



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EVRIŞİMLİ SİNİR AĞLARI KULLANILARAK RETİNA
GÖRÜNTÜLERİNİN SEGMENTASYONU VE
SINIFLANDIRILMASI

Mali MOHAMMEDHASAN

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Ağustos 2021
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mali MOHAMMEDHASAN tarafından hazırlanan “Evrişimli Sinir Ağları Kullanılarak Retina Görüntülerinin Segmentasyonu ve Sınıflandırılması” adlı tez çalışması 18/08/2021 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Halife KODAZ

Danışman

Prof. Dr. Harun UĞUZ

Üye

Doç. Dr. Hasan Erdinç KOÇER

Üye

Dr. Öğr. Üyesi Nurdan BAYKAN

Üye

Dr. Öğr. Üyesi Onur İNAN

İmza

.....

.....

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this seminar document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Mali MOHAMMEDHASAN

Date: 18/08/2021

ÖZET

DOKTORA TEZİ

EVİRİŞİMLİ SİNİR AĞLARI KULLANILARAK RETİNA GÖRÜNTÜLERİNİN SEGMENTASYONU VE SINIFLANDIRILMASI

Mali MOHAMMEDHASAN

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. Harun UĞUZ
2021, 72 Sayfa**

**Jüri
Prof. Dr. Harun UĞUZ
Prof. Dr. Halife KODAZ
Doç. Dr. Hasan Erdinç KOÇER
Dr. Öğr. Üyesi Nurdan BAYKAN
Dr. Öğr. Üyesi Onur İNAN**

Derin öğrenme, bilgisayar ve veri biliminde son birkaç yılda en hızlı büyüyen alanlardan biridir. Çeşitli uygulamalarda özellik çıkarma ve tanıma için yaygın olarak kullanılmaktadır. Derin öğrenmedeki son gelişmeler, tıbbi görüntülerdeki kalıpları tanımlamak, sınıflandırmak ve ölçmek için büyük bir adım atmıştır. Bu şekilde, derin öğrenme, çeşitli tıbbi uygulamalarda gelişmiş performanslar elde eden son teknoloji bir temel olduğunu hızla kanıtlamaktadır. Bu tez çalışmasında doku segmentasyonu ve bilgisayar destekli hastalık teşhisi üzerine iki temel çalışma gerçekleştirilmiştir. İlk çalışma, retina kan damarlarını fundus görüntülerinden otomatik olarak bölümlere ayırmak için yeni bir Derin Evrişimli Sinir Ağı (DESA) mimarisi önermektedir. Otomatik segmentasyon, retina hastalıklarının bilgisayar destekli teşhisinde temel bir rol oynamaktadır. Göz hastalıklarının ve belirgin patolojik semptomlara yol açan diğer sistemik hastalıkların tanısında oldukça önemlidir. Retina kan damarı segmentasyonu, gürültülü bir arka planda damarların morfolojisindeki aşırı değişiklikler nedeniyle zordur. Mevcut derin öğrenme tabanlı denetimli yöntemler, anlamsal segmentasyon görevlerinde avantajlı olan düşük seviyeli özelliklerin yetersiz kullanımından dolayı çeşitli problemlerle karşılaşmaktadır. Tez kapsamında önerilen mimari, retina kan damarlarını segmentlere ayırmak için hem yüksek seviyeli özellikleri hem de düşük seviyeli özellikleri kullanmaktadır. Önerilen mimarinin ana katkısı iki önemli faktöre odaklanmaktadır. Birincisi, kümelenmiş rezidüel bağlantıların son derece modülerleştirilmiş ağ mimarisini sağlamasıdır. İkincisi, ağ içindeki bilgi işlem kaynaklarının kullanımını iyileştirmektir. Bu, hesaplama maliyetinin istikrarını korurken ağın derinliğini ve genişliğini artırmaya izin veren bir tasarımla elde edilmektedir. Deneysel sonuçlar, retina damarlarını daha doğru ve net bir şekilde bölümlere ayırmada kümelenmiş rezidüel bağlantıların kullanılmasının etkinliğini göstermektedir. Mevcut en iyi yöntemlerle karşılaştırıldığında, önerilen yöntem, farklı ölçümlerde diğer mevcut yöntemlerden daha iyi performans göstermiştir. İnce damarlarda daha az yanlış pozitif içermiştir ve uzmanların manuel segmentasyonu gibi yeterli ayrıntılarla daha net sınır çizgileri içermiştir.

Diyabetik Retinopati (DR), zamanla retina dekolmanı, vitreus kanaması, glokom gibi görme sorunlarına yol açan ve daha kötü durumlarda başlangıçta periyodik DR taraması ile kontrol edilebilen körlüğe yol açan bir retina hastalığıdır. Erken teşhis, hastalığın daha fazla kontrolüne yol açacaktır, oysa tüm diyabetik hastalarda retina muayenelerinin yapılması ulaşılabilir bir ihtiyaçtır. Diyabetik retinopati, retina dokularında iz ve lezyonlar bırakacak ölçüde retinadaki kan damarlarında ilerleyici hasara neden olmaktadır. Bu lezyonlar kenarlar şeklinde görünür ve retina görüntülerini işlerken, diyabetik retinopati semptomlarının

daha iyi teşhisini sağlamak için bu kenarlar vurgulamaya çalışılır. Tez kapsamında yapılan ikinci çalışma, Evrişimli Sinir Ağlarının (ESA) gücünü DR'nin sınıflandırma teşhisine kullanılabileceğini gösteren yeni bir strateji önermektedir. DR teşhisinde çok iyi performans gösteren, rezidüel bağlantılara sahip yeni bir ESA mimarisi kullanılmaktadır. Tanılama doğruluğunu iyileştirmek için verilere öncelikle Temel Bileşen Analizi (TBA) uygulanmıştır. Önerilen model, Kenarı-koruyan Kılavuzlu Görüntü Filtrelemeden (K-KGF) yararlanmaktadır. Bir kontrast geliştirme mekanizması olarak çalışmaktadır ve düşük gradyanlı alanları düzeltirmenin yanı sıra güçlü kenarları da vurgulamaktadır. Önerilen model, “RUnet-PCA: Temel Bileşen Analizi ile Rezidüel U-net Derin ESA” olarak adlandırılmıştır. Önerilen modelle karşılaştırma için iyi bilinen AlexNet, VggNet-s, VggNet-16, VggNet-19, GoogleNet ve ResNet modelleri kullanılmıştır. DR teşhis doğruluğunu analizi için Kaggle veri kümesi kullanılmıştır. Deneysel sonuçlar, önerilen RUnet-PCA modelinin %98,44 tanı doğruluğuna ulaştığını ve diğer tanı yöntemlerine kıyasla son derece sağlam ve umut verici olduğunu göstermektedir.



ABSTRACT

SEGMENTATION AND CLASSIFICATION OF RETINA IMAGES USING CONVOLUTIONAL NEURAL NETWORKS

Mali MOHAMMEDHASAN

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

**Advisor: Prof. Dr. Harun UĞUZ
2021, 72 Pages**

**Jury
Prof. Dr. Harun UĞUZ
Prof. Dr. Halife KODAZ
Assoc. Prof. Dr. Hasan Erdiñ KOÇER
Assist. Prof. Dr. Nurdan BAYKAN
Assist. Prof. Dr. Onur İNAN**

Deep learning is one of the most rapidly growing fields in computer and data science in the past few years. It has been widely used for feature extraction and recognition in various applications. Recent advances in deep learning have made a big leap to identify, classify, and quantify patterns in medical images. In that way deep learning is rapidly proving to be the state-of-the-art foundation which achieving enhanced performances in various medical applications. In this thesis, two basic studies were carried out on tissue segmentation and computer-aided disease diagnosis. The first work proposes an incoming Deep Convolutional Neural Network (DCNN) architecture for segmenting retinal blood vessels automatically from fundus images. Automatic segmentation plays a fundamental role in computer-aided diagnosis of retinal diseases. It is of considerable importance in the diagnosis of eye diseases and other systemic diseases that give rise to noticeable pathological symptoms. Retinal blood vessel segmentation is challenging because of the excessive changes in the morphology of the vessels on a noisy background. Previous deep learning-based supervised techniques suffer from the insufficient use of low-level features which is advantageous in semantic segmentation tasks. The proposed architecture takes advantage of both high-level features and low-level features to segment retinal blood vessels. The major contribution of the proposed architecture focuses on two important points. The first, in its introducing of extremely modularized network architecture of aggregated residual connections. The second, is to improve the utilization of computing resources within the network. This is accomplished through a skillfully crafted design which permits for increased depth and width of the network while maintaining the stability of its computational cost. Experimental results prove the effectiveness of using aggregated residual connections in segmenting retinal vessels more accurately and clearly. Compared to the best existing techniques, the proposed method outperformed other existing methods in different considerations. It comprised less false positives at fine vessels, and embraced more clear boundary lines with sufficient details like the experts manual segmentation.

Diabetic Retinopathy (DR) is a disease of the retina, which drives over time to vision problems such retinal detachment, vitreous hemorrhage, glaucoma, and in worse cases leads to blindness, which can initially be avoided by recurrent DR-screening. Early diagnosis will lead to more dominance of the disease, whereas doing retinal examinations on all diabetic patients is a need that cannot be fulfilled. Diabetic retinopathy causes progressive damage to the blood vessels in the retina to the extent that it leaves traces and lesions in the tissues of the retina. These lesions back in the form of edges and when processing retinal images, we aim to accentuate these edges to enable better diagnosis of diabetic retinopathy symptoms. The second work proposes a new strategy that imports the strength of Convolutional Neural Networks (CNNs) to the diagnosis

of DR. A new CNN architecture with residual connections is used, which outperformed in diagnosing DR. Coupled with utilizing Principal Component Analysis (PCA) to improve the diagnostic accuracy. The proposed model exploiting Edge-preserving Guided Image Filtering (E-GIF) that carries out as a contrast enhancement technique, and besides to smoothing low gradient areas, it also protrudes strong edges. The proposed model is named with “RUNet-PCA: Residual U-net Deep CNN with Principal Component Analysis”. The well-known AlexNet, VggNet-s, VggNet-16, VggNet-19, GoogleNet, and ResNet models were adopted for comparison with the proposed model. Publicly available Kaggle dataset was employed for training to exploring the DR diagnosis accuracy. Experimental results prove that the proposed RUNet-PCA model accomplished a diagnosis accuracy of 98.44% and it was extremely robust and promising in comparison to other diagnosis techniques.



ÖNSÖZ

Bu tez çalışmam da yol gösteren, destek ve yardımcı olan danışman hocam Prof. Dr. Harun UĞUZ'a, gerektiğinde yardımlarını esirgemeyen Dr. Öğr. Üyesi Onur İNAN'a ve Dr. Öğr. Üyesi Nurdan (AKHAN) BAYKAN'a;

Eğitim ve öğrenim hayatım boyunca maddi, manevi desteklerini esirgemeyen anneme ve babama ve kardeşlerime teşekkür ederim.

Mali MOHAMMEDHASAN

KONYA – 2021

İÇİNDEKİLER

ÖZET	iii
ABSTRACT.....	v
İÇİNDEKİLER	viii
ŞEKİLLER VE ÇİZELGELER.....	x
KISALTMALAR	xii
SÖZLÜK.....	xiv
1. GİRİŞ.....	1
1.1. Tezin Literatüre Katkısı	4
1.2. Tezin Organizasyonu	7
2. KAYNAK ARAŞTIRMASI.....	8
2.1. Retina Kan Damarı Segmentasyonu ile İlgili Kaynak Araştırmalar	8
2.2. Diyabetik Retinopati Teşhisi ile İlgili Kaynak Araştırmalar	11
3. MATERYAL VE YÖNTEM	14
3.1. Evrişimli Sinir Ağlarının Arka Planı	14
3.1.1. Evrişimli sinir ağlarının katmanları	14
3.2. Kılavuzlu Görüntü Filtreleme (Kenar Korumalı Filtreleme).....	20
3.3. Temel Bileşenler Analizi.....	22
3.4. DRIVE Veri Kümesi Açıklaması.....	24
3.5. Kaggle Veri Kümesi Açıklaması	25
3.6. Veri Arttırma	26
3.7. Platform Yazılımı ve Kütüphaneler	27
4. RETİNA KAN DAMARI SEGMENTASYONU	28
4.1. Önerilen Model	28
4.2. Yöntem.....	33
4.3. Yama Çıkarma	35

5. DİYABETİK RETİNOPATİ TEŞHİSİ	39
5.1. Önerilen Model	39
5.2. Yöntem	43
6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	49
6.1. Retina Kan Damarı Segmentasyonunun Araştırma Sonuçları ve Tartışması	49
6.1.1. Ağ yapılandırması	49
6.1.2. Deneysel çalışma ve sonuçları	50
6.1.3. Diğer yöntemlerle karşılaştırma	56
6.2. Diyabetik Retinopati Teşhisinin Araştırma Sonuçları ve Tartışması	56
6.2.1. Deneysel çalışma ve sonuçları	57
6.2.2. Diğer yöntemlerle karşılaştırma	60
6.2.3. TBA olmadan ve TBA uygulandığında karşılaştırma deneyleri	61
7. SONUÇLAR VE ÖNERİLER	63
KAYNAKLAR	65
ÖZGEÇMİŞ	Error! Bookmark not defined.

ŞEKİLLER VE ÇİZELGELER

Şekiller	Sayfa
Şekil 1.1 Kaggle veri kümesinden örnek bir retina görüntüsü: görüntü numarası (337).....	3
Şekil 3.1 Yapay bir nöron yapısı	14
Şekil 3.2 AlexNet (Krizhevsky ve ark., 2012).....	15
Şekil 3.3 Filtreyi kaydırarak tüm görüntü üzerinde evrişim işleminin uygulanması.....	17
Şekil 3.4 r_{22} çevresindeki piksellere uygulanan W filtresini temsil eden bir nöron	17
Şekil 3.5 Maksimum ve ortalama havuzlama.....	18
Şekil 3.6 Solda standart bir sinir ağıdır, sağda bırakılan (dropout) bir ağıdır	20
Şekil 3.7 KGF uygulamasının örnek bir retina görüntüsü üzerindeki etkisidir	22
Şekil 3.8 Kullanılan Kaggle veri kümesinin sınıf dağılımı	25
Şekil 3.9 Kaggle veri kümesinin örnek retina görüntüleri.....	26
Şekil 4.1 ESA basit bir modelin bazı ara katman çıktılarının görselleştirilmesi	29
Şekil 4.2 (a) Önerilen ESA ağının mimarisi, (b) Önerilen ConvDenseBlock'un mimarisi ..	33
Şekil 4.3 (a-c), Orijinal görüntü ve karşılık gelen önceden işlenmiş görüntüler	34
Şekil 4.4 Giriş yamaları örneği ve buna karşılık gelen groundtruth	37
Şekil 4.5 Yama çıkarma kavramı.....	38
Şekil 5.1 (a-b), Önerilen modelde kullanılan derin ESA ağı ve ConvDenseBlock yapısı ...	41
Şekil 5.2 Diyabetik retinopati teşhisi için önerilen UNet-PCA modeli	43
Şekil 5.3 Önerilen UNet-PCA modelin süreç diyagramı.....	45
Şekil 5.4 DenseUNet eğitim ağının süreç diyagramı.....	46
Şekil 6.1 Zamana karşı kayıp değeri.....	51
Şekil 6.2 İki sınıf sınıflandırma problemi karmaşıklık matrisi.....	51
Şekil 6.3 (a-d), Önerilen mimarinin segmentasyon sonuçları	55
Şekil 6.4 Önerilen UNet-PCA modelinin devire (epoch) karşı kaybı	58
Şekil 6.5 Önerilen UNet-PCA modelinin AOÖ (ROC) eğrisi	60

Çizelgeler	Sayfa
Çizelge 4.1 Ağ mimarisinin parametreleri.....	31
Çizelge 5.1 Önerilen modelin girdi / çıktı katmanlarındaki öznitelik vektörlerinin boyutu.	42
Çizelge 6.1 Veri öznitelikleri.....	49
Çizelge 6.2 Ağ eğitimi yapılandırılmaları.....	49
Çizelge 6.3 Ağ testi yapılandırılmaları	50
Çizelge 6.4 DRIVE veri tabanında önerilen yöntemi kullanan farklı deneylerin sonuçları .	53
Çizelge 6.5 Önerilen yöntemin diğer yeni tekniklere göre performans (DRIVE kullanarak) ...	56
Çizelge 6.6 Kaggle veri kümesinde önerilen RUnet-PCA modelinin tanı sonuçları.....	58
Çizelge 6.7 Kaggle veri tabanında önerilen yöntemi kullanan farklı deneylerin sonuçları..	59
Çizelge 6.8 Önerilen RUnet-PCA modelinin karmaşıklık matrisi	60
Çizelge 6.9 Kaggle veri kümesindeki birkaç derin sinir modelinin sınıflandırma sonucu (Wan ve ark., 2018).....	61
Çizelge 6.10 TBA olmadan ve TBA uygulandığında karşılaştırma sonuçları	62

KISALTMALAR

BN	Batch Normalization.
DNN	Deep Neural Network.
MRI	Magnetic Resonance Imaging.
ReLU	Rectified Linear Unit.
ROC	Receiver Operating Characteristic.
ROI	Region Of Interest.
SVMs	Support Vector Machines.
SGDs	Stochastic Gradient Descents.
ANNs	Artificial Neural Networks.
DNNs	Deep Neural Networks.
MLPs	Multi-Layer Perceptrons.
CNNs	Convolutional Neural Networks.
PCA	Principal Component Analysis.
ResNets	Residual Neural Networks.
FCNs	Fully Convolutional Neural Networks.
FCRNs	Fully Convolutional Regression Networks.
STNs	Spatial Transformer Networks.
RNNs	Recurrent Neural Networks.
LSTM	Long-Short Term Memory.
GRUs	Gated Recurrent Units.
L-RNNs	Layer Recurrent Neural Networks.
DCNs	Deep Comparator Networks.
MR	Magnetic Resonance.
SSFP	Steady State Free Precession.
CLAHE	Contrast Limited Adaptive Histogram Equalization.
FN	False Negative.
FP	False Positive.
TP	True Positive.
TPCNN	Tandem Pulse Coupled Neural Network.

DLBSVM	Deep Learning-Based Support Vector Machine.
DRIVE	Digital Retinal Images for Vessel Extraction
DEDRG	Damar Ekstraksiyonu için Dijital Retinal Görüntüler
FOV	Field of View
KNN	k Nearest Neighbours
BTS-DSN	Bottom-Top and top-bottom Short connections-Deep Supervised Network



SÖZLÜK

Derin öğrenme	Deep learning
Derin Evrişimli Sinir Ağı (DESA)	Deep Convolutional Neural Network (CNN)
Otomatik segmentasyon/bölümleme	Automatic segmentation
Fundus görüntüleri	Fundus images
Retina kan damarları	Retinal blood vessels
Anlamsal/semantik segmentasyon	Semantic segmentation
Artık bağlantılar	Residual connections
Sığ/yüzeysel/derin olmayan model	Shallow model
Özellikler haritalama	Features mapping
Diyabetik Retinopati (DR)	Diabetic Retinopathy (DR)
Temel Bileşen Analizi (TBA)	Principal Component Analysis (PCA)
Kılavuzlu Görüntü Filtreleme (KGF)	Guided Image Filtering (GIF)
Rezidüel/artık/kalan bağlantılar	Residual connections
Denetimli derin öğrenme	Supervised deep learning
Denetimsiz derin öğrenme	Unsupervised deep learning
Kontrast normalleştirme	Contrast normalization
Sıfır fazlı beyazlatma	Zero-phase whitening
Bulanıklık durumu	Blurring situation
Adım adım CNN modeli	Strided-CNN model
Adım adım evrişimli katmanlar	Strided-convolutional layers
Havuzlama katmanları	Pooling layers
Kontrast Sınırlı Uyarlanabilir	Contrast Limited Adaptive
Histogram Eşitleme (KSUHE)	Histogram Equalization (CLAHE)
Tandem Nabız Bağlı Sinir Ağı (TNBSA)	Tandem Pulse Coupled Neural Network (TPCNN)
Derin Öğrenme Tabanlı Destek	Deep Learning-Based Support
Vektör Makinesi (DÖTDVM)	Vector Machine (DLBSVM)
Bırakma	Dropout
Kimlik-tabanlı	Identity-based

Algılayıcı	Perceptron
Maksimum havuzlama	Max pooling
Evrişim katmanları	Convolution layers
Tam bağlantılı (yoğun) katmanlar	Fully connected (dense) layers
Uyum	Overfitting
Yükseltme katmanı	Upscaling layer
Altörnekleme	Downsampling
Yukarı örnekleme	Upsampling
Mekânsal/uzaysal	Spatial
İkili doğrusal/Bilineer	Bilinear
Tam evrişimli ağlarda yoğun katmanlar	Dense layers in fully convolutional networks
Doğrultulmuş doğrusal	Rectified linear
Lineer olmayan/Doğrusal olmayan	Non linear
Sızdıran Doğrultulmuş Doğrusal	Leaky Rectified Linear
Bırakmak	Dropout
Aşırı uyum	Overfitting
Yığın	Batch
Yığın/ Dönüştürme	Batch Normalization
Damar Ekstraksiyonu için	Digital Retinal Images
Dijital Retinal Görüntüler DEDRG	for Vessel Extraction DRIVE
Görüş Alanı (GA)	Field of View (FOV)
Çekirdek	Kernel
Devir/ Dönem	Epochs
kEYK	k-En Yakın Komşuluk
AÜK-DDA	Alt-Üst ve üst-alt Kısa bağlantılar-Derin
	Denetimli Ağ

1. GİRİŞ

Derin öğrenme ağları, zengin hiyerarşik veri temsillerini otomatik bir şekilde öğrenmede güçlü bir beceriye sahip olmasıyla karakterize edilmiştir. Gücü, biyomedikal görüntü bölütlemeye sinir ağının, her bir görüntü pikselin belirli bir sınıfa ait olup olmadığını tahmin etmesindedir.

