



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DIYABETİK RETİNOPATİ DERECELERİNİN
DERİN ÖĞRENME - TABANLI
SINIFLANDIRILMASINDA ÖN İŞLEM
YÖNTEMLERİNİN ETKİSİNİN ANALİZ
EDİLMESİ

Nur Sena ÖZTEKİN BAKTI

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Aralık-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Nur Sena ÖZTEKİN BAKTI tarafından hazırlanan “Diyabetik Retinopati Derecelerinin Derin Öğrenme – Tabanlı Sınıflandırılmasında Ön İşlem Yöntemlerinin Etkisinin Analiz Edilmesi” adlı tez çalışması 26/12/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Doç. Dr. Ömer Kaan BAYKAN
(Konya Teknik Üniversitesi)

Danışman

Dr. Öğr. Üyesi Ali SAĞLAM
(Konya Teknik Üniversitesi)

Üye

Dr. Öğr. Üyesi Murat KARAKOYUN
(Necmettin Erbakan Üniversitesi)

İmza

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

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

DECLARATION PAGE

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

Nur Sena ÖZTEKİN BAKTI

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

DIYABETİK RETİNOPATİ DERECELERİNİN DERİN ÖĞRENME - TABANLI SINIFLANDIRILMASINDA ÖN İŞLEM YÖNTEMLERİNİN ETKİSİNİN ANALİZ EDİLMESİ

Nur Sena ÖZTEKİN BAKTI

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

Danışman: Dr. Öğr. Üyesi Ali SAĞLAM

2024, 91 Sayfa

Jüri

**Doç. Dr. Ömer Kaan BAYKAN
Dr. Öğr. Üyesi Murat KARAAKOYUN
Dr. Öğr. Üyesi Ali SAĞLAM**

Diyabetik retinopati (DR), diyabetin ciddi bir komplikasyonu olup tedavi edilmediği takdirde görme kaybına yol açabilen bir göz hastalığıdır. Erken teşhis ve doğru derecelendirme, etkili tedavi süreçleri için oldukça kritik bir öneme sahiptir. Bu bağlamda, derin öğrenme tabanlı sınıflandırma yöntemleri DR'nin tespitinde umut vadeden yaklaşımlar sunmaktadır ancak derin öğrenme modellerinin başarısı, kullanılan ön işlem yöntemlerine büyük ölçüde bağlıdır. Tez kapsamında, DR hastalığının farklı derecelerinin derin öğrenme tabanlı sınıflandırılmasında, çeşitli ön işlem yöntemlerinin etkileri incelenmektedir.

Tez çalışması kapsamında, farklı ön işlem tekniklerinin (Gaussian blur, eşikleme, kontur tespiti, CLAHE ve median blur) sınıflandırma performansı üzerindeki etkileri analiz edilmektedir. Ön işlem yöntemleri iki farklı adımda uygulanmaktadır. Veri setine ilk olarak Gaussian blur yöntemi, eşikleme yöntemi ve kontur tespiti yöntemi uygulanmış (ilk ön işlem adımı) ve eğitilmiş, ardından ilk ön işlem adımı uygulanmış görüntülere ikinci ön işlem adımı olarak CLAHE ve Median blur yöntemleri uygulanmış (ikinci ön işlem adımı) ve eğitilmiştir. EfficientNetB5, VGG16 ve VGG19 gibi transfer öğrenme tabanlı modeller kullanılmakta ve her birinin ön işlem adımlarından sonra elde edilen sonuçları karşılaştırılmaktadır. APTOS ve Diabetic Retinopathy (resized) olmak üzere iki farklı veri seti üzerinde gerçekleştirilen deneylerde, veri setlerine uygulanan ön işlem yöntemlerinin sınıflandırma doğruluğu, kesinlik, duyarlılık ve F1 skor gibi performans metrikleri üzerindeki etkileri değerlendirilmektedir. APTOS veri seti için transfer öğrenme yöntemlerinin herhangi bir ön işlem uygulanmadan önceki doğruluk (accuracy) oranı EfficientNetB5 (%96,09), VGG16 (%95,18) ve VGG19 (%95,25) olarak; ilk ön işlem adımı uygulandıktan sonra (Gaussian blur – eşikleme – kontur tespiti) transfer öğrenme yöntemlerinin doğruluk oranı EfficientNetB5 (%95,49), VGG16 (%95,40) ve VGG19 (%95,05) olarak; ikinci ön işlem adımı uygulandıktan sonra (CLAHE – Median blur) transfer öğrenme yöntemlerinin doğruluk oranı EfficientNetB5 (%93,63), VGG16 (%95,18) ve VGG19 (%94,89) olarak elde edilmektedir. Diabetic Retinopathy (resized) veri seti için transfer öğrenme yöntemlerinin herhangi bir ön işlem uygulanmadan önceki doğruluk oranı EfficientNetB5 (%87,95), VGG16 (%89,72) ve VGG19 (%89,72) olarak; ilk ön işlem adımı uygulandıktan sonra (Gaussian blur – eşikleme – kontur tespiti) transfer öğrenme yöntemlerinin doğruluk oranı EfficientNetB5 (%87,77), VGG16 (%89,54) ve VGG19 (%89,54) olarak; ikinci ön işlem adımı uygulandıktan sonra (CLAHE – Median blur) transfer öğrenme yöntemlerinin doğruluk oranı EfficientNetB5 (%87,21), VGG16 (%89,54) ve VGG19 (%89,54) olarak elde edilmektedir. Ayrıca, ön işlem yöntemlerinin modelin doğruluk ve kayıp eğrilerindeki rolü incelenmektedir. Sonuçlar, kullanılan ön işlem adımlarının model performansında kısmi iyileştirmeler sağladığını ancak sonuçların sınıflandırma doğruluğunu büyük ölçüde artırmadığını

göstermektedir. Bu bulgular, derin öğrenme tabanlı sınıflandırma süreçlerinde ön işlem yöntemlerinin her zaman belirgin bir performans artışı sağlamayabileceğini ancak görüntü kalitesini iyileştirme ve model stabilitesine katkı sunma açısından önemli olabileceğini göstermektedir. Çalışma, DR tanısında kullanılacak derin öğrenme modelleri için uygun ön işlem stratejilerinin belirlenmesine yönelik kapsamlı bir çerçeve sunmaktadır. Tez çalışması, DR tanısının daha hızlı ve güvenilir bir şekilde yapılabilmesi için derin öğrenme tabanlı çözümlerin geliştirilmesine katkı sağlamayı amaçlamaktadır.

Anahtar Kelimeler: Derin Öğrenme, Diyabetik Retinopati, Evrişimli Sinir Ağları, Ön İşleme Transfer Öğrenme



ABSTRACT

MS THESIS

ANALYZING THE EFFECT OF PREPROCESSING METHODS ON DEEP LEARNING-BASED CLASSIFICATION OF DIABETIC RETINOPATHY DEGREES

Nur Sena ÖZTEKİN BAKTI

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

Advisor: Asst. Prof. Dr. Ali SAĞLAM

2024, 91 Pages

Jury

Assoc. Prof. Dr. Ömer Kaan BAYKAN

Asst. Prof. Dr. Murat KARAKOYUN

Asst. Prof. Dr. Ali SAĞLAM

Diabetic retinopathy (DR) is a severe complication of diabetes and an ocular disease that can lead to vision loss if left untreated. Early diagnosis and accurate grading are critically important for effective treatment processes. In this context, deep learning-based classification methods offer promising approaches for DR detection. However, the success of deep learning models heavily depends on the preprocessing techniques applied. This thesis investigates the effects of various preprocessing methods on the deep learning-based classification of different DR degrees.

In the scope of this thesis study, the effects of various preprocessing techniques (Gaussian blur, thresholding, contour detection, CLAHE, and median blur) on classification performance are analyzed. The preprocessing methods are applied in two distinct steps. In the first preprocessing step, Gaussian blur, thresholding, and contour detection methods are applied to the dataset and trained. Subsequently, the images from the first preprocessing step undergo the second preprocessing step, where CLAHE and median blur methods are applied and then trained. Transfer learning-based models such as EfficientNetB5, VGG16, and VGG19 are utilized, and the results obtained after each preprocessing step are compared. Experiments are conducted on two different datasets, APTOS and Diabetic Retinopathy (resized), to evaluate the impact of preprocessing methods on performance metrics such as classification accuracy, precision, recall, and F1 score. For the APTOS dataset, the accuracy rates of transfer learning methods before any preprocessing were observed as EfficientNetB5 (96.09%), VGG16 (95.18%), and VGG19 (95.25%). After applying the first preprocessing step (Gaussian blur – thresholding – contour detection), the accuracy rates were EfficientNetB5 (95.49%), VGG16 (95.40%), and VGG19 (95.05%). Following the second preprocessing step (CLAHE – Median blur), the accuracy rates were EfficientNetB5 (93.63%), VGG16 (95.18%), and VGG19 (94.89%). For the Diabetic Retinopathy (resized) dataset, the accuracy rates of transfer learning methods before any preprocessing were EfficientNetB5 (87.95%), VGG16 (89.72%), and VGG19 (89.72%). After the first preprocessing step (Gaussian blur – thresholding – contour detection), the accuracy rates were EfficientNetB5 (87.77%), VGG16 (89.54%), and VGG19 (89.54%). Following the second preprocessing step (CLAHE – Median blur), the accuracy rates were EfficientNetB5 (87.21%), VGG16 (89.54%), and VGG19 (89.54%). Additionally, the role of preprocessing methods in the models' accuracy and loss curves is examined. The results indicate that the preprocessing steps provide partial improvements in model performance but do not significantly enhance classification accuracy. These findings suggest that preprocessing methods in deep learning-based classification processes may not always yield substantial performance improvements. However, they can be crucial for improving image quality and contributing to model stability. This study offers a comprehensive framework for identifying suitable preprocessing

strategies for deep learning models used in DR diagnosis. The thesis aims to contribute to the development of deep learning-based solutions that enable faster and more reliable DR diagnosis.

Keywords: Convolutional Neural Networks, Deep Learning, Diabetic Retinopathy, Preprocessing, Transfer Learning



ÖNSÖZ

Tez çalışması, diyabetik retinopati hastalığının derecelerinin derin öğrenme tabanlı sınıflandırma yöntemleriyle analizi ve sınıflandırma öncesi kullanılan ön işlem tekniklerinin etkilerinin incelenmesine odaklanmaktadır. Diyabetik retinopati, diyabet hastalığının gözdeki damarları etkileyerek görme kaybına yol açabilen ciddi bir komplikasyon olup, erken teşhis edilmediğinde körlükle sonuçlanabilmektedir. Bu nedenle, diyabetik retinopatinin erken evrelerde tespit edilmesi, hastalığın yönetimi açısından büyük önem taşımaktadır. Bizzat kendim de tip-1 diyabetli bir birey olarak bu çalışmanın, diyabetik retinopati sınıflandırması alanındaki araştırmalara katkı sağlaması ve tıbbi görüntüleme alanındaki derin öğrenme uygulamalarının daha verimli hale getirilmesine yardımcı olmasını dilerim.

Tez çalışmasında araştırmanın yürütülmesi ve sonuçlanmasına kadar değerli yardım ve katkılarıyla beni yönlendiren ayrıca yüksek lisans eğitim hayatım boyunca yardımlarını esirgemeyen saygıdeğer danışman hocam Dr. Öğr. Üyesi Ali SAĞLAM' a teşekkürlerimi sunarım.

Her zaman yanımda olan ve beni bugünlere getiren annem ve babam; Necmiye ve Rauf ÖZTEKİN' e teşekkürü bir borç bilirim. Ayrıca her zaman beni destekleyen sevgili eşim Adem Onur BAKTI' ya teşekkür ederim.

Nur Sena ÖZTEKİN BAKTI
KONYA-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	5
3. MATERYAL VE YÖNTEM.....	10
3.1.Gözün Yapısı	10
3.1.1.Gözün ana bileşenleri.....	10
3.2.Diyabet Nedir?	12
3.2.1.Diyabet türleri	12
3.3.Diyabetik Retinopati	12
3.3.1.Non-proliferatif DR (NPDR)	13
3.3.2. Proliferatif DR (PDR).....	13
3.3.3.DR’ nin patolojik bulguları.....	14
3.3.4.DR sınıflandırılması.....	16
3.4.Derin Öğrenme	16
3.5.Yapay Sinir Ağları (YSA)	17
3.5.1.YSA’ nın yapısı	18
3.5.2.Aktivasyon fonksiyonları.....	18
3.5.3.YSA’nın öğrenme süreci	18
3.6.Konvolüsyonel Sinir Ağları (KSA)	19
3.6.1.KSA’nın temel yapısı.....	20
3.6.2.KSA’ nın özellikleri.....	28
3.6.3.KSA’ların DR analizinde kullanımı	28
3.7.Transfer Öğrenme	29
3.7.1.Transfer öğrenme yöntemleri.....	29
3.7.2.Transfer öğrenmenin avantajları	30
3.7.3.Transfer öğrenme yaklaşımları	31
3.8.Veri Setleri	37
3.8.1.Asia Pasific Tele-Ophthalmology Society (APTOS) veri seti.....	38
3.8.2.Diabetic Retinopathy (resized) veri seti.....	39
3.9.Ön İşlem Yöntemleri	40
3.9.1.Gaussian blur yöntemi	41
3.9.2.Eşikleme (Threshold) yöntemi.....	41
3.9.3.Kontur yöntemi	42
3.9.4.Kontrast Limitli Adaptif Histogram Eşitleme (CLAHE) yöntemi	43
3.9.5.Median blur yöntemi.....	44

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	47
4.1.Kullanılan Performans Metrikleri	47
4.1.1. Doğruluk	47
4.1.2. Kesinlik	48
4.1.3.Duyarlılık	48
4.1.4.F1 skor	48
4.2. Test Sonuçları	50
4.2.1. APTOS veri seti için sonuçlar	50
4.2.2. Diabetic Retinopathy (resized) veri seti için sonuçlar	57
5. SONUÇLAR VE ÖNERİLER	66
5.1 Sonuçlar	66
5.2 Öneriler	68
KAYNAKLAR	70

SİMGELER VE KISALTMALAR

Kısaltmalar

APTOS	: Asia Pasific Tele-Oftalmoloji Derneği
CLAHE	: Kontrast Limitli Adaptif Histogram Eşitleme
DR	: Diyabetik Retinopati
IRMA	: İnra-Retinal Mikrovasküler Anomaliler
KSA	: Konvolüsyonel Sinir Ağları
NPDR	: Non-Proliferatif Diyabetik Retinopati
PDR	: Proliferatif Diyabetik Retinopati
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zeka



1. GİRİŞ

Yapay zeka (YZ), son yıllarda teknoloji dünyasının en hızlı gelişen ve dikkat çeken alanlarından biri haline gelmiştir. İlk olarak 1950'lerde Alan Turing'in "Computing Machinery and Intelligence" başlıklı makalesinde yapay zekanın temel prensipleri ortaya konmuş ve makinelerin düşünme yeteneği üzerine sorular sorulmuştur (Turing, 1950). YZ, matematiksel modelleme, algoritmalar ve bilgisayar bilimleri arasındaki etkileşimler aracılığıyla hızla ilerlemiş, makine öğrenmesi ve derin öğrenme teknikleri sayesinde önemli bir gelişim göstermiştir (LeCun ve diğ., 2015).

YZ, bilgisayarların insan zekâsına özgü işlevleri taklit etme yeteneğini ifade eder ve makine öğrenmesi ile derin öğrenme gibi teknikleri içermektedir. Makine öğrenmesi, ham verilerden örüntüler oluşturarak bilgisayarların kendi bilgilerini elde edebilme kabiliyetidir. Derin öğrenme ise, makine öğrenmesinin bir alt dalı olarak yapay sinir ağları kullanarak verilerin derinlemesine analizini sağlamaktadır (Ünsal, 2024).

Makine öğrenimi ve derin öğrenme alanındaki gelişmeler, büyük veri kümelerinin analiz edilmesi ve güçlü hesaplama kaynaklarının kullanılmasıyla mümkün olmuştur (Goodfellow ve diğ., 2016). Bu gelişmeler, sağlık, tüketici teknolojileri, finans ve otomotiv gibi çeşitli sektörlerde yapay zekanın uygulama alanlarını genişletmiştir. Örneğin, sağlık sektöründe yapay zeka tabanlı sistemler, hastalıkların erken tespit edilmesi ve kişiselleştirilmiş tedavi yöntemleri geliştirme potansiyeline sahiptir (Esteva ve diğ., 2019). Finans sektöründe ise algoritmalar, risk yönetimi ve yatırım stratejilerinin geliştirilmesine olanak tanımaktadır (Joulin ve diğ., 2016).

YZ alanında en çok kullanılan iki teknoloji olan makine öğrenmesi ve derin öğrenme, günümüzde birçok sektörde köklü değişiklikler yaratmaktadır. Makine öğrenmesi, bilgisayarların deneyim yoluyla öğrenmesini sağlayan bir yöntem olarak, veri analizi ve modelleme süreçlerinde önemli bir rol oynamaktadır. 1950'lerde Alan Turing'in makinelerin öğrenmeleri hakkındaki düşüncelerinden bu yana, makine öğrenmesi birçok evrim geçirmiştir (Mitchell, 1997).

Makine öğrenmesinin temel ilkelerinden biri, algoritmaların büyük veri kümeleri üzerinden öğrenme yeteneği kazanmasıdır. Bu süreç, veri ön işleme, model seçimi ve modelin değerlendirilmesi aşamalarını içermektedir. Özellikle destek vektör makineleri (SVM), karar ağaçları ve k-en yakın komşu (k-NN) gibi yöntemler, çeşitli uygulamalarda sıklıkla kullanılmaktadır (Cover ve Hart, 1967; Breiman ve diğ., 1986; Cortes ve Vapnik, 1995).

Makine öğrenmesi, gerçek dünyadaki bilgilerle problemleri çözebilmeyi ve öznel kararlar verebilmeyi mümkün kılmaktadır. Derin öğrenme ise, makine öğrenmesinin bir alt kümesi olarak yapay sinir ağları modelleri kullanarak verilerin derinlemesine analizini ve karmaşık veri yapılarını öğrenmeyi hedeflemektedir (Akın ve Şahin, 2024).

Derin öğrenme, makine öğrenmesinin bir alt kümesi olarak çok katmanlı yapay sinir ağları kullanarak verilerden yüksek düzeyde soyutlamalar öğrenen bir yapay zekâ tekniğidir. Bu yöntem görüntü işleme, ses tanıma ve doğal dil işleme gibi alanlarda üstün performans sergilemektedir. Ayrıca derin öğrenme, biyolojik sinir ağlarından ilham alarak birden fazla işlem katmanından oluşan hesaplama modellerinin, birden fazla soyutlama düzeyine sahip veri temsillerini öğrenmesine olanak tanımaktadır (Ünsal ve Karaoğlu Yılmaz, 2024).

Derin öğrenmenin başarılı uygulamaları, çoğu zaman konvolüsyonel sinir ağları, tekrar eden sinir ağları ve uzun-kısa vadeli bellek ağları gibi spesifik ağ mimarilerini içermektedir. Bu mimariler, görüntü, ses ve metin verilerini işleme konusunda güçlü yetenekler sunmaktadır (Hochreiter ve Schmidhuber, 1997; LeCun ve diğ., 2015). Bu bağlamda, derin öğrenme tabanlı sistemler, özellikle yüksek doğruluk oranlarıyla DR sınıflandırmasında ve sağlık hizmetlerine erişimi artırmada oldukça önemli bir rol oynamaktadır (Quelleg ve diğ., 2017; Kermany ve diğ., 2018). Özellikle retina görüntülerinin sınıflandırılması için derin öğrenme yöntemlerinin başarısı, DR' nin erken tespit edilmesinde ve tedavi planlamasında umut verici sonuçlar ortaya koymaktadır (Ting ve diğ., 2017; Abramoff ve diğ., 2018).

