



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

YAPAY ZEKA İLE DİYABETİK RETİNOPATİ TESPİTİ

YÜKSEK LİSANS TEZİ

Ravan JARJANAZI

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı

OCAK 2025

**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

YAPAY ZEKA İLE DİYABETİK RETİNOPATİ TESPİTİ

YÜKSEK LİSANS TEZİ

Ravan JARJANAZI
(22435004033)
ORCID: 0009-0009-3300-9291

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı

Danışman: Prof. Dr. Haydar ÖZKAN
ORCID: 0000-0002-7528-8091

OCAK 2025



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Ravan JARJANAZI

İmzası:

X X X X X



Eşime ve çocuklarıma,

ÖNSÖZ

Bu tez çalışmamda; bana destekleri için danışman hocam Prof. Dr. Haydar ÖZKAN'a ve eğitim hayatım boyunca desteklerini esirgemeyen aileme sonsuz teşekkürlerimi sunuyorum.

Ocak 2025

Ravan JARJANAZI



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	viii
KISALTMALAR	x
SEMBOLLER	xii
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xiv
ÖZET.....	xv
SUMMARY	xvi
1. GİRİŞ	1
1.1 Tezin Amacı	2
1.2 Tezin Katkısı	3
1.3 Literatür Araştırması	4
2. DİYABETİK RETINOPATİ (DR).....	15
2.1 Diyabetik Retinopati ve Lezyonlar	16
2.1.1 Lezyon tipleri	16
2.1.1.1 Mikro anevrizmalar (MA).....	16
2.1.1.2 Kanamalar (HM)	17
2.1.1.3 Sert eksüdalar (EX)	17
2.1.1.4 Yumuşak eksüdalar	18
2.2 Diyabetik Retinopati Derecelendirme Sistemi	18
2.3 Derecelendirme Kriterleri	19
3. DERİN ÖĞRENME ESASLARI.....	20
3.1 Transfer Öğrenme	21
3.2 Evrişimli Sinir Ağları (CNN).....	23
3.3 Eğitim Süreci ve Optimizasyon Algoritmaları	26
3.4 Performans Ölçütleri ve Değerlendirme.....	26
3.5 Derin Öğrenmenin Avantajları ve Zorlukları.....	26
3.6 VGG16 ve VGG19	26
3.7 Xception	27
3.8 InceptionV3	28
3.9 ResNet50	29
4. MATERYAL VE METOT	30
4.1 Dataset Tanımı ve Yapısı	31
4.2 Yazılımda Kullanılan Kütüphaneler.....	33
4.3 Görüntü İşleme ve Ön İşleme Teknikleri	34
4.3.1 Histogram eşitleme	34
4.3.2 CLAHE (Contrast limited adaptive histogram equalization).....	35
4.3.3 Gaussian blur.....	36
4.4 Normalizasyon	36
4.5 Veri Çoğaltma (Augmentation).....	37

4.6 Model Parametreleri	38
4.6.1 Öğrenme oranı (Learning rate)	38
4.6.2 Optimizasyon algoritması (Optimization algorithm)	39
4.6.2.1 Adam optimizasyonu (Adam optimization)	39
4.6.3 Epoch sayısı (Number of epochs)	39
4.6.4 Batch boyutu (Batch size)	40
4.6.5 Filtre boyutları (Filter sizes)	40
4.6.6 Aktivasyon fonksiyonları	40
4.6.6.1 ReLU (Rectified linear unit):	40
4.6.6.2 Softmax	40
4.7 Değerlendirme Metrikleri	41
4.7.1 Doğruluk (Accuracy)	41
4.7.2 Hassasiyet (Precision)	41
4.7.3 Duyarlılık (Recall) yada elde etme oranı	42
4.7.4 F1 skoru	42
4.7.5 Karışıklık matrisi (Confusion matrix)	43
4.8 Kullanılan Modellerde Hiperparametre Seçimi	44
4.8.1 VGG16 ve VGG19 hiperparametre seçimi	44
4.8.2 ResNet50 hiperparametre seçimi	46
4.8.3 CNN hiperparametre seçimi	47
4.8.4 InceptionV3 hiperparametre seçimi	48
4.8.5 Xception hiperparametre seçimi	50
4.9 Eğitim Süreci ve Kıyaslama	51
4.10 Web Arayüzü Uygulaması	51
5. DENEYSEL SONUÇLAR	54
5.1 Önerilerin Eğitim Senaryoları	57
5.2 VGG-16 Eğitiminin Sonuçları	58
5.3 VGG-19 Eğitiminin Sonuçları	62
5.4 CNN Eğitiminin Sonuçları	66
5.5 Karışıklık Matrisi (Confusion Matrix)	69
5.6 Tahmin Sonuçlarının Görselleştirilmesi	72
6. SONUÇ	77
KAYNAKLAR	79
ÖZGEÇMİŞ	85

KISALTMALAR

Adam	: Adaptive Moment Estimation- Uyarlanabilir Anlık Moment Tahmini
AI	: Artificial Intelligence- Yapay Zekâ
ANN	: Artificial Neural Network- Yapay Sinir Ağı
AUC	: Area Under the Curve- Eğri Altındaki Alan
BT	: Information Technology- Bilgi Teknolojisi
CLAHE	: Contrast Limited Adaptive Histogram Equalization- Kontrast Sınırlı Adaptif Histogram Eşitleme
CNN	: Convolutional Neural Network- Konvolüsyonel Sinir Ağı
CPU	: Central Processing Unit- Merkezi İşlem Birimi
DenseNet	: Densely Connected Convolutional Networks- Yoğun Bağlantılı Konvolüsyonel Ağlar
DL	: Deep Learning- Derin Öğrenme
DME	: Diabetic Macular Edema- Diyabetik Maküler Ödem
DR	: Diabetic Retinopathy- Diyabetik Retinopati
EX	: Exudates- Eksüdalar
FN	: False Negative- Yanlış Negatifler
FP	: False Positives- Yanlış Pozitifler
GMM	: Gaussian Mixture Model- Gauss Karışım Modeli
GPU	: Graphics Processing Unit- Grafik İşlem Birimi
HM	: Hemorrhages- Kanamalar
HSV	: Hue, Saturation, Value- Renk Tonu, Doygunluk, Değer
InceptionV3	: Inception Version 3- Inception Versiyon 3
KNN	: K Nearest Neighbor- K En Yakın Komşu
LOOCV	: Leave-One-Out Cross-Validation- Birini Dışarda Bırakarak Çapraz Doğrulama
MA	: Microaneurysms- Mikroanevrizmalar
NPDR	: Non-Proliferative Diabetic Retinopathy- Proliferatif Olmayan Diyabetik Retinopati
PDR	: Proliferative Diabetic Retinopathy- Proliferatif Diyabetik Retinopati
ReLU	: Rectified Linear Unit- Dikleştirilen Doğrusal Birim
ResNet50	: Residual Network 50- Kalıntılı Ağ 50

RMSprop	: Root Mean Square Propagation- Karekök Ortalama Kare Yayılımı
ROC	: Receiver Operating Characteristic- Alıcı Çalışma Karakteristiği
ROI	: Return on Investment- Yatırımın Getirisi
SDL	: Synergic Deep Learning- Sinerjik Derin Öğrenme
SGD	: Stochastic Gradient Descent- Stokastik Gradyan İnişi
SVM	: Support Vector Machine- Destek Vektör Makinesi
TN	: True Negative- Doğru Negatifler
TP	: True Positives- Doğru Pozitifler
VGG16	: Visual Geometry Group 16- Görsel Geometri Grubu 16
VGG19	: Visual Geometry Group 19- Görsel Geometri Grubu 19
Xception	: Extreme Inception- Aşırı İnception
XGBoost	: Extreme Gradient Boosting- Aşırı Gradyan Artırma

SEMBOLLER

τ	: Entegrasyon değişkenidir
$d\tau$	: Entegrasyonun değişkeni olan τ 'ya dair bir diferansiyeldir
$\int$	: İntegral sembolüdür



ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1 : Kullanılan veri kümesi örneklerine örnekler.....	32
Çizelge 4.2 : VGG16 ve VGG19 hiperparametre seçimi.	45
Çizelge 4.3 : ResNet50 hiperparametreler seçimi.	46
Çizelge 4.4 : CNN hiperparametre seçimi.	47
Çizelge 4.5 : InceptionV3 hiperparametre seçimi.	49
Çizelge 4.6 : Xception hiperparametre seçimi.....	50
Çizelge 5.1 : Deneysel sonuçlar.....	56
Çizelge 5.2 : Modelin mimarisi	58
Çizelge 5.3 : VGG-16 test sonuçları.....	60
Çizelge 5.4 : VGG-16+CLAHE test sonuçları.	61
Çizelge 5.5 : Model özellikleri.	62
Çizelge 5.6 : VGG-19 test sonuçları.....	63
Çizelge 5.7 : VGG-19+CLAHE test sonuçları.	64
Çizelge 5.8 : CNN test sonuçları.	67
Çizelge 5.9 : CNN+CLAHE test sonuçları.....	68
Çizelge 5.10 : Diyabetik retinopati tespiti için derin öğrenme modelleri.....	75

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Lezyon tipleri (Albahli ve diğ, 2022).	16
Şekil 2.2 : MA diyabetik retinopatinin farklı türü (Aldujailı, 2023).	17
Şekil 2.3 : Diyabetik retinopatinin kanamalar.	17
Şekil 2.4 : Diyabetik retinopatinin sert eksüdalar (EX).	18
Şekil 2.5 : Diyabetik retinopatinin yumuşak eksüdalar (EX).	18
Şekil 2.6 : Diyabetik retinopati derecelendirme.	18
Şekil 3.1 : Derin öğrenme esasları.	21
Şekil 3.2 : Transfer öğrenme akışları.	23
Şekil 3.3 : Evrişimli sinir ağlarının mimarisi.	23
Şekil 3.4 : VGG16 ve VGG19 modeli.	27
Şekil 3.5 : Xception modeli (Larrikins ve diğ, 2019).	28
Şekil 3.6 : InceptionV3 modeli (Brital, 2023).	28
Şekil 3.7 : ResNet50 modeli (Suresh ve diğ, 2021).	29
Şekil 4.1 : Önerilen metodoloji.	31
Şekil 4.2 : Orijinal ve işlenmiş görüntülerin karşılaştırılması – histogram eşitleme.	35
Şekil 4.3 : Orijinal ve işlenmiş görüntülerin karşılaştırılması – CLAHE.	35
Şekil 4.4 : Orijinal ve işlenmiş görüntülerin karşılaştırılması – gaussian blur.	36
Şekil 4.5 : Karışıklık matrisi (Hossin ve diğ, 2015).	43
Şekil 5.1 : Sınıflandırmak için resim seçin.	54
Şekil 5.2 : Seçilen görüntüyü sınıflandırın ve doğruluğunu görüntüleyin.	55
Şekil 5.3 : Rapor çıktısı.	55
Şekil 5.4 : VGG16 modelinin eğitim ve doğrulama doğruluk eğrileri.	59
Şekil 5.5 : VGG16 modelinin eğitim ve doğrulama kayıp eğrileri.	59
Şekil 5.6 : Eğitim ve doğrulama kaybı eğrisi.	65
Şekil 5.7 : Eğitim ve doğrulama doğruluğu eğrisi.	65
Şekil 5.8 : VGG16 Karışıklık Matrisi.	69
Şekil 5.9 : VGG19 Karışıklık Matrisi.	70
Şekil 5.10 : CNN Karışıklık Matrisi.	71
Şekil 5.11 : Tahmin sonuçlarının görselleştirilmesi.	73

YAPAY ZEKA İLE DİYABETİK RETİNOPATİ TESPİTİ

ÖZET

Diyabetik retinopati (DR), diyabetin neden olduğu göz hastalıkları arasında en yaygın ve ciddi olanlardan biridir ve retinadaki kan damarlarında mikroanevrizma, kanama ve eksudalar gibi mikrovasküler anormalliklere yol açar. DR'nin erken teşhisi, tedavi sürecinde büyük bir öneme sahip olup, manuel tanı yöntemlerinin zorlukları göz önüne alındığında, bilgisayar destekli tanı sistemlerinin geliştirilmesi oldukça önem kazanmıştır. Bu çalışmada, DR teşhisinde otomatik görüntü sınıflandırma ve lezyon tespitine yönelik farklı derin öğrenme mimarilerinin performansları değerlendirilmiştir. İlk olarak fundus görüntüleri ön işlemlerle VGG16, VGG19, CNN, Xception, InceptionV3 ve ResNet50 modelleri ile DR sınıflandırmasına tabi tutulmuştur. Daha sonra görüntüler, CLAHE (Contrast Limited Adaptive Histogram Equalization) algoritması ile ön işlemden geçirilerek iyileştirilmiş ve yeniden DR sınıflandırması yapılarak tüm sonuçlar karşılaştırılmıştır. Görüntü ön işleme yöntemi olarak kullanılan CLAHE'nin, özellikle küçük lezyonların daha görünür hale getirilmesine katkı sağladığı ve sınıflandırma performansını belirgin şekilde artırdığı gözlemlenmiştir. Elde edilen sonuçlar arasında, VGG16-CLAHE ve CNN-CLAHE modellerinin %99 doğrulukla en yüksek performansı sağladığı belirlenmiştir. Ek olarak bu çalışmada geliştirilen VGG16-CLAHE tabanlı derin öğrenme modeli, kullanıcı dostu bir ara yüz uygulamasına entegre edilmiş ve gerçek zamanlı DR teşhisi yapabilme imkânı sağlanmıştır. Uygulama, DR'nin beş sınıfını (No DR, Mild NPDR, Moderate NPDR, Severe NPDR, PDR) başarılı bir şekilde ayırt edebilmektedir. Gelecekte daha geniş veri setleri ve farklı derin öğrenme mimarileri üzerinde çalışarak sistem performansının artırılacağı öngörülmektedir.

Anahtar kelimeler: Diyabetik retinopati, Derin öğrenme, Görüntü işleme, CLAHE, VGG16, CNN, Xception, InceptionV3, ResNet50.

DIABETIC RETINOPATHY DETECTION WITH ARTIFICIAL INTELLIGENCE

SUMMARY

Diabetic retinopathy (DR) is one of the most common and serious eye diseases caused by diabetes, leading to microvascular abnormalities in the retinal blood vessels such as microaneurysms, hemorrhages and exudates. Early diagnosis of DR is of great importance in the treatment process, and given the difficulties of manual diagnostic methods, the development of computer-aided diagnostic systems has become very important. In this study, we evaluate the performance of different deep learning architectures for automatic image classification and lesion detection in DR diagnosis. First, fundus images were subjected to DR classification with VGG16, VGG19, CNN, Xception, InceptionV3 and ResNet50 models without preprocessing. Then, the images were preprocessed and enhanced with the CLAHE (Contrast Limited Adaptive Histogram Equalization) algorithm and DR classification was performed again and all results were compared. It was observed that CLAHE, which was used as an image preprocessing method, contributed to making small lesions more visible and significantly improved the classification performance. Among the results obtained, VGG16-CLAHE and CNN-CLAHE models were found to provide the highest performance with 99% accuracy. In addition, the VGG16-CLAHE-based deep learning model developed in this study was integrated into a user-friendly interface application, enabling real-time DR diagnosis. The application can successfully distinguish five classes of DR (No DR, Mild NPDR, Moderate NPDR, Severe NPDR, PDR). It is envisaged that system performance can be improved by working on larger data sets and different deep learning architectures in the future.

Keywords: Diabetic retinopathy, Deep learning, Image processing, CLAHE, VGG16, CNN, Xception, InceptionV3, ResNet50.

1. GİRİŞ

Diyabetik retinopati (DR), diyabetin görme sistemi üzerinde uzun vadeli olumsuz etkiler yaratan ve tüm dünyada giderek artan görme kaybı risklerinin önde gelen nedenlerinden biri olan kronik bir göz hastalığıdır. DR, gözün arkasındaki retina tabakasında kan damarlarının zayıflaması, anormal yeni damar oluşumu ve eksudalar gibi çeşitli lezyonlarla karakterize edilir. Bu durum, zamanında teşhis edilmez ve kontrol altına alınmazsa geri döndürülemez görme kayıplarına yol açabilir (Chen ve diğ, 2018) .

Günümüzde diyabet oranlarının küresel olarak yükselmesi, DR vakalarının da artmasına neden olmakta; bu da DR'nin doğru ve hızlı teşhisi için gelişmiş, ölçeklenebilir teknolojilere olan ihtiyacı ön plana çıkarmaktadır.

DR teşhisi için geleneksel yöntemler, oftalmologlar tarafından gerçekleştirilen manuel incelemelere dayanır. Ancak bu yöntemler zaman alıcıdır, insan gözlemine dayandığı için hata oranı yüksektir ve büyük miktarlardaki verinin işlenmesi için yetersiz kalmaktadır (Michael ve diğ, 2010). Bu kısıtlamalar, özellikle erken teşhis ve önleme stratejilerinde etkili sonuçlar elde edilebilmesini zorlaştırmaktadır. Bilgisayar destekli tanı sistemlerinin gelişimiyle birlikte, yapay zekâ ve derin öğrenme tabanlı teknikler, DR teşhisinde yeni bir dönemin kapılarını aralamıştır. Evrişimli Sinir Ağları (CNN), retina görüntülerindeki detayları algılayarak mikroanevrizma, kanama ve eksudalar gibi lezyonları belirleyebilme yeteneği ile ön plana çıkmaktadır (Gulshan ve diğ, 2016). Bu tür derin öğrenme modelleri, yüksek doğruluk oranlarıyla erken teşhis ve hastalığın ilerleme aşamasının belirlenmesine olanak tanımaktadır.

Bu çalışmada, diyabetik retinopati görüntülerinin sınıflandırılması için derin öğrenme modellerinin uygulanabilirliği incelenmiştir. Kullanılan modeller arasında VGG16, VGG19, Xception, InceptionV3, ResNet50 ve temel CNN mimarisi yer almaktadır. Bu modellerin her biri, retina görüntülerindeki ince yapısal farklılıkları algılayarak DR teşhis sürecine katkı sağlamaktadır. Bununla birlikte, düşük kontrast ve görüntü kalitesi nedeniyle küçük lezyonların belirginleştirilmesi, bu modellerin başarısını artırmada önemli bir faktör olarak karşımıza çıkmaktadır (Liu ve diğ, 2019). Bu

bağlamda, Contrast Limited Adaptive Histogram Equalization (CLAHE) gibi ön işleme teknikleri kullanılarak görüntü kontrastının artırılması ve bu lezyonların daha görünür hale getirilmesi hedeflenmiştir.

Çalışmamızda, CLAHE ön işleme yönteminin uygulanması ile lezyonları daha belirgin hale getirilmiş görüntüler üzerinde derin öğrenme modelleri eğitilmiştir. Eğitim süreci sonucunda elde edilen doğruluk oranları incelendiğinde, CLAHE uygulaması yapılan veri setleri üzerinde elde edilen sonuçların, orijinal veri setleri üzerinde yapılan modellere kıyasla daha başarılı olduğu gözlemlenmiştir. Özellikle VGG16, CNN gibi modellerde, CLAHE'nin uygulanması ile yaklaşık %99 gibi yüksek doğruluk oranlarına ulaşılmıştır. Bu sonuçlar, kontrast artırma yöntemlerinin DR teşhis modellerinin doğruluğunu artırmada önemli bir rol oynadığını ortaya koymaktadır (Ali ve diğ, 2022).

Bu tez çalışması, farklı derin öğrenme algoritmalarının DR teşhisinde uygulanabilirliğini karşılaştırarak, yapay zekâ temelli bir teşhis sisteminin potansiyel etkinliğini analiz etmektedir. Aynı zamanda, kontrast artırma gibi ön işleme tekniklerinin model performansına etkisi incelenerek, DR gibi kronik göz hastalıklarının teşhisinde ölçeklenebilir ve güvenilir bir model önerilmektedir. Ayrıca Bu çalışma, bir ara yüze entegre edilmiş derin öğrenme modeli ile klinik uygulamada kullanılabilecek hale getirilmiştir. Bu uygulamanın gelecekte hastane PACS sistemine entegrasyonu gerçekleştirilirse çekilen göz fundus görüntülerinin hızlıca analizi ve sınıflandırılması ile DR teşhisinin kolayca gerçekleştirilebileceği düşünülmektedir.

1.1 Tezin Amacı

Diyabetik Retinopati (DR), özellikle ileri aşamalarda kalıcı görme kaybına yol açabilen ve yaygın diyabet vakaları nedeniyle global ölçekte halk sağlığı açısından önemli riskler barındıran bir göz hastalığıdır. DR'nin erken aşamada tespiti, ilerlemesinin önlenmesi açısından büyük bir önem taşımaktadır. Ancak geleneksel tanı yöntemleri, zaman ve uzmanlık gerektirmesi sebebiyle geniş hasta popülasyonları için etkili çözümler sunmakta yetersiz kalmaktadır. Bu tez çalışmasının amacı, DR tespiti için yüksek doğruluk oranlarına ulaşan, aynı zamanda ölçeklenebilir ve güvenilir derin öğrenme modellerini kullanarak yeni bir yaklaşım geliştirmektir. Bu kapsamda, çalışma hem yüksek doğruluk oranına sahip yapay zekâ (AI) tabanlı tanı sistemleri kurmayı hem de bu sistemleri kullanıcı dostu bir uygulama aracılığıyla erişilebilir hale

getirmeyi hedeflemektedir. Çalışmada, VGG16, VGG19, Xception, InceptionV3, ResNet50 ve özel olarak tasarlanmış bir CNN mimarisinin performansları karşılaştırılmıştır. Aynı zamanda, DR görüntülerinde lezyonların (mikroanevrizma, kanama, eksudalar) daha belirgin hale getirilmesi için kontrast sınırlamalı adaptif histogram eşitleme (CLAHE) gibi ön işleme teknikleri uygulanarak model performanslarının iyileştirilmesi amaçlanmıştır. Bu süreçte, CLAHE yöntemiyle ön işleme yapılan ve yapılmayan veri setleri üzerinde derin öğrenme modelleri eğitilmiş, bu yöntemle lezyon tespitine olan katkı analiz edilmiştir. Çalışmada geliştirilen sistem, gerçek zamanlı DR tespiti yapabilen ve yüksek doğruluk oranlarına ulaşan bir uygulama olarak tasarlanmıştır. Kullanıcı dostu bir arayüz (Streamlit) ile desteklenen bu uygulama, hem Türkçe hem de İngilizce dil seçenekleri sunarak geniş bir kullanıcı kitlesine hitap etmektedir. Uygulama ayrıca, teşhis sonuçlarını bir PDF raporu olarak sunabilmekte, bu rapor ile doktorların hastalarını daha iyi değerlendirmelerine katkıda bulunmaktadır. Tezde kullanılan farklı derin öğrenme algoritmalarının performansları doğru tanı oranları açısından kıyaslanarak en başarılı sonuçları veren model veya modeller tespit edilmiştir. Çalışmanın nihai hedefi, DR teşhis sürecinde kullanılabilir, doğruluğu yüksek ve uygulama maliyeti düşük bir model önerisinde bulunarak, klinik uygulamalarda yapay zekâ tabanlı tanı sistemlerinin rolünü güçlendirmektir. Bu kapsamda geliştirilen sistem, klinik ortamda DR tanısının etkinliğini ve hızını artırarak, hastaların tedaviye daha erken yönlendirilmesine katkı sağlamayı amaçlamaktadır.

1.2 Tezin Katkısı

Bu tez çalışması, diyabetik retinopati (DR) tespitinde doğruluğu yüksek ve ölçeklenebilir bir yapay zekâ tabanlı sistem sunarak, DR tanısının hızını ve etkinliğini artırmayı amaçlayan yenilikçi bir yaklaşım önermektedir. Çalışmanın en önemli katkılarından biri, DR lezyonlarını daha belirgin hale getirmek için kullanılan kontrast sınırlamalı adaptif histogram eşitleme (CLAHE) gibi görüntü işleme tekniklerinin, çeşitli derin öğrenme algoritmalarıyla bir arada test edilerek tespit performansının iyileştirilmesidir. Bu amaçla, VGG16, VGG19, Xception, InceptionV3, ResNet50 ve özel olarak geliştirilmiş bir CNN modelinin yanı sıra, her modelin CLAHE ön işlemi uygulanmış veri setleri üzerindeki performansı incelenmiştir. Bu detaylı karşılaştırma sayesinde, farklı derin öğrenme mimarilerinin DR görüntülerinde mikroanevrizma,

kanama ve eksudaları tespit etme başarımları değerlendirilmiştir. Çalışmada ayrıca, kullanıcı dostu bir arayüz ile desteklenmiş, gerçek zamanlı DR tespiti yapabilen bir uygulama geliştirilmiştir. Streamlit kullanılarak oluşturulan bu uygulama hem Türkçe hem de İngilizce dil seçenekleriyle kullanıcıların erişimini kolaylaştırmakta ve hastalık tespit sürecini pratik hale getirmektedir. Uygulama, DR sınıflandırma sonuçlarını detaylı bir PDF raporu halinde sunarak doktorlara ve hastalara esneklik sağlamaktadır. Bu rapor, hastanın fundus görüntüsü, tespit edilen DR seviyesi, model doğruluğu ve tarih gibi bilgileri içermekte, ayrıca çalışmanın Bursa Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü'ne ait olduğunu gösteren bir logo ile desteklenmektedir. Bu çalışmada, CLAHE gibi ön işleme tekniklerinin DR görüntülerinde hassasiyeti artırıcı etkisi göz önüne alınarak, model doğruluğunu artırmaya yönelik önemli bir adım atılmıştır. Bu sayede, geleneksel görüntü işleme yöntemlerinin ve derin öğrenme algoritmalarının bir arada kullanımının, DR tanı süreçlerinde yüksek doğruluk ve güvenilirlik sağladığı ortaya konmuştur. Model performansları kıyaslandığında, CLAHE kullanılarak işlenmiş veri setleri üzerinde %99 doğruluk oranıyla en iyi sonuçların elde edildiği gözlemlenmiştir. Tez çalışması, hem klinik tanıda kullanılabilir yapay zeka tabanlı sistemlerin geliştirilmesine yönelik katkılar sunmakta hem de DR tanısında yüksek başarı oranlarına ulaşarak mevcut teşhis yöntemlerine hız ve verimlilik kazandırmaktadır. Bu bağlamda, geliştirilen sistemin düşük maliyetli bir çözüm olarak yaygın bir uygulama potansiyeline sahip olduğu ve DR gibi halk sağlığı açısından önemli hastalıkların erken tanısında klinik verimliliği artırabileceği öngörülmektedir. Bu çalışma, DR teşhisinde yapay zeka ve görüntü işleme teknolojilerinin entegrasyonu konusunda literatüre ve uygulamalı sağlık teknolojilerine önemli bir katkı sunmakta, aynı zamanda hem araştırmacılar hem de sağlık profesyonelleri için referans niteliğinde bir kaynak oluşturmaktadır.