Segmentasyon, retina kan damarlarının lokalizasyonu kadar diyabetik retinopati, hipertansiyon, glokom, makula dejenerasyonu, mikro anevrizmalar ve arteriyoskleroz gibi oftalmolojik hastalıkların teşhisinde hayati bir rol oynar (Niemeijer ve ark., 2004). Bu hastalıklar tedavi edilmediği durumda körlüğe kadar keskin görme bozukluğuna neden olabilmektedir. Erken teşhis ve uygun tedavi, oftalmologlar tarafından sık sık muayene ile birleştirildiğinde, bunların genişlemesini sınırlandıran anahtar faktörler olduğunu garanti etmektedir. Böylece daha iyi tahmin ile hastanın yaşamının kalitesi artmaktadır. Sedanterizm, obezite ve yaşlanma gibi bu hastalıklarla ilgili çeşitli risk faktörleri yaşam tarzıyla ilişkilidir ve genel popülasyonda tekrarlamaları artmaktadır.

Son yıllarda, otomatik retina kan damarı segmentasyonu, tıp ve sağlık sektöründe geniş bir uygulama aralığı almıştır (Al-Diri ve ark., 2009; Fraz ve ark., 2012a). Retina kan damarları, belirli kardiyovasküler hastalıkların durumunu ve diyabetik retinopatinin ciddiyetini yansıtabilmektedir (You ve ark., 2011). Retina kan damarları bu özellikleri ile güncel tıpta önemli bir işleve sahiptir. Bununla birlikte, kan damarlarının manuel olarak bölümlere ayrılması yorucu, zaman alıcı ve tekrarlayan bir iştir, bu da eğitim ve beceri gerektirmektedir. Bu durum, retina görüntü analizinde oftalmoloji uzmanlarına yardımcı olan bilgisayar destekli bir teşhis sistemi geliştirmek için otomatik yöntemlere olan ihtiyacı vurgulamıştır.

Bu nedenle, tez kapsamında ilk olarak otomatik olarak fundus görüntülerinden retina kan damarlarının segmentasyonu üzerine odaklanılmıştır. Farklı yerel alanlarda retina damarlarının boyut, şekil ve yoğunluk seviyesindeki ani ve beklenmedik büyük farklılıklar nedeniyle retina kan damarlarının segmentasyonunun zor olduğu düşünülmektedir. Ayrıca, bir damarın genişliği hem damar genişliğine hem de görüntünün çözünürlüğüne bağlı olarak genellikle 1 ile 20 piksel arasında olmaktadır ve 1 piksel genişliğindeki mikro damarın tespiti çok karmaşıktır. Gürültülü arka planın ve eğrilerin varlığı nedeniyle daha da zorlu hale gelmektedir.

Retina kan damarı teşhisinde en temel aşama, damarları retina görüntülerinden ayırmaktır. Manuel teşhisin aksine, retina görüntülerinde bilgisayar destekli teşhis, tıbbi yanlış teşhis olasılığını en aza indirebilmektedir. Retina kan damarlarının segmentasyonu olarak bilinen otomatik retina kan damarları teşhisi, bilgisayarla görme anlamsal segmentasyon operasyonunun altında yer almaktadır. Hem denetimli hem de denetimsiz makine öğrenimi teknikleriyle geniş çapta incelenmiştir.


Ricci ve ark. (Ricci ve Perfetti, 2007), görüntünün her pikselinde kan damarlarını keşfeden bir çizgi detektörü tanıtmıştır. Villalobos-Castaldi ve ark. (Villalobos-Castaldi ve ark., 2010), retina görüntülerinin birlikte oluşma matrisinden özellikleri çıkaran ve ardından belirli bir eşiği kullanarak seçilen özellikleri aday gösteren bir yöntem önermiştir. Azzopardi ve ark. (Azzopardi ve ark., 2015), kullanıcı tarafından tanımlanan düz damar ve geçiş noktaları gibi görüntüdeki gerçek desenleri hesaba katarken birlikte doğrusal olarak hizalanmış Gauss filtresini birleştiren bir yöntem sunmuştur. Zhao ve ark. (Zhao ve ark., 2015), hem özellik çıkarımını hem de piksel parlaklığını kapsayan aktif bir kontura dayalı gelişmiş bir yaklaşım önermiştir.

Denetimsiz yöntemler, etiketli verileri talep etmemektedir. Bununla birlikte, bu tür yöntemlerin katkısı gerçek uygulama durumlarında istenilen başarı seviyesinin altındadır ve birçoğu çok zaman alıcı ve yorucudur. Denetimli segmentasyon yöntemleri daha sonra bu kısıtlamaları aşmak için tanıtılmıştır. Bu denetimli yaklaşımların arkasındaki temel fikir, damar piksellerini damar olmayanlardan ayırt etmektir. Bu işlem, açıklamalı görüntülerden çıkarılan özelliklerle önceden eğitilmiş bir ikili sınıflandırıcı kullanılarak yapılmaktadır. Bu yöntemler daha iyi performans elde eder ve denetimsiz yöntemlere kıyasla çok zaman kazandırmaktadır. Fraz ve ark. (Fraz ve ark., 2012b) gradyan vektör alanı, morfolojik dönüşüm, çizgi özelliği ve Gabor yöntemlerini öznelik çıkarıcılar olarak benimsemiş ve daha sonra bunları sınıflandırıcıyı eğitmek için kullanmıştır. Marin ve ark. (Marín ve ark., 2011), özellikleri çıkarmak için gri seviyeli ve 7D özellik vektörlerinden yararlanmış ve ardından bunları sınıflandırıcıyı eğitmek için kullanmıştır.

Diyabetik Retinopati (DR), diabetes mellitus kaynaklı retinada ortaya çıkan bir rahatsızlık durumudur (Klein ve ark., 1984). DR ile yaşayan yaklaşık 93 milyon kişinin olduğu ve dünya çapında yaklaşık 28 milyon DR hastasının bu nedenle görme kaybından muzdarip olduğu tahmin edilmektedir (Yau ve ark., 2012). Arter duvarlarının zayıflığı

damarlar boyunca kabarcıklara, tıkanmalara ve sızıntılara neden olmaktadır (Hiller ve ark., 1988). Hastalık semptomlarını ciddi şekilde yayılmadan önce kontrol etmek için retinal vasküler kan akışını izlemek çok önemlidir. Buna göre retina analizi ile toplanan bilgiler diyabetin aktivitesini gösterir. Amerika Birleşik Devletleri'nde yapılan kapsamlı bir analizin bulgularına göre, DR'nin varlığı %34 ile %89 arasında bir ölüm riskini beraberinde getirmektedir (Klein ve ark., 1994; 1999).

Gözün fundusundaki diyabetik retinopatinin semptomları arasında mikro anevrizma (MA), mikro kanama (MK), sert eksüda (SE), yumuşak eksüda (YE) ve neo-vaskülerizasyon yer almaktadır (Venkatesh ve ark., 2015). Birkaç araştırma, otomatik tespit sistemleri kullanarak bu semptomların tespiti üzerinde yoğunlaşmıştır (Larsen ve ark., 2003; Marupally ve ark., 2017; Srivastava ve ark., 2017). Eksüdalar, diyabetik retinopatinin, diyabetli kişilerde arterlerden ve damarlardan sızan yüksek miktarda lipoprotein nedeniyle ilk aşamasıdır. Bu semptomlar çoğunlukla görme kaybı ile ilişkili olduğu için erken teşhis önemlidir (Kusakunniran ve ark., 2018). DR'nin ilk aşamalarında bu tür semptomların tespiti ile ilgili literatürde son zamanlarda daha fazla makale sunulmuştur (Marupally ve ark., 2017; Naqvi ve ark., 2017; Kusakunniran ve ark., 2018; Çınar ve Yıldırım, 2020). Normal ve anormal bir retina örneği Şekil 1.1'de gösterilmektedir. Şekil 1.1.a'a temiz retina görüntüsünü gösterirken Şekil 1.1.b'de DR ile enfekte olmuş retina görüntüsünü göstermektedir.



Şekil 1.1 Kaggle veri kümesinden örnek bir retina görüntüsü: görüntü numarası (337)

Şekil 1.1'de gösterildiği gibi, normal retina ve anormal retina arasındaki farklar, burada sarı eksüda ve kanama not edilebilmektedir. Bu çalışmanın temel amacı, DR otomatik teşhis sistemlerinin verimliliğini artırmaktır. Retina görüntülerini sınıflandırmada

derin evrişimli sinir ağlarının rolünü yararlanan yeni bir erken evre diyabetik retinopati tanı mekanizması önermektedir.

Makine öğrenmesinde, gradyan tabanlı öğrenme yöntemleri ve geri yayılım ile yapay sinir ağları eğitilirken kaybolan gradyan problemi ile karşılaşmaktadır. Bu genellikle derin öğrenme sistemi gibi birkaç nöronal katmana sahip sinir ağlarında meydana gelmektedir. Bu tür yöntemlerde, sinir ağının ağırlıklarının her biri, her eğitim yinelenmesinde mevcut ağırlığa göre hata fonksiyonunun kısmi türeviyle orantılı bir güncelleme almaktadır. Bazı durumlarda gradyan yok denecek kadar küçük olacak ve ağırlığın değerini değiştirmesini etkili bir şekilde önleyecektir. En kötü durumda, bu sinir ağının daha fazla eğitim almasını tamamen durdurabilir. Gradyanlar, eğitim sırasında ağırlık ne kadar öğreneceğini kontrol ettiğinden, gradyanlar çok küçük veya sıfırsa, eğitim çok az veya hiç gerçekleşemez ve bu da zayıf tahmin performansına yol açmaktadır.

İkinci çalışmanın ana katkısı, diyabetik retinopati tespiti için yeni bir evrişimli sinir ağları tabanlı mimari getirmesidir. Bu mimari, katmanlar arasında bilgi aktarımı için rezidüel bağlantıların kullanılmasının da dahil olduğu iyi bilinen U-ağ mimarisinden esinlenmiştir. Rezidüel bağlantıların kullanılması, diğer geleneksel yöntemlere göre daha üstün bir performans göstermiştir.

Ayrıca, Temel Bileşen Analizi (TBA), teşhis doğruluğunu iyileştirmek için kullanılmaktadır (Polat ve Günes, 2007; Shilaskar ve Ghatol, 2013; Velliangiri ve ark., 2019). Kılavuzlu Görüntü Filtrelemesinin (KGF) yanı sıra, retina görüntülerinde bir kontrast iyileştirme gerçekleştirmek için kullanılmaktadır. Yalnızca düşük gradyanları düzleştirmekle kalmaz, aynı zamanda düz kenarları da korumaktadır. KGF, diyabetik retinopati semptomlarının daha iyi teşhisini sağlamak için retinanın kenarlarını (dokulardaki izler ve lezyonlar) vurgulamaktadır. Son olarak, önerilen modelin performansını da veri artırma tekniği sağlamıştır.

1.1.Tezin Literatüre Katkısı

Derin öğrenmedeki son gelişmeler, tıbbi görüntülerdeki kalıpları tanımlamak, sınıflandırmak ve ölçmek için büyük bir adım atmıştır. Bu şekilde, derin öğrenme, çeşitli tıbbi uygulamalarda gelişmiş performanslar elde eden son teknoloji bir temel olduğunu

hızla kanıtlamaktadır. Otomatik segmentasyon, retina hastalıklarının bilgisayar destekli teşhisinde temel bir rol oynamaktadır. Göz hastalıklarının ve belirgin patolojik semptomlara yol açan diğer sistemik hastalıkların tanısında oldukça önemlidir.

Bu tez kapsamında, ilk çalışma, retina kan damarlarını fundus görüntülerinden otomatik olarak bölümlere ayırmak için yeni bir Derin Evrişimli Sinir Ağı (DESA) mimarisi önermektedir. Retina kan damarı teşhisinde en temel aşama, damarları retina görüntülerinden ayırmaktır. Manuel teşhisin aksine, retina görüntülerinde bilgisayar destekli teşhis, tıbbi yanlış teşhis olasılığını en aza indirebilmektedir. Retina kan damarlarının segmentasyonu olarak bilinen otomatik retina kan damarları teşhisi, bilgisayarla görme anlamsal segmentasyon alanında yer almaktadır. Retina kan damarı segmentasyonu, gürültülü bir arka planda damarların morfolojisindeki aşırı değişiklikler nedeniyle zordur. Farklı yerel alanlarda retina damarlarının boyut, şekil ve yoğunluk seviyesindeki ani ve beklenmedik büyük farklılıklar nedeniyle retina kan damarlarının segmentasyonunun zor olduğu düşünülmektedir. Ayrıca, bir damarın genişliği hem damar genişliğine hem de görüntünün çözünürlüğüne bağlı olarak genellikle 1 ile 20 piksel arasında uzanır ve 1 piksel genişliğindeki mikro damarın tespiti çok karmaşıktır. Gürültülü arka planın ve dolambaçlılığın varlığı nedeniyle daha da zorlu hale gelmektedir. Karşılaştırılabilir yoğunluk seviyesine sahip diğer yapılar, segmentasyon işlemini karıştırabilir ve çizgili kanama gibi daha karmaşık hale getirebilmektedir.

Önceki derin öğrenme tabanlı denetimli yöntemler, anlamsal segmentasyon görevlerinde avantajlı olan düşük seviyeli özelliklerin yetersiz kullanımından muzdariptir. Önerilen mimari, retina kan damarlarını segmentlere ayırmak için hem yüksek seviyeli özellikleri hem de düşük seviyeli özellikleri kullanılmaktadır. Özellikler, düşük seviyeli özelliklerden yüksek seviyeli özelliklere kadar bir hiyerarşi içinde düzenlenebilmektedir. Düşük seviyeli özellikler, kenarları ve blokları içerirken, yüksek seviyeli özellikler, nesneleri ve olayları içermektedir. Düşük seviyeli özellikler, görüntünün kıvrımlı bir filtre tarafından alınabilen çizgiler veya noktalar gibi küçük ayrıntıdır (kenarlar gibi daha soyut şeyler için). Görüntüdeki nesneleri ve daha büyük şekilleri algılamak için yüksek seviyeli özellikler, düşük seviyeli özelliklerin üzerine inşa edilmiştir.

Önerilen mimarinin literatürdeki ana katkısı iki önemli faktöre odaklanmaktadır. Birincisi, kümelenmiş rezidüel bağlantılardan oluşan son derece modülerleştirilmiş ağ

mimarisi sağlamasıdır. Bu nedenle, önerilen mimari, retina kan damarlarını segmentlere ayırmak için hem yüksek seviyeli özellikleri hem de düşük seviyeli özellikleri kullanılmaktadır. İkincisi, ağ içindeki bilgi işlem kaynaklarının kullanımını iyileştirmektir. Bu, hesaplama maliyetinin istikrarını korurken ağın derinliğini ve genişliğini artırmaya izin veren ustaca hazırlanmış bir tasarımla elde edilmektedir. Deneysel sonuçlar, retina damarlarını daha doğru ve net bir şekilde bölümlere ayırmada kümelenmiş rezidüel bağlantıların kullanılmasının etkinliğini göstermektedir. Mevcut en iyi yöntemlerle karşılaştırıldığında, önerilen yöntem, farklı ölçümlerde diğer mevcut yöntemlerden daha iyi performans göstermiştir, ince damarlarda daha az yanlış pozitif içermiştir ve uzmanların manuel segmentasyonu gibi yeterli ayrıntılarla daha net sınır çizgileri içermiştir.

Diyabetik Retinopati (DR), zamanla retina dekolmanı, vitreus kanaması, glokom gibi görme sorunlarına yol açan ve daha kötü durumlarda başlangıçta periyodik DR taraması ile kontrol edilebilen körlüğe yol açan bir retina hastalığıdır. Erken teşhis, hastalığın daha fazla kontrolüne yol açacaktır, oysa tüm diyabetik hastalarda retina muayenelerinin yapılması ulaşılamaz bir ihtiyaçtır. Bu tezin ikinci çalışması, Evrişimli Sinir Ağlarının (ESA) gücünü DR'nin teşhisine getiren yeni bir strateji önermektedir. Tanılama doğruluğunu iyileştirmek için Temel Bileşen Analizi (TBA) kullanılmıştır. TBA verimli özellikleri nedeniyle, yüksek boyutlu verilerdeki modelleri belirleyebilmektedir ve tüm verilerde mümkün olduğunca çok bilgiyi koruyan bir özellik alt kümesinin seçilmesine hizmet edebilmektedir. Başka bir deyişle, TBA, yüksek bir varyansı yakalayarak özelliklerin en değerli bilgilerini depolayan yeni bileşenler oluşturmaktadır. Önerilen model, Kenarı-koruyan Kılavuzlu Görüntü Filtrelemeden (K-KGF) yararlanmaktadır. Bir kontrast geliştirme mekanizması olarak çalışmaktadır ve düşük gradyanlı alanları düzleştirmenin yanı sıra güçlü kenarları da vurgulamaktadır. Diyabetik retinopati, retina dokularında iz ve lezyonlar bırakacak ölçüde retinadaki kan damarlarında ilerleyici hasara neden olmaktadır. Bu lezyonlar kenarlar şeklinde görünür ve retina görüntülerini işlerken, diyabetik retinopati semptomlarının daha iyi teşhisini sağlamak için bu kenarlar vurgulamaya çalışılır. DR teşhisinde çok iyi performans gösteren, rezidüel bağlantılara sahip yeni bir ESA mimarisi kullanılmaktadır. Önerilen model, "RUnet-PCA: Temel Bileşen Analizi ile Rezidüel U-net Derin ESA" ile adlandırılmıştır. Önerilen modelle karşılaştırma için iyi bilinen AlexNet, VggNet-s, VggNet-16, VggNet-19, GoogleNet ve

ResNet modelleri benimsenmiştir. DR teşhis doğruluğunu keşfetme eğitimi için halka açık Kaggle veri kümesi kullanılmıştır.

İkinci çalışmanın literatürdeki ana katkısı, diyabetik retinopati tespiti için yeni bir evrişimli sinir ağları tabanlı mimari getirmesidir. Bu mimari, katmanlar arasında bilgi aktarımı için rezidüel bağlantıların kullanılmasının da dahil olduğu iyi bilinen U-ağ mimarisinden esinlenmiştir. Rezidüel bağlantıların kullanılması, diğer geleneksel yöntemlere göre daha üstün bir performans göstermiştir. Ayrıca, Temel Bileşen Analizi (TBA), teşhis doğruluğunu iyileştirmek için kullanılmaktadır. Kılavuzlu Görüntü Filtrelemesinin (KGF) yanı sıra, retina görüntülerinde bir kontrast iyileştirme gerçekleştirmek için kullanılmaktadır. Yalnızca düşük gradyanları düzleştirmekle kalmamaktadır, aynı zamanda düz kenarları da korumaktadır. KGF, diyabetik retinopati semptomlarının daha iyi teşhisini sağlamak için retinanın kenarlarını (dokulardaki izler ve lezyonlar) vurgulamaktadır.

1.2.Tezin Organizasyonu

Yapılan tez çalışması altı başlıkta ele alınmıştır. İlk başlık olarak derin öğrenme ağları, derin öğrenme nedir, amaçları nelerdir, evrişimli sinir ağları hakkında genel bilgiler verilmiştir. İkinci bölümde konvolüsyonel sinir ağlarının retina görüntü segmentasyonunda ve diyabetik retinopati teşhisinde kullanımı ile ilgili literatür taramalarına yer verilmiştir. Üçüncü bölümde ise tez çalışmasında kullanılan materyal ve metotlar hakkında bilgiler verilmiş, kullanılan yazılım ve yöntemlere değinilmiştir. Dördüncü bölümde ESA kullanılarak retina görüntü segmentasyonu üzerine yapılan çalışmalar ele alınmıştır. Beşinci bölümde diyabetik retinopati teşhisinde evrişimli sinir ağlarının kullanımı anlatılmış, nasıl uygulandığı hakkında bilgiler verilmiştir. Elde edilen sonuçlar incelenip, karşılaştırmalar yapılmıştır. Altıncı bölümde elde edilen sonuçlar incelenmiştir.

