

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

**DERİN ÖĞRENME VE MAKİNE ÖĞRENME TEKNİKLERİ
KULLANILARAK GÖZ HASTALIKLARININ TESPİTİ**

HAZIRLAYAN

GÖZDE ARSLAN

YÜKSEK LİSANS TEZİ

ANKARA-2023

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

**DERİN ÖĞRENME VE MAKİNE ÖĞRENME TEKNİKLERİ
KULLANILARAK GÖZ HASTALIKLARININ TESPİTİ**

HAZIRLAYAN

GÖZDE ARSLAN

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

**DR. ÖĞR. ÜYESİ ÇAĞATAY
BERKE ERDAŞ**

ANKARA-2023

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Gözde Arslan tarafından hazırlanan bu çalışma, aşağıdaki jüri üyeleri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 12/10/2023

Tez Adı: Derin Öğrenme ve Makine Öğrenme Teknikleri Kullanılarak Göz Hastalıklarının Tespiti

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)	İmza
Dr. Öğr. Üyesi İclal Çetin Taş, Ostim Teknik Üniversitesi	
Dr. Öğr. Üyesi Didem Ölçer, Başkent Üniversitesi	
Dr. Öğr. Üyesi Çağatay Berke Erdaş, Başkent Üniversitesi	

ONAY

Prof. Dr. Faruk ELALDI
Fen Bilimleri Enstitüsü Müdürü
Tarih: ... /.../

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS / DOKTORA TEZ/PROJE ÇALIŞMASI
ORJİNALLİK RAPORU

Tarih: 12/10/ 2023

Öğrencinin Adı, Soyadı : Gözde ARSLAN

Öğrencinin Numarası : 22010636

Anabilim Dalı : Bilgisayar Mühendisliği

Programı : Bilgisayar Mühendisliği Doktora YL

Danışmanın Unvanı/Adı, Soyadı : Dr. Öğr. Üyesi Çağatay Berke ERDAŞ

Tez Başlığı : Derin Öğrenme ve Makine Öğrenme Teknikleri Kullanılarak

Göz Hastalıklarının Tespiti

Yukarıda başlığı belirtilen yüksek lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 61 sayfalık kısmına ilişkin, 12/10/2023 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %13'tür. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:

ONAY

Tarih: 12 /10 / 2023

Dr. Öğr. Üyesi Çağatay Berke ERDAŞ

Öğrenci Danışmanı İmza:

TEŞEKKÜR

Öncelikle, tez araştırmamın gerçekleştirilmesinde bana yol gösteren beraber çalıştığımız ilk günden beri desteğini, bilgi ve tecrübesini sonuna kadar paylaşan danışman hocam Dr. Öğr. Üyesi Çağatay Berke ERDAŞ'a çok teşekkür ederim. Kendisi bilgi ve tecrübesini sonsuz bir özveriyle benimle paylaşarak, beni her adımda cesaretlendirip bilgilendirdi.

Çalışmalarımız süresince karşılaştığım problemlerde yardımını esirgemedi vaktini ayırması, rehberliği, çözüm odaklı olması sayesinde en iyi çözümü bulmamı sağladı.

Bu güzel ve anlamlı süreci iyi bir şekilde tamamlamamda büyük katkıları olan Dr. Öğr. Üyesi Çağatay Berke ERDAŞ'a tekrar teşekkür ederek benim için zorlu bir süreci iyi olarak tamamladığımı düşünüyorum.

Son olarak tezimin her aşamasında yanımda olan tüm dostlarıma ve yakın çevreme sevgi ve saygılarımı sunarak teşekkür ederim.