DR, diyabet hastalarının gözlerinde gelişebilen ve tedavi edilmediği takdirde körlüğe yol açabilen ciddi bir göz hastalığıdır. DR, retina damarlarının hasar görmesi ile karakterize ve dünya genelinde körlüğün önde gelen nedenlerinden biri olarak kabul edilir (Klein ve diğ., 2004). Genellikle kontrol edilmeyen diyabetin ilerleyen aşamalarında ortaya çıkan retinopati gözdeki damarlara zamanla zarar vermekte, kanamalar ve sıvı sızıntılarıyla birlikte retinanın hasar görmesine neden olmaktadır. Hastalığın erken teşhisi, görme kaybının önüne geçilmesi açısından büyük bir öneme sahiptir. Geleneksel yöntemler, göz muayenesi ve çeşitli retina görüntüleme teknikleri kullanılarak tanı konulmaktadır. Ancak bu yöntemler genellikle zaman isteyen ve uzmanlık gerektiren süreçlerdir (Aiello ve diğ., 1998).

DR teşhisi genellikle göz muayenesi ve retina görüntüleme teknikleri kullanılarak yapılır. Fundus fotoğrafçılığı, optik koherens tomografi (OCT) ve fluorescein anjiyografi gibi yöntemler, retinadaki değişiklikleri ve hastalığın ilerleme seviyesini belirlemede

kritik rol oynar (Abramoff ve diğ., 2010). DR' nin erken evrelerde teşhis edilmesi ve tedaviye başlanması hastalığın ilerlemesinin durdurulması adına kritik bir öneme sahip olmaktadır. Tedavi seçenekleri arasında lazer tedavisi, intravitreal enjeksiyonlar ve vitrektomi gibi cerrahi yöntemler bulunmaktadır.

DR, hafif non-proliferatif retinopati (NPDR), ilerlemiş NPDR ve proliferatif diyabetik retinopati (PDR) olmak üzere genellikle üç ana evrede sınıflandırılmaktadır. Hafif NPDR, retinada mikroskobik damar hasarlarıyla başlar, ancak belirgin semptomlar göstermez. İlerlemiş NPDR, daha fazla damar hasarını ve kanamalarını içermektedir. Proliferatif diyabetik retinopati ise yeni damarların oluşumuyla karakterizedir ve bu yeni damarlar zayıf ve anormal olup, kanamalara ve ciddi görme kaybına neden olabilmektedir.

Son yıllarda, derin öğrenme algoritmalarının medikal görüntüleme alanında önemli ilerlemelere yol açtığı görülmektedir. Derin öğrenme, büyük veri kümesi üzerinde eğitilmiş yapay sinir ağları kullanarak görüntülerin otomatik olarak analiz edilmesini ve sınıflandırılmasını sağlamaktadır. Özellikle konvolüsyonel sinir ağları (KSA), retina görüntülerinin analizinde yüksek doğruluk ve güvenilirlik sunmaktadır (LeCun ve diğ., 2015). Ancak, derin öğrenme tabanlı sistemlerin performansı, genellikle kullanılan veri ön işlem yöntemlerine bağlıdır (Hinton ve diğ., 2012).

Ön işlem, ham görüntülerin daha anlamlı ve işlenebilir hale getirilmesi için uygulanan bir dizi tekniktir. Görüntü ön işlem yöntemleri arasında normalizasyon, boyutlandırma, gürültü azaltma, histogram eşitleme ve kontrast artırma gibi teknikler bulunmaktadır. Bu yöntemler, derin öğrenme modellerinin öğrenme süreçlerini iyileştirebilmekte ve daha yüksek sınıflandırma doğruluğu sağlayabilmektedir.

Tez çalışmasında, DR derecelerinin derin öğrenme tabanlı sınıflandırılmasında farklı ön işlem yöntemlerinin etkilerinin incelenmesi amaçlanmaktadır. Çeşitli ön işlem tekniklerinin derin öğrenme modellerinin performansını nasıl etkilediği analiz edilmektedir. Çalışma, DR teşhisinde daha etkili ve güvenilir otomatik sistemlerin geliştirilmesine katkıda bulunmayı hedeflemektedir.

Tez çalışması, 5 bölümden oluşmaktadır. İlk bölüm olan Giriş bölümünde, çalışmanın amacı ve önemi ortaya konularak DR sınıflandırmasının neden önemli bir alan olduğu ele alınmaktadır. Kaynak Araştırması başlıklı ikinci bölümde, literatürde DR sınıflandırmasında kullanılan mevcut yöntemler ve ön işlem aşamasında tercih edilen teknikler değerlendirilmektedir. Materyal ve Metot bölümünde ise, kullanılan veri setleri, derin öğrenme modeli, transfer öğrenme yöntemleri ve uygulanan ön işlem teknikleri

ayrıntılı olarak açıklanmakta, bu sürecin nedenleri ve uygulama aşamaları detaylandırılmaktadır. Dördüncü bölüm olan Araştırma Sonuçları ve Tartışma kısmında, ön işlem yöntemlerinin sınıflandırma performansına etkileri, test sonuçları ve performans metrikleri üzerinden tartışılarak sunulmaktadır. Son olarak, Sonuçlar ve Öneriler bölümünde çalışmanın elde ettiği bulgular özetlenmiş, bu bulguların DR sınıflandırmasına katkıları ve gelecekteki çalışmalar için öneriler yapılmaktadır.



2. KAYNAK ARAŞTIRMASI

DR, diyabet hastalarında retina damarlarında hasar oluşması sonucu gelişen ve görme yeteneğinin kaybolmasına neden olabilen bir göz hastalığıdır. DR'nin erken teşhisi ve doğru derecelendirilmesi, tedavi sürecinin etkinliğini artırmak açısından hayati öneme sahiptir ancak, DR'nin çeşitli evrelerdeki semptomları farklılık gösterdiğinden, doğru ve hızlı tespit zorlayıcı olabilmektedir. Bu bağlamda, derin öğrenme tabanlı sınıflandırma yöntemleri, görüntü işleme ve yapay zeka yöntemleriyle desteklenerek DR tanısı ve sınıflandırması konusunda umut verici sonuçlar sunmaktadır (Gulshan ve diğ., 2016). Bu alandaki çalışmalarda, sınıflandırma performansını iyileştirmek amacıyla farklı ön işlem yöntemleri kullanılmaktadır. Tez çalışması kapsamında, DR sınıflandırmasında kullanılan ön işlem yöntemlerinin performansına olan etkisi incelenmektedir. Bu bölümde, DR alanında yapılan çalışmalara dayanarak ilgili literatüre dair bir değerlendirme sunulmaktadır.

Shahin ve diğerleri yaptıkları çalışmada, fundus görüntülerini PDR'ye sahip olan ve olmayan olarak ikili bir sınıflandırma yapmak için bir yaklaşım geliştirmişlerdir. Entropi ve homojenlik dâhil olmak üzere iki indeksin dışında retinal kan damarlarının sahip olduğu alan ve eksüdaların sahip olduğu alan gibi patolojik bulguları çıkarmak için morfolojik işlemeyi benimsemişlerdir. Çalışmada modelin performansını artırmak için düzenli filtre bulanıklaştırma algoritması kullanılmıştır. Elde edilen sonuçlar, düzenlenmiş filtrenin fundus görüntülerinin geliştirilmesinde önemli bir rol oynadığını ve yüksek doğruluk değerlerine ulaşıldığını göstermektedir (Shahin ve diğ., 2012).

Akram ve diğerleri, fundus görüntülerinde mikroanevrizmaları, kanamaları, sert eksüdaları, yumuşak eksüdaları veya venöz lümen düzensizliklerini tespit etmek için yeni bir hibrit sınıflandırıcı tekniği oluşturmuşlardır. Önerilen tekniğin performansını değerlendirmek ve sınıflandırma doğruluğunu geliştirmek için m-medoids ile Gauss karışım modeli birleştirilmiştir. Çalışmada sistemin performansını değerlendirmek için doğruluk, hassasiyet ve özgüllük metrikleri kullanılmıştır. Elde edilen sonuçlara bakıldığında, hibrit sınıflandırıcının genel karmaşıklığının ve yürütme süresinin diğer sınıflandırıcılarla karşılaştırıldığında neredeyse aynı olduğunu, buna bağlı olarak doğruluktaki iyileşmenin hibrit sınıflandırıcı tarafından yapılan yürütme süresi üzerinde neredeyse hiçbir etkisinin olmadığını göstermektedir. Sonuçlar, önerilen sistemin patolojik bulguları yüksek doğruluk, hassasiyet ve özgüllük değerleri ile sınıflandırdığını

ve dolayısıyla önerilen sistemin patolojik bulguların erken tespiti için uygun hale getirildiğini göstermektedir (Akram ve diğ., 2013).

Welikala ve diğerleri yaptıkları çalışmada, neovaskülarizasyonu tespit ederek proliferatif DR'yi sınıflandırmak için bir yaklaşım geliştirmişlerdir. Her bir özellik kümesi üzerinde nihai sınıflandırmayı yapmak için destek vektör makinesi kullanılmıştır. Önerilen yaklaşımın performansını değerlendirmek için 60 görüntüye sahip bir veri tabanı kullanılmıştır. Elde edilen sonuçların, %88'lik bir duyarlılık değerine ve %94'lük bir özgüllük değerine sahip olduğu görülmektedir (Welikala ve diğ., 2014).

Zhang ve diğerleri, DR'yi tespit etmek için renkli fundus görüntüleri üzerinde eksüdaları tespit etmek için çalışma yapmışlardır. Bu çalışmanın performansını değerlendirmek için yeni bir klinik veri tabanı olan e-optha EX kullanılmıştır. Bu veri seti, kontur tespiti yöntemi uygulanmış eksüdaları içermektedir. Eksüdaları tespit etmek için önerilen yöntem, aynı hastanın başka zamanlardaki iki farklı muayenesi arasında hastalığın ne kadar ilerlediğinin belirlenmesi gibi karışık durumlar için geliştirilmiştir. Çalışmada segmentasyon yapılmış ve eksüdaları segmentlere ayırmak için rastgele orman algoritması kullanılmıştır. Çalışmanın sonuçlarına bakıldığında, yeni oluşturulan yöntemin önceki yöntemlerden daha iyi performans gösterdiğine ulaşılmakta ve geliştirilen yeni yöntemin test edilen tüm veri tabanlarında yüksek başarı sağladığı görülmektedir (Zhang ve diğ., 2014).

Waheed ve diğerleri, gözdeki kan damarlarının segmentasyonu için ortam sınıflandırmasına dayalı hibrit özellik veri kümesi kullanan bir yöntem geliştirmişlerdir. Çalışmada sağlıklı kan damarlarını ve diyabet etkisiyle anormal biçimde oluşan sahte kan damarlarını ayırt etmek için yeni bir bölge tabanlı hibrit özellik seti kullanmışlardır. Çalışmada, lezyonların varlığında kan damarlarını doğru segmente etmek için geliştirilmiş iki yöntem önerilmiştir. Birinci yöntemde, en iyi seçilmiş özellikler kullanılarak her bölge doğru veya yanlış olarak sınıflandırılmıştır. İkinci yöntemde ise komşuluk bazlı bölge doldurma adı verilen bir algoritma önerilmiş, sınıflandırmadan bağımsız olarak iyileştirme ve segmentasyon öncesinde lezyon bölgesinin boyanması yoluyla lezyon etkisinin azaltılması amaçlanmıştır. Bu yöntem lezyonlardan kaynaklanan sahte damarları ortadan kaldırmak için kullanılmıştır. Elde edilen sonuçların %88'lik bir doğruluk değerine sahip olduğu görülmektedir (Waheed ve diğ., 2015).

Gulshan ve diğerleri yaptıkları çalışmada, 1748 adet görüntüye sahip Messidor-2 ve 9963 adet görüntüye sahip EyePACS-1 veri setini kullanarak DR sınıflandırması yapmışlardır. Çalışmada transfer öğrenme modellerinden Inception-V3 modelini

kullanmışlardır. Elde edilen sınıflandırma sonuçlarında yüksek duyarlılık ve özgüllüğe ulaşıldığı görülmektedir (Gulshan ve diğ., 2016).

Pratt ve diğerleri yaptıkları çalışmada, Kaggle’da yer alan 80.000 adet DR görüntüsüne sahip EyePACS veri setini kullanarak DR’ yi sınıflandırmışlardır. Ayrıca DR derecelerini tespit etmek için KSA tabanlı bir model tasarlayarak beşli sınıflandırma gerçekleştirmişlerdir. Geliştirilen modelin DR’ ye sahip olmayan bir gözü öğrenmede başarılı olduğu fakat hafif, orta ve ciddi DR vakaları arasında ayırım yapmakta çok başarılı olmadığı görülmektedir. Modelin genellikle hafif ve orta DR sınıflarından gelen düşük hassasiyet nedeniyle DR'nin daha karmaşık yönlerinden bazılarını tespit etmek için yeterince derin özellikler öğrenmekte zorlandığı görülmektedir (Pratt ve diğ., 2016).

Gargeya ve Leng, klasik makine öğrenmesi yöntemi ile derin konvolüsyonel sinir ağını birleştiren bir yaklaşım geliştirmişlerdir. Çalışmada, retina görüntüleri ön işlemlerden geçirilmiştir ve sağlıklı/hastalıklı ayırımını yapmak için bir karar ağacı sınıflandırıcısı kullanılmıştır. Eğitilen modelde 5 kat çapraz doğrulamada %94 gibi başarılı bir sonuç elde edildiği görülmektedir (Gargeya ve Leng, 2017).

Gondal ve diğerleri, DR’nin tespiti için KSA modeli kullanan bir yaklaşım önermişlerdir. Eğitim için Kaggle’dan alınan EyePACS veri setini ve test için DiaretDB1 veri setini kullanmışlardır. DR’yi teşhis etmeye katkı sağlamak için fundus görüntüleri üzerinde bir derin öğrenme yaklaşımı sunulmuştur. Sunulan yaklaşımda, sınıflandırma yapılmıştır. Sınıflandırmada yüksek doğruluk değerine ulaşıldığı ve başarılı bir hassasiyet değeri elde edildiği görülmektedir (Gondal ve diğ., 2017).

Yalçın ve diğerleri çalışmalarında, DR’nin erken teşhisine yönelik yapmış oldukları ikili sınıflandırmada derin öğrenme tabanlı bir yöntem önermişlerdir. Çalışmada DiaretDB, Stare, Messidor veri setlerinden elde ettikleri 500 tane sağlıklı ve diğer 500 tanesi hastalıklı olmak üzere toplamda 1000 adet renkli fundus görüntüsü kullanmışlardır. Çalışmada derin öğrenme algoritmalarından KSA yöntemi tercih edilmiştir. Önerilen yaklaşımın %98,5 gibi yüksek bir sınıflandırma başarısına sahip olduğu görülmektedir (Yalçın ve diğ., 2018).

Qummar ve diğerleri yaptıkları çalışmada, EyePACS veri setini kullanarak DR’ yi sınıflandırmışlardır. Çalışmada renkli fundus görüntüleri kullanılarak DR’nin farklı derecelerini tespit etmek için KSA tabanlı transfer öğrenme modellerinden Dense-121, Dense-169, Resnet-50, Inception-V3, Xception modellerini kullanmışlardır. Elde edilen sonuçlar, önerilen yaklaşımın diğer güncel yöntemlerden daha yüksek performans

gösterdiğini ve aynı zamanda DR'nin tüm derecelerini tespit edebildiğini göstermektedir (Qummar ve diğ., 2019).

Sahlsten ve diğ.leri, DR'nin tespit edilmesi için yüksek doğruluğa sahip derin öğrenme tabanlı bir yöntem geliştirmişlerdir. Çalışmalarını, yüksek çözünürlüklü fundus görüntüleri üzerinde yapmışlardır. Ulaşılan sonuçlar, derin öğrenme yöntemlerinin DR'yi teşhis etmekte başarılı olduğunu göstermektedir (Sahlsten ve diğ., 2019).

Shanthi ve Sabeenian yapmış oldukları çalışmada, Messidor veri setini kullanarak DR'yi sınıflandırmışlardır. Çalışmada veri setindeki fundus görüntülerinden DR'nin 4 kategorili sınıflandırma derecelerini tespit etmek için transfer öğrenme yöntemlerinden Alexnet' i kullanmışlardır. Çalışmada, veri setindeki fundus görüntülerinin %70'i eğitim için %30'u algoritmanın performansını değerlendirmek için kullanılmıştır. Kullanılan değiştirilmiş Alexnet mimarisinin performansı doğruluk, duyarlılık, kesinlik ve özgüllük gibi performans metrikleri açısından değerlendirilmektedir. Önerilen değiştirilmiş Alexnet mimarisi kullanılarak %96 gibi başarılı bir doğruluk değerine ulaşıldığı görülmektedir (Shanthi ve Sabeenian, 2019).

Hemanth ve diğ.leri, fundus görüntülerinden DR tespiti için hibrit bir yöntem geliştirmişlerdir. Geleneksel histogram eşitleme ve kontrast limitli adaptif histogram eşitleme (CLAHE) yöntemleri kullanılarak görüntü işleme yapılmıştır. DR tespiti KSA kullanılarak gerçekleştirilmiştir. Geliştirilen yöntemin performans değerlendirmesi, 400 adet fundus görüntüsüne sahip Messidor veri seti kullanılarak gerçekleştirilmiştir. Ulaşılan tüm sonuçlar göstermiştir ki, retinopati teşhisi açısından daha yüksek sonuçlar elde etmek için derin öğrenme yöntemlerinin kullanımı önemlidir ve önerilen yöntem, derin öğrenme yöntemlerini içermeyen diğ. yöntemlere göre daha iyi performans sağlamaktadır (Hemanth ve diğ., 2020).

Bora ve diğ.leri, renkli fundus görüntülerinden oluşan EyePACS veri setini kullanarak, derin öğrenme yöntemleri ile hafif ve üzeri DR gelişme riskini tahmin etmişlerdir. Modelin, özellikle hafif ve üzeri DR gelişimini iki yıl öncesinden tahmin etmede yüksek AUC değerleri elde ederek başarılı sonuçlar elde ettiğine ulaşılmaktadır (Bora ve diğ., 2020).

Özcelik ve Altan yapmış oldukları çalışmada, fundus görüntülerine iki boyutlu sinyal işleme teknikleri uygulamışlar ve ardından Evrişimli Sinir Ağı (ESA) ve transfer öğrenme yöntemleri kullanarak hibrit bir model geliştirmişlerdir. Veri seti olarak APTOS 2019' u ve transfer öğrenme yöntemlerinden VGG19, Xception, InceptionV3, ResNet101' i kullanmışlardır. Modelin sağlamlığı 10-kat çapraz doğrulama yöntemi

kullanılarak doğrulanmıştır. Oluşturulan modelin, DR' nin beş farklı evresini sınıflandırmada en yüksek sonucu transfer öğrenme yöntemlerinden VGG19 kullanılarak %97.8 doğruluk değerine ulaşıldığı görülmektedir (Özçelik ve Altan, 2021).

Polater ve Işık yaptıkları çalışmada, APTOS 2019 veri setini kullanarak, derin öğrenme modelleriyle DR' nin teşhis ve sınıflandırılmasını gerçekleştirmişlerdir. Geliştirilen modelde Evrişimli Sinir Ağları ve transfer öğrenme yöntemlerini kullanmışlardır. Transfer öğrenme yöntemlerinden DenseNet121, MobileNetV2, DenseNet169, InceptionV3, VGG16, MobileNet, VGG19, ResNet50, ResNet101 kullanılmıştır. Önerilen modelin DenseNet121 modeli kullanılarak %97.0 doğruluk değerine ulaşıldığı görülmektedir (Polater ve Işık, 2024).



