

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



SHAP GÖRSELLEŞTİRME TEKNİĞİ VE MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE DİYABETİK
RETİNOPATİNİN ERKEN TANI MODELLEMESİ

DOKTORA TEZİ
Şükran YAMAN ATCI

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

MART, 2024

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



SHAP GÖRSELLEŞTİRME TEKNİĞİ VE MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE DİYABETİK
RETİNOPATİNİN ERKEN TANI MODELLEMESİ

DOKTORA TEZİ
Şükran YAMAN ATCI
(Y1813.610005)

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Ali GÜNEŞ

MART, 2024

ONAY SAYFASI

ONUR SÖZÜ

Doktora Tezi olarak sunduđum “Shap Görselleřtirme Tekniđi Ve Makine Öğrenmesi Yöntemleri İle Diyabetik Retinopatinin Erken Tanı Modellemesi” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça’da gösterilenlerden oluştuđunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (02/04/2024)

Şükran YAMAN ATCI

ÖNSÖZ

Bu tez çalışmasında Shap görselleştirme tekniđi ve makine öğrenmesi yöntemleri ile Diyabetik Retinopatinin erken tanı modellenmesi incelenmek istenmiştir.

Tez çalışmamda planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteđini esirgemeyen, bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren Sayın hocalarım Prof. Dr. Ali Güneş, Prof.Dr. Zafer Aslan, Prof.Dr. Metin Zontul ‘a ve aileme sonsuz teşekkürlerimi sunarım.

Mart, 2024

Şükran YAMAN ATCI

SHAP GÖRSELLEŐTİRME TEKNİĐİ VE MAKİNE ÖĐRENMESİ YÖNTEMLERİ İLE DİYABETİK RETİNOPATİNİN ERKEN TANI MODELLEMESİ

ÖZET

Diyabet, istikrarsız kan Őeker seviyelerinden kaynaklanan tedavisi mümkün olmayan ve yaŐamı tehdit eden bir durumdur ve dÜnya apında 400 milyondan fazla insanı etkilemektedir. Ölümcüllüğünün yanı sıra, diyabet vücuttaki eŐitli organlara zarar vererek eŐitli komplikasyonlara yol açabilir. Bazı hastaların diyabetin erken belirtilerini fark etmemesi durumunda, tanı konulduğunda organlarda ciddi hasarlar meydana gelebilir ve bunun sonucunda diyabetle iliŐkili yaklaşık 1.5 milyon ölüm meydana gelir. Diyabetle iliŐkili bir göz hastalığı olan diyabetik retinopati (DR), yüksek kan Őekeri seviyelerine baėlı olarak retinal kan damarlarında meydana gelen hasardan kaynaklanır. DR ilerledike, bulanık görme, aralıklı görme kaybı ve körlük gibi görme sorunları riski artar. Erken teŐhis, hastalığın ilerlemesiyle iliŐkilendirilen ciddi semptomların hafifletilmesine yardımcı olabilir.

alıŐma, farklı eėitim dönemi yapılandırmalarını inceleyerek bu incelemelerden elde edilen bulguları ve grafikleri karşılaŐtırıyor. Sonular, EfficientNET, DenseNET ve ResNet'in görüntü sınıflandırma görevlerine etkin bir şekilde katkıda bulunabileceėini göstermektedir. EfficientNET, diėerlerinden bile altı eėitim tekrarıyla daha iyi performans göstermektedir. Genel olarak, alıŐmanın sonuları, KSA mimarisinin seiminin kiŐisel tercihten ziyade ihtiyaca dayalı olması gerektiėini önermektedir. Sınıflandırma doėruluėunu deėerlendirmek için eŐitli deneyler yapılmıŐ, bu deneylerde SHAP yinelemeli ve küresel görüntüleme özümü ile eksuda ve kanama için toplam piksel sayılarının farklı kombinasyonları, eksuda ve kanlı bölgelerin sayıları kullanılmıŐtır. Sonular, tüm kullanılan sınıflandırıcı modellerde destek vektör makinesi tabanlı yaklaŐımın paracık sürü optimizasyonu ile daha yüksek doėru sınıflandırma oranlarına ulaŐmıŐtırėını göstermektedir. Son olarak,

bu tez, göz doktorları için tasarlanmış bir teşhis destek sistemi önermektedir, böylece hasta kalabalığından kaynaklanabilecek potansiyel karışıklıkları azaltır.

Anahtar Kelimeler: Retina Analizi, Medikal Veri Analizi, Makine Öğrenmesi, Evrimsel Sinir Ağları, SHAP Modelleme.

EARLY DIAGNOSIS MODELING OF DIABETIC RETINOPATHY USING SHAP VISUALIZATION TECHNIQUE AND MACHINE LEARNING METHODS

ABSTRACT

Diabetes is an incurable and life-threatening condition caused by unstable blood sugar levels, affecting over 400 million individuals worldwide. Besides its lethality, diabetes can lead to various complications by harming different organs in the body. As some patients may not recognize the early symptoms of diabetes, significant damage to organs can occur upon diagnosis, resulting in approximately 1.5 million deaths annually attributed to diabetes-related causes. Diabetic retinopathy (DR), an eye disease linked to diabetes, results from damage to retinal blood vessels due to elevated blood sugar levels. As DR progresses, the risk of vision problems such as blurriness, intermittent loss, and blindness increases. Early detection can help mitigate severe symptoms associated with disease progression.

The study delves into various training period configurations, comparing the findings and graphs obtained from these examinations. Results suggest that both EfficientNET, DenseNET and ResNet can effectively contribute to image classification tasks. EfficientNET performs better than its counterparts even with just six training iterations. Overall, the study's outcomes suggest that the choice of KSA architecture should be driven by necessity rather than personal preference. Various experiments are conducted to assess classification accuracy, employing different combinations of total pixel counts for exudate and hemorrhage, along with the numbers of exudate and hemorrhagic regions with using SHAP iterative and spherical imaging solution. Results indicate that the support vector machine-based approach with particle swarm optimization consistently achieves higher rates of correct classification compared to both the firefly and support vector machine-based approaches across all classifier models utilized. Ultimately, this thesis proposes a

diagnostic support system designed for ophthalmologists to mitigate potential confusion arising from patient overcrowding.

Keywords: Retinal Analysis, Medical Data Analysis, Machine Learning, Convolutional Neural Networks, SHAP Modeling.

İÇİNDEKİLER

ONUR SÖZÜ	iii
ÖNSÖZ.....	v
ÖZET.....	vii
ABSTRACT	ix
İÇİNDEKİLER	xi
KISALTMALAR LİSTESİ.....	xv
ŞEKİLLER LİSTESİ.....	xvii
ÇİZELGELER LİSTESİ.....	xxi
I. GİRİŞ.....	1
A. Teze Ait Problemin Tanımı.....	6
B. Teze Ait Literatür Taraması	8
C. Teze Ait Amaçlar ve Çalışmanın Önemi.....	14
D. Teze Ait Hipotez	15
E. Tezin Organizasyonu	16
II. GÖZİÇİ RETİNANIN YAPISI VE DİYABET İLE GÖZLENEN BOZUKLUK, DİYABETİK RETİNOPATİYE GENEL BİR BAKIŞ	17
A. Retinanın Anatomik Yapısı ve Görüntülenmesi	17
B. Diyabetik Retinopati (DR) Tanısı	19
1. DR Oluşum Mekanizma Tipleri.....	20
C. Retina İçinde Gözlenen DR Seviyesine ait Derecelendirilme.....	24
1. DR Dereceleri (Proliferatif, Normal, Hafif, Orta ve Yüksek Seviyeler)	25
2. NPDR ve PDR Sınıflamaları	26
D. Medikal Görüntüleme Teknikleri.....	27
E. Kaagle Açık Erişim DR Veriseti (APTOS 2019).....	29

F. Gürültülü Görüntülerde Düzeltme ve Optimizasyon (Veri İşlem Öncesi Ön İşlemler)	31
1. Kontrastla Sınırlanmış Histogramın Eşitlenmesi	32
2. Gri Tonlamalı Merkezleme ve Gama Düzeltmesi.....	34
3. DR Görüntü İçeriğinin Filtrenmesi, Optik Disk (OD) Odak Optimizasyonu	35
4. Gabor Filtrasyonu ile Retina Morfolojisi Kaynaklı Uç Değerlerin Filtrenmesi	36
III. METODOLOJİ.....	39
A. Konvolüsyonel Sinir Ağları Teknolojisi	39
B. Konvolüsyonel Sinir Ağlarının Mimarisi ve Katman Yapısı	41
C. Sinir Ağlarının Eğitimi İçin İyileştirme Algoritmaları, Stokastik Gradyan Degradasyon.....	42
D. Tasarlanan Mimari	42
1. EfficientNET	45
2. ResNET	47
3. DenseNET	49
E. SHAP (SHapley Additive exPlanations) Nesne Konumlandırması	50
IV. DENEYSEL ÇALIŞMAYA AİT BULGULAR	53
A. OD'nin Konumlandırılması.....	53
B. Optimizasyon Sonuçları	55
C. DR ve Mikroanevrizmaların Tespit Edilmesi.....	58
D. DR Lezyonlarının Tespitinde Başarım.....	64
1. Hesaplanan KSA Öznitelik Çıktıları	67
E. SHAP Küresel Modelleme Sonuçları	70
V. SONUÇ VE ÖNERİLER	79
VI. KAYNAKÇA.....	81
ÖZGEÇMİŞ.....	89

KISALTMALAR LİSTESİ

APTOS	: Asia Pacific Tele-Ophthalmology Society
DME	: Diabetic Macular Edema
DR	: Diyabetik Retinopati
DTPS	: Doğru Tespit edilmiş Piksel Sayısı
ESA	: Evrişimsel Sinir Ağları
FFA	: Fundus Floresan Anjiyografi
FNY	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
HCI	: Human-Computer Interaction
KSA	: Konvolüsyonanel Sinir Ağları
MLPNN	: Çok Katmanlı Sinir Ağı(Multi-Layer Perceptron Neural Network)
NPDR	: Nonproliferatif Diyabetik Retinopati
OD	: Optik Disk
PDR	: Proliferatif Diyabetik Retinopati
RBF	: Çapsal Tabanlı Fonksiyon (Radial Basis Function)
SHAP	: Shapley Addictive Explanations
SVM	: Destek Vektör Makinesi (Support Vector Machine)
TCC	: Toplam Doğru Sınıflandırma (Total Correct Classification)
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
TPS	: Toplam Piksel Sayısı

ŞEKİLLER LİSTESİ

- Şekil 1: İnsan gözünün anatomisi ve Retina'nın temel isimlendirme ve konumlandırılması. 4
- Şekil 2: Normal ve retinopatiye sahip farklı retinalara ait anatomik görüntülemelerde gözlenen farklılıklar. 5
- Şekil 3: FFA tekniği kullanılarak elde edilen sağlıklı retina görüntüsü (solda), ve yine aynı teknikte ileri düzey DR tanısı konulan bir retina görüntüsü (sağda) sunulmuştur. 19
- Şekil 4: Retina içerisinde gözlenen yumuşak eksudatlar. Eksudatların etrafındaki sıvının genişlemesiyle birlikte retina bölgesinde gelişen pamukçuk lekeleri, hem hızlı hem de şiddetli semptomlara neden olmaktadır..... 21
- Şekil 5: Retina içerisinde gözlenen yumuşak eksudatların genişlemesiyle oluşan sert eksudatlar. 22
- Şekil 6: Retina içerisinde gözlenen kırmızı alev olarka nitelendirilen ve kanama noktalarını gösteren kan pıhtı kümeleri..... 23
- Şekil 7: Retina içerisinde gözlenen ve DR tespitinde gürültü olarak nitelendirilen sağlıklı mikroanevrizmalar..... 24
- Şekil 8: Retina içerisinde gözlenen DR'nin aşamaları, Ramasamy et al. (2021) tarafından belirlenen sırasıyla A-E: Proliferatif, Normal, Hafif, Orta ve Yüksek Seviye aşamalarıdır. 25
- Şekil 9: Yüksek seviyeli DR gözlenen bir hasanın Sol taraftaki normal retina, sağ taraftaki (DR) olan retina ile karşılaştırılmıştır..... 25
- Şekil 10: Retinaya ait dijital görüntü veren oftalmoskop cihazları..... 27
- Şekil 11: Uluslararası Klinik Diyabetik Retinopati Hastalık Şiddeti Ölçeği, genel olarak DR şiddetini pratik olarak saptamak amacıyla oluşturulmuş, ancak kullanımı kısıtlı olması ve gelişen teknoloji sebebiyle kullanım dışı kalmıştır. 28

Şekil 12: APTOS 2019 veri setindeki görüntülerin sınıflara göre dağılımı.....	30
Şekil 13: APTOS-2019 veri kümesinden rastgele seçilmiş 15 retina görüntüsü, otomatik DR Tespiti için özel olarak oluşturulmuş bir görüntü koleksiyonunu içermektedir.....	31
Şekil 14: Retina görüntüleri ve görüntülere ait eşitlenmemiş (üstte) ve eşitlenmiş (altta) histogram kayıtları.....	33
Şekil 15: Adaptif histogram eşitlemesi uygulaması.....	34
Şekil 16: Retina görüntüsünde griye dönüştürülen retina görüntülerinde parlaklık/karşıtlık ayarlama örneği.....	35
Şekil 17: Retina görüntüsü üzerinde çembersel Optik Disk (OD) odak optimizasyonu dönüşümünün uygulanması.....	36
Şekil 18: Gabor dönüşümü ile elde edilen retina görüntüsü	38
Şekil 19: KSA mimarisinde gözlenen gizli katmanlar	41
Şekil 20: Üç boyutlu olarak tasarlanan KSA katmanlarına ait şematik görünüm.....	41
Şekil 21: KSA mimarisinin temel bileşenleri.....	42
Şekil 22: Önerilen yöntem için KSA tabanlı genel akış şeması.....	43
Şekil 23: EfficientNet'in temel mimarisi.....	46
Şekil 24: Bu tez kapsamında geliştirilen ön filtreleme işlem basamaklarının ardından oluşturulan sınıflamaya yönelik hazırlanan blok model	47
Şekil 25: Resnet'in temel mimarisi.....	48
Şekil 26: DenseNet Ağ Modeli	50
Şekil 27: Üç yoğun bloktan oluşan derin bir DenseNet mimarisini göstermektedir. İki ardışık bloğu birbirine bağlayan katmanlar, özellik haritalarının boyutunu güncellemek için evrişim ve havuzlama işlemlerini kullanan geçiş katmanları olarak adlandırılır.	50
Şekil 28: SHAP model ve rezüel değerlerin hesaplanmasına yönelik oluşturulan sinir ağı	52

Şekil 29: Farklı DR seviyelerine sahip retina görüntülerinden elde edilen küresel SHAP modellemelerine ait örnek görüntü kümeleri.....	52
Şekil 30: Rastgele seçilmiş DR içerikli retina görüntüsünden elde edilen OD birimi	54
Şekil 31: Üst kısımda yer alan rastgele seçilmiş DR içerikli retina görüntüsünün, (üst-solda), k-means algoritması ile renk tayfının otomatik olarak belirlenmesi (üst-sağda) ve alt kısımda ise OD'nin tüm görüntüden farklı olarak sınırlarının oluşturulması ..	55
Şekil 32: APTOS-2019 veri setindeki görüntülerin ön işleme aşamasında yer alan piksel sınırlama işlemine ait örnekler, görüntülerin kontrastını artırmak ve belirli alanlardaki detayları vurgulamak için kullanılan bir tekniktir. Bu işlem, görüntülerdeki piksel değerlerini sınırlayarak renk aralığını daraltır ve belirli bir aralıkta yoğunlaşmasını sağlar	57
Şekil 33: Rastgele seçilen ve veri işlem öncesi filtrelerin uygulandığı DR görüntüsü (üstte) ve kullanılan damar filtreleri ile çıkarılan indislere ait örnekler (altta).....	58
Şekil 34: Üç temel modelin birleşik model için girdi olarak kullanılmasını ve ardından birleşik modelin buna dayanarak tahmin yapacağını göstermektedir.	60
Şekil 35: EfficientNET KSA'nın altı epok değeri için sahip olduğu hassasiyet değerleri	61
Şekil 36: EfficientNET KSA'nın yirmi epok değeri için sahip olduğu hassasiyet değerleri	61
Şekil 37: Resnet KSA'nın altı epok değeri için sahip olduğu hassasiyet değerleri ...	62
Şekil 38: Resnet KSA'nın yirmi epok değeri için sahip olduğu hassasiyet değerleri	63
Şekil 39: DenseNET KSA'nın altı epok değeri için sahip olduğu hassasiyet değerleri	63
Şekil 40: DenseNET KSA'nın yirmi epok değeri için sahip olduğu hassasiyet değerleri	64
Şekil 41: Önceden eğitilmiş bir K mimarisi şematik görünümü. Üçüncü adımda, çıkarılan özelliklere bir havuzlama işlemi uygulanır ve bir özellik vektörü elde edilir.	65

Şekil 42: Manuel olarak bölütlenen eksudatları temsil eden pikseller (Kırmızı), otomatik olarak bölütlenenleri (Yeşil) ve her iki yöntemle de tespit edilenleri (Sarı) gösterir.....	66
Şekil 43: Retinal kanamaların bölütlenmesi sergilenmektedir. Uzman doktor tarafından elle tanımlanmış kanamalar kırmızı, otomatik olarak bölütlenmiş kanamalar yeşil, her iki yöntemle de tespit edilmiş kanama pikselleri ise sarı renkte gösterilmiştir	66
Şekil 44: Mikroanevrizma noktalarına ait bulgular verilmektedir.Uzman doktor tarafından elle tanımlanmış kanamalar kırmızı, otomatik olarak bölütlenmiş kanamalar yeşil, her iki yöntemle de tespit edilmiş kanama pikselleri ise sarı renkte gösterilmiştir	67
Şekil 45: DR durumunu tespit etmek için kullanılan göz alanlarını gösteren örnek görüntüler	71
Şekil 46: Çoklu sınıflandırma görevi için kayıp ve doğruluk diyagramları, öğrenme sürecinde aşırı uyum olmadığını göstermektedir.	72
Şekil 47: SHAP değerlerinin kartezyene taşınmasına.....	73
Şekil 48: Rastgele alınmış normal fundus görüntüleri için	74
Şekil 49: Üretilen SHAP modelleme sonuçlarında gözlenen, DR =2 ve DR= 3 seviye retinalardan elde edilen yüksek polariteye sahip sonuçlar.	76
Şekil 50: Proliferatif DR kategorisinden örnek yanlış sınıflandırılmış bir görüntü. SHAP analiz sonucu, bu örneğin neden orta düzey DR'ye (DR seviye = 2) yanlış sınıflandırıldığını açıklamaya yardımcı olmaktadır.	77

ÇİZELGELER LİSTESİ

Çizelge 1: Lezyonların sınıflandırılması için kullanılan şekil öznitelikleri..... 68

I. GİRİŞ

Geçtiğimiz on yıl içerisinde görüntü işleme teknolojisine ait veri işlem detaylarının gelişmesi ile akademik tabanlı araştırmacılar ve tıbbi uzmanlar, görüntü analizine ait işlem formasyonlarını ve süreçlerini kapsamlı bir şekilde araştırmış ve farklı alt başlıklarla değerlendirmişlerdir. Günümüzde tıbbi görüntüleme yalnızca her hangi bir hastalığa ait tıbbi teşhis süreçlerinde değil, aynı zamanda bireylere sağlanan sağlık ve tedavinin gerek uygulama gerekse görülemeyene ulaşma ekseninde yer alan farklı teşhis yöntemlerinde de hayati bir rol oynamaktadır. Örneğin, temel tıbbi görüntülerin basit filtrelerden günümüzde yapay zeka dahil çok farklı prosedürlerle işlenmesi, ayrıştırılması, analizi, ortamlar arasında geçişi ve modellenmesi ile teşhis ve tedaviye hazırlanmasına ait süreçler, bu alandaki gelişmelerin önemli bir sonucunu oluşturmaktadır (Rodríguez et al., 2008).

Farklı görüntüleme cihazları kaynaklı dijital görüntüler üzerine yapılan araştırmalar, tıp literatüründe yer alan tanı ilkesine dayalı çok çeşitli uygulama alanlarına sahip olmaları nedeniyle günümüzde farklı ölçekli sağlık kuruluşlarında en rağbet gören kullanım oranlarına sahiptir. Bu araştırmaların geniş kapsamlı etkileri, tıp alanındaki teşhis ve tedavi süreçlerinden endüstriyel uygulamalara kadar birçok alanda görülmektedir (Nayak et al., 2009). Dijital görüntülerin analizi ve işlenmesi, matematiksel modellemelerle entegre edilerek görüntüleme tekniklerinin geliştirilmesine imkan sağlamaktadır. Bu yaklaşım, çeşitli hastalıkların erken tespiti ve izlenmesi süreçlerine önemli bir katkı sunmaktadır. Özellikle, gelişmiş analiz yöntemleri ve veri işleme algoritmalarıyla birleştirilen dijital görüntüleme teknolojileri, sağlık uzmanlarının daha hassas teşhisler koymasına ve tedavi süreçlerini daha etkili bir şekilde yönetmelerine olanak tanımaktadır. Bu sayede, hastaların sağlık durumlarını daha erken ve daha doğru bir şekilde değerlendirmek mümkün olmakta ve tedavi başarısı artmaktadır.

Son on yılda bahsedilen bu endüstriyel gelişmeler, sağlık sektöründe sunulan tedavi kalitesini artırmak için dijital görüntüleme teknolojilerinin kullanımını büyük ölçüde desteklemektedir. Yüksek çözünürlüklü görüntülerin elde edilmesi ve hızlı veri analizi sayesinde, başta nöro ve ileri cerrahi müdahalelerin çok daha hassas, etkili ve kısa süreli tedaviye cevap verecek bir şekilde gerçekleştirilmesi mümkün hale gelmiştir. Ayrıca, dijital görüntüleme teknolojilerinin kullanımı, tedavi süreçlerinin izlenmesi ve hastaların durumlarının değerlendirilmesinde önemli bir rol oynamaktadır. Bu teknolojiler, sağlık profesyonellerine hastaların tedavi yanıtlarını ve genel sağlık durumlarını daha ayrıntılı bir şekilde inceleme ve takip etme imkanı sunar. Bu da tıbbi karar verme süreçlerini destekler ve sağlık hizmetlerinin kalitesini artırır. Özellikle, dijital görüntüleme teknolojileri, sağlık uzmanlarına hastaların tedaviye olan yanıtlarını gerçek zamanlı olarak izleme ve değerlendirme fırsatı vererek tedavi süreçlerini optimize etmelerine yardımcı olur. Bu sayede, hastaların sağlık sonuçları iyileştirilirken, tıbbi kaynakların daha etkin ve verimli bir şekilde kullanılması sağlanmaktadır. Bu bağlamda, dijital görüntüleme alanındaki araştırmalar ve teknolojik gelişmeler, tıp ve endüstri alanlarında önemli bir etkiye sahiptir ve gelecekte daha da büyük önem kazanması beklenmektedir.


Belirtilen bu gelişmelerin insan gözü üzerinde görüntüleme teknikleri ile tespit edilip tedavisine başlanan ve diyabet kaynaklı bir işlev bozukluğu olarak tanımlandırılan Diyabetik retinopati (DR), diyabetin ciddi ve potansiyel olarak yaşamı tehdit eden bir sonucu olarak giderek daha fazla önem kazanmaktadır (Singh ve Tripathi, 2010). Bu durum, gözleri etkileyen ve aynı zamanda insan vücudunda diyabetin başlangıcını haber verebilen bir bozukluktur. İnsan vücudunda diyabet, bir dizi ciddi komplikasyona rastgele veya belirli bir ardıno düzeninde neden olabilir. Retina hastalığı olarak bilinen DR, farklı aşamalara sahip ve ilerleme sekanslarında yer alan tedavi aksamalarında göz içerisinde körlüğe kadar yol açabilen çok ciddi bir risk taşımakta, (Sopharak et al., 2008) ve insan vücudunda ilerleyen yaşla birlikte geliştirme riski artmaktadır. Bu komplikasyonlardan biri de, damar şekil ve geometrilerinin değişmesiyle paralel retinanın arka kısmında meydana gelen DR, dış retinada anormal kan damarlarının büyümesi ve gelişimi ile karakterizedir. Vücut içi tanı ve inceleme yöntemlerindeki ilerlemeler, tıbbi uzmanların hastalığın doğru bir şekilde teşhis etmelerine, uygun tedavi stratejilerini uygulamalarına, hastanın ilerlemesini izlemelerine ve yenilikçi tedavi seçenekleri geliştirmelerine olanak

tanınmıştır. Mevcut gelişmeler sayesinde, DR gibi ciddi komplikasyonların erken teşhisi ve etkili müdahaleleri mümkün hale gelerek, hastaların yaşam kalitesi ve görsel sağlık durumları önemli ölçüde iyileştirilebilmektedir.

Retina içerisinde DR koşullarının gözlenmesi içerisinde bu anormal kan damarlarının büyümesi, retinanın iç kısmındaki damarlardan sızıntıya ve retinanın arka lobunda eksudat birikimine neden olabilir (Dalillah vd., 2024). Retina, insan gözündeki en karmaşık ve çok katmanlı yapılarından biridir ve bu nedenle, herhangi bir göz sağlığı sorunuyla ilgili olarak önemli bir rol oynar. Gözlerdeki görüşte bulanıklığın nedenleri çeşitli olabilir; bunlar arasında diyabetik retinopati gibi ciddi komplikasyonlar da yer almaktadır. Bu hastalık, diyabetin bir sonucu olarak gelişen ve retina dokusunu etkileyen potansiyel olarak ciddi bir durumdur. Ancak, günümüzde, medikal teknolojinin ilerlemesi ve tıbbi görüntüleme tekniklerindeki gelişmeler sayesinde, diyabetin teşhisi için bir dizi çağdaş yöntem bulunmaktadır. Bu durum, hastaların düzenli göz muayenelerine tabi tutulmalarının önemini daha da vurgulamaktadır. Çünkü erken teşhis, hastalığın ilerlemesini yönetmek ve etkili tedavi stratejileri uygulamak için kritik bir faktördür. Özellikle, retinal mikrodamar anevrizmaları, kanama ve eksudatlar (anormal yağ kitlelerinden sızmış olan sıvı) gibi belirtiler, göz muayenesi sırasında tespit edilebilecek en endişe verici bulgulardan bazılarıdır. Bu bulguların erken tespiti, diyabetik retinopatinin ilerlemesini kontrol etmek ve tedaviye hızla yanıt vermek için kritik öneme sahiptir, böylece hastaların görme sağlığı ve yaşam kalitesi korunabilir.

Bu hastalığa sahip bir hasta, retinasında kırmızılık lekeleri görebilir. Bu lekeler, gerçekte mikrovasküler anevrizmalardır. Retina içindeki kan damarlarının zarar görmesinden dolayı retina içindeki kan damarlarının onarıma yeteneğini kaybetmesi sonucu retina içinde kanamalar oluşur, bu da kanın damarlardan sızmasına neden olur (Sopharak et al., 2008). "Eksudat" terimi, anormal yağ kitlelerinden sızmış olan sıvıyı ifade eder ki bu, anormal büyümüş kan damarları içinde veya anormal şekilde genişlemiş kan damarlarından sızmış olabilir. Fovea ise retinanın ortasındaki bölgedir ve insanların en net görüşe sahip olduğu alandır. Mevcut tıbbi yöntemler içerisinde yer alan retinopati için kullanılan tanı yöntemleri, zaman alıcı, ulaşılması zor ve maliyetli niteliktedir. Diyabetik retinopatinin hızlı ilerleyişi, sağlık hizmetleri açısından önemli ve derhal endişe verici bir neden teşkil etmektedir. Dünya Sağlık Örgütü (DSÖ) tarafından yapılan projeksiyonlara göre, şu anda bu durumdan etkilenen insan


sayısının gelecekte artması beklenmektedir. Bunların çoğunun DR rahatsızlığına sahip olduklarının farkında olmamaları ise en büyük riski oluşturan faktördür. Araştırmacılar, 2040 yılına kadar diyabet hastalığıyla yaşayan insan sayısının 642 milyon olacağını tahmin etmektedir (Wong ve Sabanayagam, 2020). Bu kişilerin üçte birinin retinopati geliştirme riski bulunmaktadır. Şekil 1, retina anatomisinin bir temsili iken, Şekil 2, retina normal ve anormal versiyonlarının bir temsili şeklindedir. Bu veriler, diyabetik retinopatinin giderek artan bir küresel endişe kaynağı olduğunu göstermektedir. Ancak, bu durumun çoğu zaman semptomatik olmaması ve bireylerin enfekte olduklarının farkında olmamaları, hastalığın erken teşhisini ve etkili tedaviyi zorlaştıran bir faktör olarak ön plana çıkmaktadır. Bu nedenle, düzenli göz muayeneleri ve diyabet yönetimi önlemleri, DR riskini azaltmak ve hastalığın ilerlemesini kontrol altında tutmak için kritik öneme sahiptir.