Gözde ARSLAN Ankara, 2023

ÖZET

Gözde ARSLAN

DERİN ÖĞRENME VE MAKİNE ÖĞRENME TEKNİKLERİ KULLANILARAK GÖZ HASTALIKLARININ TESPİTİ

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

2023

Göz hastalıkları insan yaşamını ciddi derecede etkileyen sağlık sorunlarından biridir. Göz hastalıkları arasında bulunan katarakt, diyabetik-retinopati, glokom gibi hastalıklar görme bozukluğuna ve geri dönüşü olmayan göz kusurlarına neden olur. İnsan yaşamında genetik, yaş ve çevresel faktörler göz sağlığını önemli ölçüde etkiler. Hastalık tespitin yapılması ve dolayısıyla hastanın yaşam kalitesinin yükseltilebilmesi için hastalığın doğru bir şekilde tespiti kritik bir rol oynamaktadır. Gelişen teknoloji ile yapay zeka göz kusurlarını ve dolayısıyla ilgili gözde bir hastalık olup olmadığını tespit edebilmektedir. Bu tez çalışması, önemli sağlık sorunlarından göz hastalıklarının derin öğrenme modelleri ve makine öğrenmesi algoritmaları kullanılarak tespit edilmesine yönelik çözümler geliştirmeyi amaçlamaktadır. Bu çalışmada derin öğrenme türlerinden biri olan Konvolüsyonel Sinir Ağları modelleri ve makine öğrenme algoritmaları kullanılmıştır. Hastalık başarısının tahmini ve sınıflandırılmasında geleneksel makine öğrenmesi algoritmalarından Destek Vektörü Makinesi, Naive Bayes Sınıflandırıcısı, K-En Yakın Komşu, Rastgele Orman kullanılmıştır. CNN modelinden DenseNet, EfficientNet, VGG, ResNet ve Xception mimarileri kullanılmıştır. Çoklu sınıflandırma probleminde, hastalık tespiti için kullanılan veri setinde 1074 normal, 1007 glokom, 1098 diyabetik-retinopati, 1038 katarakt verileri olmak üzere toplamda 4217 Retinal Fundus görüntüsü içermektedir. İkili sınıflandırma probleminde, hastalık tespiti için kullanılan veri setinde 1374 normal ve 1374 hastalıklı veriler olmak üzere toplamda 2748 Retinal Fundus görüntüsü içermektedir. Retinal Fundus göz hastalığı sınıflandırması çalışmasında ise hazır CNN mimarileri ve makine öğrenme ile mevcut probleme uyarlanarak deneyler yürütülmüş ve performansları karşılaştırılmıştır. CNN mimarilerinin konvolüsyonel katmanlarında otomatik olarak üretilen öznitelikler makine öğrenme sınıflandırıcılarını beslemek için kullanılmıştır. Tespit ve sınıflandırma çalışmalarında elde edilen performanslara göre derin öğrenme mimarilerinin makine öğrenmesi algoritmalarından üstün geldiği gözlemlenmiştir.

ANAHTAR KELİMELEER: Sınıflandırma, Göz hastalığı, EfficientNet, Retinal Fundus, Derin Öğrenme, Makine Öğrenme