1.3 Literatür Araştırması

Diyabetik retinopati (DR) tespiti, son yıllarda derin öğrenme yöntemlerinin sağladığı önemli gelişmelerle birlikte büyük bir ilerleme kaydetmiştir. Özellikle konvolüsyonel sinir ağları (CNN), retinal görüntülerdeki lezyonları otomatik olarak tanımlama konusunda yüksek bir başarı göstermektedir. Bu yöntemler, görüntülerin doğrudan işlenmesi ile patolojik değişikliklerin tespitini sağlar ve geleneksel yöntemlere göre daha yüksek doğruluk oranları sunar. CNN'ler, katmanlı yapıları sayesinde karmaşık

özellikleri öğrenerek görüntülerin detaylarını derinlemesine analiz edebilmekte, böylece mikroanevrizmalar, hemorajiler ve eksudatlar gibi önemli lezyonları daha etkin bir şekilde ortaya çıkarabilmektedir. Ayrıca, bu teknolojilerin kullanımı, tanı süreçlerini hızlandırarak hekimlerin iş yükünü azaltmakta ve hastaların erken tedavi edilmelerini sağlamaktadır. Günümüzde, birçok araştırma ve uygulama, derin öğrenme algoritmalarının DR tespiti için entegrasyonunu incelemekte ve bu alanın daha da ileriye taşınması adına çeşitli stratejiler geliştirmektedir. Bununla birlikte, CNN tabanlı yaklaşımların, büyük veri kümeleri ile beslenmesi ve sürekli olarak güncellenmesi, model performansını artırmakta ve daha güvenilir sonuçlar elde edilmesini sağlamaktadır. Bu bağlamda, derin öğrenme tekniklerinin, tıbbi görüntüleme alanındaki dönüşümü ve hastalıkların tespitindeki rolü, özellikle diyabetik retinopati gibi yaygın ve ciddi hastalıkların yönetiminde kritik bir öneme sahiptir. Sonuç olarak, bu yenilikçi yöntemler, hem klinik pratikte hem de araştırmalarda etkili bir araç olarak kullanılmakta ve gelecekteki sağlık hizmetlerinin şekillenmesinde önemli bir katkı sağlamaktadır.

Özçelik ve diğ. (2021), yaptıkları çalışmalarında, diyabetik retinopati (DR) hastalığının erken teşhisi için fundus görüntüleri kullanılarak derin öğrenme tabanlı bir model geliştirilmiştir. Model, aşırı öğrenmeyi önlemek için görüntülere iki boyutlu sinyal işleme teknikleri uygulanarak oluşturulmuştur. Eğitimi 5100 fundus görüntüsüyle gerçekleştirilen model, 900 test görüntüsü üzerinden beş sınıfı (sağlıklı, hafif NPDR, orta NPDR, şiddetli NPDR ve PDR) sınıflandırmakta ve %97,8 başarı oranı elde etmiştir. VGG-19 mimarisi kullanılarak geliştirilen modelin performansı, doğruluk er metriklerle ölçülmüştür. Sonuçlar, modelin DR teşhisinde oldukça etkili olduğunu göstermektedir.

Aykat ve Senan (2023), yaptıkları çalışmalarında, retina hastalıklarını tespit etmek için IDRID (The Indian diabetic retinopathy image), ODIR (Ocular Disease Intelligent Recognition) ve HRF (High-Resolution Fundus) veri setlerinden fundus görüntüleri alınarak oluşturulmuş olan Kaggle veri seti kullanılmıştır. Bu veri seti sağlıklı bireyler ile diyabetik retinopati ve katarakt hastalarının fundus görüntülerinden oluşmaktadır. Çalışmada ilk önce Kaggle veri seti üzerinde histogram eşitleme yöntemi uygulanarak ön işlenmiş bir veri seti oluşturulmuştur. Ardından RestNet50, InceptionV3, MobileNet, Xception ve EffcientNetV2S geleneksel derin öğrenme modellerinin hiperparametre ayarı yapılarak veri setleri üzerinde eğitimler gerçekleştirilmiştir. Son

olarak veri setleri üzerinde en yüksek başarıya sahip MobileNet tabanlı bir hibrit model geliştirilmiştir. Önerilen hibrit model, ön işlenmiş veri seti üzerinde %99 doğruluk oranı elde etmiştir. Hibrit modelin sınıflandırma başarısının ele alınan derin öğrenme modellerinin başarısından daha yüksek olduğu görülmüştür.

Deperlioğlu ve Köse (2018), çalışmalarında, diyabetik retinopati teşhisi için retinal fundus görüntülerinde görüntü işleme teknikleri ile derin öğrenme yöntemlerini bir arada kullanmışlardır. Görüntülerin iyileştirilmesi için HSV dönüşümü, V dönüşümü algoritması ve histogram eşitleme gibi pratik yöntemler kullanılmıştır. Ardından, retinal fundus görüntülerine Gauss alçak geçiren filtre uygulanmıştır. Görüntü işleme adımlarının ardından, Sınıflandırma Evrişimsel Sinir Ağı (CNN) kullanılarak teşhis yapılmıştır. Önerilen yöntemin performansı, Kaggle Diyabetik Retinopati Tespiti veri tabanındaki 400 retinal fundus görüntüsü kullanılarak değerlendirilmiştir. Her görüntü işleme adımı için sınıflandırma çalışmaları yapılmış ve her aşama için ortalama değerler alınmıştır. Çalışmanın sonuçlarına göre, doğruluk %96,67, duyarlılık %93,33, özgüllük %97,78, hassasiyet ve hatırlama %93,33, F skoru %93,33 olarak bulunmuştur. Elde edilen sonuçlar, önerilen yöntemin, retina fundus görüntülerinden diyabetik retinopatiyi teşhis etmek için çok etkili ve başarılı olduğunu göstermektedir. Bu yöntem, diyabetik retinopati teşhisinde yüksek doğruluk ve güvenilirlik sağlamaktadır.

Akram ve diğ. (2013), yaptıkları çalışmada, diyabetik retinopati (DR) teşhisi için önerilen hibrit sınıflandırıcı ile mikroanevrizmalar, kanamalar ve eksudalar gibi DR lezyonlarının erken ve doğru teşhisini sağlamışlardır. Sistem; ön işleme, aday lezyon çıkarımı, özellik seti oluşturulması ve sınıflandırma aşamalarından oluşur. Dijital retina görüntülerinde, arka plan pikselleri ve kan damarları ile optik disk belirginleştirilerek lezyon adayları belirlenir. Her aday bölge için şekil, yoğunluk ve istatistik gibi özelliklere dayalı bir özellik seti oluşturulmuş ve bu veriler, m-Mediods ve Gauss Karışım Modeli (GMM) ile hibrit sınıflandırıcıya aktarılmıştır. Çalışmanın sonucunda, önerilen sistemin %94,6 doğruluk oranına ulaştığı tespit edilmiştir. Hassasiyet ve özgüllük oranları ise sırasıyla %92,3 ve %95,1 olarak ölçülmüştür. Bu yüksek performans değerleri, yöntemin diyabetik retinopati lezyonlarının tanımlanmasında oldukça etkili olduğunu göstermektedir. ROC eğrisi analizleri de yöntemin güçlü bir istatistiksel doğruluğa sahip olduğunu kanıtlamıştır.

Tsiknakis ve diğ. (2021), yaptıkları çalışmalarında, diyabetik retinopati teşhisi için Convolutional Neural Networks (CNN) ve Artificial Neural Networks (ANN) gibi derin öğrenme yöntemlerini kullanmışlardır. Makalede, fundus görüntüleri üzerinde gerçekleştirilen testlerle bu iki yöntemin diyabetik retinopati evreleme sürecindeki etkinliği değerlendirilmiş ve modelin %95,75 doğruluk oranına ulaştığı belirtilmiştir. Bu çalışma, derin öğrenme tekniklerinin DR teşhisindeki yüksek başarısını ortaya koyarken, aynı zamanda klinik uygulamalarda potansiyel olarak daha güvenilir sonuçlar elde edilebileceğini vurgulamaktadır.

Shankar ve diğ. (2020), yaptıkları çalışmalarında, diyabetik retinopati (DR) teşhisi için ön işleme, segmentasyon ve derin öğrenme aşamalarını içeren bir model geliştirmişlerdir. İlk olarak, ön işleme aşamasında fundus görüntülerinden kenarlardaki gürültü kaldırılmış, ardından histogram tabanlı segmentasyon tekniği ile yararlı bölgeler ayrıştırılmıştır. Modelin sınıflandırma aşamasında Synergic Deep Learning (SDL) modeli kullanılarak, DR'nin farklı şiddet seviyeleri başarıyla sınıflandırılmıştır. Model doğruluk (Accuracy) %99,28, duyarlılık (Sensitivity) %98,54, ve özgünlük (Specificity) %99,38 gibi yüksek performans oranları sunarak DR tespiti için etkili bir yöntem olduğunu göstermiştir. Bu sonuçlar, SDL modelinin hassas sınıflandırma yeteneği ile DR teşhisinde güvenilir bir seçenek olduğunu ortaya koymaktadır.

Ramaha ve Al-Dujaili (2023), yaptıkları çalışmada, makine öğrenimi ve derin öğrenme yöntemlerinin diyabetik retinopati (DR) teşhisindeki başarıları incelenmişlerdir. Makine öğrenimi için SVM, Karar Ağaçları, Naïve Bayes, Yapay Sinir Ağları, lojistik regresyon, XGBoost ve K-en yakın komşu gibi algoritmalar test edilmiştir. Çalışmanın sonuçlarına göre, bu makine öğrenimi yöntemleri belirli başarı oranları elde etmiş, ancak derin öğrenme modellerine göre daha düşük performans göstermiştir. Derin öğrenme yaklaşımı ise CNN ve RNN gibi ağları kullanarak %92,7 doğruluk, %94 hassasiyet, %91 özgüllük oranları ile üstün bir performans sergilemiştir. Bu sonuçlar, derin öğrenmenin özellik çıkarımı ve sınıflandırma süreçlerinde makine öğrenimine göre daha etkili olduğunu ve DR teşhisinde daha yüksek doğruluk oranları sunduğunu ortaya koymaktadır. Bu nedenle, çalışmada DR teşhisi için derin öğrenme yöntemlerinin kullanımının geleneksel makine öğreniminden daha başarılı olabileceği belirtilmiştir.

Han ve diğ. (2019), yaptıkları çalışmada, bilgisayarlı tomografi (BT) ile elde edilen görüntüler kullanılarak, renal hücreli karsinomun (açık hücreli, papiller ve kromofob) üç ana alt tipini ayırt etmek için görüntü tabanlı bir derin öğrenme çerçevesi kullanmışlardır. Biyopsi ile doğrulanmış bir karşılaştırma veri seti, 169 renal kanser vakasından oluşturulmuştur. Her vakada, görüntüler üç aşamada elde edilmiştir (aşama 1, kontrast ajanının enjeksiyonundan önce; aşama 2, enjeksiyondan 1 dakika sonra; aşama 3, enjeksiyondan 5 dakika sonra). Görüntü alımından sonra, her aşama görüntüsünde bir dikdörtgen ROI (ilgi alanı) radyologlar tarafından işaretlenmiştir. ROI'leri kırdıktan sonra, üç aşamalı ROI görüntülerine bir kombinasyon ağırlığı çarpılmış ve lineer olarak birleştirilmiş görüntüler, bir derin öğrenme sinir ağına girdi. Derin öğrenme sinir ağı, çizilen ROI'leri girdi olarak ve biyopsi sonuçlarını etiket olarak kullanarak renal hücreli karsinoma alt tiplerini sınıflandırmak için eğitildi. Ağ, yaklaşık %0,85 doğruluk, %0,64-0,98 duyarlılık, %0,83-0,93 özgüllük ve %0,9 AUC gösterdi. Radyologlar tarafından sağlanan ROI'ler ve derin öğrenme yöntemine dayalı önerilen çerçeve, renal hücreli karsinoma alt tip sınıflandırmasında umut verici sonuçlar göstermiştir. Bu çalışmanın bu konudaki gelecek araştırmalarına yardımcı olmasını ve gerçek klinik durumda lezyon alt tipini sınıflandırmada radyologlarla işbirliği yapmasını umuyoruz.

Omar ve diğ. (2017), yaptıkları çalışmada, diyabetik retinopatinin (DR), Malezya'da çalışma çağındaki yetişkinler arasında en yaygın körlük nedeni olan diyabet kaynaklı bir göz hastalığı olduğunu belirtmişlerdir. Şu ana kadar, yetersiz güvenilir otomatik DR tespit sistemleri nedeniyle DR hala oftalmologlar tarafından fundus görüntüleri kullanılarak manuel olarak taranmaktadır. Ancak, manuel tarama süreci karmaşık ve zaman alıcı bir süreç olduğundan en zayıf halka olarak kabul edilmektedir. Bu nedenle, bu çalışmada mevcut sistemlerin doğruluğunu artırmayı amaçlayan bir DR tespit yöntemi içeren bir algoritma önerilmiştir. DR özelliklerini, yani eksudatlar, kanamalar ve kan damarlarını tespit etmek için kullanılan yöntemler, görüntü ön işleme, damar ve kanama tespiti, optik disk çıkarımı ve eksudat tespiti olmak üzere birkaç aşamaya ayrılabilir. Ancak, kan damarı ve kanama tespiti benzer yoğunluk özelliklerinden dolayı eşzamanlı olarak gerçekleştirilmiştir. Önerilen algoritma sırasıyla 49 ve 89 fundus görüntüsü kullanılarak eğitilmiş ve test edilmiştir. Eğitimde kullanılan görüntüler Malezya, Hospital Serdang'dan elde edilmişken, testte kullanılan görüntüler DIARETDB1 veritabanından elde edilmiştir. Tüm görüntüler dört DR aşamasına, yani

hafif Non-Proliferatif Diabetic Retinopathy (NPDR), orta NPDR, şiddetli NPDR ve Proliferatif Diabetic Retinopathy (PDR) kategorize edilmiştir. Görüntüler çeşitli aydınlatma koşulları altında çekilmiştir. Testte, kan damarı ve kanamaların tespit oranının %98, eksudatların tespit oranının ise %100 olduğu görülmüştür.

Alver ve Yalçın (2018), yaptıkları çalışmada, diyabetik retinopatinin, diyabet hastalarında sık görülen ve görme kaybına neden olan bir komplikasyon olduğunu belirtmişlerdir. Erken teşhis, hastalığın ilerlemesini önlemek ve görme kaybını azaltmak için kritik öneme sahiptir. Bu çalışma, diyabetik retinopati hastalığının erken tespiti için derin öğrenme yöntemlerini kullanarak retina görüntülerinin sınıflandırılmasını amaçlamaktadır. İlk olarak, diyabetik retinopati verilerinden oluşan bir veri seti toplandı ve hazırlandı. Ardından, derin öğrenme modeli oluşturmak için evrişimli sinir ağı (CNN) mimarisi kullanıldı. Modelin eğitimi için diyabetik retinopati içeren görüntüler kullanıldı ve sınıflandırma yeteneğini artırmak için veri artırma teknikleri uygulandı. Eğitilmiş model, retina görüntülerini sağlıklı ve diyabetik retinopati içeren olmak üzere iki sınıfa sınıflandırdı. Modelin doğruluğu, hassasiyeti ve özgüllüğü test edilerek değerlendirildi ve diyabetik retinopati hastalığını erken teşhis etme yeteneği gösterildi. Sonuçlar, derin öğrenme yöntemlerinin diyabetik retinopati hastalığının erken teşhisi için etkili bir araç olabileceğini göstermektedir. Bu çalışma, diyabetik retinopati hastalığının erken teşhisi ve tedavisi için klinik uygulamalara değerli katkılar sağlayabilir.

Patel ve Sanskruti (2020), yaptığı çalışmasında, ön eğitilmiş Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN) kullanarak diyabetik retinopati tespiti ve sınıflandırmasını ele almaktadır. Diyabetik retinopati, diyabet hastalarında sık görülen ve görme kaybına neden olan ciddi bir göz hastalığıdır. Erken teşhis, hastalığın ilerlemesini önlemek ve etkili tedavi sağlamak için kritik öneme sahiptir. Bu amaçla, makalede önceden eğitilmiş CNN modelleri kullanılarak bir tespit ve sınıflandırma sistem geliştirilmiştir. Önceden eğitilmiş modeller, büyük miktarda genel görüntü verisi üzerinde eğitilmiş ve genellikle farklı görsel tanımlama görevleri için optimize edilmiştir. Geliştirilen sistem, diyabetik retinopatiyi tespit etmek ve farklı evrelerini sınıflandırmak için yüksek doğruluk sağlamıştır. Önceden eğitilmiş CNN modellerinin kullanımı, modelin genel performansını artırırken, aynı zamanda eğitim süresini de azaltarak pratik uygulamalarda daha etkili bir çözüm sunar. Sonuç olarak, bu çalışma diyabetik retinopati tespiti ve sınıflandırmasında önceden eğitilmiş CNN modellerinin

başarılı bir şekilde kullanılabilirliğini vurgulamaktadır. Bu yaklaşım, diyabetik retinopati teşhisi için otomatik ve etkili bir çözüm sunar, böylece hastaların erken teşhis edilmesine ve uygun tedaviye yönlendirilmesine yardımcı olabilir.

Ghosh ve diğ. (2017), yaptıkları çalışmalarında, Konvolüsyonel Sinir Ağları (CNN'ler) yaklaşımı, renkli fundus retina fotoğrafçılığını girdi olarak kullanarak Diyabetik Retinopati (DR) tarama yöntemini otomatikleştirmek için önerilmiştir. Ağımız, mikro-anevrizmalar ve kanamalar gibi retina üzerindeki özellikleri tanımlamak için CNN'yi gürültü giderme ile birlikte kullanmaktadır. Modellerimizi Python için açık kaynaklı bir sayısal hesaplama kütüphanesi olan Theano'yu kullanarak geliştirdik. Bu ağı, genelde erişilebilir olan Kaggle veri seti üzerinde yüksek performanslı bir GPU kullanarak eğittik. Önerdiğimiz modelimiz, iki sınıf sınıflandırması için yaklaşık %95, beş sınıf sınıflandırması için ise yaklaşık %85 doğruluk elde etmektedir.

Yaqoob ve diğ. (2021), yaptıkları çalışmalarında, Diyabetik retinopati, diyabet hastalarını yaygın olarak etkileyen bir göz hastalığıdır ve erken aşamalarda hızlı teşhis ve tedavi yapılmazsa görme kaybına neden olabilir. Belirtiler tespit edildiğinde, hastalığın şiddet seviyesi doğru ilacın reçete edilmesi için sınıflandırılmalıdır. Bu çalışma, diyabetik retinopati görüntülerinin sınıflandırılması ve derecelendirilmesi için derin öğrenme tabanlı bir yaklaşım önermektedir. Önerilen yaklaşım, ResNet-50'nin özellik haritasını kullanır ve sınıflandırma için Random Forest'a iletilir. Önerilen yaklaşım, iki kategori Messidor-2 ve beş kategori EyePACS veri setlerini kullanarak beş güncel yaklaşımla karşılaştırılmıştır. Messidor-2 veri setindeki bu iki kategori, 'Referans Olmayan Diyabetik Maküler Ödem Derecesi (DME)' ve 'Referans DME' iken beş kategori 'Proliferatif diyabetik retinopati', 'Şiddetli', 'Orta', 'Hafif' ve 'Diyabetik retinopati Yok' tan oluşmaktadır. Sonuçlar, önerilen yaklaşımın karşılaştırılan yaklaşımlardan daha üstün olduğunu ve bu veri setleri için sırasıyla %96 ve %75,09 doğruluk oranlarına ulaştığını göstermektedir. Önerilen yaklaşım, ResNet-50, VGG-19, Inception-v3, MobileNet, Xception ve VGG16 olmak üzere altı mevcut güncel mimariyi geride bırakmaktadır.

Nguyen ve diğ. (2020), yaptıkları çalışmalarında, Diyabetik Retinopati (DR), kronik diyabetle ilişkili bir göz hastalığıdır. DR, dünya genelinde çalışma çağındaki yetişkinler arasında körlüğün önde gelen nedenidir ve 93 milyondan fazla insanı etkilemesi tahmin edilmektedir. DR'nin zamanında tespit edilmesiyle görme bozukluğuna ilerlemesi yavaşlatılabilir veya kontrol altına alınabilir, ancak bu,

hastalık genellikle etkili tedavi sağlamak için çok geç olana kadar az belirti gösterdiği için zordur. Şu anda DR'nin tespiti, bir oftalmolog veya eğitimli klinisyenin retina ile ilişkilendirilen vasküler anormallikler nedeniyle hastalık tarafından oluşturulan lezyonları tanımlamak için retina dijital renkli fundus fotoğraflarını incelemesini ve değerlendirmesini gerektiren zaman alıcı ve manuel bir süreçtir. DR taramasının otomatik yöntemi, tespit ve karar verme sürecini hızlandıracak, bu da DR ilerlemesini kontrol etmeye veya yönetmeye yardımcı olacaktır. Bu makale, farklı aydınlatma ve görüş alanlarına sahip fundus görüntülerini analiz eden ve diyabetik retinopati (DR) için ciddiye derecesi üreten makine öğrenimi modelleri olan CNN, VGG-16 ve VGG-19 gibi modelleri kullanarak otomatik bir sınıflandırma sistemi sunmaktadır. Bu sistem, 0'dan 4'e kadar olan 5 kategoriye görüntüleri sınıflandırmak için %80 duyarlılık, %82 doğruluk, %82 özgüllük ve 0,904 AUC başarısına ulaşmaktadır; 0 hiç DR yokken, 4 ise proliferatif DR'dir.

Panchal ve diğ. (2024), DR tespitinde derin öğrenme tabanlı bir yöntem önermektedir. Araştırmacılar, RetinaNet modelinin, sınıflandırma ve nesne tespiti konularında sağladığı avantajlardan faydalanarak, göz retinasındaki mikro anevrizma ve kanamalara dair hassasiyet sağladığını vurgulamaktadır. Uygulanan model, görüntüleri daha iyi analiz ederek, manuel gözlemlerle karşılaştırıldığında daha hızlı ve doğru sonuçlar elde etmektedir. Çalışma, derin öğrenme tabanlı sistemlerin DR tespitinde kullanılmasının potansiyelini ortaya koymakta ve klinik uygulamalara entegrasyonu için güçlü bir temel sunmaktadır.

(Mahmoud ve diğ, 2023), klasik görüntü işleme yöntemlerini ve makine öğrenimini bir araya getirerek hibrid bir yaklaşım geliştirmiştir. Yazarlar, görüntüdeki farklı özelliklerin (bölge büyüklüğü, kenar belirginliği) analiz edilmesi ile kusurların daha etkili bir şekilde tespit edilebileceğini göstermektedir. Deney sonuçları, bu hibrid modelin, DR'nin erken teşhisinde yüksek doğruluk sağladığını ve özellikle veri setleri üzerindeki genel performansın iyileştiğini ortaya koymuştur. Bu çalışma, mevcut sistemlerin ötesinde daha karmaşık analizler için yeni bir yol sunmaktadır.

Guerbai ve Bouaraki (2024), transfer öğrenme yöntemlerini kullanarak VGG19 modelini uygulamış ve bu yöntemle DR tespitindeki doğruluğu artırmayı başarmıştır. Araştırmada, farklı veri setleri üzerinde yapılan testlerde, modelin genel olarak %95'lik bir başarı oranı gösterdiği bildirilmiştir. Ayrıca, araştırmacılar, transfer öğrenme yaklaşımının sınırlı veri setleri ile bile etkili sonuçlar üretebildiğini

vurgulamaktadır. Bu çalışma, DR tespitinde mevcut modellerin geliştirilmesi ve uygulanması için önemli bir referans oluşturmaktadır.

Tupe ve diğ. (2022), görüntü işleme tekniklerinin yanı sıra derin öğrenme algoritmalarını kullanarak DR'yi tespit eden yeni bir sistem geliştirmiştir. Çalışmada, araştırmacılar, görüntü işleme sürecinde histogram eşitleme ve kontrast iyileştirme gibi yöntemlerin kullanımı ile modelin performansını artırdıklarını ortaya koymuştur. Derin öğrenme ile entegre edilmiş bu sistem, göz retinasındaki anormallikleri tespit etmede yüksek doğruluk oranlarına ulaşmıştır. Bu araştırma, hem akademik hem de klinik alanda önemli uygulama potansiyeline sahip olduğunu göstermektedir.

(Ling ve diğ, 2023), geniş veri setleri kullanarak bir derin öğrenme modeli olan EfficientNet'i DR tespiti için uygulamıştır. Yazarlar, modelin görüntü sınıflandırma yeteneklerinin yanı sıra, farklı DR evrelerini ayırt etme konusunda yüksek doğruluk sağladığını vurgulamaktadır. Çalışmada elde edilen sonuçlar, DR tespitindeki mevcut yaklaşımların bir üst seviyeye çıkarılmasına olanak tanıyan önemli veriler sunmaktadır. EfficientNet modelinin DR tespitindeki potansiyeli, gelecekteki araştırmalar için önemli bir temel oluşturmaktadır.

Mali ve diğ. (2022), derin öğrenme tekniklerinin diyabetik retinopati tespitindeki etkinliğini incelemiştir. Yazarlar, çeşitli konvolüsyonel sinir ağları (CNN) mimarilerini karşılaştırarak, ResNet ve DenseNet gibi modellerin yüksek doğruluk oranları sağladığını belirtmiştir. Deneylerde, bu modellerin, standart görüntü işleme teknikleri ile karşılaştırıldığında, hata oranını belirgin şekilde azalttığı görülmüştür. Araştırma, derin öğrenme yöntemlerinin klinik uygulamalarda etkili bir şekilde kullanılabileceğini vurgulamaktadır.