3. MATERYAL VE YÖNTEM

Bu bölümde, DR derecelerinin derin öğrenme tabanlı sınıflandırılması için kullanılan veri setleri, ön işlem teknikleri ve transfer öğrenme modelleri detaylandırılmaktadır. Tez kapsamında, görsel verilerin analizine yönelik olarak Gaussian blur, eşikleme (thresholding), kontur tespiti, CLAHE (Contrast Limited Adaptive Histogram Equalization) ve median blur gibi çeşitli ön işlem tekniklerinden yararlanılmaktadır. Bu ön işlem yöntemleri, görüntü kalitesini iyileştirmeyi ve sınıflandırma doğruluğunu artırmayı hedeflemektedir. Derin öğrenme modellerinin eğitimi için transfer öğrenme tabanlı EfficientNetB5, VGG16 ve VGG19 ağ mimarileri kullanılmakta ve bu modeller detaylı bir şekilde incelenmektedir. Bu modellerin seçilme nedeni VGG16 ve VGG19, derin yapıları sayesinde daha fazla özellik çıkarımı yapabilen, ancak hesaplama açısından daha pahalı modellerdir. EfficientNetB5 ise verimliliği ve performansı optimize etmektedir. Bu durum, farklı derinliklerin ve model boyutlarının karşılaştırılması açısından faydalı olabileceğinden tez çalışmasında bu üç model kullanılmaktadır. Ayrıca bu üç model, farklı parametreler ve eğitim yöntemleriyle çeşitli veri setlerinde karşılaştırılabilmektedir. Bu, model seçiminde esneklik sağlamak ve en iyi performansı elde etmek için doğru modelin seçilmesine olanak tanımaktadır.


3.1.Gözün Yapısı

Göz, görme sürecini yerine getiren ve farklı dokulardan oluşan karmaşık yapıya sahip bir organdır. Gözün yapısı, ışığı algılayıp beyne iletecek şekilde düzenlenmiştir. DR, gözün retina tabakasındaki kan damarlarında meydana gelen hasarlar sonucu ortaya çıkan ve tedavi edilmediğinde ciddi görme kaybına yol açan bir hastalıktır. Bu nedenle, gözün yapısını ve özellikle retina tabakasını anlamak, DR' nin etkilerini kavramak için oldukça önemlidir.

3.1.1.Gözün ana bileşenleri

- Kornea ve Sklera: Kornea, gözün ön kısmında yer alan saydam, kubbe şeklinde bir yapıdır ve göze giren ışığın ilk kırıldığı yerdir. Sklera ise gözün dış yüzeyini kaplayan beyaz, sert bir dokudur ve göz küresinin şeklini korur (Yanoff ve Duker, 2009).

- **Ön Kamera ve Göz İçi Sıvısı:** Ön kamera, kornea ile iris arasındaki boşluktur ve bu boşluk göz içi sıvısı ile doludur. Bu sıvı, göz içi basıncını düzenler ve besinlerin taşınmasına yardımcı olur (Bowling, 2016).
- **İris ve Pupil:** İris, gözün renkli kısmıdır ve pupili kontrol eden kaslardan oluşur. Pupil göze ışığın girdiği açıklık olarak tanımlanır. İris, ışık miktarını ayarlayarak pupilin büyüüp küçülmesini sağlar (Yanoff ve Duker, 2009).
- **Lens:** Lens, göze giren ışığın içeri doğru kırılarak retinada odaklanmasına yardımcı olan şeffaf bir yapıdır. Lensin kavisli yapısı, yakına ve uzağa odaklanmayı sağlar (Bowling, 2016).
- **Retina:** Retina, gözün arka kısmında bulunan ve ışığa duyarlı hücrelerden oluşan ince bir tabakadır. Bu tabaka, ışık sinyallerini elektrik sinyallerine dönüştürerek beyne iletmek üzere optik sinire gönderir (Yanoff ve Duker, 2009). DR, retinada bulunan küçük kan damarlarının hasar görmesi sonucu gelişir ve bu hasar, kanama, ödem ve son aşamada görme kaybına neden olabilir.
- **Makula ve Fovea:** Makula, retinanın merkezinde bulunan ve merkezi görmeden sorumlu olan bölgedir. Fovea ise makulanın orta kısmında yer alır ve en net görmeyi sağlayan kısımdır (Garg ve Jani, 2011).
- **Optik Sinir:** Optik sinir, retinadan gelen sinyalleri beyne ileten kalın bir sinir demetidir. Görme işlemi burada son bulur ve görsel algı beyinde oluşturulur (Yanoff ve Duker, 2009).



Şekil 3.1. Gözün anatomik yapısı (Kaynak: <https://gozdoktor.net/gozun-yapisi/>, erişim tarihi: 3 Eylül 2024)

3.2.Diyabet Nedir?

Diyabet, vücudun kan şekerini düzenleyen mekanizmalarında sorunlar oluşması sonucu ortaya çıkan kronik bir metabolik hastalıktır. Diyabet, insülinin üretilmemesi veya üretilen insülinin etkin bir şekilde kullanılamaması durumunda kan şekeri seviyelerinin yükselmesi ile karakterize edilir. Bu durum, uzun vadede kalp, damar, göz, böbrek ve sinir sistemlerinde ciddi komplikasyonlara yol açabilir (World Health Organization [WHO], 2021).

3.2.1.Diyabet türleri

Diyabetin başlıca üç türü bulunmaktadır:

- **Tip 1 Diyabet:** Tip 1 diyabet, vücudun bağışıklık sisteminin pankreastaki insülin üreten beta hücrelerine saldırarak hasar vermesi sonucunda ortaya çıkar. Genellikle çocukluk veya gençlik döneminde teşhis edilir ve ömür boyu insülin tedavisi gerektirir (American Diabetes Association [ADA], 2022).
- **Tip 2 Diyabet:** Tip 2 diyabet, vücudun yeterli miktarda insülin üretememesi veya insüline karşı direnç göstermesi sonucu oluşur. Tip 2 diyabet çoğunlukla yetişkinlerde görülür ve yaşam tarzı değişiklikleri, diyet ve ilaç tedavisi ile yönetilebilir (ADA, 2022). Obezite, hareketsizlik ve genetik faktörler bu tip diyabetin ortaya çıkmasında önemli rol oynar (Tuzcuoğlu ve diğ., 2019).
- **Gestasyonel Diyabet:** Gestasyonel diyabet, hamilelik sırasında oluşan ve çoğunlukla doğumdan sonra kaybolan bir diyabet türüdür. Ancak, gestasyonel diyabet öyküsü olan kadınlar, ileriki yaşamlarında tip 2 diyabete yakalanma riski taşır (WHO, 2021).

3.3.Diyabetik Retinopati

DR, diyabet hastalığının gözlerdeki retina üzerinde oluşturduğu bir komplikasyondur. Bu hastalık, retina damarlarının hasar görmesi ile karakterizedir ve genellikle kan şekeri düzeylerinin iyi yönetilememesi sonucunda kan şekerinin uzun süre yüksek olmasıyla birlikte ortaya çıkar (Klein ve diğ., 2004). DR, görme kaybına yol açabilen ciddi bir rahatsızlığı ifade eder ve dünya çapında görme kaybının önde gelen nedenlerinden birisidir (Cheung ve diğ., 2010).

DR hastalığı, Non-Proliferatif DR (NPDR) ve Proliferatif DR (PDR) olmak üzere iki kategoride incelenmektedir.

3.3.1. Non-proliferatif DR (NPDR)

Hastalığın NPDR evresi kendi içerisinde hafif, orta ve şiddetli olmak üzere 3 sınıfa ayrılmaktadır:

- **Hafif NPDR:** Bu evrede, retina damarlarında mikroskobik değişiklikler gözlemlenmektedir. Bu değişiklikler mikroanevrizmalar, küçük kanamalar ve eksüdalar içermektedir. Retina üzerindeki damarlar normalden daha fazla görünür hale gelmekte, ancak genellikle görme işlevinde belirgin bir kayba yol açmamaktadır.
- **Orta NPDR:** Bu evrede, retina üzerindeki patolojik değişiklikler daha belirgin hale gelmektedir. Mikroanevrizmalara, kanamalara, eksüdalara ek olarak venöz değişiklikler ve IntRaretinal Mikrovasküler Anomaliler (IRMA) gibi bulgular gözlemlenmektedir.
- **Şiddetli NPDR:** Şiddetli evrede, kapsamlı mikroanevrizmalar, daha yaygın retina kanamaları, eksüdalar ile beraber yaygın arterioller tıkanıklıklar, venöz değişiklikler ve IRMA yoğunluğunda artışlar gözlemlenmektedir. Bu durumda, retina üzerinde belirgin ve yaygın kanamalar ve sıvı birikimleri mevcut olabilmektedir.

3.3.2. Proliferatif DR (PDR)

Proliferatif evrede, retina üzerinde anormal damar oluşumları (neovaskülarizasyon) görülmektedir. Bu yeni damarlar, genellikle retina yüzeyinin altında ve göz içindeki vitreal bölgede ortaya çıkar. Bu yeni damarlar, zayıf ve kırılgan olduklarından, kolayca kanayabilir ve vitreal kanamalara neden olabilir (Cheung ve diğ., 2010). PDR genellikle retina ve vitreus üzerinde fibröz doku oluşumlarına da yol açabilir. Bu bulgular hastaların görme yeteneklerinin zamanla azalmasına veya daha da artarak yok olmasına neden olmaktadır. Son yıllarda yapılan araştırmalar, görme yeteneğinin kaybedilmemesi için DR hastalığının erken teşhis ve tedavi edilmesi üzerine yoğunlaşmaktadır.

3.3.3.DR' nin patolojik bulguları

3.3.3.1Mikroanevrizmalar

Mikroanevrizmalar, DR'nin ilk klinik bulguları arasında yer almaktadır ve retinal kapiller duvarların fokal zayıflaması sonucu oluşan küçük, yuvarlak kırmızı noktalardır. Mikroanevrizmalar, retina damarlarının en ince bölümlerinde meydana gelmektedir ve retinal kan-beyin bariyerinin hasar gördüğünü göstermektedir. Bunlar tipik olarak retina muayenesi sırasında fundus fotoğraflarında görülebilir (Early Treatment Diabetic Retinopathy Study Research Group, 1991).

3.3.3.2.Retinal hemorajiler (Kanamalar)

Retinal kanamalar, genellikle mikroanevrizmaların yırtılması veya kapiller oklüzyonlar nedeniyle gelişir. Kanamalar genellikle nokta ve leke şeklinde veya alev şeklinde olmak üzere iki tipte görülmektedir. Nokta ve leke şeklindeki kanamalar iç retina katmanlarında meydana gelirken, alev şeklindeki kanamalar yüzeyel retina tabakasında oluşur (Aiello ve diğ., 1998). Retina kanamaları genellikle mikroanevrizmalardan daha büyük ve düzensiz kenarlara sahiptir.

3.3.3.3.Sert eksüdalar (Lipidler)

Sert eksüdalar, kan-retina bariyerinin bozulması sonucu damar dışına çıkan lipit ve proteinlerin birikimiyle ortaya çıkmaktadır. Bu eksüda, fundus görüntülerinde düzensiz şekilli, sarımsı ve keskin kenarlı birikintiler şeklinde görülmektedir. Genellikle makula çevresinde yoğunlaşır ve makula ödeminin bir göstergesi olabilir (Chew ve diğ., 1996).

3.3.3.4.Yumuşak eksüdalar (Pamuk benzeri noktalar)

Yumuşak eksüda, retinal iskeminin göstergesi olarak kabul edilmekte ve ‘pamuk benzeri lekeler’ olarak da adlandırılmaktadır. Bunlar, retina sinir lifi tabakasında aksonal taşımanın durması nedeniyle oluşan beyaz, pamuk gibi görünen bulanık alanlardır. Yumuşak eksüda, retinal kan akışının yetersiz olduğuna işaret eder ve genellikle daha ileri düzey DR vakalarında görülmektedir.

3.3.3.5.Intra-Retinal mikrovasküler anomaliler (IRMA)


NPDR' nin orta ve şiddetli evrelerinde ortaya çıkan patolojik mikrodamar oluşumlarıdır. Bu anormallikler, retinanın derin katmanlarında meydana gelir ve genellikle retinanın vasküler yapısında belirgin tıkanıklıklar veya kapiller kapanmalar sonucu oluşur. IRMA, retina kan akışının bozulması ve hipoksi durumunda ortaya çıkmakta, bu da retina dokusunun daha fazla oksijen ihtiyacını karşılamak için anormal damar oluşumuna neden olmaktadır. Fundus görüntülerinde genellikle kıvrımlı, genişlemiş ve çapraz geçişler yapan ince damarlar olarak görülmektedir. Bu damarlar, neovaskülarizasyonun aksine, retina yüzeyinin hemen altında yer almakta ve vitreus boşluğuna doğru büyümemektedir.

3.3.3.6.Venöz anomaliler

Retinal damarlarda kan akışındaki tıkanıklık veya yavaşlamanın bir sonucu olarak ortaya çıkar ve NPDR sürecinin ilerlemesiyle belirginleşir (Klein ve diğ., 1995). Venöz anomaliler arasında, venöz genişleme, segmental incelmeler, kavisleşmeler ve aralıklı daralmalar bulunmaktadır.

3.3.3.7.Neovaskülarizasyon

PDR için karakteristik bir bulgudur ve retina yüzeyinde veya optik diskte yeni, anormal damar oluşumlarını ifade eder. Bu yeni damarlar genellikle zayıftır ve göz içine kanama riski taşır. Retina veya vitreus boşluğunda kanamalar, skar dokusu oluşumu ve retina dekolmanı gibi ciddi komplikasyonlara yol açabilir (Antonetti ve diğ., 2006). Neovaskülarizasyon, fundus görüntülerinde ince ve düzensiz yeni damar oluşumları olarak görülmektedir.



Şekil 3.2. Patolojik bulgular (Orijinal görüntü üzerinde düzenleme yapılmış hali (Uyarlanmıştır: Nneji ve diğ., 2022))

3.3.4.DR sınıflandırılması

- Hafif DR dediğimiz birinci evrede mikroanevrizmalar bulunmaktadır.
- Orta DR adını verdiğimiz ikinci evrede ise yaygın retinal hemorajlar ve/veya mikroanevrizmalar bulunmaktadır. Ayrıca iki kadrandan az venöz lümen düzensizliği, yumuşak eksüda ve hafif IRMA görülebilmektedir.
- Ciddi DR adı verilen üçüncü evrede 4 kadrandan daha yoğun retina içi hemoraj veya en az iki kadranda belirgin venöz lümen düzensizliği veya kılcıl damarların en az bir kadranda anormal dallanması veya genişlemesi bulunmaktadır.
- Proliferatif DR dediğimiz dördüncü evrede ise retinal neovaskülarizasyon ya da $1/4-1/3$ disk çapından küçük veya eşit optik disk neovaskülarizasyonu bulunmaktadır. Bunlara ek olarak optik disk neovaskülarizasyonu ile birlikte preretinal hemoraj bulunmaktadır.

3.4.Derin Öğrenme

Derin öğrenme, makine öğrenmesinin bir alt alanı olarak, özellikle karmaşık veri setleri üzerinde çalışan ve çok katmanlı yapay sinir ağları kullanan bir hesaplama modelidir. Bu yöntem, insan beyninin öğrenme yeteneğinden esinlenerek tasarlanmıştır ve özellikle büyük veri setlerinden anlamlı özellikleri öğrenme ve çıkarma yeteneğine sahiptir. Derin öğrenme, diğer klasik makine öğrenmesi yöntemlerine göre daha büyük

ve karmaşık veri setleri ile çalışabilmektedir. Ayrıca klasik makine öğrenmesi yöntemlerinde verimlilik açısından özellik seçimi başlı başına büyük bir konuyken, derin öğrenme yönteminde özellik çıkarma sistem tarafından otomatik olarak yapılmaktadır (LeCun ve diğ., 2015).

Derin öğrenme, ‘derin’ yapısını, çok sayıda gizli katman içeren yapay sinir ağlarından alır. Derin öğrenme modelleri, geleneksel makine öğrenmesi algoritmalarının aksine veriden öğrenme sürecini tamamen otomatik hale getirmektedir. Özellik çıkarımı ve sınıflandırma gibi adımlar, bu modeller tarafından birbirini takip eden katmanlar aracılığıyla gerçekleştirilmekte, bu da derin öğrenme modellerinin, özellikle görüntü ve ses gibi yüksek boyutlu verilerde son derece etkili olmasını sağlamaktadır (Goodfellow ve diğ., 2016).

Derin öğrenmenin en büyük avantajlarından biri, büyük veri setlerinde bile öğrenme sürecini hızlandırabilmesi ve yüksek doğruluk oranları elde edebilmesidir. Bu nedenle, sağlık, finans, otonom araçlar ve doğal dil işleme gibi birçok alanda yaygın olarak kullanılmaktadır (Schmidhuber, 2015). Örneğin, sağlık alanında derin öğrenme modelleri, tıbbi görüntülerde hastalık tespiti ve sınıflandırması için başarıyla kullanılmaktadır (Litjens ve diğ., 2017). Özellikle DR gibi göz hastalıklarının sınıflandırılmasında, derin öğrenme tabanlı modeller yüksek doğruluk ve hassasiyet sunmaktadır (Gulshan ve diğ., 2016).

3.5.Yapay Sinir Ağları (YSA)

YSA, biyolojik sinir ağlarının çalışma prensiplerinden ilham alınarak geliştirilmiş, bilgi işleme ve öğrenme süreçlerini taklit eden algoritmalar topluluğudur. YSA, özellikle karmaşık problemlerin çözülmesi ve büyük veri kümelerinden anlamlı sonuçların çıkarılması için kullanılan güçlü bir YZ yöntemidir (Haykin, 1999).

YSA, nöron adı verilen temel birimlerden oluşur. Her nöron bir girdiyi alır, bunu işleyerek bir çıkış üretir. Girdiler genellikle ağırlıklarla çarpılır, toplanır ve ardından bir aktivasyon fonksiyonuna tabi tutulur. Bu süreç, öğrenme algoritmaları aracılığıyla gerçekleşmekte ve ağırlıklar zamanla doğru sonuçlar üretme yeteneği geliştirmesine olanak tanınmaktadır (Goodfellow ve diğ., 2016). YSA kullanılarak, tıpkı insanda olduğu gibi makinelerin de öğrenebilmesi amaçlanmaktadır.

3.5.1.YSA' nın yapısı

YSA giriş katmanı, gizli katmanlar ve çıkış katmanı olmak üzere üç ana bölümden oluşmaktadır. Giriş katmanı, dış dünyadan gelen veriyi alır ve bunu işlemek üzere gizli katmanlara iletir. Gizli katmanlar, veri üzerinde öğrenmenin gerçekleştiği bölümlerdir. Her gizli katmandaki nöronlar, bir önceki katmandan gelen bilgileri işler ve bir sonraki katmana aktarır (LeCun ve diğ., 2015).


YSA'ların başarısı, gizli katman sayısının artırılması ve ağıın derinleştirilmesi ile daha da artmaktadır. Özellikle derin öğrenme modelleri, birden fazla gizli katman içerir ve bu sayede daha karmaşık veri yapılarında yüksek doğrulukla çalışabilmektedir (Schmidhuber, 2015).

3.5.2.Aktivasyon fonksiyonları

YSA'nın önemli bileşenlerinden biri aktivasyon fonksiyonlarıdır. Aktivasyon fonksiyonları, her bir nöronun çıktısını hesaplamak için kullanılır ve ağıın doğrusal olmayan yapıları öğrenebilmesini sağlamaktadır. Yaygın olarak kullanılan aktivasyon fonksiyonları arasında Sigmoid, Tanh ve ReLU (Rectified Linear Unit) bulunur (Nair ve Hinton, 2010). ReLU, özellikle derin öğrenme modellerinde popüler bir seçimdir çünkü doğrusal olmayan problemlerde daha verimli sonuçlar ürettiği görülmektedir.


3.5.3.YSA'nın öğrenme süreci

YSA, eğitim süreci boyunca ağırlıkları güncelleyerek öğrenmektedir. Bu süreç, genellikle bir hata fonksiyonu kullanılarak gerçekleştirilmektedir. Hata fonksiyonu, ağıın ürettiği sonuç ile beklenen sonuç arasındaki farkı ölçmekte ve bu farkın minimize edilmesi için ağırlıklar güncellenmektedir. Bu işlem genellikle Gradyan İnişi (Gradient Descent) algoritması ile yapılmaktadır. Özellikle Adam gibi adaptif optimizasyon algoritmaları, sinir ağlarının daha hızlı ve doğru bir şekilde öğrenmesini sağlamaktadır (Kingma ve Ba, 2014).