2. KAYNAK ARAŞTIRMASI

2.1. Retina Kan Damarı Segmentasyonu ile İlgili Kaynak Araştırmalar

Derin sinir ağlarının güncel kapsamlı araştırmaları, retina kan damarı segmentasyonunda denetimli derin öğrenme yöntemlerini kullanmanın başarısına doğru yol göstermektedir. Ronneberger ve ark. (Ronneberger ve ark., 2015), orijinal tıbbi görüntülerden özellikleri çıkarmak için ilk olarak Evrişimli Sinir Ağları (ESA) kullanan ve ardından bu özellikleri görüntü segmentasyon işleminde kullanan bir U-net'i tanıtmıştır. Li ve ark. (Li ve ark., 2016), beş katmanlı bir sinir ağını eğitmek için yamalar ve kayan bir pencere içeren tam bir evrişimli sinir ağı önermiştir. Liskowski ve ark. (Liskowski ve Krawiec, 2016) küresel kontrast normalleştirme, sıfır faz beyazlatma kullandı ve derin sinir ağlarını eğitmek için özellik vektörleri elde etmek için geometrik dönüşümler ve gama düzenlemeleri kullanarak arttırılmıştır. Ayrıca daha iyi sonuçlar elde etmek için yapı tahmin mimarisini benimsemişlerdir.

Rahim ve ark. (Rahim ve ark., 2019), renkli göz fundus görüntülerinde diyabetik retinopati ve makülopatinin tespitini bütünleştiren yeni bir yaklaşım önermiştir. Bu yaklaşım, veri artırmayı kullanan derin öğrenme tekniği ile birlikte verimli görüntü ön işleme tekniklerini araştırmaktadır. Yeni yaklaşım, Malezya Melaka Hastanesi Oftalmoloji Departmanı Göz Kliniği tarafından toplanan yeni geliştirilmiş bir veri setinde doğrulanmıştır. Bu veri kümesinde, JPEG formatında saklanan 3872×2592 piksel boyutunda toplam 600 renkli fundus görüntüsü vardır. Önerilen yaklaşımda, sınıflandırma sürecini kolaylaştırmak için giriş retina görüntüleri ilk olarak ön işlemde geçirilir ve orijinal 3872×2592 pikselden 242×162 piksele küçültülmektedir. Daha sonra, önceden işlenmiş görüntüler, giriş görüntülerini karşılık gelen sınıflara göre sınıflandırmak için tasarlanmış bir Derin Evrişimli Sinir Ağına (DESA) beslenmektedir. Bu DESA modeli, değişen seviyelerde retinopati ve makulopati ile yeniden boyutlandırılan retina görüntüleri kullanılarak eğitilmiştir. Eğitimde, eğitim veri setinin sayısını artırmak için veri artırma tekniği uygulanmıştır. Deneysel sonuçlar, veri artırma için görüntü ön işlemenin kullanılmasının sınıflandırma performansının iyileştirilmesine yardımcı olduğunu göstermiştir.

Jin ve ark. (Jin ve ark., 2019), Deforme olabilen U-Net (DUNet) adlı tam evrişimli bir sinir ağı önermiştir. Derin sinir ağlarının damarları uçtan uca ve pikselden piksele bölme yeteneğini geliştirmek için retina damarlarının yerel özelliklerini kullanmaktadır. U-Net mimarisinden (Lupascu ve ark., 2010) ve yakın zamanda tanıtılan deforme olabilen evrişimli ağdan (Deformable-ConvNet) esinlenmiştir. DUNet, deforme olabilen evrişim ünitesi ve U-Net mimarisinin avantajlarını entegre etmek için tasarlanmıştır (Dai ve ark., 2017). Bazı evrişimli katmanların deforme olabilen evrişim blokları ile değiştirildiği U-Net'in bir uzantısı olarak düşünülebilmektedir. Simetrik U-şekilli mimari ile (Lupascu ve ark., 2010) DUNet, kodlayıcı tarafından bağlamı ayıklayacak ve kod çözücü tarafından hassas yerelleştirmeyi sağlayacak şekilde biçimlendirilmiştir. Bu işlem, düşük seviyeli özellik haritalarını yüksek seviyeli olanlarla birleştirerek elde edilmektedir. Deforme olabilen evrişim blokları sayesinde DUNet, retina kan damarlarını çeşitli şekil ve ölçeklerde yakalayabilmektedir. Alıcı alanları kan damarların ölçeklerine ve şekillerine göre uyarlayarak deforme olabilen evrişim blokları sayesinde DUNet, damarların ölçek ve şekillerine bağlı olarak alıcı alanları uyarlayarak retina kan damarlarını çeşitli şekil ve ölçeklerde yakalayabilir. Standart evrişimin normal örnekleme ızgaralarına ofsetler ekleyerek alıcı alanlar deforme olabilir ve artırılmaktadır. Bu da performansı artırır ve eğitim parametrelerini de azaltmaktadır. Ağı doğrulamak için DRIVE, STARE, CHASE DB1 ve HRF gibi halka açık veri kümeleri kullanılmaktadır. Deneysel sonuçlar, DUNet'in retina damar segmentasyonu için genel bir yüksek performanslı hesaplama çerçevesine sahip olduğunu göstermiştir (Lupascu ve ark., 2010).

Guo ve ark. (Guo ve ark., 2019), Alt-Üst ve üst-alt Kısa bağlantılar-Derin Denetimli Ağ (AÜK-DDA) adı verilen, derin denetimli, tam evrişimli bir sinir ağı sunmuştur. Retina kan damarı segmentasyonu için alt-üst ve üst-alt kısa bağlantıları kullanmaktadır. Kısa bağlantılar, yan dış katmanlar arasında anlamsal bilgileri yönlendirmek için kullanılmaktadır. Alt-üst kısa bağlantılar, düşük seviyeli ince anlamsal bilgilerin yüksek seviyelere yönlendirilmesinden sorumludur. Bu, bulanıklık durumunu hafifletmek ve sonuçları yüksek seviyeli yan dış katmanlarda iyileştirmek içindir. Üst-alt kısa bağlantı, yapısal bilgilerin düşük seviyeye yönlendirilmesinden sorumludur. Bu, düşük seviyeli yan dış katmanlarda gürültüyü azaltmayı amaçlamaktadır. Alt-üst kısa bağlantılar, yüksek seviyeli yan çıkışlarda sonuçları iyileştirmek için düşük seviyeli semantik bilgiyi yüksek

seviyeye iletir. Üst-alt kısa bağlantı, düşük seviyeli yan çıkışlardaki gürültüleri azaltmak için çok yapısal bilgiyi düşük seviyeye iletmektedir (Guo ve ark., 2019).

Önerilen AÜK-DDA ağı, DRIVE, STARE ve CHASE DB1 veri kümelerinde test edilmiştir. Sonuçlar, damar segmentasyon görevlerinde diğer yeni tekniklere göre daha yüksek bir performans elde ettiğini göstermektedir.

Soomro ve ark. (Soomro ve ark., 2019), retina kan damarlarının, özellikle de küçük damarların doğru segmentasyonu için adım adım bir ESA modeli sunmuştur. Model, maksimum havuzlama katmanlarının adım adım evrimsel katmanlarla değiştirilmesinin farkı ile derin bir kodlayıcı-kod çözücüden oluşan tamamen bir ESA'dır. Bu katmanlar eğitilebilir ve daha iyi damar segmentasyonu için daha fazla özellik çıkarılmasına yardımcı olmaktadır. Ön işleme adımları, morfolojik eşleştirmelere ve daha iyi eğitim için arka planlarına karşı tek tip bir retina kan damarı seviyesi oluşturmak için Temel Bileşen Analizi (TBA) tekniklerini kullanmaktadır. Rezidüel bağlantıları, kodlayıcıdan ve kod çözücü parçalarından özellik haritalarını birleştirmek için sunulmaktadır. Rezidüel bağlantıları, damar segmentasyonunu iyileştirmek ve damarların daha keskin kenarlarını oluşturmak için faydalıdır. Sınıf dengeleme kaybı işlevi, ağı piksel dengesi sorunuyla ilgilenmesi ve damar görüntü kalitesini iyileştirmesi için eğitmek için kullanılmaktadır. Ağın performansı, DRIVE, STARE, CHASE-DB1 ve HRF gibi farklı veri kümelerinde test edilmiştir. Genel ağ performansı, önceki tüm diğer yöntemlerden daha iyi performans göstermektedir.

Jebaseeli ve ark. (Jebaseeli ve ark., 2019), giriş görüntüsünden arka planı ortadan kaldırmak ve ön plandaki kan damarı piksellerini artırmak için Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (KSUHE) kullanan bir çerçeve önermiştir. Tandem Nabız Bağlı Sinir Ağı (TNBSA), özellik haritalarının otomatik olarak oluşturulması için kullanılmaktadır. Kan damarlarını fundus görüntülerinden çıkarır ve tüm küçük damarları çapraz sınırlarında göstermektedir. Bu küçük damarlar depigmentasyonla bastırılmaktadır. Derin Öğrenme Tabanlı Destek Vektör Makinesi (DÖTDVM), kan damarlarının çıkarılması ve sınıflandırılması için tanıtılmıştır. DÖTDVM, damar piksellerini damar olmayan piksellerden kategorize ederken sınıflandırma doğruluğunu geliştirmektedir. STARE, DRIVE, HRF, REVIEW ve DRIONS fundus görüntü veri kümeleri, önerilen modeli değerlendirmek için tasarlanmıştır. Sonuçlar, önerilen yöntemin, retina kan

damarlarının segmentli yapısını dikkate alarak, Diyabetik Retinopati tanısında göz doktorlarına yardımcı olduğunu ortaya koymaktadır.

2.2.Diyabetik Retinopati Teşhisi ile İlgili Kaynak Araştırmalar

Popüler ESA, AlexNet'in derin öğrenme tekniklerini büyük işlevsel uygulamalara itmesinden sonra araştırma odağı etkili ESA mimarilerinin geliştirilmesine kaydırılmıştır (Krizhevsky ve ark., 2012). Derinlik, ağ verimliliği ile ilgili ana husustur. ResNet (He ve ark., 2016), daha derin evrişimli sinir ağlarını ortaya çıkaran özellik atlama bağlantıları içermektedir. DenseNet (Huang ve ark., 2017) ve DPN (Chen ve ark., 2017), derin sinir ağı öğrenimini ve temsil işlevlerini geliştirmek için katmandan katmana iletişim süreci değişikliklerini kullanmaktadır. Veit, ResNet benzeri ağların oldukça sıkı ağ grupları gibi davrandığına inanmaktadır. Ayrıca, verimliliklerindeki gelişmeler daha derin ağ mimarisinden değil, model kombinasyonlarından kaynaklanmaktadır (Veit ve ark., 2016). Bu bakış açısına dayanarak, Highway ve Inception (Ioffe ve Szegedy, 2015; Srivastava ve ark., 2015) mimarileri, ağı derinliğini genişleterek alt ağların sayısını artırmaktadır.

AlexNet, mekansal tabanlı bir ESA mimarisidir. Mekansal sömürü, evrişimli işlemin giriş piksellerinin komşuluğunu (korelasyonunu) dikkate aldığı anlamına gelmektedir. Bu nedenle, farklı filtre boyutları kullanılarak farklı korelasyon seviyeleri araştırılabilmektedir. AlexNet ile ilgili en güçlü yönler, ilk (5x5 ve 11x11) katmanlar ve son (3x3) katmanlar üzerinde büyük ve küçük boyutlu filtreler kullanarak düşük, orta ve yüksek seviyeli özelliklerin çıkarılmasıdır. Ayrıca, derin ve geniş ESA mimarileri hakkında fikir vermeyi, ESA'larda düzenlileştirme kavramını tanıtmayı ve karmaşık mimarilerde hızlandırıcı olarak GPU'ların paralel kullanımını başlatmayı da içermektedir. Diğer yandan, AlexNet ile ilişkili en büyük sorun, birinci ve ikinci katmanlardaki inaktif nöronlardır (Krizhevsky ve ark., 2012).

ResNet, DenseNet ve Highway Networks, çok yollu tabanlı bir ESA mimarisidir. Çoklu yol, kısayol yollarının bazı katmanları atlama seçeneği sağladığı anlamına gelmektedir. Literatürde kullanılan kısayol bağlantılarının farklı türleri sıfır dolgulu projeksiyon, bırakma (dropout), ve 1x1 bağlantılar vb. gibidir.

ResNet ile ilişkili en güçlü yönler, katmanlar arası bağlantıyı sağlamak için kimlik tabanlı atlama bağlantılarının kullanılmasıdır. Ayrıca, bilgi akış kapıları veriden bağımsızdır ve parametresizdir ve sinyali her iki yönde de ileri ve geri kolayca iletebilmektedir. Diğer taraftan, ResNet ile ilgili en büyük sorun, birçok katmanın çok az bilgi katkısında bulunabilmesidir veya hiç bilgi vermemesidir. Ayrıca gereksiz özellik haritalarının yeniden öğrenilmesi de gerçekleştirilmektedir (He ve ark., 2016).

DenseNet ile ilişkili başlıca güçlü yönler şunlardır: derinlik veya çapraz katman boyutunun tanıtılması, ağdaki katmanlar arasında maksimum veri akışının sağlanması, gereksiz özellik haritalarının yeniden öğrenilmesinden kaçınılması ve hem düşük hem de yüksek seviyeli özelliklerin karar katmanları tarafından erişilebilir olmasıdır. Diğer taraftan, DenseNet ile ilgili en büyük sorun, her katmandaki özellik haritalarının sayısındaki artıştan dolayı parametrelerdeki büyük artıştır (Huang ve ark., 2017).

Highway Ağları ile ilişkili en güçlü yönler, katmanlar arası bağlantı sunarak derin ağların sınırlamalarını azaltmaktır. Highway Ağları ile ilgili en büyük sorun, kapıların verilere bağlı olması ve bu nedenle parametrelere maliyet getirebilmesidir (Ioffe ve Szegedy, 2015; Srivastava ve ark., 2015).

Daha önce, doğruluğu artırmak için katman sayısının artırılması gerektiği varsayılıyordu. Bununla birlikte, katman sayısını artırarak, kaybolan gradyan sorunu ortaya çıkar ve eğitim yavaşlayabilmektedir. Böylece, bir katmanı genişletme kavramı da araştırılmıştır. Inception, genişliğe dayalı bir ESA mimarisidir ve temel güçlü yönleri şunlardır: Inception modülünün içindeki değişen boyuttaki filtrelerin ara katmanların çıktısını artırdığını ve değişen boyuttaki filtreler, yüksek detaylı görüntülerde çeşitliliği yakalamak için faydalıdır. Diğer taraftan, Inception ile ilgili en büyük sorun, uzay ve zaman karmaşıklığındaki artıştır.

Derin füzyon ağı (Zhao ve ark., 2018) aynı zamanda, topluluğun tüm bölümlerindeki en derin ağı, temel performansı artırmada merkezi bir rol oynamadığını da göstermektedir. Ancak bunun yerine topluluk ölçeğini sağlamak için daha fazla katman eklemektedir. Zhao, iki ağı birleştirme/çalıştırma füzyon tekniğiyle bütünleştiren yeni bir derin kaynaşmış ağ biçimi sunmaktadır (Zhao ve ark., 2018). ResNet'ten daha doğrudur ancak daha az sayıda katmana ve eşit sayıda parametreye sahiptir. ResNeXt (Xie ve ark., 2017), ResNet rezidüel blok stratejilerini tamamen Inception ağına içermektedir. Bunun

yanı sıra, bölünmüş dönüştürme-birleştirme tekniğini de içermektedir. Bu tür homojen çok dallı ağ, daha düşük sayıda hiperparametreye sahiptir. Ayrıca boyutu yükseltmek için yalnızca "kardinalite" adı verilen kümelenmiş bir evrişim tekniğini içerdiğinden daha küçük kapasitelere sahiptir. Deney bulguları, kardinaliteyi yükseltmenin ağ verimliliğini derinleştirmek veya genişletmekten daha verimli bir yöntem olduğunu göstermektedir. Kanallar arası korelasyonlar, özneliklerin bir bileşimini oluşturmak için çizilmektedir. Bu durum, mekânsal yapıdan (Chollet, 2017) bağımsız olarak veya 1×1 evrişim işlemlerine kısayol olan düzenli evrişimli filtrelerle gerçekleştirilmektedir (Lin ve ark., 2014).


Çoğu araştırma, hesaplama maliyetlerini en aza indirmeyi ve eğitim zorluklarını basitleştirmeyi amaçlasa da bu tür araştırmalar bir kanal korelasyonuna odaklanmıştır. Kanallar arası ilişki için örnek-agnostik özelliklerin ve yerel alıcı alanların bir kombinasyonu olarak eşlenebilmektedir. Diğer yandan, Hu ve ark. (Hu ve ark., 2018), küresel veri kaynaklarını kullanan kanalların karmaşık ve doğrusal olmayan etkileşimlerine odaklanmaktadır. Bu tür mimari tasarım, öğrenme ve temsil yeteneklerini desteklemek ve geliştirmek için diğer iyi bilinen ağlarla birleştirilebilmektedir. PolyNet (Zhang ve ark., 2017), rezidüel inceptions'ın geliştirilmesi için farklı polinom kombinasyonları kullanan ağ tasarımının alternatif bir yönü olan yapısal çeşitliliği tartışmaktadır.

3. MATERYAL VE YÖNTEM

3.1. Evrişimli Sinir Ağlarının Arka Planı

Yapay sinir ağları, biyolojik sinir ağlarından esinlenmiştir. Benzer şekilde, evrişimli sinir ağları da hayvanların görsel sisteminden ilham almaktadır. Yapay bir sinir ağı, adından da anlaşılacağı gibi, aralarında bağlantılar bulunan yapay nöron birimlerinden oluşan bir ağıdır. Şekil 3.1’de yapay bir nöron yapısı gösterilmiştir. Denklem 3.1’de yapay sinir ağının aktivasyon değerini gösterilmiştir.

$$a = \sum_{j=1}^N u_j w_j + \theta \quad (3.1)$$




Şekil 3.1 Yapay bir nöron yapısı

Eğer $f(a)$ (aktivasyon fonksiyonu) bir eşik fonksiyonuysa, bu nörona bir perceptron (algılayıcı) denmektedir.

3.1.1. Evrişimli sinir ağlarının katmanları

ESA, optimizasyon yöntemleri, kayıp fonksiyonları vb. gibi sinir ağlarının bazı genel özelliklerini paylaşmaktadır. Bu bölüm ESA’nın genel olmayan özelliklerine odaklanmaktadır. Son teknoloji bir görüntü sınıflandırma ağı olan AlexNet (Krizhevsky ve ark., 2012). Evrişim katmanları, havuz katmanları ve tam bağlantı katmanları ile Şekil 3.2’de gösterilmiştir. Bir sınıflandırma ağı olduğundan, yukarı örnekleme katmanlarına sahip değildir. Ayrıca, segmentasyon durumunda sondaki tam bağlı (yoğun) katmanlar 1x1

evrişimli katmanlar haline gelmektedir. Daha fazla ayrıntı Bölüm 1.3.1.1.4'te verilmiştir. Şekil 3.2'de AlexNet yapısı gösterilmiştir.



Şekil 3.2 AlexNet (Krizhevsky ve ark., 2012)

Her kutu, evrişimlerle elde edilen özelliklere karşılık gelmektedir. Kesikli çizgiler evrişim katmanlarını göstermektedir. Sonunda, düz çizgilerle gösterilen tam bağlantılı (yoğun) 3 katman vardır.