Sheetal ve Abhilash (2024), yapay zeka tabanlı bir sistem geliştirerek, DR'nin erken teşhisinde önemli bir katkı sağladıklarını bildirmiştir. Çalışmalarında, destek vektör makineleri (SVM) ile görüntü işleme tekniklerinin birleşiminin DR tespitindeki doğruluğu artırdığını ortaya koymuşlardır. Ayrıca, elde ettikleri sonuçlar, sistemin gerçek zamanlı uygulamalar için uygun olduğunu göstermektedir. Yazarlar, bu tür sistemlerin tıbbi karar destek sistemlerine entegre edilmesinin faydalı olabileceğini belirtmiştir.

Priya ve diğ. (2013), çeşitli görüntü işleme teknikleri ile DR'nin belirti ve bulgularını analiz eden bir çalışma yapmıştır. Yazarlar, kenar algılama, histogram eşitleme ve renk

analizi gibi yöntemlerin DR tespitindeki önemini vurgulamaktadır. Elde edilen sonuçlar, bu tekniklerin kullanılması ile DR'nin erken aşamalarında bile tespit edilebileceğini göstermiştir. Çalışma, klinik ortamlarda bu yöntemlerin uygulanabilirliğine dair önemli bilgiler sunmaktadır.

Hagos ve Kant (2019), birçok farklı modelin uygulandığı bir karşılaştırma çalışması gerçekleştirmiştir. Yazarlar, Transfer Learning (Transfer Öğrenme) yönteminin, sınırlı veri setlerinde bile DR tespitinde yüksek doğruluk sağladığını ifade etmektedir. Araştırmada, çeşitli derin öğrenme mimarileri üzerinde yapılan testler, Transfer Learning'in avantajlarını ortaya koymuş ve bu yaklaşımın sağlık alanındaki potansiyelini göstermiştir.

Beri ve diğ. (2024), yapay zeka destekli bir sistem geliştirmiştir. Bu sistem, optik koherens tomografi (OCT) görüntülerinin analizi ile DR'nin tespitinde yüksek hassasiyet sağlamaktadır. Yazarlar, modelin, tıbbi görüntülerin işlenmesi ve yorumlanması konusundaki potansiyelini vurgulamış ve sistemin klinik uygulamalara entegrasyonunu önermiştir.

Jayakumari ve Maruthi (2011). zaman serisi verileri üzerinde çalışan bir model geliştirmiştir. Yazarlar, görüntü işleme tekniklerinin yanı sıra, zamanla değişen parametreleri dikkate alarak DR tespitini artırmayı hedeflemiştir. Deney sonuçları, bu yaklaşımın DR'nin ilerleyişinin izlenmesinde faydalı olabileceğini göstermiştir. Araştırma, zaman serisi analizi ile birlikte görüntü işleme tekniklerinin birleştirilmesinin önemini ortaya koymaktadır.

Rajalakshmi ve diğ. (2018), göz tabanlı görüntüleri analiz eden bir yapay zeka sistemi geliştirmiştir. Yazarlar, bu sistemin, eğitim sürecinde öğrendiği verilerle DR tespitinde yüksek hassasiyet sağladığını belirtmiştir. Çalışma, göz sağlığına yönelik yapay zeka uygulamalarının önemini vurgulamakta ve bu tür sistemlerin geniş bir veri seti ile eğitilmesinin gerekliliğini ortaya koymaktadır.

Vardhan ve diğ. (2024), Göz Hastalıkları için Derin Öğrenme Uygulamaları üzerine bir derleme yapmış ve mevcut yaklaşımların kapsamını değerlendirmiştir. Yazarlar, derin öğrenmenin potansiyelinin yanı sıra, mevcut zorlukları ve sınırlamaları ele almışlardır. Bu çalışma, DR tespitinde kullanılan yöntemlerin genel bir çerçevesini sunarak gelecekteki araştırmalar için önemli bir temel oluşturmaktadır.

Tan ve diğ. (2023), göz sađlıđında yapay zeka uygulamaları üzerine bir alıřma yapmıř ve DR tespitinin yanı sıra, diğ. göz hastalıklarının tespitinde de yapay zeka kullanmanın avantajlarını vurgulamıřtır. Yazarlar, DR tespitinde kullanılan derin ğrenme modellerinin diğ. göz hastalıklarına da uygulanabileceđini öne sürmektedir. Bu alıřma, göz sađlıđı alanında yapay zekanın rolünü ve potansiyelini deđerlendiren önemli bir arařtırmadır.



2. DİYABETİK RETINOPATİ (DR)

Diyabetik retinopati (DR), diyabetin bir komplikasyonu olarak ortaya çıkan, retina kan damarlarının hasar görmesiyle karakterize edilen bir göz hastalığıdır. Diyabetik retinopati, diyabetin kontrolsüz seyri sonucu yüksek kan şekeri seviyelerinin göz damarlarında yol açtığı hasar neticesinde gelişir. Retinada meydana gelen bu hasar, hastalığın evrelerine bağlı olarak mikroanevrizm, kanamalar, sert ve yumuşak döküntüler ve nihayetinde proliferatif diyabetik retinopatiye (PDR) kadar ilerleyebilir. DR, genellikle beş farklı sınıfa ayrılır: sınıf 0 (sağlıklı), sınıf 1 (hafif NPDR), sınıf 2 (orta NPDR), sınıf 3 (şiddetli NPDR) ve sınıf 4 (proliferatif DR).

Diyabetik retinopatinin patofizyolojisi, hipergliseminin retina üzerindeki etkileri ile başlar. Yüksek kan şekeri seviyeleri, retinal kan damarlarında zararlı metabolik değişikliklere yol açarak endotel hücrelerinde hasara neden olur. Bu durum, damarların geçirgenliğinin artmasına ve mikroanevrizm oluşumuna zemin hazırlar. Zamanla, kanama ve sıvı birikimi ile birlikte, retina yapısında belirgin değişiklikler gözlemlenir. DR, iki ana evrede sınıflandırılmaktadır: non-proliferatif diyabetik retinopati (NPDR) ve proliferatif diyabetik retinopati (PDR). NPDR aşamasında, mikroanevrizm ve hafif kanama gibi erken belirtiler ortaya çıkar. PDR aşamasında ise anormal kan damarlarının oluşumu (neovaskülarizasyon) ile birlikte ciddi kanamalar ve retina dekolmanı riski artar.

Diyabetik retinopati, dünya genelinde görme kaybının önde gelen nedenlerinden biridir. Küresel olarak, diyabet hastalarının yaklaşık %30-40'ında bu hastalığın bir formu görülebilmektedir (Yau ve diğ, 2012). Özellikle, tipi 1 ve tipi 2 diyabet hastalarında uzun süreli hiperglisemi, diyabetik retinopatinin gelişiminde önemli bir risk faktörüdür.

Diyabetik retinopatinin erken evrelerinde, hastalar genellikle belirgin bir semptom hissetmez. Bununla birlikte, hastalık ilerledikçe görme bulanıklığı, lekeler, karanlık noktalar ve gece görüşünde zorluk gibi belirtiler ortaya çıkabilir. Tanı, genellikle göz muayenesi sırasında yapılan fundus görüntüleme yöntemleri ile konur. Fundus

fotoğraflama ve fluorescein anjiyografi, lezyonların tespiti ve değerlendirilmesi için yaygın olarak kullanılan tekniklerdir.

Diyabetik retinopatinin yönetimi, hastalığın evresine bağlı olarak değişir. Erken evrelerde, kan şekeri seviyelerinin kontrol altında tutulması, hastalığın ilerlemesini önlemek için kritik öneme sahiptir. İleri evrelerde ise lazer tedavisi, intravitreal ilaç uygulamaları (anti-VEGF tedavisi) ve vitrektomi gibi cerrahi müdahaleler gerekebilir. Son yıllarda, derin öğrenme tabanlı görüntüleme sistemleri, DR'nin erken tanısı ve sınıflandırılmasında önemli bir rol oynamaktadır.


Diyabetik retinopati, erken tanı ve tedavi edilmediğinde ciddi görme kaybına neden olabilen bir hastalıktır. Göz sağlığı için düzenli kontroller ve diyabetin yönetimi, bu komplikasyonun önlenmesinde hayati öneme sahiptir (Ağca ve diğ., 2022)

2.1 Diyabetik Retinopati ve Lezyonlar

Diyabetik retinopati (DR), diyabet hastalarında görülen göz hastalıklarından biridir ve retinal görüntülerdeki lezyonların varlığı ile karakterize edilir

2.1.1 Lezyon tipleri

Bu lezyonlar arasında kanamalar (HM), mikroanevrizmalar (MA) ve yumuşak ile sert eksüdalar (EX) bulunmaktadır Şekil 2.1'de görüldüğü gibi.




Şekil 2.1 : Lezyon tipleri (Albahli ve diğ., 2022).

2.1.1.1 Mikro anevrizmalar (MA)

Mikroanevrizmalar, diyabetik retinopatinin en erken belirtisi olup, genellikle kırmızı renkli dairesel noktalar olarak görünür.

Bu lezyonlar, zayıflamış kan damarı duvarlarından kaynaklanır ve boyutları 125 μm 'den küçüktür. Mikroanevrizmalar, keskin kenarları olan belirgin yapılar olarak retina üzerinde gözlemlenir. Şekil 2.2'de görüldüğü gibi Altı ana tip mikroanevrizma mevcuttur




Şekil 2.2 : MA diyabetik retinopatinin farklı türü (Aldujailı, 2023).

İsimleri sırasıyla: Fokal çıkıntı, Sakküler, İğ şeklinde, Karışık, Saplı ve Düzensiz şeklindedir.

2.1.1.2 Kanamalar (HM)

Diyabetik retinopatinin ikinci aşaması olarak, kanamalar genellikle büyük lekeler halinde kendini gösterir Şekil 2.3'te görüldüğü gibi.




Şekil 2.3 : Diyabetik retinopatinin kanamalar.

Retina dokusundaki bu lekeler, boyutu 125 μm 'yi aşan düzensiz kenarlara sahip olan kanama alanlarıdır.

2.1.1.3 Sert eksüdalar (EX)

Sert eksüdalar, retina dokusunda belirgin sınırları olan parlak sarı lekeler şeklinde görülür ve plazma sızıntısından kaynaklanır Şekil 2.4'te görüldüğü gibi.

Bu tür lezyonlar, genellikle retinanın dış katmanlarında yer alır.



Şekil 2.4 : Diyabetik retinopatinin sert eksüdalar (EX).

2.1.1.4 Yumuşak eksüdalar


Yumuşak eksüdalar, sinir lifi tabakasındaki mikrovasküler tıkanmalar nedeniyle oluşan beyaz lekeler olarak tanımlanır Şekil 2.5'te görüldüğü gibi. Genellikle oval bir şekle sahiptir.



Şekil 2.5 : Diyabetik retinopatinin yumuşak eksüdalar (EX).

2.2 Diyabetik Retinopati Derecelendirme Sistemi

Diyabetik retinopati tespitinde kullanılan veri setleri, göz dibi (fundus) fotoğrafları içerir ve belirli bir derecelendirme sistemine göre sınıflandırılır Şekil 2.6'da görüldüğü gibi. Bu derecelendirme, retinopatinin ciddiyetine göre yapılır:



Şekil 2.6 : Diyabetik retinopati derecelendirme.

- 0- No DR (Diyabetik Retinopati Yok): Gözde diyabetik retinopati belirtileri yok.
- 1- Mild NPDR (Hafif Non-proliferatif Diyabetik Retinopati): Küçük mikroanevrizmalar gibi hafif belirtiler var.

- 2- Moderate NPDR (Orta Derecede Non-proliferatif Diyabetik Retinopati): Mikroanevrizmalar, intraretinal hemorajiler ve sert eksüdalar gibi belirtiler mevcut.
- 3- Severe NPDR (Şiddetli Non-proliferatif Diyabetik Retinopati): Çok sayıda mikroanevrizmalar, intraretinal mikrovasküler anormallikler ve daha ciddi hemorajiler var.
- 4- PDR (Proliferatif Diyabetik Retinopati): Yeni damar oluşumları ve vitreus kanamaları gibi ileri seviye retinopati belirtileri var.

2.3 Derecelendirme Kriterleri

Derecelendirme, göz dibi fotoğraflarında belirli patolojik özelliklerin varlığına ve sayısına göre yapılır. Bu özellikler arasında:

- Mikroanevrizmalar : Küçük kan damarlarının baloncuk şeklinde genişlemesi.
- Hemorajiler: Retina içinde veya altında kanamalar.
- Sert Eksüdalar : Lipid sızıntılarının neden olduğu sarımsı beyaz birikintiler.
- Yumuşak Eksüdalar : Pamuksu lekeler, sinir lifi tabakasındaki mikrovasküler tıkanmalar nedeniyle oluşur.
- Yeni Damar Oluşumları (Neovaskülarizasyon) : Retinada yeni, anormal kan damarlarının oluşumu.
- Vitreus veya Preretinal Kanama : Retina yüzeyinde veya vitreus jölesinde kanama.

Diyabetik retinopatinin erken teşhisi ve uygun yönetimi, görme kaybını önlemek için son derece önemlidir. Göz sağlığına yönelik düzenli kontroller, bu tür komplikasyonların önlenmesinde kritik bir rol oynamaktadır.

3. DERİN ÖĞRENME ESASLARI

Derin öğrenme, yapay zekanın bir alt dalı olarak, hesaplama sistemlerinin büyük veri setlerinden öğrenme yeteneğini geliştiren karmaşık bir çerçeve sunmaktadır. Bu disiplin, yapay sinir ağları gibi çok katmanlı yapıların kullanımıyla verilerdeki gizli kalıpları ortaya çıkarmayı hedefler. "Derin öğrenme" terimi, 2000'li yılların başlarında, yapay sinir ağlarının çok katmanlı yapıları ve bu yapıların verimliliği konusundaki ilerlemeleri ifade etmek amacıyla literatüre girmiştir. 2006 yılında Hinton ve arkadaşlarının çalışmaları, çok katmanlı ileri beslemeli sinir ağlarının etkinliğini ortaya koymuş ve derin öğrenme alanında önemli bir dönüm noktası olmuştur (Hinton ve diğ, 2006) . Derin öğrenme, makine öğrenimi çerçevesinde ele alındığında, genellikle denetimli ve denetimsiz öğrenme olarak iki ana kategoriye ayrılır. Denetimli öğrenme, belirli bir etiket setine dayalı olarak eğitim almış veriler üzerinde modelin geliştirilmesine dayanır. Bu süreçte, model, etiketli veriler üzerinden öğrenerek, yeni ve açıklamasız veriler üzerinde tahminler yapabilme yeteneği kazanır (Goodfellow ve diğ, 2016). Öte yandan, denetimsiz öğrenme algoritmaları, açıklamasız veri kümeleri ile çalışarak verilerin içsel yapısını keşfetmeye odaklanır. Bu tür yöntemler, veriler arasında benzerlikleri ve farklılıkları ayırt etmek için kümeleme gibi teknikler kullanır (Adugna ve diğ, 2024) . Derin öğrenmenin temel yapı taşlarından biri, çok katmanlı yapılar aracılığıyla karmaşık veri temsillerinin elde edilmesidir. Bu katmanlar, her biri belirli bir işlevi yerine getirerek verilerdeki soyutlamaları artırır. Derin öğrenme modelleri, insan beyninin nörobiyolojik temellerinden esinlenerek tasarlanmıştır ve bu sayede, doğal verilerdeki karmaşıklıkları anlamak için gereken yetenekleri kazandırır (LeCun ve diğ, 2015) . Gelişen bilgi işlem teknolojileri, derin öğrenme alanındaki ilerlemeleri hızlandırmıştır. Yüksek performanslı CPU ve GPU'lar, büyük veri setlerinin işlenmesi için kritik öneme sahiptir. Bu donanımlar, derin öğrenme algoritmalarının hızla çalışmasını sağlarken, aynı zamanda büyük veri kümelerinden bilgi çıkarmayı da kolaylaştırır. Sonuç olarak, derin öğrenme, veri analizi ve tahminleme süreçlerinde yüksek başarı oranları elde etme potansiyeline sahip bir yöntem haline gelmiştir (Wang, 2019) . Özellikle görüntü işleme alanında derin öğrenme uygulamaları, medikal görüntüleme,

nesne tanıma ve görüntü sınıflandırma gibi alanlarda çığır açan gelişmelere imza atmıştır. Bu yöntemler, görüntülerdeki karmaşık ilişkileri çözümleyerek, daha önce insan gözüyle bile fark edilemeyen detayları ortaya çıkarabilmektedir. Bu bağlamda, derin öğrenme algoritmaları, öğrenme süreçlerinde hiyerarşik temsiller oluşturarak, veri setlerinin derinlemesine analiz edilmesine olanak tanımaktadır (Krizhevsky ve diğ., 2012). Sonuç olarak, derin öğrenme, makine öğreniminin ötesinde, daha karmaşık ve sofistike veri analiz yöntemleri sunarak, çok çeşitli uygulamalarda kullanılmaktadır. Bu teknolojinin potansiyeli, araştırmacıların ve endüstri profesyonellerinin farklı alanlarda yeni çözümler geliştirmesine olanak tanımaktadır. Şekil 3.1’de derin öğrenme esasları nasıl çalıştığını gösterir.



Giriş görüntüleri derin öğrenme modeline uygulandıktan sonra model, görüntüler üzerinden özellikler çıkartır ve bu özelliklere bağlı olarak sınıflandırılmış çıkış görüntüsü üretir.

3.1 Transfer Öğrenme

Transfer öğrenme, derin öğrenmenin önemli bir alt dalıdır ve önceden eğitilmiş bir modelin bilgilerini yeni ve benzer bir problem üzerinde kullanmayı sağlar. Bu teknik, özellikle sınırlı veri setleriyle çalışırken veya yeni bir görev için model eğitimi sürecini hızlandırmak amacıyla etkili bir strateji sunar. Transfer öğrenme, bir modelin öğrenme süreçlerinde elde ettiği bilgi ve özelliklerin, başka bir probleme aktarılabilmesi ilkesine dayanır. Örneğin, bir görüntü sınıflandırma modelinin, daha önce eğitildiği nesne tanıma görevinde kazandığı özellikleri, yeni bir görüntü sınıflandırma görevinde kullanması mümkündür (Pan ve diğ., 2010). Transfer öğrenmenin temel prensibi, bir modelin öğrendiği bilgileri farklı görevler arasında paylaşabilmesidir. Derin öğrenme

modellerinin genellikle büyük veri setleri üzerinde eğitilmesi gerektiğinden, bu durum zaman ve kaynak tasarrufu sağlar. Örneğin, ImageNet gibi geniş veri setleri üzerinde eğitilmiş modeller, daha sonra belirli bir görev için yeniden eğitilebilir veya ince ayar yapılabilir (fine-tuning) (Yosinski ve diğ, 2014). Transfer öğrenme, birçok farklı alanda uygulanmaktadır. Görüntü işleme, doğal dil işleme ve ses tanıma gibi alanlarda, önceden eğitilmiş modellerin kullanımı yaygındır. Bu bağlamda, özellikle derin öğrenme modellerinin başarıyla uygulandığı alanlardan biri tıbbi görüntü analizi olarak öne çıkmaktadır. Burada, sınırlı veri setlerine sahip durumlarda transfer öğrenme sayesinde daha iyi sonuçlar elde etmek mümkün olmaktadır.

Transfer öğrenme süreci genellikle şu aşamalardan oluşur:


Önceden Eğitilmiş Modelin Seçilmesi: Görevle ilgili özellikleri öğrenmiş bir model (örneğin VGG16, ResNet50) seçilir.

Yeni Göreve Uyarlanma: Seçilen model, yeni görev için yeniden yapılandırılır. Genellikle modelin son katmanları değiştirilir veya çıkarılır.

Eğitim: Model, yeni veri seti üzerinde yeniden eğitilir veya ince ayar yapılır. Bu aşamada, modelin öğrenme sürecini hızlandırmak için daha az sayıda epoch kullanılabilir.

Değerlendirme: Son olarak, modelin performansı yeni görevde değerlendirilir ve gerekirse daha fazla ince ayar yapılır.


Transfer öğrenme, derin öğrenme alanında önemli bir yer tutar ve özellikle veri yetersizliği veya hesaplama kaynaklarının kısıtlı olduğu durumlarda büyük avantajlar sunar. Araştırmalar, transfer öğrenmenin daha az veri ile eğitilen modellerin başarısını artırdığını ve eğitim süresini önemli ölçüde kısalttığını göstermektedir (Kornblith, 2019). Dolayısıyla, transfer öğrenme, derin öğrenme uygulamalarının verimliliğini artıran kritik bir yöntem olarak kabul edilmektedir. Transfer öğrenme akışları aşağıdaki şekilde verilmiştir (Şekil 3.2).



Şekil 3.2 : Transfer öğrenme akışları.

3.2 Evrişimli Sinir Ağları (CNN)

Derin öğrenme algoritmalarının içinde en bilineni CNN'dir. Görüntü sınıflandırma problemlerinde sıklıkla kullanılmaktadır. CNN'de her bir katmanda matris üzerinde işlem yapan genellikle boyutları 3x3, 5x5, 7x7 olan filtreler (çekirdekler) kullanılmaktadır. Daha sonra bu filtrelerin çıktılarının üzerinde havuzlama (pooling) işlemi yapılmaktadır. Havuzlama ile çekirdekte bulunan veriler filtrelendir. Max pooling yöntemi sıklıkla kullanılan havuzlama yöntemi olup bu yöntemde matris içindekilerden en büyüğünün alınması mantığı ile çalışmaktadır. Evrişimli sinir ağlarının mimarisi aşağıdaki şekilde verilmiştir (Şekil 3.3).



Şekil 3.3 : Evrişimli sinir ağlarının mimarisi.

CNN'de, bazı filtreler çok katmanlı bir sinir ağındaki "w" parametresi gibi öğrenme parametreleri olarak işlev görmektedir. Genelde evrişim işlemlerinde kullanılırlar. Evrişim sırasında seçilen filtre, her seferinde görüntü üzerinde kaydırılır. İşlem sırasında filtrenin değerleri, o pencere boyutundaki görüntünün değerleri ile çarpılır.

Sonucunda ise görüntünün tüm değerlerini bu pencere boyutunda temsil eden tek bir sayı oluşur. CNN’de işlem yapılan görüntü matris formatındadır. Şekil’de 6x8 boyutunda bir görüntü matrisi ve 3x3 boyutunda bir çekirdek matrisi görülmektedir. Görüntü matrisine uygulanan filtre sayesinde görüntü üzerinden belli özellikler üzerinde karşılaştırma yapılarak görüntüden veriler elde edilmektedir. Algoritmayı kullanırken seçilen kütüphaneler, çekirdek filtrelerini otomatik olarak seçebilmektedir. Parametrelerin doğru olarak tanımlanması da önemlidir. Bu işlem ile görüntü üzerinde bazı özellikler yakalanmaya çalışılır. Bu sayede belli bir olasılıkla resmin görüntünün hangi sınıfa ait olduğu tespit edilir. Bu işlemler diğer görüntüler üzerinde de uygulanarak, benzerlikler kurulmaya çalışılır. Belirlenen filtre görüntü üzerinden kaydırılarak resmin tamamına uygulanır. Bu kaydırma işlemi “stride” denilen adım sayısına göre gerçekleştirilir (Okumuş ve diğ, 2019). Havuzlama katmanında ise öğrenilen parametre yoktur. Burada girdi olarak verilen matrisin kanal sayısını sabit kalır ancak yükseklik ve genişlik bilgisi indirgenir. Bu adımda hesaplama karmaşıklığı azaltılır. Şekil’de 4x6 boyutundaki matrise, 2x2 boyutunda maksimum ve ortalama havuzlama işlemleri uygulanmış, bunun sonucunda her bir 4 elemanın 1 çıkışı olmuştur. Böylece matris dörtte üç oranında küçültülmüş olur.

İki Fonksiyonun (f & g) Sonlu Aralıktaki $[0, t]$ Evrişimi denklem 3.1’de verilmiştir :

$$[f * g](t) \equiv \int_0^t f(\tau)g(t-\tau)d\tau \quad (3.1)$$

Burada $[f * g](t)$, f ve g fonksiyonlarının evrişimi anlamına gelmektedir. Evrişim daha çok sonsuz bir aralıkta alınır: Bir CNN modelinin iki önemli avantajı vardır. Bunlardan ilki, önemli ölçüde öğrenilmesi gereken filtrelerin parametrelerine indirgemedir. Çok fazla nöronun öğrenilmesi ve ihtiyaç duyulması için birçok parametre olduğunda, birçok sorun ortaya çıkmaya başlayabilir. Giriş olarak yüksek çözünürlüğe sahip bir görüntü varsa, piksellere göre bir milyon değere sebep olur. Aşırı öğrenmeye sebep olabilecek ve çok fazla hesaplama gücü gerektiren çok derin ve tam olarak bağlı katmanlara ihtiyaç duyacaktır. Bununla birlikte CNN, özellikle bilgisayarla görme işlemlerde, aşırı öğrenme olasılığını azaltabilir ve hesaplama gücünü koruyabilir. İkinci ana avantaj parametre paylaşımıdır. CNN ile öğrenilen parametreler bir sonraki katmana girdi olarak paylaşılır. Bu sebeple, aynı ağırlıklar katmandan tekrar kullanılır, bu da katmanlarda tekrar öğrenmeye gerek olmadığı

anlamına gelir. Bu şekilde, daha sonraki katmanlar daha karmaşık özellik ve kalıpları öğrenebilir (Satar, 2018). Veriyi işleyerek öğrenen modelleri tasarlarlarken, tasarımcılar kullanılacak algoritmaya ve tekniklere de karar vermektedir. Bu karar beraberinde bazı parametreleri de getirir. K en yakın komşu (K Nearest Neighbor-KNN) algoritmasındaki “k” değeri, SVM algoritmasında kullanılacak çekirdek fonksiyonu ve derin öğrenme modellerinde seçilen “seyreltme (Drop Out)” değerleri gibi bazı parametreler, modeli tasarlayan tarafından belirlenir. Bu belirleme işlemi verinin türüne, ele alınan konuya ve verinin boyutuna bağlı olarak değişebilmektedir. Bu açıklamalardan yola çıkarak, hiper-parametre kavramı ortaya atılmıştır. Ne olması gerektiği, modeli tasarlayan kişiye bırakılmış, probleme, veri setine göre değişiklik gösteren parametreler hiper-parametre (hyperparameters) olarak adlandırılmaktadır (Çarkacı ve diğ, 2018). Oluşturulacak modelde kullanılacak hiper-parametreler, derin öğrenme uygulamalarındaki en önemli problemlerden birisidir. Hiper-parametreler ve bunların değerlerinin seçimi, verinin türüne, programcının tecrübesine ve sezgisine, yeni çalışmalara, farklı uygulamalarda elde edilen sonuçlar vb. gibi pek çok duruma bağlı olarak değişmektedir. Model tasarlanırken kullanılabilecek parametrelerden başlıcaları şunlardır:

- Ağda Kullanılacak Çekirdek Boyutu
- Parti büyüklüğü sayısı (Batch-size)
- Çevrim Sayısı
- Katman Sayısı
- Kullanılacak Aktivasyon Fonksiyonu
- Optimizasyon Algoritması
- Öğrenme Hızı (Learning Rate)
- Seyreltme (Drop Out) Değeri
- Seyreltme Kullanılacak Yerler
- Veri Setinin Büyüklüğü

Pek çok çalışmada bu hiper-parametreler, test et/sonucu yorumla yöntemiyle defalarca tekrarlanan çalışmalar sonucunda belirlenir. Modele en uygun olanı ve en iyi sonuç vereni, programcı tarafından belirlenerek, modelin son hali olarak kaydedilir.