Şekil 1: İnsan gözünün anatomisi ve Retina'nın temel isimlendirme ve konumlandırılması.

Bir dizi tıbbi görüntüleme yöntemi kombinasyonu kullanılarak, retinopati birçok aşamasında ve ilerleme evresinde tanımlanabilir ve sınıflandırılabilir. Bu koşulları hastalarda tanımlamak için bir dizi farklı görüntüleme yöntemi kullanılabilir, ancak tıp alanındaki uzmanların büyük çoğunluğu tarafından, görüntülemenin hem en güvenilir hem de en sık kullanılan yöntem olduğuna inanılmaktadır. Retinopati tanımlanması ve vakaların şiddet derecesine göre sınıflandırılması amacıyla

görüntüleme prosedürleri kullanılmaktadır. İnsanlardaki bu ve benzeri hastalıkları teşhis etmek için bir dizi yöntemden biri olan görüntüleme, genellikle en kapsamlı ve detaylı yöntem olarak kabul edilmektedir. Retinal hastalığın tanımlanması, doğru bir teşhise büyük ölçüde bağlıdır.



Şekil 2: Normal ve retinopatiye sahip farklı retinalara ait anatomik görüntülemelerde gözlenen farklılıklar.

Bu doktora tezinin başlıca amacı, DR hastalığının aşamalarının erken tespiti ve belirtilere dayalı olarak hastalığın segmentasyonu ve sınıflandırılmasıyla retinopati hastalığının tanımlanmasına yardımcı olacak bir makine öğrenimi (Machine Learning – ML) ve küresel nesne konumlandırma modeli ile lezyonlara ait üç boyutlu kestirim modellerinin oluşturulmasıyla DR koşullarına sahip kan damarlarına ait konum, hacim ve DR sınıfına ait nicel sonuçlar önermektedir.

Bu, bir göz doktorunun aynı gün içinde bu kişinin retinası içerisinde DR koşullarının oluşup oluşmadığını saptayacak, dolayısıyla hızlı bir şekilde tanı ve tedavi koşullarının belirlenmesine olanak tanıyacaktır. Bu bağlamda, muayene süresini kısaltan, hastanın masraflarını azaltan ve test prosedürü sırasında vücutlarında endişe ve rahatsızlık yaşayan hastaların oranını düşüren bir yöntem tasarlamak amaçlanmıştır. Bu tür bir model, DR'yi erken evrelerde teşhis etme yeteneğine sahip olabilmekte ve literatürde yer alan benzer çalışmalara kıyasla tedaviye başlama sürecini hızlandırarak hastalıkla ilgili olası komplikasyon riskini azaltabilmektedir. Ayrıca, bu yöntemler bütünü, hastaların sağlık hizmetlerine erişimini kolaylaştırarak, sağlık eşitsizliklerinin azaltılmasına ve sağlık hizmetlerinin daha adil bir şekilde

dağıtılmasına katkıda bulunabilir. Bu nedenle, DR'nin erken teşhisinde ve tedavisinde kullanılacak etkili bir makine öğrenimi modelinin geliştirilmesi, hem sağlık hizmetlerinin kalitesini artırmak hem de bireylerin yaşam kalitesini iyileştirmek için büyük önem taşımaktadır.

A. Teze Ait Problemin Tanımı

Şeker hastalığı, kan şekeri düzensizlikleri ile ilişkilendirilen kronik ve ölümcül bir hastalıktır. Kalp, kan damarları, gözler ve sinirler gibi birçok insan vücut bölgesinde hasara neden olur. Diyabet, iki türde görülebilir. Tip 1 diyabet, pankreasın kan şekerini dengelemek için yeterli miktarda insülin üretmediği bir hastalıktır. Tip 2 diyabette ise Tip 1 diyabette görülen insülin eksikliğine ek olarak insülin direnci vücuda kritik şekilde etki eder. Dünya Sağlık Örgütü (DSÖ) raporlarına göre (Singh et al., 2010; Sabirjanevich vd., 2024), dünya genelinde 400 milyondan fazla insan diyabetten muzdarip olup, her yıl diyabetle ilişkili 1.6 milyon ölüm kaydedilmektedir. Ayrıca, diyabetiklerin sayısı her geçen yıl artmaktadır. Bu nedenle, erken evre tespiti, diyabetin etkilerini azaltma açısından önemlidir.

Literatürde yer alan araştırmalar, diyabetin teşhis edilmeden önce 4 ila 12 yıl boyunca ilerleyebileceğini belirtmektedir (Singh et al., 2010). Diyabetle ilişkili hasarın teşhis yapıldığında hastaların yarısında zaten meydana geldiği belirtilmektedir. Bu araştırmalar dahilinde, diyabetin erken teşhisinin kalp, göz, böbrek ve damar sistemi ile ilgili hastalıkları önlemeye yardımcı olacağını belirtmektedir (Hiller et al., 1988). Bu nedenle, erken teşhis hastalığın etkilerini azaltmak ve hastaların mevcut yaşam kalitesini artırmak için çok önemlidir. Yüksek kan şekeri seviyelerinden kaynaklanan komplikasyonun retina damarlarında hasara neden olmasıyla oluşan DR seviyelerini gerçekleştirme fazlarına göre gruplayan Melcaldo et al. (2017), sınıflama kriterlerini belirleyerek "*proliferatif*" ve "*non-proliferatif*" adlı iki ana fazın varlığını tespit etmiştir.

Non-proliferatif faz, hastalığın erken evresidir ve genellikle retinanın küçük damarlarının sızdırması sonucu bulanık görüğe neden olmaktadır. Bununla birlikte, proliferatif faz, DR'nin ileri evresidir ve non-proliferatif evrede teşhis edilmediği takdirde, retina kolayca kanayan yeni damarlar büyötmeye başlar. Bu kanamaların büyüklüğü, aralıklı veya tamamen görme kaybının olasılığını artırır (Chen and Pan,

2018). Bu durumlar, DR'nin ciddiyetini ve etkilerini vurgularken, erken teşhis ve uygun tedavi önlemlerinin önemini de ortaya koymaktadır. DR, görsel sağlık açısından ciddi bir tehdit oluşturduğundan, hastaların düzenli göz muayeneleri yaptırması ve sağlıklı yaşam tarzı seçimleri yapması, bu hastalığın etkilerini azaltmak için kritik öneme sahiptir.

DR'nin en tehlikeli ve kritik kısmı, belirgin erken semptomların eksikliğidir (Joshi and Priyanka,). DR, başlangıçta sessiz bir şekilde ilerleyebilir ve semptomlar gözle görülmeden önce ciddi hasara yol açabilir. Bu nedenle, erken teşhis çok önemlidir. Diyabetik göz taraması, DR'nin erken teşhisi için diyabetlilere yılda bir kez önerilmektedir. Bu tarama sırasında, gözlerin arkasındaki damarların görüntüleri çekilir. Bu, hastanın görüşünü etkilemeden önce potansiyel sorunları belirlemeye yardımcı olmaktadır (Joshi and Priyanka, 2015). Erken teşhis konan hastalar, yaşam tarzı değişiklikleri yaparak ve düzenli olarak göz muayenelerine devam ederek, DR'nin olası yan etkilerini minimize edebilir ve sağlıklı bir şekilde yaşamlarını sürdürebilirler. Bu nedenle, diyabetli bireylerin düzenli göz taramalarına katılması, görsel sağlık açısından kritik bir öneme sahiptir.

Makine öğrenimi, yapay zekanın bir alt alanı olup, veriyi kullanarak karmaşık problemler için öngörü modelleri oluşturmayı amaçlar (Başer et al., 2021). Bu, veri analizi ve öğrenim koşullu hastalık koşullarını oluşturan etmen ve koşul parametre bilgilerin kazanımı için kullanılmaktadır. Ayrıca, mevcut verileri kullanarak görünmeyen verilerin tahmin edilmesi, makine öğrenimi metodolojilerinin birçok farklı alanda uygulanmasını mümkün kılmaktadır. Bu bilgiler temelinde, makine öğrenimi metodolojileri, tıp alanında mevcut verilerden doku üzerinde yer alan desen anlama ve dokulara ait bilgi çekme amacıyla kullanılarak sağlık problemlerinin gelecekteki eğilimlerini tahmin etmekte de uygulanabilir. Örneğin, polidipsi, poliüri, kaşıntı, polifaji ve geç iyileşme gibi bazı belirtiler şeker hastalığının erken belirtileri olarak halihazırda bilinmektedir. Ancak, sağlıklı bireyler de bu sorunlardan bazılarını yaşayabilir. DR teşhisi için doktorlar tarafından retinopati tarama görüntüleri incelenir. Teşhis için retinal özellikler ve kan damarları gözden geçirilir. Doktorlar tarafından retinal görüntülerin incelenmesi uzun ve zahmetli bir görevdir. Bu süreç, derin öğrenme yöntemleri ile otomatik hale getirilebilir. Derin öğrenme, karmaşık problemleri çözmek için insan beyninin aktivitelerini taklit etmeye çalışan bilgisayar bilimlerinin bir alt dalıdır (Bilgin, 2021). Derin öğrenme yöntemlerinin

kullanılmasıyla ilgili, özellikle makine öğrenmesinin derinleşmesiyle birlikte, tıbbi görüntüleme alanında oldukça heyecan verici bir gelişme yaşanmaktadır. Ancak, mevcut literatürde derin öğrenme ile elde edilen sonuçların derlenmesi ve yorumlanmasına yönelik bir problem bulunmaktadır. Özellikle, diyabet retinopatisi gibi durumlar için derin öğrenme algoritmalarıyla elde edilen sonuçların klinik olarak yorumlanabilirliği ve doğruluğu hakkında güvenilirlik eksikliği vardır. Bu, hastalıkların doğru teşhis edilmesi ve tedavi planlarının belirlenmesi açısından kritik öneme sahiptir. Dolayısıyla, mevcut literatürde, derin öğrenme ile elde edilen sonuçların güvenilir ve yorumlanabilir hale getirilmesine yönelik bir problem bulunmaktadır ve bu alanda daha fazla araştırmaya ihtiyaç duyulmaktadır.

B. Teze Ait Literatür Taraması

Diyabetin en ciddi ve potansiyel olarak körlüğe neden olan etkilerinden biri diyabetik retinopati (DR) olarak adlandırılmaktadır. Hastalığın ilerlemesini kontrol etmek ve gerek potansiyel gerekse DR etkilerinin gözlemlendiği görme kusurlu bireylere destek sağlamak amacıyla erken teşhis kritik oldukça önemli bir öneme sahiptir. Bu bağlamda, DR oluşumunu izlemek ve anlamak için düzenli tarama süreçlerinin sık sık gerçekleştirilmesi önerilmektedir. Göz doktorlarının, retinopatiye özgü fundus görüntülerini etkin bir şekilde tespit edip sınıflandırabilmesi, ayrıca bu hastalık nedeniyle oluşabilecek körlük riskini azaltabilmesi için güçlü bir algoritmanın varlığı gereklidir (Wong ve Sabanayagam, 2020). Bu sebeple, araştırmacılar yakın geçmişte artan bir ivme ile DR teşhisini destekleyebilecek çeşitli görüntü analizi yöntemlerini araştırma ve geliştirme çabalarına yönelmişlerdir. Günümüzde, görüntü işleme alanında çeşitli teknikler bulunmaktadır. Bu teknikler arasında yapay zeka, uzmanlaşmış donanım ve algoritmalar gibi yöntemler öne çıkmaktadır. Bu teknikler, siyah-beyaz ve renkli görüntüler kullanılarak normal bir retina ile işlevsiz bir retina arasındaki farkları belirleyebilir ve ardından işlevsiz retinanın çeşitli hastalıklara sınıflandırılmasını sağlayabilir. Bu yaklaşım, görüntü işleme alanında hastalık teşhisi ve sınıflandırmasında önemli bir adım olarak kabul edilmektedir. Önceki araştırmaların özlu bir genel bakışı sunularak, bu tekniklerin sistemleri, metodolojileri ve gelişme aşamaları detaylı bir şekilde ele alınacaktır.

Microaneurizmalar, küçük boyutları, kırmızı rengi ve belirgin yuvarlak yapısı ile karakterize edilen lezyonlardır (Flickner et al., 1995). Bu lezyonların otomatik tanımlanması üzerine odaklanan araştırmalarda, genellikle fundus görüntülerine geleneksel görüntü işleme metodolojileri uygulanmıştır. İlk adımlar, optik disk ve retinanın kan damarları gibi anatomik bölgelerin çıkarılması gibi görevleri içermiştir. Krizhevsky et al. (2012) tarafından yapılan bir çalışmada, gözetimli vektör nicemleme ile oluşturulan bir yapay sinir ağı, başarılı bir şekilde mikroanevrizmaların tespitini göstermiştir. Bu modelleme yaklaşımı, mikroanevrizmaların tespitinin doğruluğunu artırma potansiyeline sahip olsa da, genellikle uzun bir zaman dilimini gerektirebilir.

Qummar ve diğ. (2019), tahminlerde bulunmak için en bilgilendirici özellikleri keşfetmek için veri setini analiz ederek “*Symmetrical ve Correlation Attribute Evaluator*” gibi birkaç özellik değerlendirme yöntemini uyguladılar. Özellik seçimi adımından sonra, Random Forest, KN Yakın Komşu, karar ağacı ve Naive Bayes yöntemlerini “*SEQA*” adlı bir makine öğrenimi aracı kutusu kullanarak uyguladılar. Sonuçlar, 10 katlı çapraz doğrulama şemasını kullanarak değerlendirildi. Bu çalışmada gözlemlenen en yüksek doğruluk oranı, Random Forest yöntemi kullanılarak elde edilen %98,31'lük değer ile oldukça isabetli bir kestirim seviyesine sahip olsa da, kullanılan karar verici parametrelerin oluşturduğu gelişigüzel gürültülerin de DR olarak betimlenmesini engelleyememiştir. Bu doktora tez çalışmasında ise bu tip gürültülerin giderimine yönelik Gürültülü Görüntülerde Düzeltme ve Optimizasyon başlığında yer alan işlem basamakları yer almaktadır.

Qummar ve diğ. (2019) tarafından çalışılan veri seti üzerinde Quiao et al. (2020) tarafından yapılan bir diğer çalışmada, çok katmanlı algılayıcıyı optimize etmek için “*Adaptif Parçacık Sürüsü Optimizasyon*” seçim algoritması ve yöntemleri kullanılmıştır. Elde edilen sonuçlar, karar ağacı, random forest, destek vektör makinesi, naive bayes, KN yakın komşu ve lojistik regresyon gibi birçok makine öğrenimi yöntemi ile karşılaştırılmıştır. Model değerlendirmesi için 85:15 oranında eğitim ve test bölünmesi kullanılmış ve önerilen optimizasyon tabanlı çok katmanlı algılayıcı kullanılarak ortalama ~%94 doğruluk ve kestirim kabiliyetine erişilmiştir. Buna ek olarak Tao et al. (2019) tarafından aynı veri seti üzerinde yürütülen bir çalışma içerisinde karar ağacını içeren random forest yöntemini uyguladılar. %98,08 doğruluk ve %99,79 (Rate of Change) ROC skoru bildirmişlerdir. Başka bir araştırmada Shaban et al. (2020), erken aşama diyabet riski tahmin veri seti üzerinde

K en yakın komşu algoritması uygulanarak %98,08 doğruluk elde edilmiştir. Ayrıca, çok katmanlı algılayıcı, karar ağacı, destek vektör makinesi, lineer ayırım analizi ve ensemble öğrenme algoritmaları gibi birçok makine öğrenimi yöntemi de uygulanmış ve diyabetin erken teşhisi için bir kiti geliştirilmiştir. Genellikle kullanılan makine öğrenimi uygulamalarından farklı olarak, Tiwari ve Singh (2021) tarafından aynı veri seti üzerinde zaman alanına özgü bir derin öğrenme yaklaşımı kullanılarak ortalama ROC skoru %98,9 olarak bildirilmiştir. Bu çalışmalarda kullanılan verisetleri optimuma yakın görüntülere sahip olmasından ötürü güncel tıp konjektörüne uzak kalmasından dolayı geniş veri setleri kullanan diğer çalışmalar tarafından eleştirel bir bakış açısı getirilmektedir.

Retina görüntülerinin işlenmesi için kullanılan yazılım ile retinadaki kılcal damarların biçim dışı biçimlenme (exude) varlığını vurgulayarak, Franklin et al. (2014), retinopatiyi tanımlama yeteneğine sahip olmuşlardır. Bu salgınların doğrudan bir sonucu olarak meydana gelen belirgin ton değişimleri herhangi bir çaba sarf etmeden gözlemlenebilmektedir. Bu hedefi gerçekleştirmek için, bir yapay sinir ağı, tıbbi profesyoneller tarafından verilen referans görüntülerin boyutları, renkleri, görünüşleri ve dokuları temelinde tahminler üretmek üzere eğitilmiştir.

Jahiruzzaman and Hossain (2016), k-mean metodolojisi şeklinde sunulan bir yöntemle DR'nin tanımlanması ve teşhisi için bir yöntem sundular. Bu metodolojide, doğrudan k-mean algoritması kullanarak görüntüleri nasıl segmente edileceği gösterilmektedir. Direk yaklaşımın kullanılmasının ardından, bulguları daha da iyileştirmek amacıyla geliştirilmiş k-mean algoritması veri üzerinde uygulanmıştır. Önerilen teknikler, k-means kullanılarak görüntü segmentasyonu için gerekli işleme süresini kısaltma potansiyeline sahip olurken yüksek bir doğruluk seviyesinin korunmasına imkan tanınmaktadır. Szegedy et al.(2016) tarafından da her birinde benzersiz bir renk uzayı kullanılan bir dizi deneyde, görüntülerin segmente edilmesinin daha keskin görüntülerin üretilmesini sağladığını ve renk ayırımını iyileştirdiğini gösterilmiştir.

Banerjee et al. (2018) farklı veritabanlarından alınan görüntülerle bağlamsal verileri entegre eden bir yöntem sunmaktadır. Bu nedenle, görsel ve bağlamsal bilgileri içeren karar ağaçları geliştirilmiştir. Görüntüler, temel bileşenlerin çıkarılabilmesi ve çeşitli hastalıkları göstermek için bölünmüş ve önışlemeden geçirilmiş olmalıdır.

Prototipin karmaşık görüntüleri, ilişkilendirilmiş bağlamsal bilgiler içindeki bilgiler oldukça benzer olduğundan, doğrudan filtrelenmiş karmaşık görüntülerle eşleştirilmektedir. Bu yaklaşım, görüntülerin daha anlamlı ve bilgilendirici hale gelmesini sağlar, böylece temel bileşenlerin daha doğru bir şekilde belirlenmesine ve DR gibi hastalıkların tanımlanmasına olanak tanınmaktadır.

Pratt et al., (2016), kolay bir otomatik teşhis sunma amacıyla geliştirilmiş bir “*Evrişimli Sinir Ağı (ESA)*” teknolojisi kullanmışlardır. Bu teknoloji, retinopatinin beş aşamasını sınıflandırmak için kullanılmıştır. Çalışma içerisinde yer alan bulgular DR başlangıç aşamalarını doğru bir şekilde sınıflandıramamaktadır. Ancak bu olumsuzluk tıp uzmanlarının konu üzerinde yorumlamaya yönelik ön bilgi bulguların model sistemlerine girmesine olanak sağlamasından ötürü Pratt et al., (2016) çalışması ML kullanılmasına öncülük ederek DR tespitine yönelik ilk çalışma olarak literatür dahilinde bir alt başlık oluşturmuştur. Ayrıca, yüksek özgüllük ve düşük duyarlılık arasında denge kurarak önyargılı bir veri setini avantajlarına kullanarak bir avantaj elde etmelerinin yanı sıra, bir dizi diğer topluluk (ensemble) yaklaşımı da önerilmiştir.

Bu aşamadan sonra Melcaldo et al. (2017) tarafından veri setlerine eleştirel bir yorum getirilmiştir. Artan DR tespit odaklı çalışmaların tümünde ideal veri setleri kullanılmakta, ROC eğrisinin pozitif sonuç verdiği her çalışma olumlu bir gelişme olarak lanse edilmekteydi. Ancak Melcaldo et al. (2017) tarafından toplanan ve günümüzde Asia Pacific Tele-Ophthalmology Society (APTOS) veri seti olarak açık-kaynak olarak sunulan veri setleri hastaneler tarafından toplanan ve sağlıklı/DR rahatsızlığına sahip binlerce retina görüntüsüne sahip olan bir veri seti oluşumu ve bu set üzerinde yapılan DR tespiti çalışmasını içermektedir. 2017 yılından günümüze APTOS veri seti her yıl binlerce retina görüntüsünün eklenmesinden sonra 2019’da azami seviyede sabit tutularak retina çalışmalarında günümüzde dahil kullanılmaktadır. Gondal et al. (2017), modelini APTOS veri seti üzerinde eğitip “*Diaret DBI*” veritabanında test etmişlerdir. Bu araştırmacılar tarafından bu tez dahilinde de benzer amaçla kullanılan “*Konvolüsyonel Sinir Ağı (KSA)*” kullanılmıştır. Bu çalışmada keşfedilen ağır aşamalardan ayrı olarak normal aşama ve altı daha normal olmayan retinopati aşaması ayrımı da yapılmıştır. Yukarıdaki bilgileri sınıflandırmak için evrişimli sinir ağı kullanılmıştır ve DenseNET sinir ağı mimarisi içerisinde yaklaşık olarak %95,4'lük bir eğri başarımlar/kestirim grafiği elde etmiştir.

Abdelmaksoud et al. (2021), bilgisayar görüşü alanındaki temel bir kavram olan “Çoklu Etiket Sınıflandırma (MLC)” metodolojisini araştırmalarında kullanmışlardır. Bu sayede oftalmologlar, çeşitli derecelerdeki retinopatiyi tanıyabilir ve hastaların en etkili tedaviyi bulmalarına ve retinanın kötüleşme riskini önlemelerine olanak tanımak amacıyla APTOS 2019 veri kümesi üzerinde transfer öğrenmeyi uygulamak için üç derin öğrenme ağı uyguladı. Sırasıyla DenseNet169, DenseNet121 ve ResNet50 modelleri için %96.54, %90.93 ve %90.93 sınıflandırma doğrulukları bildirdi. Bu bağlamda, Dola (2021) bu çalışmayı baz alarak orijinal RGB formatındaki görüntülerin sınıf dengesini sağlamak için veri artırma tekniklerini uygulamıştır. Ardından, veri ön işleme için veri setinden bulanık veya yinelenen görüntüleri kaldırarak modelleme aşamasında çözünürlüğü düşüren arka plan içeriğini Laplacian filtresi uygulayarak kaldırmıştır. Bu ön işleme adımlarından sonra EfficientNet e bir transfer öğrenme konseptinde uygulayarak APTOS 2019 veri kümesinde %84 doğruluk elde etmiştir.

Benzer şekilde, Hoover ve diğ. (2020), DR'nin şiddet seviyesini belirlemek için hem APTOS 2019 hem de Messidor veri setlerinde çalışmıştır. Veri ön işleme adımı için DR veri işlem parametrelerinde artık standart olmuş olan arka plan eleme, bulanıklık ve veri artırma tekniklerini uygulamışlardır. Bu mimari, ek konvolüsyonel katmanlar eklenerek özelleştirilen önceden eğitilmiş bir ResNet sinir ağı modelini içermektedir. Önerilen model için sırasıyla Messidor ve APTOS 2019 veri setleri için %72.33 ve %82.18 test doğrulukları test edilmiştir. Gangwar ve Ravi (2021), APTOS 2019 veri setindeki görüntülerin iyileştirilmesi için bu tezde de benzer şekilde işlenen ve optimizeyi sağlanan “*Contrastive Limited Adaptive Histogram Equalization*” yöntemini uygulanmıştır. Ardından, iki ayrı ögenin benzer özellik kümelerini belirlemek için aynı girişin iki artırılmış sürümünü kullanan denetimli kontrastlı öğrenme yaklaşımını uygulayarak optimizasyon için bir marj hiperparametre ayarı gerçekleştirdi. Veri kümesini DR vakalarını tespit etme ve DR şiddetini belirleme aşamalarında analiz ederek çalışmasını yayınlamış olup üretilen bu mimari, hem DR tespiti hem de DR şiddet seviyesi tahmini için kullanılmıştır. Sırasıyla DR ve non-DR sınıflandırma için %98.36 ve DR şiddetini tahmin etme için %84.36 sınıflandırma doğrulukları elde edilmiştir.

Chakraborty ve diğ. (2020), Ekoe (2019) tarafından DR tanı paradigmasını ve APTOS 2019 veri setinin sınıf dağılımı açısından son derece dengesiz olduğunu

vurgulayarak, sınıf dengesini sağlamak için filtre tasarımını önermişlerdir. Sınıf dengesini, bu tezde yer alan piksel tonlamasına benzer şekilde tonlama sağladıktan sonra, DR derecelendirme problemini üç bölüme ayıran üç aşamalı bir mimari oluşturarak, DR olmayan, az DR veya çok DR olarak üç çıkışa sahip bir model tasarlanmıştır. İkinci model, ilk modelin çıkışına göre DR tespiti durumunda, az DR veya çok DR'nin belirlenmesi için özelleştirilmiş başka bir modelle tekrar sınıflandırma yapmaktadır. Bu tezde de benzer mimari sınıflamasının yer aldığı üç aşamalı mimari ile ortalama ~%77 kestirim hassasiyeti belirtilmiştir. Bu çalışmaya ek olarak Giancardo (2021) tarafından APTOS 2019 veri seti için retinal görüntülerin özellikleri; histogram kullanılarak kullanılarak filtrelenmesinin ardından karar ağacı yöntemlerinin evrişimi ile ortalama ~%93 sınıflandırma doğruluğunu bildirildi. Aynı APTOS 2019 veri seti üzerinde başka bir ensemble öğrenme yaklaşımı uygulanarak Giancardo (2021) tarafından üretilen modelin performansı Sikder ve diğ., (2021) tarafından artırıldı. Bu tez kapsamında da değinilen gürültülü ve yinelenen görüntüler kaldırılması ve retina görüntü kalitesini artırmak amacıyla görüntülerin kontrast seviyeleri ayarlanmıştır, böylece DR seviyelerinin dokusal özellikleri ön plana çıkarılmıştır.

Son yıllarda ortaya konan farklı çalışmalarda, “ensemble” veri işlem adımının yüksek performans vermes üzerine DR tanımı sinir ağları üzerinde uygulanmaya başlanmıştır. Zhang et al. (2019), veri kümesini kullanarak kaynak olmadan transfer öğrenme yaklaşımını farklı bir perspektiften benimsemiştir. Bu çalışma, modelleri baştan eğitmeyi ve transfer öğrenme prensibini uygulamayı amaçlamıştır. Eğitim aşamasının ardından, bu modelleri APTOS 2019 veri kümesinin sınıflandırılmasında kullanarak %91.2 doğruluk elde etmiştir. Güncel literatürde son olarak olarak Jebaseeli et al. (2019), APTOS 2019 veri kümesindeki retinal görüntülerin ResNet, DenseNet ve DetNet modellerini eğitmeyi tercih etmişlerdir. En yüksek doğruluk, ResNet34 modeli kullanılarak %96.35 olarak ölçülmüştür. Diğer yandan, Densenet ve ResNet modelleri sırasıyla %84.05 ve %93.99 tespit sonuçlarına ulaşmıştır. Olewi et al. (2020), bir grafik ağı kullanarak ikili DR tespiti gerçekleştirmişlerdir. Retina özelliklerini çıkarmak için otomatik kodlayıcı öğrenme kullanılmış ve bu özelliklerin kullanılmasıyla grafik konvolüsyon ağı tasarlanmış ve APTOS 2019 veri kümesinde %94.4 doğruluk elde edilmiştir. Son olarak Bodapati ve diğ. (2021), önceden eğitilmiş modelleri üzerinde “*multi-model fusion*” modelleme paradigmasını uygulamıştır. Bu

iki modelin çıkışlarını yeni bir yoğun katman içinde blokları kullanarak birleştirdiler. APTOS 2019 veri seti için ortalama ~%82 DR tespit doğruluğu belirtilmiştir.