ABSTRACT

Gözde ARSLAN

DETECTION OF EYE DISEASE WITH DEEP LEARNING AND MACHINE LEARNING APPROACH

Başkent University Institution of Science and Engineering

Department of Computer Engineering

2023

Eye diseases are one of the health problems that seriously affect human life. Diseases such as cataract, diabetic-retinopathy, glaucoma, which are among the eye diseases, cause visual impairment and irreversible eye defects. Genetic, age and environmental factors significantly affect eye health in human life. Accurate detection of the disease plays a critical role in detecting the disease and thus improving the quality of life of the patient. With the developing technology, artificial intelligence can detect eye defects and therefore whether there is a disease in the related eye. This thesis study aims to develop solutions for the detection of eye diseases, which are important health problems, by using deep learning models and machine learning algorithms. In this study, Convolutional Neural Network models, which is one of the deep learning types, and machine learning algorithms were used. In the prediction and classification of disease success, Support Vector Machine, Naive Bayes Classifier, K-Nearest Neighbor, Random Forest, which are traditional machine learning algorithms, were used. DenseNet, EfficientNet, VGG, ResNet and Xception architectures from the CNN model were used. In the multi-classification problem, the data set used for disease detection includes a total of 4217 Retinal Fundus images, 1074 normal, 1007 glaucoma, 1098 diabetic-retinopathy, 1038 cataract data. In the binary classification problem, the data set used for disease detection includes a total of 2748 Retinal Fundus images, 1374 normal and 1374 diseased data. In the retinal fundus eye disease classification study, experiments were carried out by adapting them to the existing problem with ready-made CNN architectures and machine learning, and their performances were compared. Automatically generated features in convolutional layers of ready-made CNN architectures are used to feed machine learning classifiers. According to the performances obtained in detection and classification studies, it has been observed that deep learning architectures are superior to machine learning algorithms.

KEYWORDS: Classification, Eye disease, EfficientNet, Retinal Fundus, Deep Learning, Machine Learning

İÇİNDEKİLER

TEŞEKKÜR.....	i
ÖZET	ii
ABSTRACT	iv
TABLolar LİSTESİ	vii
ŞEKİLLER LİSTESİ	viii
SİMGELER VE KISALTMALAR LİSTESİ.....	x
1. GİRİŞ	1
1.1. Tanım ve Motivasyon.....	1
1.2. Tez Çalışmasının Genel Katkıları	3
1.3. Tez Planı	4
2. ALAN BİLGİSİ VE LİTERATÜR	5
3. MATERYAL VE YÖNTEM	8
3.1. Retinal Fundus Görüntüleri Veri Kümesi.....	10
3.2. Öznitelik Çıkarımı	12
3.3. Derin Öğrenme Yöntemleri	16
3.3.1. Konvolüsyonel Sinir Ağları.....	17
3.3.2. Hazır Konvolüsyonel Sinir Ağları Mimarileri	21
3.4. Makine Öğrenme.....	25
3.4.1. Makine Öğrenme Algoritmaları	25
4. DENEYSEL SONUÇLAR.....	28
4.1. Deneysel Kurulum.....	28
4.2. Başarı Ölçütleri	30
4.3. Analiz Sonuçları	32
4.3.1.CNN Modelinden Elde Edilen Sonuçlar	32
4.3.2. Makine Öğrenmesinden Elde Edilen Sonuçlar	38
4.3.3. Otokodlayıcı İle Elde Edilen Sonuçlar	51
5. TARTIŞMA VE SONUÇLAR.....	54
KAYNAKLAR.....	58

TABLÖLER LİSTESİ

Sayfa

Tablo 4.1. Sınıflandırma hata matrisi	30
Tablo 4.2. İkili sınıflandırma 10-kat çapraz geçirme ile elde edilen sonuçlar.....	32
Tablo 4.3. Çoklu sınıflandırma 10-kat çapraz geçirme ile elde edilen sonuçlar	35
Tablo 4.4. HOG özelliklerinin KNN ile ikili sınıflandırılması	38
Tablo 4.5. HOG özelliklerinin KNN ile çoklu sınıflandırılması	39
Tablo 4.6. HOG özelliklerinin SVM ile ikili sınıflandırılması.....	40
Tablo 4.7. HOG özelliklerinin SVM ile çoklu sınıflandırılması.....	42
Tablo 4.8. HOG özelliklerinin NB ile ikili sınıflandırılması	43
Tablo 4.9. HOG özelliklerinin NB ile çoklu sınıflandırılması	44
Tablo 4.10. HOG özelliklerinin RF ile ikili sınıflandırılması.....	45
Tablo 4.11. HOG özelliklerinin RF ile çoklu sınıflandırılması.....	46
Tablo 4.12. Encoder özelliklerinin KNN ile ikili sınıflandırılması	47
Tablo 4.13. Encoder özelliklerinin SVM ile ikili sınıflandırılması	48
Tablo 4.14. Encoder özelliklerinin NB ile ikili sınıflandırılması	50
Tablo 4.15. Encoder özelliklerinin RF ile ikili sınıflandırılması	50
Tablo 4.16. Otokodlayıcı ikili sınıflandırma ile elde edilen sonuçlar.....	52
Tablo 4.17. Otokodlayıcı çoklu sınıflandırma ile elde edilen sonuçlar.....	53