3.3 Eğitim Süreci ve Optimizasyon Algoritmaları

Derin öğrenme modelleri, eğitim ve doğrulama süreçlerinden geçerek öğrenme yapar. Eğitim sürecinde, ağırlıklarının optimize edilmesi için genellikle gradyan inişi (gradient descent) gibi optimizasyon algoritmaları kullanılır. Geriye yayılım (backpropagation) algoritması, hata oranını azaltmak için her nöronun ağırlıklarını günceller. Modern derin öğrenme modellerinde, Adam veya RMSprop gibi gelişmiş optimizasyon yöntemleri tercih edilir (Erdoğan, 2016).

3.4 Performans Ölçütleri ve Değerlendirme

Bir derin öğrenme modelinin başarısı, doğruluk, hassasiyet, özgüllük gibi performans ölçütleri ile değerlendirilir. Ayrıca, ROC Eğrisi (Receiver Operating Characteristic) ve AUC (Area Under Curve) gibi istatistiksel araçlar da modelin ayırt ediciliğini ölçmede kullanılır (Değerlioğlu ve Köse, 2024).


3.5 Derin Öğrenmenin Avantajları ve Zorlukları

Derin öğrenme, karmaşık verileri yüksek doğrulukla analiz etme kapasitesine sahiptir. Ancak, büyük miktarda veriye ve yüksek hesaplama gücüne ihtiyaç duyar. Bu nedenle, GPU'lar gibi güçlü donanımlar gerektirebilir. Ayrıca, aşırı uyum (overfitting) ve veri dengesizliği gibi zorluklar da derin öğrenme modellerinde dikkat edilmesi gereken hususlardır (Tekin, 2019).

3.6 VGG16 ve VGG19

VGG16 ve VGG19, derin öğrenmede popüler olan VGG (Visual Geometry Group) mimarisinin iki varyasyonudur. Bu mimari, her iki modelin adındaki sayıların da belirttiği gibi, sırasıyla 16 ve 19 katmana sahiptir. VGG mimarisi, nispeten daha küçük 3x3 konvolüsyon filtreleri kullanarak derin bir yapıyı mümkün kılar. Her bir konvolüsyon katmanı, görsel özellikleri giderek daha yüksek soyutlama seviyelerine çıkarırken, havuzlama katmanları (özellikle max pooling), uzamsal boyutları küçültür. VGG16, 13 konvolüsyon ve 3 tam bağlı katmandan oluşur. Özellikle tıbbi görüntü analizinde yaygın olarak kullanılan bu mimari, geniş veri kümelerinde eğitildikten sonra çeşitli sınıflandırma görevlerinde başarılı sonuçlar elde etmiştir. VGG16'nın belirgin bir avantajı, hesaplama açısından karmaşık olmasına rağmen, özellikleri iyi

genelleştirme kapasitesine sahip olmasıdır. Bu yüzden transfer öğrenme süreçlerinde sıklıkla tercih edilir. VGG19, VGG16'ya benzer bir yapı sergiler ancak üç ek konvolüsyon katmanı içerir. Bu, modelin daha karmaşık veri desenlerini öğrenmesine olanak tanır. Derinliği artırmanın, doğruluğa katkı sağladığı görülmüştür, ancak bu aynı zamanda daha fazla hesaplama gücü gerektirir (Simonyan ve diğ, 2015). VGG16 VS. VGG19 modeli aşağıdaki şekilde verilmiştir (Şekil 3.4).




Şekil 3.4 : VGG16 ve VGG19 modeli.

3.7 Xception

Xception (Extreme Inception), Inception mimarisine dayanan bir CNN modelidir, ancak standard Inception modüllerinin yerine derin ayrık konvolüsyon (depthwise separable convolution) kullanır. Bu yöntem, klasik konvolüsyon işlemlerinin gereksiz hesaplamalarını azaltırken, doğruluğu artırır. Derin ayrık konvolüsyon, her bir kanal üzerinde ayrı bir konvolüsyon işlemi gerçekleştirilerek işlem yükünü azaltır. Xception


modeli, özellikle büyük veri kümeleri üzerinde eğitim alarak etkili sonuçlar sunar ve yüksek verimlilik sağlar (Chollet, 2017). Xception modeli aşağıdaki şekilde verilmiştir (Şekil 3.5).



Şekil 3.5 : Xception modeli (Larrikins ve diğ, 2019).

3.8 InceptionV3


InceptionV3, Google tarafından geliştirilen ve Inception mimarisinin daha gelişmiş bir versiyonu olan bir modeldir. Inception mimarisi, her katmanda birden fazla filtre boyutu (1x1, 3x3, 5x5 gibi) kullanarak özellikleri paralel olarak öğrenir. Bu, modelin daha fazla bilgi yakalamasını ve farklı ölçeklerde öznetelik çıkarmasını sağlar. InceptionV3 ayrıca, hesaplama verimliliğini artırmak ve overfitting riskini azaltmak amacıyla faktörize edilmiş konvolüsyonları kullanır (Szegedy ve diğ, 2016). InceptionV3 modeli aşağıdaki şekilde verilmiştir (Şekil 3.6).



Şekil 3.6 : InceptionV3 modeli (Brital, 2023).

3.9 ResNet50

ResNet50, derin öğrenme modellerinde önemli bir yenilik olan residual learning (artık öğrenme) tekniğini kullanır. ResNet mimarisi, derin modellerde görülen eğitim zorluklarını çözmek amacıyla, her bir katmanda önceki katmanın çıktılarını "skip connection" adı verilen bir bağlantı ile bir sonraki katmana ekleyerek öğrenme sürecini kolaylaştırır. Bu sayede, daha derin ağların eğitilmesi mümkün hale gelir. ResNet50, 50 katmanlı bir yapıdadır ve yüksek doğruluğa sahip derin öğrenme modelleri arasında yer alır (He ve diğ, 2015). ResNet50 modeli aşağıdaki şekilde verilmiştir (Şekil 3.7).




Şekil 3.7 : ResNet50 modeli (Suresh ve diğ, 2021).

4. MATERYAL VE METOT

Bu bölümde, diyabetik retinopati (DR) sınıflandırması için kullanılan veri setine ve işleme yöntemlerine dair detaylar sunulmaktadır. Çalışmamızda, toplam 5099 yüksek çözünürlüklü retina görüntüsü yer almaktadır. Eğitim süreci için 4200 görüntü, test süreci için ise 900 görüntü kullanılmaktadır. Her sınıfta 840 görüntü yer almakta olup, bu sayede her sınıf arasında dengeli bir dağılım sağlanmaktadır. Veri setinin sınıflandırması, uzmanlar tarafından 0'dan 4'e kadar olan bir ölçekle yapılmıştır; burada 0, hiçbir DR belirtisi olmadığı, 4 ise proliferatif DR olduğu anlamına gelmektedir (Cukierski, 2024).

Eğitim ve test işlemlerinin gerçekleştirilmesi için, HP Victus Gaming bilgisayarını kullanarak oluşturulmuş yüksek hesaplama gücüne sahip (12th Gen Intel(R) Core (TM) i7-12650H 2.30 GHz GPU) bir cihaz kullanılmıştır. Ancak, büyük veri setleri kullanıldığı için her bir modelin eğitimi yaklaşık iki gün sürmüştür. Model eğitimi sürecinde kullanılan Python programlama dili ve TensorFlow kütüphanesi gibi yazılımlar, derin öğrenme algoritmalarının uygulanmasını kolaylaştırmaktadır.

Mevcut çalışmanın önerilen metodolojisi Şekil 4.1'de gösterilmektedir. Çalışmada hem orijinal veri seti hem de CLAHE ile ön işleme uygulanmış veri seti kullanılarak eğitim gerçekleştirilmiştir. Bu süreçte, CLAHE ön işleme yönteminin model doğruluğunu artırdığı ve orijinal veri setine kıyasla daha yüksek doğruluk oranları elde edildiği gözlemlenmiştir.



Şekil 4.1 : Önerilen metodoloji.

Ön işlemede, görüntüler gri tonlama, histogram eşitleme, CLAHE (Contrast Limited Adaptive Histogram Equalization), ve Gaussian Blur gibi teknikler kullanılarak daha belirgin hale getirilmeye çalışılmıştır. CLAHE yöntemi, görüntünün farklı bölgelerindeki kontrastı artırarak, aşırı parlak veya koyu alanların oluşmasını engellediği için diğer yöntemlere göre, özellikle mikromanevrizmalar, kanamalar ve eksüdaların daha net bir şekilde tespit edilmesini sağlamaktadır. Bu işlem sırasında kullanılan iki ana parametre, clipLimit ve tileGridSize, görüntü iyileştirme sürecinin kalitesini belirleyen kritik unsurlardır (Faraj ve diğ, 2018).




4.1 Dataset Tanımı ve Yapısı

Bu çalışma için kullanılan Diabetic Retinopathy (DR) veri kümesi, Kaggle tarafından sağlanan yüksek çözünürlüklü retina görüntülerinden oluşmaktadır. Çeşitli görüntüleme koşullarında elde edilen bu görüntülerde, her bir bireyin sol ve sağ göz retina görüntüleri ayrı ayrı bulunmaktadır (örneğin, 1_left.jpeg, birey 1'in sol gözünü

temsil eder). Her görüntü, ilgili hasta kimliği ile birlikte "sol" veya "sağ" göz olarak etiketlenmiştir.

Veri kümesindeki görüntüler, diyabetik retinopati (DR) şiddetinin 0 ile 4 arasında değişen beş dereceli bir ölçekle sınıflandırıldığı bir sistem kullanılarak bir klinisyen tarafından puanlanmıştır aşağıdaki şekilde örnek verilmiştir (Şekil 4.1):

Çizelge 4.1 : Kullanılan veri kümesi örneklerine örnekler.

0 - DR yok	
1 - Hafif DR	
2 - Orta DR	
3 - Şiddetli DR	
4 - İlerlemiş DR	

Veri kümesine Kaggle Diabetic Retinopathy Detection sayfasından erişilebilir. Toplamda 5,099 retina görüntüsü içeren veri kümesi, her biri farklı derecede retinopati içeren beş sınıfa ayrılmıştır: 0 (DR yok), 1 (hafif DR), 2 (orta DR), 3 (şiddetli DR), ve 4 (proliferatif DR). Her bir sınıf, belirli bir DR seviyesi için örnekler içermektedir ve veri kümesi, modelin her sınıftan dengeli sayıda örnek görmesini sağlayacak şekilde düzenlenmiştir.

Veri kümesi iki ana bölüme ayrılmıştır: eğitim ve test. Eğitim seti toplamda 4,200 görüntü içerirken, test seti 900 görüntüden oluşmaktadır. Her iki sette de beş sınıf için dengeli bir dağılım sağlanmış olup, her sınıfta eğitim setinde 840, test setinde ise 180 görüntü bulunmaktadır. Bu dengeli dağılım, modelin sınıflar arasında yanlışlık geliştirmeden öğrenmesini sağlamak amacıyla tercih edilmiştir.

4.2 Yazılımda Kullanılan Kütüphaneler

Bu çalışmada, Python programlama dili önerilmektedir çünkü mükemmel makine öğrenimi ve derin öğrenme kütüphanelerine sahiptir. Önerilen metodolojilerin uygulanması için Anaconda Jupyter kullanılmıştır; bu, Python kodlarını yazma, düzenleme ve çalıştırma için uygun bir ortam sağlamaktadır.

Aşağıdaki kütüphaneler ve bağımlılıklar kullanılmıştır:

TensorFlow : TensorFlow, derin öğrenme modelleri oluşturmak ve eğitmek için kullanılan açık kaynaklı bir makine öğrenimi çerçevesidir. Makine öğrenimi uygulamaları oluşturmak ve dağıtmak için kapsamlı bir araç ve kütüphane seti sağlar. Görüntü tanıma, doğal dil işleme gibi birçok alanda yaygın olarak kullanılmaktadır. Bizim uygulamamızda, derin öğrenme modellerinin oluşturulması ve eğitimi için bu kütüphane kullanılacaktır (Abadi ve diğ, 2015).

Keras : Keras, derin öğrenme modelleri oluşturmak ve eğitmek için yüksek seviyeli bir API'dir. TensorFlow'un üstüne inşa edilmiştir ve kullanıcıların birkaç satır kod ile kolayca sinir ağları oluşturmalarına ve eğitmelerine olanak tanır. Bu kütüphane, derin öğrenme modelleri oluşturma ve eğitim için basit bir arayüz sunmaktadır (Chollet, 2018).

NumPy : NumPy, büyük, çok boyutlu diziler ve matrisler için destek sağlayan bir Python kütüphanesidir ve bu diziler üzerinde işlem yapabilmek için geniş bir

matematiksel fonksiyon koleksiyonu içerir. Bilimsel hesaplama, veri analizi ve makine öğrenimi uygulamalarında yaygın olarak kullanılmaktadır (Oliphant ve diğ, 2006).

Pandas : Pandas, yüksek performanslı veri manipülasyonu ve analiz araçları sağlayan bir Python kütüphanesidir. NumPy'nin üstüne inşa edilmiştir ve tablo şeklindeki verilerle çalışmak için destek sunar; veri okuma ve yazma, veri filtreleme, toplama ve birleştirme gibi işlemleri içerir (Kinney ve diğ, 2017).

OpenCV (cv2) : OpenCV, görüntü ve video işleme için araçlar sağlayan açık kaynaklı bir bilgisayarla görü kütüphanesidir. Görüntü filtreleme, özellik tespiti, nesne tespiti ve takip gibi işlevleri içerir (Bradski ve diğ, 2008).

Matplotlib : Matplotlib, Python'da statik, animasyonlu ve etkileşimli görselleştirmeler oluşturmak için destek sağlayan bir kütüphanedir. Çizgi grafikleri, saçılma grafikleri, çubuk grafikleri gibi çeşitli grafik türlerini destekler ve bilimsel hesaplama, veri analizi ve makine öğrenimi uygulamalarında yaygın olarak kullanılmaktadır.

Bu kütüphaneler, yüksek hesaplama gücüne sahip cihazlarla birlikte kullanılarak, derin öğrenme modellerinin eğitiminde verimlilik sağlamakta ve projede gereken hesaplama sürelerini azaltmaktadır (Hunter ve diğ, 2007).


4.3 Görüntü İşleme ve Ön İşleme Teknikleri

Diyabetik retinopati görüntülerinde yer alan küçük detayların belirginleştirilmesi ve görüntü kalitesinin artırılması için kullanılan ön işleme yöntemleri aşağıda sunulmaktadır. Görüntülerin renkli bileşenlerinin çıkarılarak gri tonlamaya dönüştürülmesi, lezyonları vurgulamada önemli bir ilk adımdır. Grayscale işleme daha az bilgiyle çalışılırken lezyonlar daha net hale gelmektedir. Bu aşamada her bir piksel, gri tonlama ile tek bir renk değeri alır, böylece renk bilgisinden kaynaklanabilecek karışıklıklar minimize edilir (Huseynova ve diğ, 2024).

4.3.1 Histogram eşitleme

Görüntülerin kontrastını artırarak lezyonların belirginleşmesini sağlayan histogram eşitleme işlemi, özellikle mikromanevrizmalar ve kanamalar gibi küçük detayları daha görünür kılmaktadır. Piksel yoğunluklarını eşit bir dağılıma yayıp kontrastı artırarak düşük ışık koşullarında çekilen görüntülerdeki detaylar vurgulanmıştır (Güney ve diğ, 2013).

Şekil 4.2’de görüldüğü gibi mevcut olan orijinal data setten bir görüntü ve görüntü üzerinde histogram eşitleme uygulanmış hale.




Şekil 4.2 : Orijinal ve işlenmiş görüntülerin karşılaştırılması – histogram eşitleme.

4.3.2 CLAHE (Contrast limited adaptive histogram equalization)

Bu yöntem, görüntünün farklı bölgelerinde kontrastı kontrollü bir şekilde artırarak aşırı parlak ya da koyu alanları dengelemede etkilidir. CLAHE sırasında iki önemli parametre bulunmaktadır:

clipLimit : Kontrast sınırını belirler. Daha yüksek bir clipLimit, daha fazla kontrast artışı sağlarken aşırı değerler gürültüyü artırabilir. Varsayılan değer olan 2.0 kullanılmakla birlikte, en iyi sonuç için 1.0-10.0 aralığında testler yapılmıştır.

tileGridSize : Bu parametre, histogram eşitlemesinin yapıldığı ızgara boyutunu ayarlamaktadır. 4x4, 8x8 ve 16x16 gibi farklı boyutlar test edilerek, küçük bölgelerde ince detayları vurgulayan optimal grid boyutu seçilmiştir (Stephen ve diğ, 1987) CLAHE, görüntüdeki mikromanevrizmalar ve kanamalar gibi kritik detayları vurgulamada diğer yöntemlere göre daha başarılı bulunmuş ve nihai eğitim için seçilmiştir. Şekil 4.3’te görüldüğü gibi mevcut olan orijinal data setten bir görüntü ve görüntü üzerinde clahe uygulanmış hale.




Şekil 4.3 : Orijinal ve işlenmiş görüntülerin karşılaştırılması – CLAHE.

4.3.3 Gaussian blur

Gürültü azaltarak görüntüyü pürüzsüzleştiren bu yöntem, kenar tespiti gibi algoritmalar öncesinde kullanılmaktadır. 5x5 boyutunda çekirdek kullanılarak uygulanan Gaussian Blur, yüksek frekanslı gürültüyü azaltıp mikromanevrizmaların netliğini artırmaktadır. Çekirdek boyutu 3x3, 5x5 ve 9x9 olarak test edilmiş, 5x5 boyutunun ideal bulanıklığı sağladığı görülmüştür (Forsyth ve diğ, 2012).

Şekil 4.4'te görüldüğü gibi mevcut olan orijinal data setten bir görüntü ve görüntü üzerinde Gaussian Blur uygulanmış hale.



Şekil 4.4 : Orijinal ve işlenmiş görüntülerin karşılaştırılması – gaussian blur.

4.4 Normalizasyon

Makine öğrenimi ve derin öğrenme modellerinde, görüntü verilerinin normalizasyonu, modelin eğitimi ve genelleme performansı için kritik bir adımdır. Görüntülerin piksellerinin genellikle 0-255 arasında değişen ham değerleri, modelin öğrenme sürecini optimize etmek için belirli bir ölçeğe dönüştürülmelidir. Bu çalışmada, tüm görüntü pikselleri [0, 1] aralığına normalize edilmiştir.

Bu işlem için her bir piksel değeri, 255'e bölünerek yeniden ölçeklendirilmiştir. Böylece, modelin daha hızlı ve stabil öğrenmesi sağlanmıştır. Ayrıca, normalizasyon sayesinde, ağırlıkların büyük değişimlerden etkilenmesi engellenmiş ve gradyan tabanlı optimizasyon algoritmalarının daha verimli çalışması mümkün kılınmıştır (Yavuz ve diğ, 2013).

Avantajları:

- Hızlı ve Stabil Eğitim : Normalizasyon, modelin eğitimi sırasında ağırlık güncellemelerinin dengeli olmasını sağlayarak, eğitim sürecinin stabilitesini artırır.
- Model Performansı : Daha küçük ve dengeli giriş değerleri, modelin daha etkili bir şekilde öğrenmesine ve genelleme performansının artmasına katkıda bulunur.
- Hesaplama Verimliliği : Normalize edilmiş veriler, donanımın bellek yönetimini optimize eder ve işlem hızını artırır.

Bu çalışmada kullanılan normalizasyon yöntemi, genelleme performansı için temel bir gereklilik olarak ele alınmış ve tüm eğitim ve test görüntüleri üzerinde uygulanmıştır.

4.5 Veri Çoğaltma (Augmentation)

Veri artırma (augmentation), makine öğrenimi ve derin öğrenme projelerinde modelin genelleme yeteneğini artırmak ve aşırı öğrenmeyi (overfitting) önlemek amacıyla kullanılan etkili bir tekniktir. Özellikle sınırlı miktarda eğitim verisine sahip olduğumuz durumlarda, veri artırma yöntemiyle mevcut veriler çeşitli biçimlerde manipüle edilerek yapay olarak yeni veriler oluşturulabilir.

Bu çalışmada veri artırma işlemi için *Keras ImageDataGenerator* sınıfı kullanılmıştır. Uygulanan veri artırma teknikleri aşağıda açıklanmaktadır:

rotation_range

Görüntünün belirli bir derece aralığında rastgele döndürülmesini sağlar. Örneğin, *rotation_range=40* parametresi, görüntüyü -40 ile +40 derece arasında rastgele döndürür. Bu, görüntülerin farklı açılardan öğrenilmesini sağlayarak modelin döndürülmüş örnekleri daha iyi genellemesine yardımcı olur.

width_shift_range

Görüntünün yatay ekseninde belirli bir oranda rastgele kaydırılmasını sağlar. Örneğin, *width_shift_range=0.2* değeri, görüntüyü yatay ekseninde genişliğin %20'sine kadar kaydırabilir. Bu, veri kümesindeki nesnelerin farklı pozisyonlarda yer alabileceği durumları modelin öğrenmesine yardımcı olur.

height_shift_range

Görüntünün dikey ekseninde belirli bir oranda rastgele kaydırılmasını sağlar. Örneğin, *height_shift_range=0.2* değeri, görüntüyü dikey ekseninde yüksekliğin %20'sine kadar

kaydırabilir. Bu, nesnelerin farklı dikey pozisyonlarda olabileceği durumları simüle eder.

shear_range

Görüntüye belirli bir kesme (shear) açısı uygulayarak geometrik bozulma oluşturur. Örneğin, `shear_range=0.2` değeri, görüntüyü 0.2 radyanlık bir kesme açısıyla bozar. Bu, modelin daha fazla varyasyonla karşılaşmasını sağlar.

zoom_range

Görüntünün belirli bir oranda rastgele yakınlaştırılmasını veya uzaklaştırılmasını sağlar. Örneğin, `zoom_range=0.2` değeri, görüntüyü %20 oranında büyütüp küçültebilir. Bu, farklı mesafelerden alınan görüntüleri modelin öğrenmesini destekler.

horizontal_flip

Görüntüyü yatay olarak rastgele çevirmeyi sağlar. Örneğin, nesnenin sola ve sağa bakma varyasyonlarını öğrenmek için kullanışlıdır. Özellikle simetrik olmayan nesnelerin bulunduğu veri kümelerinde oldukça faydalıdır.

fill_mode

Dönüştürme işlemleri sırasında görüntü sınırlarının dışında kalan boş alanları doldurmak için kullanılır. Örneğin, `fill_mode='nearest'` seçeneği, sınır piksel değerlerini kullanarak bu alanları doldurur. Bu, görüntünün orijinal yapısının korunmasına yardımcı olur.

Bu teknikler sayesinde model, görüntülerin çeşitli varyasyonlarını öğrenme yeteneği kazanır. Böylelikle, sınırlı veri setine rağmen daha geniş bir hipotez uzayında öğrenme gerçekleştirilir ve genelleme yeteneği artar. Bu çalışmada veri artırma işlemleri, eğitim verilerine uygulanarak daha sağlam ve esnek bir model elde edilmesi sağlanmıştır (Goodfellow ve diğ, 2016).

4.6 Model Parametreleri

4.6.1 Öğrenme oranı (Learning rate)

Öğrenme oranı, modelin her güncelleme adımında hata gradyanının ne kadar değişeceğini belirleyen bir katsayıdır. Öğrenme oranının doğru belirlenmesi, modelin konverjansını yani eğitim sırasında en düşük hata değerine ulaşmasını sağlar. Küçük bir öğrenme oranı, modelin öğrenme sürecini yavaşlatırken daha stabil bir konverjans

sağlar; ancak bu durumda modelin doğruluk kazanması için daha fazla epoch gereklidir (Ian Goodfellow, 2016). Çok yüksek öğrenme oranları ise modelin optimum çözüme ulaşmadan gradyanlarda sıçramalar yapmasına, yani kararsız bir öğrenme sürecine yol açabilir. Bu nedenle ideal öğrenme oranının belirlenmesi için genellikle 0.001 veya 0.0001 gibi değerler tercih edilir, ancak model karmaşıklığına ve veri setinin büyüklüğüne göre ayarlama yapılır (LeCun, 2012).

4.6.2 Optimizasyon algoritması (Optimization algorithm)

Optimizasyon algoritmaları, modelin eğitim sırasında kayıp fonksiyonunu minimize ederek en iyi ağırlıkları öğrenmesini sağlar. Doğru bir optimizasyon algoritması seçimi, modelin hızlı ve kararlı bir şekilde öğrenmesini sağlar. Klasik gradient descent algoritmasının yanında, modern optimizasyon algoritmaları olan Adam, RMSprop, ve SGD (Stochastic Gradient Descent) yaygın olarak kullanılmaktadır (Kingma ve diğ, 2015). Özellikle büyük veri kümelerinde, bu algoritmalar modelin daha etkin bir şekilde eğitim almasını sağlar. Örneğin, Adam optimizasyonu, öğrenme oranının yanı sıra momentum ve uyarlamalı öğrenme oranı gibi parametreleri de içeren gelişmiş bir optimizasyon algoritmasıdır ve yaygın olarak tercih edilir (Tieleman ve Hinton, 2012).