C. Teze Ait Amaçlar ve Çalışmanın Önemi

Bu çalışmanın temel amacı, özellikle diyabet teşhisi olmaksızın kronik retina kaynaklı sağlık sorunları yaşama potansiyeli bulunan hastalar için oldukça büyük fayda sağlayacak olan bilgisayar destekli tıbbi görüntü tanımı, segmentasyonu ve tanı kalitesini artırmaktır. Bu amaçla, DR teşhisi konusunda yardımcı olmak amacıyla konvolüsyonel sinir ağı kullanan ve üç boyutlu gerçeğe yakınsayan bir retina görüntüsü üzerinde DR lokasyonlarını ve sınıfını, ilerlemesini ve hatta DR seviyesini belirten kullanımı oldukça pratik ve geliştirmeye açık bir araç geliştirilerek gerçekleştirilecektir. DR gibi hastalıkların erken teşhisi, tıbbi görüntüleme için bilgisayar görüşü kullanımıyla mümkün hale gelmiştir. Yüksek kaliteli retina görüntüleri elde etmek, işlemek, doğru ve hızlı tıbbi teşhis almak kesinlikle gereklidir.

Ayrıca, bu yöntemler, tıp doktorlarına yüksek derecede doğrulukla bilgi elde etmelerinde yardımcı olmaktadır; bu da doktorların teşhis ve tedavi planı yapmalarına, olasılıklara bel bağlamadan, doğrudan ve etkili bir şekilde yardımcı olur ve bu durumda potansiyel DR hastaları en iyi tedavi uygulamalarını dozajında alabilir. Unutulmamalıdır ki, DR'nin yaygın doğası nedeniyle sağlık kurumlarının hastaları tedavi etmek için daha fazla maliyet ödemeleri gerekecektir. Bu, geleneksel sistemik tedavilerin etkili olması için önemli bir süre gerektirmesi ve hastalığın kronik olması nedeniyle bu tedavilerin sürekli izleme gerektirmesi gerçeğinden kaynaklanmaktadır.

Bir tıp doktoru, geçmişte tanı konulamamış farklı görüntü spektrumlarına sahip hastalığını doğru bir şekilde teşhis etmede hata yaparsa, hastanın retina sağlığı tehlikeye girebilir. Üçüncü bölümde daha detaylı bir şekilde açıklanacak olan bu strateji, ortalama kategoriye giren hastalar için geleneksel teşhis yönteminin yarattığı kaygıyı da azaltacağı aşikardır.

İstenen sonuçların elde edildiği durumlarda:

- Teknoloji üretimi, göz doktorlarının gerçekleştirdiği prosedürleri hatasız bir şekilde tekarlayarak aynı süre içerisinde çok daha efektif bulgular elde eder.

- Teknoloji gelişimi, acemi göz doktoru veya geçmişinde çok farklı DR görüntülere sahip hastalar üzerinde daha etkili olup kullanım için daha az zaman gerektirir.
- Retina ile ilgili verilerin toplanması ve titiz bir şekilde incelenmesi, en uygun bilgilerin seçilmesi.
- Sağlıklı ve hastalıklı retinal fundus dokularını ayırt etmek için retinopati segmentasyon tekniğinin geliştirilmesi.
- Retinopatileri sınıflandırmak ve derecelendirmek için bir sistem oluşturulması.
- Belirlenmiş bir veri seti üzerinde sınıflandırma ve segmentasyon prosedürünü doğrulamak için bir dizi deneme gerçekleştirme ve
- Önerilen desenlerin ilgili araştırmalarla karşılaştırılması, sonuçları öğrenmek ve değerlendirmek amacıyla deneysel çalışmaların standartizasyonu amaçlanmaktadır.

D. Teze Ait Hipotez

Makine öğrenimi, bilgisayarların mevcut verilere dayanarak gelecekteki sonuçları tahmin etmelerine olanak tanıyan bir disiplindir. Diyabet hastalığına ilişkin veriler kullanılarak, diyabetle ilişkilendirilen özelliklerin keşfedilmesi mümkündür. Ayrıca, bir konunun şu anda diyabetli olup olmayacağını veya gelecekte diyabetli olup olmayacağını doğru bir şekilde tahmin etmek de mümkün olabilir.

Derin öğrenme, makine öğreniminin bir alt disiplinidir ve görüntü, video, ses veya metin verilerini işlemek için kullanılabilir. Bu çalışmada, retinal görüntüleri analiz etmek için görüntü verileri işlenir. Mevcut veriler kullanılarak, bir konunun diyabetle ilişkili retinopati (diyabet nedeniyle gelişen bir hastalık) olup olmadığını ve eğer öyleyse bunun şiddet seviyesinin ne olduğunu tahmin etmek mümkün olabilir.

Aşağıdaki maddelerde bu tez kapsamında işlenen hipotezler şunlardır:

- Mevcut veriler kullanılarak gelecekteki sonuçları tahmin etmek mümkündür. Veri analizi, desenleri ve ilişkileri ortaya çıkarmak için faydalıdır.
- Yapay sinir ağları ve bir boyutlu evrişimli sinir ağları, sayısal ve kodlanmış kategorik özellikler üzerinde tahmin yapmak için kanıtlanmış yöntemlerdir.

EfficientNet başta olmak üzere ResNET ve DenseNET gibi derin öğrenme modelleri, retinal görüntüleri analiz etmek ve üzerlerinde tahmin yapmak için kullanılabilir.

- Temel modellerin sınıf tahminleri ve tahmin olasılıkları, ensemble modelleri oluşturmak için kullanılabilir. Yığılmış genelleme ensemble modelleri, temel öğrenen modellere göre daha rasyonel sonuçlar üretebilmektedir.

E. Tezin Organizasyonu

Bu doktora tezi aşağıdaki gibi düzenlenecektir:

Giriş ve Literatür İncelemesi: Bu bölüm, çalışmanın genel amaçlarını açıklar ve karşılaşılan zorluklar, engeller ve hedefler için bağlam sağlar.

DR tespitine yönelik temeller ve genel bakış bölümünde,

Metodoloji: Bu üçüncü bölümde, çalışmanın amaçlarına ulaşmak için makine öğrenimi tekniklerinin nasıl uygulanabileceğine dair bağlam sunulacaktır. Hem zaman serisi hem de makine öğrenimi yaklaşımlarına dayalı önceki araştırmalardan elde edilen temel başarılar sunulacak ve tartışılacaktır. Tahmin modelinin ne kadar iyi çalıştığını incelemek için istatistiksel modellerin matematiksel teorisinin detaylı bir sunumu planlanmıştır. Bu bölüm, verilerin, veri işleme süreçlerinin, özellik mühendisliğinin ve performans metriklerinin ayrıntılı bir açıklamasını içerecektir. Her bir bireysel model için metodolojiler, final sunumda yer alacaktır.

Sonuçlar ve Analiz: Bu bölümde elde edilen sonuçlar görüntülenecektir. Sonuçlar analiz edilecek ve tartışılacaktır. Ayrıca çalışmanın avantajları ve dezavantajlarının detaylı bir şekilde açıklanacak ve nasıl iyileştirilebileceğine dair öneriler sunulacaktır.

Sonuç: Proje yönetiminin zorlukları ve her paydaşın bu süreçteki rolü görüntülenecektir. Araştırma tamamlandığında bulgular ve öneriler derlenecektir.

II. GÖZİÇİ RETİNANIN YAPISI VE DİYABET İLE GÖZLENEN BOZUKLUK, DİYABETİK RETİNOPATİYE GENEL BİR BAKIŞ

Bu bölümde, retinopatinin farklı evrelerindeki hastalıkların ilerlemesi, ele alınacak teorik konulardan biridir. Bu bölüm, metodoloji ile ilgili olan, görüntü işleme uygulamalarını (görüntü iyileştirme, çeşitli optimize etme yöntemleri, teşhis ve sınıflandırma yöntemleri de dahil olmak üzere) içeren yönleri ele alacaktır. Bununla birlikte çalışmanın kullanılan veritabanı kullanımına dair bir açıklama yapılacaktır.

A. Retinanın Anatomik Yapısı ve Görüntülenmesi

İnsan vücudunda, dış dünyayla etkileşimi sağlayan beş duyu organından biri olan iki adet göz bulunur. Yaklaşık olarak 2-2.5 santimetre çapına sahip ve ortalama 10-12 gram ağırlığında küresel bir yapıya sahip olan göz, çeşitli mesafelerde bulunan nesnelere renk ve biçim bilgilerini algılayarak dış dünya ile etkileşimi sağlamaktadır. Şekil 1’de insan gözünün, dıştan içe doğru sert tabaka, damar tabaka ve retina tabaka olmak üzere temelde üç tabakadan oluşan anatomisi görülmektedir. Işık ilk defa kırıldığı nokta olan sert tabaka, gözün dış katmanında bulunmaktadır. Bu tabaka, gözün iç ve dış dünya arasında koruyucu bir bariyer görevi görür (Hardy, 1971). Sert tabakanın altındaki damar tabakası, retinanın kanlanması ve beslenmesini sağlar. Retinayı kaplayan ve damar tabakasının altındaki bir diğer katman olan retina tabakası ise görme sürecini gerçekleştirir. Bu tabakada renk ve ışığa duyarlı sinir hücreleri bulunur. Bu hücreler, retina üzerine düşen ışığı elektriksel sinyallere dönüştürür. Elde edilen bu sinyaller daha sonra optik sinire iletilir ve merkezi sinir sistemine aktarılır. Merkezi sinir sistemine iletilen sinyallerle görüntüleme süreci gerçekleştirilir (Willoughby et al., 2010).

Optik sinirlerin sert tabakayı delerek geçtiği, retinanın merkezinde konumlanan alan, optik disk olarak bilinir. Bu bölgede ışığa duyarlı hücrelerin bulunmaması nedeniyle optik disk, "kör nokta" olarak nitelendirilmektedir (Hiller et al., 1988). Retinanın ortasına doğru yerleşen ve 4-5 mm çapına sahip olan makula, merkezinde

fovea adı verilen bir yapı içerir. Fovea, sarımsı bir pigment içermemesi sebebiyle "sarı nokta" olarak adlandırılır ve bu bölge, keskin görmenin sağlandığı alanı temsil eder (Willoughby et al., 2010). Retina yapısının ana bileşenleri Şekil 2'de gösterilmiştir. Retina yapısındaki bozulmalar, retinal dekolman, retina yırtığı nedeniyle görme fonksiyonlarında bozulma, retinal ven ve arter tıkanıklıkları, sarı nokta hastalığı, göz travmaları, epiretinal membran, makula deliği ve şeker hastalığına bağlı gelişen D gibi çeşitli göz hastalıklarına yol açabilir.

Diyabet, vücutta salgılanan insülin hormonunun yetersizliği veya etkisinin azlığı sebebiyle kan şekerinin sürekli olarak yükselmesiyle karakterize edilen kronik bir hastalıktır. Bu durum, ömür boyu devam eden bir seyir izler. Diyabetin bir komplikasyonu olarak, gözün retinal tabakasındaki damarlarda meydana gelen hasarlar, diyabetik retinopati (DR) olarak adlandırılmaktadır. DR, diyabetin süresi ile orantılı olarak görülme olasılığını artırmaktadır (Hatamaka et al., 2008). Erken aşamada teşhis edilen DR, etkili bir şekilde tedavi edilebilir ve görme kaybının önüne geçilebilir. Ancak, erken teşhis ve tedavi yapılmadığında, DR ciddi görme kayıplarına yol açabilir ve hatta körlüğe neden olabilir. Bu nedenle, DR riski altında bulunan diyabet hastalarının düzenli retina taramalarından geçmeleri önemlidir. Günümüzde, retina taramaları genellikle Fundus Floresan Anjiyografi (FFA) tekniği kullanılarak gerçekleştirilmektedir. Bu teknikte, retinanın damarsal görüntüleri, sarı-turuncu floresein adlı bir madde kullanılarak mavi ışık altında uyarıldığında meydana gelen floresans ile elde edilmektedir. Deneyimli bir hekim tarafından yapılan FFA görüntülerinin analizi ile DR tanısı konulabilmektedir.

Şekil 3'de, sağlıklı bir retina görüntüsü ile DR tanısı konulan bir retina görüntüsü, FFA tekniği ile elde edilmiş örnekler olarak gösterilmiştir. DR teşhisi, hastalığın erken evrelerinde belirgin semptomların göstermemesi ve hekim tarafından yapılan FFA görüntü analizindeki hatalar nedeniyle hastalığın erken aşamalarında zorlu bir süreç olabilir. Bu durum, hastalığın hızla ilerlemesine ve tedavi sürecinin zorlaşmasına yol açabilir (Hatanaka et al., 2008).



Şekil 3: FFA tekniği kullanılarak elde edilen sağlıklı retina görüntüsü (solda), ve yine aynı teknikle ileri düzey DR tanısı konulan bir retina görüntüsü (sağda) sunulmuştur.

B. Diyabetik Retinopati (DR) Tanısı

Diyabet, insanları etkileyen potansiyel olarak hayatı tehdit eden bir bozukluktur. Diyabetin neden olduğu komplikasyonlar, göz retinasına zarar verebilir ve bu da görme kaybına yol açabilir (Hardy, 1971; Hiller et al., 1988). Diyabet kaynaklı görme kaybı, hastalığın erken aşamalarında tespit edilip kişilerin retina duyarlılığına yönelik kollektif tedavi edilirse önlenebilir. Erken aşamada ilerleyen retinopatinin öncü belirtisi olarak, retinal mikroanevrizmalar retina üzerinde görülebilir. Anevrizma büyümeye devam ederse, hasta risk altında olduğunun farkında olmayabilir; ancak anevrizma büyümeye devam ederse hastaların alınan DR Fundus görüntüleri göz doktorları tarafından incelenir ve anevrizma manuel olarak tespit edilir ve düzenli aralıklarla takip edilir. Bu periyot, muayene sırasında önemli hataların olasılığı olduğunu ve sürecin zaman alıcı ve tekrarlayıcı olduğunu gösterir. DR oluşumuna sahip kılcal damarların erken aşamada tespiti, hastayı takip etme ve hastalığın kontrol altına alınana kadar kontrol altında tutma sürecini içerir ve hastalığın retinada tehlikeli bir aşamaya ilerlemesini önlemek amacıyla yapılır.

Retinal fundus görüntülerinin analizi, çeşitli DR aşamalarını içeren bir dizi durumu tespit etme yeteneğine sahip sağlık profesyonellerine olanak tanır. Bu görüntülerin analizinde bir dizi bilgisayarlı görü sistem algoritması kullanılmaktadır. Ancak retinadaki kan şekeri seviyeleri tehlikeli derecede yükseldiğinde, retinadaki kan

damarları ciddi zarar görür. Kan şekerinin artmasıyla birlikte kan damarları delinmeye daha yatkın hale gelir, bu da görme sistemini bozar ve göze kan akmasına neden olur. Bu durum, DR olarak bilinir. Bu, bir kusura, büyük bir hasara ve potansiyel olarak ölümcül etkilere neden olabilmektedir.

Beyin hücreleri, retionapati etrafında kan kaybını tespit ederse, beyin bu hücrelere mesaj gönderir ve harekete geçmelerini, bir grup oluşturmalarını sağlamalarını istemektedir. Bu adımları gerçekleştirerek, anormal yeni kan damarlarının oluşumunu tetiklenir (Basha and Prasad, 2008) Yeni oluşan kan damarları kırılğan olduğundan ve görme kaybına neden olma potansiyeli olduğundan, diyabetik hastaların retinanın düzenli ve sık muayenelerden geçmeleri önemlidir. Bu nedenle, göz doktorunun retinayı dikkatlice izlemesi ve düzenli aralıklarla görüntülü bir şekilde incelemesi gerekmektedir.


1. DR Oluşum Mekanizma Tipleri

Mikrosistemler, kan damarları, kanamalar, sert ve yumuşak pamukçuk gibi birçok alt türün tanındığı durumlarda terimlerin literatür dahilinde belirsizleşme olasılığı bulunmaktadır. Bu durum, tıbbi literatürdeki terimlerin farklı yorumlara yol açabileceği ve bu nedenle hastalıkların doğru teşhisinin zorlaşabileceği anlamına gelmektedir. Özellikle retina üzerinde etkisi olan hastalıkların doğru bir şekilde tanımlanması, uygun tedaviye başlanabilmesi ve hastalığın ilerlemesinin önlenmesi açısından hayati önem taşımaktadır. Bu nedenle, tıbbi terminolojinin standartlaştırılması ve doğru tanımlamaların yapılması, klinik uygulamalarda tutarlılık ve etkinlik sağlamak için kritik bir adımdır.

Anomalilerin varlığı ve bunların ne ölçüde ortaya çıktığı, bu hastalıkların şiddetini belirlemede önemli faktörlerdir. Göz hastalıklarını tedavi etmenin ilk ve en önemli adımı, onları retina anormallikleri olarak doğru bir şekilde tanımlamaktır. Tanı konu olan hastalıkların birçok kategorisinin tanındığı durumlarda, söz konusu hastalıkların tüm öğeleri keşfedilir ve etiketlenir. Retinaların görüntüleri; bir dizi anormalliğin varlığı açısından göz doktorları tarafından titizlikle incelenir. Bu incelemede aranan doku özellikleri örnekleri arasında eksudatlar, kanamalar ve kan damarlarının ve arterlerin daralması bulunmaktadır (Figueiredo et al., 2015).

Retinopati daha ileri bir seviyeye ilerlediğinde, retinada yumuşak eksudatlar tespit edilebilir. Sinir liflerine ulaşabilen kan miktarında azalma olduğunda, lifler genişler ve eksudat adı verilen bir sıvı salgılar (Basha and Prasad, 2008; Kaur et al., 2018). Pamukçuk lekeler, yumuşak eksudat olarak adlandırılan bir tür eksudatın bir örneğidir. Bu nedenle, bunları retinopatinin daha ileri aşamalarında görülememektedir. Retinanın bu bölgesinde gelişen pamukçuk lekeleri, hem hızlı hem de şiddetli semptomlara neden olmaktadır (Kaur et al., 2018). Bu aşama, hastalığın en tehlikeli evresi olarak kabul edilir, çünkü bu belirtiler genellikle hastalığın ilerlediğini ve görsel kaybın yaklaşmakta olduğunu gösterir.


Retinal infarktüs, mikroskopik kan damarlarının tıkanmasına yol açarak yumuşak eksudatların oluşmasına neden olmaktadır. Bu durumda etkilenen damar, gerilmiş bir silindir gibi şişebilir. Eksudat aranırken hastalığın şiddeti göz önüne alınır çünkü bu sıvı boşalmaların boyutu ve yeri değişebilir. Sert eksudatlar ve yumuşak eksudatlar, anatomilerindeki farklılıklardan dolayı birbirinden ayırt edilebilir; bunlar genellikle boyut, renk, şekil, sınırlar ve insan retina özelliklerindeki belirgin farklar aracılığıyla kontrol edilir. İki tip eksudat arasındaki karşılaştırma, bu farkları ortaya koymak için kullanılabilir. Şekil 4'de, yumuşak eksudatların görsel örnekleri sunulmaktadır, bu da farklılıkların görsel olarak tanınmasına olanak tanır.



Şekil 4: Retina içerisinde gözlenen yumuşak eksudatlar. Eksudatların etrafındaki sıvının genişlemesiyle birlikte retina bölgesinde gelişen pamukçuk lekeleri, hem hızlı hem de şiddetli semptomlara neden olmaktadır.

Funda yer alan yağ birikintileri, lezyonlarla karıştırılabilen ve zamanla sararan protein birikimlerinden oluşur. Ayrıca, lezyonlarla karıştırılabilirler. Gözün arka segmenti olarak bilinen fundusta ortaya çıkarlar ve parlak bir yüzeye sahip düzensiz


bir alanla karakterizedirler. Bu nedenle ışığın retina ulaşması önemli ölçüde zorlaşır ve bu da görmenin bulanıklaşmasına neden olur (Jutel, 2011). Kan damarının ince duvarlarından kaynaklanan sızıntı, basınç kuvvetini artırır. Makula ödeminin teşhisi için önemli bir kaynak eksudattır, bu da sıvı ve artmış vasküler geçirgenlik içerir. Salgınlar retinopatinin teşhisini belirlemede önemli bir rol oynarlar. Retina üzerinde ortaya çıkan lekelerin boyutu, durumun doğası ve şiddetine bağlı olarak çok büyük veya çok küçük ölçekli olabilir ve belirgin sınırlara sahip olmayabilirler (Şekil 5). Bu nedenle, lekelerin boyutu ve sınırları, hastalığın karakteristiği ve ciddiyeti hakkında önemli bilgiler sağlayabilirler.



Şekil 5: Retina içerisinde gözlenen yumuşak eksudatların genişlemesiyle oluşan sert eksudatlar.

Bu süreç, retinanın en içteki katmanlarında gerçekleşir ve yuvarlak bir şekilde oluşuyla karakterizedir. Lekeler, kan kaybının ve vasküler duvarların içinden kanın dışa doğru hareketinin bir sonucudur. Lekelerin sebebi, kan kaybı ve vasküler duvarların içinden kanın dışa doğru hareketidir. Retinanın tabanı kırmızı renkte tonlanmıştır ve genel olarak asimmetrik bir şekle sahiptir. Retina içindeki kanamalar, dış veya iç katmanlarda gerçekleşebilir ve genellikle dairesel bir görünüme ve küçük kan lekelerinin görünümüne sahiptirler. Retinopati teşhisi konmuş kişilerde kalıcı körlüğün ikinci en yaygın sebebidir. Bu nedenle intraretinal kanama, ciddi retinopatinin bir belirtisidir. Kanamaların görünümü, boyutu ve sayısı gibi özelliklere dayanarak hastalığın şiddeti tahmin edilebilir (Jutel, 2011). Kanamanın ortaya çıktığı sinir lifleri tabakasında parlak amorf yapı benzeri bir görünümle gözlemlenebilir ve kırmızı alev (red flare) olarak adlandırılır (Basha and Prasad, 2008). Bu görünüm Şekil

6'da belirtilmiş şekilde gözlenmekte olup tıp literatürde, kırmızı alevin mikroanevrizmalardan mı yoksa nokta kanamalarından mı kaynaklandığı konusunda göreceli bir anlaşmazlık bulunmaktadır.



Şekil 6: Retina içerisinde gözlenen kırmızı alev olarak da nitelendirilen ve kanama noktalarını gösteren kan pıhtı kümeleri

Klinik muayeneler sırasında retinada sıklıkla ilk olarak tespit edilen anormallikler genellikle mikroanevrizmalardır ve etkilenen ışığa duyarlı retina, mikroskobik kan damarlarının veya minik, koyu kırmızı noktaların, ya tek başlarına ya da gruplar halinde, belirtilerini sergileyebilir (Hardy, 1971). Mikroanevrizmalar genellikle küresel bir yapıya sahiptir ve çapları 10 ila 100 mikron arasında değişir, ki bu da yaklaşık olarak optik disk çapının 1/12'sine denk gelir. Bu aşamada ciddi bir hastalığa dair belirtiler bulunmamaktadır (Hoover ve diğ. 2020). Mikroanevrizmalar, Şekil 7'de belirtildiği üzere küçük kırmızı noktalar olarak tasvir edilmiştir. Bu noktalar genellikle bir araya gelerek daha büyük, topaklı kümeler oluştururlar.




Şekil 7: Retina içerisinde gözlenen ve DR tespitinde gürültü olarak nitelendirilen sağlıklı mikroanevrizmalar

C. Retina İçinde Gözlenen DR Seviyesine ait Derecelendirilme

Bu doktora tezi içerisinde DR oluşumundan etkilenen hastalarda meydana gelebilecek retinopatinin birçok aşamasını (veya derecesini) yüzeysel düzeyde ele alacaktır. Proliferatif (PDR) ve non-proliferatif (NPDR) retinopatiler arasında ayırım yapılabilir. PDR, proliferatif diabetik retinopatiyi ifade eder. Mikroskobik kan damarlarının sızması, hastalığın non-proliferatif aşamasında meydana gelen retinanın genişlemesine neden olur. Başka bir deyişle, retinal ödem, retinopati teşhisi konmuş kişilerde körlüğün ana nedenidir. PDR, hastalığın retinanın yeni kan damarları oluşturduğu bir noktaya ilerlediği ve bu kan damarlarının kanamadan dolayı büyüdüğü bir noktaya ilerlediğinde ortaya çıkar, bu da ciddi bir kusura ve hastanın görüşünün engellenmesine neden olur (Mahmud and Bhattacharjee, 2020). Bu aşamada, DR zararlı olarak kabul edilir çünkü PDR, hastalığın retinanın yeni kan damarları oluşturduğu ve bu kan damarlarının kanamadan dolayı büyüdüğü bir noktaya ilerlediği bir aşamadır.

DR aşamaları ve ciddiyet seviyelerinin kapsamlı bir incelemesi Şekil 8'de sunulmaktadır. DR aşamaları, PonniBala ve Vijayachitra (2012) tarafından beş farklı aşamaya ayrılmış olup, bu aşamalar ayrıntılı bir şekilde bir alt başlıkta incelenmektedir.



Şekil 8: Retina içerisinde gözlenen DR'nin aşamaları, Ramasamy et al. (2021) tarafından belirlenen sırasıyla A-E: Proliferatif, Normal, Hafif, Orta ve Yüksek Seviye aşamalarıdır.

1. DR Dereceleri (Proliferatif, Normal, Hafif, Orta ve Yüksek Seviyeler)

Hastalığın en tehlikeli evresi, kan damarlarının kanla doyurulamadığı aşama olup, bu durum retina iç tabakasındaki zararlı ve tehlikeli kan damarlarının yayılmasına neden olmaktadır. Bu durum, gözün ortasında bir miktar katı, sıvı ve jöle benzeri bir madde oluşumu ile birleşerek hastalığın en tehlikeli evresini belirlemektedir. Yeni oluşan anormal kan damarlarının hassas yapılarından dolayı sızma eğiliminde olduklarından, görme kaybının şiddeti, olağandışı ince kan damarlarının kanamaya yatkınlığıyla doğrudan ilişkilidir (PonniBala ve Vijayachitra, 2012). Yara izi ile ilişkilendirilmiş çevresel doku çekildiğinde ve küçüldüğünde, retina dekolmanı riski ortaya çıkar. Bu senaryoda retina dekolmanı, hastanın görme yetisine ciddi ve kalıcı zarar verebilir (Mahmud and Bhattacharjee, 2020). Patlamış bir kan arteri sonucu görme kaybının evrimi Şekil 9'da görülmektedir.



Şekil 9: Yüksek seviyeli DR gözlenen bir hasanın Sol taraftaki normal retina, sağ taraftaki (DR) olan retina ile karşılaştırılmıştır.

DR tanısı koymak, hastalığın retina içindeki küçük balon benzeri yamaların şişip önemli ölçüde genişlemesine neden olması nedeniyle oftalmologlar için zorlu bir süreçtir. Problemin ilk belirtisi, anevrizmadan kaynaklanan küçük bir deformite olup,

bu deformite hastalığın ilk gözlemlenebilir belirtisidir. Bu hastalık, "*kapiller sızıntı*" olarak adlandırılan ve kan damarlarından sızan sıvılarla retina içine doğru genişleyen kan damarlarından kaynaklanan bir durumdur.

Bu durumda, kan sızıntısı ve sıvı eksudatları da meydana gelir ve hastalık daha ileri bir duruma ilerledikçe, kan damarları genişler. Retinopatinin bu evresinde, hastalığın şiddeti birçok retina kan damarında kanın hareket etmesini veya girmesini engeller, bu da kanın retina farklı bölgelerine ulaşmasını önler. Bu durumda, gözün arka kısmındaki retina yeni kan damarları oluşturmaya başlar, ancak sonradan bu damarların garip bir görünüme sahip olmaları nedeniyle anormal oldukları belirlenir. Bu hastalığa "*kapiller yetersizlik*" adı verilir. Sonuç olarak, kan damarlarının tıkanıklığından kaynaklanan hasar görmüş retina, gözün arkasında tehlikeli yeni kan damarlarının oluşumuna ve çoğalmasına neden olduğunda, kişinin görüşü bulanıklaşır (Mahmud and Bhattacharjee, 2020). Bu, bir kişinin görüşünün bulanıklaşmasına neden olan durumdur ve şeklini bozarak retinayı besleyen kan damarlarında anormalliklere yol açar. Bu beş farklı varyasyon arasında geçişler oldukça sübjektif olması ve farklı tedavi niteliklerine sahip olmasından ötürü PonniBala ve Vijayachitra (2012) tarafından Hardy (1971) tarafında keşfinin yapmış ve Jutel (2011) tarafından detaylandıran sınıflamanın retinopathi verileri üzerine denk gelen PDR ve NPDR adlı iki nihai gruplama ölçütü ortaya konulmuştur. Bu sınıflama üzerinden görüntü işleme yöntemleri çok daha spesifik sonuçlar ortaya koymaktadır.