3.6.Konvolüsyonel Sinir Ağları (KSA)

KSA, özellikle görüntü işleme ve sınıflandırma alanlarında büyük başarılar elde eden, derin öğrenme tabanlı bir yapay sinir ağı modelidir. KSA'lar, görüntülerin içerdiği iki boyutlu yapısal bilgilere doğrudan odaklanarak, uzamsal ilişkileri modelleyebilen bir yapı sunmaktadır. Bu özellik, özellikle büyük veri kümeleri üzerinde çalışırken önemli avantajlar sağlamaktadır (LeCun ve diğ., 1998).



3.6.1.KSA'nın temel yapısı

KSA'lar, genellikle konvolüsyon katmanı, havuzlama katmanı ve tam bağlı katman olmak üzere üç ana katmandan oluşmaktadır. Bu katmanlar, birlikte çalışarak giriş görüntüsündeki özellikleri çıkardıktan sonra bu özelliklere göre sınıflandırma işlemi yapmaktadırlar. KSA'lar, klasik yapay sinir ağlarından farklı olarak, veri üzerinde yerel filtreler kullanarak işlem yapmaktadırlar.


3.6.1.1.Giriş katmanı

Giriş katmanı, bir KSA'nın ilk katmanı olup veri setindeki verilerin ağı iletildiği katmandır. Giriş katmanı, verinin model tarafından doğru anlaşılabilmesi için öncelikli adım olup, KSA'nın ham veriyi alarak işlemeye başladığı kısımdır. Görüntü boyutları, modelin öğrenme kapasitesi açısından büyük öneme sahiptir. Giriş katmanında yer alan verilerin normalizasyonu veya ölçeklenmesi gibi işlemler, modelin daha iyi öğrenmesini sağlamak için sıklıkla uygulanmaktadır.

3.6.1.2.Konvolüsyon katmanı

Konvolüsyon katmanı adından da anlaşılacağı üzere KSA'nın temelini oluşturmaktadır ve görüntü üzerinde yerel filtreler kullanarak görüntünün belirli bölgelerinden özellikler çıkarmaktadır. Bu katman, görüntüdeki kenarlar, köşeler ve diğer temel yapısal özellikleri tespit etmektedir (Fukushima, 1980). Konvolüsyon işlemi, giriş verisi ve filtre arasında kayan bir pencere uygulayarak yapılmaktadır. Her filtre, farklı bir özellik çıkarmakta ve bu sayede görüntüdeki farklı yönler öğrenebilmektedir. Öğrenme, konvolüsyon katmanında gerçekleşmektedir.

Şekil 3.5'te 5x5 boyutundaki giriş matrisine 3x3 boyutlu konvolüsyon matrisi diğer bir adıyla filtre uygulanmıştır. Konvolüsyon matrisi giriş matrisinin üzerinde kaydırılırken matrislerde eşleşen her bir değer birbiri ile çarpılarak ve ardından toplama işlemine tabi tutularak çıktı matrisleri elde edilmiştir. 3x3'lük filtre giriş matrisi boyunca kaydırılarak aynı aşamalar tekrar edilir ve özellik haritası çıkarılır. Özellik haritası, görüntüde bulunan ağırlık değerlerinin belirlenmesine olanak sağlamaktadır.



Şekil 3.5. Konvolüsyon katmanını özellik çıkarımı (Kuchera ve diğ., 2019)

3.6.1.3. Aktivasyon fonksiyonu

KSA' nın en önemli bileşenlerinden biri de aktivasyon fonksiyonlarıdır. Aktivasyon fonksiyonları, ağıın doğrusal olmayan ilişkileri öğrenmesini sağlamak ve modelin karmaşık veri yapılarında daha başarılı olmasına yardımcı olmaktadır. Bu fonksiyonlar, her bir nöronun girdisini işleyip hangi çıktıların üretilmesi gerektiğine karar verirler. Bir KSA, aktivasyon fonksiyonları olmadan doğrusal bir modelden öteye geçememekte ve karmaşık problemlerde yetersiz kalmaktadır. Aktivasyon fonksiyonlarının seçimi, ağıın öğrenme performansı ve eğitim sürecinde büyük bir rol oynamaktadır. Bazı fonksiyonların belirli veri kümeleri ve problemler için daha uygun olduğu görülmektedir. Örneğin, ReLU ve türevleri derin öğrenme modellerinde hızla popüler hale gelmiştir çünkü büyük veri kümeleri üzerinde daha etkili çalışmaktadır. Diğer yandan, sınıflandırma problemlerinde softmax ve sigmoid gibi fonksiyonlar yaygın olarak kullanılmaktadır (Goodfellow ve diğ., 2016).


Konvolüsyonel sinir ağlarında öğrenme süreci, geriye yayılım (backpropagation) algoritması ile gerçekleştirilmektedir. Bu süreç, modelin çıktısı ile hedef arasındaki hata (loss) kullanılarak ağı her bir katmanındaki ağırlıkların güncellenmesini sağlamaktadır. Geriye yayılım algoritmasında türevlerin hesaplanması gerekmektedir. Bu nedenle aktivasyon fonksiyonları türevlenebilir olmalıdır.

KSA gibi karmaşık yapıları modellerde, her katman için uygun aktivasyon fonksiyonlarının seçilmesi modelin doğruluğunu ve genel başarımını doğrudan etkileyen bir faktördür.

- Doğrusal Aktivasyon Fonksiyonu: Girdi ile çıktı arasında doğrudan bir ilişki kuran ve doğrusal bir denklemle tanımlanan en basit aktivasyon fonksiyonudur. Matematiksel olarak şu şekilde ifade edilmektedir:

$$f(x) = ax \quad (3.1)$$

Denklemden gösterilen a değeri herhangi bir sabit bir sayı değeri olabilir ve fonksiyonun davranışını (artış, azalış veya sabitlik) belirleyen temel katsayıdır.



Şekil 3.6. Doğrusal fonksiyon ve türevi


Doğrusal aktivasyon fonksiyonu, basit doğrusal regresyon problemlerinde etkili olabilir, ancak derin sinir ağları veya karmaşık problemlerde doğrusal olmayan aktivasyon fonksiyonları tercih edilmelidir. Çünkü doğrusal olmayan aktivasyon

fonksiyonları, modelin veriler arasındaki karmaşık ilişkileri öğrenmesine olanak tanımakta ve modelin doğrusal olmayan sınırlar çizebilmesini sağlamaktadır.

- Sigmoid Aktivasyon Fonksiyonu: YSA' da sıkça kullanılan doğrusal olmayan bir aktivasyon fonksiyonudur. Çıktısı her zaman 0 ile 1 arasında sınırlıdır, bu yüzden özellikle olasılık hesaplamalarında kullanılmaktadır. Matematiksel formülü şu şekildedir:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.2)$$

Burada x, nöronun girdisidir ve bu fonksiyon, x' i [0, 1] aralığına ölçeklemektedir.




Şekil 3.7. Sigmoid aktivasyon fonksiyonu ve türevi

- Hiperbolik Tanjant (tanh) Aktivasyon Fonksiyonu: Sigmoid aktivasyon fonksiyonuna benzer şekilde doğrusal olmayan bir aktivasyon fonksiyonudur, ancak çıktı aralığı farklıdır. Tanh fonksiyonu, girdileri -1 ile 1 arasında ölçeklemektedir. Matematiksel olarak şu şekilde tanımlanmaktadır:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.3)$$

Bu formül, Sigmoid aktivasyon fonksiyonuna göre daha geniş bir çıktı aralığı sağlamakta ve çoğu durumda daha iyi performans göstermektedir.




Şekil 3.8. Hiperbolik tanjant aktivasyon fonksiyonu ve türevi

- ReLU (Rectified Linear Unit) Aktivasyon Fonksiyonu: Derin öğrenme modellerinde en çok tercih edilen aktivasyon fonksiyonlarından birisidir. Oldukça basit bir matematiksel formüle sahiptir ve doğrusal olmayan yapısı sayesinde sinir ağlarının karmaşık problemleri öğrenmesini sağlamaktadır. Matematiksel formülü şu şekildedir:

$$f(x) = \max(0, x) \quad (3.4)$$

Bu formüle göre giriş değeri 0'dan küçükse, çıktı 0 olur; giriş değeri 0'dan büyükse, çıktı girişin kendisidir.




Şekil 3.9. ReLU aktivasyon fonksiyonu ve türevi

- Leaky ReLU (Leaky Rectified Linear Unit) Aktivasyon Fonksiyonu: Standart ReLU aktivasyon fonksiyonunun bir varyasyonudur. ReLU'da negatif girişler için çıktı sıfır olurken, Leaky ReLU, negatif girişler için küçük bir eğim bırakmaktadır. Bu, negatif girdilere duyarsız kalınmasını önlemek ve ‘ölü nöronlar’ sorununu hafifletmek için geliştirilmiş bir çözümdür. Matematiksel olarak şu şekilde ifade edilmektedir:

$$f(x) = \begin{cases} x, & x > 0 \\ mx, & x \leq 0 \end{cases} \quad (3.5)$$

Burada m küçük bir sabittir ve genellikle 0.01 gibi bir değerde tutulmaktadır.




Şekil 3.10. Leaky ReLU aktivasyon fonksiyonu ve türevi

3.6.1.4. Havuzlama katmanı (Pooling)

Havuzlama katmanı, özellikle görüntülerin boyutunu küçültmek ve hesaplama maliyetini azaltmak için kullanılmaktadır. Bu katmanda öğrenme işlemi gerçekleşmez sadece özelliklerin korunması sağlanmaktadır. En yaygın kullanılan havuzlama yöntemi maksimum havuzlama olup, belirli bir bölgedeki en büyük değeri seçerek çıktı boyutunu küçültmektedir (Scherer ve diğ., 2010). Diğer bir havuzlama yöntemi olarak ortalama havuzlama, isminden de anlaşılacağı gibi belirli bir bölgedeki değerlerin ortalamalarının alınmasıyla gerçekleşmekte ve çıktı boyutunun küçülmesinin yanı sıra işlem maliyetinin

de düşürülmesine katkı sağlamaktadır. Havuzlama işlemi aynı zamanda modelin yerel özniteliklere karşı daha esnek hale gelmesini sağlamaktadır.



Şekil 3.11. 2x2 Maksimum Havuzlama, Ortalama Havuzlama (Yani ve diğ., 2019)

Şekil 3.11’ de maksimum havuzlama ve ortalama havuzlama yöntemleri gösterilmektedir. 4×4 boyutunda bir giriş matrisine 2×2 filtre boyutunda maksimum havuzlama işlemi uygulandığında her filtredeki maksimum değer alınmakta ve 2×2 boyutunda yeni bir çıktı elde edilmektedir. Ortalama havuzlama işleminde ise her filtredeki ortalama değer alınmakta ve yine 2×2 boyutunda yeni bir çıktı elde edilmektedir.


3.6.1.5. Tam bağlantılı katman

KSA’nın son aşamasında, çıkarılan öznitelikler tam bağlı katman aracılığıyla sınıflandırılmaktadır. Bu katman, geleneksel YSA katmanları gibi çalışmakta ve son sınıflandırma bu katmanda yapılmaktadır. Tam bağlantılı katmanlar, bir sinir ağının son aşamalarında yer almakta ve girişteki tüm nöronların çıktısındaki her bir nörona bağlanmasını sağlayarak sınıflandırma veya regresyon gibi görevlerde önemli bir rol oynamaktadır. Bu katman, özellikle yüksek seviyeli özelliklerin birleştirilmesi ve nihai

tahminlerin yapılması için kullanılmaktadır (Goodfellow ve diğ., 2016). Şekil 3.11 (a)'da tam bağlantılı katman görülmektedir.

3.6.1.6.Seyreltme katmanı


Seyreltme katmanı, modelin aşırı öğrenmesini önlemek için kullanılan bir tekniktir. Eğitim sırasında nöronların rastgele bir kısmı devre dışı bırakılarak modelin belirli nöronlara aşırı bağımlı olması engellenmektedir. Bu da modelin daha genelleşici olmasını sağlamaktadır (Srivastava ve diğ., 2014).



Şekil 3.12. Seyreltme işlemi için (a) orijinal KSA ve (b) seyreltme işlemi uygulanan KSA (Srivastava ve diğ., 2014).

3.6.1.7.Düzleştirme katmanı

Bu katman, konvolüsyonel ve havuzlama katmanlarından gelen 2 boyutlu özellik haritalarını tek boyutlu bir vektöre dönüştürmektedir. Bu dönüşüm, verinin tam bağlantı katmanına uygun hale getirilmesi için gereklidir (Simonyan ve Zisserman, 2014).



Şekil 3.13. Düzleştirme Katmanı

3.6.2.KSA' nın özellikleri

KSA'ların en büyük avantajlarından biri, görüntülerin yapısının korunarak işlenmesidir. KSA'lar, geleneksel YSA' nın aksine görüntülerdeki yerel bağlantıları kullanarak boyutları küçültmekte ve modelin aşırı öğrenme riskini azaltmaktadır. KSA'lar özellikle büyük görüntü veri setlerinde yüksek performans göstermektedir. Bu durum, görüntü işleme problemlerinin yanı sıra ses ve video analizinde de sıklıkla kullanılmasına yol açmaktadır (Krizhevsky ve diğ., 2012).

3.6.3.KSA'ların DR analizinde kullanımı

KSA' lar DR gibi tıbbi görüntülerin analizinde geniş çapta kullanılmaktadır. Fundus görüntülerindeki değişiklikleri tespit etmek ve DR'nin farklı derecelerini sınıflandırmak, KSA'ların öznelikleri etkili bir şekilde öğrenme kapasitesi sayesinde mümkün olmaktadır. KSA kullanılarak geliştirilen bir modelin, retina tarama görüntülerinde DR' yi tespit etmede yüksek bir doğruluk oranına ulaşıldığı görülmektedir. Bu tür derin öğrenme tabanlı modeller, hastalık teşhislerinde otomatikleştirilmiş sistemler için umut verici adımlar atmaktadır (Gulshan ve diğ., 2016).

3.7.Transfer Öğrenme

Transfer öğrenme, makine öğrenmesi ve derin öğrenme alanlarında bir modelin daha önce eğitildiği bir görevden elde ettiği bilgileri başka bir göreve transfer etmesine dayanmaktadır. Özellikle büyük miktarda veriyle eğitilmiş modellerin kısıtlı verilere sahip benzer problemler için yeniden kullanılmasıyla yüksek performans elde edilmesi mümkün olmaktadır. Bu yaklaşım, kısıtlı veri ve hesaplama kaynaklarıyla çalışan araştırmacılar için büyük bir avantaj sağlamaktadır (Pan ve Yang, 2010).

Transfer öğrenmenin temel amacı, bir modelin eğitildiği kaynak görevde öğrendiği bilgileri hedef görevde kullanmaktır. Transfer öğrenme özellikle derin öğrenme tabanlı görüntü sınıflandırma problemlerinde önemli bir rol oynamaktadır. Genellikle büyük ve geniş veri kümeleriyle önceden eğitilmiş modeller, başka bir alanda yeniden eğitilerek daha küçük ve sınırlı veri setlerine sahip problemlere uyarlanabilmektedir. Bu yaklaşım hem küçük ve sınırlı veri kümelerinde daha yüksek sonuçlar elde edilmesine destek olmakta hem de eğitim süresini kısaltmaktadır.

Görüntü sınıflandırması, transfer öğrenmenin en yaygın uygulama alanlarından biri olarak karşımıza çıkmaktadır. Özellikle tıbbi görüntüleme gibi sınırlı veri içeren alanlarda transfer öğrenme büyük faydalar sağlamaktadır. Transfer öğrenme, DR sınıflandırmasında da genellikle kısıtlı miktarda etiketli veriye sahip olunması nedeniyle sınıflandırma performansını artırmak için etkili bir yöntemdir. Transfer öğrenme DR sınıflandırmasında yalnızca sınırlı veri kümesi ile verimli sonuçlar elde edilmesine yardımcı olmakla kalmamakta, aynı zamanda modelin eğitim süresinin kısalmasını ve genelleme yeteneğinin artmasını da sağlamaktadır.

3.7.1.Transfer öğrenme yöntemleri

Transfer öğrenme yöntemleri genel olarak iki ana başlık altında incelenmektedir:

- **Özellik Çıkarma:** Bu yöntemde, genellikle ImageNet gibi büyük veri kümelerine benzer geniş bir veri kümesi üzerinde önceden eğitilmiş bir modelin alt katmanları sabitlenmekte ve yalnızca sınıflandırma katmanları yeniden eğitilmektedir. Bu yaklaşım modelin önceden öğrendiği genel özellikleri kullanarak istenilen göreve adaptasyon sağlamaktadır. Özellik çıkarma yöntemiyle birlikte, görsel özelliklerin ön plana çıktığı DR gibi tıbbi görüntü analizlerinde başarılı sonuçlar

elde edilmektedir (Kermany ve diğ., 2018). Özellik çıkarma yöntemi sınırlı veri kümesine sahip alanlarda kullanıldığında modelin genelleme yeteneğini de artırmaktadır.

- **İnce Ayar Yapma:** Bu yaklaşımda, önceden eğitilmiş modelin tüm katmanları yeniden eğitilebilmekte veya gerekli katmanlar yeniden eğitime tabi tutulabilmektedir. Model, ince ayar yapma işlemi sırasında daha önce öğrenilmiş genel özellikler korunurken yeni veri kümesine uyum sağlamaktadır. İnce ayar yapma, istenilen görevde performansın iyileştirilmesini sağlamaktadır.

3.7.2. Transfer öğrenmenin avantajları

Transfer öğrenmenin DR gibi tıbbi görüntü sınıflandırma problemlerindeki avantajları aşağıda belirtilmektedir:

- **Veri Yetersizliği Problemi:** Derin öğrenme modelleri genellikle büyük miktarda etiketlenmiş veriye ihtiyaç duymakta ancak tıbbi görüntüleme alanında veri elde etmek zor olabilmektedir. Transfer öğrenme, önceden eğitilmiş modelleri kullanarak bu problemi aşmaktadır (Shin ve diğ., 2016). Daha küçük veri kümeleri üzerinde dahi yüksek performans elde edilebilmektedir.
- **Hesaplama Maliyetlerinin Azaltılması:** Bir derin öğrenme modelini sıfırdan eğitmek hem zaman almakta hem de yüksek hesaplama maliyetlerine neden olmaktadır. Transfer öğrenme sayesinde önceden eğitilen bir modelin yeniden kullanılması bu maliyetleri büyük ölçüde azaltmaktadır. Örneğin, Gulshan ve arkadaşlarının çalışmasında büyük çapta eğitilmiş bir derin öğrenme modeli DR sınıflandırmasında yeniden kullanılarak yüksek başarıya ulaşıldığı görülmektedir (Gulshan ve diğ., 2016).
- **Genelleme Yeteneğinin Artması:** Transfer öğrenme, modelin daha önce büyük bir veri kümesi üzerinde eğitilmesi nedeniyle genelleme yeteneğini artırmaktadır. Kermany ve arkadaşlarının çalışmasında retinal görüntülere sahip bir veri seti kullanılarak ve transfer öğrenme yöntemi uygulanarak hastalık tespiti için yüksek doğruluk oranlarına ulaşıldığı görülmektedir (Kermany ve diğ., 2018).

3.7.3. Transfer öğrenme yaklaşımları

3.7.3.1. EfficientNet

EfficientNet, günümüzde derin öğrenme modellerinin en verimli ve performanslı mimarilerinden biri olarak kabul edilmektedir. Google Brain araştırmacıları tarafından geliştirilen EfficientNet, klasik KSA boyutlandırma sorununu çözmeye odaklanmakta ve bu mimarinin ölçeklenebilirliğini geliştirmektedir. Model belirli bir hesaplama bütçesi içinde mümkün olan en yüksek doğruluğu elde etmek amacıyla genişlik, derinlik ve çözünürlük gibi üç temel parametrenin dengeli bir şekilde ölçeklenmesini sağlamaktadır.