3.1.1.1.Evrişim katmanları

Evrişimli sinir ağlarında, mimariye de adını veren, en önemli katman türü evrişim katmanlarıdır. Evrişim katmanı aslında özel bir ileri-beslemeli ağ katmanına karşılık gelmektedir. Her piksel p_{ij} 'in bir u_j girişine karşılık geldiği ve evrişim filtresinin her w_{ij} değeri, bir w_j ağırlığına karşılık gelmektedir. 3×3 filtre boyutu ve $d \times n$ giriş boyutu varsayıldığında, $(d \times 2) \times (n \times 2)$ sayıda çıkışa sahip $(d \times 2) \times (n \times 2)$ nöron vardır (Bora, 2018). $(d \times 2) \times (n \times 2)$ sayıda farklı ağırlık matrisine sahip olan geleneksel bir ağın aksine, bir evrişim katmanındaki tüm nöronlar arasında paylaşılan yalnızca bir ağırlık matrisi vardır. Bu, evrişimli bir sinir ağının en önemli özelliğidir. Paylaşılan ağırlıkları mümkün kılan şey, özelliklerin mekânsal konumlara göre değişmemesidir. Transfer fonksiyonu Denklem 3.2'de, bir ESA'daki bir evrişime karşılık gelmektedir. Denklem 3.3'te, 3×3 ağırlık matrisli basit bir 2D evrişim formüle edilmiştir (Bu denklem, Denklem 3.2'deki genel 2D ayırık evrişim formülünün aksine filtrenin simetrik değerini

almamaktadır). Temel olarak, bir evrişim filtresi, Şekil 3.4'de verilen yapay bir nöron olarak adlandırılabilir. Bu işlem, **Error! Reference source not found.**'de gösterildiği gibi filtre kaydırılarak bütün görüntüye uygulanmaktadır.

$$C_{ij} = \sum_{k=-1}^1 \sum_{l=-1}^1 A_{(i-k)(j-l)} B_{(k)(l)} \quad (3.2)$$

burada $1 < i < D$ ve $1 < j < N$ ve matris A 'nın boyutları $D \times N$ 'dir.

$$P = \begin{bmatrix} p_{11} & p_{12} & p_{13} & \dots & p_{1n} \\ p_{21} & p_{22} & p_{23} & \dots & p_{2n} \\ \dots & \dots & \dots & \dots & \dots \\ p_{d1} & p_{d2} & p_{d3} & \dots & p_{dn} \end{bmatrix} \quad W = \begin{bmatrix} w_{11} & w_{12} & w_{13} \\ w_{21} & w_{22} & w_{23} \\ w_{31} & w_{32} & w_{33} \end{bmatrix}$$

$$R = \begin{bmatrix} r_{22} & r_{23} & r_{24} & \dots & r_{2(n-1)} \\ r_{32} & r_{33} & r_{34} & \dots & r_{3(n-1)} \\ \dots & \dots & \dots & \dots & \dots \\ r_{(d-1)2} & r_{(d-1)3} & r_{(d-1)4} & \dots & r_{(d-1)(n-1)} \end{bmatrix}$$


$$r_{ij} = \sum_{k=-1}^1 \sum_{l=-1}^1 p_{(i+k)(j+l)} w_{(2+k)(2+l)} \quad (3.3)$$

burada $1 < i < d$ ve $1 < j < n$

Denklem 3.3, yalnızca 1 kanalın bir evrişimini temsil etmektedir. Birden fazla kanal varsa, W filtresi aynı sayıda kanala sahip bir 3D matris haline gelmektedir.


Diğer bir deyişle, evrişim katmanları, girişin her kanalına uygulanacak filtrelerden oluşmaktadır. Bir görüntüye filtre uygulamak temelde bir evrişim olduğundan, bu katmanlar evrişim katmanları olarak adlandırılmaktadır. Filtreler uygulanarak, her filtreye karşılık gelen bir görüntünün özellikleri bulunmaktadır. (Fukushima, 1980)'te önerilen mimariye benzer şekilde, katmanlar derinleştikçe, özellikler daha karmaşık hale gelmektedir. Örneğin, birinci katmanda bir görüntünün dikey ve yatay kenarlarının bulunduğunu varsayalım. İkinci katmanda, görüntüdeki köşeleri bulmak için birinci katmanın (görüntünün dikey ve yatay kenarlarına karşılık gelen) çıktıları kullanılmaktadır.

Gerçek uygulamalarda özellikler, bir ağın daha derin katmanlarında çok daha karmaşık hale gelmektedir.



Şekil 3.3 Filtreyi kaydırarak tüm görüntü üzerinde evrişim işleminin uygulanması

P 'deki kırmızı dikdörtgen, sol üst köşedeki 3×3 pikseli temsil etmektedir. Sonuç, R 'deki kırmızı dikdörtgendir ve aslında Şekil 3.4'de r_{22} 'dir.




Şekil 3.4 r_{22} çevresindeki piksellere uygulanan W filtresini temsil eden bir nöron

3.1.1.2. Havuzlama katmanları

Havuzlama katmanları genellikle bir evrişim katmanının çıktısının boyutlarını azaltmak için kullanılmaktadır. Bu katmanlar gereklidir, çünkü bir evrişim katmanından elde edilen özelliklerin sayısı istenmeyen bir şekilde yüksek olabilmektedir. Örneğin, evrişim sonucunun görüntü ile aynı boyutta olması için kenarlarda sıfır dolgu varsayıldığında, $H \times G \times C$ boyutundaki bir RGB görüntüsünün $H \times G \times$ (katmandaki filtre

sayısı) özellikleri olacaktır. Bu kadar çok sayıda özelliğin eğitimi, aşırı uyum (overfitting) gibi sorunlara yol açacaktır. Bu nedenle boyut küçültmeye ihtiyaç vardır. Ortalama havuzlama ve maksimum havuzlama gibi boyutları azaltmak için kullanılabilecek birçok yöntem vardır. En çok tercih edileni maksimum havuzlamadır çünkü havuzlamanın uygulandığı yerel bölgede baskın olan özelliği çıkarmaktadır. Bu modül, hatanın en yüksek yanıtlarla yayılmasına izin verdiği için özellikle kritiktir. Böylece, ortalama havuzlamada sıklıkla gözlemlenebilecek gradyan kaybolma probleminin olasılığını azaltmaktadır. Şekil 3.5, adım 2 ile 2 x 2 pencerelere uygulanan maksimum havuzlamayı ve ortalama havuzlamayı göstermektedir.



(a) Görüntü piksel değerleri. (b) Her renkli bölge üzerinde maksimum havuzlamanın sonucu. (c) Her bir renkli bölge üzerinde ortalama havuzlamanın sonucu.

Şekil 3.5 Maksimum ve ortalama havuzlama

3.1.1.3. Yükseltme katmanı (Altörnekleme)

Sinir ağlarında her zaman altörnekleme gerekli değildir. Yukarı örnekleme, piksel sınıflandırma veya anlamsal görüntü segmentasyon gibi görevler için sinir ağlarında da gereklidir. Klasik sınıflandırma görevinde olduğu gibi mekânsal/uzamsal boyutları azalttıktan sonra, piksel sınıflandırma için oluşturulmuş bir ESA, aynı mekânsal/uzamsal girdi boyutlarına sahip bir çıktı oluşturmalıdır. Bu nedenle, derin özelliklerin boyutunu artırmak için örnekleme katmanları kullanılmaktadır. ESA'da yukarı örnekleme katmanı olarak kullanılan birçok yöntem vardır. Çift doğrusal enterpolasyon, ters evrişim ve alt piksel yukarı örneklemede önemli olan yöntemlerden bazılarıdır.

1. İkili doğrusal (Bilinear) enterpolasyon,

2. Ters evrişim,
3. Alt piksel üst örnekleme.

3.1.1.4. Tam bağlantılı katmanlar

Tam bağlantılı katmanlar, son bir sınıf etiketine ulaşmak için özellik bilgilerini kullanmaktadır. Tam bağlantılı katmanların düğümleri, önceki katmanın her bir çıktısına bağlanır ve bunların çıktıları, bir sonraki katmanın her düğümüne bağlanmaktadır. Son katmanda, n sayıda düğüm vardır, burada n , sınıfların sayısına eşitlenmektedir (Şekil 3.2). Tam bağlantılı katmanların son katmanındaki düğümler genellikle özel bir etkinleştirme işlevine sahiptir. Bu işlev, her etiket için olasılıklı bir sonuç üretecektir. Bu aktivasyon fonksiyonu genellikle bir softmax fonksiyonu veya ikili sınıflandırma durumunda bir sigmoid fonksiyonudur.

3.1.1.5. Aktivasyon fonksiyonları (etkinleştirme işlevleri)


Yapay bir nöronun girdisi ağırlıklarla çarpıldıktan ve bir skalere (sabit bir sayı) toplandıktan sonra, sonuç bir $f(x)$ aktivasyon fonksiyonuna beslenmektedir (Şekil 3.1). Aşağıdakiler gibi farklı aktivasyon fonksiyonları vardır:

1. Softmax
2. Sigmoid
3. Tanh
4. Doğrultulmuş doğrusal (Rectified linear)
5. Sızdıran doğrultulmuş doğrusal

3.1.1.6. Bırakmak (Dropout)

Bırakma, belirli yinelemelerde bazı nöronları görmezden gelerek bir sinir ağını eğitmektir. Bu, aşırı uyumu önlemeye yardımcı olmaktadır (Srivastava ve ark., 2014). Göz ardı edilen nöronların diğer nöronlar üzerindeki etkisi azaltılmakta böylece göz ardı

edilmeyen nöronlar daha iyi öğrenmektedir. Şekil 3.6'da bırakılan bir ağ görülmektedir (Srivastava ve ark., 2014).



Şekil 3.6 Solda standart bir sinir ağıdır, sağda bırakılan (dropout) bir ağıdır

Çaprazlanan nöronlar mevcut yinelemede göz ardı edilmektedir.

3.1.1.7.Yığın normalleştirme

Derin öğrenmede kullanılan veri kümeleri çok büyük olduğundan, ağ girdileri önemli ölçüde değişiklik göstermektedir. Yığın normalleştirme, adından da anlaşılacağı gibi, mini-yığındaki verileri normalleştirmek ve normalleştirmeyi ağı bir parçası yapmaktır. Böylece görüntü sınıflandırma gibi görevlerde öğrenme hızını artırmaktadır (Ioffe ve Szegedy, 2015). Ek olarak, (Ioffe ve Szegedy, 2015) yığın normalizasyonu bir düzenleyici olarak davrandığı için bırakma (dropout) katmanlarına olan ihtiyacın hariç tutulabileceğini belirtmektedir.

3.2.Kılavuzlu Görüntü Filtreleme (Kenar Korumalı Filtreleme)

Kenarları-koruyan Kılavuzlu Görüntü Filtreleme (K-KGF), bir kontrast geliştirme mekanizması görevi görmektedir. Düşük gradyanlı alanları yumuşatmanın yanı sıra, güçlü kenarları da vurgulamaktadır. Diyabetik retinopati, retina dokularında iz ve lezyonlar bırakacak ölçüde retinadaki kılcal damar ve arterlere ilerleyici zarar vermektedir. Bu lezyonlar kenarlar şeklinde görünür ve retina görüntülerini işlerken, DR semptomlarının

daha iyi teşhisini sağlamak için bu kenarlar vurgulamaya çalışılmıştır. Kılavuzlu görüntü filtrelemenin özelliklerinden yararlanmak için motivasyon noktası budur.

Kılavuzlu filtre, filtrelemeyi gerçekleştirmek için belirli bir görüntü üzerinde kenarları koruyan bir yumuşatma işlevi uygulamaktadır. Kılavuz görüntü olarak adlandırılan başka bir görüntüye dayanmaktadır (He ve ark., 2010). Kılavuz görüntü, görüntünün kendisi veya değiştirilmiş bir versiyonu veya tamamen farklı bir görüntü olabilmektedir (Paris ve ark., 2009).

I_p ve G_p , giriş ve kılavuzlu görüntünün piksel p 'deki yoğunluk değerleridir. ω_k , k pikselinde ortalananmış çekirdek penceresidir. KGF daha sonra Denklem 3.4'teki gibi ifade edilmektedir:

$$GIF(I)_p = \frac{1}{\sum_{q \in \omega_k} W_{GIF_{pq}}(G)} \sum_{q \in \omega_k} W_{GIF_{pq}}(G) I_q \quad (3.4)$$

ve çekirdek ağırlıkları fonksiyonu $W_{GIF_{pq}}(G)$ Denklem 3.5'teki gibi tanımlanabilir:

$$W_{GIF_{pq}}(G) = \frac{1}{|\omega|^2} \sum_{k: (p,q) \in \omega_k} \left(1 + \frac{(G_p - \mu_k)(G_q - \mu_k)}{\sigma_k^2 + \varepsilon}\right) \quad (3.5)$$


Burada μ_k ve σ_k^2 yerel pencere ω_k 'deki kılavuzlu görüntü G 'nin ortalaması ve varyansdır, $|\omega|$ bu penceredeki piksel sayısıdır.

$\left(1 + \frac{(G_p - \mu_k)(G_q - \mu_k)}{\sigma_k^2 + \varepsilon}\right)$ terimi, KGF'in kenar koruma yeteneğini gerçekleştirmenin anahtarıdır.

G_p ve G_q aynı anda bir kenarın aynı tarafında olduğunda (ikisi de ortalamadan daha küçük veya daha büyükse), piksel q 'ya atanan ağırlık büyük olacaktır. Tersine, farklı taraflarda olduklarında (biri daha küçük, diğeri ortalamadan daha büyük), piksel q 'ya küçük bir ağırlık atanacaktır. (He ve ark., 2010)'daki hesaplamalarda, Denklem 3.4' deki normalizasyon terimini 1'e eşit olduğunu vurgulamaktadır. KGF'in filtre çekirdeği Denklem 3.6'daki gibi kısaltılabilmektedir:

$$GIF(I)_p = \sum_{q \in \omega_k} W_{GIF_{pq}}(G)I_q \quad (3.6)$$

KGF'in düzgünleştirme / keskinleştirme seviyesi, ε parametresi ile kontrol edilmektedir. ε parametresinin değeri ne kadar büyük olursa, filtrelenmiş görüntü o kadar düzgün olmaktadır. Şekil 3.7. ε parametresinin farklı değerlerini ayarlayarak, kılavuzlu görüntü filtrelemenin örnek bir retina görüntüsü üzerindeki etkisini göstermektedir.



Şekil 3.7 KGF uygulamasının örnek bir retina görüntüsü üzerindeki etkisidir

3.3.Temel Bileşenler Analizi

Temel Bileşen Analizi (TBA), gelişmiş matematiksel kavramları kullanan güçlü bir hesaplama tekniğidir. Bir dizi ilişkili özelliği, temel bileşenler adı verilen minimal bir özellik kümesine dönüştürmektedir. TBA'de, bir veri setinde depolanan veriler küçültülmüş boyutlarla korunmaktadır. Bu, örneklerin bir ortogonal aks yöntemi ile oluşturulan bir alt uzaya entegre bir projeksiyonuna bağlıdır. Azaltılmış boyutlu hesaplama bilgileri, önemli veri özelliklerinin herhangi bir veri kaybı olmadan belirleneceği şekilde seçilmektedir. Bu azalma, görüntü sıkıştırma, veri gösterimi ve benzeri birçok alanda faydalıdır. Bu nedenle TBA, biyomedikal görüntü işleme uygulamalarının geniş bir alanında kullanılmaktadır. Örneğin, yüz tanıma ve görüntü sıkıştırma, yüksek boyutlu verilerde desenler bulma ve özellik çıkarma, görüntü bölümleme, görüntü kaydı, görüntü füzyonu ve görüntülerin

gürültüden arındırılma gibi uygulamalarında kullanılmaktadır. Azaltılmış boyutsal, uzay kovaryans matrisinin özvektörleri ile hesaplanabilmektedir, Denklem 3.11'deki gibi ifade edilmektedir.

$x_1 x_2 \dots x_n$, $n N \times 1$ vektörlerden oluşan bir setse, $\bar{x}$ bunların ortalamasıdır, Denklem 3.7 ve Denklem 3.8'deki gibi ifade edilmektedir.

$$x_i = \begin{bmatrix} x_{i1} \\ x_{i2} \\ \vdots \\ x_{iN} \end{bmatrix} \quad (3.7)$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n \begin{bmatrix} x_{i1} \\ x_{i2} \\ \vdots \\ x_{iN} \end{bmatrix} \quad (3.8)$$

$X, x_1 - \bar{x}, x_2 - \bar{x}, \dots x_n - \bar{x}, \bar{x}$ sütunlu $N \times n$ matris ise, $\dots \bar{x}$ ortalama değerdir, Denklem 3.9 ve Denklem 3.10 gibi ifade edilmektedir.

$$x = [x_1 - \bar{x} \quad x_2 - \bar{x} \quad \dots \quad x_n - \bar{x}] \quad (3.9)$$

$Q = XX^T$, $N \times N$ matrisi olsun:

$$Q = xx^T = [x_1 - \bar{x} \quad x_2 - \bar{x} \quad \dots \quad x_n - \bar{x}] \begin{bmatrix} (x_1 - \bar{x})^T \\ (x_2 - \bar{x})^T \\ \vdots \\ (x_n - \bar{x})^T \end{bmatrix} \quad (3.10)$$

Q kovaryans matrisi "aka saçılma matrisi" ve görüntü işlemede N genellikle görüntünün piksel sayısıdır. Her x_j Denklem 3.11'deki gibi yazılabilmektedir:

$$x_j = \bar{x} + \sum_{i=1}^n g_{ji} e_i \quad (3.11)$$

Burada e_i , Q 'nun sıfır olmayan özdeğerlere sahip n özvektörleridir. Özvektörler $e_1 e_2 \dots e_n$ bir özuzayı kapsar ve $e_1 e_2 \dots e_n$ $N \times 1$ ortonormal vektörlerdir. Skaler g_{ji} , uzayda x_j 'in koordinatlarıdır, Denklem 3.12'deki gibi ifade edilmektedir.

$$g_{ji} = (x_j - \bar{x}) \cdot e_i \quad (3.12)$$

3.4.DRIVE Veri Kümesi Açıklaması

Önerilen modelin performansı, çok yaygın ve herkes tarafından elde edilebilen bir veri kümesine göre değerlendirilmektedir. (Damar Ekstraksiyonu için Dijital Retinal Görüntüler) 'in kısaltması DRIVE veri kümesi olarak adlandırılmaktadır (Maninis ve ark., 2016). DRIVE veritabanı, retina görüntülerinden kan damarları segmentasyonu üzerinde karşılaştırmalı çalışmalar ve deneyler sağlamak için özel olarak oluşturulmuştur.

DRIVE veri setinin görüntüleri, Hollanda'da diyabetik retinopati için bir tarama programından elde edilmiştir. Taramada kullanılan popülasyon, 25-90 yaşları arasındaki 400 diyabet hastasından oluşmaktadır. 40 görüntü rastgele seçilmiştir, 33'ü herhangi bir diyabetik retinopati belirtisi göstermemektedir ve 7 görüntü erken hafif diyabetik retinopati belirtilerini göstermektedir. Her görüntü JPEG dosyası olarak sıkıştırılmıştır (Staal ve ark., 2004).


Görüntüler, 45° görüş alanına (GA) sahip Canon CR5 midriatik olmayan 3CCD kamera kullanılarak elde edilmektedir (Maninis ve ark., 2016). Her görüntü 584 x 565 pikselde her bir renk seviyesi için 8-bit kullanılarak yakalanmıştır. Her görüntünün GA'sı yaklaşık 540 piksel çapında daireseldir. Bu veri tabanında, görüntüler GA çevresinde kırılmış ve GA'yı belirten her görüntü için bir maske görüntüsü sağlanmıştır.

40 görüntüden oluşan veri seti, her biri 20 görüntü içeren eğitim ve test setine bölünmüştür. Eğitim seti görüntüleri için, vaskülatürün tek bir manuel segmentasyonu mevcuttur. Test seti görüntüleri için iki manuel segmentasyon mevcuttur. Biri standart olarak kullanılmaktadır. Diğeri, bilgisayar tabanlı oluşturulan segmentasyonları bağımsız bir insan gözlemcilerle karşılaştırmak için kullanılabilir. Damar sistemini manuel bir şekilde bölümlere ayıran insan gözlemciler, yetenekli bir göz doktoru tarafından

yönlendirilmiştir ve eğitilmiştir. Doktorlardan damar olduğundan en az %70 emin oldukları tüm pikselleri işaretlemeleri istenmiştir (Staal ve ark., 2004).


3.5.Kaggle Veri Kümesi Açıklaması

Kaggle, çok sayıda yüksek çözünürlüklü retina görüntülerinden oluşan bir diyabetik retinopati veri kümesidir. Çeşitli görüntüleme koşulları altında çekilmiş ve EyePACS klinikleri tarafından sağlanmıştır (January 2018). Görüntü açıklaması uzman göz doktorları tarafından sağlanmıştır. Herhangi bir gerçek veri kümesi gibi hem görüntülerde hem de etiketlerde gürültüyle karşılaşmaktadır. Görüntüler: kusurlu, odak dışı, az pozlanmış veya aşırı pozlanmış olabilmektedir. Bu çalışmada, veri setinin seçilmiş bir versiyonu kullanılmıştır (2018). Semptomlar ve semptom olmayanlar şeklinde düzenlenmiştir. Semptom seti 595 görüntü içerirken semptom olmayan set 1468 görüntü içermektedir. Şekil 3.8, önerilen RUnet-PCA modelimizde kullanılan Kaggle veri setinin sınıf dağılımını göstermektedir.