2. NPDR ve PDR Sınıflamaları

DR hastalığı belirli evrelere kadar herhangi bir belirti göstermeyebilir. Ancak bu durumlar, bireyin ani görme kaybına yol açabilir. Uzak ve yakın görmede azalma, bulanık veya eğri büğrü görme durumları, DR'nin tipik belirtileri arasında yer almaktadır.

DR, Erken Retinopati Çalışma Grubu (Early Treatment Diabetic Retinopathy Study Research Group-ETDRS) tarafından geliştirilen Airlie House sınıflandırmasına göre derecelendirilir (Early Treatment Diabetic Retinopathy Study Research Group 1991). DR, non-proliferatif diyabetik retinopati (NPDR) ve proliferatif diyabetik retinopati (PDR) olarak iki evrede incelenir. NPDR evresi, DR hastalığının ilk evresini temsil ederken, PDR evresi DR hastalığının ilerlemiş evresini ifade eder.

D. Medikal Görüntüleme Teknikleri

Işık ışınları, cisimlerden yansyarak önceki saydam bir tabakaya ulaşır ve bu tabakada kırılma geçirir. Ardından, göz bebeğine yönlendirilen kırılmış ışınlar, göz merceğinde bir kez daha kırılarak retina (ağ tabaka) üzerine düşer. Retina üzerindeki sarı leke bölgesinde ters bir görüntü oluşur. Bu oluşan görüntü, görme reseptörleri tarafından algılanır ve beyindeki görme merkezine iletilmek üzere görme sinirleri aracılığıyla iletilir. Bu ters görüntü, görme merkezinde düz bir şekilde algılanarak görme süreci tamamlanır.

Retinal hastalıkların tanısı ve tedavi planlaması için retina görüntüleri büyük bir öneme sahiptir. Bu sayede kan damarlarındaki sızıntılar, tıkanıklıklar, makula bölgesindeki anormallikler gibi durumlar daha kolay bir şekilde tespit edilebilir. Oftalmoskop cihazı kullanılarak elde edilen retina görüntüsünde, optik disk alanının sağda veya solda bulunması, sağ veya sol göze ait retina görüntüsünü ifade eder.

Von Helmholtz tarafından 1850 yılında geliştirilen oftalmoskop cihazı, retina görüntülerinin elde edilmesini sağlar. Retina bölgesindeki damarlar, optik disk, fovea ve makula gibi yapılar oftalmoskop cihazı kullanılarak incelenir ve potansiyel bir hastalığa yönelik tedavi stratejileri belirlenebilir. Şekil 10'da, oftalmoskop cihazı ile çekilmiş bir örnek retina yapısı gösterilmektedir.



Şekil 10: Retinaya ait dijital görüntü veren oftalmoskop cihazları (Ebrahimi vd. (2024)'den uyarlanmıştır).

Diabetik retinopatinin herhangi bir aşamasında, (Diabetic Macular Edema - DME) oluşumu görme kaybına önemli ölçüde katkıda bulunabilir. DME ile ilişkilendirilen dikkate değer anormallikler arasında foveanın merkezinden bir disk çapı mesafede bulunan eksudatlar, makula içinde bulunan eksudatlar ve foveanın merkezinin bir disk çapı içinde retinanın kalınlaşması yer almaktadır; aynı bölgede mikroanevrizmaların veya kanamaların bulunması da dâhildir. DR'nin klinik şiddetini değerlendirmek için çeşitli derecelendirme protokolleri geliştirilmiştir. Geliştirilen bu derecelendirme sistemi, genellikle retinopatiyi değerlendirmenin altın standart olarak kabul edilse de, günlük klinik uygulamada uygulanması zor olmuştur.

Hastaların taranmasını ve sağlık profesyonelleri arasındaki iletişimi kolaylaştırmak için çeşitli ülkelerde alternatif şiddet ölçekleri önerilmiştir. Uluslararası Klinik Diyabetik Retinopati Hastalık Şiddeti Ölçeği, genel olarak DR şiddetini sınıflandırmak için küresel olarak tanınan bir standart olarak kabul edilmektedir. Bu ölçek, genişletilmiş oftalmoskopi sırasında gözlenen belirli bulgulara dayanarak retinopatiyi beş şiddet seviyesine ayıran Şekil 11'de gösterilen bir ölçek sistemidir. Bu bulgular, mikroanevrizma, intraretinal kanamalar, venöz incelme ve (IRMA) ile neovaskülarizasyonun varlığını içerir.

Stage	Dilated Ophthalmoscopy Observable Findings	Severity
I	No abnormalities	No DR
II	Micro-aneurysms only	Mild non-proliferative DR
III	Any of the following: - micro-aneurysms - retinal dot and blot haemorrhages - hard exudates or cotton wool spots No signs of severe non-proliferative diabetic retinopathy	Moderate non-proliferative DR
IV	Any of the following: - more than 20 intra-retinal hemorrhages in each of 4 quadrants - definite venous beading in 2 or more quadrants - prominent intra-retinal microvascular abnormality (IRMA) in 1 or more quadrants No signs of proliferative retinopathy	Severe non-proliferative DR
V	One or both of the following: - Neovascularization - Vitreous/pre-retinal hemorrhage	Proliferative DR

Şekil 11: Uluslararası Klinik Diyabetik Retinopati Hastalık Şiddeti Ölçeği, genel olarak DR şiddetini pratik olarak saptamak amacıyla oluşturulmuş, ancak kullanımı kısıtlı olması ve gelişen teknoloji sebebiyle kullanım dışı kalmıştır.

Günümüzde gerçekleştirilen tıbbi görüntüleme teknolojilerindeki gelişmeler, klinisyenlerin birçok hastalığın doğru teşhisini yapmasını sağlamıştır. Özellikle, geleneksel manuel teşhisin, hastaların sözlü ifadelerine ve gözlemlerine dayanan yaklaşımının, tıbbi görüntüleme teknolojisinin ortaya çıkmasıyla büyük ölçüde işlevsiz hale gelmesi dikkat çekicidir. Temelde, bu ilerleme kaçınılmazdır. Tıbbi görüntüleme teknolojilerinin kullanımı, hastalıkların daha erken ve daha kesin bir şekilde tespit edilmesine ve tedavi edilmesine olanak sağlamıştır..

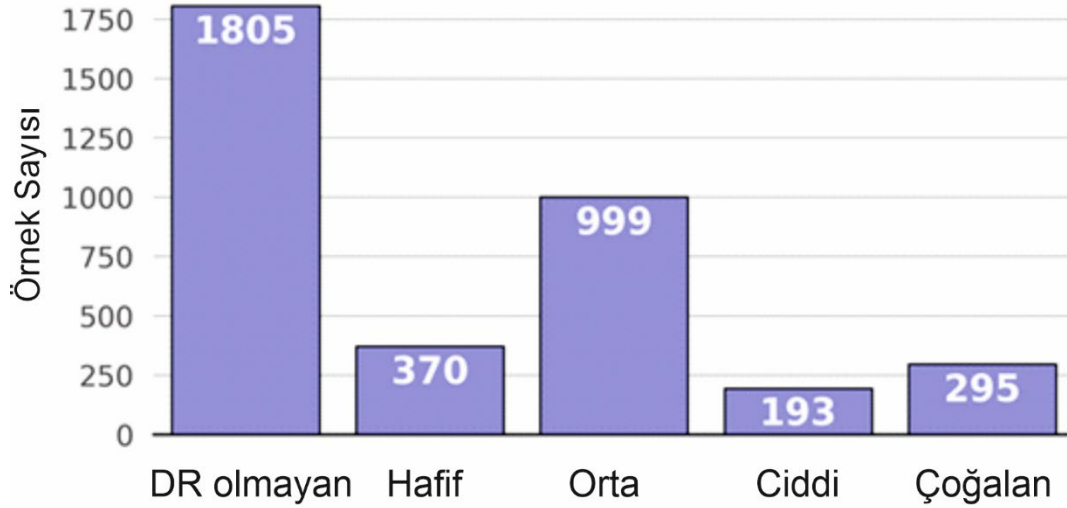
Son on yılda, hekimler arasında tıbbi görüntüleme teknolojisinin geniş çapta benimsenmesi, bir dizi avantajı, yüksek hassasiyeti ve teşhis için önemli olan görünür bileşenlerin hızlı tanımlanmasını teşvik eden faktörlerle tetiklenmiştir. Tıbbi görüntülemenin gelişen uygulamaları, hastalıklara karşı mücadelede erken teşhisi, cerrahi müdahaleleri, tedavileri ve iyileşmeyi kolaylaştırarak önemli bir rol oynamaktadır. X-ışını görüntüleme, medikal ultrason görüntüleme, manyetik rezonans görüntüleme, termal görüntüleme, endoskopik görüntüleme gibi çeşitli görüntüleme modalitelerini kullanan tıbbi görüntüleme, biyolojik görüntüleme prosedürlerinin ayrılmaz bir parçası haline gelmiştir (Bankman, 2009).

Son yıllarda tıbbi görüntüleme, özellikle insan vücudunun iç yapılarını non-invaziv bir şekilde görüntüleme konusundaki karmaşık teşhis zorluklarına çözüm olarak ortaya çıkmıştır. Ancak, medikal görüntüler genellikle renk interferansı, önemli miktarda gürültü ve veri toplamayı etkileyen diğer faktörlerle ilgili zorluklarla karşılaşmaktadır, bu da bulanık ve düşük çözünürlüklü görüntülere neden olmaktadır. Örneğin, retina görüntülerinin analizi, renk interferansı, artan gürültü ve bulanık kenarlar gibi sorunlar nedeniyle zor olabilir. Bu nedenle, bir hastanın göz sağlığı iyileşse bile, bu durum bir oftalmolog tarafından yeterli bulunmadan önce değerlendirilmelidir. Bilgisayarların artan ölçüde görüntüleri daha kullanılabilir ve net hale getirme yetenekleri nedeniyle, son yıllarda medikal görüntülemenin önemi artmıştır.

E. Kaagle Açık Erişim DR Veriseti (APTOS 2019)


Bu tezdeki deneysel çalışmalar, DR tespiti alanındaki en güncel veri seti olan APTOS 2019 veri setini kullanmaktadır. 2019 yılında Asya Pasifik Tele-Göz Hekimliği Derneği (APTOS), retinopatinin şiddet seviyesini ve varlığını öngörmek

amacıyla retinal görüntülerin toplandığı APTOS 2019 veri setini oluşturmuştur. Kamuya açık olan APTOS 2019 veri seti, farklı kamera tipleri kullanılarak çeşitli kliniklerden toplanan 3962 retinal görüntüyü içermektedir. Uzmanlar tarafından görüntüler, DR yok, hafif, orta, şiddetli ve yaygın DR olmak üzere beş farklı sınıfa ayrılmıştır. Görüntülerin sınıflar üzerindeki dağılımı Şekil 12'de verilmiştir.



Şekil 12: APTOS 2019 veri setindeki görüntülerin sınıflara göre dağılımı

APTOS 2019 veri seti, farklı koşullar altında çekilen retinal görüntüler kullanılarak hazırlanmıştır. 0'dan 4'e kadar olan 5 etiket içeren 3962 eğitim görüntüsü bulunmaktadır. DR olmadığı için 0, hafif için 1, orta için 2, şiddetli için 3 ve yaygın DR için 4 olarak etiketlenmiştir. 0'dan 4'e kadar DR şiddeti artmaktadır. Yaygın DR, hastanın görme kaybından muzdarip olduğu aşamadır.



Şekil 13: APTOS-2019 veri kümesinden rastgele seçilmiş 15 retina görüntüsü, otomatik DR Tespiti için özel olarak oluşturulmuş bir görüntü koleksiyonunu içermektedir.

Veri ön işleme açısından, daha sağlam modeller oluşturmak için bazı görüntü işleme teknikleri uygulanmıştır. Veri ön işleme adımları alt başlık içerisinde açıklanmıştır.

F. Gürültülü Görüntülerde Düzeltme ve Optimizasyon (Veri İşlem Öncesi Ön İşlemler)

Görüntü optimizasyonunda kullanılan son stratejiler, görsellerin genel estetik yorumlanabilirliğini artırmak için görüntüleri filtreleyerek ve işleyerek kullanılır. Bazı durumlarda, görüntüler gerekli netlik düzeyine sahip olmadığında, bu görüntüler üzerinde işlem yapmak için yüksek bir netlik hassasiyeti gereklidir. Dolayısıyla, günümüzde kullanılan görüntü iyileştirme teknikleri, özellikle tıp alanında, görüntülerin daha net ve anlaşılır hale getirilmesi için kritik öneme sahiptir. Görüntü optimizasyonu, bir görüntünün kullanılabilirliğini artırma sürecidir, böylece özellikleri daha hızlı bir şekilde algılanabilir (Kavakiotis et al., 2017).

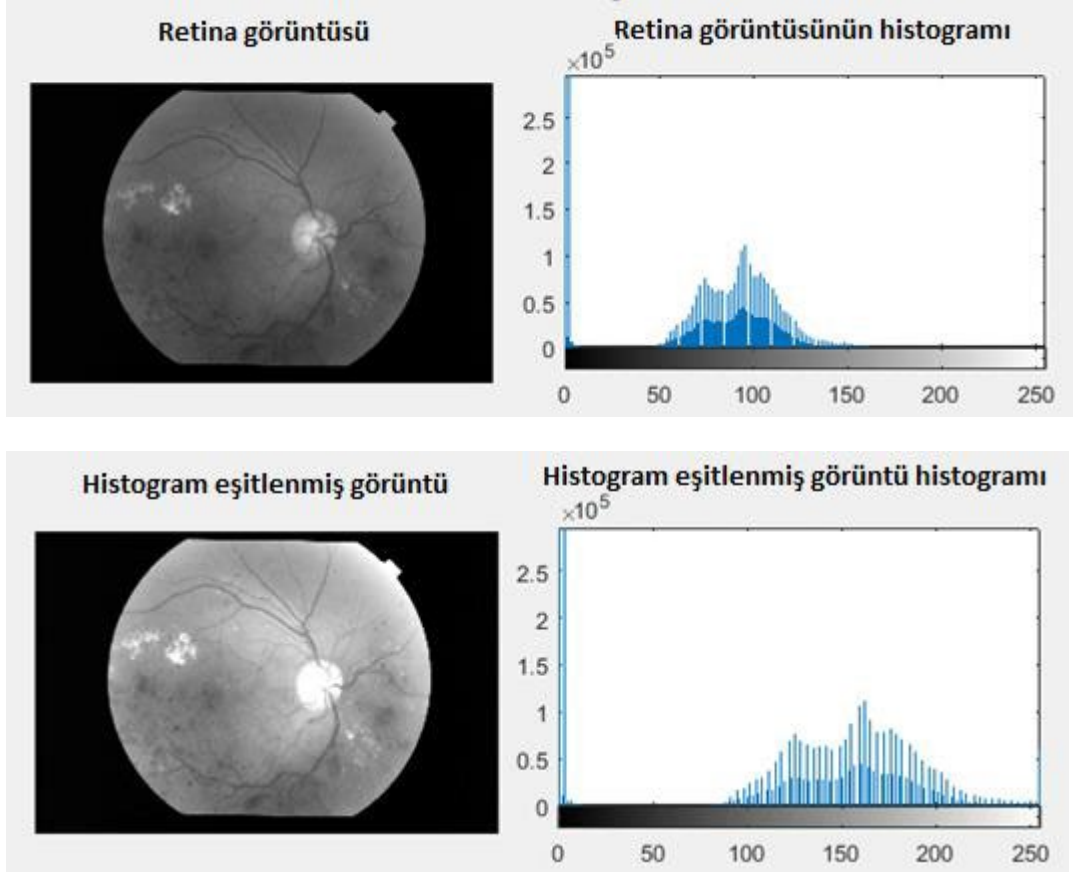
Daha net görünen görüntünün yüksek çözünürlüğü, okunabilirliği artırmayı amaçlayan ilk hedefle ilgilidir. İkinci hedefe ulaşmak için görüntü, bileşen parçalarını ayırmak amacıyla değerlendirilir ve düzenlenir. Görüntüleri geliştirmenin bir başka tekniği de, gürültüyü azaltmak, kontrastı değiştirmek ve görüntü kenarlarını ve

özelliklerini vurgulamak için algoritmaların kullanılmasıdır. Bu tekniklerin görüntüye yanlış uygulanması, sınıflandırma ihtiyacı olan bölgeleri bulmayı zorlaştırabilir ve orijinal görüntüdeki kusurları daha belirgin hale getirebilir (Kononenko, 2001). Bu tekniklerin yanlış uygulanması aynı zamanda görüntü sınırlarının bulanıklaşmasına neden olabilmektedir.

Kullanıcılar, görüntüler üzerinde değişiklik yaparken beklenmeyen sonuçlarla karşılaşmamak için bu alanda büyük dikkat göstermeli ve dikkatli davranmalıdır. Bu tez için yapılan çalışmanın odak noktası çoğunlukla sınıflandırmadır; bu nedenle, görüntüler üzerinde kullanılan iyileştirme ve işleme süreçlerinin kalitesi son derece yüksek olmalıdır. Retina sorunlarının tespiti ve hastalıkların derecelendirilmesi şimdi daha kesin bir şekilde yapılabilmekte ve gözlemlenen görüntülerin kalitesi, uygun filtreler ve algoritmalar kullanılarak önemli ölçüde artırılabilir. Görüntü işleme aşamaları arasında segmentasyon, özellik çıkarma ve sınıflandırma bulunmaktadır.

1. Kontrastla Sınırlanmış Histogramın Eşitlenmesi

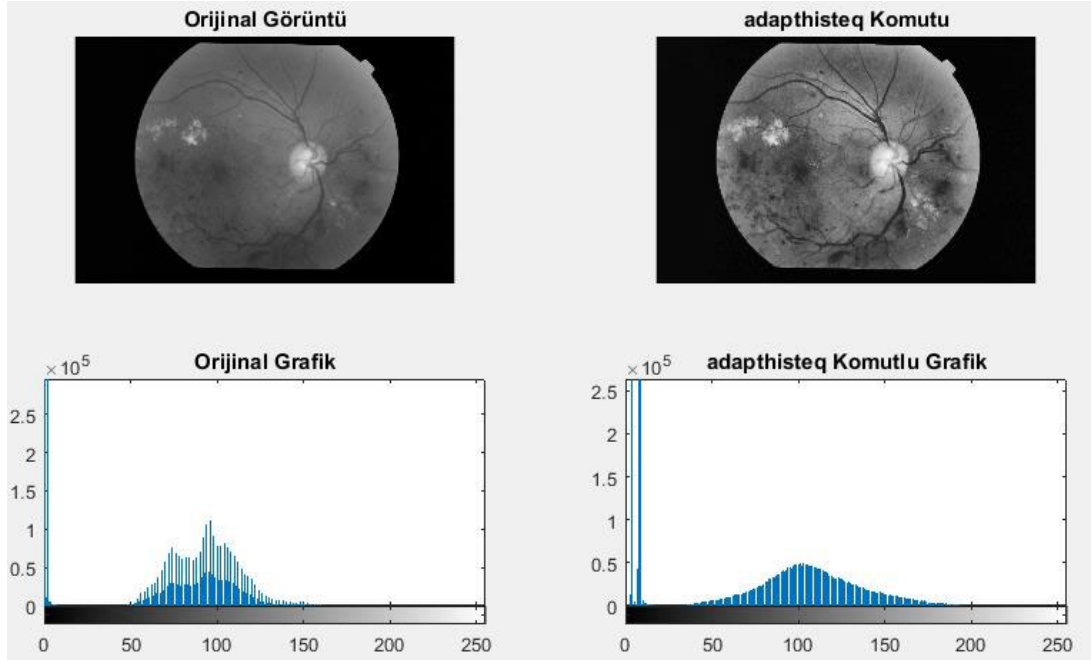
İlk olarak, histogramın eşitlenmesi tekniği tıbbi görüntülerin netliğini ve doğruluğunu artırmak amacıyla geliştirilmiş olup, ancak şu anda geniş bir yelpazede kullanılmaktadır. Bu teknik özelinde; kare şeklindeki küçük piksel parçalarında tanımlama potansiyeline sahiptir (Kavakiotis et al., 2017), ancak görüntülerde yakalanan tüm bölgeleri tanımlamaz. Görüntü optimizasyonu sürecinde, komşu karelere interpolasyon yöntemi kullanılarak belirli bölgelerde kontrast azaltılır. Bu, aşama görüntünün bulanıklaşmasını önlemek için yapılmaktadır (Kavakiotis et al., 2017; Şekil 14).



Şekil 14: Retina görüntüleri ve görüntülere ait eşitlenmemiş (üstte) ve eşitlenmiş (altta) histogram kayıtları.

Bunun sonucunda, önceki şekilde bulanık olan görüntünün bazı bölümleri daha belirgin hale gelir ve bu bölümler ile orijinal versiyon arasındaki kontrast vurgulanmaktadır. Bu nedenle; histogramın eşitlenmesi teknolojisi görüntü değerlerini diğer değerlere dönüştürerek daha pürüzsüz, daha net ve ekstra değerli yönleri olan bir görüntü elde etmeye olanak tanır. Bu, hastalıklar ve bunların şiddet seviyeleri hakkında geniş bir bilgi çıkarılmasını mümkün kılar.


Adaptif histogram eşitleme işlemi özellikle dar bir bölgede yoğun dağılıma sahip görüntülerde gürültü oluşma sorununu çözmek amacıyla kullanılan bir yerel histogram eşitleme algoritmasıdır. Bu algorithmada, temel görüntü dikdörtgenel alt bölgelere bölünür ve her bölgeye histogram eşitleme uygulandıktan sonra bi-lineer interpolasyon yöntemiyle alt bölgeler birleştirilerek temel görüntü tekrar elde edilir (Teo, 2003).



Şekil 15: Adaptif histogram eşitlemesi uygulaması

2. Gri Tonlamalı Merkezleme ve Gama Düzeltmesi

Renkli görüntülerin gri tonlu görüntülere dönüştürülme süreci, renkli görüntülerdeki hasar bölgelerini tanımlamak için gri tonlu görüntülerin tanımlanmasından daha kolay olduğu bir önemli süreçtir. Bu dönüşüm, retinal görüntülerdeki hasar bölgelerini belirlemeyi kolaylaştırabilir, çünkü gri tonlu görüntüler genellikle daha net kontrasta sahiptir ve bu nedenle hasar bölgeleri daha belirgin hale gelir. Ancak, renkli görüntülerin benzer renklere sahip olması, retinal görüntülerdeki hasar bölgelerinin tanımlanmasını bazen zorlaştırabilir. Örneğin, birçok retinal patoloji durumunda, renk tonları arasındaki farklar çok az olabilir, bu da hasarlı bölgelerin belirlenmesini zorlaştırabilir. Ayrıca, yalnızca temel renkler olan kırmızı, yeşil ve maviyi içeren bir renk uzayı kullanan görüntüler, gri tonlu görüntülere kıyasla daha yavaş bir işleme tabi tutulabilir, çünkü renkli görüntüler daha fazla bilgi içerir ve bu nedenle işleme süresi daha uzun olabilir. Bu nedenle, renkli görüntülerin gri tonlu görüntülere dönüştürülmesi, retinal patolojilerin tanımlanması ve izlenmesi gibi tıbbi uygulamalarda önemli bir adımdır.



Şekil 16: Retina görüntüsünde griye dönüştürülen retina görüntülerinde parlaklık/karşıtlık ayarlama örneği

3. DR Görüntü İçeriğinin Filtrelenmesi, Optik Disk (OD) Odak Optimizasyonu

Optik Disk (OD) Odak Optimizasyonu dönüşümünün özel bir türü olan çembersel “Hough Dönüşümü” olarak anlandırılır ve ilk olarak kenarları tespit eder ve bulunan kenarlar üzerinden belirli bir eşikleme yöntemi kullanılarak siyah-beyaz bir yeni görüntü oluşturulur (Parashar, 2014). Akümülatör matrisi, kenar pikselleri için kullanılır ve her bir çember parametresi için bir akümülatör yapıları oluşturulur. Bu sayede çemberin merkez koordinatları ve yarıçapı, akümülatör değerleri aracılığıyla belirlenir. Akümülatör matrisi, kenar piksellerinin geometrik cisimlerin polar düzlemindeki değerlerinde bulunma olasılığını temsil eder. Her bir piksel, muhtemel geometrik şekillerin polar düzlemindeki değerlerini artıran bir şekilde akümülatör matrisine katkıda bulunur. Bu şekilde tüm pikseller için olası geometrik şekillerin belirlenmesi sağlanır. Akümülatör matrisi, r yarıçaplı ve $[A,B]$ merkezli çemberde üç


boyutlu bir yapı oluşturur. Yarıçap aralığı belirlendikten sonra çember denklemini kullanarak çemberin merkezi tespit edilir (Parashar, 2014). (a,b) koordinatlarına sahip ve r yarıçaplı çemberin analitik düzlemdeki denklemini sunmaktadır. OD'ye ait optimizasyonda uygulanan işlem adımları:

İşlem 1: Görüntüyü gri renk uzayına dönüştürülmesi,

İşlem 2: Gri renk uzayındaki görüntüye Canny kenar bulma algoritması uygulanması,

İşlem 3: Kenar bulma algoritması uygulanmış siyah-beyaz görüntünün tüm piksellerinde belirlenen yarıçap değerine göre çember taranması ve

İşlem 4: Bulunan çemberleri gri renk uzayındaki görüntüde çizerek belirlenmesi şeklindedir. Bu işlemlere ait,



Şekil 17: Retina görüntüsü üzerinde çembersel Optik Disk (OD) odak optimizasyonu dönüşümünün uygulanması.

4. Gabor Filtrasyonu ile Retina Morfolojisi Kaynaklı Uç Değerlerin Filtrelenmesi

Gabor dönüşümü, görüntü üzerinde belirli yönlere uzanan ayrıtları tespit etmek ve özellik çıkarmak için kullanılan bir görüntü işleme algoritmasıdır. Yapısı gereği yön temelli bir filtre olan bu dönüşüm, plaka tanıma, karakter tanıma ve yüz tanıma gibi uygulamalarda yaygın olarak kullanılmaktadır (Thaiyalnayaki, 2021). Algoritmanın çalışma adımları şu şekildedir

Gabor dönüşümü, görüntü üzerinde belirli yönlere uzanan ayrıtları tespit etmek ve özellik çıkarmak için kullanılan bir görüntü işleme algoritmasıdır. Aşağıda Gabor dönüşümünün adım adım uygulanışını içeren bir açıklama bulunmaktadır:

İşlem Adımı – 1 : Görüntüyü [x,y] şeklinde iki boyutlu bir matrise dönüştürülür.

İşlem Adımı – 2 : Gabor dönüşümü, bir Gabor filtresinin bir sinyal veya görüntü üzerine uygulanmasıyla elde edilir. Gabor filtresi, bir sinüs dalgasının bir Gauss

penceresiyle modüle edilmesiyle oluşturulur. Matematiksel olarak, 2D Gabor filtresi aşağıdaki formülle ifade edilir:

$$g(x, y; f, \theta, \lambda, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda} + \phi\right) \quad (2.1)$$


x ve y matrisin işlem yürüttüğü eleman ait koordinat değerini, f filtre frekansını, θ açısı filtre yönelimi, λ değeri dalga boyunu, σ standart sapma değerini oluşturur. Filtre optimizasyonunda bu değerlerin hepsi optimum değerini alarak sabitlenir. Ancak sonu değer olan γ gamma değeri matriks çıkışında; filtrenin sahip olduğu rezidüel değerine sahip olduğundan her filtre çıktısında sıfıra yakınsayan bir değer alması optimaldir. Son nihai Gabor dönüşümünde gamma değeri ~0.003 olarak elde edilmiş ve filtre katsayıları nihai halini almıştır.

İşlem Adımı – 3 : Gabor dönüşümü eşitliğinde gerekli $[x', y']$ değerleriyle hesaplanır.

$$\begin{aligned} x' &= x \cos(\theta) + y \sin(\theta) \\ y' &= y \cos(\theta) - x \sin(\theta) \end{aligned} \quad (2.2)$$

İşlem Adımı – 4 : Gabor dönüşümünde kullanılan ϕ , faz kayması hesaplanır. Bu kayma ile tüm görüntü kümeleri ortak bir segmente alınır (Şekil 18, üst görüntü)

İşlem Adımı – 5 : Gabor çekirdeği konvüle edilerek tüm görüntülere elde edilen Gabor filtresini uygulanır, Şekil 18'de alt kısımda yer alan gri tonlamalı retina görüntüleri tüm APTOS kütüphanesi için uygulanarak işlem adımları sonlandırılır.