EfficientNet'in gelişim süreci

EfficientNet, öncesinde kullanılan geleneksel model ölçekleme yöntemlerine bir alternatif olarak ortaya çıkmıştır. Çoğu derin öğrenme modeli, modelin performansını artırmak amacıyla ya derinliğini (katman sayısını) ya da genişliğini (her katmandaki nöron sayısını) artırmaktadır ancak bu yöntemler genellikle ya performansın belirli bir noktadan sonra artmasını durdurmakta ya da aşırı hesaplama maliyetine neden olmaktadır. EfficientNet, Bileşik Ölçeklendirme (Compound Scaling) adı verilen bir yöntemle genişlik, derinlik ve çözünürlüğü aynı anda dengeli bir şekilde artırarak daha verimli bir model oluşturmayı başarmaktadır (Tan ve Le, 2019).

EfficientNet'in temel yapı taşı olan EfficientNetB0 modeli, Sinirsel Mimari Arama (Neural Architecture Search (NAS)) adlı otomatik bir yöntemle tasarlanmış olup daha ileri versiyonlar (B1-B7), bu temel modelin ölçeklendirilmesi ile elde edilmektedir.

EfficientNet mimarisi katmanları

EfficientNet, temel olarak MobileNetV2'de kullanılan 'Inverted Residual Blocks' ve MnasNet'teki 'Squeeze and Excitation' bloklarını kullanmaktadır. Bu bloklar, EfficientNet'in hesaplama verimliliğini ve doğruluğunu artıran önemli bileşenlerdir.

- Giriş Katmanı: EfficientNet mimarisi diğer geleneksel KSA modellerinde olduğu gibi bir giriş katmanı ile başlamaktadır. Giriş katmanında 456x456 çözünürlüğünde bir RGB görüntü işlenmektedir. Genellikle 3x3 boyutunda

konvolüsyonel filtreler ve batch normalization kullanılmaktadır. Bu katman, görüntüdeki düşük seviyeli özelliklerin çıkarılmasını sağlamaktadır.

- MBConv Blokları (Mobile Inverted Bottleneck Convolution): EfficientNet'in en önemli bileşenlerinden biri olan MBConv blokları verimli hesaplama yapısı ile bilinmektedir. Bu bloklar dar (sıkıştırılmış) bir bilgi yolu kullanarak hem geniş hem de dar ağlar arasında bilgi akışı sağlamaktadır. MBConv blokları, iki temel bileşenden oluşmaktadır:
 - Depthwise Separable Convolutions: Konvolüsyon işlemi her bir kanal için ayrı ayrı uygulanmakta ve bu durum da hesaplama maliyetini düşürürken performansı artırmaktadır (Howard ve diğ., 2017).
 - Squeeze and Excitation (SE) Blokları: Bu bloklar her kanalın önem derecesini belirleyerek kanal bazında dikkat mekanizması uygulamakta ve modelin önemli özellikleri daha iyi öğrenmesini sağlamaktadır (Hu ve diğ., 2018).
- Bileşik Ölçeklendirme (Compound Scaling): EfficientNet'in yenilikçi yaklaşımı olan Bileşik Ölçeklendirme, modelin boyutlandırılmasında üç temel parametrenin dengeli bir şekilde ölçeklenmesini sağlamaktadır:
 - Genişlik: Modelin katmanlarının genişliği yani her bir katmandaki filtre sayısı artırılmaktadır.
 - Derinlik: Modelin katman sayısı artırılmaktadır.
 - Çözünürlük: Giriş görüntülerinin boyutu büyütülerek daha fazla ayrıntının modele sunulması sağlanmaktadır (Tan ve Le, 2019).
- Sınıflandırıcı Katman: Son katmanlar, genellikle tam bağlı katmanlardan ve softmax aktivasyon fonksiyonundan oluşmaktadır. Bu katmanlar modelin öğrenmiş olduğu özelliklere dayanarak son tahminleri yapmaktadır.


EfficientNet'in avantajları

EfficientNet mimarisinin en büyük avantajı kısıtlı kaynaklarla yüksek doğruluk sunabilmesidir. EfficientNet, ImageNet veri setinde oldukça başarılı sonuçlar elde


etmekle birlikte geleneksel modellerle karşılaştırıldığında çok daha az hesaplama maliyeti ile yüksek doğruluk sağlamaktadır (Tan ve Le, 2019).

- Yüksek Verimlilik: EfficientNet, aynı doğruluk seviyesini sağlarken diğer mimarilere göre daha düşük hesaplama gücü kullanmaktadır.
- Ölçeklenebilirlik: Bileşik Ölçeklendirme yaklaşımı sayesinde model hem küçük hem de büyük veri setlerine göre kolayca uyarlanabilmektedir.
- Daha Az Parametre: Diğer derin öğrenme mimarilerine kıyasla daha az parametre ile daha yüksek doğruluk oranları elde edilebilmektedir.

EfficientNet'in sağladığı bu avantajlar özellikle tıbbi görüntü sınıflandırması gibi büyük veri kümelerine sahip olmayan alanlarda büyük önem taşımaktadır.



Şekil 3.14. EfficientNet-B0 Temel Ağ Yapısı Blok Gösterimi (Kaynak: <https://ayyucekizrak.medium.com/>, erişim tarihi: 9 Eylül 2024)



Şekil 3.15. Transfer Öğrenme Yaklaşımları Performansı

3.7.3.2.VGGNet

VGGNet mimarisi, derin öğrenme mimarileri arasında görüntü sınıflandırma ve diğer bilgisayarla görü uygulamalarında kullanılan popüler bir KSA' dır. 2014 yılında Oxford Üniversitesi'nden Simonyan ve Zisserman tarafından önerilen VGGNet mimarisi, daha derin ağlar oluşturarak görsel tanıma doğruluğunu artırmayı amaçlamaktadır (Simonyan ve Zisserman, 2014). Bu mimari, çok sayıda küçük 3x3 konvolüsyon filtresi kullanarak derinliği artırırken aynı zamanda hesaplama maliyetlerini dengelemesiyle öne çıkmaktadır.

VGGNet'in yapısı

VGGNet'in en belirgin özelliklerinden biri, ağı oluşturan katmanların oldukça düzenli bir şekilde sırayla yerleştirilmesidir. Özellikle daha derin katmanlar ve küçük boyutlu filtrelerle hesaplama yükü düşürülürken, daha yüksek seviyeli özellikler öğrenilebilmektedir. VGGNet mimarisi, her bir katmanda aynı filtre boyutlarını kullanarak daha tutarlı bir yapıya sahip olmakla birlikte farklı derinliklerdeki versiyonları VGG16 ve VGG19 olarak adlandırılmaktadır. Bu isimler, ağıdaki toplam katman sayısını belirtmektedir.

VGGNet'in temel mimarisi aşağıdaki katmanlardan oluşmaktadır:

- Giriş Katmanı: Giriş katmanında 224x224 çözünürlüğünde bir RGB görüntü işlenmektedir. Bu boyut modelin kabul edebileceği sabit bir çözünürlüktür. Görüntü verisi, piksellerin normalize edilmesiyle modele sunulmaktadır. VGGNet' in başarısı için giriş görüntülerinin sabit bir çözünürlüğe sahip olması önemli bir rol oynamaktadır.
- Konvolüsyonel Katmanlar: VGGNet' in en ayırt edici özelliklerinden biri her bir konvolüsyon katmanında 3x3 boyutunda küçük filtreler kullanılmasıdır. Küçük filtrelerin kullanımı ağı daha fazla sayıda katmana sahip olmasına olanak tanımakla birlikte aynı zamanda her katmanda daha karmaşık özelliklerin öğrenilmesine olanak sağlamaktadır. İlk katmanlarda düşük seviyeli özellikler öğrenilirken daha derin katmanlarda daha soyut ve yüksek seviyeli özellikler öğrenilmektedir (Simonyan ve Zisserman, 2014). VGGNet' teki konvolüsyonel

katmanlar her bir katmandan sonra ReLU aktivasyon fonksiyonu kullanarak, modelin doğrusal olmayan ilişkileri öğrenmesini sağlamaktadır.


- **Havuzlama Katmanları:** VGGNet, konvolüsyonel katmanların ardından boyut küçültme amacıyla 2x2 boyutunda maksimum havuzlama işlemi uygulamaktadır. Bu işlem, ağıın boyutunu ve hesaplama maliyetini azaltmakla birlikte aynı zamanda önemli özelliklerin korunmasını sağlamaktadır. Maksimum havuzlama, görüntüdeki en belirgin özellikleri seçmekte ve uzaysal boyutları küçülterek ağıın derin katmanlarda daha yüksek seviyeli bilgileri işlemlerini sağlamaktadır (He ve diğ., 2016).
- **Tam Bağlantılı Katmanlar:** VGGNet' in son aşamasında yer alan tam bağlantılı katmanlar, daha önceki katmanlardan öğrenilen özellikleri bir sınıflandırıcıya yönlendirmektedir. VGG16 ve VGG19 mimarilerinde üç adet tam bağlantılı katman bulunmaktadır. Bu katmanlarda ReLU aktivasyon fonksiyonu kullanılmakta ve son sınıflandırıcı katmanında softmax fonksiyonu uygulanarak sınıflandırma yapılmaktadır (Simonyan ve Zisserman, 2014).
- **Çıkış Katmanı:** VGGNet mimarisi genellikle ImageNet veri seti ile eğitildiği için 1000 farklı sınıfı tanımak üzere yapılandırılmıştır. Çıkış katmanında her sınıf için olasılık tahminleri yapılmakta ve bu tahminler softmax fonksiyonu ile normalize edilmektedir. Çıkış katmanı görsel tanıma görevlerinde en yüksek olasılığa sahip sınıfı tahmin etmektedir.

VGG16 ve VGG19 mimarileri

VGGNet'in iki farklı versiyonu olan VGG16 ve VGG19, derinlik açısından farklılık göstermektedir. VGG16 mimarisinde toplam 16 katman bulunurken, VGG19 mimarisi 19 katmandan oluşmaktadır. Bu katmanların büyük bir kısmı konvolüsyonel katmanlardan oluşmakta, aralarındaki fark yalnızca derinlik ve eklenen konvolüsyonel katman sayısı olmaktadır.

VGG16:


- 13 konvolüsyonel katman
- 3 tam bağlantılı katman
- Toplam 16 katman



Şekil 3.16. VGG 16 Mimarisi (Orijinal görüntü üzerinde düzenleme yapılmış hali (Uyarlanmıştır: Varshney, 2024))

VGG19:

- 16 konvolüsyonel katman
- 3 tam bağlantılı katman
- Toplam 19 katman



Şekil 3.17. VGG 19 Mimarisi (Özçelik ve Altan, 2021)

VGGNet'in avantajları ve dezavantajları

Avantajları:

- Derinlik: Daha fazla sayıda konvolüsyonel katman sayesinde ağ, daha soyut özellikleri öğrenebilmekte ve bu da sınıflandırma doğruluğunu artırmaktadır.
- Basitlik: VGGNet'in mimarisi, belirli yapı taşlarının tekrarı ile oldukça düzenlidir ve bu da mimarinin anlaşılmasını ve uygulanmasını kolaylaştırmaktadır (Simonyan ve Zisserman, 2014).

Dezavantajları:

- Yüksek Hesaplama Maliyeti: VGGNet'in derin yapısı ve çok sayıda parametre içermesi hesaplama maliyetini artırmaktadır. VGG16 ve VGG19 modelleri, büyük veri kümeleri üzerinde eğitilirken çok fazla bellek ve işlem gücü gerektirmektedir.
- Ağır Model: VGGNet modelleri, özellikle mobil cihazlar ve gömülü sistemlerde kullanıldığında çok ağırdır ve bu da pratik uygulamalarda bazı kısıtlamalara neden olmaktadır (He ve diğ., 2016).

3.8. Veri Setleri

Tez çalışmasında, Asia Pasific Tele-Ophthalmology Society (APTOS) ve Diabetic Retinopathy (resized) olmak üzere iki adet veri seti üzerinde çalışılmıştır. Veri setlerinin her ikisinin de %70' i eğitim için %30'u test için ayrılmıştır. İlk veri seti için 3662 veriden 2563 veri eğitim için, 1099 veri test için ayrılmıştır. İkinci veri seti için 35126 veriden 24588 veri eğitim için 10538 veri test için ayrılmıştır. Ayrıca, verilerin bölünmesi sırasında 'shuffle = True' parametresi kullanılmaktadır. Bu parametrenin kullanılması, veri setinin sıralı ya da sistematik bir yapıya sahip olmasından kaynaklanabilecek önyargıları önlemektedir. Shuffle işlemi, verilerin rastgele karıştırılmasını sağlayarak eğitim ve test gruplarının sınıflar açısından olabildiğince benzer bir dağılıma sahip olmasını garanti etmektedir. Bu durum özellikle sınıflar arasında dengesizlik varsa modelin her iki alt grupta da performansının adil bir şekilde ölçülmesini sağlamaktadır. Veri setinin %70 eğitim ve %30 test olarak bölünmesi makine öğrenmesi ve derin öğrenme çalışmalarında yaygın olarak kullanılan bir yöntem olmaktadır ve bu oran

genellikle modelin performansını değerlendirmek için iyi bir denge sağlamaktadır. Eğitim verisi, modelin öğrenme sürecinde kullanılarak temel yapıyı ve veri özelliklerini anlamasına olanak tanırken, test verisi ise modelin eğitilmemiş yeni veriler üzerinde nasıl performans gösterdiğini ölçmek için ayrılmaktadır. %70 eğitim ve %30 test oranı veri setinin boyutu sınırlıysa, aşırı öğrenmeyi önleme ve genelleme yeteneğini test etme açısından dengeli bir yaklaşım olarak kabul edilmektedir ancak bu oran, veri setinin büyüklüğüne, problem türüne ve modelin karmaşıklığına bağlı olarak ayarlanabilmektedir.

3.8.1. Asia Pasific Tele-Ophthalmology Society (APTOS) veri seti

Fundus görüntülerinden oluşan veri seti, Hindistan’ da birçok katılımcıdan elde edilen verilerle oluşturulmuştur. Hindistan’daki Aravind Göz Hastanesi çalışanları tarafından fundus fotoğrafçılığı kullanılarak çeşitli görüntüleme koşulları altında birden fazla klinikten toplanan toplam 3662 retina görüntüsünden oluşmaktadır. Veri setinde .png formatında yer alan retina görüntülerinin çözünürlüğü 474×358 ile 3388×2588 piksel arasında değişmektedir.

Veriler;

0 → No DR (Sağlıklı)


1 → Mild (Hafif Retinopati)

2 → Moderate (Orta Retinopati)

3 → Severe (Ciddi retinopati)

4 → Proliferative Retinopati

Olmak üzere toplamda 5 sınıftan oluşmaktadır. Fundus görüntülerinden oluşan veri setinde, 1805 adet “DR Yok”, 370 adet “Hafif NPDR”, 999 adet “Orta NPDR”, 193 adet “Ciddi NPDR” ve 295 adet “PDR” sınıfına ait retina görüntüleri yer almaktadır.



Şekil 3.18. APTOS veri setinden DR evrelerine ait fundus görüntü örnekleri

3.8.2.Diabetic Retinopathy (resized) veri seti

Kaggle’da yayınlanan veri seti toplamda 35126 fundus görüntüsünden oluşmaktadır. Veri setinde .jpeg formatında yer alan retina görüntülerinin çözünürlüğü 1024×1024 pikseldir.

Veriler;

0 → No DR (Sağlıklı)


1 → Mild (Hafif Retinopati)

2 → Moderate (Orta Retinopati)

3 → Severe (Ciddi retinopati)

4 → Proliferative Retinopati


Olmak üzere toplamda 5 sınıftan oluşmaktadır. Fundus görüntülerinden oluşan veri setinde, 25810 adet “DR Yok”, 2443 adet “Hafif NPDR”, 5292 adet “Orta NPDR”, 873 adet “Ciddi NPDR” ve 708 adet “PDR” sınıfına ait retina görüntüleri yer almaktadır.



Şekil 3.19. Diabetic retinopathy (resized) veri setinden DR evrelerine ait fundus görüntü örnekleri

3.9.Ön İşlem Yöntemleri


Ön işlem adımlarına başlamadan önce görüntülerin gri seviyeye dönüştürülmesi, işlem sürecini basitleştirmek ve daha verimli hale getirmek için yaygın bir adım olmaktadır. Renkli görüntüler genellikle her piksel için kırmızı, yeşil ve mavi (RGB) olmak üzere üç kanal içerirken, gri seviye görüntüler tek bir yoğunluk değerine sahiptir. Bu dönüşüm, hesaplama maliyetini azaltırken aynı zamanda birçok görüntü işleme algoritmasının gri seviye üzerinde çalışmak üzere tasarlanmış olması nedeniyle gerekli olmaktadır.



Şekil 3.20. Gri seviyeye dönüştürülmüş fundus görüntüsü

3.9.1. Gaussian blur yöntemi

Gaussian blur yöntemi, görüntüdeki yüksek frekanslı detayları azaltarak daha pürüzsüz bir görünüm elde edilmesini sağlamaktadır. Bu yöntem görüntüdeki gürültüyü azaltmak ve modelin daha genel özellikleri yakalayabilmesine olanak tanımak için kullanılmaktadır. Bu yöntemde her bir piksel komşu piksellerin ağırlıklı ortalaması alınarak yeniden hesaplanmakta ve bu ağırlıklar, bir Gauss dağılım fonksiyonu kullanılarak belirlenmektedir. Bu yöntemin DR sınıflandırmasında, optik disk ve kan damarları gibi dikkat dağıtıcı detayların yumuşatılmasında faydalı olduğu görülmektedir (Gonzalez ve Woods, 2002).




Şekil 3.21. Gaussian blur yöntemi uygulanmış fundus görüntüsü

3.9.2. Eşikleme (Threshold) yöntemi

Eşikleme, görüntüdeki belirli bir parlaklık seviyesinin altındaki pikselleri siyah, belirli bir parlaklık seviyesinin üzerindeki beyaz yaparak ikili bir görüntü oluşturmaktadır. Bu yöntem, DR gibi hastalıkları sınıflandırırken lezyonlar ve damarlar

gibi belirgin yapıları ortaya çıkarmak için yaygın olarak kullanılmaktadır (Otsu, 1979). Özellikle adaptif eşikleme gibi yöntemler, yerel kontrast farklılıklarına duyarlı olup görüntünün farklı bölümlerinde her bölgeye uygun farklı eşik değerleri kullanarak görüntüyü daha belirgin hale getirmektedir (Bradley ve Roth, 2007).



Şekil 3.22. Threshold yöntemi uygulanmış fundus görüntüsü

3.9.3.Kontur yöntemi


Kontur yöntemi, bir görüntüdeki nesnelerin kenarlarını ve sınırlarını belirlemek amacıyla kullanılan bir tekniktir. Kontur, bir görüntüde aynı yoğunluk değerine sahip olan piksel gruplarının sınır çizgisi olarak tanımlanmaktadır. Kontur yöntemi, nesnelerin şekillerini ve ana hatlarını çıkarmak için sıklıkla kullanılan bir yöntem olarak karşımıza çıkmaktadır.

DR gibi tıbbi görüntü analizlerinde kontur tespiti, retina yüzeyindeki lezyonların, mikroanevrizmaların ve kan damarlarının sınırlarının belirginleştirilmesi için kullanılabilir. Konturlar, kenar tespit algoritmaları ile birlikte kullanılarak belirlenmekte ve ardından kontur algoritmaları bu kenarları takip ederek nesnenin ana hatlarını çıkarmaktadır.

Kontur yöntemi, görüntüdeki gürültüden etkilenmemesi için öncelikle Gaussian blur gibi filtreleme yöntemleri ile birlikte kullanılmaktadır. Bu sayede görüntüdeki gürültü azaltılmakta ve daha net konturlar elde edilmektedir.

Tez çalışmasında kontur yöntemi uygulanırken eşikleme yapılan görüntü kullanılarak fundus görüntüsünün koordinatları belirlenmiştir. Bu koordinatlar

kullanılarak fundus şeklinin dışındaki siyah alanlar kırpılmıştır. Kırpma işleminin ardından görüntü, orijinal görüntüyle aynı boyuta getirilmiştir. Sonrasında görüntü RGB'ye çevrilerek eğitim yapılmıştır.