ŞEKİLLER LİSTESİ

Sayfa

Şekil 3.1. Sınıflandırma Yapısının Genel Diyagramı	8
Şekil 3.2. Normal ve Hastalıklı Göz.....	11
Şekil 3.3. Normal, Katarakt, Diyabetik-Retinopati ve Glokom Göz.....	11
Şekil 3.4. Veri Kümesinin Çoklu Sınıflara Göre Dağılımı.....	12
Şekil 3.5. Veri Kümesinin İkili Sınıflara Göre Dağılımı.....	12
Şekil 3.6. HOG Öznitelikleri İle Elde Edilmiş Bir Görüntü	13
Şekil 3.7. HOG Öznitelik Vektörünün Oluşturulması	14
Şekil 3.8. HOG Öznitelik Vektörünün Elde Edilmesi	14
Şekil 3.9. Otokodlayıcı Mimarisi Veri Sıkıştırma Şeması	15
Şekil 3.10. Otokodlayıcı Şeması.....	16
Şekil 3.11. Yapay Sinir Ağı Bir Katman	17
Şekil 3.12. Yapay Sinir Ağı Hücresi	17
Şekil 3.13. Genel CNN Mimarisi	18
Şekil 3.14. İki Boyutlu Konvolüsyonel İşlemi	19
Şekil 3.15. Düzleştirilmiş Doğrusal Birim Grafiği	19
Şekil 3.16. Ortalama ve Maksimum Havuzlama İşlemleri	20
Şekil 3.17. Tam Bağlı Katman	21
Şekil 3.18. Genel DenseNet Mimarisi	22
Şekil 3.19. Genel EfficientNet Mimarisi	22
Şekil 3.20. Genel VGG Mimarisi	23
Şekil 3.21. Genel ResNet Mimarisi	24
Şekil 3.22. Genel Xception Mimarisi	24
Şekil 3.23. Destek Vektör Makinesi	26
Şekil 3.24. Naïve Bayes Sınıflandırıcısı	26
Şekil 3.25. KKN En Yakın Komşu Algoritması	27
Şekil 3.26. Rastgele Orman Algoritması	28
Şekil 4.1. K-Kat Çarpaz Geçerleme	29
Şekil 4.2. EfficientNet İkili Karmaşıklık Matrisi	33
Şekil 4.3. DenseNet İkili Karmaşıklık Matrisi	33
Şeki 4.4. Xception İkili Karmaşıklık Matrisi	34
Şekil 4.5. VGG İkili Karmaşıklık Matrisi	34