Şekil 18: Gabor dönüşümü ile elde edilen retina görüntüsü

III. METODOLOJİ

A. Konvolüsyonel Sinir Ağları Teknolojisi

Derin öğrenme teknolojisi, insan zihninin gerçek anlama yeteneğindeki farklı katmanların yaptığı işlemleri taklit etmek için kullanılan bir sinir ağıdır. Bu sinir ağı, biyolojik süreçleri tespit etmek ve izlemek için optimize edilmiştir, biyolojik süreçleri tespit etmek ve izlemek üzere tasarlanmıştır (Shanthi and Sabeenian, 2019). Derin sinir ağları (DSN'ler) ve konvolüsyonel sinir ağları (KSA'lar), her bir ağın öğrendiği bilgi, ağların nasıl oluşturulduğu veya nasıl yapılandırıldığı açısından benzer özelliklere sahip değildir. DSN'ler, genellikle görüntü verisi gibi bilgileri işlerken, KSA'lar, veri bazında işlevsel olduğundan dolayı pikselleştirilmiş görüntü formatta çalışır ve hem iki hem de üç boyutta var olabilir. Bu nedenle, derin öğrenme teknolojisi, karmaşık bilgi işleme problemlerini çözmek için geniş bir uygulama alanına sahiptir ve özellikle görüntü tanıma, doğal dil işleme ve oyun yapay zekası gibi alanlarda büyük başarı elde etmiştir.


Bu anlamda, KSA'nın öğrenme süreci, belirli özelliklere sahip nesnelere tanıma yeteneği üzerine odaklanır. Ayrıca, KSA, veride veya grafiklerde bulunan belirli özelliklere dayalı tanımlamalar yapabilir. Örneğin; nesnelere sahip olduğu görüntülerin köşe, kenar veya desen gibi belirli özelliklerine dayanarak tanıma ve sınıflandırma işlemlerini gerçekleştirebilir. KSA yaklaşımlarının temel faydalarının kaynağı, diğer yöntemlere göre sunduğu avantajlardan gelir (Bilgin, 2021). Özellikle, KSA'nın derin öğrenme yetenekleri, büyük veri kümelerinden karmaşık desenleri öğrenebilme ve belirli özelliklerin algılanması konusunda üstün performans gösterme kabiliyetine dayanır. Bu yetenekler, özellikle tıbbi görüntülerin özelliklerini kullanarak hastalıkları tanıma ve çeşitli evreler ve derecelere sınıflandırma gibi karmaşık görevleri başarıyla yerine getirebilir. Örneğin, retinal görüntülerdeki lezyonların tespiti ve sınıflandırılması gibi tıbbi tanı süreçlerinde KSA'nın başarılı bir şekilde kullanıldığına dair çalışmalar bulunmaktadır (Franklin et al., 2014; Mercaldo et al., 2017; Zhang et al., 2019; Qummar et al., 2019; Başer et al., 2021; Bodapati et

al., 2021). Bu nedenle, KSA'nın tıbbi görüntüleme alanında hastalık tanıma ve sınıflandırma gibi kritik konularda önemli bir araç olduğu kabul edilmektedir.


KSA, bir görüntünün renk piksellerinden oluşan üç boyutlu bir matris olarak görünür (genişlik, yükseklik ve derinlik), her biri 0 ile 1 arasında bir değere sahiptir

(Qummar et al., 2019). Eğer girişte renkli bir görüntü bulunuyorsa, renk dikey ve yatay yönlere dağılmış olacaktır. Diğer yandan, monokromatik görüntüler oluşturmak için tek renk kanalı kullanılır, bu da gri tonlamaya neden olur. KSA, birçok katmandan oluşan üstün mimarisi nedeniyle karmaşık alt katmanlarının varlığına rağmen bilgiyi başarıyla kategorize edebilir. Bir havuzlama katmanı, bir konvolüsyon katmanı ve bir tam bağlı katman içeren gizli katmanlar ve çıkışı, bir sonraki katmana giriş olarak kullanılıp kullanılmadığına bağlı olarak bir aktivasyon veya özellik haritası olarak adlandırılabilir (Şekil 19.; Qummar et al., 2019). Ayrıca, ilk katmanda bir resme uygulanabilecek çeşitli filtreler bulunmaktadır; bu da özellikle dokularda yer alan kan damarları, konturlar veya sınırlar gibi belirli özellikleri vurgulamak amaçlı kullanılmaktadır.

Bu tanım mekanizmalarını ve içerisinde barındırdığı katmanların işleyişini daha ayrıntılı bir şekilde açıklamak için önce bunları ayrı ayrı tartışmak ve ardından nasıl birlikte çalıştıklarını göstermek daha etkili olabilir. KSA'lar içinde, sinir ağının gerçekleştirdiği önemli faaliyetlerden sorumlu olan gizli katmanlar bulunmaktadır. Bu gizli katmanlar, KSA'nın işlevini belirleyen ve nöronların birbirleriyle iletişimini sağlayan kritik yapı taşlarıdır. Bir KSA olarak bilinen bir ağın, matematiksel hesaplamaları yapmak ve bu hesaplamaları uygulamak için tamamen adanmış bağlı ünitelere sahip olduğunu belirtmek önemlidir. Bu üniteler, her biri belirli bir hesaplama görevini gerçekleştiren ve bilgiyi diğer nöronlara ileterek bir haberci gibi hareket eden nöronlar tarafından oluşturulur (Bodapati et al., 2021). Bu gizli katmanların gösterimi Şekil 19 ve Şekil 20'de görülmektedir. KSA'nın ilk katmanı, giriş işlemlerini yönetmekle sorumludur ve ardışık katmanlar kendilerini çıkış işlemleri için hazırlarlar. Nöronların girişi çıkışa dönüştürdüğü ve bir KSA'nın üç boyutlu olarak yapılandırıldığı bir noktada (uzunluk, genişlik ve derinlik), bu sürecin doğrudan bir sonucu olarak, Şekil 20'de gösterildiği gibi, yapılanma gösterdiği şematik olarak göstermek mümkündür.



Şekil 19: KSA mimarisinde gözlenen gizli katmanlar

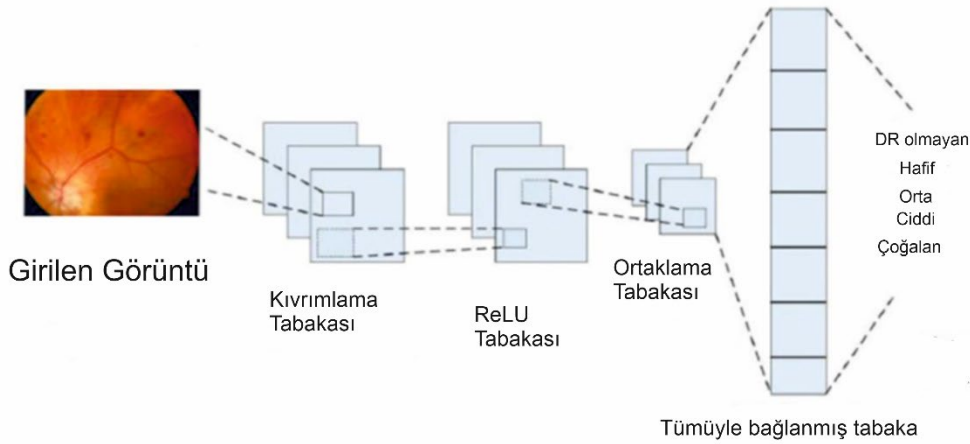


Şekil 20: Üç boyutlu olarak tasarlanan KSA katmanlarına ait şematik görünüm

B. Konvolüsyonel Sinir Ağlarının Mimarisi ve Katman Yapısı

KSA, giriş görüntüsündeki analizini gerçekleştirmek için birçok katmandan oluşan bir yapı kullanır. Bu katmanlar, genellikle birbirine bağlıdır ve her biri belirli bir işlevi yerine getirir. Örneğin, ilk katman, giriş görüntüsünden temel özellikleri çıkararak işleme sürecine başlar. Bu özellikler, görüntünün kenarları, köşeleri veya diğer önemli yapısal unsurları gibi görsel öznitelikler olabilir (Qummar et al., 2019). İkinci katman, önceki katmanların çıktılarını bir araya getirerek (havuzlama), görüntünün daha yüksek düzeydeki özelliklerini öğrenmeye devam eder. Son katman ise bir sınıflandırıcı olarak işlev görür ve KSA'nın çıktılarını daraltarak, verilen görüntünün belirli bir sınıfa veya kategoride olma olasılığını tahmin etmektedir. Şekil 21; bir KSA mimarisinin temel bileşenlerini görsel olarak temsil etmekte olup; KSA'nın giriş katmanından başlayarak, ardışık katmanların nasıl bir araya geldiğini ve bilgi işleme sürecinin nasıl ilerlediğini açıkça gösterir. Bodapati et al. (2021) her bir katmanın işlevi, görsel olarak net bir şekilde belirtilmiştir, bu da KSA'nın iç yapısını

anlamının ve nasıl çalıştığını görsel olarak kavramanın daha kolay olduğunu sağlamaktadır.



Şekil 21: KSA mimarisinin temel bileşenleri

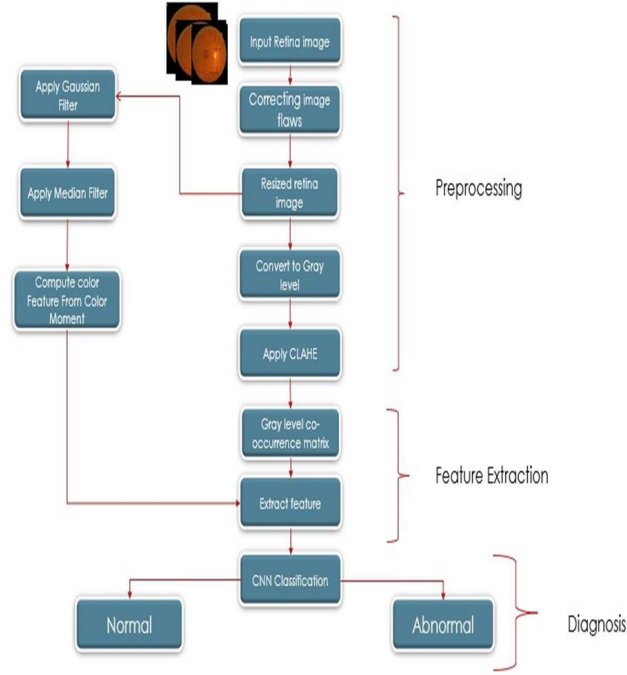
C. Sinir Ağlarının Eğitimi İçin İyileştirme Algoritmaları, Stokastik Gradyan Degradasyon

Bu bölümde; stokastik gradyan inişi; Bodapati et al., (2021) tarafından da geliştirilen “Adam ve RMSprop” gibi birkaç öne çıkan optimizasyon yöntemi üzerinde tartışılacaktır. Bu metodolojiler, sinir ağlarının eğitim sürecinde önemli bir rol oynamaktadır. Modelin performansını artırmak için dropout ve batch normalization gibi tekniklerin kullanılması önerilir (Bodapati et al., 2021). Bu aşamada hedeflenen kayıp fonksiyonunu minimize etmek ve aynı anda modelin doğruluğunu artırmaya çalışmaktır. Birden çok veri örneği üzerinde optimizasyon yapıldığında, temel amaç genel kaybı mümkün olan en üst düzeye indirmektir.

D. Tasarlanan Mimari

DR tespiti için retina görüntülerinin bir dizi kullanılması her zaman amaçlanmıştır. Gri tonlamalı görüntüler, retinopati teşhisi ve tespitini optimize eden “CLAHE” adlı bir sistemde işlenir. Renkli görüntüler, optimizasyon teknikleri ve uygulamaları kullanılarak filtrelenir ve özellikleri kodlamak için “CLAHE” kullanılır, ardından bir konvolüsyonel sinir ağına gönderilir. Şekil 3.14, renkli ve gri tonlamalı görüntülerin, pratik iyileştirme, dönüşüm ve “CLAHE” rutin proses aşamalarında elde

edilen özellikler kullanılarak retinopati alt tiplerini tahmin etmek için bir KSA ağına beslendiği sistem tasarımını göstermektedir. Şekil 22 içerisinde bu aşamaların sistemde hangi işlem adımıyla gerçekleştiği görülmektedir.



Şekil 22: Önerilen yöntem için KSA tabanlı genel akış şeması.

KSA'nın baştan eğitilmesi için önemli miktarda etiketli veri gerekmektedir. Eğitim sürecinin başarısı, mevcut veri miktarı, görüntülerin kalitesi ve kullanılan KSA mimarisi olmak üzere üç temel faktöre bağlıdır. Bu faktörlerin her biri, KSA'nin doğruluğunu ve performansını etkileyebilmektedir. Özellikle, yeterli ve doğru etiketlenmiş veri miktarının, KSA'nin başarılı bir şekilde eğitilmesi için kritik öneme sahip olduğu gözlemlenmektedir. Görüntülerin kalitesi de eğitim sürecinin başarısını etkileyebilmektedir; çünkü net, yüksek çözünürlüklü görüntüler, KSA'nin öğrenme ve özellik çıkarımı süreçlerini daha etkili bir şekilde gerçekleştirmesine olanak tanımaktadır.

Ancak, bu çalışma dahilinde kullanılan APTOS 2019 veri setinde de yer alan farklı cihazlardan elde edilmiş verilerin de benzer şekilde yer aldığı başlangıç veri miktarı yetersiz olabilir veya görüntülerin kalitesi düşük olabilir. Bu durumda, transfer öğrenme ve artırma teknikleri kullanılabilir. Transfer öğrenme, önceden eğitilmiş bir modelin farklı bir sorunu ele almak için kullanılması anlamına gelir. Bu yaklaşım, özellikle başlangıç veri miktarı sınırlı olduğunda veya özel bir görev için yeni bir

model eğitmenin maliyeti yüksek olduğunda faydalıdır. Başka bir deyişle, transfer öğrenme, bir modelin öğrendiği bilgiyi başka bir alana aktarma sürecidir ve çeşitli senaryolarda uygulanabilen esnek bir öğrenme yaklaşımıdır. Etiketli veri setlerinin pratik uygulamalarda genellikle erişilemez olduğu için bu son derece önemli bir fonksiyondur.

Tıbbi alanda yeterli miktarda veri elde etmek zorlu bir süreçtir, çünkü uzmanlaşmış anotasyonlar pahalıdır ve bazı hastalıkların (örneğin, lezyonlar gibi) nadir olması veya hasta gizliliği gibi nedenlerle gerekli veriye erişim genellikle sınırlıdır. Tıbbi görüntüler genellikle uzman hekimler tarafından manuel olarak yorumlanır ve bu işlem, uzmanlığa dayalı ve zaman alıcıdır. Dolayısıyla, büyük miktarda etiketli veriye erişim genellikle kısıtlıdır ve bu durum, derin öğrenme gibi veriye dayalı tekniklerin başarısını olumsuz yönde etkileyebilir. Ek olarak, bazı hastalıklar nadir olabilir veya belirli bir nüfus örneğinde çok az hasta bulunabilir. Nadir hastalıkların veya nadir durumların teşhisi için yeterli sayıda örnek elde etmek zor olabilir, bu da modelin etkinliğini değerlendirmeyi ve geliştirmeyi zorlaştırmaktadır.

Bir diğer husus ise hasta gizliliği de veri toplama sürecini etkileyebilir. Kişisel sağlık bilgilerinin korunması gerektiği için, tıbbi verilerin paylaşılması ve kullanılması sıkı yasal düzenlemelere tabidir. Bu durum, araştırmacıların geniş kapsamlı tıbbi veri setlerine erişimini kısıtlayabilir ve böylece modelin eğitimini ve değerlendirmesini zorlaştırabilir. Tüm bu faktörler yeterli veri elde etme zorluğuna katkıda bulunur. Bu varsayımsal durumda, KSA modelleri ya doğrudan bir tıbbi uygulamadan diğerine ya da bir tıbbi uygulamadan alınabilir

ML için yığılmış modelin eğitimi için öncelikle temel modellerin eğitilmesi ve hazırlanması gerekmektedir. Bu süreçte, veri kümesi her bir temel model için ayrı ayrı eğitilir ve hazırlanır. Her modelin eğitimi tamamlandıktan sonra, bu temel modellerin her birinin çıktıları yığılmış modelin girdisi olarak kullanılır. Bu tez çalışmasında, görüntü işleme üzerine literatür dahilinde kabul görmüş üç temel model kullanılmıştır. Bu temel modellerin detayları üç alt başlık şeklinde aşağıda verilmiştir. Bu alt başlıklar altında her bir temel modelin eğitim süreci, kullanılan özellikler, parametreler ve elde edilen sonuçlar ayrıntılı olarak açıklanmıştır. Bu bilgiler, yığılmış modelin

oluşturulması ve eğitilmesi için temelleri oluşturmakta olup, modellere ait dezavantajlı noktalar kendi alt başlıkları dahilinde irdelenmiştir.

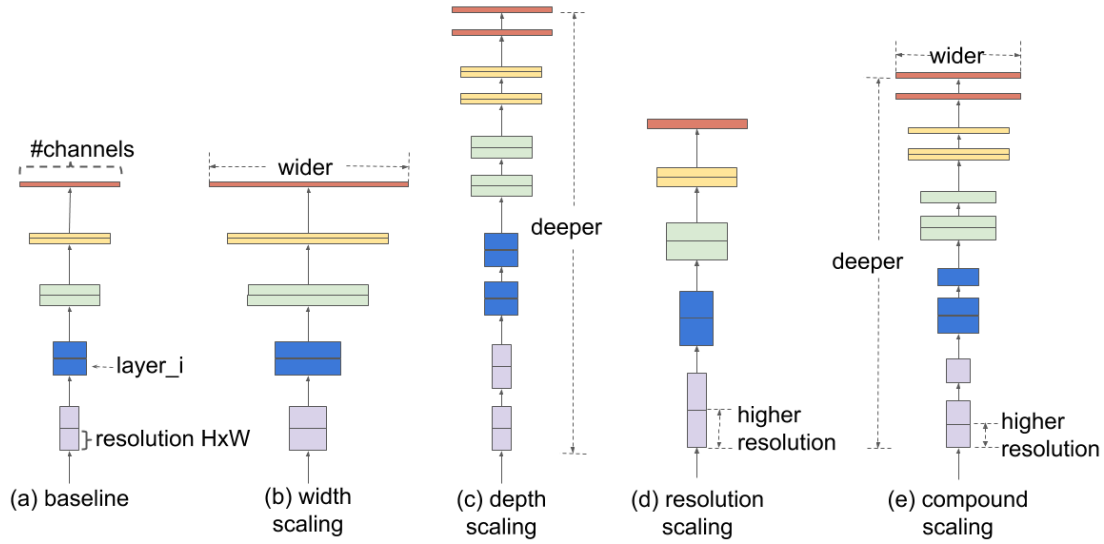
1. EfficientNET

EfficientNet modelleri, bilgisayar görüşü ve derin öğrenme alanlarında daha güvenilir ve doğru yaklaşımlar elde etme amacıyla geliştirilmiştir. Bu modeller, derinlik, genişlik ve çözünürlüğü ölçeklendirerek model boyutunu etkili bir şekilde azaltarak bu hedefi gerçekleştirir. EfficientNet ailesi, B0'dan B7'ye kadar olan 8 modelden oluşur; model numarasıyla parametre sayısı artmaz, ancak doğruluk önemli ölçüde artar. “ReLU” aktivasyon fonksiyonunu kullanan diğer KSA modellerinin aksine, EfficientNet yeni bir aktivasyon fonksiyonu olan “SWISH” fonksiyonu üzerinden tanıtır, bu fonksiyon doğrusal ve sigmoid aktivasyonlarını birleştirir. EfficientNet'in mimarisi, doğrudan bağlantılar ve kanal sıkıştırma kullanarak genişleme katmanlarına göre daha az bağlantılı kanallar elde eden tersine “MBCConv” konvolüsyon modülü ile karakterizedir. Var olan KSA modellerine kıyasla, EfficientNet modelleri daha yüksek doğruluk ve verimlilik sergiler; EfficientNet-B7, ImageNet veri kümesinde %84,4'lük birinci ve %97,1'lik beşinci sınıf doğruluğu ile en son teknoloji performansını elde eder (Bodapati et al., 2021).

EfficientNet'in mimarisi ayrıca, çekirdek boyutu k^2 olduğunda hesaplamayı k katmanında azaltarak derin ayrılabilir evrişimleri içermektedir. Derinlik, genişlik ve çözünürlüğün tutarlı ölçeklenmesini sağlamak için, bileşik katsayı ϕ bileşik ölçekleme prensiplerini takip ederek kullanılır.

$$\phi = (1.0, 1.1, 240) \quad (3.1)$$

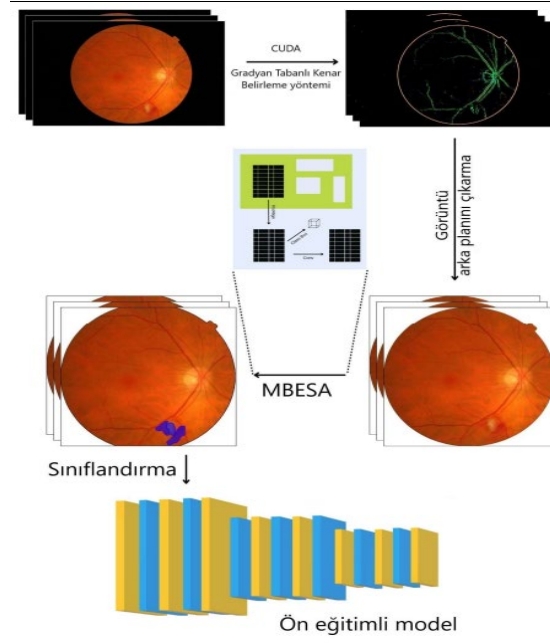
Denklem takımı 3.1, modelin genişlik, derinlik ve çözünürlük boyutlarını belirler. Genişlik katsayısı (1.0), modelin genişlik boyutunu belirler. Derinlik katsayısı (1.1), modelin derinlik boyutunu belirler. Çözünürlük katsayısı (240), modelin giriş çözünürlüğünü belirlemektedir. EfficientNet modelleri, yüksek doğruluk elde etmeyi hedeflerken aynı zamanda hesaplama kaynaklarını verimli bir şekilde kullanmayı amaçlar. İlk temel model olarak EfficientNet-B5 kullanılmıştır. EfficientNet modellerinin ölçeklenebilir mimarisi, model boyutunu erişilebilir kaynaklara veya belirli gereksinimlerinize uygun olarak kolayca değiştirmeyi sağlamakta olup Şekil 23 içerisinde temel mimari yapısı verilmiştir.



Şekil 23: EfficientNet'in temel mimarisi

EfficientNet-B5, doğruluk ve hesaplama verimliliğini bir araya getiren etkili bir derin öğrenme modelidir. EfficientNet ailesinin bir parçası olarak, mimarinin genişliğini, derinliğini ve çözünürlüğünü ölçeklendirerek optimal performansı elde etmek için tasarlanmıştır. Daha büyük boyutuyla, EfficientNet-B5 verilerdeki karmaşık desenleri ve özellikleri yakalar ve aynı zamanda hesaplama verimliliğini korur. Büyük ölçekli veri kümeleri üzerinde eğitilmiş ve karmaşıklığı azaltmak için derinlik tabanlı ayırıcı evrişimler gibi teknikleri kullanır. EfficientNet-B5, çeşitli bilgisayar görüşü görevlerinde etkileyici sonuçlar elde etmiş olup, doğru görsel tanıma gerektiren uygulamalar için en uygun mimari seçeneği olarak değerlendirilmektedir.

Önceki sürümlere kıyasla daha büyük boyutuyla, EfficientNet-B5, verilerden karmaşık detayları yakalama ve karmaşık temsiller öğrenme kapasitesine sahiptir. Geniş veri kümelerinde eğitilmiş olması, çeşitli görsel tanıma görevlerine iyi genelleşmesini sağlar (Şekil 23). Model, hesaplama karmaşıklığını azaltarak doğruluktan ödün vermeden mekansal ve kanal bazlı dönüşümleri ayıran derinlik bazlı ayırıcı evrişimleri içermektedir. EfficientNet-B5'i kullanma nedeni, doğruluk ve hesaplama verimliliği arasında denge kuran güçlü bir derin öğrenme modeli olmasıdır. Ölçeklenebilir mimarisi ve yenilikçi tasarım seçenekleriyle, farklı görsel tanıma görevlerinde dikkate değer bir performans elde etmesine olanak tanır. EfficientNet-B5'i kullanarak, araştırmacılar ve uygulayıcılar yüksek doğruluk ve etkili kaynak kullanımından faydalanabilir ve bu nedenle DR araştırmalarında kullanım için uygun bir seçenek oluşturmaktadır.




Şekil 24: Bu tez kapsamında geliştirilen ön filtreleme işlem basamaklarının ardından oluşturulan sınıflamaya yönelik hazırlanan blok model

2. ResNET

ResNet mimarisi, derin sinir ağlarında sıklıkla karşılaşılan gradyan kaybı veya aşırı şiddetlenme gibi sorunlara karşı etkili bir çözüm sunar. Bu çözüm, artıklık bloklarını tanıtarak gerçekleşir. ResNet'in temel özelliği olan artıklık blokları, atlanmış bağlantıları içerir ve bir katmanın aktivasyonlarını doğrudan sonraki katmana bağlayarak oluşturulur (Bodapati et al., 2021). Bu yaklaşım, ağız artıklık eşlemelerini öğrenmesine izin verir ve hedeflenen eşlemeyi doğrudan modellemek yerine tahmin edilen ve gerçek çıktılar arasındaki farka odaklanır. Atlanmış bağlantılar, derinlik arttıkça performansın bozulmasını ele almasına olanak tanır. Bu da, gradyan kaybı veya aşırı şiddetlenme gibi sorunlarla karşılaşmadan son derece derin sinir ağlarının eğitimini mümkün kılar. Bu sayede, daha derin ve karmaşık sinir ağlarının eğitilmesi daha etkili hale gelir ve modelin daha iyi öğrenmesi sağlanır (Sidibe et al., 2015).

ResNet mimarisi, derin öğrenme alanında önemli bir ilerleme olarak kabul edilir ve birçok uygulamada başarılı sonuçlar verir. Bu nedenle, ResNet'in artıklık blokları, derin sinir ağlarının güvenilir ve etkili bir şekilde eğitilmesinde önemli bir rol oynar. ResNet modelleri arasında ResNet50, ResNet101, ResNet152, ResNet50V2, ResNet101V2 ve ResNet152V2 gibi çeşitli versiyonlar bulunmaktadır. Bu modeller, katman sayısı ve özel mimari değişiklikler açısından farklılık göstermektedir.

Özellikle, ResNet'in V2 versiyonları, her ağırlık katmanından önce grup normalleştirmeyi içerir ve bu, eğitim stabilitesi ve performansında daha fazla iyileştirme sağlar. ResNet ağırları, birçok bilgisayarlı görüntü uygulamasının temelini oluşturan klasik bir sinir ağı türüdür. Ancak, derin sinir ağlarının eğitimi sırasında gradyan kaybı gibi sorunlarla karşılaşılabilir. Bu sorunları çözmek için geliştirilen ResNet, atlanmış bağlantılar kavramını öncülük etmiştir. Atlanmış bağlantılar, gradyanın farklı bir kısayol yolu izleyerek akmasına olanak tanır ve modelin bir kimlik eşlemesi öğrenmesine izin verir. Böylece, daha yüksek katmanların mümkün olduğunca iyi performans göstermesi ve hatta daha iyi performans göstermesi sağlanır. Atlanmış bağlantılar olmadığında, giriş " γ " ile ağırlıklandırılır ve bir "bias" (yönleme) terimi eklenir. Bu süreç, giriş ve çıkış arasındaki ilişkiyi modellemeye çalışırken, gradyanların geriye doğru iletilmesi sırasında ortaya çıkan zorlukları ele almayı amaçlar. Bu önceden eğitilmiş modellerin bulunabilirliği, ResNet mimarilerinin çeşitli bilgisayarlı görüş uygulamalarında entegrasyonunu ve dağıtımını kolaylaştırır. Bu durum, araştırmacıların ve uygulamacıların belirli görevler için ResNet'in gücünden yararlanmasına ve derin sinir ağlarının daha iyi eğitilmesine ve daha iyi performans göstermesine olanak tanır.