4.6.2.1 Adam optimizasyonu (Adam optimization)

Adam (Adaptive Moment Estimation), momentuma dayalı bir optimizasyon algoritması olup, modelin öğrenme oranını uyarlayarak her bir parametreye göre optimize eder. Adam algoritması, hem gradyanın ortalama değerini hem de ikinci momentini kullanarak öğrenme hızını ayarlar, bu da stabil ve hızlı bir konverjans sağlar. Öğrenme oranı adaptasyonu ve momentumun birleşimi, özellikle karmaşık ve büyük veri kümelerinde Adam algoritmasını daha güvenilir kılar (Kingma ve diğ, 2015). Momentum özelliği sayesinde Adam, hızlı bir öğrenme süreci sunar ve yerel minimumlara takılmadan küresel minimuma ulaşma olasılığını artırır.

4.6.3 Epoch sayısı (Number of epochs)

Epoch sayısı, modelin eğitim verisi üzerinden kaç kez geçtiğini ifade eder. Bir epoch, modelin tüm eğitim veri setini baştan sona taramasını içerir. Epoch sayısının doğru belirlenmesi, modelin eğitim performansı üzerinde önemli bir etkiye sahiptir. Yetersiz epoch sayısı, modelin yeterli öğrenme gerçekleştirememesine yani “underfitting” sorununa yol açabilirken, çok yüksek epoch sayısı ise modelin eğitim verisine fazla

uyum sağlmasına yani “overfitting” sorununa sebep olabilir (Goodfellow ve diğ. Y. B., 2016) Genellikle 30, 50, 100 gibi değerlerle başlanır ve model performansına göre bu sayı artırılabilir veya azaltılabilir.

4.6.4 Batch boyutu (Batch size)

Batch boyutu, eğitim sırasında modelin her adımda kaç veri örneği üzerinden güncelleme yapacağını belirler. Büyük batch boyutları modelin daha dengeli bir gradyan güncellemesi yapmasını sağlarken, küçük batch boyutları modelin daha hızlı öğrenmesine olanak tanır. Genelde 32, 64 gibi batch boyutları seçilir, ancak veri setinin büyüklüğüne ve modelin kapasitesine göre bu değer optimize edilebilir. Küçük batch boyutları modelde bazı kararsızlıklara yol açabileceğinden dolayı, batch boyutunun doğru ayarlanması önemlidir (Keskar ve diğ, 2017).

4.6.5 Filtre boyutları (Filter sizes)

Konvolüsyonel sinir ağlarında kullanılan filtre boyutları, görüntülerin farklı ölçeklerdeki özelliklerini yakalamak için gereklidir. Filtre boyutları, modelin farklı ölçeklerdeki kenar, doku ve lezyon gibi özellikleri öğrenmesine olanak sağlar. Genellikle 3x3, 5x5 veya 7x7 gibi kare matrisler halinde seçilir. Küçük filtre boyutları detaylı bilgi yakalarken, büyük filtreler daha geniş yapıları yakalamada etkilidir (Krizhevsky ve diğ, 2012). Bu parametre, mikromanevrizmalar gibi küçük detayları tespit edebilmek için önemlidir.

4.6.6 Aktivasyon fonksiyonları

4.6.6.1 ReLU (Rectified linear unit):

ReLU fonksiyonu, negatif değerleri sıfıra sabitleyip pozitif değerleri geçiren bir aktivasyon fonksiyonudur. Bu, modelin gradyanların kaybolma problemi olmadan daha derin katmanları öğrenmesini sağlar ve CNN’lerde en çok tercih edilen aktivasyon fonksiyonlarından biridir. ReLU’nun bu özellikleri, modelin derin yapısında bilgiyi daha etkin öğrenmesini sağlar (Nair ve diğ, 2010).

4.6.6.2 Softmax

Softmax, son katmanda sınıflandırma işlemi için kullanılan aktivasyon fonksiyonudur. Sınıfların olasılık dağılımını verir ve modelin her sınıfa ait olasılığı hesaplamasını sağlar. DR sınıflandırması gibi çok sınıflı problemler için Softmax oldukça uygundur.

Softmax, tüm sınıfların olasılığını 0-1 arasında normalleştirerek toplam olasılığı 1'e eşitler, bu sayede model, her görüntünün hangi sınıfa ait olduğunu daha kesin bir şekilde belirler (Bridle ve diğ, 1990).

4.7 Değerlendirme Metrikleri

Bu çalışmada kullanılan modellerin başarılarının değerlendirilmesi için çeşitli performans metrikleri uygulanmıştır. Bu metrikler, sınıflandırma doğruluğu ve modelin genel performansı hakkında detaylı bilgi sağlayarak her bir modelin güçlü ve zayıf yönlerini belirlemede kritik bir rol oynamaktadır.

4.7.1 Doğruluk (Accuracy)

Modelin tüm tahminleri içerisindeki doğru tahminlerin oranını ifade eder. Genel performansın bir ölçütü olarak yaygın kullanılan bu metrik, özellikle veri sınıfları arasında dengeli bir dağılım varsa güvenilir sonuçlar vermektedir. Ancak, veri dengesizliği durumunda yanıltıcı olabilir (Karim ve Masud, 2013).

$$\text{Doğruluk} = \frac{\text{True Positives (TP)} + \text{True Negatives (TN)}}{\text{Total Number of Predictions}} \quad (4.1)$$

Denklem 4.1'de *True Positives (TP)* : Doğru şekilde pozitif olarak sınıflandırılan örneklerin sayısı

True Negatives (TN) : Doğru şekilde negatif olarak sınıflandırılan örneklerin sayısı

Total Number of Predictions : Tüm doğru ve yanlış sınıflandırmaların toplamı

(TP + TN + False Positives (FP) + False Negative (FN))

Accuracy, tüm sınıflandırmalar içindeki doğru tahminlerin oranını gösterir.

4.7.2 Hassasiyet (Precision)

Bir sınıf için yapılan tüm pozitif tahminlerin ne kadarının doğru olduğunu gösterir. Bu metrik, özellikle yanlış pozitiflerden kaçınmanın önemli olduğu durumlarda kullanılmaktadır. Yüksek hassasiyet, modelin belirli bir sınıfta doğru tahmin yapma yeteneğinin yüksek olduğunu gösterir (Öğündür ve Gülcan, 2018).

$$\text{Precision} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{FALSE POSITIVES (FP)}} \quad (4.2)$$

Denklem 4.2’de *True Positives (TP)* : Doğru bir şekilde pozitif olarak sınıflandırılan örneklerin sayısıdır.

False Positives (FP) : Yanlış bir şekilde pozitif olarak sınıflandırılan örneklerin sayısıdır.

Precision, pozitif olarak tahmin edilen örneklerin ne kadarının gerçekten doğru olduğunu gösterir.

4.7.3 Duyarlılık (Recall) yada elde etme oranı

Gerçek pozitiflerin ne kadarının doğru bir şekilde tespit edildiğini ifade eder. Özellikle, yanlış negatiflerin minimize edilmesinin önemli olduğu durumlarda tercih edilen bir metriktir. Yüksek duyarlılık, modelin ilgili sınıfta eksik tahmin yapma riskini azaltır (Öğündür ve Gülcan, 2018).

$$\text{Recall} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{FALSE Negatives (FN)}} \quad (4.3)$$

Denklem 4.3’te *True Positives (TP)* : Doğru şekilde pozitif olarak sınıflandırılan örneklerin sayısı

False Negatives (FN) : Gerçekte pozitif olan ancak yanlış bir şekilde negatif olarak sınıflandırılan örneklerin sayısı

Duyarlılık, modelin gerçek pozitifleri bulmadaki başarısını ölçen bir metriktir.

4.7.4 F1 skoru

Hassasiyet ve duyarlılık değerlerinin harmonik ortalaması olarak hesaplanır. F1 skoru, veri setinde dengesizlik olduğunda etkili bir ölçüt sağlar, çünkü hem yanlış pozitifleri hem de yanlış negatifleri dikkate alır. Hem hassasiyet hem de duyarlılık arasında denge kurarak modelin genel başarısını daha kapsamlı bir şekilde değerlendirmeyi mümkün kılar (Öğündür ve Gülcan, 2018).

$$\text{F1 Skoru} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4.4)$$

Denklem 4.4’te *Precision*: Doğru şekilde pozitif olarak sınıflandırılan örneklerin, pozitif olarak tahmin edilen tüm örneklere oranı

Recall : Gerçek pozitiflerin, model tarafından doğru bir şekilde pozitif olarak tahmin edilen kısmı

F1 Skoru, precision ve recall arasında bir denge sağlar ve her ikisinin de önemli olduğu durumlarda özellikle faydalıdır.

4.7.5 Karışıklık matrisi (Confusion matrix)

Modelin doğru ve yanlış sınıflandırmalarını sınıf bazında gösterir. Bu matris, modelin hangi sınıflarda daha başarılı veya başarısız olduğunu analiz etme imkanı sunar ve hata türlerini görselleştirir. Sınıflandırma performansını daha detaylı bir perspektiften anlamak için kullanılan önemli bir araçtır (Öğündür ve Gülcan, 2018).

Predicated Values		Actual Values	
		Positive	Negative
	Positive	TP	FP
	Negative	FN	TN

Şekil 4.5 : Karışıklık matrisi (Hossin ve diğ, 2015).

Şekil 4.5'te *TP (True Positive)* : Doğru pozitif, modelin bir örneği doğru bir şekilde pozitif sınıfa atadığı durum.

FP (False Positive) : Yanlış pozitif, modelin yanlış bir şekilde negatif bir örneği pozitif sınıfa atadığı durum.

FN (False Negative) : Yanlış negatif, modelin pozitif bir örneği yanlış bir şekilde negatif sınıfa atadığı durum.

TN (True Negative) : Doğru negatif, modelin bir örneği doğru bir şekilde negatif sınıfa atadığı durum.

Karışıklık Matrisi, modelin sınıflandırma başarısını daha ayrıntılı bir şekilde incelemeyi sağlar ve özellikle çok sınıflı sınıflandırma problemlerinde modelin performansını değerlendirirken çok kullanışlıdır.

4.8 Kullanılan Modellerde Hiperparametre Seçimi

VGG16, VGG19, Xception, InceptionV3 ve ResNet50 gibi derin öğrenme modelleri, başarılı bir şekilde sınıflandırma yapabilmek için dikkatlice seçilmiş hiperparametrelere ihtiyaç duyar. Bu modellerin her birinde, eğitim sürecinin doğruluğunu ve etkinliğini artırmak amacıyla belirli hiperparametre ayarları yapılmıştır. Örneğin, öğrenme oranı, epoch sayısı ve batch boyutu gibi parametreler, modelin genel performansını optimize etmek için özenle ayarlanmıştır.

Bu çalışmada, modelin eğitim süresi, öğrenme oranı ve batch boyutu gibi kritik hiperparametreler üzerinde yapılan optimizasyonlarla sınıflandırma performansı artırılmıştır. Özellikle öğrenme oranı, modelin doğruluğunu doğrudan etkileyen en önemli faktörlerden biri olarak belirlenmiş; küçük değişiklikler modelin doğruluğunu ve eğitim süresini büyük ölçüde etkilemiştir. Hiperparametrelerin doğru bir şekilde ayarlanması, modellerin diyabetik retinopati tespiti görevini istenilen doğrulukla gerçekleştirebilmesi için kritik öneme sahiptir.

Bu hiperparametreler dikkatlice seçilmediğinde, aşırı uyum (overfitting) veya yetersiz uyum (underfitting) gibi sorunlar ortaya çıkabilir. Bu nedenle, en uygun hiperparametrelerin belirlenmesi, derin öğrenme modellerinin başarısını önemli ölçüde artırmak için yapılması gereken temel bir adımdır (Szegedy ve diğ. V. V., 2016).

4.8.1 VGG16 ve VGG19 hiperparametre seçimi

VGG16 ve VGG19 modellerinin başarıya ulaşmasında, seçilen hiperparametreler önemli bir rol oynamaktadır. Bu hiperparametreler, modelin öğrenme kapasitesi, eğitim süresi ve genel performansını etkileyen temel faktörlerdir.

Çizelge 4.2'de, çalışmamız kapsamında diyabetik retinopati sınıflandırması amacıyla kullanılan VGG16 ve VGG19 modellerine ilişkin hiperparametre seçimleri sunulmuştur. Hiperparametrelerin doğru seçimi, modellerin karmaşık özellikleri doğru şekilde öğrenmesini sağlamak açısından büyük önem taşımaktadır. Çalışmamızda eğitim aşamasında giriş görüntü boyutu olarak 300x300 seçilmiştir. Bu boyut, yeterli detay sağlarken, aynı zamanda eğitim sürecini de optimize etmektedir. Modelde kullanılan öğrenme oranı (0.0001) ile model parametreleri güncellenirken stabil ve verimli bir öğrenme sağlanmıştır. Daha yüksek öğrenme oranları kararsızlığa neden olurken, çok düşük değerler modelin yavaş öğrenmesine sebep olabilmektedir. Batch

boyutu, her eğitim adımında kullanılan görüntü sayısını belirler ve 80 olarak seçilmiştir. Bu, bellek kullanımını dengeleyerek daha hızlı eğitim sağlarken, öğrenmeyi verimli hale getirmektedir. Epok sayısı olarak 50 belirlenmiş ve bu değer tüm veri setinin modele aktarılması ve öğrenme sürecinin tamamlanması için yeterli bir döngü sunmaktadır. Model, önceden eğitilmiş ImageNet ağırlıkları ile başlatılmış, böylece transfer öğrenme tekniğiyle doğruluğun artırılması hedeflenmiştir. Ayrıca, modelin son dört katmanı eğitilebilir şekilde bırakılarak üst katmanların özellik çıkarımı korunmuş, son katmanların eğitimi ile sınıflandırma performansı artırılmıştır.

Çizelge 4.2 : VGG16 ve VGG19 hiperparametre seçimi.

Hiperparametre	Değer	Açıklama
Eğitim Görüntü Boyutu	300x300	Modelin eğitim sırasında kullanılan görüntü boyutu.
Test Görüntü Boyutu	300x300	Modelin test sırasında kullanılan görüntü boyutu.
Öğrenme Oranı	0.0001	Modelin parametrelerini güncelleme hızını belirler; düşük bir değer stabil öğrenmeyi sağlar.
Batch Boyutu	80	Her eğitim adımında işlenen görüntü sayısı; bellek verimliliği ve eğitim süresi dengelenmiştir.
Epok Sayısı	50	Tüm veri setinin model tarafından kaç kez işlendiği; bu değer model doğruluğunu artırmak için optimize edilmiştir.
Model Ağırlıkları	"imagenet"	Model, önceden eğitilmiş ImageNet ağırlıklarıyla başlatılarak eğitim sürecinin hızlanması ve doğruluğun artırılması hedeflenmiştir.
Katmanların Dondurulması	Son 4 katman eğitilebilir	Modelin üst katmanları dondurularak temel özellik çıkarımı korunmuş, son katmanların eğitilmesi ile belirli özelliklerin öğrenilmesi sağlanmıştır.

Bu hiperparametre seçimleri, çalışmamızda kullanılan modellerin diyabetik retinopati sınıflandırması için yüksek doğruluk ve verimle çalışmasını sağlamak üzere özenle ayarlanmıştır.

4.8.2 ResNet50 hiperparametre seçimi

ResNet50 modelinin başarısı, eğitim sırasında doğru hiperparametrelerin dikkatlice seçilmesine bağlıdır. Bu parametreler, modelin karmaşıklığını, öğrenme hızını, bellek gereksinimlerini ve genel performansını doğrudan etkiler. Çalışmamızda ResNet50 için belirlenen hiperparametreler aşağıdaki gibidir:

Çizelge 4.3 : ResNet50 hiperparametreler seçimi.

Hiperparametre	Değer	Açıklama
Eğitim Görüntü Boyutu	300x300	Modelin eğitim sırasında kullanılan görüntü boyutu.
Test Görüntü Boyutu	300x300	Modelin test sırasında kullanılan görüntü boyutu.
Öğrenme Oranı	0.0001	Modelin parametrelerini güncelleme hızını belirler; düşük bir değer stabil öğrenmeyi sağlar.
Batch Boyutu	80	Her eğitim adımında işlenen görüntü sayısı; bellek verimliliği ve eğitim süresi dengelenmiştir.
Epok Sayısı	50	Tüm veri setinin model tarafından kaç kez işlendiği; bu değer model doğruluğunu artırmak için optimize edilmiştir.
Model Ağırlıkları	"imagenet"	Model, önceden eğitilmiş ImageNet ağırlıklarıyla başlatılarak eğitim sürecinin hızlanması ve doğruluğun artırılması hedeflenmiştir.
Katmanların Dondurulması	Son 4 katman eğitilebilir	Modelin üst katmanları dondurularak temel özellik çıkarımı korunmuş, son katmanların eğitilmesi ile belirli özelliklerin öğrenilmesi sağlanmıştır.

Çizelge 4.3'te eğitim sırasında, giriş görüntü boyutunun 300x300 piksel olarak belirlenmesi, modelin hem detaylı hem de ölçeklenebilir özellikler öğrenmesini sağlamıştır. Bu seçim, hesaplama maliyetlerini dengelerken, veri setindeki önemli görsel ipuçlarının korunmasına da olanak tanımıştır.

Modelin öğrenme oranı, aşamalı öğrenmeyi teşvik eden 0.0001 gibi düşük bir değerde sabitlenmiştir. Bu, modelin parametre güncellemelerini daha hassas bir şekilde yaparak aşırı öğrenme veya kararsızlık gibi olumsuzlukların önlenmesine yardımcı olmuştur. 80 görüntülük batch boyutu ise eğitim sırasında hem hesaplama yükünü

dengelemiş hem de modelin genelizasyon yeteneğini artırmıştır. Epok sayısı olarak belirlenen 50, veri setinin tamamının model tarafından etkin bir şekilde öğrenilmesine imkan tanımış ve erken durdurma stratejileriyle uyumlu bir yapı sergilemiştir. ResNet50'nin katmanlar arası atlamalı bağlantıları, vanishing gradient problemini minimize ederek derin ağlarda karşılaşılan temel zorlukların üstesinden gelmiştir. Bu yapı, diyabetik retinopati gibi karmaşık görsel sınıflandırma görevlerinde modelin hem doğruluk hem de dayanıklılık açısından üstün bir performans göstermesine katkı sağlamıştır.

4.8.3 CNN hiperparametre seçimi

CNN (Convolutional Neural Network) modellerinin başarısı, eğitim sırasında belirlenen hiperparametrelerin doğru bir şekilde ayarlanmasına bağlıdır.

Çizelge 4.4 : CNN hiperparametre seçimi.

Hiperparametre	Değer	Açıklama
Eğitim Görüntü Boyutu	150x150	Eğitim sırasında kullanılan giriş görüntü boyutu, modelin özellik çıkarımını optimize etmekte etkili olmuştur.
Konvolüsyonel Katman Sayısı	2	Modelde iki adet konvolüsyonel katman bulunmaktadır. Bu katmanlar, görüntüden özellik çıkarımında kritik rol oynar.
Max Pooling Boyutu	(2,2)	Max pooling katmanı ile görüntü boyutu, bu parametre ile 2x2 oranında küçültülmektedir, böylece modelin hesaplama yükü azaltılır.
Öğrenme Oranı	0.001	Öğrenme oranı, modelin ağırlıklarının güncellenme hızını belirler; bu çalışmada 0.001 olarak seçilmiştir. Yüksek bir oran, hızlı öğrenmeyi sağlarken, düşük bir oran yakınsama sürecini yavaşlatabilir.
Batch Boyutu	128	Her eğitim adımında işlenen görüntü sayısıdır. Daha büyük bir batch boyutu, daha hızlı eğitim sağlar, ancak bellek gereksinimlerini artırır.
Epok Sayısı	50	Tüm eğitim verisinin model tarafından kaç kez işleneceğini belirler. Bu çalışmada 50 epok tercih edilmiştir.
Tam Bağlantılı Katman Sayısı	1	Son katmanda bir adet tam bağlantılı katman bulunmaktadır, bu katman sınıflandırma işlemi için önemlidir.

Bu hiperparametreler, modelin mimarisini, öğrenme sürecini ve sonuçların doğruluğunu doğrudan etkiler. yukarıdaki tabloda, bu çalışmada kullanılan CNN modelinin hiperparametreleri ve açıklamaları yer almaktadır.

Çizelge 4.4'te sunulan hiperparametrelerin optimizasyonu, modelin performansını en üst seviyeye taşımak için stratejik olarak planlanmıştır. Eğitim sürecinde, giriş görüntü boyutunun 150x150 piksel olarak belirlenmesi, modelin gerekli görsel detayları yakalamasına olanak sağlamış, aynı zamanda hesaplama süresini ve kaynak kullanımını optimize etmiştir. Batch boyutunun 128 olarak seçilmesi, eğitim sırasında modelin verimli bir şekilde öğrenmesini sağlamış, aynı zamanda donanımsal sınırlamaları göz önünde bulundurmıştır. Bu ayar, her iterasyonda yeterli miktarda veri kullanılarak modelin genelleme yeteneğini artırmıştır. Epok sayısının 50 olması, modelin veri setindeki desenleri tam anlamıyla öğrenmesine olanak tanırken, fazla eğitimin önüne geçmek için dikkatle planlanmıştır. Eğitim sürecinde Adam optimizasyon algoritması tercih edilmiştir. Bu algoritma, adaptif öğrenme oranı sayesinde modelin hızlı ve kararlı bir şekilde öğrenmesini sağlamıştır. Özellikle doğruluk, hassasiyet ve kararlılık gibi metriklerde gözle görülür bir artış sağlanmıştır. Bu hiperparametre ayarlarının etkisi, modelin diyabetik retinopati gibi karmaşık sınıflandırma görevlerinde güvenilir ve tutarlı bir performans göstermesine olanak tanımıştır. Elde edilen sonuçlar, doğru hiperparametre seçimlerinin, derin öğrenme modellerinin başarısında ne denli kritik bir role sahip olduğunu bir kez daha ortaya koymaktadır.

4.8.4 InceptionV3 hiperparametre seçimi

InceptionV3 modelinin başarısı, eğitim sırasında belirlenen hiperparametrelerin doğru bir şekilde ayarlanmasına bağlıdır. Bu hiperparametreler, modelin mimarisini, öğrenme sürecini ve sonuçların doğruluğunu doğrudan etkiler. Aşağıda, bu çalışmada kullanılan InceptionV3 modelinin hiperparametreleri ve açıklamaları yer almaktadır. Çizelge 4.5'te Eğitim sürecinde giriş görüntü boyutunun 299x299 piksel olarak belirlenmesi, modelin önemli görsel detayları yakalamasını mümkün kılarken, hesaplama maliyetlerini kontrol altında tutmayı sağlamıştır. Batch boyutunun 32 olarak seçilmesi, modelin eğitim sırasında dengeli ve verimli bir şekilde çalışmasına olanak tanımıştır. Daha küçük batch boyutları, bellek yönetimini kolaylaştırmış ve modelin genelleme yeteneğini artırmıştır. Epok sayısının 30 olarak belirlenmesi ise

modelin yeterli öğrenme süresi bulmasını sağlamış, fazla eğitimi önlemek için uygun bir denge sunmuştur. Bu süreçte kullanılan Adam optimizasyon algoritması, modelin öğrenme oranını dinamik olarak düzenleyerek eğitim sırasında kararlılığı artırmış ve sonuçların daha hızlı iyileşmesini sağlamıştır. Ayrıca, dropout oranının %50 olarak belirlenmesi, aşırı öğrenme riskini azaltarak modelin genelleme kabiliyetini artırmıştır. Hiperparametrelerin bu şekilde özenle seçilmesi, modelin doğruluk, kesinlik ve geri çağırma gibi metriklerde istikrarlı sonuçlar elde etmesini sağlamıştır. Bu ayarlar, derin öğrenme modellerinde hiperparametre optimizasyonunun ne kadar önemli olduğunu bir kez daha ortaya koymaktadır ve farklı veri setleri ve görevler için de rehberlik edebilecek bir yaklaşım sunmaktadır.

Çizelge 4.5 : InceptionV3 hiperparametre seçimi.

Hiperparametre	Değer	Açıklama
Eğitim Görüntü Boyutu	299x299	InceptionV3 modelinin girdi boyutu olarak belirlenmiştir. Bu boyut, modelin karmaşıklığını ve detayları öğrenme yeteneğini artırmaktadır. Her eğitim adımında işlenen görüntü sayısını belirler. Daha büyük bir batch boyutu, eğitim süresini kısaltırken bellek kullanımını artırabilir.
Batch Boyutu	32	Modelin tüm veri setini yeterince öğrenmesi için uygun bir döngü sunar. 30 epok, eğitim sürecinin etkinliğini artırır.
Epok Sayısı	30	Modelin öğrenme sürecindeki güncellemeleri etkileyen bir parametredir. Adam optimizasyon algoritması ile otomatik olarak ayarlanmaktadır.
Öğrenme Oranı	-	Modelin öğrenme oranını otomatik olarak ayarlayarak eğitimi daha stabil ve etkili hale getirir.
Optimizasyon Yöntemi	Adam	Aşırı öğrenmeyi önlemek için kullanılan bir tekniktir. Bu değer, modelin genel performansını artırabilir.
Dropout Oranı	0.5	

Çizelge 4.5'te Eğitim sürecinde giriş görüntü boyutunun 299x299 piksel olarak belirlenmesi, modelin önemli görsel detayları yakalamasını mümkün kılarken, hesaplama maliyetlerini kontrol altında tutmayı sağlamıştır. Batch boyutunun 32 olarak seçilmesi, modelin eğitim sırasında dengeli ve verimli bir şekilde çalışmasına olanak tanımıştır. Daha küçük batch boyutları, bellek yönetimini kolaylaştırmış ve modelin genelleme yeteneğini artırmıştır. Epok sayısının 30 olarak belirlenmesi ise

modelin yeterli öğrenme süresi bulmasını sağlamış, fazla eğitimi önlemek için uygun bir denge sunmuştur. Bu süreçte kullanılan Adam optimizasyon algoritması, modelin öğrenme oranını dinamik olarak düzenleyerek eğitim sırasında kararlılığı artırmış ve sonuçların daha hızlı iyileşmesini sağlamıştır. Ayrıca, dropout oranının %50 olarak belirlenmesi, aşırı öğrenme riskini azaltarak modelin genelleme kabiliyetini artırmıştır. Hiperparametrelerin bu şekilde özenle seçilmesi, modelin doğruluk, kesinlik ve geri çağırma gibi metriklerde istikrarlı sonuçlar elde etmesini sağlamıştır. Bu ayarlar, derin öğrenme modellerinde hiperparametre optimizasyonunun ne kadar önemli olduğunu bir kez daha ortaya koymaktadır ve farklı veri setleri ve görevler için de rehberlik edebilecek bir yaklaşım sunmaktadır.