Şekil 3.8 Kullanılan Kaggle veri kümesinin sınıf dağılımı

Şekil 3.9, Kaggle veri kümesinin örnek retina görüntülerini göstermektedir. Üst sıradaki ilk iki görüntü normal deneklerden (sağlıklı) ve alttaki iki görüntü diyabetik retinopati hastalarına aittir.



Şekil 3.9 Kaggle veri kümesinin örnek retina görüntüleri

3.6. Veri Arttırma

Veri kümesinde yalnızca birkaç eğitim örneği varsa, veri artırma son derece önemli bir rol oynamaktadır. Ağın gerekli değişmezlik ve sağlamlık özelliklerini öğrenmesini sağlamaktadır. Mikroskobik görüntülerde, öncelikle kayma ve dönüş değişmezliği yanı sıra deformasyonlara gürbüzlük ve gri değer varyasyonlarına ihtiyaç vardır.

Veri artırma, eğitim veri setlerinin boyutunu ve kalitesini artırmayı amaçlayan bir dizi tekniği kapsamaktadır. Veri kümesi, çevirme, yatay çevirme, rastgele kırpma, döndürme, ölçek dönüştürme ve gürültü bozulması gibi çeşitli veri artırma teknikleriyle genişletilebilmektedir. Bu, ağın aşırı uymasını önlemeye yardımcı olurken, aynı zamanda derin ağlarda çok sayıda parametrenin ayarlanmasına yardımcı olmaktadır.

Hussain ve ark. (Hussain ve ark., 2018) büyütme stratejilerini karşılaştırmıştır. Döndürme ve gauss filtresi gibi büyütme stratejilerinin tıbbi görüntü istatistiklerinde önemli doğrulamalara yol açtığını göstermiştir.

t 'inci yinelemedeki $D_t: \{x_i\}_{i=1}^M$ veri örnekleri, derin ESA'a beslendiklerinde veri artırma tekniği ile $\widetilde{D}_t: \{\tilde{x}_i\}_{i=1}^M$ 'ye genişletilmektedir. Bunu matematiksel olarak ifade etmek için, her örneğin $(x \rightarrow \tilde{x})$ veri arttırma işlemi Denklem 3.13'te görülebilmektedir:

$$\tilde{x} = g(x) \quad (3.13)$$

Burada $g(x)$, karşılık gelen veri arttırma işlemi temsil etmektedir. Her farklı veri artırma tekniği farklı bir $g(x)$ ile temsil edilebilmektedir.

3.7.Platform Yazılımı ve Kütüphaneler

Tez kapsamında Python 3.6, Jupyter Notebook ve Anaconda3 kullanılarak uygulanmıştır. Sinir ağı, arka uç olarak TensorFlow kullanılarak Keras libraryla geliştirilmiştir. Ayrıca, Python3 +, opencv, keras2.0 +, h5py, ConfigParser, Numpy, scikit-learn, matplotlib, PIL kütüphaneleri kullanılmıştır.


4. RETİNA KAN DAMARI SEGMENTASYONU

4.1.Önerilen Model

Bu bölümde, tez kapsamında önerilen evrişimli sinir ağı mimarisinin genel modeli açıklanmaktadır. Ağa beslenen retina görüntülerinin ilk aşamada önceden işlendiğini varsayılmıştır. Derin öğrenme tabanlı denetimli yöntemler, geleneksel denetimli ve denetimsiz yaklaşımlara kıyasla gerçek uygulamalarda çok daha yüksek performans ve memnuniyet sağlamaktadır. Geleneksel yaklaşımlar, segmentasyonda düşük seviyeli özellikler kullandığından, performans olarak yeterli değildir. Bu sorunun üstesinden gelmek için, rezidüel bağlantıların varlığıyla evrişimli sinir ağları kullanılmaktadır. Bu, düşük seviyeli özelliklerin elde edilmesini sağlamaktadır.

Çok derin ağların eğitimi, bir dizi zorlukları beraberinde getirmektedir. Bu zorluklar gradyanlar kaybolması ve eğitim süresinin son derecede yavaş olabilmesidir. Bu sorunları ele almak için, düşük seviyeli özelliklerin derin olmayan katmanlardan yeniden kullanılması vurgulanmıştır. Bu, derin sinir ağlarının yakın zamandaki başarısını tamamlamaktadır.

Rezidüel bağlantılar, derin katmanlardan gelen yüksek seviyeli özellikleri derin olmayan katmanlardan düşük seviyeli özelliklerle birleştiren bir mimari sağlamaktadır. Böylelikle hassas ve kapsamlı segmentasyon süreci elde edilebilmektedir. Her katmanda, önceki katmanların özellik haritaları girdi olarak kullanılmaktadır. Kendi özellik haritaları, sonraki katmanlara girişler olarak beslenmektedir. Düşük seviyeli özelliklerin yeniden kullanılması birkaç önemli motivasyona sahiptir: kaybolan gradyan problemini hafifletmek, özellik yayılmasını desteklemek, özelliğin yeniden kullanımını teşvik etmek ve önceki bir katmandan etkinleştirmeleri yeniden kullanarak parametre sayısını önemli ölçüde azaltmaktadır. Şekil 4.1, bazı ara katmanların çıktısının bir örneğini göstermektedir.



Şekil 4.1 ESA basit bir modelin bazı ara katman çıktılarının görselleştirilmesi

Önerilen DESA mimarisi Şekil 4.2(a-b)'de gösterilmektedir. Bu mimari için U-Net mimarisinden esinlenmiştir (Ronneberger ve ark., 2015). Önerilen mimarinin ana katkısı iki önemli özelliğe odaklanmaktadır: birincisi, kümelenmiş rezidüel bağlantılardan oluşan son derece modülerleştirilmiş ağ mimarisi sağlamasıdır. İkincisi, ağ içindeki bilgi işlem kaynaklarının kullanımını iyileştirmektir. Bu, hesaplama maliyetinin istikrarını korurken ağı derinliğini ve genişliğini artırmaya izin veren bir tasarımla elde edilmektedir.

U-Net mimarisine benzer şekilde, (Ronneberger ve ark., 2015) önerilen ağ mimarisi bir daralma yolundan (sol taraf) ve bir genişletme yolundan (sağ taraf) oluşmaktadır. Her ikisi de aynı topolojiye sahip bir dizi dönüşümü bir araya getiren bir yapı bloğunun tekrarlanmasıyla oluşturulmaktadır. Önerilen uyumlu tasarım, ayarlanacak yalnızca birkaç hiper parametreye sahip homojen, çok dallı bir mimari ile sonuçlanmaktadır. Çizelge 4.1, önerilen ağ mimarisinin parametrelerini göstermektedir. (Lupascu ve ark., 2010) tarafından yapılan çalışma, deneysel olarak, ağıdaki kardinalitenin artırılmasının (dönüşüm kümesinin boyutu) sınıflandırma doğruluğunu iyileştirebileceğini göstermektedir. Dahası, artan kardinalite, kapasite artırma durumunda daha derine veya daha genişlemekten daha etkilidir (Lupascu ve ark., 2010).

Daralma yolu iki kısımdan oluşmaktadır. İlki, bir yığın normalleştirme işlemini ve ardından bir ReLU işlemini ve son olarak 3 x 3-evrişimli bir işlemini içermektedir. İkinci kısım, rezidüel bağlantıların dahil edilmesiyle evrişimli bir sinir ağının tipik mimarisini takip etmektedir. Bu işlemler tekrarlı bir şekilde yığın normalleştirme işlemi, ardından bir ReLU işlemi ve ardından 3 x 3 evrişim işlemi sırasında uygulanır. Her evrişim işlemi bir toplama işlemi ile takip edilmektedir. Bu, rezidüel bağlantıları gerçekleştirmektedir. Son toplama işlemi, ilk çıktısını içermektedir. Bu yapı bloklarının her birini ReLU işlemi ve

adım = 2 ile 2 x 2 maks-havuzlama işlemi ile takip edilmektedir. Maksimum havuzlama işlemi altörnekleme gerçekleştirmektedir. Her alt örnekleme adımında, özellik kanallarının sayısı çoğaltılmaktadır.

Genişletme yolundaki her katman şunlardan oluşmaktadır: 2 x 2 yukarı örnekleme (un-pooling) işlemi, ardından kasılma yolundan karşılık gelen kırpılmış özellik haritaları ile birleştirme işlemi. Genişletme yolundaki ilk dal, bir yığın normalleştirme işlemini, ardından bir ReLU işlemini ve ardından 3 x 3-evrişimli işlemi içermektedir. İkinci dal, rezidüel bağlantıların dahil edilmesiyle evrişimli bir sinir ağının tipik mimarisini takip etmektedir. Bu işlemlerin tekrarlanan bir uygulamasını içermektedir: yığın normalleştirme işlemi, ardından bir ReLU işlemi ve ardından 3 x 3 evrişim işlemi. Her evrişim işlemini bir toplama işlemi ile takip edilmektedir. Bu, rezidüel bağlantıyı gerçekleştirmektedir. Son toplama işlemi, ilk dalın çıktısını içermektedir. Bu yapı bloklarının her birini ReLU işlemi ve tekrar 2 x 2 yukarı örnekleme (un-pooling) işlemi ile takip edilmektedir. Her evrişimde kenar piksellerinin kaybı nedeniyle kırpma kaçınılmazdır. Her bir yukarı örnekleme adımında, özellik kanallarının sayısı yarıya inmektedir. Son katmanda, 1 x 1 evrişim işlemi, sonuçta elde edilen 32 özellik vektörünü gereken sınıf sayısına eşlemek için kullanılmaktadır (bu durumda ikili sınıflandırma problemi gerçekleştiren iki sınıftır).

Şekil 4.2 (a - b) önerilen derin evrişimli sinir ağı mimarisini göstermektedir. Ayrıca, ağdaki katman sayısı ve her katmanda kullanılan filtre sayısı ve bu filtrelerin boyutu dahil olmak üzere önerilen mimarinin kullanılan parametrelerini görülmektedir. Burada her katmandaki giriş ve çıkış bileşeni özellikleri vektörünün boyutu da açıkça göstermektedir.

Daha sonra, 48 x 48 x 1 boyutlu giriş alt görüntüsünün 3 x 3 x N filtrelili (1 adımla) evrişimi yapılırken, sıfır dolgusu girişi sınır çevresinde sıfırlarla doldurmaktır. Çıktı bileşenleri 48 x 48 x N boyutlu olacaktır (girdi boyutu korunmaktadır).

Özellik bileşenlerinin çıkış boyutunu hesaplama formülü aşağıdaki gibidir:

$$\text{Çıkış Boyutu} = (50 - 3) / 1 + 1 = 48.$$


Önerilen mimari, önceden işlenmiş orijinal görüntülerin farklı alt görüntü setleri (yamalar) kullanılarak doğrulanmıştır. 48 x 48 boyutundaki yamalar, tam orijinal görüntünün içindeki merkezini rastgele bir şekilde seçerek çıkarılmaktadır (alınmaktadır)

(Mohammedhasan ve Uğuz, 2020a). DRIVE veritabanı 20 resim içermektedir, bu nedenle orijinal resimler (20, 1, 584, 565) olarak ifade edilebilir. Örneğin, 20 DRIVE eğitim görüntüsünün her birinde 11445 yamanın rasgele çıkarılmasıyla 228900 yamalık bir set elde edilir. Bu nedenle, yama görüntülerinin şekli öyledir: (228900, 1, 48, 48). Yeniden şekillendirme işlemi, tensorflow "reshape" işlevi kullanılarak gerçekleştirilmektedir. Yamaların boyutları çeşitli denemeler yoluyla deneysel olarak seçilmiştir. Seçilen boyut ile eğitim sürecinde en iyi sonuçları ve kabul edilebilir süreler elde edilmiştir.


Segmentasyon problemi, sinir ağının her pikseli sınıflardan birine atanması gereken bir sınıflandırma problemi olarak düşünülebilmektedir. Softmax, genellikle sınıflandırma problemlerinde çıktı katmanının aktivasyon işlevi olarak kullanılmaktadır. Belirli bir sınıfa ait her görüntünün olasılıklarını oluşturmakla görevlendirilmiştir. Softmax işlevini kullanmanın temel avantajı, her birimin çıkış olasılıklarını 0 ile 1 aralığında olmak üzere sıkıştırmasıdır. Çıkışı, çıktı olasılıklarının toplamı 1'e eşit olacak şekilde bölmektedir. Sigmoid işlevinden daha geneldir. Çizelge 4.1, önerilen ağ mimarisinin parametrelerini göstermektedir.

Çizelge 4.1 Ağ mimarisinin parametreleri

katman sayısı	7
evrişim filtresi sayısı	32, 64, 128, 256, 128, 64, 32
filtre boyutları	3x3
Adım (strides)	1
altörnekleme faktörü (downsampling)	2x2
yukarıörnekleme faktörü (upsampling)	2x2



(a) Önerilen ESA ağının mimarisi



(b) Önerilen ConvDenseBlock'un mimarisi

Şekil 4.2 (a) Önerilen ESA ağının mimarisi, (b) Önerilen ConvDenseBlock'un mimarisi

4.2.Yöntem

Rahim ve ark. (Rahim ve ark., 2019), görüntü ön işleme tekniklerinin sınıflandırma performansını en üst düzeye çıkarma yeteneğini araştırmıştır. Bu nedenle tez kapsamında önerilen modelde bu benzer ön işlemleri uyguladık. DRIVE veri setlerinin 20 retina görüntüsü ilk olarak birkaç etkili görüntü ön işleme tekniği ile önceden işlenmektedir. Bu, orijinal görüntüden mümkün olduğunca çok özelliği korurken modelin sınıflandırılmasını kolaylaştırmaktadır.

Ağ eğitimine başlamadan önce, görüntüler aşağıdaki dönüşüm listesi ile önceden işlenmektedir (Mohammedhasan ve Uğuz, 2020a):

- Gri tonlama dönüştürme
- Standardizasyon


- Kontrastla Sınırlı Uyarlanabilir Histogram Eşitleme (KSUHE)
- Gama ayarı

Gama düzeltmesinin değeri deneysel olarak seçilmiştir. Ayrıca, alandaki diğer araştırmalar da aynı değeri kullanmıştır (Cao ve ark., 2018).


Python 3.6, RGB görüntüleri gri tonlamalı görüntülere dönüştürmek için kullanılmaktadır. Daha sonra görüntüler standardizasyon, KSUHE ve gama ayarı ile işlenmektedir. Sonuçlar, Şekil 4.3'te gösterilmektedir.



(a) Orijinal görüntü



(b) Gri tonlamalı görüntü ve normalleştirilmiş görüntü



(c) KSUHE görüntü ve gama düzeltmeli görüntü [gama: 0.5]

Şekil 4.3 (a-c), Orijinal görüntü ve karşılık gelen önceden işlenmiş görüntüler

Sinir ağı eğitimi, önceden işlenmiş orijinal tam görüntülerin yamaları adı verilen alt görüntüler üzerinde gerçekleştirilmektedir. 48 x 48 boyutlu yamalar, tam orijinal retina görüntüleri içinde merkezlerinin rastgele seçilmesiyle elde edilmektedir. Ek olarak, Görüş Alanının (GA) kısmen dışında kalan yamalar da seçilmektedir. Bu şekilde sinir ağı, GA sınırını kan damarlarından nasıl ayırt edeceğini öğrenmektedir.

20 DRIVE eğitim görüntüsünün her birinden belirli sayıda yamanın rastgele çıkarılmasıyla alt görüntü setleri (yamalar) elde edilmektedir. Farklı yamalar, orijinal görüntülerin aynı kısmına sahip olabilmektedir (yamalar örtüştüğü için). Daha fazla veri artırma gerçekleştirilmemektedir. Bu, orijinal görüntülerden mümkün olduğunca çok özelliği korurken modelin performansını en üst düzeye çıkarmaya olanak tanmaktadır (Mohammedhasan ve Uğuz, 2020a).

Çapraz entropi fonksiyonu bir kayıp fonksiyonu olarak kullanılır ve stokastik gradyan inişi optimizasyon için kullanılmaktadır. Kayıp fonksiyonu, Denklem 4.1'de gösterildiği gibi tanımlanmaktadır (Marín ve ark., 2011).

$$\mathcal{L}(W) = -\beta \sum_{j \in Y^+} \log P(y_j = 1 | X; W) - (1 - \beta) \sum_{j \in Y^-} \log P(y_j = 0 | X; W) \quad (4.1)$$

W , ESA'nın standart parametre setini belirtmektedir. S , eğitim veri setini belirtmektedir $S = \{(X_n, Y_n), n = 1, \dots, N\}$. X_n , girdi görüntüsüdür. $Y_n = \{y_j(n), j = 1, \text{ile} \dots |X_n|\}$; $y_j(n) \in \{0,1\}$ tahmin edilen piksel etiketlerdir. Daha basit hale getirmek için, n alt simge düşürülmüştür.

Her evrişimli katmandan sonra ReLU bir aktivasyon fonksiyonu olarak kullanılmaktadır. Her iki ardışık evrişimli katman arasında 0.2'lik bir bırakma (dropout) kullanılmaktadır. Eğitim, 150 ve 200 devir (epochs) boyunca yapılmaktadır. Bölüm 6.1.1, ağ yapılandırmalarını ayrıntılı olarak göstermektedir (Mohammedhasan ve Uğuz, 2020a).

4.3.Yama Çıkarma

DRIVE veri kümesine göre, total_imgs test görüntüsü bulunmaktadır. (Her birinin boyutu $\text{img_h} \times \text{img_w}$ 'dir).

Gri tonlama dönüşümünden sonra test görüntülerinin şekli şu şekilde açıklanabilir: (total_imgs, channels, img_h, img_w).

Burada,

total_imgs	tam görüntülerin sayısıdır,
channels	kanal sayısıdır,
img_h	görüntünün yüksekliğidir,
img_w	görüntü genişliğidir,
patch_h	yama yüksekliğidir,
patch_w	yama genişliğidir,
stride_h	stride yüksekliğidir,
stride_w	stride genişliğidir,
patches_hight	yükseklikteki yama sayısı,
patches_width	genişlikteki yama sayısı,
p	dolgu miktarı ise (dolgulu kenar genişliğidir).

Yükseklikteki yama sayısı = $\text{floor}((\text{img_h} + 2p - \text{patch_h}) / \text{stride_h}) + 1$ = **patches_hight** yama.


Genişlikteki yama sayısı = $\text{floor}((\text{img_w} + 2p - \text{patch_w}) / \text{stride_w}) + 1$ = **patches_width** yama.

Görüntü başına yama sayısı = (**patches_hight** * **patches_width**) = **patches_image** yama.

Toplamda bu veri kümesi için = (**patches_image** * **total_imgs**) = **total_patches** yama.

Test yamaları şekli şu şekilde açıklanabilir: (total_patches, channels, patch_h, patch_w).

Şekil 4.4, örnek girdi yamaları ve buna karşılık gelen groundtruth göstermektedir.




Şekil 4.4 Giriş yamaları örneği ve buna karşılık gelen groundtruth

Tahmin edilen görüntüde, her piksel damarın tahmin edilen olasılığını gösterir. Her piksel için tahmin edilen damar olasılığı, aynı pikseli kaplayan çok sayıda örtüşen yama üzerinden tahmin edilen olasılığın ortalaması alınarak hesaplanır.

Her pikselin tahmini, örtüşen tüm eklerinin tahmini şu şekilde hesaplanarak elde edilir:

1. Bu pikseli içeren tüm yamaların tahminini hesaplayın.
2. Tahminde ortalamayı hesaplayın, bu sonuçları iyileştirir ancak tahmin edilmesi için daha fazla yama gerektirir.
3. Yama çıkarma için adım (stride), örtüşen yamalar için yükseklik boyunca adım, daha küçük adım daha fazla sayıda yama verir.
4. $\text{Stride_yüksekliği} = 5$. (stride = kutunun piksel cinsinden görüntü boyunca hareket ettiği mesafe). Şekil 4.5, yama çıkarma kavramını göstermektedir.



Şekil 4.5 Yama çıkarma kavramı

Test, DRIVE test veri setinin **test_imgs** görüntüsü ile gerçekleştirilmektedir. Yalnızca GA'a ait pikseller dikkate alınmaktadır.

Performansı iyileştirmek için, her pikselin damar olasılığı, çoklu tahminlerin ortalaması alınarak elde edilmektedir. Hem yükseklik hem de genişlikte **stride** piksellik bir adımla, her test görüntüsünde birbirini takip eden çok sayıda örtüşen yamalar ayıklanmaktadır. Daha sonra, her piksel için, pikseli kaplayan tüm tahmin edilen yamalar üzerinden olasılıkların ortalaması alınarak damar olasılığı elde edilmektedir.