Şekil 25: Resnet'in temel mimarisini

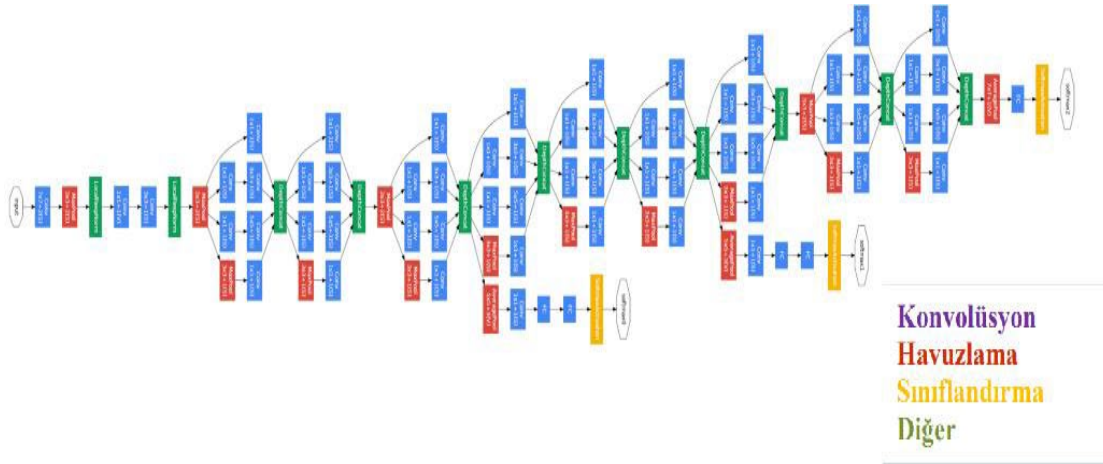
ResNet modellerinde, kaybolan gradyanlarla eğitim sorununu çözmeye yardımcı olmak için artıklı bağlantılar kullanılır. ResNet-18, 18 katmandan oluşan Residual Neural Network (ResNet) mimarisinin bir varyantıdır. ResNet-18, özellikle görüntü sınıflandırma ve nesne tespiti gibi alanlarda, bilgisayarlı görüş görevlerinde geniş çapta benimsenmiştir. Karmaşık görsel verilerle başa çıkma etkinliği, onu bu alanlarda popüler bir seçim haline getirmiştir. Göreceli olarak kompakt boyutuna rağmen, ResNet-18, dikkate değer doğruluk ve genelleme yeteneklerine sahiptir, bu da onu bilgisayarlı görüş alanında çeşitli uygulamalar için popüler bir seçim yapar.

ResNet-18, ařağıdaki uygulamalar için kullanılmaktadır. Bu, daha derin ağıları verimli bir şekilde eğitmeyi mümkün kılar ve modelin genel performansını artırır. Daha derin varyantlara kıyasla, ResNet18, görece hafif bir ağıdır, bu da eğitimi hızlandırır ve daha az hesaplama gücü kullanır (Wang et al., 2020).

3. DenseNET


DenseNet, geleneksel beslemeli ileri beslemeli KSA'lerden farklı olan bir KSA mimarisidir. DenseNet mimarisi, her katmanı ağıdaki her dięer katmanla doğrudan bağlantı kurarak Olanaklı Bloklar ve Geçiş Katmanlarından oluşur. Yoğun Bağlantılar ve Geçiş Katmanları, her katmanın önceki katmandan ve sonraki her katmandan doğrudan girdi almasını sağlamaktadır (Huang et al., 2017). DenseNet-121 ve DenseNet-169, katman sayısı ve parametrelerin sayısı ile karakterize edilen iki popüler DenseNet uygulama betiğidir.

Geleneksel bir KSA'de, her katman önceki katmandan girdi alır ve bir çıkış özellik haritası oluşturur. Ancak, ağı daha derin hale geldikçe, kaybolan gradyanlar sorunu ortaya çıkar ve etkili eğitimi engeller. Bu durum, bilgi birçok katmanı geçerken kaybolur veya 'kaybolur' olduğunda meydana gelir. Kaybolan gradyan sorunu, ağın etkili bir şekilde öğrenmesini ve yüksek performans elde etmesini kısıtlar. DenseNet'ler, katmanlar arasında yoğun bağlantıları sağlayarak ve özelliklerin yeniden kullanımını ve yayılmasını teşvik ederek kaybolan gradyan sorununu ele alır. Geleneksel KSA'lerin aksine, DenseNet'ler gereksiz özellik eşlemelerini öğrenme ihtiyacını ortadan kaldırdıkları için daha az parametre gerektirirler. Bir DenseNet'te, her bir katman doğrudan dięer tüm katmanlara bağlıdır, bu da L sayısındaki katmanlar için ağıda toplam $L(L+1)/2$ doğrudan bağlantı sağlar.



Şekil 26: DenseNet Ağ Modeli

DenseNet mimarisi, gradyan akışını iyileştirir, katmanlar arası bilgi akışını kolaylaştırır ve ağ parametrelerini etkin bir şekilde kullanır. Derin katmanlardaki büyük giriş sayısı sorununu ele almak için, her 3x3 evrişim öncesine 1x1 evrişim ile bir darboğaz katmanı tanıtılır. Bu darboğaz katmanı, hesaplamaların verimliliğini ve hızını artırmaya yardımcı olur. DenseNet'ler, daha az parametre değerlendirilmesi yaparak, özellik yeniden kullanımını teşvik ederek ve daha kompakt modeller oluşturarak geleneksel KSA veya ResNet mimarilerinden ayrılır. Bu özellikler, çeşitli veri kümelerindeki üstün performans ve verimliliğe katkıda bulunur. DenseNet'lerin yoğun bağlantılı yapısı, bu sonuçları elde etmede anahtar rol oynar.



Şekil 27: Üç yoğun bloktan oluşan derin bir DenseNet mimarisini göstermektedir. İki ardışık bloğu birbirine bağlayan katmanlar, özellik haritalarının boyutunu güncellemek için evrişim ve havuzlama işlemlerini kullanan geçiş katmanları olarak adlandırılır.

E. SHAP (SHapley Additive exPlanations) Nesne Konumlandırması


SHAP (Shapley Additive Explanations), makine öğrenimi modellerinin çıktılarını anlamak ve açıklamak için son derece etkili bir yöntem olarak öne

çıkmaktadır. Bu metodoloji, her bir özellik veya değişkenin model çıktısına katkısını ölçerek, modelin karmaşık tahminlerini daha anlaşılır bir şekilde ifade etmektedir. Bu noktada, özelliklerin etkileşimlerini ve ilişkilerini gözlemlemek, modelin davranışını daha bütünsel bir şekilde anlamamıza olanak tanır.

SHAP analizi, bir modelin iç işleyişini detaylı bir şekilde incelemek için güçlü bir araçtır. Özellikle, her bir özelliğin tahmine katkısını belirleme yeteneği, modelin hangi özelliklerin çıktı üzerinde daha belirleyici olduğunu anlamamıza yardımcı olur. Ancak, sadece özelliklerin tek başına etkilerini değil, aynı zamanda bu etkilerin bir araya gelerek nasıl birleştiğini de göz önünde bulundurmak önemlidir. Bu sayede, modelin karmaşıklığını anlamak ve tahminlerin neden bu şekilde yapıldığını daha kapsamlı bir şekilde değerlendirmek mümkün olur. Ayrıca, SHAP analizi, özellikler arasındaki ilişkileri ve etkileşimleri de vurgular. Özelliklerin birbirleriyle nasıl etkileşime girdiğini görmek, modelin neden belirli bir çıktıya ulaşmıştırdığını daha derinlemesine anlamamıza yardımcı olur. Bu, özellikler arasındaki ilişkilerin ve bağlantıların modelin sonuçları üzerindeki etkisini anlamak için kritik bir adımdır. Bu metodoloji, özelliklerin tek başına katkılarını değerlendirmenin yanı sıra, özellikler arasındaki etkileşimleri ve ilişkileri de göz önünde bulundurarak modelin davranışını daha bütünsel bir şekilde anlamamıza olanak tanır.

SHAP, Shapley değerlerini temel alır ve bu değerlerin özelliklerin katkılarını anlamada nasıl kullanılabileceğini gösterir. Her özellik veya değişken, tahmin edilen çıktıya katkıda bulunur ve SHAP değerleri, bu katkının büyüklüğünü ölçer. Bu sayede, her özelliğin tahmin üzerindeki etkisi net bir şekilde anlaşılabilir ve yorumlanabilir. SHAP, özelliklerin tahmindeki etkisini görselleştirmek için çeşitli grafikler ve araçlar sunar. Bu şekilde, bir modelin tahminlerini açıklamak ve anlamak daha kolay hale gelir, bu da modelin güvenilirliğini artırır ve karar alma süreçlerini destekler. SHAP (SHapley Additive exPlanation) çerçevesi, LIME ve DeepLIFT gibi daha önce önerilen açıklama yöntemlerini bir araya getirerek, eklemeli özellik atıf yöntemleri sınıfı altında toplar (Lundberg and Lee, 2017). Bu sınıftaki yöntemler, basitleştirilmiş ikili değişkenlerin lineer bir fonksiyonu olarak açıklama modelleridir.


Burada, $f(x)$ orijinal modeli; $g(x)$ açıklama modelini; z basitleştirilmiş girişi; $x = hx(z)$ orijinal yönteme bir eşlem fonksiyonudur; ve $\theta_0 = f(hx(0))$ tüm basitleştirilmiş girişler olmadan model çıktısıdır.



Şekil 28: SHAP model ve rezüel değerlerin hesaplanmasına yönelik oluşturulan sinir ağı

SHAP'ın sağlam bir teorik temeli vardır, bu da düzenlenmiş senaryolarda bir avantaj sağlar. Başta oyun teorisi kapsamında Shapley değerlerini kullanarak belirli bir tahmini açıklar ve her özelliğe bir önem değeri (SHAP değeri) atar. Bu SHAP değerleri:

- lokal doğruluk - açıklama modeli orijinal modelin çıktısına uyum sağlamalıdır;
- ekstrapolasyon görülmemesi - orijinal girdide bulunmayan özelliklerin etkisi olmamalıdır;
- tutarlılık - bir modeli belirli bir özelliğe daha fazla bağlı hale getirirsek, o özelliğin önemi, diğer özelliklerden bağımsız olarak azalmamalıdır (Chakraborty ve diğ. (2020)).



Şekil 29: Farklı DR seviyelerine sahip retina görüntülerinden elde edilen küresel SHAP modellemelerine ait örnek görüntü kümeleri


IV. DENEYSEL ÇALIŞMAYA AİT BULGULAR

Bu bölümde, önerilen görüntü işleme yazılımının işleyişini detaylı bir şekilde analiz etmek için ASTER 2019 veritabanında yer alan retina görüntüleri kullanılmıştır. En iyi sonuçları elde etmek için farklı veritabanlarından alınan görüntüler üzerinde, optik disk ve kan damarlarının otomatik olarak tespit edilmesi Python dili üzerinde yer alan ve geliştirilen betikler (scripts) aracılığıyla gerçekleştirilmiştir. Optik disk ve kan damarlarının görüntüden tespit edilmesi ve göz ardı edilmesinden sonra, eksuda ve hemoraji lezyonlarının tespiti ile DR sınıflandırması için eğitim aşamasında KSA sinir ağı ve SHAP küresel modelleme modelleri kullanılmıştır. Sınıflandırma sonuçları grafikler ve çizelgeler şeklinde sunulmuş ve analiz edilmiştir. Geliştirilen bu görüntü işleme yazılımının çalışma adımları Şekil 30'de gösterilmiştir.

A. OD'nin Konumlandırılması


Bilindiği üzere Optik Disk (OD), retina merkezinde yer alan bir yapıdır ve görsel sistemin önemli bir bileşenini oluşturur. Miyelin kılıfının varlığı nedeniyle sarı parlak bir renge sahip olan bu yapı, genellikle yuvarlak bir disk şeklinde görülür. OD, beyinden gelen optik sinir liflerinin retinaya bağlandığı kritik bir noktadır ve görme sürecinde önemli bir işlevi üstlenir. Yaklaşık olarak 3 mm çapında olan optik disk, ortalama çözünürlükteki bir retinal görüntüde yaklaşık 80-100 piksel büyüklüğündedir. Bu ölçüler, görsel bilginin retinadan optik sinire geçişindeki önemli bir ara yüzün boyutunu yansıtır (Hardy, 1971).

Renkli bir fundus görüntüsünde optik diskin karakteristik görünümü Şekil 30'de gösterilmiştir. Bu görüntü, OD'nin görsel olarak tanımlanmasını sağlar ve gözün arka bölgesindeki yapıların incelenmesinde önemli bir referans noktası oluşturur. Optik disk, görsel bilginin beyne iletilmesinde kritik bir geçiş noktası olduğundan, fundus görüntülerindeki optik disk boyutu ve morfolojisi, oftalmolojik muayenelerde önemli bir değerlendirme kriteridir.



Şekil 30: Rastgele seçilmiş DR içerikli retina görüntüsünden elde edilen OD birimi

Optik disk, sahip olduğu dairesel şekil nedeniyle optik disk bölünmesinde Hough dönüşümü kullanılmıştır (Şekil 31). Bu yöntem, optik disk çevresini algılamak ve tanımlamak için etkili bir araç sağlar. Görüntülerin eşiklenmesi için ise K-Means algoritması tercih edilmiştir. Renkli fundus görüntülerinde, optik disk bölgesi genellikle yeşil bileşen görüntüsünde parlak ve koyu bölgeler olarak belirgin bir şekilde görülür. Bu nedenle, eşikleme işlemi için yeşil bileşen görüntüsü üzerinde K-Means algoritması uygulanmıştır. Bu yöntem, görüntüdeki piksel değerlerini belirli bir sınıflandırmaya göre gruplamak için kullanılır. Bu çalışmada, sınıf sayısı üç olarak seçilmiştir, bu da optik disk ve çevresindeki yapıların net bir şekilde ayrılmasını sağlar. Bu sayede, OD bölgesinin doğru bir şekilde belirlenmesi ve analiz edilmesi için uygun bir temel sağlanmış olur.



Şekil 31: Üst kısımda yer alan rastgele seçilmiş DR içerikli retina görüntüsünün, (üst-solda), k-means algoritması ile renk tayfının otomatik olarak belirlenmesi (üst-sağda) ve alt kısımda ise OD'nin tüm görüntüden farklı olarak sınırlarının oluşturulması


B. Optimizasyon Sonuçları

APTOS-2019 veri setinin ön işleme aşamasında, retinal görüntülere bir dönüşüm işlemi uygulanmaktadır. Bu dönüşüm işlemi, görüntüleri analiz için hazırlamak amacıyla çeşitli dönüşümleri içerir. İlk olarak, herhangi bir aykırı değerin olup olmadığını kontrol edilerek herhangi bir yinelenen veya boş görüntüye rastlanılmamıştır. Ardından, takip eden görüntüler sabit 224x224 piksel boyutuna yeniden boyutlandırıldı. Bu yeniden boyutlandırma adımı, tüm görüntülerin aynı boyuta sahip olmasını sağlayarak veri setinin tutarlı bir şekilde işlenmesine olanak tanır. Daha sonra, bu görüntüler tensörlere dönüştürüldü, bu sayısal temsiller derin öğrenme modelleri için en uygun olanıdır. Bu dönüşüm, verimli hesaplama ve derin

öğrenme çerçeveleri ile entegrasyonu sağlar. Son olarak, görüntülerin piksel değerleri normalize edilir. Normalleştirme işlemi, piksel değerlerini (0.485, 0.456, 0.406) ortalama ve (0.229, 0.224, 0.225) standart sapma ile standart hale getirir.

Ardından yapılan normalleştirme işlemi, piksel değerlerini standart hale getirerek farklı görüntü özelliklerinin etkisini azaltmaya yardımcı olur. Bu, görüntülerin tutarlı bir formatta hazırlanmasını sağlar ve APTOS-2019 veri seti üzerinde derin öğrenme modellerini eğitmek ve değerlendirmek için önemli bir adımdır. Normalleştirme işlemi, görüntülerdeki piksel değerlerinin ortalama ve standart sapma kullanılarak yeniden ölçeklenmesini içerir. Bu sayede, farklı görüntüler arasındaki yoğunluk ve kontrast farklılıkları dengelenir ve modelin eğitim sürecinde tutarlılık sağlanır. Bu ön işleme adımlarının uygulanmasıyla, APTOS-2019 veri seti, derin öğrenme modellerini eğitmek ve değerlendirmek için uygun ve standart bir formatta hazırlanmış olmaktadır.

Bu tez çalışması dahilinde üretilen modellerin uygun şekilde eğitilip değerlendirilebilmesi için veri seti eğitim ve doğrulama alt kümelerine ayrılmıştır. Veri setinin bu şekilde bölünmesiyle, modeller verinin bir kısmında (yani eğitim setinde) eğitilebilir ve ardından performansları ikinci bir veri alt kümesinde (doğrulama setinde) değerlendirilebilir, bu veriye eğitim sırasında maruz kalmamışlardır. Gerçek veri kümelerinde yapılan uygulamalarda, bu eğitilmiş modellerin yeni verilere nasıl tepki vereceğinin tahmin edilmesine yardımcı olur. Bu, pandas'ın örnekleme işlevinin kullanılmasıyla yapılmıştır. Bu işlev, verilerden rastgele bir örnek alır ve parametrelerle belirtilen kodla, verinin %80'ini eğitim seti olarak seçmiş bulunmaktayız, çünkü parametre 0.8 olarak ayarlanmıştır. `random_state` parametresi belirli bir değere ayarlanmıştır, böylece sonuçların yeniden üretilebilirliği sağlanmıştır.




Şekil 32: APTOS-2019 veri setindeki görüntülerin ön işleme aşamasında yer alan piksel sınırlama işlemine ait örnekler, görüntülerin kontrastını artırmak ve belirli alanlardaki detayları vurgulamak için kullanılan bir tekniktir. Bu işlem, görüntülerdeki piksel değerlerini sınırlayarak renk aralığını daraltır ve belirli bir aralıkta yoğunlaşmasını sağlar

Eğitim seti belirlendikten sonra, doğrulama seti oluşturulurken, tüm veri setinden eğitim setine ait olmayan indisler çıkarılarak oluşturulmuştur. Böylece, eğitim setinin parçası olmayan verilerin %20'si doğrulama seti olarak belirlenmiş ve bu veriler silinmiştir. Bu tür bölünme, bu çalışmada DR tespiti üzerine kullanılmıştır, çünkü makine öğrenimi ve derin öğrenme projelerinde sıkça kullanılan bir yaklaşım olan modellerin eğitilmesi ve test edilmesi için dengeli bir yaklaşım sunar (Şekil 32).

Bu yöntem, modelin eğitiminde kullanılan veri setinin doğrulaması için ayrılan veri setiyle aynı özelliklere ve dağılıma sahip olmasını sağlar. Böylece, modelin gerçek dünya verileri üzerindeki performansını daha iyi değerlendirmemize olanak tanır. Ayrıca, bu yaklaşımın kullanılmasıyla, modelin genelleme yeteneği daha sağlam bir şekilde test edilebilir ve aşırı uydurma (overfitting) riski azaltılabilir.

Bu nedenle, veri setinin bu şekilde bölünmesi, DR tespiti gibi önemli bir görevde modelin performansını değerlendirmek için güvenilir bir yol sunar. Bu, hem modelin geliştirilmesi sürecinde hem de sonuçların yorumlanması aşamasında önemlidir.



Şekil 33: Rastgele seçilen ve veri işlem öncesi filtrelerin uygulandığı DR görüntüsü (üstte) ve kullanılan damar filtreleri ile çıkarılan indislere ait örnekler (altta)

Şekil 33 (üstte), retinopati tanısında kullanılan bir görüntünün, veri işlem öncesi durumunu temsil eder. Bu görüntü, işleme tabi tutulmadan önceki halini yansıtır ve doğrudan gözlemlenebilir durumdadır. Şekil 33 (alt) ise, kullanılan damar filtreleri ile çıkarılan indislerin örnekleri görülür. Bu aşamada, görüntüler üzerine belirli filtreler uygulanır ve belirli özellikler vurgulanır. Örneğin, damar filtreleri ile damarların belirginleştirilmesi amaçlanabilir. Bu, görüntülerdeki damar yapılarının daha belirgin hale gelmesini sağlar ve DR tespiti gibi görevler için önemli bir ön işleme adımıdır. Bu iki görüntü arasındaki fark, görüntü işleme adımlarının önemini vurgular. Görüntü işleme, gürültüyü azaltmak, önemli özellikleri vurgulamak ve analiz için uygun hale getirmek gibi amaçlarla kullanılır. DR görüntülerinin işlenmesindeki bu adımlar, tanı algoritmalarının etkinliğini artırmaya ve retinopatiyi doğru bir şekilde sınıflandırmaya yardımcı olur. Bu da hastalığın erken teşhisini ve etkili tedavi yöntemlerinin uygulanmasını kolaylaştırır.

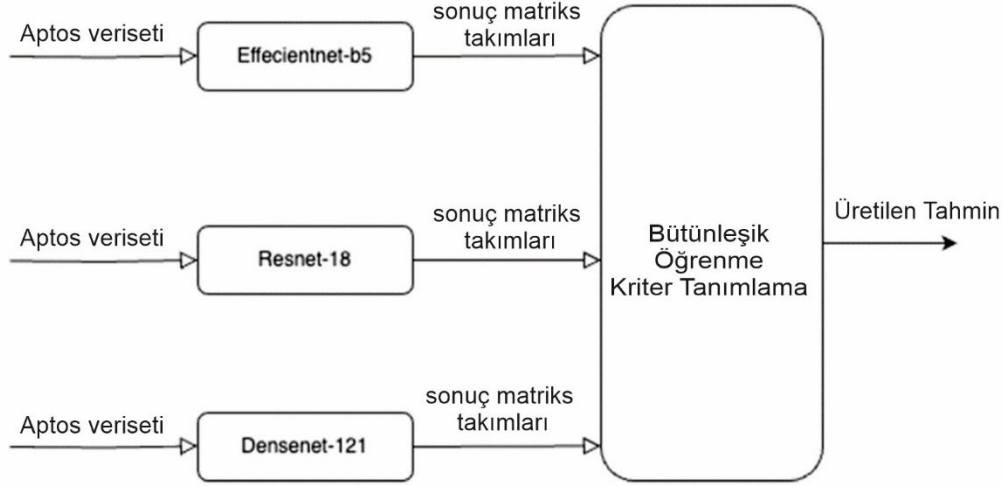
C. DR ve Mikroanevrizmaların Tespit Edilmesi

Modellerin eğitimi, temel modeller ve yığın modeli de dahil olmak üzere, standart derin öğrenme teknikleri kullanılarak gerçekleştirildi. Model parametrelerinin

optimize edilmesi için Parashar et al. (2014) tarafından geliştirilen “*Adam Optimizasyon*” tekniği kullanılmıştır . Bu adaptif öğrenme oranı yöntemi az bellek kullanır ve hesaplama açısından etkilidir. Etkinliği nedeniyle derin öğrenmede geniş bir şekilde kullanılmaktadır. Çoklu sınıf problemleri için yaygın bir yaklaşım olan “*Çapraz-Entropi Kaybı (Cross-Entropy Loss)*”, modellerin eğitilmesinde kullanılmıştır. Beklenen olasılık ile gerçek etiketler arasındaki fark “*Çapraz-Entropi Kaybı*” ile ölçülür. Sonuç olarak, modelin yanlış sınıflar için düşük olasılık ve doğru sınıflar için yüksek olasılık çıkarılan sonuçlar üretmesi önerilir.

Tez kapsamında üretilen ana modeller başlangıçta ayrı ayrı eğitilmiştir. Ardından yığın modeli, Adam optimizasyon algoritması ve Çapraz-Entropi Kaybı modüllerinin eklenmesiyle birlikte veri girişleri birleştirilerek bu süreçte kullanılmıştır. Yığın modeli, temel modellerin hatalarını düzeltmek için eğitilir; bu da modelin tahminlerini bu çıktılara dayandırarak doğruluğu artırmaktadır.

Temel modellerin (EfficientNet, ResNet ve DenseNet) tahminleri, yığın modelini (stack model) eğitmek için kullanıldı. Yığın modelinin girişi, bu modellerin tahminlerinin birleşimiydi. Bu, geleneksel olarak orijinal özelliklerin (bu durumda görüntü verisi) girdi olarak kullanılmasından farklı bir yaklaşımdır. Yığın modeli, standart denetimli öğrenme prosedürü kullanılarak eğitilmiştir (Şekil 34). İkili sınıflandırma sorunları için uygun bir kayıp fonksiyonu olan “*Logits Kayıplı Binary Çapraz-Entropi*” kullanılmıştır. Eğitim sırasında 500 DR görüntüsü bir epok olarak isimlendirilerek modelleme boyunca her yirmi epok desen tanım işlem sonucunda kayıp değeri kaydedildi ve ilerlemesi izlendi. Model parametreleri, eğitimden sonra daha sonraki kullanımlar için saklanmıştır.




Şekil 34: Üç temel modelin birleşik model için girdi olarak kullanılmasını ve ardından birleşik modelin buna dayanarak tahmin yapacağını göstermektedir.

Toplam altı eğitim döngüsü sonrasında, doğrulama seti doğruluk oranı, “Kaggle” olarak belirtilen standart medikal tabanlı görüntü işleme uygulamaları için %75 olarak belirlenmiştir. Bu, modelin sadece altı eğitim döngüsü sonrasında doğrulama setindeki görüntülerin %75’ini sınıflandırmada etkili olduğunu göstermektedir (Şekil 35). Kayıp fonksiyonuna ait değerler, eğitim sürecinde azalma eğilimi göstermiş olup bu da modelin tahmin üretme konusunda daha yetkin hale geldiğini göstermektedir. Kayıp fonksiyonunun modellerin eğitim sürecinde azalması, modelin eğitiminin ilerlediğini ve tahmin üretme konusunda daha yetkin hale geldiğini gösterir. Kayıp fonksiyonunun azalması, modelin verilerdeki desenleri daha iyi öğrenmeye başladığını ve bu desenleri daha doğru bir şekilde tahmin etmeye başladığını göstermektedir. Bu durum, modelin daha genelleştirilebilir ve daha güvenilir tahminler yapma yeteneğini artırır. Dolayısıyla, kayıp fonksiyonunun azalması, modelin eğitim sürecinin başarılı bir şekilde ilerlediğini ve daha yetkin hale geldiğini işaret eder.

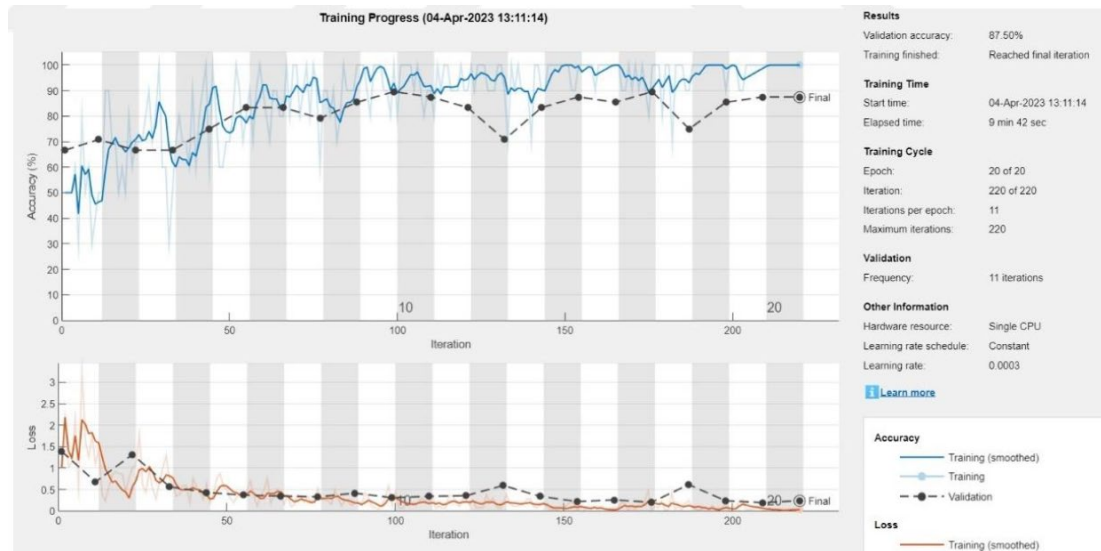
Bununla birlikte, kayıp fonksiyonunun tek başına düşmesi yeterli değildir. Modelin aşırı uyuma/uyuşma (overfitting) eğilimini kontrol etmek amacıyla doğrulama verileri üzerinde de benzer bir performans iyileştirmesi gözlemlenmelidir. Ancak, genel olarak kayıp fonksiyonunun azalması, modelin eğitim sürecinde ilerleme kaydettiğini ve daha iyi tahminler yapma yeteneğine sahip hale geldiğini gösterir. Bu

aşamada yer alan diğer KSA optimizasyon sonuçlarında ayrıca bu uyuma dikkat edilmiştir.