4.8.5 Xception hiperparametre seçimi

Xception modelinin başarısı, eğitim sırasında belirlenen hiperparametrelerin doğru bir şekilde ayarlanmasına bağlıdır. Aşağıda, bu çalışmada kullanılan Xception modelinin hiperparametreleri ve açıklamaları yer almaktadır.

Çizelge 4.6 : Xception hiperparametre seçimi.

Hiperparametre	Değer	Açıklama
Eğitim Görüntü Boyutu	299x299	Xception modelinin girdi boyutu olarak belirlenmiştir. Bu boyut, modelin karmaşıklığını ve detayları öğrenme yeteneğini artırmaktadır. Her eğitim adımında işlenen görüntü sayısını belirler. Bu değer, bellek kullanımı ve eğitim süresini optimize eder.
Batch Boyutu	32	Modelin tüm veri setini yeterince öğrenmesi için uygun bir döngü sunar. 30 epok, eğitim sürecinin etkinliğini artırır.
Epok Sayısı	30	Modelin öğrenme sürecindeki güncellemeleri etkileyen bir parametredir. Adam optimizasyon algoritması ile otomatik olarak ayarlanmaktadır.
Öğrenme Oranı	-	Modelin öğrenme oranını otomatik olarak ayarlayarak eğitimi daha stabil ve etkili hale getirir.
Optimizasyon Yöntemi	Adam	Aşırı öğrenmeyi önlemek için kullanılan bir tekniktir. Bu değer, modelin genel performansını artırabilir.
Dropout Oranı	0.5	

Çizelge 4.6’da sunulan hiperparametreler, Xception modelinin diyabetik retinopati tespiti gibi karmaşık bir sınıflandırma probleminde etkin bir şekilde performans göstermesini sağlamak amacıyla titizlikle seçilmiştir. Giriş görüntü boyutunun 299x299 piksel olarak belirlenmesi, modelin ince detayları yakalamasını sağlarken, daha büyük boyutların getireceği işlem yükünü sınırlandırmaktadır. Batch boyutunun 32 olması, modelin her adımda yeterli miktarda veriyle öğrenmesini destekleyerek hesaplama verimliliğini artırmıştır. Epok sayısının 30 olarak belirlenmesi ise modelin eğitim süresi boyunca yeterli düzeyde öğrenme gerçekleştirmesine imkân sağlamış, aynı zamanda aşırı eğitim riskini de minimize etmiştir. Bu çalışma kapsamında kullanılan Adam optimizasyon algoritması, modelin öğrenme oranını dinamik olarak düzenlemiş ve bu sayede daha dengeli bir öğrenme süreci sağlanmıştır. Dropout oranının %50 olarak seçilmesi, özellikle aşırı uyum problemini önlemekte etkili bir rol oynamış ve modelin farklı veri örneklerinde genelleme yapma kabiliyetini güçlendirmiştir. Xception modelinde gerçekleştirilen bu hiperparametre ayarlamaları, sınıflandırma doğruluğu ve metriklerde önemli bir iyileşme sağlamıştır. Bu ayarlar, Xception’ın hem derin hem de geniş yapısının avantajlarını en iyi şekilde kullanabilmesi için kritik bir temel oluşturmuştur. Her model ve veri seti için benzer optimizasyon süreçleri, başarılı bir sonuç elde etmenin anahtarı olarak görülmektedir.

4.9 Eğitim Süreci ve Kıyaslama

Çalışmada hem orijinal veri seti hem de CLAHE ile ön işleme uygulanmış veri seti kullanılarak eğitim gerçekleştirilmiştir. Bu süreçte, CLAHE ön işleme yönteminin model doğruluğunu artırdığı ve orijinal veri setine kıyasla daha yüksek doğruluk oranları elde edildiği gözlemlenmiştir.

4.10 Web Arayüzü Uygulaması

Bu çalışmada geliştirilen derin öğrenme modeli ile DR tespitinin hekimler tarafından kolayca tespit edilmesi için kullanıcı dostu bir web arayüzü geliştirilmiştir. Bu arayüzün geliştirilmesindeki amaç, diyabetik retinopati tespit sürecini hızlandırmak, doğruluk oranını artırarak erken teşhise katkı sağlamak ve sağlık profesyonellerinin iş yükünü azaltmaktır. Geliştirilen web arayüz ana ekrana şekil 4.6’de görülmektedir.

 Diyabetik Retinopati Tespiti

Retina görüntülerini analiz ederek diyabetik retinopati belirtilerini tespit edin

Bu uygulama, retina görüntülerini diyabetik retinopati belirtileri için sınıflandırmak için derin öğrenme kullanır.

Retina Görüntüsünü Yüklemek İçin Sürükleyin ve Bırakın veya Tıklayın (JPEG, PNG, JPG)



Drag and drop file here

Limit 200MB per file • JPEG, JPG, PNG

Browse files

© 2024 Diyabetik Retinopati Tespiti | Yöneten: Ravan Bektaş | E-posta: ravanbektas@gmail.com

Mühendislik ve Doğa Bilimleri Fakültesi | Bilgisayar Mühendisliği Bölümü

Şekil 4.6 : Web arayüz ana sayfa.


Uygulama, girdi görüntülerini alıp Diyabetik Retinopati sınıflandırması yapar ve gerçek zamanlı sonuçlar sunar. Bu sistem, Python programlama dili ve Streamlit kütüphanesi kullanılarak Visual Studio Code ortamında inşa edilmiştir. Streamlit, veri görselleştirme ve etkileşimli web uygulamaları oluşturmak için tercih edilen bir araç olup, kullanıcıların modelin performansını kolayca gözlemlemesine imkan tanımaktadır. Python ise, güçlü kütüphaneleri ve derin öğrenme framework'leri ile bu tür yapay zekâ tabanlı uygulamaların geliştirilmesinde yaygın olarak kullanılmaktadır. Geliştirilen sistem, diyabetik retinopatinin çeşitli evrelerini doğru bir şekilde sınıflandırarak, göz hastalıklarının erken teşhisine yardımcı olmayı amaçlamaktadır. İlk olarak, bir görüntü işleme modeli eğitilmiştir. VGG16+CLAHE modeli kullanılarak verimli bir derin öğrenme modeli oluşturulmuştur. Bu süreç sonunda, model .h5 dosyası formatında kaydedildi. Daha sonra bu modelin görevleri, Jupyter Notebook'ta örnek görüntüler yüklenerek test edilmiştir. Kullanıcı dostu ve etkileşimli bir uygulama geliştirmek için Streamlit gücünden yararlanılmıştır. Streamlit, veri bilimi ve makine öğrenimi projeleri için etkileşimli web uygulamaları oluşturmayı sağlayan güçlü bir Python kütüphanesidir. Geliştiriciler, ileri düzey web geliştirme bilgisine ihtiyaç duymadan uygulamalarını kolayca oluşturabilir ve dağıtabilir. Streamlit, kullanıcı dostu bir arayüz ve önceden tanımlanmış birçok bileşen sunarak veri odaklı uygulama geliştirme sürecini basitleştirir.

Streamlit 'in Temel Özellikleri

- Kullanımı kolay arayüz

- Veri görselleştirme için etkileşimli widget'lar
- Pandas ve Matplotlib gibi popüler veri bilimi kütüphanelerine destek
- Anında güncellemeler için otomatik yenileme
- Sorunsuz dağıtım seçenekleri

Şekil 4.7’de web arayüze ait çalışma akış diyagramı görülmektedir



Şekil 4.7 : Uygulama oluşturma süreçlerini açıklayan akış şeması.

Uygulamanın arayüzüne giriş yapıldıktan sonra bir dil seçiminin yapılması gerekmektedir. Kullanıcılara Türkçe ve İngilizce olmak üzere iki seçenek sunulmaktadır. Dil seçminden sonra arayüzden görüntü okutulur. Sistem çalıştırılır arka planda derin öğrenme modeli ile sınıflandırma gerçekleştirilir ve sonuç ekranda gösterilir. Doktorlar isterlerse sistemden detaylı bir PDF raporu indirebilir. Bu PDF raporunda, raporun tarihi, hastanın fundus görüntüsü, tespit edilen diyabetik retinopati sınıfı ve elde edilen doğruluk gibi önemli bilgiler yer alacaktır ve bu çalışmanın Bursa teknik üniversitesi bilgisayar mühendisliği bölümüne ait olduğunu belirtilen bir logosu göstermektedir.

5. DENEYSEL SONUÇLAR

Uygulama, örnek görüntülerle test edilerek gerçek zamanlı performansı değerlendirilmiştir. Bu test sırasında görüntüler, aşağıdaki sınıflar arasında sınıflandırılır:

0- No DR (Diyabetik Retinopati Yok) : Gözde diyabetik retinopati belirtileri bulunmaz.


1- Mild NPDR (Hafif Non-proliferatif Diyabetik Retinopati) : Küçük Mikroanevrizmalar gibi hafif belirtiler gözlenir.

2- Moderate NPDR (Orta Derecede Non-proliferatif Diyabetik Retinopati) : Mikroanevrizmalar, intraretinal hemorajiler ve sert eksüdalar bulunur.

3- Severe NPDR (Şiddetli Non-proliferatif Diyabetik Retinopati) : Çok sayıda mikroanevrizma, intraretinal mikrovasküler anormallikler ve ciddi hemorajiler tespit edilir.


4- PDR (Proliferatif Diyabetik Retinopati) : Yeni damar oluşumları ve vitreus kanamaları gibi ileri seviye retinopati belirtileri vardır.

Şekil 5.1’de görüldüğü gibi web arayüzden öncelikli olarak sınıflandırmak istenilen fundus görüntüsü okutulur.



Şekil 5.1 : Sınıflandırmak için resim seçin.

Görüntü okutulduktan sonra sistem, arka planda otomatik çalışarak sınıflandırma işlemini gerçekleştirir ve şekil 5.2’de görüldüğü gibi sonuç ekranı çıkartır.



Şekil 5.2 : Seçilen görüntüyü sınıflandırın ve doğruluğunu görüntüleyin.

Eğer hekim sonuçları bir pdf dokümanı olarak görmek isterse arayüz üzerindeki “pdf oluştur” isimli butona basılır ve şekil 5.3’te görüldüğü gibi doküman elde edilir.

Diyabetik Retinopati Tespiti Raporu

Oluşturulma Tarihi: 2025-01-27 18:30:56

Yüklenen Görüntü:



Sonuç: Level 4- Proliferatif Diyabetik Retinopati (PDR)

Doğruluk Oranı: 99.93%

Bu rapor, retina görüntüsünün diyabetik retinopati için analizini sağlar. Eğer tahmin güveni düşükse, ek tıbbi danışmanlık önerilir. Bu analiz, retina görüntülerindeki diyabetik retinopati belirtilerini tanımak için eğitilmiş derin öğrenme algoritmalarına dayanmaktadır. Son tanı ve tedavi planı için mutlaka bir göz doktoru veya sağlık uzmanı ile iletişime geçilmesi gereklidir.

Şekil 5.3 : Rapor çıktısı.

Doküman üzerinde oluşturma tarihi, yüklenen görüntü, sonuç ve sonucun doğruluk oranı yer almaktadır.

Bu çalışmada gerçekleştirilen tüm test sonuçları bu bölümde değerlendirilmiştir. Deneylerde kullanılan farklı derin öğrenme modelleri ve ön işleme yöntemleri karşılaştırılacak, her bir modelin doğruluk, hassasiyet ve duyarlılık gibi çeşitli metriklerle performansları değerlendirilecektir. Elde edilen sonuçlar üzerinden model performansları tartışılacak, ön işleme tekniklerinin sınıflandırma doğruluğu üzerindeki etkisi incelenecektir. Çalışmanın bulguları, seçilen modellerin güçlü ve zayıf yönlerini ortaya koyarken, ön işleme yöntemlerinin model performansını nasıl optimize ettiği üzerine de kapsamlı bir analiz sunulacaktır.

Çizelge 5.1’de farklı derin öğrenme mimarilerinin (VGG16, VGG19, CNN, Xception, InceptionV3, ResNet50) görüntü sınıflandırma görevlerindeki performansları, CLAHE ön işleme yöntemi ile birlikte incelenmiştir. Elde edilen sonuçlar, her modelin genel başarı oranını göstermektedir:

Çizelge 5.1 : Deneysel sonuçlar.

Modeller	Doğruluk
VGG16	%93
VGG16+CLAHE	%99
VGG19	%66
VGG19+CLAHE	%74
CNN	%94
CNN+CLAHE	%99
Xception	%55
Xception+CLAHE	%67
InceptionV3	%55
InceptionV3+CLAHE	%53
RESNET50	%21
RESNET50+CLAHE	%22

Sonuçlar, VGG16 ve CNN modellerinin, CLAHE ile ön işleme uygulandığında %99 oranına ulaşarak en yüksek başarıyı elde ettiğini göstermektedir. VGG16 ve CLAHE kombinasyonunun sağladığı %99'luk doğruluk, bu modelin görüntü özelliklerini etkili bir şekilde çıkarabildiğini ve CLAHE uygulamasının model performansını belirgin şekilde artırdığını göstermektedir. Diğer yandan, VGG19 ve CNN gibi modellerin, CLAHE ön işleme ile performanslarında kayda değer bir artış yaşandığı gözlemlenmiştir.

Xception ve InceptionV3 modellerinin sonuçları ise, beklentinin altında kalmış olup, sırasıyla %55 ve %53 oranlarında sınıflandırma doğruluğu sağlamıştır. Bu, derin öğrenme mimarilerinin karmaşıklığının, belirli bir veri setinde istenilen sonuçları vermeyebileceğini ortaya koymaktadır. Özellikle, ResNet50'nin düşük başarı oranı (%21), bu modelin bu çalışma bağlamında yetersiz kaldığını ve hiperparametre ayarlamaları veya veri setinin niteliği ile ilgili potansiyel sorunların olabileceğini düşündürmektedir.

CLAHE ön işleme yöntemi uygulandığında, VGG16 ve CNN modellerinin performanslarında kayda değer bir iyileşme görülmesi, bu ön işlemenin veri kalitesini artırmada önemli bir rol oynadığını göstermektedir. Elde edilen sonuçlar, derin öğrenme modellerinin etkinliğinin, kullanılan mimari ve veri ön işleme teknikleriyle doğrudan ilişkili olduğunu ortaya koymaktadır.

Gelecek çalışmalar, farklı veri setleri ve daha fazla model ile karşılaştırmalar yaparak, bu modellerin genel geçerliliğini ve uygulama potansiyelini artırmayı hedefleyebilir.

5.1 Önerilerin Eğitim Senaryoları

Bu çalışmada, görüntü sınıflandırma performansını artırmak amacıyla çeşitli derin öğrenme modelleri ve ön işleme teknikleri uygulanmıştır.

Özellikle CLAHE tekniği, düşük kontrastlı ve homojen yapıya sahip görüntülerde kontrastı artırarak modelin öğrenme kapasitesini yükseltmeyi hedeflemektedir. Bu ön işleme yöntemi, modelin detayları daha iyi yakalayabilmesi ve sınıflandırma doğruluğunun artması için kullanılmıştır.

Elde edilen sonuçlar, her bir modelin CLAHE ön işlemesi ile performansında belirgin artış olduğunu göstermektedir. Örneğin, VGG16 modeli CLAHE kullanıldığında doğruluğunu %92'den %99'a yükseltmiştir. Benzer şekilde, CNN modeli de %94 doğruluk seviyesinden %99 seviyesine ulaşmıştır. Bununla birlikte, bazı modellerde CLAHE'nin etkisi sınırlı kalmıştır. InceptionV3 ve ResNet50 modelleri bu doğrultuda daha düşük performans göstermiş ve CLAHE ön işlemesi ile beklenen doğruluk artışını sağlamamıştır.

Bu deneysel çalışma, çeşitli derin öğrenme modelleri ve ön işleme tekniklerinin etkilerini ayrıntılı olarak inceleyerek, hangi kombinasyonların en yüksek doğruluğa ulaştığını ortaya koymaktadır.

5.2 VGG-16 Eğitiminin Sonuçları

Bu senaryoda, VGG16 modelini temel alarak görüntü sınıflandırma işlemi gerçekleştirilmiştir. VGG16, derin öğrenme alanında yaygın olarak kullanılan bir Konvolüsyonel sinir ağıdır ve 16 katmandan oluşmaktadır. Eğitimin ilk aşamasında, modelden 9x9x512 boyutunda bir özellik haritası çıkarılmıştır. Bu harita, görsel verilerden elde edilen önemli özellikleri temsil etmekte olup, sonraki aşamalarda kullanılmak üzere düzeltilmiştir.

Çizelge 5.2 : Modelin mimarisi

Katman (tür)	Çıkış Şekli	Parametre
VGG16 (Fonksiyonel)	(None, 9, 9, 512)	14714688
Flatten_1 (Flatten)	(None, 41472)	0
Dense_3 (Yoğun)	(None, 256)	10617088
Dropout_2 (Bırakma)	(None, 256)	0
Dense_4 (Yoğun)	(None, 128)	32896
Dropout_3 (Bırakma)	(None, 128)	0
Dense_5 (Yoğun)	(None, 5)	645
Toplam parametreler: 25,365,317		
Eğitilebilir parametreler: 17,730,053		
Eğitilemeyen parametreler: 7,635,264		

Çizelge 5.2’de bu mimari, modelin öğrenme yeteneğini artırmakta ve daha derin katmanlarla daha karmaşık özelliklerin öğrenilmesine olanak tanımaktadır. Eğitimin sonunda elde edilen doğruluk başarı oranları aşağıdaki gibidir:

VGG16: %92

VGG16 + CLAHE: %99

Sonuçlar, VGG16 modelinin, özellikle CLAHE ile kombinlediğinde, sınıflandırma performansında önemli bir iyileşme sağladığını göstermektedir. CLAHE uygulaması, görüntülerin kontrastını artırarak modelin daha iyi performans göstermesine yardımcı olmuştur.

Bu bulgular, VGG16’nın derin öğrenme uygulamalarında ne denli etkili olduğunu ve görsel veri setlerinde elde edilen sonuçların, modelin mimarisine ve ön işleme tekniklerine bağlı olarak nasıl değişebileceğini ortaya koymaktadır. Elde edilen sonuçların, derin öğrenme literatüründe mevcut yöntemlerle karşılaştırıldığında oldukça umut verici olduğu söylenebilir.

VGG16 tabanlı derin öğrenme (DL) modelinin eğitim ve doğrulama sürecine ait doğruluk ve kayıp eğrileri, diyabetik retinopati tespitinde elde edilen sonuçları


görselleştirmekte önemli bir rol oynamaktadır. Aşağıda, bu eğrilerin analizi ile ilgili bilgiler sunulmaktadır:

Eğitim sürecinde modelin doğruluk oranı zamanla artış gösterirken, kayıp değeri ise azalmaktadır. Bu durum, modelin verilerden öğrenme kapasitesinin arttığını ve overfitting (aşırı uyum) riskinin düşük olduğunu göstermektedir. Eğriler, eğitim ve doğrulama aşamalarında elde edilen performansın karşılaştırılmasını sağlamaktadır.


Aşağıdaki görseller, VGG16 tabanlı DL modelinin eğitim ve doğrulama doğruluğu ile kayıp eğrilerini göstermektedir:

Eğitim ve Doğrulama Doğruluğu Eğrisi : Modelin eğitim süresince doğruluk oranının nasıl değiştiğini gösterir. Bu eğri, modelin öğrenme sürecinin etkinliğini değerlendirmek için önemli bir göstergedir (Şekil 5.4).

Eğitim ve Doğrulama Kaybı Eğrisi : Modelin kayıp değerinin zaman içindeki seyrini gösterir. Eğitim kaybının düşmesi, modelin veriye iyi bir uyum sağladığını, doğrulama kaybının ise modelin genelleme yeteneğini yansıtmaktadır (Şekil 5.5).



Şekil 5.4 : VGG16 modelinin eğitim ve doğrulama doğruluk eğrileri.



Şekil 5.5 : VGG16 modelinin eğitim ve doğrulama kayıp eğrileri.

Bu eğrilerin analizi, VGG16'nın diyabetik retinopati tespitindeki etkinliğini ve modelin genel performansını değerlendirmek açısından kritik öneme sahiptir. Ek olarak, eğitim ve doğrulama sonuçlarının izlenmesi, gelecekteki iyileştirmeler için önemli bilgiler sunmaktadır.

VGG16 tabanlı derin öğrenme modelinin performansını değerlendiren kesinlik, geri çağırma ve F1 puanı sonuçları aşağıda sunulmuştur. Bu metrikler, modelin her bir diyabetik retinopati evresindeki başarısını detaylı bir şekilde göstermektedir.

Çizelge 5.3 : VGG-16 test sonuçları.

Modeller	Sınıflar	Kesinlik	%Duyarlılık	%F1-Skoru	%Test örneği sayısı
VGG16	0	0.70	0.93	0.80	180
	1	0.55	0.39	0.46	180
	2	0.47	0.43	0.45	180
	3	0.79	0.82	0.81	180
	4	0.89	0.89	0.89	180

Çizelge 5.3'de sonuçların, *Sıfırıncı Evre (0)* : Model, bu evrede yüksek bir geri çağırma oranı (%93) ve sağlam bir kesinlik (%70) elde etmiştir. Bu durum, modelin sağlıklı gözlerin doğru tespiti konusunda oldukça etkili olduğunu göstermektedir.

Birinci Evre (1) : Kesinlik %55 gibi düşük bir değerle sonuçlanırken, geri çağırma oranı %39'dur. Bu, modelin bu evredeki pozitif örnekleri tespit etme konusunda zayıf kaldığını göstermektedir.

İkinci Evre (2) : Her iki metrik de (%47 kesinlik ve %43 geri çağırma) düşüktür. Bu, modelin diyabetik retinopatinin orta düzeydeki etkilerini tanımakta zorlandığını işaret etmektedir.

Üçüncü Evre (3) : Bu evrede model, yüksek bir kesinlik (%79) ve geri çağırma (%82) oranı göstermektedir. Bu sonuç, modelin ağır vakaları tespit etme yeteneğinin oldukça iyi olduğunu ortaya koymaktadır.

Dördüncü Evre (4) : Son olarak, dördüncü evrede model, hem kesinlik (%89) hem de geri çağırma (%89) ile etkileyici bir performans sergilemektedir. Bu, modelin ciddi diyabetik retinopati vakalarını doğru bir şekilde tanımlamada başarılı olduğunu göstermektedir.

Bu sonuçlar, VGG16 tabanlı derin öğrenme modelinin diyabetik retinopati tespitinde değişen evreler için nasıl performans gösterdiğini açıkça ortaya koymaktadır.

Özellikle 0 ve 4. evrelerdeki yüksek metrikler, modelin belirli durumlarda etkinliğini vurgulamaktadır. Ancak, 1. ve 2. evrelerdeki düşük sonuçlar, modelin bu alanlarda daha fazla geliştirilmesi gerektiğini işaret etmektedir.

Çizelge 5.4 : VGG-16+CLAHE test sonuçları.

Modeller	Sınıflar	Kesinlik	%Duyarlılık	%F1-Skoru	%Test örneği sayısı
VGG16+CLAHE	0	0.60	1.00	0.75	180
	1	0.52	0.32	0.39	180
	2	0.39	0.23	0.29	180
	3	0.78	0.86	0.82	180
	4	0.87	0.90	0.89	180

Çizelge 5.4'te *Sıfırıncı Evre (0)* : Model, bu evrede yüksek bir geri çağırma oranı (%100) ve sağlam bir kesinlik (%60) elde etmiştir. Bu, modelin sağlıklı gözlerin doğru tespiti konusunda oldukça etkili olduğunu ve doğru negatifleri yüksek başarıyla ayırt ettiğini göstermektedir.

Birinci Evre (1) : Kesinlik %52 gibi düşük bir değerle sonuçlanırken, geri çağırma oranı %32'dir. Bu, modelin bu evredeki pozitif örnekleri tespit etme konusunda zayıf kaldığını ve sınıf dengesizliği ya da düşük kontrastlı örneklerin model tarafından zor tanındığını göstermektedir.

İkinci Evre (2) : Her iki metrik de (%39 kesinlik ve %23 geri çağırma) düşük seviyededir. Bu, modelin orta düzeydeki diyabetik retinopati vakalarını tanımakta zorlandığını ve sınıfın daha az belirgin özelliklerine sahip olduğunu gösterir.

Üçüncü Evre (3) : Bu evrede model, yüksek bir kesinlik (%78) ve geri çağırma (%86) oranı göstermektedir. Bu sonuç, modelin ağır vakaları tespit etme konusunda oldukça iyi bir performans sergilediğini ve bu tür vakaların doğru şekilde sınıflandırıldığını ortaya koymaktadır.

Dördüncü Evre (4) : Son olarak, dördüncü evrede model, hem kesinlik (%87) hem de geri çağırma (%90) ile etkileyici bir performans sergilemektedir. Bu, modelin ciddi diyabetik retinopati vakalarını doğru bir şekilde tanımlamada başarılı olduğunu göstermektedir.

Bu sonuçlar, VGG16+CLAHE modelinin diyabetik retinopati tespitinde farklı evreler için nasıl performans gösterdiğini açıkça ortaya koymaktadır. Özellikle 0 ve 4. evrelerdeki yüksek metrikler, modelin belirli durumlarda etkinliğini vurgulamaktadır.