Tüm sonuçlar yalnızca GA'ya ait piksellere atıfta bulunur. Her görüntünün GA'sı yaklaşık $D \approx 540$ piksel çapında daireseldir (Staal ve ark., 2004).

- Her görüntünün görüş alanı GA daireseldir. Görüş alanı yarıçapı yaklaşık olarak $R \approx (D / 2)$ pikseldir.
- Sonuçları/tahminleri yalnızca görüş alanı GA içinde hesaplayarak (yamalar yalnızca GA içinde çıkarılır): $(R * R * \pi) * \text{test_imgs} \approx P$ pixels.
- P , Karmaşıklık Matrisinde kullanılan sonuçların sayısı.

Burada,

test_imgs	test görüntülerin sayısıdır,
stride	stride yüksekliğidir = stride genişliğidir,
D	görüş alanının çapıdır,
R	görüş alanının yarıçapıdır,
P	görüş alanındaki tahminlerin sayısıdır.

5. DİYABETİK RETİNOPATİ TEŞHİSİ

5.1.Önerilen Model



Bu çalışmanın amacı, konvolüsyonel sinir ağlarının gücünü DR teşhisine getiren yeni bir strateji tanıtmaktır. Literatürde diyabet hastalığının tanısal doğruluğunu iyileştirmek için TBA tabanlı yöntemleri kullanılmıştır (Polat ve Günes, 2007; Shilaskar ve Ghatol, 2013; Velliangiri ve ark., 2019). TBA, bir sınıflandırıcı sistemi daha etkili hale getirmek için kullanılmaktadır. Bu çalışmada önerilen ESA modelinden elde edilen ayırt edici özelliklerden yararlanılmaktadır. Daha sonra TBA kullanılarak en verimli özellikler belirlemektedir. TBA, yüksek boyutlu verilerdeki modelleri belirleyebilmektedir. Ayrıca, tüm verilerde mevcut olan mümkün olduğunca fazla bilgiyi koruyan bir özellik alt kümesinin seçilmesine çalışmaktadır. TBA, yüksek bir varyansı yakalayarak özelliklerin en değerli bilgilerini depolayan yeni bileşenler oluşturmaktadır (Guyon ve ark., 2006). Son zamanlarda, birkaç çalışma, sağlık hizmetlerinde sınıflandırma için bir özellik çıkarma tekniği olarak TBA'yi kullanmıştır. Rajagopal ve ark. (Rajagopal ve Ranganathan, 2017), sinir ağı sınıflandırıcısı ile beş farklı doğrusal (lineer) ve doğrusal olmayan (lineer olmayan) denetimsiz boyutsal indirgeme tekniği kullanarak otomatik bir kardiyak aritmi sınıflandırmasını karşılaştırmıştır. Zhang ve ark. (Zhang ve ark., 2018b), TBA'ye dayalı bir AdaBoost algoritması kullanarak meme kanserini tespit etmiştir. Negi ve ark. (Negi ve ark., 2016) üst ekstremitate hareketlerini kontrol eden en iyi özellikleri elde etmek için TBA'yi ilişkisiz doğrusal (lineer) diskriminant analizi (İLDA) adı verilen bir özellik azaltma tekniği ile birleştirmiştir. Avendano- Valencia ve ark. (Avendano-Valencia ve ark., 2009), kalp seslerini azaltmak ve performansı artırmak için zaman frekansı gösterimlerine (ZFG) TBA uygulamıştır. Kamencay ve ark. (Kamencay ve ark., 2013), farklı tıbbi görüntülerde ölçek-değişmez özellik dönüşümü tanımlayıcısı olarak adlandırılan TBA-kEYK'yu kullanan yeni bir yöntem sunmuştur. Bu, 200 görüntüyü eğitirken %83,6 doğruluk sağlamıştır. Ratnasari ve ark. (Ratnasari ve ark., 2013) eşik tabanlı ve TBA kullanarak X-ışını görüntülerini azaltmıştır. 150'lik en iyi gri seviye eşiğini elde etmişler.

Verimli bir evrişimli sinir ağı mimarisini içeren önerilen model, bu bölümde açıkça tartışılmaktadır. İlk adımda modele sağlanan retina görüntülerini önceden işledik. Önerilen mimari, rezidüel bağlantıların katılımıyla U-ağından etkilenen bir sinir ağı kullanmaktadır.

Bu tür sorunların üstesinden gelmek için, rezidüel bağlantılar, verimli bir sınıflandırma yöntemine doğru düşük seviyeli karakteristiklerle birlikte yüksek seviyeli karakteristikleri birleştiren bir bağlantı tasarımı benimsemektedir. Önceki katmanlardan gelen özellik vektörleri, geçerli katmana girişler olarak kullanılmaktadır. Bunun yanı sıra, kendi yerel özellikleri sonraki katmanlara girdi olarak eklenmektedir. Düşük seviyeli özelliklerin yeniden kullanılmasının birçok ilham verici uyararı vardır: gradyan inişi sorununu azaltır, özelliklerin yayılmasını kolaylaştırır, özelliklerin yeniden kullanımını güçlendirir ve parametreleri önemli ölçüde en aza indirmektedir.

Şekil 5.1, önerilen RUnet-PCA derin ESA'nın mimarisini göstermektedir (Mohammedhasan ve Uğuz, 2020b). Bu modelde U-Ağının (Ronneberger ve ark., 2015) mimari tasarımından esinlenilmiştir. Önerilen mimari tasarımın temel katkısını yoğunlaştıran iki önemli özellik vardır. İlk olarak, kümelenmiş rezidüel bağlantılardan oluşan son derece modülerleştirilmiş ağ mimarisi sağlamasıdır. İkincisi, ağ içindeki bilgi işlem kaynaklarının kullanımını iyileştirmektir. Bu, hesaplama maliyetini sabit tutarken ağın derinliğinin ve genişliğinin genişletilmesine izin veren, uzmanlıkla tasarlanmış bir mimari ile gerçekleştirilmektedir (Mohammedhasan ve Uğuz, 2020a; 2020b).

U-Ağının (Ronneberger ve ark., 2015; Mohammedhasan ve Uğuz, 2020a) yapısı gibi, önerilen modelin mimarisi de bir daralma yolundan (sol taraf) ve bir genişletme yolundan (sağ taraf) oluşmaktadır. Her ikisi de aynı topolojiye sahip bir dizi dönüşümü bir araya getiren bir yapı bloğunun tekrarlanmasıyla oluşturulmaktadır. Önerilen uyumlu mimari, ayarlanması gereken birkaç hiper parametreye sahip homojen, çok dallı bir mimari ile sonuçlanmaktadır. (Lupascu ve ark., 2010) tarafından yapılan çalışmada, deneysel olarak, ağ kardinalitenin artırılmasının (dönüşüm kümesinin boyutu) sınıflandırma doğruluğunu iyileştirebileceğini göstermektedir. Dahası, artan kapasite durumlarında, kardinaliteyi artırmak, derinleşmekten veya genişletmekten çok daha faydalıdır (Lupascu ve ark., 2010; Mohammedhasan ve Uğuz, 2020a).



(b) Önerilen modelde kullanılan ConvDenseBlock yapısı
 Şekil 5.1 (a-b), Önerilen modelde kullanılan derin ESA ağı ve ConvDenseBlock yapısı


Çizelge 5.1 açıkça her katmandaki girdi ve çıktı durumlarındaki özellik vektörlerinin boyutlarına atıfta bulunmaktadır. Şekil 5.1, sunulan modelin rezidüel bağlantılara dayalı derin ESA'nı göstermektedir. Ayrıca, modelde kullanılan katman sayısı ve bu katmanlarda kullanılan filtre sayısı ve hatta bu filtrelerin boyutları gibi parametreleri göstermektedir.

Önerilen model, orijinal önceden işlenmiş görüntülerin farklı alt görüntü setleri (yamalar) kullanılarak doğrulanmıştır. 48 x 48 boyutlu yamalar, tam orijinal retina görüntüleri içinde merkezlerinin rastgele seçilmesiyle elde edilmektedir. Softmax, genellikle sınıflandırma görevlerinde çıktı katmanının aktivasyon işlevi olarak kullanılmaktadır. Belirli bir kategoriyle ilgili ise her görüntünün olasılıklarını belirlemekten sorumludur. Softmax aktivasyonunun temel avantajı, sonuç olasılıklarını [0 - 1] kapsam dahilinde biriktirmesidir (Mohammedhasan ve Uğuz, 2020b).

Çizelge 5.1 Önerilen modelin girdi / çıktı katmanlarındaki öznitelik vektörlerinin boyutu

Katman	Giriş	Çıktı
Katman 1 ConvDenseBlok1(32x3x3)	(1x48x48)	(32x48x48)
Katman 2 Havuzlama1(2x2)	(32x48x48)	(32x24x24)
Katman 3 ConvDenseBlok2(64x3x3)	(32x24x24)	(64x24x24)
Katman 4 Havuzlama2(2x2)	(64x24x24)	(64x12x12)
Katman 5 ConvDenseBlok3(128x3x3)	(64x12x12)	(128x12x12)
Katman 6 Havuzlama3(2x2)	(128x12x12)	(128x6x6)
Katman 7 ConvDenseBlok4(256x3x3)	(128x6x6)	(256x6x6)
Katman 8 Yukarı Örnekleme1(2x2)	(256x6x6)	(256x12x12)
Katman 9 ConvDenseBlok5(128x3x3)	(384x12x12)	(128x12x12)
Katman 10 Yukarı Örnekleme2(2x2)	(128x12x12)	(128x24x24)
Katman 11 ConvDenseBlok6(64x3x3)	(192x24x24)	(64x24x24)
Katman 12 Yukarı Örnekleme3(2x2)	(64x24x24)	(64x48x48)
Katman 13 ConvDenseBlok7(326x3x3)	(96x48x48)	(32x48x48)
Katman 14 Evrişim(2x1x1)	(32x48x48)	(2x48x48)
Katman 15 Reshape	(2x48x48)	(2304x2)

Önerilen modelde kullanılan kayıp fonksiyonu çapraz entropidir, ayrıca optimizasyon için stokastik gradyan inişi kullanılmaktadır (Marín ve ark., 2011). Her evrişimli katmandan sonra ReLU bir aktivasyon fonksiyonu olarak kullanılmaktadır. Her iki ardışık evrişimli katman arasında 0.2'lik bir bırakma (dropout) kullanılmaktadır. Model eğitimi, 150 ve 200 devir (epochs) boyunca yapılmaktadır. Şekil 5.2, derin ESA ve temel bileşen analizi yoluyla erken evre diyabetik retinopati teşhisinin genel önerilen RUnet-PCA modelini göstermektedir (Mohammedhasan ve Uğuz, 2020b).



Şekil 5.2 Diyabetik retinopati teşhisi için önerilen RUnet-PCA modeli

5.2.Yöntem

Önerilen erken evre diyabetik retinopati tanı modeli, RUnet-PCA olarak adlandırılmıştır. Bu, Temel Bileşen Analizi ile Rezidüel U-net Derin ESA'nın bir kısaltmasıdır. Önerilen modelin tüm akışı dört adımdan oluşmaktadır: görüntü ön işleme, kenarı koruyan KGF kullanarak görüntü geliştirme, veri artırma ve ardından DenseRUnet eğitim ağını kullanarak teşhis işlemleridir. Şekil 5.3, önerilen RUnet-PCA modelin süreç diyagramını göstermektedir. Şekil 5.4, DenseRUnet eğitim ağına ilişkin süreç diyagramını

göstermektedir (Mohammedhasan ve Uğuz, 2020b). Aşağıdaki sözde kod, önerilen modelin adımlarını göstermektedir.

Algoritmanın Sözde (Pseudo) Kodu:

ADIM 1: Kaggle resimlerini orijinal formatında kullanın

ADIM 2: görüntüleri gri tonlamalı forma dönüştürün, bu dönüştürmeleri uygulayın (standardizasyon, CLAHE ve gama ayarı)

ADIM 3: kontrast iyileştirme mekanizması yapmak için kenarı koruyan kılavuzlu görüntü filtrelemesi uygulayın

ADIM 4: [48 x 48] boyutlu yamalar oluşturarak veri görüntülerini artırın


ADIM 5: veri kümesine TBA uygulayın

ADIM 6: veri seti örneklerini hazırlayın, eğitim için %60 ve test için %40


ADIM 7: DenseRUnet eğitim ağını oluşturun

ADIM 8: özellik çıkarmak için eğitim veri kümesini kullanarak DenseRUnet eğitim ağını eğitin

ADIM 9: test veri setini kullanarak eğitilmiş ağı değerlendirin ve test edin, ardından softmax işlevini kullanarak görüntüleri sınıflandırın



Şekil 5.3 Önerilen RUnet-PCA modelin süreç diyagramı



Şekil 5.4 DenseRUnet eğitim ağının süreç diyagramı

Rahim ve ark. (Rahim ve ark., 2019), görüntü ön işleme yöntemleriyle sınıflandırma verimliliğini artırma yeteneğini araştırmaktadır. Önerilen modelde, Kaggle diyabetik retinopati veri setinin retina görüntüleri ilk olarak bir dizi görüntü ön işleme yöntemiyle işlenmektedir. Bu, mümkün olduğunca çok orijinal görüntü özelliğini korurken model sınıflandırmasını desteklemektedir.

Genel olarak, kullanılan dönüşümlerin dizisi matematiksel olarak Denklem 5.1-5.4'teki gibi temsil edilebilmektedir:

$$\tilde{x}_g = \text{grayscale}(x) \quad (5.1)$$

$$\tilde{x}_n = \frac{\tilde{x}_g - \text{average}(\tilde{x}_g)}{\max(\tilde{x}_g) - \min(\tilde{x}_g)} \text{ ortalama normalleşme için} \quad (5.2)$$

$$\tilde{x}_c = \text{CLAHE}(\tilde{x}_n) \quad (5.3)$$

$$\tilde{x}_{ga} = A\tilde{x}_c^\gamma \quad (5.4)$$

Burada $\tilde{x}_c$ giriş değeri γ gücüne yükseltilmektedir ve A sabiti ile çarpılmaktadır. Genel durumda $A = 1$, girişler ve çıkışlar tipik olarak 0-1 aralığındadır.

Retina görüntüleri, ağ eğitime başlamadan önce farklı ön işleme teknikleriyle işlenmektedir. Ön işleme adımları Bölüm 4.2 'de açıklandığı gibi uygulanmıştır.

Önerilen modelde, kullanılan Kaggle veri kümesinin tam görüntülerinden rastgele olarak yamalar kümeleri (veya alt görüntüler) oluşturulmaktadır. 48 x 48 boyutlu yamalar, tam orijinal retina görüntüleri içinde merkezlerinin rastgele seçilmesiyle elde edilmektedir. Kısmen Görüş Alanının (GA) dışında kalan yamalar da seçilmektedir. Bu, sinir ağının görüş alanı sınırını kan damarından (damar, arter veya kılcal damar) ayırt etmesine yardımcı olmaktadır. Elde edilen yamalar örtüştüğü için, farklı yamalar orijinal görüntülerin benzer kısımlarını içerecektir. Bu, orijinal görüntülerden mümkün olan maksimum sayıda özelliği korurken modelin verimliliğini optimize etmeyi amaçlamaktadır.

Aşağıdaki adımlar, birleşik bir algoritma oluşturmak için algoritmanın dört parçasını etkili bir şekilde birbirine bağlamaktadır.

1. Önerilen algoritmayı etkili bir şekilde açıklamak için Kaggle veri kümesinin veri örneklerini şu şekilde düşünerek başlayalım: $x \in D: \{x_i\}_{i=1}^{2063}$
2. Veri örneklerini gri tonlamalı formatına dönüştürmek ve ardından denklem (5.1-5.4) 'te tartışıldığı gibi bir dizi dönüşüm uygulamak, şunu elde etmekteyiz: $x_{pre} = transformation(x)$
3. Kontrast geliştirme mekanizmasını gerçekleştirmek için kenarı koruyan kılavuzlu görüntü filtreleme uygulamak için: $x_{GIF(x_{pre})_p} = \sum_{q \in \omega_k} W_{GIF_{pq}}(G) x_{pre_q}$. Çekirdek ağırlıkları fonksiyonu $W_{GIF_{pq}}(G)$, denklem (3.6) 'te tanımlanmıştır.
4. [48 x 48] boyutlu yamalar oluşturarak örnek sayısını artırmak için veri arttırma uygulamak için: $x_{aug} = g(x_{GIF})$
5. Tanılama doğruluğunu iyileştirmek için TBA uygulanır. Yeni boyutsal uzay, kovaryans matrisinin özvektörleri ile hesaplanabilmektedir: $x_j = \bar{x} + \sum_{i=1}^{i=n} g_{ji} e_i$. Skaler g_{ji} , uzayındaki x_j koordinatlarıdır: $g_{ji} = (x_j - \bar{x}) \cdot e_i$. Burda, $\bar{x}$ denklem (12) 'da tanımlandığı gibidir.
6. Veri örneklerini eğitim ve test setlerine ayırmak için: sırasıyla %60 ve %40. Kaggle veri setini başka oranlara bölmek için deneysel çalışmalar yapılmıştır. 90/10 oranı denenmiş, ancak zamana en uygun olduğu ve sonuçların tatmin edici olduğu için 60/40 oranı kullanılmıştır.
7. Önerilen ESA tabanlı DenseRUnet eğitim ağını oluşturulur.
8. Özellik çıkarma işlemini gerçekleştirmek için eğitim veri setini kullanarak DenseRUnet eğitim ağıının eğitimini gerçekleştirilir. $D: \{x_i\}_{i=1}^N$ veri kümesinde eğitilmiş derin bir ESA modeli $M: f(x)$ elde etmek için.
9. $D: \{x_i\}_{i=1}^M$ test veri kümesini kullanarak eğitilmiş ağı $M: f(x)$ değerlendirmek ve test etmek, ardından softmax işlevini kullanarak görüntüleri sınıflandırmak için: $f(x) = softmax()$

6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

6.1. Retina Kan Damarı Segmentasyonunun Araştırma Sonuçları ve Tartışması

Bu bölüm tez kapsamındaki deneyleri ve çıktı analizini tartışmaktadır. Guoa ve ark. (Guo ve ark., 2019) retina damar segmentasyonu için AÜK-DDA sinir ağı önermektedir. Önerilen AÜK-DDA yöntemi, DRIVE veri seti üzerinde doğrulanmıştır. Ayrıca Zhan ve ark. (Zhang ve ark., 2018a) retina damar segmentasyonu için yeni bir evrimsel sinir ağı önermektedir. Önerilen model, DRIVE veri seti üzerinde değerlendirilmiştir. Benzer bir şekilde, bu tez kapsamında literatürde en popüler ve yaygın olarak kullanılan veri kümelerinden ikisi (DRIVE ve Kaggle) kullanılmıştır. Mevcut veri kümelerinin daha fazla araştırılması gelecekteki çalışma olarak gerçekleştirilecektir.

6.1.1. Ağ yapılandırması

Bu alt bölüm, Çizelge 6.1 Çizelge 6.2

Çizelge 6.3'te gösterildiği gibi ağ yapılandırmasını, veri özniteliklerini, eğitim ve test ayarlarını açıklamaktadır.

Çizelge 6.1 Veri öznitelikleri

Tam görüntülerden çıkarılan yamaların boyutları.	
yama uzunluğu	48
yama_genişliği	48

Çizelge 6.2 Ağ eğitimi yapılandırmaları

Toplam yama sayısı.	N_subimgs = 10000, 15000 (farklı değerler)
Stochastic gradient descent parametreleri.	
Eğitim devri (epochs) sayısı.	N_epochs = 150, 200
Batch boyutu.	batch_boyutu = 32


Çizelge 6.3 Ağ testi yapılandırmaları

Test edilecek model: best=minimum kayıplı epoch, last=son epoch.	best_last = best
Test için tam görüntü sayısı (en fazla 20).	full_images_to_test = 20
Her çıktı görüntüsünde görselleştirilecek görüntü sayısı.	N_group_visual = 5
Yama çıkarma için adım (stride).	
Yama uzunluğu	stride_height = 5
Yama genişliği	stride_width = 5

6.1.2. Deneysel çalışma ve sonuçları

Önerilen modelin performansını doğrulamak için, DRIVE veri setlerinin 20 retina görüntüsü ilk olarak birkaç etkili görüntü ön işleme tekniği kullanılarak önceden işlenmiştir. Bunlar, gri tonlamalı dönüştürme, standardizasyon, CLAHE ve gama ayarıdır.