Şekil 3.23. Kontur yöntemi uygulanmış fundus görüntüsü

3.9.4. Kontrast Limitli Adaptif Histogram Eşitleme (CLAHE) yöntemi

CLAHE, görüntüdeki kontrastı yerel olarak iyileştirmek için kullanılan bir histogram eşitleme yöntemidir. Geleneksel histogram eşitleme, tüm görüntüye tek bir eşitleme fonksiyonu uygulayarak genel kontrastı artırırken, CLAHE yöntemi görüntüyü daha küçük bölgelere ayırarak her bir bölgenin kontrastını ayrı ayrı artırmaktadır. Geleneksel histogram eşitleme, görüntünün genel kontrastını artırmak için kullanılmaktadır ancak görüntünün parlak alanlarında aşırı doygunlaşmaya neden olabilmekte ve bu da önemli detayların kaybolmasına yol açmaktadır. CLAHE, bu sorunun önüne geçmek için her bir bölgedeki kontrastı sınırlayarak bu aşırı doygunluğu önlemektedir. Her bir bölgedeki histogram önceden belirlenen bir maksimum limit ile sınırlandırılmakta ve böylece yerel kontrast artırılırken aşırı doygunlaşma engellenmektedir (Pizer ve diğ., 1987; Zuiderveld, 1994).

DR görüntüleri genellikle düşük kontrast içermekte ve küçük patolojik detayların görünürlüğü sınırlı olmaktadır. CLAHE yöntemi, bu tür tıbbi görüntülerde ince detayların vurgulanması için oldukça etkili olmaktadır. DR sınıflandırmasında, fundus görüntülerinin daha keskin ve detaylı hale getirilmesi, tanısal doğruluğu artırmak için kritik bir rol oynamaktadır. Mikroanevrizmalar, kanamalar, eksüdalar ve diğer patolojik yapıların belirgin hale getirilmesinde CLAHE'nin uygulanması bu yapılar üzerindeki düşük kontrastın iyileştirilmesine yardımcı olmaktadır. Fundus görüntülerinde


CLAHE'nin uygulanması ile retina yüzeyindeki küçük damarlar, kanamalar ve lezyonlar daha net bir şekilde ortaya çıkmaktadır. Bu da modelin DR sınıflandırması sırasında daha doğru ve güvenilir sonuçlar üretmesini sağlamaktadır (Zuiderveld, 1994).



Şekil 3.24. CLAHE yöntemi uygulanmış fundus görüntüsü

3.9.5. Median blur yöntemi


Median blur, her bir pikselin değerini komşu piksellerin ortanca değeri ile değiştirerek görüntüdeki gürültüyü azaltan bir yöntemdir. Görüntüdeki gürültüyü azaltırken kenarları koruyan bir filtredir. Gaussian blur'dan farklı olarak Median blur kenarları korumakta ve bu sayede görüntüdeki detaylar kaybolmamaktadır. Özellikle tuz ve karabiber gürültüsünün yoğun olduğu görüntülerde oldukça etkilidir. DR görüntülerinde, retina yüzeyindeki damarlar ve mikroanevrizmalar gibi ince yapıların korunarak gürültünün azaltılması amacıyla kullanılabilir (Huang ve diğ., 1979). Median blur, görüntüdeki keskin yapıları koruyarak gürültüyü azalttığı için, fundus görüntülerinde sıklıkla tercih edilen bir yöntemdir (Smith ve Brady, 1997).




Şekil 3.25. Median blur yöntemi uygulanmış fundus görüntüsü

Şekil 3.26’ da ön işlem adımları sırasıyla gösterilmektedir. İlk adımda, orijinal renkli görüntü gri seviyeye dönüştürülmüş, ardından Gaussian blur filtresi uygulanmış daha sonra eşikleme işlemi gerçekleştirilmiş, kontur çıkarma işlemi uygulanarak görüntü kırılmış ve RGB formatına dönüştürülmüştür. İkinci ön işlem adımında, CLAHE yöntemi kullanılmış ardından median blur filtresi uygulanarak görüntüdeki gürültü azaltılmıştır.

Şekil 3.27’ de sırasıyla Gaussian blur, eşikleme, kontur tespiti, CLAHE ve Median blur yöntemlerinin uygulanmış olduğu fundus görüntüsü örnekleri gösterilmektedir.



Şekil 3.26. Bütün ön işlem adımlarının tek tek uygulandığı fundus örnekleri



Şekil 3.27. Sırasıyla gaussian blur, eşikleme, kontur tespiti, CLAHE ve median blur yöntemlerinin uygulanmış olduğu fundus görüntüleri örnekleri

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, DR derecelerinin sınıflandırılmasında kullanılan iki farklı veri setine uygulanan ön işlem teknikleri ve transfer öğrenme modellerinin performans sonuçları ele alınmakta ve tartışılmaktadır. Çeşitli ön işlem yöntemlerinin ve transfer öğrenme tabanlı modellerin sınıflandırma doğruluğuna etkisi, doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skor gibi performans metrikleri üzerinden incelenmesine ek olarak doğruluk ve kayıp grafiklerinin incelenmesi yoluyla da analiz edilmektedir. EfficientNetB5, VGG16 ve VGG19 modelleri ile yapılan testlerde farklı ön işlem ve veri seti kombinasyonlarının sınıflandırma performansı üzerindeki etkisi değerlendirilmektedir.

4.1.Kullanılan Performans Metrikleri

Derin öğrenme tabanlı sınıflandırma modelinin DR derecelerini ayırt etme başarısını değerlendirmek için kullanılan performans metrikleri üzerinde durulmaktadır. Performans metrikleri, modelin hem genel doğruluğunu hem de farklı sınıflarda gösterdiği başarıyı ölçmeyi amaçlamaktadır. Bu bağlamda modelin başarısını analiz etmek amacıyla doğruluk, kesinlik, duyarlılık ve F1 skor olmak üzere dört temel metrik incelenmektedir. Bu metrikler, makine öğrenmesi ve derin öğrenme modellerinin değerlendirilmesinde yaygın olarak kullanılan standart performans kriterleridir (Sokolova ve Lapalme, 2009).

4.1.1. Doğruluk

Doğruluk, tüm tahminlerin içinde doğru olanlarının oranını ifade etmektedir. DR sınıflandırmasında doğruluk metriği, modelin tüm sınıflar genelinde ne kadar doğru sonuçlar ürettiğini göstermektedir. Doğruluk değeri her sınıfa ait eşit miktarda görüntü varsa daha doğru sonuçlar vermekte ancak sınıflar arasında dengesizlik varsa (örneğin, bir sınıfın sahip olduğu görüntü sayısı diğerlerinden çok daha fazla sayıda ise) doğruluk tek başına yeterli bir metrik olmamaktadır çünkü model az görülen sınıflarda düşük performans gösterse bile doğruluk değeri yüksek olabilmektedir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

4.1.2. Kesinlik

Kesinlik, modelin pozitif (hasta) olarak sınıflandırdığı örneklerin ne kadarının gerçekten pozitif (hasta) olduğunu göstermektedir. Kesinlik, yanlış pozitif sınıflandırmaların önemli olduğu uygulamalarda kritik bir metriktir. Kesinlik metriği, DR teşhisinde yanlış pozitiflerin gereksiz endişelere ve tedavilere yol açabileceği düşünüldüğünde modelin başarısını önemli ölçüde etkilemektedir.

$$Kesinlik = \frac{TP}{TP + FP} \quad (4.2)$$

4.1.3. Duyarlılık

Duyarlılık, gerçekte pozitif (hasta) olan örneklerin ne kadarının doğru bir şekilde pozitif (hasta) olarak sınıflandırıldığını göstermektedir. DR gibi kritik bir hastalığın teşhisinde duyarlılık önemlidir çünkü bu metrik, hastalığa sahip bireylerin doğru bir şekilde tanımlanması gerektiğini vurgulamaktadır. Yüksek duyarlılık, modelin hastalığı olan hastaları doğru bir şekilde tanımlayabildiğini göstermektedir.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (4.3)$$

4.1.4. F1 skor

F1 skor, kesinlik ve duyarlılığın harmonik ortalamasıdır ve modelin dengeli bir performans gösterip göstermediğini değerlendirmektedir. Dengesiz veri kümelerinde (örneğin, DR' nin farklı dereceleri arasında görüntü sayılarında büyük farklar olduğunda), F1 skor kullanışlı bir metrik olarak öne çıkmaktadır çünkü hem yanlış pozitifler hem de yanlış negatifler göz önünde bulundurulmaktadır. F1 skor, sınıflar arasında dengesizlik olduğunda dengeli bir performans ölçümü sağlamak ve modelin genel başarısını daha iyi yansıtmaktadır. DR gibi önemli bir sağlık durumunda yanlış teşhislerden kaçınmak kadar doğru teşhis koymak da büyük önem taşımaktadır.

$$F1 \text{ Skor} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4.4)$$

TP (True Positive), TN (True Negative), FP (False Positive) ve FN (False Negative) kavramları, sınıflandırma problemlerinde modelin performansını değerlendirmek için kullanılan temel sınıflandırma sonuçlarını ifade etmektedir.

- TP (Gerçek Pozitif)

Gerçek pozitif, modelin bir örneği doğru bir şekilde ‘pozitif (hasta)’ olarak sınıflandırdığı durumu ifade etmektedir. Örneğin, DR teşhisinde model gerçekten hastalığı olan bir bireyi doğru bir şekilde ‘hasta’ olarak sınıflandırmışsa bu bir TP’ dir. TP değerinin yüksek olması modelin hastalığı olan bireyleri doğru bir şekilde teşhis etme kapasitesinin güçlü olduğunu göstermektedir. Bu durum, yüksek duyarlılık metriği ile doğrudan ilişkilidir.

- TN (Gerçek Negatif)

Gerçek negatif, modelin bir örneği doğru bir şekilde ‘negatif (hasta değil)’ olarak sınıflandırdığı durumu ifade etmektedir. Yani, DR’ ye sahip olmayan bir bireyin doğru bir şekilde ‘hasta değil’ olarak sınıflandırılmasıdır. TN değerinin yüksek olması modelin gereksiz yere tedavi veya müdahaleden kaçınma kapasitesini göstermektedir. Bu durum, hastalığa sahip olmayan bireyleri doğru bir şekilde dışlamada önemlidir.

- FP (Yanlış Pozitif)

Yanlış pozitif, modelin bir örneği yanlış bir şekilde ‘pozitif (hasta)’ olarak sınıflandırdığı durumu ifade etmektedir. Bu durumda, birey aslında DR’ ye sahip değilken model tarafından ‘hasta’ olarak sınıflandırılmaktadır. Yanlış pozitifler, gereksiz tedavi ve endişeye neden olabileceğinden sağlık uygulamalarında istenmeyen durumlardan olmaktadır. FP sayısının fazla olması, modelin gereksiz tedavi kararlarına yol açabileceğini göstermekte ve bu durum kesinlik metriğini düşürmektedir. Yüksek FP, modelin yanlış alarmlar verdiği anlamına gelmektedir.

- FN (Yanlış Negatif)

Yanlış negatif, modelin bir örneği yanlış bir şekilde ‘negatif (hasta değil)’ olarak sınıflandırdığı durumu ifade etmektedir. Bu durumda, birey aslında DR’ ye sahipken

model onu ‘hasta değil’ olarak sınıflandırmaktadır. Yanlış negatifler, sağlık uygulamalarında oldukça önemli hatalar olabilmektedir çünkü hastalığın var olduğu durumda tedavi uygulanmayabilmekte ve bu durum da ciddi sonuçlara yol açabilmektedir. FN sayısının fazla olması, modelin hastalığa sahip olan bireyleri kaçırdığı anlamına gelmektedir ve bu durumda duyarlılık metriği düşük olmaktadır. Hastalığın kaçırılmasının riskli olduğu sağlık durumlarında FN değerini düşük tutmak çok önemlidir.

4.2. Test Sonuçları

Tez çalışması kapsamında kullanılan her iki veri setinin de %70’ i eğitim, %30’ u test için ayrılmıştır. Eğitim için öğrenme oranı 0,0001 olarak, adım sayısı (epoch) 10 ve batch size değeri 16 olarak belirlenmiştir. Optimizasyon yöntemi olarak Adam kullanılmış ve kayıp fonksiyonu olarak İkili Çapraz Entropi (Binary Cross Entropy) tercih edilmiştir. Bu hiper parametreler, modelin performansını optimize etmek ve aşırı öğrenmeyi en aza indirmek amacıyla deneme yanılma yoluyla seçilmiştir.

4.2.1. APTOS veri seti için sonuçlar

Tez çalışmasında APTOS veri setine uygulanan beş farklı ön işlem yöntemi ve üç farklı transfer öğrenme modeli uygulanarak ortaya çıkan sonuçlar incelenmektedir. Ön işlem yöntemleri iki farklı adımda uygulanmaktadır. Veri setine ilk olarak Gaussian blur yöntemi, eşikleme yöntemi ve kontur tespiti yöntemi uygulanmış (ilk ön işlem adımı) ve eğitilmiş, ardından ilk ön işlem adımı uygulanmış görüntülere ikinci ön işlem adımında CLAHE ve Median blur yöntemleri uygulanmış (ikinci ön işlem adımı) ve eğitilmiştir. Ön işlemsiz sonuçlar, Gaussian blur – eşikleme – kontur tespiti yöntemlerinin uygulandığı sonuçlar (ilk ön işlem adımı sonuçları) ve son olarak ilk ön işlem adımı uygulanmış görüntülere CLAHE – Median blur yöntemlerinin uygulandığı sonuçlar (ikinci ön işlem adımı sonuçları) EfficientNetB5, VGG16 ve VGG19 transfer öğrenme modelleri de kullanılarak elde edilmektedir.


4.2.1.1. EfficientNetB5 modeli sonuçları

APTOS veri seti için transfer öğrenme modellerinden EfficientNetB5 modeline ait sonuçlar üç bölüme ayrılmaktadır. Öncelikle herhangi bir ön işlem uygulanmadan elde

edilen sonuçlar, ardından Gaussian blur – eşikleme – kontur tespiti ön işlemlerinin uygulanıp elde edilen sonuçlar (ilk ön işlem adımı sonuçları) ve son olarak ilk ön işlem adımı uygulanmış görüntülere CLAHE ve Median blur ön işlemlerinin uygulanıp elde edilen sonuçlar (ikinci ön işlem adımı sonuçları) karşılaştırılmaktadır.

- **Ön İşlemsiz Sonuçlar**


Şekil 4.1’de APTOS veri seti için ön işlemsiz sonuçlar transfer öğrenme yöntemlerinden EfficientNetB5 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %96,09 doğruluk değerine sahiptir.



Şekil 4.1. EfficientNetB5 modeli için ön işlemsiz doğruluk ve kayıp grafikleri

- **İlk Ön İşlem Adımının Sonuçları (Gaussian blur-Eşikleme-Kontur tespiti)**


Şekil 4.2’de APTOS veri seti için ilk ön işlem adımının sonuçları transfer öğrenme yöntemlerinden EfficientNetB5 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %95,49 doğruluk değerine sahiptir.



Şekil 4.2. EfficientNetB5 modeli için ilk ön işlem adımının doğruluk ve kayıp grafikleri

• İkinci Ön İşlem Adımının Sonuçları (CLAHE-Median blur)

Şekil 4.3'te APTOS veri seti için ikinci ön işlem adımının sonuçları transfer öğrenme yöntemlerinden EfficientNetB5 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %93,63 doğruluk değerine sahiptir.



Şekil 4.3. EfficientNetB5 modeli için ikinci ön işlem adımının doğruluk ve kayıp grafikleri

Çizelge 4.1. APTOS veri seti için EfficientNetB5 modeli performansı


Model	Adım	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 skor (%)
EfficientNetB5	Ön İşlemsiz	0,9609	0,9664	0,9402	0,9531
	İlk Ön İşlem Adımı	0,9549	0,9605	0,9316	0,9458
	İkinci Ön İşlem Adımı	0,9363	0,9782	0,8688	0,9202

4.2.1.2. VGG16 modeli sonuçları

APTOS veri seti için transfer öğrenme modellerinden VGG16 modeline ait sonuçlar üç bölüme ayrılmaktadır. Öncelikle herhangi bir ön işlem uygulanmadan elde edilen sonuçlar, ardından Gaussian blur – eşikleme – kontur tespiti ön işlemlerinin uygulanıp elde edilen sonuçlar (ilk ön işlem adımı sonuçları) ve son olarak ilk ön işlem adımı uygulanmış görüntülere CLAHE ve Median blur ön işlemlerinin uygulanıp elde edilen sonuçlar (ikinci ön işlem adımı sonuçları) karşılaştırılmaktadır.

- **Ön İşlemsiz Sonuçlar**


Şekil 4.4'te APTOS veri seti için ön işlemsiz sonuçlar transfer öğrenme yöntemlerinden VGG16 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %95,18 doğruluk değerine sahiptir.



Şekil 4.4. VGG16 modeli için ön işlemsiz doğruluk ve kayıp grafikleri

- İlk Ön İşlem Adımının Sonuçları (Gaussian blur-Eşikleme-Kontur tespiti)


Şekil 4.5'te APTOS veri seti için ilk ön işlem adımının sonuçları transfer öğrenme yöntemlerinden VGG16 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %95,40 doğruluk değerine sahiptir.



Şekil 4.5. VGG16 modeli için ilk ön işlem adımının doğruluk ve kayıp grafikleri

- İkinci Ön İşlem Adımının Sonuçları (CLAHE-Median blur)

Şekil 4.6'da APTOS veri seti için ikinci ön işlem adımının sonuçları transfer öğrenme yöntemlerinden VGG16 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %95,18 doğruluk değerine sahiptir.



Şekil 4.6. VGG16 modeli için ikinci ön işlem adımının doğruluk ve kayıp grafikleri

Çizelge 4.2. APTOS veri seti için VGG16 modeli performansı


Model	Adım	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 skor (%)
VGG16	Ön İşlemsiz	0,9518	0,9379	0,9488	0,9433
	İlk Ön İşlem Adımı	0,9540	0,9617	0,9281	0,9446
	İkinci Ön İşlem Adımı	0,9518	0,9594	0,9251	0,9419

4.2.1.3. VGG19 modeli sonuçları

APTOS veri seti için transfer öğrenme modellerinden VGG19 modeline ait sonuçlar üç bölüme ayrılmaktadır. Öncelikle herhangi bir ön işlem uygulanmadan elde edilen sonuçlar, ardından Gaussian blur – eşikleme – kontur tespiti ön işlemlerinin uygulanıp elde edilen sonuçlar (ilk ön işlem adımı sonuçları) ve son olarak ilk ön işlem adımı uygulanmış görüntülere CLAHE ve Median blur ön işlemlerinin uygulanıp elde edilen sonuçlar (ikinci ön işlem adımı sonuçları) karşılaştırılmaktadır.

- **Ön İşlemsiz Sonuçlar**


Şekil 4.7’de APTOS veri seti için ön işlemsiz sonuçlar transfer öğrenme yöntemlerinden VGG19 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %95,25 doğruluk değerine sahiptir.



Şekil 4.7. VGG19 modeli için ön işlemsiz doğruluk ve kayıp grafikleri

- İlk Ön İşlem Adımının Sonuçları (Gaussian blur-Eşikleme-Kontur tespiti)


Şekil 4.8’de APTOS veri seti için ilk ön işlem adımının sonuçları transfer öğrenme yöntemlerinden VGG19 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %95,05 doğruluk değerine sahiptir.



Şekil 4.8. VGG19 modeli için ilk ön işlem adımının doğruluk ve kayıp grafikleri

- İkinci Ön İşlem Adımının Sonuçları (CLAHE-Median blur)

Şekil 4.9’da APTOS veri seti için ikinci ön işlem adımının sonuçları transfer öğrenme yöntemlerinden VGG19 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %94,89 doğruluk değerine sahiptir.



