong H., Wei Z., Jun W., Zebin S. (2019). Combination of contrast limited adaptive histogram equalisation and discrete wavelet transform for image enhancement. *IET Image Processing* 2015; 9 (10): 908-915.
- Ma W., Yu S., Ma K., Wang J., Ding X. ve Zheng Y. (2019). Multi-task neural networks with spatial activation for retinal vessel segmentation and artery/vein classification. In: *International Conference on Medical Image Computing and Computer-Assisted Intervention*; 2019. pp. 769-778.
- Mishra S., Chen DZ., Hu X.S. (2020). A data-aware deep supervised method for retinal vessel segmentation. In: *IEEE 2020 17th International Symposium on Biomedical Imaging*; 2020. pp. 1254-1257.
- Oliveira W.S., Teixeira JV., Ren T.I., Cavalcanti G.D., Sijbers J. (2016). Unsupervised retinal vessel segmentation using combined filters. *PloS One* 2016; 11 (2): e0149943.

- Panda R., Puhan N. B., Panda G. (2015). New binary hausdorf symmetry measure based seeded region for growing for retinal vessel segmentation. *Biocybernetics and Biomedical Engineering* 2015; 36-1, p 119-129.
- Retinal Diseases (2020, 31 Mart). 18 Haziran 2021 tarihinde <https://www.mayoclinic.org/diseases-conditions/retinal-diseases/symptoms-causes/syc-20355825> adresinden erişildi.
- Ronneberger O., Fischer P., Brox T. (2015). U-net: Convolutional networks for biomedical image segmentation. In: *International Conference on Medical Image Computing and Computer-Assisted Intervention*; 2015. pp. 234-241.
- Sahu S., Singh A.K., Ghrera S.P., Elhoseny M. (2019). An approach for de-noising and contrast enhancement of retinal fundus image using CLAHE. *Optics & Laser Technology* 2019; 110: 87-98.
- Salvi M., Acharya U.R., Molinari F., Meiburger K.M. (2020). The impact of pre-and post-image processing techniques on deep learning frameworks: A comprehensive review for digital pathology image analysis. *Computers in Biology and Medicine* 2020; 128: 104129.
- Saroj S.K., Kumar R., Singh N.P. (2020). Fréchet PDF based matched filter approach for retinal blood vessels segmentation. *Computer Methods and Programs in Biomedicine* 2020; 194: 105490.
- Soomro T. A., Afifi A. J., Gao J., Hellwich O., Zheng L., Paul M. (2019). Strided fully convolutional neural network for boosting the sensitivity of retinal blood vessels segmentation. *Expert Systems with Applications* 2019; 134, p36-52.
- Staal J., Abramoff M.D., Niemeijer M., Viergever M.A., Van Ginneken B. (2004). Ridge-based vessel segmentation in color images of the retina. *IEEE Transactions on Medical Imaging* 2004; 23 (4): 501-509.
- Wang B., Qiu S., He H. (2019). Dual encoding U-net for retinal vessel segmentation. In: *International Conference on Medical Image Computing and Computer-Assisted Intervention*; 2019. pp. 84-92.

- Wang K., Zhang X., Huang S., Wang Q., Chen F. (2020). CTF-Net: Retinal vessel segmentation via deep coarse-to-fine supervision network. *In: IEEE 2020 17th International Symposium on Biomedical Imaging; 2020*. pp. 1237-1241.
- Wang W., Zhang J., Wu W., Zhou S. (2018). An automatic approach for retinal vessel segmentation by multi-scale morphology and seed point tracking. *Journal of Medical Imaging and Health Informatics 2018; 8 (2): 262-274*.
- Willoughby C.E., Ponzin D., Ferrari S., Lobo A., Landau K., Omid Y. (2010). Anatomy and physiology of the human eye: effects of mucopolysaccharidoses disease on structure and function – a review. *Clinical & Experimental Ophthalmology 2010; 38: 2-11*.
- Wu Y., Xia Y., Song Y., Zhang Y., Cai W. (2020). NFN+: A novel network followed network for retinal vessel segmentation. *Neural Networks 2020; 126: 153-162*.
- Wu Y., Xia Y., Song Y., Zhang D., Liu D., Zhang C. ve Cai W. (2019). Vessel-Net: Retinal vessel segmentation under multi-path supervision. *In: International Conference on Medical Image Computing and Computer-Assisted Intervention; 2019*. pp. 264- 272.
- Wu Y., Xia Y., Song Y., Zhang Y., Cai W. (2018). Multiscale network followed network model for retinal vessel segmentation. *In: International Conference on Medical Image Computing and Computer-Assisted Intervention; 2018*. pp. 119-126.
- Yan Z., Yang X., Cheng K.T. (2018). Joint segment-level and pixel-wise losses for deep learning based retinal vessel segmentation. *IEEE Transactions on Biomedical Engineering 2018; 65 (9): 1912-1923*.
- You X., Peng Q., Yuan Y., Cheung Y.M., Lei J. (2011). Segmentation of retinal blood vessels using the radial projection and semi-supervised approach. *Pattern Recognition 2011; 44 (10-11): 2314-2324*.
- Zhang B., Zhang L., Zhang L., Karray F. (2010). Retinal vessel extraction by matched filter with first-order derivative of Gaussian. *Computers in Biology and Medicine 2010; 40 (4): 438-445*.

- Zhang J., Dashtbozorg B., Bekkers E., Pluim J.P., Duits R. (2016). Robust retinal vessel segmentation via locally adaptive derivative frames in orientation scores. *IEEE Transactions on Medical Imaging* 2016; 35 (12): 2631-2644.
- Zhang Y., Chung AC. (2018). Deep supervision with additional labels for retinal vessel segmentation task. In: *International Conference on Medical Image Computing and Computer-Assisted Intervention*; 2018. pp. 83-91.
- Zhao, H., Li, H., Cheng, L. (2020). Improving retinal vessel segmentation with joint local loss by matting. *Pattern Recognit.* 98. doi: 10.1016/j.patcog.2019.107068.
- Zhou M., Jin K., Wang S., Ye J., Qian D. (2017). Color retinal image enhancement based on luminosity and contrast adjustment. *IEEE Transactions on Biomedical Engineering* 2017; 65 (3): 521 527.
- Zhao Y.Q., Wang X.H., Wang X.F., Shih F.Y. (2014). Retinal vessels segmentation based on level set and region growing. *Pattern Recognition* 2014; 47 (7): 2437-2446.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı – Soyadı : Cem YAKUT

EĞİTİM BİLGİLERİ

- 2019 – T. C. Trakya Üniversitesi (Yüksek Lisans)**
Hesaplamalı Bilimler Anabilim Dalı
- 2010 – 2016 T. C. Yeditepe Üniversitesi (Hazırlık + Lisans)**
Biyomedikal Mühendisliği (İngilizce)
(%50 Burslu – 2,62 / 4,00)
- 2006 – 2010 Edirne Anadolu Lisesi (Lise)**
Fen Bilimleri

YABANCI DİL

İngilizce Okuma: İleri, Yazma: İleri, Konuşma: İleri