Önerilen modelin eğitimini, önceden işlenmiş 20 DRIVE tam görüntünün farklı alt görüntü setleri (yamalar) üzerinde gerçekleştirilmektedir. 48 x 48 boyutlu yamalar, tam orijinal retina görüntüleri içinde merkezlerinin rastgele seçilmesiyle elde edilmektedir. GA'n kısmen dışında kalan yamalar da seçilmiştir. Bu, sinir ağının GA sınırını kan damarlarından nasıl ayırt edeceğini öğrenmesini sağlamaktadır. Yamalar örtüştüğü için, farklı yamalar orijinal görüntülerin aynı bölümünü içerebilmektedir 20 DRIVE eğitim görüntüsünün her birinden belirli sayıda yamanın rastgele çıkarılmasıyla alt görüntü setleri (yamalar) elde edilmektedir. Çapraz entropi fonksiyonu bir kayıp fonksiyonu olarak kullanılır ve stokastik gradyan inişi optimizasyon için, ReLU, her evrişimli katmandan sonra bir aktivasyon fonksiyonu olarak kullanılmıştır. Her iki ardışık evrişimli katman arasında 0.2'lik bir bırakma (dropout) değeri kullanılırken, Softmax, çıktı katmanından sonra bir aktivasyon fonksiyonu olarak kullanılmıştır. Eğitim, 150 ve 200 devir (epochs) boyunca yapılmaktadır. Şekil 6.1, zamana karşı kayıp değerini göstermektedir.



Şekil 6.1 Zamana karşı kayıp değeri

Karmaşıklık Matrisi (Confusion Matrix), sınıflandırma problemlerinin performansını açıklamak için iyi bir seçenektir, çünkü sınıflandırıcı çıktıları ile gerçek olanlar arasındaki ilişkileri fark etmek mümkündür. Şekil 6.2, iki sınıflı bir sınıflandırma problemi karmaşıklık matrisini göstermektedir.

Class	Tamin edilen (1)	Tahmin edilen (0)
Gerçek değeri (1)	Gerçek Pozitif (TP)	Yanlış Negatif (FN)
Gerçek değeri (0)	Yanlış Pozitif (FP)	Gerçek Negatif (TN)

Şekil 6.2 İki sınıf sınıflandırma problemi karmaşıklık matrisi

2 sınıflı bir sınıflandırma problemi için karmaşıklık matrisi için:

- (1) Gerçek Pozitifler: Bunlar gerçek değeri 1 ve tahmin ettiğimiz değerin de 1 olduğu örneklerdir.
- (2) Gerçek Negatifler: Bunlar gerçek değeri 0 ve tahmin ettiğimiz değerin de 0 olduğu örneklerdir.
- (3) Yanlış Pozitifler: Bunlar gerçek değeri 0 ancak tahmin ettiğimiz değerin 1 olduğu örneklerdir.
- (4) Yanlış Negatifler: Bunlar gerçek değeri 1 ancak tahmin ettiğimiz değerin 0 olduğu örneklerdir.

Çizelge 6.4’de önerilen mimari kullanılarak yapılmış farklı deneylerin sonuçlarını özetlemektedir. Performans, doğruluk (accuracy), duyarlılık (sensitivity), özgüllük (specificity), kesinlik (precision), hata oranı (error rate) ve Jaccard benzerlik puanı (Jaccard similarity score) gibi karmaşıklık matrisinden farklı değerlendirme ölçütleri kullanılarak ölçülmektedir.

$$\text{Doğruluk/Accuracy} = (TP + TN) / (TP + TN + FP + FN)$$

$$\text{Özgüllük/Specificity} = TN / (TN + FP)$$

$$\text{Duyarlılık/Sensitivity} = TP / (TP + FN)$$

$$\text{Kesinlik/Precision} = TP / (TP + FP)$$


$$\text{Hata Oranı/Error Rate} = (FP + FN) / (TP + TN + FN + FP)$$

$$\text{Jaccard benzerlik puanı/Jaccard similarity score} = TP / (TP + FP + FN)$$

Çizelge 6.4 DRIVE veri tabanında önerilen yöntemi kullanan farklı deneylerin sonuçları

N epochs	N subimgs	Jaccard benzerlik puanı	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
150	2000	0,9210388	0,9210388	0,4039494	0,9964577	0,9432873
	6000	0,9463029	0,9463029	0,6715202	0,9863807	0,8779224
	8000	0,9444682	0,9444682	0,6302287	0,9903009	0,9045554
	10000	0,9469390	0,9469390	0,6587097	0,9889781	0,8970847
	12000	0,9496159	0,9496159	0,6835119	0,9884279	0,8959948
	15000	0,9472495	0,9472495	0,6595718	0,9892081	0,8991343
	16000	0,9578790	0,9578790	0,7749273	0,9845630	0,8798326
	17000	0,9679144	0,9679144	0,8197623	0,9891045	0,9149760
200	15000	0,9506646	0,9506646	0,7071041	0,9861885	0,8818977
	2000	0,9300101	0,9300101	0,4993551	0,9928223	0,9102906


Şekil 6.3, %96,79'luk en iyi doğruluğa ulaşan deneyin çıktısını göstermektedir. Şekil 6.3'de 1. satır, ön işlem aşamasından sonraki görüntüleri; ikinci satır, açıklayıcılar (annotators) tarafından bölümlere ayrılan kesin referans (ground-truth) görüntülerini gösterir ve son satır, önerilen mimari tarafından bölümlere ayrılan görüntüleri göstermektedir. Kullanılan veri setinde 20 görüntü vardır ve Şekil 6.3 'deki gibi bölümlere ayrılmıştır.

iriş görüntüleri	
Groundtruth görüntüleri	
Bölgelere ayrılmış görüntüler	

(a) İlk beş giriş görüntüsünün çıktısı

Giriş görüntüleri	
Groundtruth görüntüleri	
Bölgelere ayrılmış görüntüler	

(b) İkinci beş giriş görüntüsünün çıktısı

Giriş görüntüleri	
Groundtruth görüntüleri	
Bölgelere ayrılmış görüntüler	

(c) Üçüncü beş giriş görüntüsünün çıktısı

Giriş görüntüleri	
Groundtruth görüntüleri	
Bölgelere ayrılmış görüntüler	

(d) Son beş giriş görüntüsünün çıktısı

Şekil 6.3 (a-d), Önerilen mimarinin segmentasyon sonuçları

6.1.3. Diğer yöntemlerle karşılaştırma

Çizelge 6.5 önerilen mimariyi DRIVE veri setinde doğruluk, duyarlılık, belirtme, kesinlik, hata oranı ve Jaccard benzerlik puanı açısından performanslarını yayınlayan diğer yeni tekniklerle karşılaştırmaktadır.

Çizelge 6.5 Önerilen yöntemin diğer yeni tekniklere göre performans (DRIVE kullanarak)

No	Tür	Yöntem	Yıl	Doğruluk	Duyarlılık	Özgüllük
1	Denetimsiz yöntemler	Niemeijer (Niemeijer ve ark., 2004)	2004	0,9416	N.A	N.A
2		Al-Diri (Al-Diri ve ark., 2009)	2009	N.A	0,7272	0,9551
3		Fraz (Fraz ve ark., 2012a)	2011	0,9430	0,7152	0,9759
4		You (You ve ark., 2011)	2011	0,9434	0,7410	0,9751
5		Azzopardi (Azzopardi ve ark., 2015)	2015	0,9442	0,7655	0,9704
6	Denetimli yöntemler	Ricci (Ricci ve Perfetti, 2007)	2007	0,9595	N.A	N.A
7		Lupascu (Lupascu ve ark., 2010)	2010	0,9597	0,7200	N.A
8		Marin (Marín ve ark., 2011)	2011	0,9452	0,7067	0,9801
9		Fraz (Fraz ve ark., 2012b)	2012	0,9480	0,7406	0,9807
10		Li (Li ve ark., 2016)	2016	0,9527	0,7569	0,9816
11		Fu (Fu ve ark., 2016)	2016	0,9523	0,7603	N.A
12		Liskowski (Liskowski ve Krawiec, 2016)	2016	0,9535	0,7811	0,9807
13		Maninis (Maninis ve ark., 2016)	2016	0,9552	0,7855	0,9799
14		Oliveira (Oliveira ve ark., 2017)	2017	0,9543	0,7810	0,9800
15		Feng (Feng ve ark., 2017)	2017	0,9560	0,7811	0,9839
16		Unet (Ronneberger ve ark., 2015)	2018	0,9536	0,7810	0,9807
17		SP-64 (Zhang ve ark., 2018a)	2018	0,9581	0,8033	0,9808
18		Song Guo (Guo ve ark., 2019)	2018	0,9560	0,7890	0,9803
19		Önerilen Metot (Mohammedhasan ve Uguz, 2020a)	2019	0,9679	0,8197	0,9891

6.2. Diyabetik Retinopati Teşhisinin Araştırma Sonuçları ve Tartışması

Bu bölümde diyabetik retinopati teşhisi için deneysel veriler ve değerlendirme ölçütleri tartışılarak, deneysel çalışma ve analiz sonuçları sunulmuştur.

6.2.1. Deneysel çalışma ve sonuçları

Önerilen modelin etkinliğini doğrulamak için, ilk olarak Kaggle diyabetik retinopati veri setinin retina görüntüleri işlenmekte ve gri tonlama dönüştürme, standardizasyon, Kontrastla Sınırlı Uyarlanabilir Histogram Eşitleme (KSUHE) ve gama uyarlaması gibi bazı verimli ön işleme yöntemleri kullanılarak analiz edilmektedir.

Model eğitimi, önceden işlenmiş tam Kaggle görüntülerinin farklı alt görüntü setleri (yamalar) üzerinde gerçekleştirilmiştir. 48 x 48 boyutlu yamalar, tam orijinal retina görüntüleri içinde merkezlerinin rastgele seçilmesiyle elde edilmektedir. Burada kısmen Görüş Alanının (GA) dışında kalan yamalar da seçilmektedir. Bu, sinir ağının GA sınırını kan damarlarından (damar, arter veya kılcal damar) nasıl ayırt edeceğini öğrenmesini sağlamaktadır. Yamalar örtüştüğü için, farklı yamalar orijinal görüntülerin aynı bölümünü içerebilmektedir.


Kaggle veri kümesinin her görüntüsünden belirli sayıda yamanın rastgele çıkarılmasıyla farklı alt görüntü setleri (yamalar) elde edilmektedir. Veri kümesinin ilk %60'ı eğitim için kullanılırken geri kalan %40'u test için kullanılmaktadır. Kaggle veri setini başka oranlara bölmek için deneysel çalışmalar yapılmıştır. 90/10 oranı denenmiş, ancak zamana en uygun olduğu ve sonuçların tatmin edici olduğu için 60/40 oranı kullanılmıştır.

Önerilen modelde kullanılan kayıp fonksiyonu çapraz entropidir. Ayrıca optimizasyon için stokastik gradyan inişi de kullanılmaktadır. ReLU, her evrişimli katmandan sonra bir aktivasyon fonksiyonu olarak kullanılırken, her iki ardışık evrişimli katman arasında 0.2'lik bir bırakma (dropout) değeri kullanılmıştır. Softmax, çıktı katmanından sonra bir aktivasyon fonksiyonu olarak kullanılmaktadır. Eğitim, 150 devir (epochs) boyunca yapılmaktadır.

Önerilen UNet-PCA modeli %91,49 kesinlik (precision), %94,45 duyarlılık (sensitivity), %98,93 özgüllük (specificity) ve %98,44 doğruluk (accuracy) elde etmiştir. Deneysel sonuçlar, önerilen UNet-PCA modelinin diğer teşhis yöntemlerine kıyasla daha iyi bir teşhis doğruluğu sağladığını göstermektedir. Çizelge 6.6, önerilen UNet-PCA modelinin Kaggle veri seti üzerindeki performans analizini özetlemektedir. Şekil 6.4, önerilen modelin devir (epoch) karşı kayıp eğrisini göstermektedir.

Çizelge 6.6 Kaggle veri kümesinde önerilen RUnet-PCA modelinin tanı sonuçları

Model	Özgüllük	Duyarlılık	Kesinlik	Doğruluk
RUnet-PCA (Önerilen Model)	0,9893	0,9445	0,9149	0,9844

**Şekil 6.4** Önerilen RUnet-PCA modelinin devire (epoch) karşı kaybı

Çizelge 6.7, farklı deneylerin parametrelerini ayarlarken önerilen modelin karşılaştırmalı performansını göstermektedir. Kaggle diyabet veri setini sınıflandırmak için TBA ile birlikte bir derin eğitim ağı (DenseRUnet) kullanılmıştır. TBA kullanmanın ana fikri, sınıflandırıcının doğruluğunu iyileştirmektir. 150 ve 200 devir (epoch) kullanılarak bir dizi deney gerçekleştirildi. Bu deneylerde, ağa beslenen alt görüntülerin sayısı değiştirildi. En iyi performans sonuçları, alt görüntü sayısı 17000 olduğunda ve 150 dönem kullanıldığında elde edilmiştir. Sınıflandırma doğruluğu %98,44, duyarlılık %94,45, özgüllük %98,93 ve kesinlik %91,49'dur. Alt görüntü sayısı 15000 olduğunda ve 200 devir (epoch) kullandığında, model %96,79 sınıflandırma doğruluğuna, %81,97 duyarlılığa ve %98,91 özgüllüğe ve %91,49 kesinliğe ulaşmaktadır.

Çizelge 6.7 Kaggle veri tabanında önerilen yöntemi kullanan farklı deneylerin sonuçları

N epochs	N subimngs	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
150	10000	0,9520072	0,6861560	0,9890387	0,8971145
	12000	0,9560282	0,7204951	0,9882920	0,8939524
	15000	0,9617949	0,7787155	0,9897781	0,9209118
	16000	0,9541737	0,6896545	0,9920839	0,9258487
	17000	0,9844409	0,9445063	0,9893065	0,9149760
200	15000	0,9679144	0,8197623	0,9891045	0,9149760


Bu çalışmada, deneğin diyabet hastalığının durumunu gösteren iki sınıf vardır. Semptom olmayanlar (sağlıklı) ve semptomlar (hasta). Önerilen sistemin sınıflandırma sonuçları bir karmaşıklık matrisi kullanılarak görüntülenmiştir. Bir karmaşıklık matrisinde, her hücre, istenen ve gerçek ağ çıktılarının karşılık gelen kombinasyonu için sınıflandırılmış ham örnek sayısını içermektedir. Önerilen derin öğrenmeye dayalı model, sağlıklı ve hasta deneklerin teşhisinde çok umut verici sonuçlar vermiştir. Önerilen model, Çizelge 6.9'da sınıflandırıcılar arasında en yüksek sınıflandırma doğruluğuna ulaşmıştır. Bu sonuçlardan, önerdiğimiz yöntemin tıbbi tanısal karar verme sürecine karşılık gelen ve güvenli bir sistem olduğu gösterilmiştir.

Sınıflandırma sonuçları ile gerçek sonuçlar arasındaki ilişki gözlemlenebildiğinden, sınıflandırma problemlerinin etkinliği bir karmaşıklık matrisi ile ölçülebilmektedir. Önerilen modelin verimliliği, doğruluk (accuracy), duyarlılık (sensitivity), özgüllük (specificity), kesinlik (precision), hata oranı (error rate) ve Jaccard benzerlik puanı (Jaccard similarity score) gibi karmaşıklık matrisinden farklı değerlendirme ölçütleri kullanılarak ölçülmektedir.

Doğruluğun, doğru sınıflandırılmış örneklerin tüm örneklere oranı olduğu kabul edilmektedir ve bu, modelin performansını değerlendirmek için mükemmel bir metriktir. Çizelge 6.8, Önerilen RUnet-PCA modelinin karmaşıklık matrisini göstermektedir. Şekil 6.5, Alıcı Operatör Özellikleri AOÖ (Receiver Operator Characteristics ROC) eğrisini göstermektedir.

Çizelge 6.8 Önerilen RUnet-PCA modelinin karmaşıklık matrisi

Sınıf	RUnet-PCA modeli (Önerilen model)	
	Semptomlar	Semptomsuz
Semptomlar	4002018	43258
Semptomsuz	27351	465516

**Şekil 6.5** Önerilen RUnet-PCA modelinin AOÖ (ROC) eğrisi

6.2.2. Diğer yöntemlerle karşılaştırma

Çizelge 6.9, önerilen RUnet-PCA modelinin performansını doğruluk, duyarlılık ve Kaggle diyabetik retinopati veri setinde belirtilen sınıflandırma performanslarını ölçen diğer yaygın derin ESA mimarileri ile karşılaştırmaktadır (Wan ve ark., 2018).

Çizelge 6.9 Kaggle veri kümesindeki birkaç derin sinir modelinin sınıflandırma sonucu (Wan ve ark., 2018)

Model	Özgüllük	Duyarlılık	Doğruluk
AlexNet	0,9407	0,8127	0,8975
VggNet-s	0,9743	0,8647	0,9568
VggNet-16	0,9432	0,9078	0,9317
VggNet-19	0,9649	0,8931	0,9373
GoogleNet	0,9345	0,7766	0,9336
ResNet	0,9556	0,8878	0,9040
Önerilen RUnet-PCA	0,9893	0,9445	0,9844

Çizelge 6.9'da gösterildiği gibi, VggNet-s modelinin Kaggle sınıflandırması üzerindeki doğruluğu %95,68'dir (Wan ve ark., 2018). Genel olarak iyi bir sınıflandırma performansındır. Öte yandan, önerdiğimiz model %98,44 gibi üstün bir sınıflandırma doğruluğuna ulaşmıştır. Bu, önerilen RUnet-PCA modelimizin diğer modellere kıyasla son derece sağlam olduğunu ve etkili teşhis sonuçları elde edebileceğini kanıtlamaktadır.

6.2.3. TBA olmadan ve TBA uygulandığında karşılaştırma deneyleri

Bu bölümdeki yapılan deneysel çalışmalar, TBA kullanırken ve TBA olmadan iki durumun karşılaştırmasını amacıyla yapılmıştır. Burada TBA, herhangi bir veriyi atlamadan uzayı yeni TBA uzayına değiştirmek için kullanılmaktadır. Çizelge 6.10'de doğruluk, özgüllük ve duyarlılık açısından TBA uygulamasının etkisini göstermektedir.

Çizelge 6.10'de gösterildiği gibi, TBA'yi uygularken doğruluğun, TBA'nin kullanılmadığı duruma kıyasla biraz daha yüksek başarıya sahip olduğu söylenebilir. Bu, TBA uygulamasının olumlu bir etkisini ifade etmektedir. Alt görüntü sayısı 15000 olduğunda, TBA kullanılması %96,17 doğruluk verirken ve TBA kullanılmaması durumunda %95,52 doğruluk vermektedir. Görüldüğü gibi alt görüntü sayısı 17000 olduğunda, TBA kullanılması %98,44 doğruluk verirken ve TBA kullanılmaması durumunda %97,82 doğruluk vermektedir. Böylece, alt görüntülerin sayısı arttıkça, TBA'nin davranışının daha etkili olduğu sonucuna varabiliriz.

Çizelge 6.10 TBA olmadan ve TBA uygulandığında karşılaştırma sonuçları

N epochs	N subimgs	Modeli	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
150	12000	ESA	0,9499210	0,6979018	0,9876166	0,8939525
		ESA + TBA	0,9560283	0,7204951	0,9882921	0,8939525
150	15000	ESA	0,9552041	0,7417691	0,9897224	0,9210887
		ESA + TBA	0,9617949	0,7787155	0,9897781	0,9209118
150	16000	ESA	0,9522128	0,6789696	0,9920913	0,9260871
		ESA + TBA	0,9541738	0,6896545	0,9920839	0,9258487
150	17000	ESA	0,9782689	0,8922248	0,9894732	0,9169219
		ESA + TBA	0,9844410	0,9445063	0,9893065	0,9149760

7. SONUÇLAR VE ÖNERİLER

Tez kapsamında, retina kan damarlarını segmentlere ayırmak için hem yüksek seviyeli özellikleri hem de düşük seviyeli özellikleri kullanan yeni bir derin denetimli evrişimli sinir ağı mimarisi önerilmiştir. Önceki derin öğrenme tabanlı denetimli yöntemler, anlamsal segmentasyon görevlerinde avantajlı olan düşük seviyeli özelliklerin yetersiz kullanımından muzdariptir. Önerilen derin evrişimli sinir ağı mimarisinin büyük katkısı iki önemli özelliğe odaklanır: birincisi, kümelenmiş rezidüel bağlantılardan oluşan son derece modülerleştirilmiş ağ mimarisi sağlamasıdır. İkincisi, ağ içindeki bilgi işlem kaynaklarının kullanımını iyileştirmektir. Bu, hesaplama maliyetinin istikrarını korurken ağın derinliğini ve genişliğini artırmaya izin veren bir tasarımla elde edilmektedir.