Ancak, 1. ve 2. evrelerdeki düşük performans, modelin bu alanlarda daha fazla geliştirilmesi gerektiğini işaret etmektedir. Bu durum, modelin orta seviyedeki ve düşük kontrastlı vakaları daha iyi tanıyabilmesi için daha fazla eğitim verisi veya model iyileştirmelerine ihtiyaç duyduğunu göstermektedir.

5.3 VGG-19 Eğitiminin Sonuçları

Bu senaryoda, diyabetik retinopati tespiti için temel model olarak VGG19 kullanılmıştır. VGG19, derin öğrenme mimarisi olarak, 19 katmanlı bir yapıya sahiptir ve bu yapı sayesinde karmaşık görsel verilerin işlenmesinde etkili bir performans sergilemektedir. Aşağıda modelin yapısı ve parametreleri detaylandırılmaktadır.

Çizelge 5.5 : Model özellikleri.

Katman (tür)	Çıkış Şekli	Parametre
VGG19 (Fonksiyonel)	(None,9 ,9 512)	20024384
Flatten_1(Falatten)	(None, 41472)	0
Dense_3 (Yoğun)	(None, 256)	10617088
Dropout_2 (Bırakma)	(None, 256)	0
Dense_4 (Yoğun)	(None,128)	32896
Dropout_3 (Bırakma)	(None,128)	0
Dense_5 (Yoğun)	(None,5)	645
Toplam parametreler: 30,675,013		
Eğitilebilir parametreler: 17,730,053		
Eğitilemeyen parametreler: 7,635,264		

Çizelge 5.5'te VGG19 modelinin çıkışı, 9x9x512 boyutunda bir özellik haritası şeklinde elde edilmiştir. Bu özellik haritası, görsel verilerden çıkarılan önemli özellikleri temsil eder ve sonraki aşamalarda düzleştirilmiştir.

Eğitimin sonunda elde edilen doğruluk başarı oranları şu şekildedir:

VGG19: %66

VGG19 + CLAHE: %74

VGG19 modelinin performansı, CLAHE (Contrast Limited Adaptive Histogram Equalization) ile birleştirildiğinde belirgin bir iyileşme göstermiştir. CLAHE, görüntülerin kontrastını artırarak modelin daha iyi performans sergilemesine yardımcı olmuştur. Bu bulgular, VGG19'un derin öğrenme uygulamalarındaki etkinliğini ve

görsel veri setlerinde elde edilen sonuçların, modelin mimarisine ve ön işleme tekniklerine bağlı olarak nasıl değişebileceğini göstermektedir.

Sonuçların, VGG19 modelinin kesinlik, geri çağırma ve F1 puanı metrikleri üzerinden yapılan analiz aşağıdaki gibidir:

Çizelge 5.6 : VGG-19 test sonuçları.

Modeller	Sınıflar	Kesinlik	%Duyarlılık	%F1-Skoru	%Test örneği sayısı
VGG19	0	0.47	0.88	0.61	180
	1	0.44	0.17	.025	180
	2	0.33	0.33	0.33	180
	3	0.72	0.56	0.63	180
	4	0.80	0.76	0.78	180

Çizelge 5.6'da *Sıfırıncı Evre (0)* : Model, bu evrede yüksek bir geri çağırma oranı (88%) elde ederken, kesinlik oranı %47 olarak belirlenmiştir. Bu, modelin sağlıklı gözleri doğru tespit etme konusunda etkili olduğunu göstermektedir.

Birinci Evre (1) : Kesinlik %44 ve geri çağırma %17 ile düşük kalmıştır. Bu durum, modelin bu evredeki pozitif örnekleri tespit etme konusunda zayıf olduğunu ortaya koymaktadır.

İkinci Evre (2) : Her iki metrik de düşük olup, %33 kesinlik ve %33 geri çağırma ile sonuçlanmıştır. Bu, modelin orta düzeydeki diyabetik retinopatinin etkilerini tanımlama zorluk yaşadığını göstermektedir.

Üçüncü Evre (3) : Bu evrede modelin kesinliği %72 ve geri çağırma %56'dır. Model, ağır vakaları tespit etme yeteneği açısından orta düzeyde bir performans göstermektedir.

Dördüncü Evre (4) : Model, bu evrede hem kesinlik (%80) hem de geri çağırma (%76) ile etkileyici bir performans sergilemiştir. Ciddi diyabetik retinopati vakalarını doğru bir şekilde tanımlamada başarılı olduğu anlaşılmaktadır.

VGG19 modelinin diyabetik retinopati tespitindeki değişen evrelerdeki performansı, modelin belirli durumlarda etkinliğini vurgularken, düşük sonuçlar gösteren evreler, daha fazla geliştirme gerektiren alanları işaret etmektedir. Sonuçlar, derin öğrenme alanındaki literatüre katkı sağlamakta ve gelecekteki çalışmalara yön vermektedir.

Çizelge 5.7 : VGG-19+CLAHE test sonuçları.

Modeller	Sınıflar	Kesinlik	%Duyarlılık	%F1-Skoru	%Test örneği sayısı
VGG19+CLAHE	0	0.46	0.88	0.61	180
	1	0.42	0.28	0.33	180
	2	0.34	0.27	0.30	180
	3	0.83	0.58	0.68	180
	4	0.84	0.77	0.80	180

Çizelge 5.7’de *Sıfırıncı Evre (0)* : Model, bu evrede %88 geri çağırma oranı ile yüksek bir doğruluk gösterirken, kesinlik %46’dır. Bu, modelin sağlıklı gözlerin doğru tespiti konusunda güçlü bir performans sergilediğini, ancak aynı zamanda fazla pozitif sonuçlar üreterek yanlış pozitifleri artırabileceğini göstermektedir.

Birinci Evre (1) : Kesinlik %42 ile düşük bir seviyededir ve geri çağırma oranı %28’dir. Bu, modelin bu evredeki pozitif örnekleri tespit etme konusunda zayıf kaldığını, özellikle 1. evredeki diyabetik retinopatinin tespiti konusunda iyileştirme yapılması gerektiğini göstermektedir.

İkinci Evre (2) : Bu evrede kesinlik %34 ve geri çağırma oranı %27 gibi düşük değerlerde kalmaktadır. Bu, modelin orta düzeydeki diyabetik retinopatinin tanımlanmasında zorluk yaşadığını, sınıfın belirgin olmayan özellikleri nedeniyle daha fazla iyileştirme yapılması gerektiğini göstermektedir.

Üçüncü Evre (3) : Üçüncü evrede model, %83 kesinlik ve %58 geri çağırma oranı ile daha güçlü bir performans sergileyerek, ağır vakaların tespitinde başarıya ulaşmaktadır. Ancak, geri çağırma oranının biraz daha düşük olması, bazı pozitif vakaların kaçırıldığını gösteriyor olabilir.


Dördüncü Evre (4) : Dördüncü evrede model, %84 kesinlik ve %77 geri çağırma oranlarıyla etkileyici bir performans göstermektedir. Bu, modelin ciddi diyabetik retinopati vakalarını doğru bir şekilde tanıma konusunda başarılı olduğunu ortaya koymaktadır. Bu sonuçlar, VGG19+CLAHE modelinin diyabetik retinopati tespitinde farklı evreler için nasıl performans gösterdiğini göstermektedir. Özellikle 0. ve 4. evrelerde yüksek metrikler, modelin belirli durumlarda etkinliğini vurgulamaktadır. Ancak, 1. ve 2. evrelerdeki düşük metrikler, modelin bu evrelerdeki pozitif örnekleri daha iyi tanıyabilmesi için geliştirilmesi gerektiğini işaret etmektedir. Bu durum,

modelin orta düzey ve daha az belirgin vakaları daha iyi tanıyabilmesi için daha fazla veri veya model iyileştirmeleri gerektirdiğini göstermektedir.


Aşağıdaki görseller, VGG19 tabanlı derin öğrenme (DL) modelinin eğitim ve doğrulama doğruluğu ile kayıp eğrilerini göstermektedir:

Eğitim ve Doğrulama Kaybı Eğrisi : Bu eğri, modelin kayıp değerinin zaman içindeki seyrini göstermektedir. Eğitim kaybının düşmesi, modelin veriye iyi bir uyum sağladığını, doğrulama kaybının ise modelin genelleme yeteneğini yansıttığını göstermektedir. Aşağıda ilgili VGG19 modeline ait görseller yer almaktadır (Şekil 5.6).

Eğitim ve Doğrulama Doğruluğu Eğrisi : Bu eğri, modelin eğitim süresi boyunca doğruluk oranının nasıl değiştiğini gösterir. Modelin öğrenme sürecinin etkinliğini değerlendirmek için kritik bir göstergedir. Yüksek doğruluk oranları, modelin eğitim verisi ile iyi bir şekilde uyum sağladığını işaret eder. Aşağıda ilgili VGG19 modeline ait görseller yer almaktadır (Şekil 5.7).



Şekil 5.6 : Eğitim ve doğrulama kaybı eğrisi.



Şekil 5.7 : Eğitim ve doğrulama doğruluğu eğrisi.

Bu eğrilerin analizi, VGG19'un diyabetik retinopati tespitindeki etkinliğini ve modelin genel performansını değerlendirmek açısından kritik öneme sahiptir. Ayrıca, eğitim ve doğrulama sonuçlarının izlenmesi, gelecekteki iyileştirmeler için önemli bilgiler sunmaktadır.

5.4 CNN Eğitiminin Sonuçları

Bu senaryoda, görüntü sınıflandırma işlemi için temel model olarak bir Konvolüsyonel Sinir Ağı (CNN) kullanılmıştır. Modelin mimarisi, 150x150 boyutunda RGB görüntü girişlerini kabul eden, birkaç Konvolüsyonel ve havuzlama katmanından oluşmaktadır. Modelin katmanları şu şekildedir:

CNN Modelinin Mimarisi

Bu çalışmada kullanılan CNN modelinin mimarisi, aşağıdaki katmanları içermektedir:

Conv2D Katmanı : İlk katman, 32 filtre ve (3, 3) boyutlarında çekirdek (kernel) kullanarak konvolüsyon işlemi gerçekleştirir. Bu katman, girdi olarak 150x150 boyutunda üç kanallı (RGB) görüntü alır ve 'ReLU' aktivasyon fonksiyonunu kullanır.

MaxPooling2D Katmanı : İkinci katman, 2x2 boyutunda bir havuzlama uygulayarak modelin boyutunu azaltır ve özelliklerin en belirgin olanlarını çıkarır. Bu işlem, modelin hesaplama yükünü hafifletir ve aşırı uyum riskini azaltır.

Conv2D Katmanı : Üçüncü katman, yine 32 filtre kullanarak başka bir konvolüsyon işlemi yapar ve 'relu' aktivasyon fonksiyonu ile çalışır.

MaxPooling2D Katmanı : Dördüncü katman, önceki katmandan gelen çıktıyı havuzlayarak boyutunu daha da küçültür.

Flatten Katmanı : Beşinci katman, havuzlama katmanından çıkan çok boyutlu verileri tek boyutlu bir diziye dönüştürerek, tam bağlantılı (dense) katmanlar için uygun bir format sağlar.

Dense Katmanı : Altıncı katman, 128 nörondan oluşan tam bağlantılı bir katmandır ve yine 'relu' aktivasyon fonksiyonunu kullanır. Bu katman, modelin öğrenme kapasitesini artırır.

Dense Katmanı : Son katman, 6 nöron ile çalışır ve 'softmax' aktivasyon fonksiyonunu kullanarak çıktıyı sınıflandırma için hazırlar.

Modelin toplam parametre sayısı 1,555,429'dur ve bu sayede modelin eğitimi sırasında birçok farklı özelliği öğrenebilmesi sağlanmıştır. Bu mimari, diyabetik retinopati tespiti gibi görsel veri sınıflandırma görevleri için uygun bir yapı sunmaktadır.

Eğitim sürecinde elde edilen sonuçlar aşağıdaki gibidir:

Çizelge 5.8 : CNN test sonuçları.

Modeller	Sınıflar	Kesinlik	%Duyarlılık	%F1-Skoru	%Test örneği sayısı
CNN	0	0.71	0.90	0.82	180
	1	0.59	0.40	0.48	180
	2	0.50	0.43	0.47	180
	3	0.80	0.84	0.81	180
	4	0.80	0.76	0.78	180

Çizelge 5.8'de sonuçların analizi şu şekildedir, Sıfırıncı Evre (0) : Model, bu evrede yüksek bir geri çağırma oranı (90%) ve sağlam bir kesinlik (71%) elde etmiştir. Bu durum, modelin sağlıklı gözlerin doğru tespiti konusunda oldukça etkili olduğunu göstermektedir.

Birinci Evre (1) : Kesinlik %59 ile düşük kalırken, geri çağırma oranı %40'tır. Bu, modelin bu evredeki pozitif örnekleri tespit etme konusunda zayıf kaldığını göstermektedir.

İkinci Evre (2) : Her iki metrik de (%50 kesinlik ve %43 geri çağırma) düşüktür. Bu, modelin diyabetik retinopatinin orta düzeydeki etkilerini tanımakta zorlandığını işaret etmektedir.

Üçüncü Evre (3) : Bu evrede model, yüksek bir kesinlik (%80) ve geri çağırma (%84) oranı göstermektedir. Bu sonuç, modelin ağır vakaları tespit etme yeteneğinin oldukça iyi olduğunu ortaya koymaktadır.

Dördüncü Evre (4) : Son olarak, dördüncü evrede model, hem kesinlik (%90) hem de geri çağırma (%90) ile etkileyici bir performans sergilemektedir. Bu, modelin ciddi diyabetik retinopati vakalarını doğru bir şekilde tanımlamada başarılı olduğunu göstermektedir. Bu bulgular, CNN tabanlı modelin diyabetik retinopati tespitinde değişen evreler için nasıl performans gösterdiğini açıkça ortaya koymaktadır. Özellikle 0 ve 4. evrelerdeki yüksek metrikler, modelin belirli durumlarda etkinliğini vurgulamaktadır. Ancak, 1. ve 2. evrelerdeki düşük sonuçlar, modelin bu alanlarda

daha fazla geliştirilmesi gerektiğini işaret etmektedir. Çizelge 5.7’de *Sıfırıncı Evre (0)* : Model, bu evrede yüksek bir kesinlik (%94) ve mükemmel bir geri çağırma oranı (%98) elde etmiştir. Bu sonuç, modelin sağlıklı gözlerin doğru tespiti konusunda son derece etkili olduğunu ve neredeyse tüm doğru örnekleri yakalayabildiğini göstermektedir.

Çizelge 5.9 : CNN+CLAHE test sonuçları.

Modeller	Sınıflar	Kesinlik	%Duyarlılık	%F1-Skoru	%Test örneği sayısı
CNN+CLAHE	0	0.94	0.98	0.96	180
	1	0.88	0.85	0.87	180
	2	0.84	0.83	0.83	180
	3	0.97	0.97	0.97	180
	4	0.99	0.99	0.99	180

Çizelge 5.9’da sonuçların analizi şu şekildedir, *Birinci Evre (1)* : Kesinlik %88, geri çağırma ise %85 ile oldukça yüksek seviyelerdedir. Bu, modelin 1. evredeki pozitif örnekleri tespit etme konusunda oldukça başarılı olduğunu, ancak bazı yanlış pozitiflerin olabileceğini göstermektedir. *İkinci Evre (2)* : Bu evrede model, %84 kesinlik ve %83 geri çağırma oranları ile yüksek bir performans göstermektedir. Orta düzeydeki diyabetik retinopatinin doğru tanımlanmasında etkili bir sonuç elde edilmiştir.

Üçüncü Evre (3) : Model, üçüncü evrede neredeyse mükemmel bir performans sergileyerek, %97 kesinlik ve %97 geri çağırma oranlarına ulaşmıştır. Bu, ağır vakaların doğru şekilde tespit edildiğini ve modelin bu evrede yüksek doğrulukla çalıştığını göstermektedir.

Dördüncü Evre (4) : Dördüncü evrede, model neredeyse kusursuz bir sonuç elde ederek %99 kesinlik ve %99 geri çağırma oranlarına ulaşmıştır. Bu, ciddi diyabetik retinopati vakalarının doğru bir şekilde tespit edildiğini ve modelin bu evredeki pozitif örnekleri çok başarılı bir şekilde tanıdığını göstermektedir.


CNN+CLAHE modelinin test sonuçları, tüm evrelerde yüksek doğruluk ve geri çağırma oranları ile oldukça etkileyici bir performans sergilemektedir. Model, özellikle ileri evrelerde mükemmel sonuçlar verirken, erken evrelerde de yüksek doğruluk oranları elde etmiştir. Bu durum, modelin genel olarak diyabetik retinopati

tespitinde güçlü bir performans sergilediğini ve farklı evrelerdeki vakaları doğru bir şekilde tanıyabildiğini göstermektedir.

5.5 Karışıklık Matrisi (Confusion Matrix)

Karışıklık matrisi, her bir modelin sınıflandırma performansını değerlendirmek için kullanılan bir araçtır. Aşağıda, uyguladığımız modellerin karışıklık matrislerine ait görseller yer almaktadır. Bu matrisler, her sınıf için doğru ve yanlış tahminleri göstererek, modelin hangi sınıflarda daha başarılı olduğunu ve hangi sınıfların karıştırıldığını belirlemeye yardımcı olur.

Her bir model için elde edilen karışıklık matrisleri, modelin genel başarısını ve diyabetik retinopati tespitindeki etkinliğini analiz etmek açısından kritik öneme sahiptir. Görsellerin analizi, gelecekteki iyileştirmeler için önemli bilgiler sunmakta ve modelin hangi alanlarda güçlendirilmesi gerektiğini ortaya koymaktadır.



Şekil 5.8 : VGG16 Karışıklık Matrisi.

Şekil 5.8’de VGG16 modeli kullanılarak diyabetik retinopati sınıflandırması için oluşturulan karışıklık matrisini (confusion matrix) göstermektedir. Matrisin satırları gerçek sınıfları (True), sütunları ise model tarafından tahmin edilen sınıfları (Predicted) temsil etmektedir.

0. sınıf : Model, 0. sınıfa ait 180 örneği doğru sınıflandırmış ve herhangi bir yanlış tahminde bulunmamıştır.


1. sınıf : Model, 57 örneği doğru tahmin etmiş; 63 örneği yanlışlıkla 0, 43 örneği 2, 14 örneği 3 ve 3 örneği 4 olarak sınıflandırmıştır.

2. sınıf : Model, 41 örneği doğru tahmin etmiş; 50 örneği 0, 48 örneği 1, 26 örneği 3 ve 15 örneği 4 olarak yanlış sınıflandırmıştır.

3. sınıf: Model, 155 örneği doğru tahmin etmiş; 7 örneği 0, 1 örneği 1, 13 örneği 2 ve 4 örneği 4 olarak yanlış sınıflandırmıştır.

4. sınıf: Model, 149 örneği doğru tahmin etmiş; 4 örneği 1, 8 örneği 2 ve 4 örneği 3 olarak yanlış sınıflandırmıştır.

Karışıklık matrisi, modelin hangi sınıflarda daha başarılı olduğunu ve hangi sınıflar arasında karışıklık yaşadığını açıkça göstermektedir. Özellikle 0 ve 3. sınıflarda yüksek doğruluk gözlemlenirken, 1 ve 2. sınıflarda karışıklığın daha fazla olduğu görülmektedir. Bu sonuçlar, modelin belirli sınıflardaki performansını iyileştirmek için veri dengesizliği veya model optimizasyonu gibi konuların ele alınabileceğini göstermektedir.



Şekil 5.9 : VGG19 Karışıklık Matrisi.

Şekil 5.9'da VGG19 modeli kullanılarak diyabetik retinopati sınıflandırması için oluşturulan karışıklık matrisini göstermektedir. Matris, modelin sınıflandırma performansını detaylı bir şekilde ortaya koymaktadır. Satırlar gerçek sınıfları (Gerçek), sütunlar ise modelin tahmin ettiği sınıfları (Tahmin Edilen) temsil etmektedir.

0. sınıf: Model, 0. sınıfa ait 158 örneği doğru sınıflandırmıştır. Ancak 16 örneği 1, 5 örneği 2 ve 1 örneği 4 olarak yanlış tahmin etmiştir.


1. sınıf: Model, 74 örneği doğru tahmin etmiş; 53 örneği 0, 41 örneği 2, 8 örneği 3 ve 4 örneği 4 olarak yanlış sınıflandırmıştır.

2. sınıf: Model, 55 örneği doğru sınıflandırmış; 40 örneği 0, 52 örneği 1, 15 örneği 3 ve 18 örneği 4 olarak yanlış sınıflandırmıştır.

3. sınıf: Model, 123 örneği doğru tahmin etmiş; 4 örneği 0, 3 örneği 1, 36 örneği 2 ve 14 örneği 4 olarak yanlış tahmin etmiştir.

4. sınıf: Model, 153 örneği doğru tahmin etmiş; 2 örneği 0, 1 örneği 1, 19 örneği 2 ve 4 örneği 3 olarak yanlış sınıflandırmıştır.

VGG19 modeli, özellikle 0 ve 4. sınıflarda yüksek doğruluk oranı göstermiştir. Ancak, 1 ve 2. sınıflar arasında belirgin bir karışıklık yaşandığı gözlemlenmektedir. Bu durum, veri dengesizliği veya sınıfların benzer özelliklerinden kaynaklanıyor olabilir. Genel olarak, modelin sınıflandırma performansı tatmin edici olmakla birlikte, belirli sınıflardaki doğruluk oranını artırmak için veri artırma veya model optimizasyonu gibi yöntemler değerlendirilebilir.



Şekil 5.10 : CNN Karışıklık Matrisi.

Şekil 5.10'da CNN (Convolutional Neural Network) modeli kullanılarak yapılan sınıflandırma işleminin karışıklık matrisini (confusion matrix) göstermektedir. Matrisin satırları gerçek sınıfları (True), sütunları ise model tarafından tahmin edilen sınıfları (Predicted) temsil etmektedir.

0. Sınıf: Doğru Tahminler: Model, 0. sınıfa ait 148 örneği doğru sınıflandırmıştır.

Yanlış Tahminler: 17 örneği 1. sınıf, 11 örneği 2. sınıf, 3 örneği 3. sınıf, 1 örneği 4. sınıf olarak tahmin etmiştir.

1. Sınıf: Doğru Tahminler: Model, 1. sınıfa ait 54 örneği doğru tahmin etmiştir.

Yanlış Tahminler: 36 örneği 0. sınıf, 51 örneği 2. sınıf, 23 örneği 3. sınıf, 16 örneği 4. sınıf olarak tahmin etmiştir.

2. Sınıf: Doğru Tahminler: Model, 2. sınıfa ait 48 örneği doğru sınıflandırmıştır.

Yanlış Tahminler:48 örneği 0. sınıf,52 örneği 1. sınıf,17 örneği 3. sınıf,15 örneği 4. sınıf olarak tahmin etmiştir.

3. Sınıf: Doğru Tahminler: Model, 3. sınıfa ait 101 örneği doğru tahmin etmiştir.

Yanlış Tahminler: 16 örneği 0. sınıf,26 örneği 1. sınıf,22 örneği 2. sınıf, 15 örneği 4. sınıf olarak tahmin etmiştir.

4. Sınıf: Doğru Tahminler: Model, 4. sınıfa ait 120 örneği doğru sınıflandırmıştır.

Yanlış Tahminler:10 örneği 0. sınıf,20 örneği 1. sınıf,18 örneği 2. sınıf,11 örneği 3. sınıf olarak tahmin etmiştir.


Doğru Tahminler: Özellikle 0 ve 4. sınıflarda modelin performansı oldukça yüksektir (148 ve 120 doğru tahmin). Bu sınıflarda karışıklık diğer sınıflara kıyasla daha azdır.

5.6 Tahmin Sonuçlarının Görselleştirilmesi

Aşağıda, test görüntüleri üzerinde yapılan tahminlerin görselleştirildiği örnekler yer almaktadır. Bu görseller, her bir görüntü için modelin yaptığı tahminleri ve gerçek sınıfları karşılaştırmakta yardımcı olmaktadır. Her bir görüntü, tahmin edilen sınıfın yanı sıra, gerçek sınıf etiketini de göstermektedir.

Kodda kullanılan yöntem, modelin tahminlerini görselleştirerek, modelin diyabetik retinopati tespitindeki performansını daha iyi anlamamıza olanak tanır. Elde edilen görseller, modelin hangi durumlarda doğru tahminlerde bulunduğunu ve hangi durumlarda yanlış sınıflandırmalar gerçekleştirdiğini açıkça ortaya koymaktadır.

Görsellerin analizi, modelin güçlü ve zayıf yönlerini belirlemek açısından kritik bir rol oynamaktadır. Aşağıda, test görüntüleri üzerinde yapılan tahminlerin görselleştirildiği örnekler yer almakta olup, her bir görüntüye gerçek sınıf eklenerek, tahmin edilen sınıfın hangi sınıf olduğunun verildiği belirtilmiştir (Şekil 5.11).



Şekil 5.11 : Tahmin sonuçlarının görselleştirilmesi.

Bu görseller, modelin başarısını değerlendirmek için önemli bir referans noktası sunmakta ve gelecekteki geliştirme çalışmalarına ışık tutmaktadır.

Bu çalışmada, diyabetik retinopati tespitinde kullanılan farklı derin öğrenme modellerinin performansı kapsamlı bir şekilde incelenmiştir. Derin öğrenme, görüntü işleme ve sınıflandırma görevlerinde yüksek başarı oranlarıyla dikkat çekmektedir. Konvolüsyonel sinir ağları (CNN'ler), tıbbi görüntü analizi gibi alanlarda karmaşık özellikleri öğrenme yetenekleri sayesinde yaygın olarak kullanılmaktadır.

VGG16 ve VGG19, derin öğrenme literatüründe popüler mimarilerdir ve genellikle büyük veri setleri üzerinde etkili performans sergilemektedir. VGG16'nın eğitim sürecinde elde edilen %92'lik doğruluk oranı, modelin etkili öğrenme kapasitesini göstermektedir. CLAHE (Contrast Limited Adaptive Histogram Equalization) ile birlikte kullanıldığında, doğruluk oranı %99'a yükselmiştir. Bu bulgu, görüntülerin kontrastını artırmanın modelin sınıflandırma yeteneğini belirgin şekilde geliştirdiğini göstermektedir.