Şekil 4.9. VGG19 modeli için ikinci ön işlem adımının doğruluk ve kayıp grafikleri

Çizelge 4.3. APTOS veri seti için VGG19 modeli performansı

Model	Adım	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 skor (%)
VGG19	Ön İşlemsiz	0,9525	0,9657	0,9204	0,9425
	İlk Ön İşlem Adımı	0,9505	0,9580	0,9234	0,9403
	İkinci Ön İşlem Adımı	0,9489	0,9494	0,9286	0,9388

4.2.2. Diabetic Retinopathy (resized) veri seti için sonuçlar


Tez çalışmasında Diabetic Retinopathy (resized) veri setine uygulanan beş farklı ön işlem yöntemi ve üç farklı transfer öğrenme modeli uygulanarak ortaya çıkan sonuçlar incelenmektedir. Ön işlem yöntemleri iki farklı adımda uygulanmaktadır. Veri setine ilk olarak Gaussian blur yöntemi, eşikleme yöntemi ve kontur tespiti yöntemi uygulanmış (ilk ön işlem adımı) ve eğitilmiş, ardından ilk ön işlem adımı uygulanmış görüntülere ikinci ön işlem adımında CLAHE ve Median blur yöntemleri uygulanmış (ikinci ön işlem adımı) ve eğitilmiştir. Ön işlemsiz sonuçlar, Gaussian blur – eşikleme – kontur tespiti yöntemlerinin uygulandığı sonuçlar (ilk ön işlem adımı sonuçları) ve son olarak ilk ön işlem adımı uygulanmış görüntülere CLAHE – Median blur yöntemlerinin uygulandığı sonuçlar (ikinci ön işlem adımı sonuçları) EfficientNetB5, VGG16 ve VGG19 transfer öğrenme modelleri de kullanılarak elde edilmektedir.

4.2.2.1. EfficientNetB5 modeli sonuçları

Diabetic Retinopathy (resized) veri seti için transfer öğrenme modellerinden EfficientNetB5 modeline ait sonuçlar üç bölüme ayrılmaktadır. Öncelikle herhangi bir ön işlem uygulanmadan elde edilen sonuçlar, ardından Gaussian blur – eşikleme – kontur tespiti ön işlemlerinin uygulanıp elde edilen sonuçlar (ilk ön işlem adımı sonuçları) ve son olarak ilk ön işlem adımı uygulanmış görüntülere CLAHE ve Median blur ön işlemlerinin uygulanıp elde edilen sonuçlar (ikinci ön işlem adımı sonuçları) karşılaştırılmaktadır.

- **Ön İşlemsiz Sonuçlar**


Şekil 4.10'da Diabetic Retinopathy (resized) veri seti için ön işlemsiz sonuçlar transfer öğrenme yöntemlerinden EfficientNetB5 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %87,95 doğruluk değerine sahiptir.



Şekil 4.10. EfficientNetB5 modeli için ön işlemsiz doğruluk ve kayıp grafikleri

- **İlk Ön İşlem Adımının Sonuçları (Gaussian blur-Eşikleme-Kontur tespiti)**


Şekil 4.11'de Diabetic Retinopathy (resized) veri seti için ilk ön işlem adımının sonuçları transfer öğrenme yöntemlerinden EfficientNetB5 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %87,77 doğruluk değerine sahiptir.



Şekil 4.11. EfficientNetB5 modeli için ilk ön işlem adımının doğruluk ve kayıp grafikleri

- İkinci Ön İşlem Adımının Sonuçları (CLAHE-Median blur)

Şekil 4.12’de Diabetic Retinopathy (resized) veri seti için ikinci ön işlem adımının sonuçları transfer öğrenme yöntemlerinden EfficientNetB5 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %87,21 doğruluk değerine sahiptir.



Şekil 4.12. EfficientNetB5 modeli için ikinci ön işlem adımının doğruluk ve kayıp grafikleri

Çizelge 4.4. Diabetic retinopathy (resized) veri seti için EfficientNetB5 modeli performansı


Model	Adım	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 skor (%)
EfficientNetB5	Ön İşlemsiz	0,8795	0,9106	0,6701	0,7720
	İlk Ön İşlem Adımı	0,8777	0,8952	0,6777	0,7714
	İkinci Ön İşlem Adımı	0,8721	0,8626	0,6899	0,7666

4.2.2.2. VGG16 modeli sonuçları

Diabetic Retinopathy (resized) veri seti için transfer öğrenme modellerinden VGG16 modeline ait sonuçlar üç bölüme ayrılmaktadır. Öncelikle herhangi bir ön işlem uygulanmadan elde edilen sonuçlar, ardından Gaussian blur – eşikleme – kontur tespiti ön işlemlerinin uygulanıp elde edilen sonuçlar (ilk ön işlem adımı sonuçları) ve son olarak ilk ön işlem adımı uygulanmış görüntülere CLAHE ve Median blur ön işlemlerinin uygulanıp elde edilen sonuçlar (ikinci ön işlem adımı sonuçları) karşılaştırılmaktadır.

- **Ön İşlemsiz Sonuçlar**


Şekil 4.13'te Diabetic Retinopathy (resized) veri seti için ön işlemsiz sonuçlar transfer öğrenme yöntemlerinden VGG16 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %89,72 doğruluk değerine sahiptir.



Şekil 4.13. VGG16 modeli için ön işlemsiz doğruluk ve kayıp grafikleri

- **İlk Ön İşlem Adımının Sonuçları (Gaussian blur-Eşikleme-Kontur tespiti)**


Şekil 4.14'te Diabetic Retinopathy (resized) veri seti için ilk ön işlem adımının sonuçları transfer öğrenme yöntemlerinden VGG16 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %89,54 doğruluk değerine sahiptir.



Şekil 4.14. VGG16 modeli için ilk ön işlem adımının doğruluk ve kayıp grafikleri

- İkinci Ön İşlem Adımının Sonuçları (CLAHE-Median blur)

Şekil 4.15'te Diabetic Retinopathy (resized) veri seti için ikinci ön işlem adımının sonuçları transfer öğrenme yöntemlerinden VGG16 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %89,54 doğruluk değerine sahiptir.



Şekil 4.15. VGG16 modeli için ikinci ön işlem adımının doğruluk ve kayıp grafikleri

Çizelge 4.5. Diabetic retinopathy (resized) veri seti için VGG16 modeli performansı


Model	Adım	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 skor (%)
VGG16	Ön İşlemsiz	0,8972	0,9999	0,6605	0,7955
	İlk Ön İşlem Adımı	0,8954	1,0000	0,6567	0,7927
	İkinci Ön İşlem Adımı	0,8954	1,0000	0,6558	0,7921

4.2.2.3. VGG19 modeli sonuçları

Diabetic Retinopathy (resized) veri seti için transfer öğrenme modellerinden VGG19 modeline ait sonuçlar üç bölüme ayrılmaktadır. Öncelikle herhangi bir ön işlem uygulanmadan elde edilen sonuçlar, ardından Gaussian blur – eşikleme – kontur tespiti ön işlemlerinin uygulanıp elde edilen sonuçlar (ilk ön işlem adımı sonuçları) ve son olarak ilk ön işlem adımı uygulanmış görüntülere CLAHE ve Median blur ön işlemlerinin uygulanıp elde edilen sonuçlar (ikinci ön işlem adımı sonuçları) karşılaştırılmaktadır.

- **Ön İşlemsiz Sonuçlar**


Şekil 4.16'da Diabetic Retinopathy (resized) veri seti için ön işlemsiz sonuçlar transfer öğrenme yöntemlerinden VGG19 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %89,72 doğruluk değerine sahiptir.



Şekil 4.16. VGG19 modeli için ön işlemsiz doğruluk ve kayıp grafikleri

- **İlk Ön İşlem Adımının Sonuçları (Gaussian blur-Eşikleme-Kontur tespiti)**


Şekil 4.17'de Diabetic Retinopathy (resized) veri seti için ilk ön işlem adımının sonuçları transfer öğrenme yöntemlerinden VGG19 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %89,54 doğruluk değerine sahiptir.



Şekil 4.17. VGG19 modeli için ilk ön işlem adımının doğruluk ve kayıp grafikleri

- İkinci Ön İşlem Adımının Sonuçları (CLAHE-Median blur)

Şekil 4.18’de Diabetic Retinopathy (resized) veri seti için ikinci ön işlem adımının sonuçları transfer öğrenme yöntemlerinden VGG19 kullanılarak elde edilmektedir. X eksenindeki değerler adım sayısını, Y eksenindeki değerler doğruluk değerlerini göstermektedir. Model %89,54 doğruluk değerine sahiptir.



Şekil 4.18. VGG19 modeli için ikinci ön işlem adımının doğruluk ve kayıp grafikleri

Çizelge 4.6. Diabetic retinopathy (resized) veri seti için VGG19 modeli performansı

Model	Adım	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 skor (%)
VGG19	Ön İşlemsiz	0,8972	1,0000	0,6605	0,7955
	İlk Ön İşlem Adımı	0,8954	1,0000	0,6567	0,7927
	İkinci Ön İşlem Adımı	0,8954	1,0000	0,6559	0,7921

Çizelge 4.4, 4.5 ve 4.6’ da ikinci veri seti için elde edilen sonuçlarda, kesinlik değerinin yüksek, duyarlılık değerinin ise düşük olduğu gözlemlenmektedir. Bu durum modelin pozitif örneklerin (hasta örneklerin) bazılarını tespit edemediğini göstermektedir. Bu tür bir performans özellikle veri setindeki sınıf dengesizliğinden (sağlıklı örneklerin sayısının hasta örneklerden çok daha fazla olmasından) kaynaklanıyor olabilir. Ayrıca eğitim doğruluğunun düşük, test doğruluğunun yüksek olması, modelin eğitim sırasında veriyi yeterince öğrenemediğini ya da eğitim setindeki özelliklerin daha karmaşık ve gürültülü olabileceğini göstermektedir.

Çizelge 4.7. Veri setleri ve modeller için ön işlem adımlarının performans metriklerine etkisi

Veri Seti	Model	Adım	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 skor (%)
APTOS	EfficientNetB5	Ön İşlemsiz	0,9609	0,9664	0,9402	0,9531
		İlk Ön İşlem Adımı	0,9549	0,9605	0,9316	0,9458
		İkinci Ön İşlem Adımı	0,9363	0,9782	0,8688	0,9202
APTOS	VGG16	Ön İşlemsiz	0,9518	0,9379	0,9488	0,9433
		İlk Ön İşlem Adımı	0,9540	0,9617	0,9281	0,9446
		İkinci Ön İşlem Adımı	0,9518	0,9594	0,9251	0,9419
APTOS	VGG19	Ön İşlemsiz	0,9525	0,9657	0,9204	0,9425
		İlk Ön İşlem Adımı	0,9505	0,9580	0,9234	0,9403
		İkinci Ön İşlem Adımı	0,9489	0,9494	0,9286	0,9388
DR (resized)	EfficientNetB5	Ön İşlemsiz	0,8795	0,9106	0,6701	0,7720
		İlk Ön İşlem Adımı	0,8777	0,8952	0,6777	0,7714
		İkinci Ön İşlem Adımı	0,8721	0,8626	0,6899	0,7666
DR (resized)	VGG16	Ön İşlemsiz	0,8972	0,9999	0,6605	0,7955
		İlk Ön İşlem Adımı	0,8954	1,0000	0,6567	0,7927
		İkinci Ön İşlem Adımı	0,8954	1,0000	0,6558	0,7921
DR (resized)	VGG19	Ön İşlemsiz	0,8972	1,0000	0,6605	0,7955
		İlk Ön İşlem Adımı	0,8954	1,0000	0,6567	0,7927
		İkinci Ön İşlem Adımı	0,8954	1,0000	0,6559	0,7921

Çizelge 4.8. Literatürde var olan sonuçlarla tez sonuçlarının karşılaştırılması

Özellik/Metrik	Özçelik ve Altan, 2021	Pratt ve diğ., 2016	Polater ve Işık, 2024	Tez Sonuçları
Model Türü	KSA	KSA	KSA	KSA
Veri Seti	APTOS	Kaggle Dataset	APTOS	APTOS
Transfer Öğrenme	VGG19	-	VGG16	EfficientNetB5
Doğruluk (%)	97.8	75	96	96
Precision (%)	97.6	-	96.1	96.6
Recall (%)	97.7	-	96.1	94
F1 Skor (%)	97.6	-	96.1	95.3

Çizelge 4.7’ de, APTOS ve DR (resized) veri setleri üzerinde EfficientNetB5, VGG16 ve VGG19 modelleriyle yapılan çalışmanın doğruluk, kesinlik, duyarlılık ve F1 skor değerleri karşılaştırılmaktadır. Her model için, ön işlem uygulanmamış sonuçlar ve iki farklı ön işlem adımı sonrası elde edilen sonuçlar gösterilmektedir.

Çizelge 4.8’de, tez çalışmasında elde edilen sonuçlar literatürdeki diğer çalışmalarla karşılaştırılmaktadır. Özçelik ve Altan (2021), Pratt ve diğerleri (2016), Polater ve Işık (2024) gibi çalışmalar, APTOS ve Kaggle veri setleri üzerinde çeşitli modeller kullanılarak gerçekleştirilmiştir.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Tez çalışması kapsamında, DR derecelerinin derin öğrenme tabanlı sınıflandırılması sürecinde ön işlem yöntemlerinin (Gaussian blur, eşikleme, kontur tespiti, CLAHE ve median blur) etkisini analiz etmek amaçlanmaktadır. Araştırma kapsamında, EfficientNetB5, VGG16 ve VGG19 gibi transfer öğrenme yöntemleri kullanılarak farklı ön işlem tekniklerinin model performansı üzerindeki etkisi incelenmektedir. Çalışmada kullanılan iki farklı veri seti üzerinde yapılan test sonuçları, farklı ön işlem adımlarının doğruluk, kesinlik, duyarlılık ve F1 skor gibi metrikler üzerindeki etkilerini ayrıntılı bir şekilde ortaya koymaktadır.

APTOS veri seti için herhangi bir ön işlem uygulanmadan önceki doğruluk oranları, EfficientNetB5 (%96,09) ile en yüksek performansı gösterirken, VGG16 (%95,18) en düşük doğruluğu sağlamaktadır. İlk ön işlem adımı uygulandığında (Gaussian blur - eşikleme - kontur tespiti) sadece VGG16 modelinde iyileşme gözlemlenmekte, diğer modellerde minimal bir düşüş olmaktadır. İkinci ön işlem adımı uygulandığında (CLAHE - Median blur), doğruluk oranlarında genel bir düşüş gözlemlenmektedir.

Diabetic retinopathy (resized) veri seti için herhangi bir ön işlem uygulanmadan elde edilen doğruluk oranları üç modelde de oldukça benzer olup %88 - %89 civarındadır. İlk ön işlem adımı uygulandığında (Gaussian blur - eşikleme - kontur tespiti), tüm modellerde doğruluk değerlerinde küçük düşüşler gözlemlenmekte, ikinci ön işlem adımı uygulandığında (CLAHE - Median blur) ise EfficientNetB5 modelinin doğruluk oranında yine küçük bir düşüş olurken VGG16 ve VGG19 modellerinde doğruluk değerlerinin aynı kaldığı gözlemlenmektedir.

APTOS veri seti, genel olarak her model için daha yüksek doğruluk, kesinlik, duyarlılık ve F1 skor değerleri sağlamıştır. Bu, APTOS veri setinin DR (resized) veri setine göre daha temiz ve daha dengeli bir yapıya sahip olduğunu göstermektedir. DR (resized) veri seti, özellikle duyarlılık değerlerinde düşük performans göstermiştir. Bu durum, veri setindeki sınıfların dengesizliği veya daha karmaşık bir dağılıma sahip olmasıyla ilişkilendirilebilir.

APTOS veri setinde, ön işlem yapılmayan durum genellikle en iyi sonuçları vermektedir. EfficientNetB5 modeli, ham veride en yüksek doğruluk ve F1 skorlarına

ulaşmaktadır. Bu, ön işlemlerin bazı durumlarda modellerin öğrenme kapasitesini sınırlayabileceğini göstermektedir. DR (resized) veri setinde, ön işlem adımlarının performansta herhangi bir iyileşme sağlamadığı görülmektedir. Bu durum, bu modellerin ham verideki detaylardan daha iyi faydalandığını, ancak ön işlemle birlikte bazı bilgilerin kaybolabileceğini gösterebilir.

Ön işlem adımları, veri seti ve model özelliklerine bağlı olarak farklı etkiler göstermektedir. Bazı durumlarda ön işlemler bilgi kaybına neden olurken, bazı durumlarda modellerin performansını artırmaktadır. APTOS veri setinde genellikle daha yüksek metrik değerlerine ulaşılmış olması, bu veri setinin sınıflandırma görevleri için daha uygun olduğunu göstermektedir. Modellerin başarısı, yalnızca kullanılan veri seti ile değil, aynı zamanda veri setinin doğasına uygun ön işlem adımlarıyla da doğrudan ilişkili olmaktadır.

APTOS veri setinde genel doğruluk ve F1 skorlar değerleri daha yüksektir. Bu, APTOS veri setinin DR (resized)' ye göre daha temiz veya sınıflandırma için daha uygun bir dağılıma sahip olduğunu gösterebilir. DR veri setinde özellikle duyarlılık değerleri (%66 - %69 aralığı) oldukça düşüktür. Bu, DR (resized) veri setinin dengesiz sınıflar veya zorlu sınıflandırma örnekleri içerdiğini göstermektedir.

Veri setlerinin görüntü çözünürlükleri APTOS veri seti için 474×358 ile 3388×2588 arasında değişirken, DR (resized) veri seti için 1024×1024 ' tür. Transfer öğrenme yaklaşımlarında kabul edilen giriş görüntüsü boyutları ise EfficientNetB5 için 456×456 iken VGG16 ve VGG19 için 224×224 ' tür. APTOS veri setindeki görüntü çözünürlüklerinin yüksek bir aralıkta değişmesi, modellerin giriş boyutlarına uyum sağlamak için uygulanan yeniden boyutlandırma işlemlerinde önemli bir bilgi kaybına yol açabilmektedir. Özellikle küçük boyutlu görüntülerin yeniden boyutlandırılması sırasında detay kaybı, büyük boyutlu görüntülerin ise aşırı sıkıştırma nedeniyle bilgi kaybı yaşaması muhtemeldir. DR (resized) veri setinde görüntülerin çözünürlüğü sabit olduğu için, yeniden boyutlandırma işlemleri daha tutarlı bir şekilde yapılabilir ancak bu boyutun modellerin giriş boyutlarıyla uyumu da önemlidir. 1024×1024 'ten 456×456 'ya boyut küçültme sırasında özellikle ince detayların kaybolması muhtemeldir. EfficientNet' in bu detaylara bağımlı öğrenme yapısı performansın düşmesine neden olabilir. Bu durum, DR (resized) veri setindeki düşük duyarlılık değerleriyle uyumludur. VGGNet' teki daha küçük giriş boyutları, DR (resized) veri setindeki yüksek çözünürlüklü görüntülerin daha agresif bir şekilde yeniden boyutlandırılmasını gerektirir. Bu işlem sırasında daha fazla bilgi kaybı yaşanabilmektedir.

APTOS veri seti için, yüksek çözünürlük çeşitliliği, EfficientNetB5'in geniş çözünürlük aralığındaki avantajını ortaya çıkarabilmektedir. VGG modelleri ise daha küçük boyutlara indirgeme sırasında daha fazla bilgi kaybı yaşayabilir, bu da özellikle düşük çözünürlüklü görüntülerde EfficientNet'e göre daha düşük performans göstermelerine neden olabilmektedir.

DR veri seti için, sabit çözünürlük yeniden boyutlandırma işlemlerinin daha tutarlı yapılmasını sağlasa da, EfficientNetB5 ve VGG modelleri için giriş boyutlarına indirgeme sırasında önemli detayların kaybolması genel performansı düşürmektedir. Bu durum, özellikle duyarlılık değerlerinde gözlemlenmektedir.

5.2 Öneriler

Transfer öğrenme modellerinin katmanlarının ince ayar yapılarak DR sınıflandırmasına daha uygun hale getirilmesi önerilmektedir.

Tez çalışmasının sonuçları, klinik uygulamalar için otomatik DR tarama sistemlerinin geliştirilmesinde bir temel olarak kullanılabilir. Özellikle yüksek doğruluk ve duyarlılık sağlayan modeller erken tanı süreçlerinde kullanılabilir.