Deneysel sonuçlar, kümelenmiş rezidüel bağlantıların kullanılmasının etkinliğini göstermektedir. Ayrıca yöntemimiz, farklı ölçülerde diğer mevcut yöntemlerden daha iyi performans göstermiştir. Mevcut en iyi yöntemlerle karşılaştırıldığında, önerilen yöntem, farklı ölçümlerde diğer mevcut yöntemlerden daha iyi performans göstermiştir, ince damarlarda daha az yanlış pozitif içermiştir ve uzmanların manuel segmentasyonu gibi yeterli ayrıntılarla daha net sınır çizgileri içermiştir.

Önerilen ağ, retina damarı segmentasyonu için genel, yüksek performanslı bir hesaplama mimarisi sağlamaktadır. Pek çok araştırma yönü hala açıktır ve gelecekteki çalışma olarak düşünülmelidir. İlk araştırma noktası ağ mimarisi ile ilgilidir, performansı iyileştirmede önemli bir rol oynayan en önemli katmanları bulmak için derin öğrenme mimarilerinin daha fazla araştırılması üzerinde çalışılmalıdır. İkinci nokta, mevcut veri tabanları ile ilgilidir. Önerilen mimariyi doğrulamak için daha fazla retina damarı görüntüsü dahil edilebilir. Diğer bir araştırma noktası eğitim süreci ile ilgili olmalıdır. ESA mimarisi, retina damar segmentasyonu görevinde hangi kayıp fonksiyonunun çok daha iyi performans gösterdiğini gözlemlemek için farklı parametreler ve farklı kayıp fonksiyonları kullanılarak eğitilebilir. Bu nedenle, bu araştırma yönergeleri, gerçek senaryolarda potansiyel olarak kullanılabilecek daha güvenilir ve doğru bir mimari geliştirmeye yol açabilecektir.

Guoa ve ark. (Guo ve ark., 2019) retina damar segmentasyonu için AÜK-DDA sinir ağı önermektedir. Önerilen AÜK-DDA yöntemi, DRIVE veri seti üzerinde doğrulanmıştır. Ayrıca Zhan ve ark. (Zhang ve ark., 2018a) retina damar segmentasyonu için yeni bir

evrişimsel sinir ağı önermektedir. Önerilen model, DRIVE veri seti üzerinde değerlendirilmiştir. Benzer bir şekilde, bu tez kapsamında literatürde en popüler ve yaygın olarak kullanılan veri kümelerinden ikisi (DRIVE ve Kaggle) kullanılmıştır. Mevcut veri kümelerinin daha fazla araştırılması gelecekteki çalışma olarak gerçekleştirilecek ve önerilen mimariyi doğrulamak için daha fazla retina damar görüntüsü dahil edilecektir.

Sınırlı sayıda oftalmologun mevcudiyeti, otomatikleştirilmiş bir sistemin çok sayıda retina görüntüsünün teşhisinde yer alan zahmetli manuel işi büyük ölçüde azaltabileceği fikrine yol açmaktadır. Önceki çalışmalar genel olarak öznitelik çıkarma temelli diyabetik retinopati tanı mekanizmalarına odaklanmıştır. Daha sonra derin evrişimli sinir ağlarının hızlı gelişimi, araştırmacıların ilgi odağı haline gelmiş ve retina görüntülerinin sınıflandırılmasında ve genel olarak tüm tıbbi görüntü işleme uygulamalarında yeni teknoloji haline gelmiştir (Neelapu ve ark., 2018).

Bu çalışmada, retina görüntülerinde diyabetik retinopati hastalığının teşhisinde derin evrişimli sinir ağlarının rolünü kullanan yeni bir erken evre diyabetik retinopati tanı mekanizması önerilmiştir. İlk olarak, rezidüel bağlantıların kullanılmasıyla birlikte iyi bilinen U-ağından etkilenen yeni bir ESA mimarisi sunulmuştur. Rezidüel bağlantılar, diğer yöntemlere göre üstün performans gösteren katmanlar arasında bilgi aktarmayı amaçlamaktadır. Ayrıca, Temel Bileşen Analizi (TBA), tanılama doğruluğunu iyileştirmek için kullanılmıştır. Kılavuzlu Görüntü Filtrelemesinin (KGF), retina görüntülerinde bir kontrast iyileştirme gerçekleştirmek için kullanılmaktadır. Yalnızca düşük gradyanları düzleştirmekle kalmaz, aynı zamanda düz kenarları da korumaktadır. KGF, diyabetik retinopati semptomlarının daha iyi teşhisini sağlamak için retinanın kenarlarını (dokulardaki izler ve lezyonlar) vurgulamaktadır. Son olarak, önerilen modelin performansını da veri arttırma tekniği sağlanmıştır. Sonuçlar, önerilen modelin diyabetik retinopatinin teşhisinde etkili olduğunu göstermektedir.

KAYNAKLAR

2018, Subset of Kaggle Dataset.

January 2018, Kaggle Dataset.

Al-Diri, B., Hunter, A. ve Steel, D., 2009, An Active Contour Model for Segmenting and Measuring Retinal Vessels, *IEEE Transactions on Medical Imaging*, 28 (9), 1488-1497.

Avendano-Valencia, D., Martinez-Tabares, F., Acosta-Medina, D., Godino-Llorente, I. ve Castellanos-Dominguez, G., 2009, TFR-based feature extraction using PCA approaches for discrimination of heart murmurs, *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 5665-5668.

Azzopardi, G., Strisciuglio, N., Vento, M. ve Petkov, N., 2015, Trainable COSFIRE filters for vessel delineation with application to retinal images, *Medical Image Analysis*, 19, 46-57.

Bora, B., 2018, Convolutional Neural Network Based Brain Mri Segmentation, *METU, ELECTRICAL AND ELECTRONICS ENGINEERING*.

Cao, G., Huang, L., Tian, H., Huang, X., Wang, Y. ve Zhi, R., 2018, Contrast enhancement of brightness-distorted images by improved adaptive gamma correction, *Computers & Electrical Engineering*, 66, 569-582.

Chen, Y., Li, J., Xiao, H., Jin, X., Yan, S. ve Feng, J., 2017, Dual path networks. Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, California, USA, Curran Associates Inc.: 4470-4478.

Chollet, F., 2017, Xception: Deep Learning with Depthwise Separable Convolutions, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1800-1807.

Çınar, A. ve Yıldırım, M., 2020, Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture, *Medical Hypotheses*, 139, 109684.

Dai, J., Qi, H., Xiong, Y., Li, Y., Zhang, G., Hu, H. ve Wei, Y., 2017, Deformable Convolutional Networks, *2017 IEEE International Conference on Computer Vision (ICCV)*, 764-773.

- Feng, Z., Yang, J. ve Yao, L., 2017, Patch-based fully convolutional neural network with skip connections for retinal blood vessel segmentation, *2017 IEEE International Conference on Image Processing (ICIP)*, 1742-1746.
- Fraz, M. M., Remagnino, P., Hoppe, A., Uyyanonvara, B., Rudnicka, A. R., Owen, C. G. ve Barman, S. A., 2012a, Blood vessel segmentation methodologies in retinal images - A survey, *Computer Methods and Programs in Biomedicine*, 108 (1), 407-433.
- Fraz, M. M., Remagnino, P., Hoppe, A., Uyyanonvara, B., Rudnicka, A. R., Owen, C. G. ve Barman, S. A., 2012b, An Ensemble Classification-Based Approach Applied to Retinal Blood Vessel Segmentation, *IEEE Transactions on Biomedical Engineering*, 59 (9), 2538-2548.
- Fu, H., Xu, Y., Lin, S., Kee Wong, D. W. ve Liu, J., 2016, DeepVessel: Retinal Vessel Segmentation via Deep Learning and Conditional Random Field, *Medical Image Computing and Computer-Assisted Intervention MICCAI 2016*, Cham, 132-139.
- Fukushima, K., 1980, Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, *Biological Cybernetics*, 36 (4), 193-202.
- Guo, S., Wang, K., Kang, H., Zhang, Y., Gao, Y. ve Li, T., 2019, BTS-DSN: Deeply supervised neural network with short connections for retinal vessel segmentation, *International Journal of Medical Informatics*, 126, 105-113.
- Guyon, I., Gunn, S., Nikraves, M. ve Zadeh, L., 2006, Feature Extraction: Foundations and Applications (Studies in Fuzziness and Soft Computing).
- He, K., Sun, J. ve Tang, X., 2010, Guided Image Filtering, *Computer Vision ECCV 2010*, Berlin, Heidelberg, 1-14.
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep Residual Learning for Image Recognition, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.
- Hiller, R., Sperduto, R. D., Podgor, M. J., Ferris, F. L., III ve Wilson, P. W. F., 1988, Diabetic retinopathy and cardiovascular disease in type II diabetics. The Framingham Heart Study and the Framingham Eye Study, *American Journal of Epidemiology*, 128 (2), 402-409.

- Hu, J., Shen, L. ve Sun, G., 2018, Squeeze-and-Excitation Networks, *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 7132-7141.
- Huang, G., Liu, Z., Maaten, L. V. D. ve Weinberger, K. Q., 2017, Densely Connected Convolutional Networks, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2261-2269.
- Hussain, Z., Gimenez, F., Yi, D. ve Rubin, D., 2018, Differential Data Augmentation Techniques for Medical Imaging Classification Tasks, *AMIA ... Annual Symposium proceedings. AMIA Symposium*, 2017, 979-984.
- Ioffe, S. ve Szegedy, C., 2015, Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *ArXiv*, abs/1502.03167.
- Jebaseeli, T. J., Deva Durai, C. A. ve Peter, J. D., 2019, Retinal blood vessel segmentation from diabetic retinopathy images using tandem PCNN model and deep learning based SVM, *Optik*, 199, 163328.
- Jin, Q., Meng, Z., Pham, T. D., Chen, Q., Wei, L. ve Su, R., 2019, DUNet: A deformable network for retinal vessel segmentation, *Knowledge-Based Systems*, 178, 149-162.
- Kamencay, P., Hudec, R., Benco, M. ve Zachariasova, M., 2013, Feature extraction for object recognition using PCA-KNN with application to medical image analysis, *2013 36th International Conference on Telecommunications and Signal Processing (TSP)*, 830-834.
- Klein, R., Klein, B. E. K., Moss, S. E., Davis, M. D. ve DeMets, D. L., 1984, The Wisconsin Epidemiologic Study of Diabetic Retinopathy: II. Prevalence and Risk of Diabetic Retinopathy When Age at Diagnosis Is Less Than 30 Years, *Archives of Ophthalmology*, 102 (4), 520-526.
- Klein, R., Klein, B. E. K., Moss, S. E. ve Cruickshanks, K. J., 1994, The Wisconsin Epidemiologic Study of Diabetic Retinopathy: XIV. Ten-Year Incidence and Progression of Diabetic Retinopathy, *Archives of Ophthalmology*, 112 (9), 1217-1228.
- Klein, R., Klein, B. E. K., Moss, S. E. ve Cruickshanks, K. J., 1999, Association of Ocular Disease and Mortality in a Diabetic Population, *Archives of Ophthalmology*, 117 (11), 1487-1495.

- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, ImageNet classification with deep convolutional neural networks. Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1. Lake Tahoe, Nevada, Curran Associates Inc.: 1097-1105.
- Kusakunniran, W., Wu, Q., Ritthipravat, P. ve Zhang, J., 2018, Hard exudates segmentation based on learned initial seeds and iterative graph cut, *Computer Methods and Programs in Biomedicine*, 158, 173-183.
- Larsen, M., Godt, J., Larsen, N., Lund-Andersen, H., Sjølie, A. K., Agardh, E., Kalm, H., Grunkin, M. ve Owens, D. R., 2003, Automated Detection of Fundus Photographic Red Lesions in Diabetic Retinopathy, *Investigative Ophthalmology & Visual Science*, 44 (2), 761-766.
- Li, Q., Feng, B., Xie, L., Liang, P., Zhang, H. ve Wang, T., 2016, A Cross-Modality Learning Approach for Vessel Segmentation in Retinal Images, *IEEE Transactions on Medical Imaging*, 35 (1), 109-118.
- Lin, M., Chen, Q. ve Yan, S., 2014, Network In Network, *CoRR*, abs/1312.4400.
- Liskowski, P. ve Krawiec, K., 2016, Segmenting Retinal Blood Vessels With Deep Neural Networks, *IEEE Transactions on Medical Imaging*, 35 (11), 2369-2380.
- Lupascu, C. A., Tegolo, D. ve Trucco, E., 2010, FABC: Retinal Vessel Segmentation Using AdaBoost, *IEEE Transactions on Information Technology in Biomedicine*, 14 (5), 1267-1274.
- Maninis, K., Pont-Tuset, J., Arbeláez, P. ve Gool, L., 2016, Deep Retinal Image Understanding, *ArXiv*, abs/1609.01103.
- Marín, D., Aquino, A., Gegúndez-Arias, M. E. ve Bravo, J. M., 2011, A New Supervised Method for Blood Vessel Segmentation in Retinal Images by Using Gray-Level and Moment Invariants-Based Features, *IEEE Transactions on Medical Imaging*, 30 (1), 146-158.
- Marupally, A. G., Vupparaboina, K. K., Peguda, H. K., Richhariya, A., Jana, S. ve Chhablani, J., 2017, Semi-automated quantification of hard exudates in colour fundus photographs diagnosed with diabetic retinopathy, *BMC Ophthalmology*, 17 (1), 172.

- Mohammedhasan, M. ve Uğuz, H., 2020a, A New Deeply Convolutional Neural Network Architecture for Retinal Blood Vessel Segmentation, *International Journal of Pattern Recognition and Artificial Intelligence*, 35 (01), 2157001.
- Mohammedhasan, M. ve Uğuz, H., 2020b, A New Early Stage Diabetic Retinopathy Diagnosis Model Using Deep Convolutional Neural Networks and Principal Component Analysis, *Traitement du signal*, 37 (5), 711-722.
- Naqvi, S. A. G., Zafar, H. M. F. ve Haq, I., 2017, Hard exudates referral system in eye fundus utilizing speeded up robust features, *International journal of ophthalmology*, 10 7, 1171-1174.
- Neelapu, R., Lavanya Devi, G. ve Srinivasa Rao, K., 2018, Deep learning based conventional neural network architecture for medical image classification, *Traitement du signal*, 35 (2), 169-182.
- Negi, S., Kumar, Y. ve Mishra, V. M., 2016, Feature extraction and classification for EMG signals using linear discriminant analysis, *2016 2nd International Conference on Advances in Computing, Communication, & Automation (ICACCA) (Fall)*, 1-6.
- Niemeijer, M., Staal, J., Ginneken, B., Loog, M. ve Abramoff, M., 2004, Comparative study of retinal vessel segmentation methods on a new publicly available database, *SPIE Medical Imaging*.
- Oliveira, A., Pereira, S. ve Silva, C. A., 2017, Augmenting data when training a CNN for retinal vessel segmentation: How to warp?, *2017 IEEE 5th Portuguese Meeting on Bioengineering (ENBENG)*, 1-4.
- Paris, S., Kornprobst, P., Tumblin, J. ve Durand, F., 2009, Bilateral Filtering: Theory and Applications, *Foundations and Trends in Computer Graphics and Vision*, 4 (1), 1-73.
- Polat, K. ve Günes, S., 2007, An expert system approach based on principal component analysis and adaptive neuro-fuzzy inference system to diagnosis of diabetes disease, *Digital Signal Processing*, 17 (4), 702-710.
- Rahim, S. S., Palade, V., Almakky, I. ve Holzinger, A., 2019, Detection of Diabetic Retinopathy and Maculopathy in Eye Fundus Images Using Deep Learning and Image Augmentation, *Machine Learning and Knowledge Extraction*, Cham, 114-127.

- Rajagopal, R. ve Ranganathan, V., 2017, Evaluation of effect of unsupervised dimensionality reduction techniques on automated arrhythmia classification, *Biomedical Signal Processing and Control*, 34, 1-8.
- Ratnasari, N. R., Susanto, A., Soesanti, I. ve Maesadji, 2013, Thoracic X-ray features extraction using thresholding-based ROI template and PCA-based features selection for lung TB classification purposes, *2013 3rd International Conference on Instrumentation, Communications, Information Technology and Biomedical Engineering (ICICI-BME)*, 65-69.
- Ricci, E. ve Perfetti, R., 2007, Retinal Blood Vessel Segmentation Using Line Operators and Support Vector Classification, *IEEE Transactions on Medical Imaging*, 26 (10), 1357-1365.
- Ronneberger, O., Fischer, P. ve Brox, T., 2015, U-Net: Convolutional Networks for Biomedical Image Segmentation, *MICCAI*.
- Shilaskar, S. ve Ghatol, A., 2013, Dimensionality Reduction Techniques for Improved Diagnosis of Heart Disease, *International Journal of Computer Applications*, 61, 1-8.
- Soomro, T., Afifi, A. J., Gao, J., Hellwich, O., Zheng, L. ve Paul, M., 2019, Strided fully convolutional neural network for boosting the sensitivity of retinal blood vessels segmentation, *Expert Syst. Appl.*, 134, 36-52.
- Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R., 2014, Dropout: a simple way to prevent neural networks from overfitting, *J. Mach. Learn. Res.*, 15, 1929-1958.
- Srivastava, R., Greff, K. ve Schmidhuber, J., 2015, Highway Networks, *ArXiv*, abs/1505.00387.
- Srivastava, R., Duan, L., Wong, D., Liu, J. ve Wong, T., 2017, Detecting retinal microaneurysms and hemorrhages with robustness to the presence of blood vessels, *Computer Methods and Programs in Biomedicine*, 138, 83-91.
- Staal, J., Abramoff, M. D., Niemeijer, M., Viergever, M. A. ve Ginneken, B. v., 2004, Ridge-based vessel segmentation in color images of the retina, *IEEE Transactions on Medical Imaging*, 23 (4), 501-509.

- Veit, A., Wilber, M. ve Belongie, S., 2016, Residual networks behave like ensembles of relatively shallow networks. Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona, Spain, Curran Associates Inc.: 550-558.
- Velliangiri, S., Alagumuthukrishnan, S. ve Thankumar joseph, S. I., 2019, A Review of Dimensionality Reduction Techniques for Efficient Computation, *Procedia Computer Science*, 165, 104-111.
- Venkatesh, P., Sharma, R., Vashist, N., Vohra, R. ve Garg, S., 2015, Detection of retinal lesions in diabetic retinopathy: comparative evaluation of 7-field digital color photography versus red-free photography, *International Ophthalmology*, 35 (5), 635-640.
- Villalobos-Castaldi, F., Felipe-Riverón, E. ve Sánchez-Fernández, L., 2010, A fast, efficient and automated method to extract vessels from fundus images, *J. Visualization*, 13, 263-270.
- Wan, S., Liang, Y. ve Zhang, Y., 2018, Deep convolutional neural networks for diabetic retinopathy detection by image classification, *Computers & Electrical Engineering*, 72, 274-282.
- Xie, S., Girshick, R., Dollár, P., Tu, Z. ve He, K., 2017, Aggregated Residual Transformations for Deep Neural Networks, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 5987-5995.
- Yau, J., Rogers, S., Kawasaki, R., Lamoureux, E., Kowalski, J., Bek, T., Chen, S.-J., Dekker, J., Fletcher, A., Grauslund, J., Haffner, S., Hamman, R., Ikram, K., Kayama, T., Klein, B., Klein, R., Krishnaiah, S., Mayurasakorn, K., O'Hare, J. ve Vioque, J., 2012, Global Prevalence and Major Risk Factors of Diabetic Retinopathy, *Diabetes care*, 35, 556-564.
- You, X., Peng, Q., Yuan, Y., Cheung, Y.-m. ve Lei, J., 2011, Segmentation of retinal blood vessels using the radial projection and semi-supervised approach, *Pattern Recognition*, 44 (10), 2314-2324.
- Zhang, B., Huang, S. ve Hu, S., 2018a, Multi-scale Neural Networks for Retinal Blood Vessels Segmentation, *ArXiv*, abs/1804.04206.

- Zhang, D., Zou, L., Zhou, X. ve He, F., 2018b, Integrating Feature Selection and Feature Extraction Methods With Deep Learning to Predict Clinical Outcome of Breast Cancer, *IEEE Access*, 6, 28936-28944.
- Zhang, X., Li, Z., Loy, C. C. ve Lin, D., 2017, PolyNet: A Pursuit of Structural Diversity in Very Deep Networks, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3900-3908.
- Zhao, L., Li, M., Meng, D., Li, X., Zhang, Z., Zhuang, Y., Tu, Z. ve Wang, J., 2018, Deep Convolutional Neural Networks with Merge-and-Run Mappings, *IJCAI*.
- Zhao, Y., Rada, L., Chen, K., Harding, S. P. ve Zheng, Y., 2015, Automated Vessel Segmentation Using Infinite Perimeter Active Contour Model with Hybrid Region Information with Application to Retinal Images, *IEEE Transactions on Medical Imaging*, 34 (9), 1797-1807.