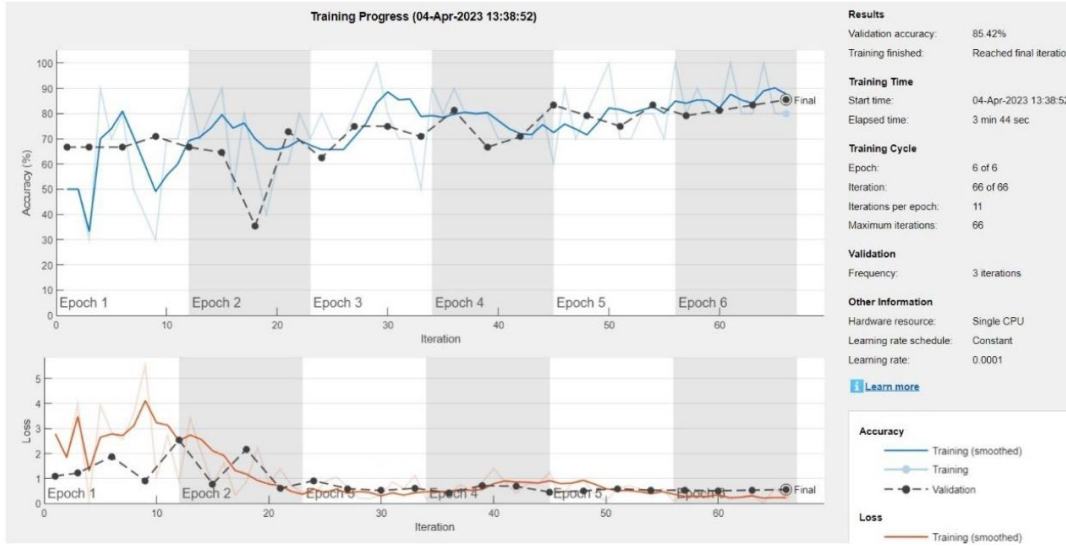
Şekil 35: EfficientNET KSA'nın altı epok değeri için sahip olduğu hassasiyet değerleri

Doğrulama seti doğruluk oranı, toplam 20 epok eğitildikten sonra tüm zamanların en yüksek seviyesine ulaşmıştır (Şekil 36). Bu, modelin verileri anlama yeteneği ve sonuçları tahmin etme yeteneğinin her bir ardışık eğitim seansıyla iyileştiğini göstermektedir. Kayıp fonksiyonu daha keskin bir hızla azaldı, bu da modelin kullanılabilirliğinde daha belirgin bir iyileşme olduğunu göstermektedir.




Şekil 36: EfficientNET KSA'nın yirmi epok değeri için sahip olduğu hassasiyet değerleri

Altı eğitim döngüsünden sonra, ResNet, doğrulama setini başarıyla %85,42 doğruluk oranıyla tamamlanmıştır (Şekil 37). Bu, modelin toplam altı epok boyunca eğitimden geçtikten sonra doğrulama setindeki görüntülerin %85,42'sini doğru bir şekilde sınıflandırabildiğini göstermektedir. Eğitim süreci boyunca kayıp fonksiyonundaki azalma, modelin gelecekteki sonuçları tahmin etme konusunda daha iyi hale geldiğini göstermektedir.




Şekil 37: Resnet KSA'nın altı epok değeri için sahip olduğu hassasiyet değerleri

Ek olarak 20 epok daha eğitildikten sonra, model doğrulama setinde %100 doğruluk oranı elde etti (Şekil 39). Bu, modelin veri anlayışının, eğitim tekrarları arttıkça geliştiğini ve bu durumun modelin tahmin doğruluğunun artmasına neden olduğunu göstermektedir. Kayıp fonksiyonu daha belirgin bir hızda azaldı, bu da modelin performansının daha fark edilir bir şekilde arttığını göstermektedir. Bu veriler, görüntülerin sınıflandırılması için ResNet'in kullanılabilirliğine dair kanıtlar sunmaktadır. Sadece altı eğitim döngüsü sonrasında kabul edilebilir bir doğruluk seviyesine ulaşıldı ve yirmi tekrar sonrasında önemli kazanımlar olduğu kanıtlandı. Sürekli azalan kayıp fonksiyonu, modelin veri kümesinden öğrenme yeteneğini ve davranışını buna göre ayarlama yeteneğini göstermektedir. Bu bulgular, ResNet'in genel olarak görüntü sınıflandırma görevleri için güvenilir olduğunu göstermektedir.

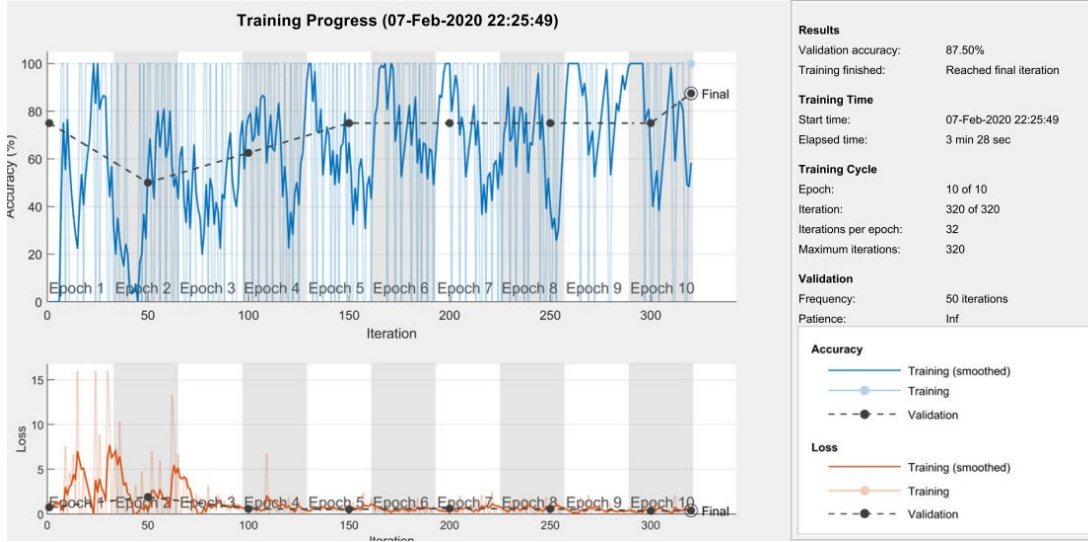


Şekil 38: Resnet KSA'nın yirmi epok değeri için sahip olduğu hassasiyet değerleri

Tüm bu olumlu sonuçlara karşıt, DenseNET KSA sisteminde köşe matrislerin sahip olduğu rezidüzel seviyelerin yarattığı tutarlı gürültü (consistent noise) seviyeleri ile epok iterasyonları başarılı bir şekilde sonuç vermemiştir. Altta Şekil 39 ve 40'de altı ve yirmi epok seviyelerinde gözlenen tutarsız sonuçlar yer almaktadır. Bu seviyede DR nokta ve seviyelerinin hassas bir şekilde tespitine yönelik EfficientNET ve ResNET KSA sistem çıktıları ile devam edilmiştir.



Şekil 39: DenseNET KSA'nın altı epok değeri için sahip olduğu hassasiyet değerleri




Şekil 40: DenseNET KSA'nın yirmi epok değeri için sahip olduğu hassasiyet değerleri

D. DR Lezyonlarının Tespitinde Başarım


DR ile ilişkili lezyonların tespitinde elde edilen başarılar açıklanmıştır. Retinal lezyonların doğru bir şekilde belirlenmesi, yapılan araştırmanın etkinliği ve DR ile ilgili klinik yorumlar açısından büyük önem taşımaktadır. Özellikle, eksudatlar, mikroanevrizmalar ve kanamalar gibi retinal lezyonların hem görüntü bölütlenme (image segmentation) hem de tespit başarıları incelenmiştir.

Bölütlenme başarısını değerlendirmek için, retinal damarlar ve optik disk gibi yapıların tespitinde olduğu gibi “Dice ve Jaccard” benzerlik indeksleri gibi ölçütler kullanılmıştır (Parashar et al., 2014). Bu indeksler gerçek ve tahmin edilen bölütler arasındaki benzerliği ölçerek; bölütlenme işleminin ne kadar doğru yapıldığını değerlendirir. Lezyonların tespiti için ise doğruluk, duyarlılık ve özgüllük gibi metrikler göz önünde bulundurulmuştur. Doğruluk, doğru pozitif ve doğru negatif tahminlerin toplam veri sayısına oranını ifade ederken, duyarlılık gerçek pozitiflerin tüm pozitifler içindeki oranını, özgüllük ise gerçek negatiflerin tüm negatifler içindeki oranını belirtir (Şekil 41). Bu metrikler; lezyon tespit algoritmalarının performansını değerlendirmede önemli bir rol oynar ve klinik uygulamalarda güvenilir sonuçlar elde etmek için gereklidir.




Şekil 41: Önceden eğitilmiş bir K mimarisi şematik görünümü. Üçüncü adımda, çıkarılan özelliklere bir havuzlama işlemi uygulanır ve bir özellik vektörü elde edilir.


Her iki performans ölçütü için bölütlemenin ve lezyon tespitin gerçekleştirildiği görüntüler, hem otomatik bir süreçle hem de uzman doktorlar tarafından manuel olarak işlenmiştir. Bu, algoritmaların ve uzman yorumunun karşılaştırılabilirliğini sağlamak adına önemlidir. Şekil 42-44 figürleri içerisinde, KSA çıktılarında elde edilen eksudat örneklerine yer verilmiştir. Bu karşılaştırma, otomatik algoritmaların insan uzmanlarına kıyasla ne kadar etkili olduğunu ve gerçek dünya uygulamalarında ne kadar güvenilir sonuçlar üretebildiğini değerlendirmek için yapılmıştır. Ayrıca, otomatik yöntemlerin doğruluğunu ve hassasiyetini belirlemek için uzmanlar tarafından yapılan manuel işlemler, standart olarak kabul edilmiştir. Bu nedenle bu karşılaştırma algoritmaların performansını objektif bir şekilde değerlendirmeye olanak tanır.



Şekil 42: Manuel olarak bölütlenen eksudatları temsil eden pikseller (Kırmızı), otomatik olarak bölütlenenleri (Yeşil) ve her iki yöntemle de tespit edilenleri (Sarı) gösterir.



Şekil 43: Retinal kanamaların bölütlenmesi sergilenmektedir. Uzman doktor tarafından elle tanımlanmış kanamalar kırmızı, otomatik olarak bölütlenmiş kanamalar yeşil, her iki yöntemle de tespit edilmiş kanama pikselleri ise sarı renkte gösterilmiştir



Şekil 44: Mikroanevrizma noktalarına ait bulgular verilmektedir. Uzman doktor tarafından elle tanımlanmış kanamalar kırmızı, otomatik olarak bölütlenmiş kanamalar yeşil, her iki yöntemle de tespit edilmiş kanama pikselleri ise sarı renkte gösterilmiştir

1. Hesaplanan KSA Öznelik Çıktıları

KSA çıktısı olan retina görüntülerine ait farklı çeşitlerde yer alan boyut, şekil ve pozisyonuyla ilgili bilgiler, görüntüye ait öznelikler olarak adlandırılır. Bu öznelikler, görüntünün geometrik özelliklerini tanımlar ve çeşitli analizlerde kullanılabilir. Örneğin; görüntünün alanı, ağırlık merkezi, eni, boyu, dolu alanı, çevresi, yuvarlaklığı gibi bilgiler özneliklere (attributes) örnek olarak verilebilir. Bu özneliklerden bazıları:

- Alan (Area): Görüntünün kapladığı alanın büyüklüğünü ifade eder. Piksel veya birim kare cinsinden ölçülür.
- Ağırlık Merkezi (Centroid): Görüntünün ağırlık merkezinin koordinatlarını belirtir. Bu, görüntünün dengesini ve dağılımını ifade eder.
- En (Width) ve Boy (Height): Görüntünün en ve boyunu ölçer, genellikle dikdörtgen veya benzeri geometrik şekiller için kullanılır.
- Dolu Alan (Filled Area): Görüntünün içindeki dolu piksellerin sayısını ifade eder. Yani, görüntünün içindeki boşluk olmayan alanın büyüklüğünü belirtir.
- Çevre (Perimeter): Görüntünün dış sınırlarının toplam uzunluğunu ifade eder.

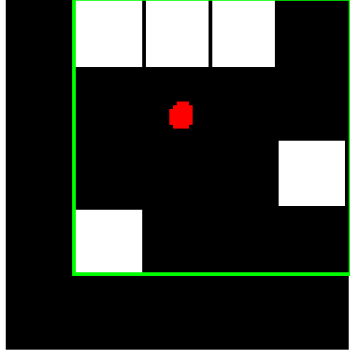

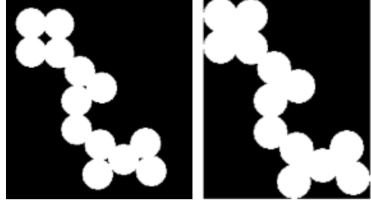


- Kapsam (Extent): Görüntünün dolu piksellerin toplam alanına oranını belirtir. Bu, görüntünün doluluk derecesini ifade eder.
- Yuvarlaklık (Circularity): Görüntünün ne kadar yuvarlak olduğunu belirtir. Bu, görüntünün dairesel bir şekle ne kadar yakın olduğunu gösterir.

Bu öznitelikler, görüntülerin analiz edilmesi ve sınıflandırılması gibi birçok uygulamada kullanılır. Örneğin, nesne tanıma, görüntü segmentasyonu ve şekil tanıma gibi alanlarda bu özniteliklerin kullanımı yaygındır. Bu öznitelikler, görüntülerin içerdiği bilgileri daha anlamlı bir şekilde çıkarmak ve daha sonra analiz etmek için temel sağlar. Tablo 4.1. içerisinde, verilen bir fonksiyondan alınan skaler değerli şekil öznitelikleri ve açıklamaları listelenmiştir. Bu öznitelikler, bir şeklin geometrik özelliklerini ve yapısal özelliklerini tanımlar ve genellikle görüntü işleme, nesne tanıma ve benzeri alanlarda kullanılır.

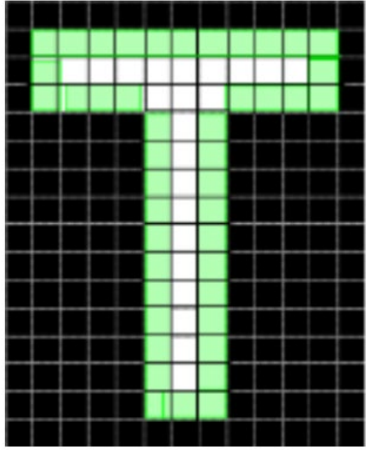
Çizelge 1: Lezyonların sınıflandırılması için kullanılan şekil öznitelikleri

Öznitelik	Özniteliğin Karşılığı	Şekil veya Karşılık Gelen Formül
Alan	İlgili bölgenin toplam piksel sayısı, belirli bir alanı kaplayan ve bu alanda bulunan piksellerin toplam sayısını ifade eder. Bu öznitelik, bir görüntünün belirli bir bölgesinin yoğunluğunu ve büyüklüğünü belirlemek için kullanılır. Bu özniteliğin değeri, ilgili bölgede bulunan tüm piksellerin sayısını gösterir ve genellikle sayısal bir değer olarak ifade edilir.	$A = \sum_{i=0}^M \sum_{j=0}^N \text{Img}(i, j)$ <p>Görüntüdeki siyah ve beyaz piksellerin toplam sayısını ifade eder. Gabon filtreli bir görüntüde her piksel siyah veya beyaz renge sahip olduğundan, toplam piksel sayısı görüntünün genel boyutunu ve yoğunluğunu belirlemek için önemlidir.</p>
Sınır Değerler	En küçük dörtgen, bölgenin dış sınırlarını belirlemek ve bu sınırların içine tam olarak sığan bir dikdörtgen oluşturmak için kullanılır. Bu öznitelik, lezyonun geometrik yapısını ve büyüklüğünü tanımlamak için kullanılır ve lezyonların sınıflandırılması ve tanımlanması için önemli bir bilgi sağlar.	İlk iki öge, dikdörtgenin sol üst köşesinin koordinatlarını x ve y ekseninde belirtir. Son iki öge ise dikdörtgenin genişliğini ve yüksekliğini belirtir. Bu bilgi, nesnelerin konumunu ve boyutunu tanımlamak için kullanılır ve nesnelerin algılanması, sınıflandırılması ve izlenmesi gibi birçok görüntü işleme ve makine öğrenimi uygulamasında önemlidir.

Çizelge 1: Lezyonların sınıflandırılması için kullanılan şekil öznitelikleri devamı

<p>Lezyon/OD Merkezi</p>	<p>Bölgenin içindeki piksellerin dağılımını tanımlamak ve bölgenin geometrik merkezini belirlemek için kullanılır. Özellikle nesne tespiti, nesne takibi ve görüntü segmentasyonu gibi alanlarda, bölgenin kütle merkezi önemli bir özniteliktir ve nesnelerin konumunu belirlemede kullanılır.</p>	
<p>Öznitelik Şekil Kontav Alanı</p>	<p>Özniteliğin Karşılığı</p> <p>Bu öznitelik, bir görüntünün içindeki dışbükey bir nesnenin boyutunu ve büyüklüğünü belirlemek için kullanılır. Dışbükey bir görüntü, iç kıvrımları veya çıkıntıları olmayan ve sınırları dışbükey bir şekilde olan bir görüntüdür</p>	<p>Şekil veya Karşılık Gelen Formül</p> 
<p>Piksel Yoğunluğu</p>	<p>Nesnenin iç kısmındaki dolu piksellerin yanı sıra, boşluk olarak adlandırılan ve içerisinde hiçbir piksel olmayan alanların da toplamını ifade eder. Özellikle, nesnelerin içindeki boşlukların varlığı ve boyutu, nesnelerin yapısını ve özelliklerini tanımlamak için önemlidir</p>	
<p>Eksen Uzunlukları</p>	<p>Genellikle bir nesnenin en büyük boyutu, nesnenin boyutunu ve nesnelerin sınıflandırılması ve tanımlanması için önemlidir. Piksel cinsinden eksen (a,b) uzunluk, nesnenin genel boyutunu ifade eder ve genellikle görüntü işleme ve nesne tanıma gibi alanlarda kullanılır.</p>	
<p>Öznitelik Oryantasyon</p>	<p>Özniteliğin Karşılığı</p> <p>En büyük eksenle yatay noktaların yaptığı açı, bir nesnenin en büyük ekseninin yatay düzleme göre ne kadar eğik olduğunu ifade eder. Bu açı, nesnenin yönünü ve eğilimini belirler.</p>	<p>Şekil veya Karşılık Gelen Formül</p> 

Çizelge 1: Lezyonların sınıflandırılması için kullanılan şekil öznitelikleri devamı

Sınırlayan Pksel Değeri/Sayısı	Bu mesafe, nesnenin sınırlarının belirlenmesi ve dış çevresinin uzunluğunun ölçülmesi için kullanılır. Genellikle piksel cinsinden ölçülür ve nesnenin dış sınırlarının etrafındaki toplam piksel sayısını ifade eder.	
---------------------------------------	--	--


E. SHAP Küresel Modelleme Sonuçları

DR tespiti üzerine makine öğrenimi kullanarak yapılan araştırmaların sonuçlarını karşılaştırmak amacıyla (Zhang et al., 2019; Tao et al., 2019; Tran et al., 2019; Birgül vd., 2024), yaygın olarak kullanılan geleneksel üç mimariyi karşılaştırmalı bir çalışma gerçekleştirmişlerdir. Çalışmalarının sonuçları, EfficientNet'in doğruluk ve model mimarisi için kullanılan parametre sayısı açısından diğer modellere üstünlük sağladığını göstermektedir. Bu tez çalışmasının devamında EfficientNET KSA çıktıları, küresel ekseninde modelleme çalışmalarına dahil edilerek sonuçları irdelenmiştir.

Görüntü işleme ve genel makine öğrenimi bağlamında, her SHAP değeri, her bir özelliğin (örneğin, bir görüntünün alanı) hedef tahminine olumlu ve olumsuz olarak ne kadar katkıda bulunduğunu belirler. Mevcut özellik analizi teknikleri, özelliklerin önemini genel olarak hesaplanmasına rağmen, SHAP yaklaşımı her veri kümesi görüntüsü için yerel özellik önemini hesaplar ve her bir özelliğe belirli bir tahmin için bir önem değeri atanmıştır. Bu yaklaşım, mevcut özellik önemi tekniklerindeki tutarsızlık sorunlarını ele alınabilir ve bu tutarsızlıklarla ilişkilendirilen yanlış yorumların etkisi azaltılabilir. Bu çalışmada, SHAP analiz tekniği, fundus görüntülerinin hangi bölgelerinin, hastalığın ciddiyetine göre DR varlığını veya farklı DR aşamalarını en çok gösterildiğini vurgulamak için kullanılmıştır.

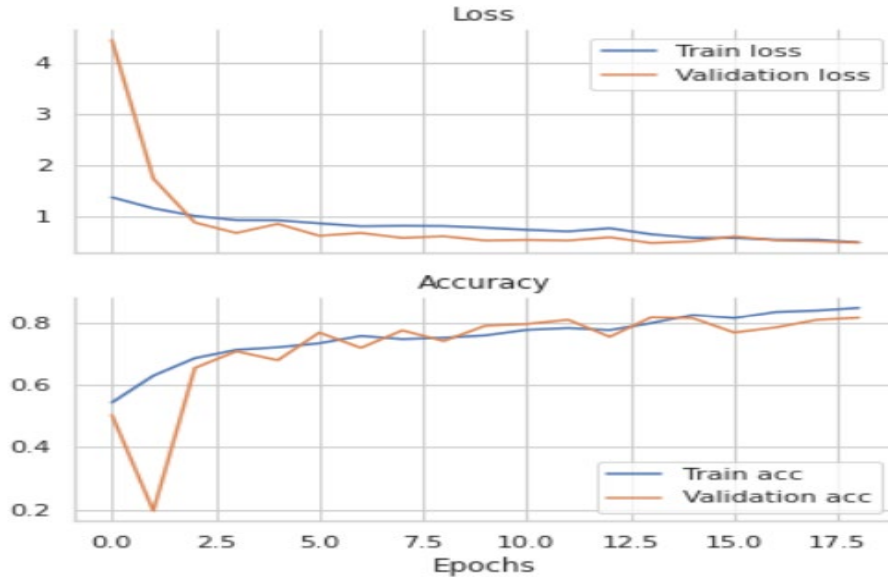
DR tespiti sorununa olan katkımızı belirlemek amacıyla SHAP analizi sonuçlarının örnek sonuçları Şekil 45'da sunulmuştur. Bu şekilde, orijinal görüntünün

sunumu ve yapılandırması açısından benzer iki veri örneği sağlanmıştır. Bir örnek DR=0 olarak etiketlenmişken, diğeri ise DR görüntüsünü temsil etmektedir (Şekil 45). Her bir görüntünün sağ tarafında sunulan SHAP çıktısı, derin öğrenme modelinin tahmini için kullandığı önemli bölgeleri vurgulamaktadır. Bu DR noktalarını küresel koordinat düzleminde görselleştirmede, kırmızı pikseller modelin tahminini arttırırken, mavi pikseller tahmin noktalarını azaltmaktadır. Ayrıca, Şekil 45'deki yeşil alanlar, APTOS verisetinde yer alan ve tıp uzmanı tarafından manuel olarak belirlenen lezyonlu bölgeleri temsil etmektedir. Tekrar bu şekilde alt kısımda yer alan, DR olmayan şekilde kırmızı olarak vurgulanan alanların, DR olarak etiketlenmiş görüntüde mavi olarak vurgulandığı gözlemlenmektedir.



Şekil 45: DR durumunu tespit etmek için kullanılan göz alanlarını gösteren örnek görüntüler

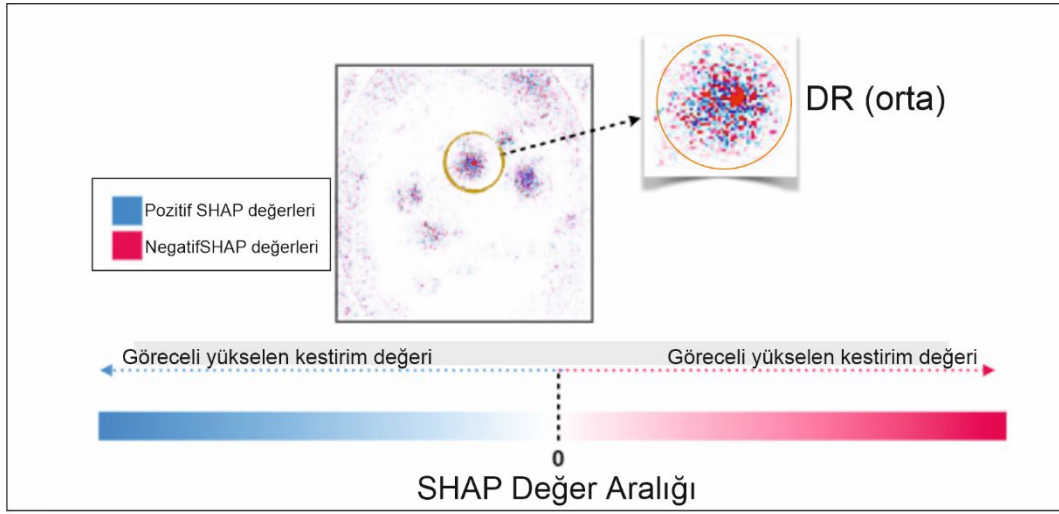
Bu tez kapsamında, genel doğruluk oranı %87 ve kayıp piksel oranı ise 0.0048 olarak elde edilmiştir (Şekil 46). Model, en iyi performansını DR olmayan sınıfı tespit etmek için %98 doğrulukla sergilemiş olup, takriben %84 doğrulukla Orta DR izledi. Hafif DR ve Ağır DR sınıfları sırasıyla %76 ve %71 doğrulukla tespit edilmiştir. Proliferatif DR kategorisi modelleme başarımleri arasında, örneklerin sadece %65'ini doğru bir şekilde tespit edebilmek sonuncu sırayı almıştır. Bu sınıftan yanlış sınıflandırılan örneklerin çoğu, bu sınıfın küçük boyutundan veya bu üç kategorideki DR belirtileri arasındaki klinik benzerlikten kaynaklanmaktadır. Ayrıca, ayrıntılı tahmin sonuçları, Ağır DR sınıfının çoğu Yanlış Negatif'inin (FN) Orta DR kategorisine atandığını göstermektedir. Bu, ilerleyen DR'yi tespit etmek için otomatik teknikler geliştirirken veri veya öğrenme mimarisi üzerinde modelin sahip olduğu KSA'nın ön niteliklere ihtiyaç duyduğu gerekliliğini vurgulamaktadır.



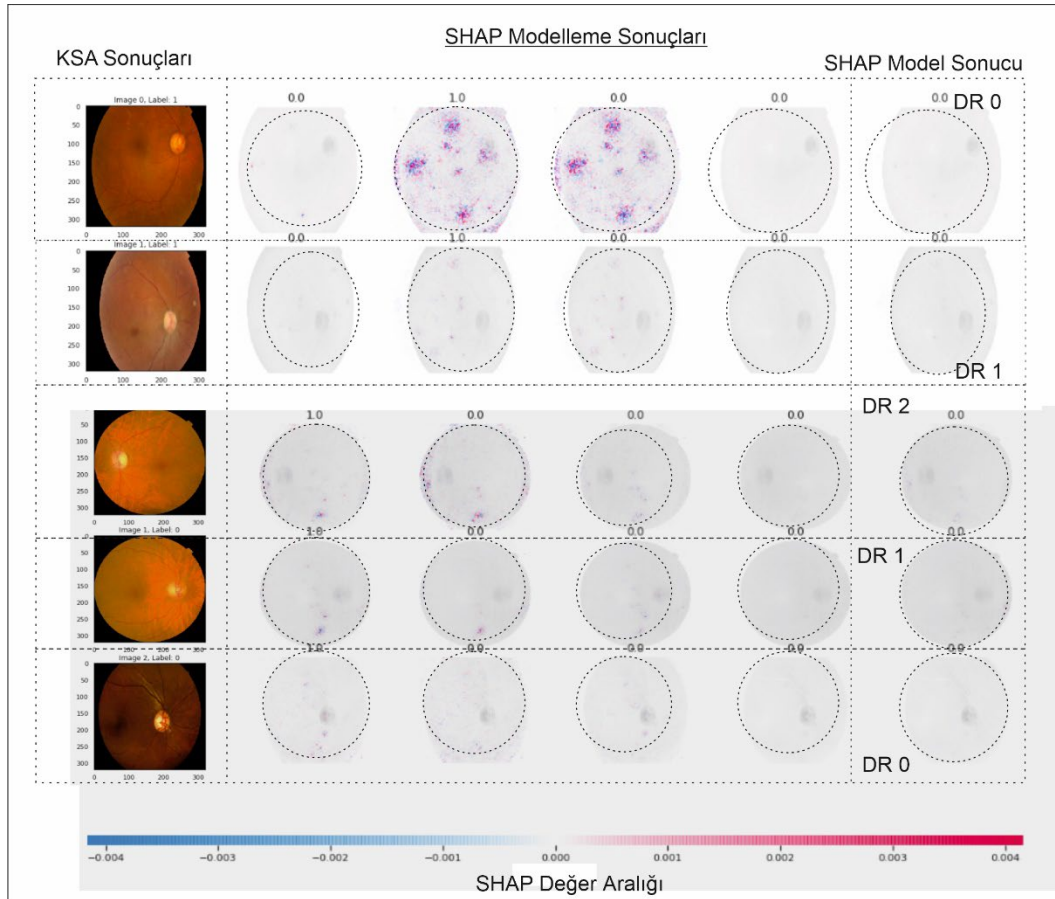
Şekil 46: Çoklu sınıflandırma görevi için kayıp ve doğruluk diyagramları, öğrenme sürecinde aşırı uyum olmadığını göstermektedir.