Derin öğrenme modellerinin yanı sıra hibrit yaklaşımlar (örneğin, geleneksel görüntü işleme ile derin öğrenme kombinasyonu) araştırılabilir.

Daha karmaşık ve düşük performans gösteren veri setleri için, sınıf dengesizliklerini gidermeye yönelik yöntemler (ör. veri artırma veya SMOTE) kullanılabilir.

Veri setlerinin özelliklerine göre özelleştirilmiş ön işlem adımları kullanılabilir. Örneğin, daha düşük kontrastlı görüntüler için CLAHE yöntemi etkili olabilirken, fazla gürültülü veri setlerinde blur tercih edilebilir.

Farklı veri setleri için transfer öğrenme yöntemlerinin performansı değişiklik gösterebildiğinden her yeni veri setinde performans analizi yapılmalı ve en iyi sonuç veren model seçilmelidir.

Veri setlerinin özelliklerini anlamaya yönelik detaylı analizler yapılabilir ve bu analizler ışığında daha spesifik ön işlem adımları geliştirilebilir.

Transfer öğrenme yöntemleriyle birlikte hiper parametre optimizasyonu yapılması performansı artırabilir.

APTOS ve DR (resized) veri setleri üzerinde elde edilen sonuçlar, gelecekteki çalışmalarda bu veri setlerinin özelliklerine özgü daha iyi çözümler geliştirmek için referans alınabilir.

Tez çalışması kapsamında, DR sınıflandırmasında ön işlem yöntemlerinin etkileri ortaya konmaya çalışılmıştır. Daha gelişmiş teknikler ve daha dengeli veri setleri ile bu alandaki başarı oranlarının artırılabilceğı düşünölmektedir.



KAYNAKLAR

- Abràmoff MD, Garvin MK, Sonka M. Retinal imaging and image analysis. *IEEE Rev Biomed Eng.* 2010;3:169-208. doi: 10.1109/RBME.2010.2084567. PMID: 22275207; PMCID: PMC3131209.
- Abràmoff MD, Lavin PT, Birch M, Shah N, Folk JC. Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. *NPJ Digit Med.* 2018 Aug 28;1:39. doi: 10.1038/s41746-018-0040-6. PMID: 31304320; PMCID: PMC6550188.
- Aiello L. M. (2003). Perspectives on diabetic retinopathy. *American journal of ophthalmology*, 136(1), 122–135. [https://doi.org/10.1016/s0002-9394\(03\)00219-8](https://doi.org/10.1016/s0002-9394(03)00219-8)
- Aiello LP, Gardner TW, King GL, Blankenship G, Cavallerano JD, Ferris FL 3rd, Klein R. Diabetic retinopathy. *Diabetes Care.* 1998 Jan;21(1):143-56. doi: 10.2337/diacare.21.1.143. PMID: 9538986.
- Akın, E., & Şahin, M. E. (2024). Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. *EMO Bilimsel Dergi*, 14(1), 27-38.
- Akram MU, Shahzad K, Shoaib AK. Identification and classification of micro aneurysms for early detection of diabetic retinopathy. *Pattern Recogn* 2013; 46:107–116.
- American Diabetes Association (ADA). (2022). Standards of Medical Care in Diabetes—2022. *Diabetes Care*, 45(Supplement_1), S1-S264.
- Antonetti DA, Barber AJ, Bronson SK, Freeman WM, Gardner TW, Jefferson LS, Kester M, Kimball SR, Krady JK, LaNoue KF, Norbury CC, Quinn PG, Sandirasegarane L, Simpson IA; JDRF Diabetic Retinopathy Center Group. Diabetic retinopathy: seeing beyond glucose-induced microvascular disease. *Diabetes.* 2006 Sep;55(9):2401-11. doi: 10.2337/db05-1635. PMID: 16936187.

- APTOS (2019). Blindness detection. URL: <https://www.kaggle.com/c/aptos2019-blindness-detection>.
- Bora A, Balasubramanian S, Babenko B, Virmani S, Venugopalan S, Mitani A, de Oliveira Marinho G, Cuadros J, Ruamviboonsuk P, Corrado GS, Peng L, Webster DR, Varadarajan AV, Hammel N, Liu Y, Bavishi P. Predicting the risk of developing diabetic retinopathy using deep learning. *Lancet Digit Health*. 2021 Jan;3(1):e10-e19. doi: 10.1016/S2589-7500(20)30250-8. Epub 2020 Nov 26. PMID: 33735063.
- Bowling, B. (2016). *Kanski's Clinical Ophthalmology: A Systematic Approach*. Elsevier.
- Bradley, D., & Roth, G. (2007). Adaptive Thresholding using the Integral Image. *Journal of Graphics Tools*, 12, 13 - 21.
- Breiman, L., Friedman, J., Olshen, R. A., & Stone, C. J. (1986). *Classification and Regression Trees*. Chapman and Hall/CRC.
- Brownlee J. 2019. Web Sites: <https://machinelearningmastery.com/transfer-learning-for-deep-learning/>, Erişim Tarihi: 25.12.2023.
- Chan, T. H., Jia, K., Gao, S., Lu, J., Zeng, Z., & Ma, Y. (2015). PCANet: A simple deep learning baseline for image classification. *IEEE Transactions on Image Processing*, 24(12), 5017-5032.
- Cheung N, Mitchell P, Wong TY. Diabetic retinopathy. *Lancet*. 2010 Jul 10;376(9735):124-36. doi: 10.1016/S0140-6736(09)62124-3. Epub 2010 Jun 26. PMID: 20580421.
- Chew, E. Y., Klein, M. L., Ferris, F. L., Remaley, N. A., Murphy, R. P., Chantry, K., Hoogwerf, B. J., & Miller, D. (1996). Association of elevated serum lipid levels with retinal hard exudate in diabetic retinopathy: Early treatment diabetic retinopathy study (ETDRS) report 22. *Archives of ophthalmology*, 114(9), 1079-1084. <https://doi.org/10.1001/archopht.1996.01100140281004>

- Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20(3), 273-297.
- Cover, T. M., & Hart, P. E. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21-27.
- Esteva, A., Kuprel, B., Novoa, R. A., et al. (2019). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.
- FIRAT, M., & GÜNGÖR, M. (2004). Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi. *Teknik Dergi*, 15(73).
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36, 193-202.
- Garg, S., & Jani, P. D. (2011). Diabetic Retinopathy: An Update on Diagnostic and Therapeutic Approaches. *Clinical Ophthalmology*, 5, 657-665.
- Gargeya R, Leng T. Automated identification of diabetic retinopathy using deep learning. *Ophthalmology* 2017; 124(7): 962–969.
- Gondal WM, Köhler JM, Grzeszick R Fink GA, Hirsch M, Weakly-supervised localization of diabetic retinopathy lesions in retinal fundus images. Paper presented at: IEEE international conference on image processing (ICIP) 2017: 2069-2073.
- Gonzalez, R. C., & Woods, R. E. (2002). *Digital Image Processing*. Prentice Hall.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Göksu, M., Sünnetci, K., Alkan, A. (2021). Derin Öğrenme Ağları Kullanılarak Mısır Yapraklarında Hastalık Tespiti. *Journal of Computer Science*.

Göz Doktor. (Erişim tarihi: 3 Eylül 2024). Gözün yapısı. <https://gozdoktor.net/gozun-yapisi/>

Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., Venugopalan, S., Widner, K., Madams, T., Cuadros, J., Kim, R., Raman, R., Nelson, P. C., Mega, J. L., & Webster, D. R. (2016). Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*, 316(22), 2402–2410. <https://doi.org/10.1001/jama.2016.17216>

Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice Hall.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.

Hemanth DJ, Deperlioglu O, Kose U. An enhanced diabetic retinopathy detection and classification approach using deep convolutional neural network. *Neural Computing and Applications* 2020; 32(3): 707-721.

Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.

Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *ArXiv, abs/1704.04861*.

Hu, J., Shen, L., Albanie, S., Sun, G., & Wu, E. (2017). Squeeze-and-Excitation Networks. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 7132-7141.

- Huang, T.S., Yang, G., & Tang, G. (1979). A fast two-dimensional median filtering algorithm. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 27, 13-18.
- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial Neural Networks: A Tutorial. *Computer*, 29(3), 31–44. doi:10.1109/2.485891
- Joulin, A., Grave, E., Bojanowski, P. & Mikolov, T. (2016). Bag of Tricks for Efficient Text Classification (cite arxiv:1607.01759)
- Kempen JH, O'Colmain BJ, Leske MC, Haffner SM, Klein R, Moss SE, Taylor HR, Hamman RF; Eye Diseases Prevalence Research Group. The prevalence of diabetic retinopathy among adults in the United States. *Arch Ophthalmol*. 2004 Apr;122(4):552-63. doi: 10.1001/archopht.122.4.552. PMID: 15078674.
- Kermany DS, Goldbaum M, Cai W, Valentim CCS, Liang H, Baxter SL, McKeown A, Yang G, Wu X, Yan F, Dong J, Prasadha MK, Pei J, Ting MYL, Zhu J, Li C, Hewett S, Dong J, Ziyar I, Shi A, Zhang R, Zheng L, Hou R, Shi W, Fu X, Duan Y, Huu VAN, Wen C, Zhang ED, Zhang CL, Li O, Wang X, Singer MA, Sun X, Xu J, Tafreshi A, Lewis MA, Xia H, Zhang K. Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. *Cell*. 2018 Feb 22;172(5):1122-1131.e9. doi: 10.1016/j.cell.2018.02.010. PMID: 29474911.
- Kingma, D.P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. *CoRR*, abs/1412.6980.
- Klein B. E. (2007). Overview of epidemiologic studies of diabetic retinopathy. *Ophthalmic epidemiology*, 14(4), 179–183. <https://doi.org/10.1080/09286580701396720>
- Klein, R., Klein, B. E., & Moss, S. E. (2004). The epidemiology of diabetic retinopathy. *Diabetic Retinopathy Clinical Research Network*, 48(1), 122-128.

- Klein R, Klein BE, Moss SE, Cruickshanks KJ. The Wisconsin Epidemiologic Study of Diabetic Retinopathy. XV. The long-term incidence of macular edema. *Ophthalmology*. 1995 Jan;102(1):7-16. doi: 10.1016/s0161-6420(95)31052-4. PMID: 7831044.
- Krizhevsky, A., Sutskever, I., & Hinton, G.E. (2012). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60, 84 - 90.
- Kuchera, M.P., Ramanujan, R., Taylor, J.Z., Strauss, R.R., Bazin, D., Bradt, J., & Chen, R. (2018). Machine Learning Methods for Track Classification in the AT-TPC. *ArXiv*, *abs/1810.10350*.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521, 436-444. doi:10.1038/nature14539
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proc. IEEE*, 86, 2278-2324.
- Li X, Pang T, Xiong B, Liu W, Liang P, Wang T, Convolutional neural networks based transfer learning for diabetic retinopathy fundus image classification. Paper presented at: 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). IEEE 2017: 1–11.
- Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, van der Laak JAWM, van Ginneken B, Sánchez CI. A survey on deep learning in medical image analysis. *Med Image Anal*. 2017 Dec;42:60-88. doi: 10.1016/j.media.2017.07.005. Epub 2017 Jul 26. PMID: 28778026.
- Mathworks. (2024). Konvolüsyonel sinir ağları. <https://www.mathworks.com/discovery/convolutional-neural-network.html>
- Medium. (Erişim tarihi: 9 Eylül 2024). EfficientNet temel ağ yapısı. <https://ayyucekizrak.medium.com/%C3%B6l%C3%A7eklendirme-ile-cnn-modelinin-do%C4%9Fruluk-ve-verimlili%C4%9Fini-art%C4%B1rma-efficientnet-cb6f2b6512de>

- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- Nair, V., & Hinton, G.E. (2010). Rectified Linear Units Improve Restricted Boltzmann Machines. *International Conference on Machine Learning*.
- Nazir, T., Irtaza, A., Shabbir, Z., Javed, A., Akram, U., & Mahmood, M. T. (2019). Diabetic retinopathy detection through novel tetragonal local octa patterns and extreme learning machines. *Artificial Intelligence in Medicine*, 99, 101695, 1-10.
- Nneji GU, Cai J, Deng J, Monday HN, Hossin MA, Nahar S. Identification of Diabetic Retinopathy Using Weighted Fusion Deep Learning Based on Dual-Channel Fundus Scans. *Diagnostics*. 2022; 12(2):540. <https://doi.org/10.3390/diagnostics12020540>
- Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Trans. Syst. Man Cybern.*, 9, 62-66.
- Özçelik, Y. B., & Altan, A. (2021). Diyabetik Retinopati Teşhisi için Fundus Görüntülerinin Derin Öğrenme Tabanlı Sınıflandırılması. *Avrupa Bilim Ve Teknoloji Dergisi*(29), 156-167. <https://doi.org/10.31590/ejosat.1011806>
- Pan, S.J., & Yang, Q. (2010). A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22, 1345-1359.
- Pizer, S.M., Amburn, E.P., Austin, J.D., Cromartie, R., Geselowitz, A., Greer, T., Romeny, B.M., & Zimmerman, J.B. (1987). Adaptive histogram equalization and its variations. *Graphical Models Vgraphical Models and Image Processing Vcomputer Vision, Graphics, and Image Processing*, 39, 355-368.
- Polater, S. N., & Isık, A. H. (2024). Diyabetik Retinopati Tespiti İçin Derin Öğrenmeye Dayalı Sınıflandırma. *Uluborlu Mesleki Bilimler Dergisi*, 7(2), 13-19. <https://doi.org/10.46236/umbd.1426129>

- Pratt, H., Coenen, F., Broadbent, D. M., Harding, S. P., & Zheng, Y. (2016). Convolutional Neural Networks for Diabetic Retinopathy. *Procedia Computer Science*, 90(July), 200–205. <https://doi.org/10.1016/j.procs.2016.07.014>
- Quelleg G, Charrière K, Boudi Y, Cochener B, Lamard M. Deep image mining for diabetic retinopathy screening. *Med Image Anal.* 2017 Jul;39:178-193. doi: 10.1016/j.media.2017.04.012. Epub 2017 Apr 28. PMID: 28511066.
- Qummar, S., Khan, F. G., Shah, S., Khan, A., Shamshirband, S., Rehman, Z. U., Khan, I. A., & Jadoon, W. (2019). A Deep Learning Ensemble Approach for Diabetic Retinopathy Detection. *IEEE Access*, 7. <https://doi.org/10.1109/ACCESS.2019.2947484>
- Saeedi, P., Petersohn, I., Salpea, P., Malanda, B., Karuranga, S., Unwin, N., Colagiuri, S., Guariguata, L., Motala, A. A., Ogurtsova, K., Shaw, J. E., Bright, D., Williams, R., & IDF Diabetes Atlas Committee. (2019). Global and regional diabetes prevalence estimates for 2019 and projections for 2030 and 2045: results from the international diabetes federation diabetes atlas. *Diabetes Research and Clinical Practice*, 157, 107843, 1-10.
- Sahlsten J, Jaskari J, Kivinen J, Turunen L, Jaanio E, Hietala K, Kaski K. Deep learning fundus image analysis for diabetic retinopathy and macular edema grading. *Scientific reports* 2019; 9: 1–11.
- Scherer, D., Müller, A.C., & Behnke, S. (2010). Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition. *International Conference on Artificial Neural Networks*.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117.
- Shahin, E.M., Taha, T.E., Al-Nuaimy, W., Rabaie, S.E., Zahran, O., & El-Samie, F.E. (2012). Automated detection of diabetic retinopathy in blurred digital fundus

- images. *2012 8th International Computer Engineering Conference (ICENCO)*, 20-25.
- Shanthi, T., & Sabeenian, R. S. (2019). Modified Alexnet architecture for classification of diabetic retinopathy images. *Computers and Electrical Engineering*, 76. <https://doi.org/10.1016/j.compeleceng.2019.03.004>
- Shin HC, Roth HR, Gao M, Lu L, Xu Z, Nogues I, Yao J, Mollura D, Summers RM. Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. *IEEE Trans Med Imaging*. 2016 May;35(5):1285-98. doi: 10.1109/TMI.2016.2528162. Epub 2016 Feb 11. PMID: 26886976; PMCID: PMC4890616.
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *CoRR*, *abs/1409.1556*.
- Smith, S.M., & Brady, M. (1997). SUSAN—A New Approach to Low Level Image Processing. *International Journal of Computer Vision*, 23, 45-78.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Inf. Process. Manag.*, 45, 427-437.
- Srivastava, N., Hinton, G.E., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.*, 15, 1929-1958.
- Tan, M., & Le, Q.V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *ArXiv*, *abs/1905.11946*.
- Ting DSW, Cheung CY, Lim G, Tan GSW, Quang ND, Gan A, Hamzah H, Garcia-Franco R, San Yeo IY, Lee SY, Wong EYM, Sabanayagam C, Baskaran M, Ibrahim F, Tan NC, Finkelstein EA, Lamoureux EL, Wong IY, Bressler NM, Sivaprasad S, Varma R, Jonas JB, He MG, Cheng CY, Cheung GCM, Aung T, Hsu W, Lee ML, Wong TY. Development and Validation of a Deep Learning System for Diabetic

Retinopathy and Related Eye Diseases Using Retinal Images From Multiethnic Populations With Diabetes. JAMA. 2017 Dec 12;318(22):2211-2223. doi: 10.1001/jama.2017.18152. PMID: 29234807; PMCID: PMC5820739.

Turing, A. M. (1950). Computing Machinery and Intelligence. Mind, 59(236), 433-460.

Tuzcuoğlu, İ., Öztürk, H., & Yılmaz, A. (2019). Obezite ve Tip 2 Diyabet İlişkisi. Journal of Endocrinology and Metabolism, 8(2), 35-42.

Ünsal, G., & Karaoğlu Yılmaz, F. G. (2024). Eğitimde Yapay Zekâ ve Derin Öğrenme Alanında 2019-2023 Yıllar Arasında Yayınlanan Makalelerin Betimsel Analizi. Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi, 8(2), 177-197. <https://doi.org/10.31200/makuubd.1459260>

Ünsal, H (2024). “Yapay Zekâ Ve Yapay Zekânın Eğitimin Geleceğine İlişkin Olası Doğurguları”, Journal of Social, Humanities and Administrative Sciences, 10(5): 674-682. DOI: <https://doi.org/10.5281/zenodo.13851822>

Waheed A, Waheed Z, Usman Akram M, Shaukat A. Removal of false blood vessels using shape based features and image inpainting. Journal of Sensors 2015.

Welikala RA, Dehmeshki J, Hoppe A, Tah V, Mann S, Williamson TH. Automated detection of proliferative diabetic retinopathy using a modified line operator and dual classification. Computer methods and programs in biomedicine 2014; 114(3): 247-261

World Health Organization (WHO). (2021). Global report on diabetes.

Varshney, P. (2024). VGG16 mimarisi. <https://www.kaggle.com/code/blurredmachine/vggnet-16-architecture-a-complete-guide>

- Yamashita, R., Nishio, M., Do, R.K.G. et al. Convolutional neural networks: an overview and application in radiology. *Insights Imaging* 9, 611–629 (2018). <https://doi.org/10.1007/s13244-018-0639-9>
- Yani, M., Budhi Irawan, S.S., & Casi Setiningsih, S.M. (2019). Application of Transfer Learning Using Convolutional Neural Network Method for Early Detection of Terry's Nail. *Journal of Physics: Conference Series*, 1201.
- Yanoff, M., & Duker, J. S. (2009). *Ophthalmology*. Elsevier.
- Yalcin, N., Alver, S., & Uluhaturun, N. (2018). Classification of retinal images with deep learning for early detection of diabetic retinopathy disease. 26th IEEE Signal Processing and Communications Applications Conference, SIU 2018.
- Zhang X, Thibault G, Decenci re E, Marcotegui B, La  B, Danno R. Exudate detection in color retinal images for mass screening of diabetic retinopathy. *Medical image analysis* 2014; 18(7): 1026-1043.
- Zuiderveld, K.J. (1994). Contrast Limited Adaptive Histogram Equalization. *Graphics gems*.