VGG19 ise benzer bir mimariye sahip olmasına rağmen, %66'lık bir doğruluk oranı ile sonuçlanmıştır. Bu durum, modelin yapısal karmaşıklığından ve daha fazla parametre içermesinden kaynaklanabilir. VGG19'un daha fazla katman içermesi, modelin daha uzun bir eğitim süresi gerektirmesine yol açmakta ve bu da sonuçların daha düşük olmasına neden olmaktadır. Ayrıca, veri setindeki sınıf dengesizlikleri ve çeşitlilik de modelin öğrenme sürecini olumsuz yönde etkileyebilir.

CNN modelinin performansı da dikkat çekicidir; %90'lık bir kesinlik oranıyla 4. evre diyabetik retinopatinin tespitinde başarılı olmuştur. Ancak, 1. ve 2. evrelerdeki düşük performansı, bu aşamalarındaki veri çeşitliliğinin yetersizliğinden kaynaklanıyor olabilir. Daha basit bir mimari sunmasına rağmen, yeterli eğitim verisi ile etkili sonuçlar elde edilmiştir.

VGG16 ve CNN mimarileri, diyabetik retinopati tespitinde en yüksek başarı oranlarına sahip olurken, RESNET50 ve İnceptionV3 gibi modellerin daha düşük performansı, veri setinin çeşitliliği ve modelin mimari yapısıyla ilgili sorunları göstermektedir.

Bu analiz, derin öğrenme modellerinin diyabetik retinopati gibi tıbbi görüntüleme problemlerinde etkinliğini değerlendirmeye yönelik önemli bilgiler sunmaktadır. Gelecekteki çalışmalar, model mimarilerini geliştirme ve daha fazla veri toplama stratejileri üzerinde odaklanarak bu alandaki başarıyı artırabilir. Karışıklık matrisleri ve elde edilen metrikler, her modelin performansını anlamak adına önemli bilgiler sunmaktadır. Her modelin hangi sınıflarda daha iyi veya kötü performans gösterdiği, daha ileri düzeyde iyileştirmeler için kritik öneme sahiptir. Bu bağlamda, daha fazla veri toplama, veri artırma tekniklerinin uygulanması ve model mimarilerinin optimize edilmesi, elde edilen sonuçların iyileştirilmesine katkı sağlayabilir.

Literatürde öne çıkan bazı çalışmalar ve bizim çalışma sonuçlarımızın karşılaştırılması Çizelge 5.10'da görülmektedir.

Çizelge 5.10 : Diyabetik retinopati tespiti için derin öğrenme modelleri.

Makale	Veriseti	Önişleme	Model	Sonuç	Web uygulaması
Özçelik, (2021)	APTOS 2019	-	VGG-19	%97	HAYIR
			ResNet101	%95	
			InceptionV3	%88	
			ResNet101	%84	
Deperlioğlu ve Köse (2018)	Kaggle'de n 300 görüntü	Histogram Eşitleme Gaussian Filtre Gauss Karışım Modeli (GMM)	CNN	%96	HAYIR
Akram ve diğ. (2014)	Messidor	Histogram eşitleme	RSM	%96	HAYIR
			AdaBoost	%92	
Tsiknakis ve diğ. (2021)	Kaggle Messidor Diaret db, messido	-	CNN	%85	HAYIR
Omar ve diğ. (2017)	Diaret db1	CLAHE	CNN	%80	HAYIR
Alver ve Yalçın (2018)	Stare 1000 görüntü	Ortanca filtre	CNN	%98	HAYIR
Patel (2020)	Kaggle	-	VGG16	%89	HAYIR
			MobileNetV1	%89	
Ghosh ve diğ. (2017)	Kaggle	-	CNN	%85	HAYIR
Mishra ve diğ. (2020)	APTOS	-	VGG16	%73	HAYIR
			DenseNet121	%96	
			VGG16	%93	
			VGG16+CLAHE	%99	
Bu çalışma	Kaggle	CLAHE	VGG19	%66	EVET
			VGG19+CLAHE	%74	
			CNN	%94	
			CNN+CLAHE	%99	
			Xception	%55	
			Xception+CLAHE	%67	
			InceptionV3	%55	
			InceptionV3+CLAHE	%53	
			ResNet50	%21	
			ResNet50+CLAHE	%22	

Literatürde farklı mimarilerle gerçekleştirilen çalışmaların doğruluk oranları genellikle %78 ile %95 arasında değişmektedir. Örneğin, bir çalışmada ResNet50 ve VGG19 gibi derin öğrenme tabanlı CNN modelleri kullanılarak DR teşhisi yapılmış ve %72 ile %93 arasında doğruluk elde edilmiştir. Başka bir araştırma, CNN ile %85 doğruluk elde etmiş ve DR sınıflandırmasında lezyonların otomatik tespitine

odaklanmıştır. Bu sonuçlar, genel olarak CNN tabanlı modellerin DR tespiti için güçlü performanslar sergilediğini ve sınıflandırma süreçlerini iyileştirdiğini göstermektedir. Bizim çalışmamızda ise, hem VGG16 hem de CLAHE (Contrast Limited Adaptive Histogram Equalization) yöntemi kullanılarak modelin doğruluğu %99 seviyesine çıkartılmıştır. Literatürdeki diğer çalışmalarda da görüldüğü gibi, veri ön işleme teknikleri, özellikle kontrast artırıcı yöntemler, model performansını artırmada önemli bir faktördür.

Bunun yanı sıra, geliştirdiğimiz modelin pratikte kullanımını kolaylaştırmak amacıyla bir web arayüzü entegrasyonu gerçekleştirilmiştir. Bu arayüz sayesinde kullanıcılar, diyabetik retinopati görüntülerini sisteme kolaylıkla yükleyerek hızlı bir şekilde sınıflandırma sonuçlarına ulaşabilmektedir. Web arayüzü entegrasyonu, çalışmamızın sadece yüksek doğruluk oranlarıyla sınırlı kalmayıp, aynı zamanda kullanıcı dostu bir sistem sunarak klinik uygulamalarda kullanılabilirliğini artırdığını göstermektedir. Bu özellik, modelimizin başarısının literatürdeki birçok çalışmadan daha ileri düzeyde olduğunu ve diyabetik retinopati tespiti için yenilikçi bir çözüm sunduğunu ortaya koymaktadır. Çalışmamız, mevcut literatürdeki modellerin doğruluk oranlarını artırmaya yönelik yöntemler, kontrast iyileştirme gibi veri işleme teknikleri ve web arayüzü entegrasyonu ile önemli bir katkı sağlamaktadır. Özellikle, CLAHE ile desteklenen modelimizin yüksek doğruluğa ulaşması ve web arayüzü ile pratik bir çözüm sunması, diyabetik retinopati teşhisinde klinik süreçleri hızlandırmak ve kolaylaştırmak adına umut verici bir yaklaşım olarak öne çıkmaktadır. Bu bağlamda, geliştirilen sistemin, DR'nin erken teşhisi ve doğru sınıflandırması açısından literatüre ve klinik uygulamalara değerli bir katkı sunduğu değerlendirilmektedir.

6. SONUÇ

Bu tez çalışmasında, diyabetik retinopati (DR) tespitinde derin öğrenme tabanlı modellerin etkinliğini araştırarak, özellikle VGG16, VGG19, CNN, Xception, InceptionV3 ve ResNet50 gibi popüler derin öğrenme mimarileri üzerine odaklanmıştır. Ayrıca, CLAHE (Contrast Limited Adaptive Histogram Equalization) yöntemi kullanılarak, görüntü ön işlemenin model performansı üzerindeki etkileri kapsamlı bir şekilde incelenmiştir. Elde edilen bulgular, özellikle CLAHE'nin kontrast artırıcı etkisiyle modellerin küçük lezyonları daha iyi algılayarak sınıflandırma doğruluğunu artırdığına işaret etmektedir. Yapılan deneylerde, VGG16 ve CNN modellerinin CLAHE ile birleştirildiğinde %99 doğruluk oranına ulaştığı gözlenmiştir. Bu sonuçlar, literatürde bildirilen çoğu çalışmayı geride bırakmakta ve önerilen yöntemlerin DR tespiti için yüksek performanslı bir çözüm sunduğunu göstermektedir. Öte yandan, ResNet50 ve InceptionV3 gibi daha karmaşık modellerin nispeten düşük performans göstermesi, bu mimarilerin mevcut veri seti ile yeterince optimize edilememiş olmasından kaynaklanıyor olabilir. Bu durum, model seçiminin ve veri ön işleme yöntemlerinin birlikte ele alınmasının önemini vurgulamaktadır.

Çalışma kapsamında ayrıca, VGG16+CLAHE tabanlı eğitilen modeli temel alarak, DR tespiti ve sınıflandırması için yenilikçi bir Streamlit platformu ile kullanıcı dostu ara yüz geliştirilmiştir. Uygulama ara yüzü, giriş görüntülerini işleyerek anında sonuç sağlayabilmekte ve sınıflandırma süreçlerini kolaylaştırmaktadır. Gerçek zamanlı sınıflandırma yeteneği, DR gibi ilerleyici hastalıkların erken teşhisinde pratik bir çözüm sunmaktadır. Uygulamanın, farklı DR evrelerini (No DR, Mild NPDR, Moderate NPDR, Severe NPDR ve PDR) doğru bir şekilde ayırt edebildiği, bu nedenle klinik uygulamalara yönelik bir adım olarak değerlendirilebileceği ortaya konmuştur. Ayrıca, uygulamamızda web arayüzü entegrasyonu sayesinde, kullanıcıların DR sınıflandırma süreçlerine erişimi kolaylaştırılmıştır. Web arayüzü, klinik ve sahada hızlı ve etkili bir sınıflandırma çözümü olarak kullanılabilir bir platform sunmaktadır. Bu sayede, sağlık profesyonelleri ve klinik uzmanlar, görüntüleri hızlıca inceleyerek teşhis süreçlerini optimize edebilir ve daha doğru sonuçlara ulaşabilir. Bu araştırma,

derin öğrenme tabanlı yöntemlerin DR teşhisinde yüksek doğruluk oranlarına ulaşabileceğini ve CLAHE gibi görüntü ön işleme tekniklerinin bu başarıya katkı sağladığını göstermiştir. Bu bulgular, DR teşhisi için kullanılan yöntemlerin daha da geliştirilmesi adına yol gösterici olabilir. Gelecekte daha büyük ve dengeli veri setleri ile çalışılarak, modellerin genel performansının artırılması hedeflenmelidir. Ayrıca, geliştirilmiş model mimarilerinin ve daha karmaşık ön işleme tekniklerinin kullanımı, yalnızca DR değil, diğer retina hastalıklarının teşhisi için de faydalı olabilir.

Bu çalışma hem akademik literatüre hem de uygulamalı sağlık teknolojilerine önemli katkılar sağlamış ve özellikle yapay zekâ tabanlı çözümlerin klinik uygulamalarda kullanılabilirliğini artırma potansiyelini ortaya koymuştur. Bu bağlamda, DR gibi ciddi hastalıkların erken teşhisi ve yönetimi için daha geniş çaplı uygulamaların geliştirilmesi hem hasta sonuçlarını iyileştirecek hem de sağlık sistemlerinde önemli tasarruflar sağlayacaktır.

KAYNAKLAR

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ... & Zheng, X.** (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv:1603.04467*.
- Adugna, A. R.** (2024). A review of pattern recognition and machine learning. *Journal of Machine and Computing*, 9.
- Abood, L. K.** (2018). Contrast enhancement of infrared images using adaptive histogram equalization (AHE) with contrast limited adaptive histogram equalization (CLAHE). *Iraqi Journal of Physics*, 16(37), 127–135.
- Ağca, K., & Takcı, H.** (2022). Hibrit bir model oluşturarak diyabetik retinopati sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (36), 227–236.
- Akram, M. U., Khalid, S., Tariq, A., Khan, S. A., & Azam, F.** (2014). Detection and classification of retinal lesions for grading of diabetic retinopathy. *Computers in Biology and Medicine*, 45, 161–171.
- Albahli, S., & Ahmad Hassan Yar, G. N.** (2022). Automated detection of diabetic retinopathy using custom convolutional neural network. *Journal of X-Ray Science and Technology*, 30(2), 275–291.
- Al-Dujaili, S. I. H.** (2023). Diabetic retinopathy detection using ensemble transfer deep learning (Doctoral dissertation).
- Ali, A. A., & Dawood, F. A. A.** (2022). Diabetic retinopathy detection and classification based on deep learning: A review. *International Journal of Nonlinear Analysis and Applications*, 13(2), 3203–3212.
- Arlot, S., & Celisse, A.** (2010). A survey of cross-validation procedures for model selection.
- Aykat, S. S.** (2023). Derin öğrenme kullanılarak fundus görüntülerinden katarakt ve diyabetik retinopati tespiti. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 13.
- Beri, M., Gill, K. S., Upadhyay, D., & Devliyal, S.** (2024). Revolutionizing retinal health: AI-driven analysis for early pathology detection in OCT scans.
- Bradski, G.** (2008). Learning OpenCV: Computer vision with the OpenCV library. *O'Reilly Google Scholar*, 2, 334–352.
- BRITAL., A.** (2023, October 23). Inception V3 CNN architecture explained. Medium. Retrieved from <https://medium.com/@AnasBrital98/inception-v3-cnn-architecture-explained-691cfb7bba08>.
- Bridle, J. S.** (1990). Probabilistic interpretation of feedforward classification network outputs, with relationships to statistical pattern recognition. In *Neurocomputing: Algorithms, architectures, and applications* (pp. 227–236). Berlin, Heidelberg: Springer.

- Chen, Y. W., Wu, T. Y., Wong, W. H., & Lee, C. Y.** (2018, April). Diabetic retinopathy detection based on deep convolutional neural networks. In *2018 IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)* (pp. 1030–1034). IEEE.
- Chollet.** (2017). Xception: Deep learning with depthwise separable convolutions. *IEEE*, 8.
- Chollet, F.** (2021). Deep learning with Python. Simon and Schuster.
- Cukierski.** (2024). Kaggle: Diabetic Retinopathy Detection Data. Retrieved from <https://www.kaggle.com/c/diabetic-retinopathy-detection/data>.
- Çarkacı, N.** (2018, January 2). Derin öğrenme uygulamalarında en sık kullanılan hiper parametreler. Medium. Retrieved from <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4>.
- Deperlioğlu, Ö., & Köse, U.** (2018, October). Diagnosis of diabetic retinopathy by using image processing and convolutional neural network. In *2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1–5). IEEE.
- Elitez, O.** (2015). Handwritten digit string segmentation and recognition using deep learning (Master's thesis).
- Erdoğan, P.** (2016). Doğadan esinlenen optimizasyon algoritmaları ve optimizasyon algoritmalarının optimizasyonu. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 4(1), 293–304.
- Forsyth, D. A., & Ponce, J.** (2002). *Computer vision: A modern approach*. Prentice Hall Professional Technical Reference.
- Ghosh, R., Ghosh, K., & Maitra, S.** (2017, February). Automatic detection and classification of diabetic retinopathy stages using CNN. In *2017 4th International Conference on Signal Processing and Integrated Networks (SPIN)* (pp. 550–554). IEEE.
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). *Deep Learning (Vol. 1)*. MIT Press.
- Guerbai, Y., Bouaraki, W., Saibi, A., Bida, M., & Halimouche, R.** (2024). Deep learning techniques for diabetic retinopathy classification: A focus on VGG16 and EfficientNetB0. *South Florida Journal of Development*, 5(10), e4517–e4517.
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., ... & 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.
- Güney, R., & Karlı, H.** (2013). Histogram eşitleme ve germe teknikleri ile sismik verilerin görüntülerinin zenginleştirilmesi. *Enhancement of Images of Seismic Data by Histogram Equalization and Stretching Techniques*.
- Hagos, M. T., & Kant, S.** (2019). Transfer learning-based detection of diabetic retinopathy from a small dataset. *arXiv preprint arXiv:1905.07203*.

- Han, S., Hwang, S. I., & Lee, H. J.** (2019). The classification of renal cancer in 3-phase CT images using a deep learning method. *Journal of Digital Imaging*, 32, 638–643.
- He, K., Zhang, X., Ren, S., & Sun, J.** (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770–778).
- Hinton, G. E., Osindero, S., & Teh, Y. W.** (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527–1554.
- Hinton, G.** (2009). Deep belief networks. *Scholarpedia*, 4(5), 5947. <https://doi.org/10.4249/scholarpedia.5947>.
- Hossin, M., & Sulaiman, M. N.** (2015). A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process*, 5(2), 1.
- Hunter, J. D.** (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(03), 90–95.
- Hüseynova, T. M., & Ahmədov, A. C.** (2024). Effective and simple methods in the synthesis of Nonin-1 with the participation of alkaline metal complexes. *Proceedings of Azerbaijan High Technical Educational Institutions*, 2(148), 88–93.
- Jayakumari, C., & Maruthi, R.** (2011). Longitudinal time-series of color retinal fundus image for diabetic retinopathy. *International Journal of Computer Applications*, 33(10), 43–46.
- Karim, M., & Rahman, R. M.** (2013). Decision tree and naive Bayes algorithm for classification and generation of actionable knowledge for direct marketing.
- Keskar, N. S., Mudigere, D., Nocedal, J., Smelyanskiy, M., & Tang, P. T. P.** (2016). On large-batch training for deep learning: Generalization gap and sharp minima. *arXiv preprint arXiv:1609.04836*.
- Kingma, D. P., & Ba, J.** (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Kinney, W.** (2017). *Python for Data Analysis*. O'Reilly Media.
- Kornblith, S., Shlens, J., & Le, Q. V.** (2019). Do better ImageNet models transfer better? In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 2661–2671).
- Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.
- Larrikins, T.** (2019). Xception architectural design. *Coding*. Retrieved from <https://stephan-osterburg.gitbook.io/coding/coding/ml-dl/tensorflow/ch3-xception/xception-architectural-design>.
- LeCun, Y. A., Bottou, L., Orr, G. B., & Müller, K. R.** (2012). Efficient backprop. In *Neural Networks: Tricks of the Trade* (pp. 9–48). Springer.

- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P.** (2015). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Li, F., Liu, Z., Chen, H., Jiang, M., Zhang, X., & Wu, Z.** (2019). Automatic detection of diabetic retinopathy in retinal fundus photographs based on deep learning algorithm. *Translational Vision Science & Technology*, 8(6), 4–4.
- Mahmoud, M. H., Alamery, S., Fouad, H., Altinawi, A., & Youssef, A. E.** (2023). An automatic detection system of diabetic retinopathy using a hybrid inductive machine learning algorithm. *Personal and Ubiquitous Computing*, 1–15.
- Mali, K., Jadhav, B., & Mujawar, I.** (2022). Study of diabetic retinopathy detection using deep learning techniques. In *Proceedings of a Conference* (pp. 208–216).
- Michael, D. A., Garvin, M. K., & Sonka, M.** (2010). Retinal imaging and image analysis. *IEEE Reviews in Biomedical Engineering*, 3, 169–208.
- Mishra, S., Hanchate, S., & Saquib, Z.** (2020, October). Diabetic retinopathy detection using deep learning. In *2020 International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE)* (pp. 515–520). IEEE.
- Nair, V., & Hinton, G. E.** (2010). Rectified linear units improve restricted Boltzmann machines. In *Proceedings of the 27th International Conference on Machine Learning (ICML-10)* (pp. 807–814).
- Nguyen, Q. H., Muthuraman, R., Singh, L., Sen, G., Tran, A. C., Nguyen, B. P., & Chua, M.** (2020, January). Diabetic retinopathy detection using deep learning. In *Proceedings of the 4th International Conference on Machine Learning and Soft Computing* (pp. 103–107).
- Okumuş, R.** (2019, March 19). Convolutional neural networks (evrimsel sinir ağları). *Medium*. Retrieved from <https://medium.com/@rabiakumus96/convolutional-neural-networks-evri%C5%9Fimsel-sinir-a%C4%9Flar%C4%B1-cceb887a2979>.
- Oliphant, T. E.** (2006). *Guide to NumPy* (Vol. 1, p. 85). USA: Trelgol Publishing.
- Omar, Z. A., Hanafi, M., Mashohor, S., Mahfudz, N. F. M., & Muna'Im, M.** (2017, October). Automatic diabetic retinopathy detection and classification system. In *2017 7th IEEE International Conference on System Engineering and Technology (ICSET)* (pp. 162–166). IEEE.
- Öğündür, G.** (2018, November 9). Doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ya da F1-score. *Medium*. Retrieved from <https://medium.com/@gulcanogundur/do%C4%9Fruluk-accuracy-kesinlik-precision-duyarl%C4%B1k-recall-ya-da-f1-score-300c925feb38>.
- Özcan, H.** (2014). Çok düşük çözünürlüklü yüz imgelerinde derin öğrenme uygulamaları (Master's thesis, Deniz Bilimleri ve Mühendisliği Enstitüsü).

- Özçelik, Y. B., & Altan, A.** (2021). Diyabetik retinopati teşhisi için fundus görüntülerinin derin öğrenme tabanlı sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (29), 156–167.
- Pan, S. Y.** (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359.
- Panchal, P.** (2024). Early detection of diabetic retinopathy using deep learning. *International Journal of Knowledge-Based Computer Systems*, 12, 16.
- Patel, S.** (2020). Diabetic retinopathy detection and classification using pre-trained convolutional neural networks. *International Journal on Emerging Technologies*, 11(3), 1082–1087.
- Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T., ... & Zuiderveld, K.** (1987). Adaptive histogram equalization and its variations. *Computer Vision, Graphics, and Image Processing*, 39(3), 355–368.
- Priya, R., Aruna, P., & Suriya, R.** (2013). Image analysis technique for detecting diabetic retinopathy. *International Journal of Computer Applications*, 1, 34–38.
- Rajalakshmi, R., Subashini, R., Anjana, R. M., & Mohan, V.** (2018). Automated diabetic retinopathy detection in smartphone-based fundus photography using artificial intelligence. *Eye*, 32(6), 1138–1144.
- Ramaha, N. T. A., & Al-Dujaili, S. I.** (2023). Diabetic retinopathy diagnosis using machine learning versus deep learning. *European Journal of Science and Technology*, (51), 301–313.
- Satar, B., & Dirik, A. E.** (2018). Deep learning-based vehicle make-model classification. In *Artificial Neural Networks and Machine Learning–ICANN 2018: 27th International Conference on Artificial Neural Networks* (pp. 544–553). Springer International Publishing.
- Shankar, K., Sait, A. R. W., Gupta, D., Lakshmanaprabu, S. K., Khanna, A., & Pandey, H. M.** (2020). Automated detection and classification of fundus diabetic retinopathy images using synergic deep learning model. *Pattern Recognition Letters*, 133, 210–216.
- Sheetal, S., & B., A.** (2024). Artificial intelligence in detecting the severity of diabetic retinopathy. *Journal of Evolution of Medical and Dental Sciences*, 13(5), 144–150. <https://doi.org/10.14260/jemds.v13i5.645>.
- Simonyan, K., & Zisserman, A.** (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Stajyeri, T. A. S. A. M., & Tekin, Z.** (2019). Derin öğrenme yaklaşımının gücü.
- Suresh, B., Pillai, K., Kalsi, G. S., Abuhatzera, A., & Subramoney, S.** (2021). Early prediction of DNN activation using hierarchical computations. *Mathematics*, 9(23), 3130.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z.** (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2818–2826).

- Tan, T. F., Thirunavukarasu, A. J., Jin, L., Lim, J., Poh, S., Teo, Z. L., ... & Ting, D. S. W.** (2023). Artificial intelligence and digital health in global eye health: Opportunities and challenges. *The Lancet Global Health*, 11(9), e1432–e1443.
- Tieleman, T., & Hinton, G.** (2012). RMSprop: Divide the gradient by a running average of its recent magnitude. *Coursera: Neural Networks for Machine Learning*.
- Tiken, C.** (2015). Derin öğrenme uygulamaları (Master's thesis). İstanbul Üniversitesi / Fen Bilimleri Enstitüsü / Bilgisayar Mühendisliği Ana Bilim Dalı.
- Tsiknakis, N., Theodoropoulos, D., Manikis, G., Ktistakis, E., Boutsora, O., Berto, A., ... & Marias, K.** (2021). Deep learning for diabetic retinopathy detection and classification based on fundus images: A review. *Computers in Biology and Medicine*, 135, 104599.
- Tupe, A., Joshi, Y., Tambe, S., & Dewan, J.** (2022). Diabetic retinopathy detection using image processing techniques: A study. In Proceedings of a Conference. https://doi.org/10.1007/978-981-16-5689-7_56.
- Vardhan, K. B., Nidhish, M., Dudekula, N. S., Varanasi, S. C., & Bhavadharini, R. M.** (2025). Eye disease detection using deep learning models with transfer learning techniques. *EAI Endorsed Transactions on Scalable Information Systems*, 12(1).
- Weisstein, E. W.** (2019). Convolution. *Wolfram*. Retrieved from <https://mathworld.wolfram.com/Convolution.html>.
- Xia, K. J., Yin, H. S., & Wang, J. Q.** (2019). A novel improved deep convolutional neural network model for medical image fusion. *Cluster Computing*, 22, 1515–1527.
- Yalçın, N., Alver, S., & Uluhatun, N.** (2018, May). Classification of retinal images with deep learning for early detection of diabetic retinopathy disease. In *2018 26th Signal Processing and Communications Applications Conference (SIU)* (pp. 1–4). IEEE.
- Yaqoob, M. K., Ali, S. F., Bilal, M., Hanif, M. S., & Al-Saggaf, U. M.** (2021). ResNet-based deep features and random forest classifier for diabetic retinopathy detection. *Sensors*, 21(11), 3883.
- Yavuz, S., & Deveci, M.** (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167–187.
- Yosinski, J. C.** (2014). Transfer learning by fine-tuning deep visual classification models. *IEEE Conference on Computer Vision and Pattern Recognition Workshops*.
- Yu, X., Wang, J., Hong, Q. Q., Teku, R., Wang, S. H., & Zhang, Y. D.** (2022). Transfer learning for medical images analyses: A survey. *Neurocomputing*, 489, 230–254.

ÖZGEÇMİŞ

TARANMIŞ
VESİKALIK
FOTOĞRAF

Ad-Soyad : Ravan JARJANAZI

Doğum Tarihi ve Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** : 2021, Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

-
-

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

-
-
-

DİĞER ESERLER, SUNUMLAR VE PATENTLER:

-
-