SHAP küresel (spherical) çözümler , modelin tahminlerini daha doğru bir şekilde açıklamak için görüntünün bireysel piksellerine özellik önem skorları atayarak daha kesin bir açıklama sağlamaktadır. SHAP analizi, görüntülerin önemli bölgelerini belirleme konusunda daha etkili olduğumuzu tespit ettik; pembe bölgeler, retinoblastoma görüntülerinde önemli olarak tanımlanan alanları doğru bir şekilde vurgularken, mavi bölgeler normal görüntülerde önemli özelliklerin eksikliğini göstermektedir. SHAP konumlandırma modülü ayrıca, sınıflandırma için en önemli

özelliklerin sarı-beyaz OD kitlesi ve klasifikasyonun klinik gözlemlerle uyumlu sonuçlar verdiğini de göstermektedir. SHAP değerlerinin görselleştirmeleri, modelin karar verme sürecine değerli bir içgörü sağlar ve tıbbi profesyonellerin modelin tahminlerini yorumlamasına yardımcı olabilmekte olup bu tezin hipotezlerinde belirtilen kestirim şartlarını sağlamaktadır. Şekil 47. içerisinde SHAP değerlerinin kartezyene taşınmasına yönelik örnek bir görüntü, Şekil 48. içerisinde ise veri setinden rastgele alınmış normal fundus görüntüleri için SHAP değerlerme sonuçlarını göstermektedir.



Şekil 47: SHAP değerlerinin kartezyene taşınmasına

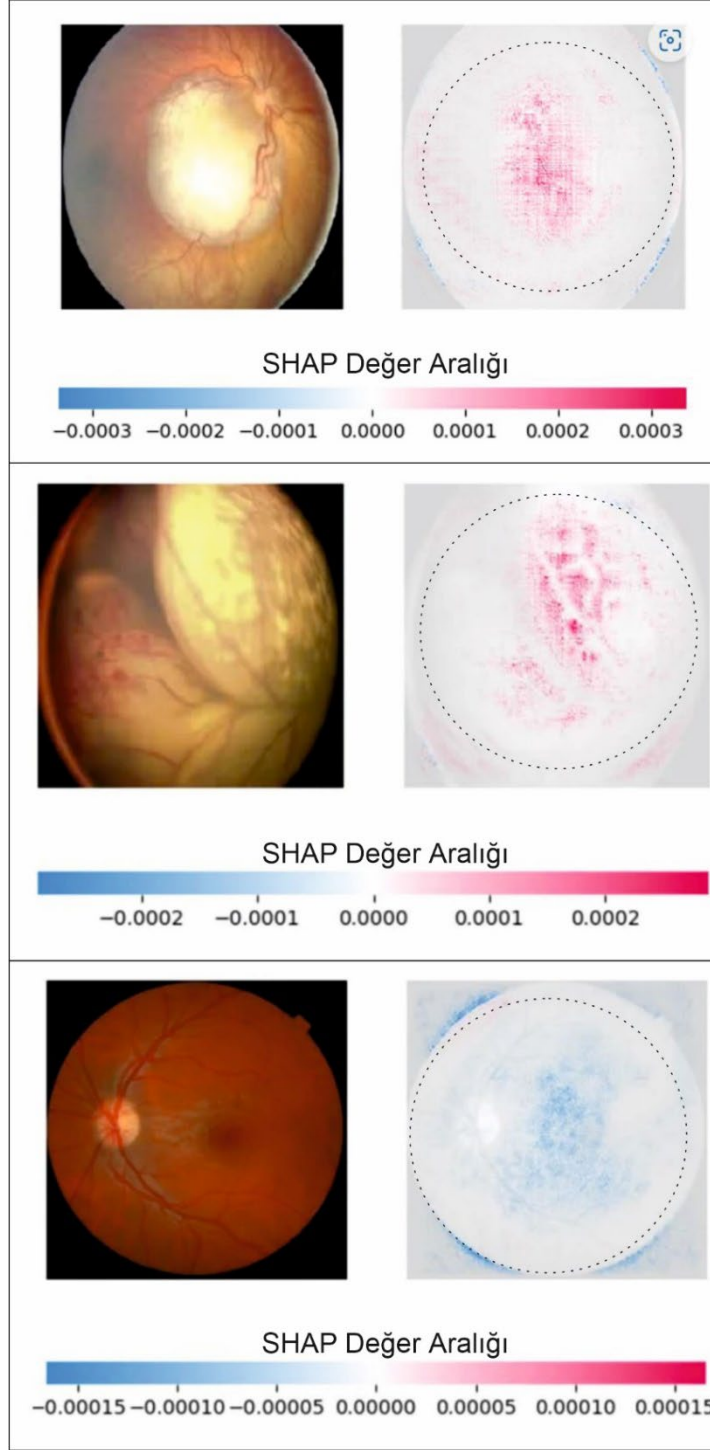


Şekil 48: Rastgele alınmış normal fundus görüntüleri için

Bu çalışma, literatür özetinde yer alan ve KSA temelli DR tespit, lokasyon ve derece kestirim çalışmalarıyla karşılaştırdığımızda, doğruluk ve diğer performans metrikleri açısından çoğunu geride bıraktığımızı açıkça görmekteyiz. Örneğin, Gangwar et al. (2021) yaptığı çalışmada, yapay zeka modeli duyarlılıkta %81, PPV (pozitif tahmin değeri) değerinde %79,6 ve NPV (negatif tahmin değeri) değerinde %67 başarı elde etti. Onların modeli yüksek özgünlük ve PPV değerlerine sahip olsa da, duyarlılık ve NPV açısından zayıf bir performans sergilemiştir. Buna karşın, kendi modelimiz ortalama %84 yüksek bir geri çağrı elde etmiştir, ki bu, pozitif örnekleri doğru bir şekilde tanımlama yeteneğini göstermektedir. Bu özellik, yanlış negatif sonuçların hastaların sonuçları üzerinde olumsuz etkilere sahip olabileceği tıbbi uygulamalarda özellikle önemlidir.

KSA tabanlı benzer çalışmalar içerisinde EfficientNET mimarisi kullanarak Ekoe (2019) ortalama ~%75, Chakraborty ve diğ. (2020) ~%77 doğruluk kestirimi elde ederken ResNet50 mimari altyapımı kullanan Olewi et al. (2020) çalışmasında, ortalama %78 doğruluk kestirimi elde etmiştir. Bu oranlar, bu tez çalışması


kapsamında üretilen nihai modelin elde ettiği %84'lük doğruluktan önemli ölçüde daha düşüktür. Bu, ön işlemlerde Gabon gibi öznelik filtrelerinin efektif kullanarak yapılan aktarım öğrenme yaklaşımının modelin doğruluğunu artırmada etkili olduğunu göstermektedir. Dahası, Jebaseeli et al. (2019) çalışmasında, doğrusal tahminsel karar tabanlı ortanca filtre ve KSA modeli %98,84 doğruluk, %97,96 duyarlılık ve %98,32 özgünlük elde ettiği gözlenmektedir. Bu çalışmanın sahip olduğu modeli yüksek doğruluk ve duyarlılık elde etmesine rağmen, özgünlük ve farklı verisetlerine karşı modelin kendini adaptasyonu açısından bu çalışmada üretilen SHAP çıktıları ile kıyaslandığında (Şekil 49) daha düşük bir performans sergilemiştir. Bu sonuçlar, bu çalışmada üretilen negatif örnekleri yüksek hassasiyetle doğru bir şekilde tanımlayabileceğini göstermektedir.



Şekil 49: Üretilen SHAP modelleme sonuçlarında gözlenen, DR =2 ve DR= 3 seviye retinalardan elde edilen yüksek polariteye sahip sonuçlar.

Bu çalışmanın bir diğer önemli bulgusu, prospektif DR tespiti için öngörülse modellerin kullanılması durumunda, etiketlerin kalitesi ve önceden eğitilmiş modellerin zenginliği (örneğin, tez kapsamında işlenen ResNet mimarisi) ne olursa olsun, verilerin derin öğrenme modelinden geçirilmeden önce özellik mühendisliği

yapılmasının önemli olmasıdır. Örneğin, Şekil 50'de gösterildiği gibi, çok sınıflı sınıflandırma amaçlı Jebaseeli et al. (2019) tarafından tanımlanan Proliferatif DR (DR seviye= 4) görüntüsü, Proliferatif DR kategorisi için modeldeki bağlam bilgisinin eksikliği nedeniyle orta DR'ye (yani, etiket = 2) şeklinde yanlış sınıflandırılmıştır. SHAP çıktılarındaki vurgulanan alanlar, modelin DR sonucu hakkındaki kararlarını etkileyen veri noktalarını sunmaktadır.



Şekil 50: Proliferatif DR kategorisinden örnek yanlış sınıflandırılmış bir görüntü. SHAP analiz sonucu, bu örneğin neden orta düzey DR'ye (DR seviye = 2) yanlış sınıflandırıldığını açıklamaya yardımcı olmaktadır.

Şekil 50'deki örnekte gösterildiği gibi, modelin doğru kategori hakkında en az bilgiye sahip olduğunu gözlemleyebiliriz. Bu durum, Proliferatif DR kategorisine daha fazla örnek ekleyerek ve daha özelleştirilmiş bir özellik mühendisliği yaparak (örneğin, bu durumda SHAP analizi kullanarak) hafifletilebilir. Bu figür ayrıca, Orta ve Ağır DR (yani, DR seviye = 2 ve 3) kategorilerinin benzerliği hakkındaki önceki tartışmamızı doğrulamaktadır. Aynı alanların neredeyse her iki kategoride de en etkili alanlar olarak vurgulandığını görebiliriz. Dahası, SHAP analizi görevlerimizin sonuçları, bireysel hastalarda gelişen DR'yi tahmin etmek için derin öğrenmeyi kullanma üzerine yapılan ve literatür taraması başlığında yer alan çalışmalarda belirlenen noktalarla da uyumludur.

V. SONUÇ VE ÖNERİLER

Sonuç olarak, bu çalışma Diyabetik Retinopati'nin şiddetini sınıflandırmak için önceden eğitilmiş konvolüsyonel sinir ağlarının farklı yığın yaklaşımının etkinliğini sergilemiştir. EfficientNet, ResNet ve DenseNet'den oluşan yığın modeli, sonuçları SHAP isimli iki boyutta elde edilen verilerin küresel eksen üzerinde modellenmesini amaçlayan bir modül yardımıyla insan gözünün sentetik bir kopyası üzerinde değerlendirmeye olanak sağlamaktadır. Yaklaşık olarak ortalama %88'lik bir doğrulama doğruluğu elde etmiş ve temel benzer çalışmalarda yer alan modellerin performanslarını yakalayıp bazı güncel çalışmalardan üst düzey sonuçlar göstermiştir. Yığın KSA modellerin yüksek kestirim ve hassasiyeti, duyarlılığı, ROC-AUC puanı ile ifade edilmiştir. Bu bulgular, tıbbi görüntü sınıflandırma görevlerinde “ensemble” öğrenme ve konvolüsyonel sinir ağları yöntemlerinin efektif uygulamasını vurgulamaktadır, özellikle birden fazla modelin güçlü yanlarını birleştirerek genel performansı artırmak için bir kümülatif model ölçeği güncel tıp literatüründe yer alan DR gibi görüntü işleme ünitelerinde yer alan bir hastalık üzerinde oldukça efektif bir şekilde kullanılabilir.

Gelecekte, potansiyel iyileştirme ve gelecek çalışma alanları bulunmaktadır. Temel modellerin belirli görevler üzerinde ince ayarlanması, yığın model için farklı mimarilerin keşfedilmesi ve hiperparametre ayarlanması yapılması, ensemble performansını daha da artırabilir. Ayrıca, ensemble'nin farklı mimarilere dayalı modelleri içerecek şekilde genişletilmesi, sağlamlığını artırabilir. Bu araştırma alanları, retinopatiyi sınıflandırmada daha yüksek doğruluk elde etmek için umut vadetmektedir. Bu bağlamda, gelecekteki çalışmaların, daha karmaşık algoritmaların incelenmesi, ensemble tekniklerinin geliştirilmesi ve model hiperparametrelerinin daha iyi ayarlanması gibi yöntemlerle, mevcut sınıflandırma modellerinin performansını artırmak üzerine odaklanması gerekebilir.

Bu çalışmanın sonuçları, retinopati sınıflandırmasının ötesindeki etkilerini vurgulamaktadır. Doğru erken teşhis yoluyla hastalık tanısında modellerinin

potansiyelini ve sonuçlarını iyileştirmektedir. Tıp alanında, modellerin sürekli olarak doğrulanması ve değerlendirilmesi, hem eğitim verilerinde hem de gerçek dünya verilerinde etkin performans sağlamak için kritik önem arz etmektedir. Bu sürekli doğrulama ve değerlendirme süreci, yanlış teşhislerin ilişkilendirildiği riskleri azaltarak ve sonuç olarak hasta bakımının kalitesini artırarak, modelin güvenilirliğini ve kullanılabilirliğini artırabilir. Bu nedenle, tıbbi modellerin geliştirilmesi ve sürdürülmesinde bu tür bir süreç, başarılı sonuçlar elde etmek için önemli bir adımdır.

VI. KAYNAKÇA

KİTAPLAR

- ABDELMAKSOU, E., EL-SAPPAGH, S., BARAKAT, S., ABUHMED, T., & ELMOGY, M. (2021). Automatic Diabetic Retinopathy Grading System Based on Detecting Multiple Retinal Lesions. **IEEE Access**, cilt 9, ss. 15939–15960
- APTOS 2019 BLINDNESS DETECTION. [Online]. Available: <https://www.kaggle.com/competitions/aptos2019-blindness-detection/data> (visited on 2024).
- BAŞER, B. Ö., YANGIN, M., & SARIDAŞ, E. S. (2021). Makine öğrenmesi teknikleriyle diyabet hastalığının sınıflandırılması. **Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi**, cilt 25, sayı 1, ss. 112-120.
- BANERJEE, I., CRAWLEY, A., BHETHANABOTLA, M., DALDRUP-LINK, H. E., & RUBIN, D. L. (2018). Transfer learning on fused multiparametric MR images for classifying histopathological subtypes of rhabdomyosarcoma. **Computerized Medical Imaging and Graphics : The Official Journal of the Computerized Medical Imaging Society**, cilt 5, sayı 65, ss. 167–175.
- BİLGİN, G. (2021). Makine öğrenmesi algoritmaları kullanarak erken dönemde diyabet hastalığı riskinin araştırılması. **Journal of Intelligent Systems: Theory and Applications**, cilt 4, sayı 1, ss. 55-64.
- BODAPATI, J. D., SHAIK, N. S., & NARALASETTI, V. (2021). Composite deep neural network with gated-attention mechanism for diabetic retinopathy severity classification. **Journal of Ambient Intelligence and Humanized Computing**, cilt 12, sayı 10, ss. 9825-9839.
- CHAKRABORTY S, JANA G C, KUMARI D AND SWETAPADMA A. (2020) An Improved Method Using Supervised Learning Technique for Diabetic Retinopathy Detection. **International Journal of Information Technology**, cilt 12, sayı 2, ss. 473-477.

- CHEN, P., PAN, C. (2018) Diabetes Classification Model Based on Boosting Algorithms. **BMC Bioinformatics**, cilt 19, sayı 1, ss. 1-9.
- DOLA A. (2021)“Automated Grading Of Diabetic Retinopathy Using Densenet-169 Architecture,” **International Journal of Computer Applications**, cilt 8, sayı 2, ss. 18–23.
- EKOE J.M. (2019) “Diagnosis and Classification of Diabetes Mellitus,” **Encyclopedia of Endocrine Diseases (Second Edition)**, cilt 1, pp. 105–109,
- FLICKNER, M., SAWHNEY, H., NIBLACK, W., ASHLEY, J., HUANG, Q., DOM, B., GORKANI, M., HAFNER, J., LEE, D., PETKOVIC, D., STEELE, D., & YANKER, P. (1995). Query by Image and Video Content: The QBIC System. **Computer**, cilt 28, sayı 9, ss. 23–32.
- FLEMING AD, PHILIP S, GOATMAN KA, OLSON JA, SHARP PF., (2006) ”Automated microaneurysm detection using local contrast normalization and local vessel detection. **IEEE Trans Med Imaging**.; cilt 25, sayı, 9, ss.:1223–32.
- FLEMING, A.D., SAM, P., GOATMAN, K.A (2006). “Automated microaneurysmdetection using local contrast normalization and local vessel detection” **IEEETrans. Med. Imaging**. cilt 25, sayı 9, ss. 1223–1232.
- FRANKLIN, S. W., & RAJAN, S. E. (2014). Diagnosis of diabetic retinopathy by employing image processing technique to detect exudates in retinal images. **IET Image Processing**, cilt 8, sayı 10, ss. 601–609.
- GANGWAR, A. K., & RAVI, V. (2021). Diabetic Retinopathy Detection Using Transfer Learning and Deep Learning. **Advances in Intelligent Systems and Computing**, ss. 1176, 679–689.
- GIANCARDO, L. (2021). “Automated fundus images analysis techniques to screen retinal diseases in diabetic patients”. **International Journal of Computer Applications** cilt 28, sayı 9, ss. 23–32.
- GONDAL, W. M., KOHLER, J. M., GRZESZICK, R., FINK, G. A., & HIRSCH, M. (2017). Weakly-supervised localization of diabetic retinopathy lesions in retinal fundus images. **Proceedings - International Conference on Image Processing**, 2017-September, 2069–2073.

- HANSGEN, P., UNDRILL P.E. VE CREE M.J., 1998. **The application of wavelets to retinal image compression and its effect on automatic microaneurysm analysis.** *Comput. Methods Programs Biomed.* 56 (1), 1–10.
- HARDY, R.L., 1971. Multiquadric equations of topography and other irregular surfaces. **Journal of Geophysical Research.** Cilt 76, sayı 8, ss. 1905–1915.
- HATANAKA, Y., NAKAGAWA T., HAYASHI Y., KAKOGAWA M., SAWADA A., KAWASE K., HARA T. VE FUJITA H., 2008. Improvement of automatic hemorrhages detection methods using brightness correction on fundus images. in:**Proceedings of the SPIE.**cilt 6915, ss 69-153.
- HILLER, R, SPERDUTO R.D., PODGOR M.J., FERRIS F.L., VE WILSON P.W., 1988. Diabetic retinopathy and cardiovascular disease in type II diabetics. **The Framingham Heart Study and the Framingham Eye Study.** cilt 128, sayı 2, ss. 402-9.
- HOOVER, A., KOUZNETSOVA V. VE GOLDBAUM M., 2020. Locating blood vessels in retinal images by piece-wise threshold probing of a matched filter response. **IEEE Transactions on Medical Imaging.** cilt 19, sayı 3, ss. 203-210.
- JAHIRUZZAMAN, M., & HOSSAIN, A. B. M. A. (2016). Detection and classification of diabetic retinopathy using K-means clustering and fuzzy logic. **2015 18th International Conference on Computer and Information Technology, ICCIT 2015,** ss. 534–538.
- JEBASEELI, T. J., DURAI, C. A. D., AND PETER, J. D. (2019). Segmentation of retinal blood vessels from ophthalmologic **Diabetic Retinopathy images.** **Computers and Electrical Engineering,** cilt 73, ss. 245-258.
- JOSHÍ S., PRIYANKA SHETTY, S. R. (2015). Performance Analysis of Different Classification Methods in Data Mining for Diabetes Dataset using WEKA Tool. **International Journal on Recent and Innovation Trends in Computing and Communication,** cilt 3, sayı 11, ss. 68-73.
- JUTEL, A., (2011). Classification, disease, and diagnosis. **Perspectives in biology and medicine,** cilt 54, sayı 2, ss. 189-205.

- KAUR, H., KUMARĪ, V., 2018. Predictive modelling and analytics for diabetes using a machine learning approach. **Applied Computing and Informatics**, cilt 7, ss. 292–299.
- KAVAKĪOTĪS, I., TSAVE, O., SALĪFOGLOU, A., MAGLAVERAS, N., VLAHAVAS, I., CHOUVARDA, I., (2017). Machine learning and data mining methods in diabetes research. **Computational And Structural Biotechnology Journal**, cilt 15, ss. 104-116.
- KONONENKO, I., (2001). Machine learning for medical diagnosis: history, state of the art and perspective. **Artificial Intelligence in Medicine**, cilt. 23, sayı 1, ss. 89-109.
- KRIZHEVSKY A, SUTSKEVER I AND HINTON G E (2012). Imagenet Classification with Deep Convolutional Neural Networks. **Advances in Neural Information Processing Systems**, cilt 25, sayı 5, ss. 1097-1105.
- MERCALDO, F., NARDONE, V., SANTONE, A., (2017). Diabetes Mellitus Affected Patients Classification and Diagnosis through Machine Learning Techniques. **Procedia Computer Science**, cilt 112, sayı 25, ss. 19-28.
- NAYAK, J., BHAT, P. S., & ACHARYA, U. R. (2009). “Automatic identification of diabetic maculopathy stages using fundus images”. **Journal of Medical Engineering & Technology**, cilt 33, sayı 2, ss. 119–129.
- OLEIWI, K., L. SHI, Y. TAO, L.WEI, (2020) “A comparative analysis and risk prediction of diabetes at early stage using machine learning approach,” **International Journal of Future Generation Communication and Networking**, cilt. 13, ss. 4151–4163
- QIAO L, ZHU Y AND ZHOU H (2020) Diabetic Retinopathy Detection Using Prognosis of Microaneurysm and Early Diagnosis System for Non-Proliferative Diabetic Retinopathy Based on Deep Learning Algorithms. **IEEE Access**, cilt 8, ss. 104292-104302.
- QUMMAR S, KHAN F G, SHAH S, KHAN A, SHAMSHIRBAND S, REHMAN Z U, IFTIKHAR A K AND JADOON W (2019) A Deep Learning Ensemble Approach for Diabetic Retinopathy Detection. **IEEE Access**, cilt 7, ss. 150530-150539.

- PARASHAR, A., BURSE, K., RAWAT, K., (2014). A Comparative approach for Pima Indians diabetes diagnosis using lidasupport vector machine and feed forward neural network. **International Journal of Advanced Research in Computer Science and Software Engineering**, cilt 4, sayı 11, ss. 378-383.
- PRATT, H., COENEN, F., BROADBENT, D. M., HARDING, S. P., & ZHENG, Y. (2016). Convolutional Neural Networks for Diabetic Retinopathy. **Procedia Computer Science**, cilt 90, sayı 1, ss. 200–205.
- RODRÍGUEZ, R., CASTILLO, P. J., GUERRA, V., AZUELA, J. H. S., SUÁREZA, A. G., & IZQUIERDO, E. (2008). “A comparison between two robust techniques for segmentation of blood vessels”. **Computers in Biology and Medicine**, cilt 38, sayı 8, ss. 931–940.
- SHABAN, M., MAHMOUD, A. H., SHALABY, A., GHAZAL, M., SANDHU, H., & EL-BAZ, A. (2020). Low-complexity computer-aided diagnosis for diabetic retinopathy. **Diabetes and Retinopathy**, cilt 6, sayı 1, ss. 133–149.
- SHANTHI, T., & SABEENIAN, R. S. (2019). Modified Alexnet architecture for classification of diabetic retinopathy images. **Computers & Electrical Engineering**, sayı 76, ss. 56–64.
- SIDIBÉ, D., SADEK, I., MÉRİAudeau, F. (2015). Discrimination of retinal images containing bright lesions using sparse coded features and SVM. **Computers in Biology and Medicine**, sayı 62, ss. 175–184.
- SIKDER, M. MASUD, A. K. BAIRAGI, A. S. M. ARIF, A. A. NAHID, H. A. ALHUMYANI, “Severity classification of diabetic retinopathy using an ensemble learning algorithm through analyzing retinal images,” **Phys. Rev E.**, cilt. 13, ss.. 670, 2021.
- SZEGEDY, C., VANHOUCHE, V., IOFFE, S., SHLENS, J., & WOJNA, Z. (2016). Rethinking the inception architecture for computer vision. **In Proceedings of the IEEE conference on computer vision and pattern recognition**, ss. 2818-2826.
- SINGH, N., & TRIPATHI, R. C. (2010). “Automated Early Detection of Diabetic Retinopathy Using Image Analysis Techniques”. **International Journal of Computer Applications**, cilt 8, sayı 2, ss. 18–23.

- SOPHARAK, A., UYYANONVARA, B., BARMAN, S., & WILLIAMSON, T. H. (2008). “Automatic detection of diabetic retinopathy exudates from non-dilated retinal images using mathematical morphology methods”. **Computerized Medical Imaging and Graphics : The Official Journal of the Computerized Medical Imaging Society**, cilt 32, sayı 8, ss. 720–727.
- TAO Li, YINGQI Gao, KAI Wang, SONG Guo, HANRUO Liu, HONG Kang. (2019) “Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening”, **Information Sciences**, cilt 501, sayı 20, ss. 511-522.
- THAIYALNAYAKI, K., (2021). Classification of Diabetes Using Deep Learning and SVM Techniques. **International Journal of Current Research and Review**, cilt 13, sayı 1, ss. 110-146.
- TIWARI, P., SINGH, V. (2021) Diabetes disease prediction using significant attribute selection and classification approach. **In Journal of Physics: Conference Series**, cilt 1714, sayı 1, ss. 12-23.
- TRAN, B. X., LATKIN, C. A., GIANG, V. T., HUONG, L. T. N., SON, N., MINGXUAN, T., ZHI-KAI, L., CYRUS, S. H. H., ROGER, C. M. H. (2019). The Current Research Landscape of the Application of Artificial Intelligence in Managing Cerebrovascular and Heart Diseases: A Bibliometric and Content Analysis. **International Journal of Environmental Research and Public Health**, sayı 16, cil 2, ss. 69-99.
- WANG, C., LONG, Y., LI, W., DAI, W., XIE, S., LIU, Y., ZHANG, Y., LIU, M., TIAN, Y., LI, Q., DUAN, Y. (2020). Exploratory study on classification of lung cancer subtypes through a combined K-nearest neighbor classifier in breathomics. **Scientific reports**, cilt10, sayı 1, ss. 1-12.
- WILLOUGHBY C E, PONZIN D, FERRARI S, LOBO A, LANDAU K AND OMIDI Y (2010) Anatomy and Physiology of The Human Eye: Effects of Mucopolysaccharidoses Disease on Structure and Function—A Review. **Clinical & Experimental Ophthalmology**, cilt, 3, sayı 8, ss. 2-11.
- WONG, T. Y., & SABANAYAGAM, C. (2020). Strategies to Tackle the Global Burden of Diabetic Retinopathy: From Epidemiology to Artificial Intelligence. **International Journal of Ophthalmology**. cilt 243, sayı 1, ss. 9–20.

ZHANG, W., ZHONG, J., YANG, S., GAO, Z., HU, J., CHEN, Y., & YI, Z. (2019).
“Automated identification and grading system of diabetic retinopathy using
deep neural networks”. **Knowledge-Based Systems**, cilt 17, sayı 5, ss. 12–25.

ÖZGEÇMİŞ

Adı ve Soyadı: Şükran YAMAN ATCI

Eğitim Durumu (Kurum ve Yıl)

Lise: Kocasinan Süper Lise -1997

Lisans: Lefke Avrupa Üniversitesi-2005

Yüksek Lisans: Lefke Avrupa Üniversitesi-2009

Çalıştığı Kurum/Kurumlar ve Yıl:

Kuzey Kıbrıs Turkcell 2006-2008

Girne Amerikan Üniversitesi 2008-2010

Haliç Üniversitesi 2010-Devam ediyor