Şekil 4.6. ResNet İkili Karmaşıklık Matrisi	36
Şekil 4.7. EfficientNet Çoklu Karmaşıklık Matrisi	36
Şekil 4.8. DenseNet Çoklu Karmaşıklık Matrisi	36
Şekil 4.9. Xception Çoklu Karmaşıklık Matrisi	37
Şekil 4.10. VGG Çoklu Karmaşıklık Matrisi	37
Şekil 4.11. ResNet Çoklu Karmaşıklık Matrisi	37
Şekil 4.12. KNN (3) İkili Karmaşıklık Matrisi	39
Şekil 4.13. KNN (5) İkili Karmaşıklık Matrisi	39
Şekil 4.14. KNN Çoklu Karmaşıklık Matrisi	40
Şekil 4.15. SVM (RBF) İkili Karmaşıklık Matrisi	41
Şekil 4.16. SVM (Linear) İkili Karmaşıklık Matrisi	41
Şekil 4.17. SVM (Sigmoid) İkili Karmaşıklık Matrisi	41
Şekil 4.18. SVM (Linear) Çoklu Karmaşıklık Matrisi	42
Şekil 4.19. SVM (Sigmoid) Çoklu Karmaşıklık Matrisi	42
Şekil 4.20. SVM (RBF) Çoklu Karmaşıklık Matrisi	43
Şekil 4.21. NB İkili Karmaşıklık Matrisi	44
Şekil 4.22. NB Çoklu Karmaşıklık Matrisi	45
Şekil 4.23. RF (200) İkili Karmaşıklık Matrisi	46
Şekil 4.24. RF (300) İkili Karmaşıklık Matrisi	46
Şekil 4.25. RF (200) Çoklu Karmaşıklık Matrisi	47
Şekil 4.26. RF (300) Çoklu Karmaşıklık Matrisi	47
Şekil 4.27. KNN (3) İkili Karmaşıklık Matrisi	48
Şekil 4.28. KNN (5) İkili Karmaşıklık Matrisi	48
Şekil 4.29. SVM (Sigmoid) İkili Karmaşıklık Matrisi	49
Şekil 4.30. SVM (Linear) İkili Karmaşıklık Matrisi	49
Şekil 4.31. SVM (RBF) İkili Karmaşıklık Matrisi	49
Şekil 4.32. NB İkili Karmaşıklık Matrisi	50
Şekil 4.33. RF (200) İkili Karmaşıklık Matrisi	51
Şekil 4.34. RF (300) İkili Karmaşıklık Matrisi	51
Şekil 4.35. Otokodlayıcı İkili Karmaşıklık Matrisi	52
Şekil 4.36. Otokodlayıcı Çoklu Karmaşıklık Matrisi	54

SİMGELER VE KISALTMALAR LİSTESİ

AE	Otokodlayıcı (AutoEncoder)
CNN	Konvolüsyonel Sinir Ağları
ML	Makine Öğrenmesi (Machine Learning)
DR	Diyabetik Retinopati
DRN	Derin Kalıntı Ağlar
ESA	Evrişimli Sinir Ağı
DANS	Veri Arşivleme ve Ağ Oluşturma Hizmetleri
SVM	Destek Vektör Makinesi
RF	Rastgele Orman
NB	Naive Bayes Sınıflandırıcısı
KNN	K-En Yakın Komşu Algoritması
MCC	Matthews Katsayısı Korelasyonu
HOG	Yönlü Gradyanların Histogramı
ReLu	Düzleştirilmiş Doğrusal Birim
FFA	Fundus Floresein Anjiyografi

1. GİRİŞ

Günümüzde insanların yaşadığı göz hastalıkları genetik ve çevresel faktörlere bağlı olarak kendini göstermektedir. Oluşan bu göz hastalıkları toplumda yaygın olarak görülmekte olup her hastalığın semptomları farklıdır. Bu semptomların neler olduğu ve insan yaşantısına etkisinin nasıl olduğu konusunda çeşitli araştırmalar yapılmaktadır. Dünya genelinde yaygın olarak görülen göz hastalıkları çeşitli nedenlere bağlı olarak değişir. Gözün yapısında ve işlevinde meydana gelen hasarlar sonucunda göz hastalıklarının belirtileri ortaya çıkmaktadır. Ortaya çıkan belirtiler insanlarda her yaşta görülebilir. Gözde oluşan belirtilere göre görme duyusundaki azalma insanın tüm hayat kalitesini olumsuz etkileyebilir. Dünya Sağlık Örgütü'nün 2021 verilerine göre, dünya genelinde yaklaşık olarak 253 milyon insanın göz hastalıklarıyla ilgili sorunlar yaşadığı bilinmektedir [1].

1.1. Tanım ve Motivasyon

Göz hastalıkları konusunda bu hastalıkların neler olduğunu bilmek ve bu bilinçle hareket etmek hasta yaşamını etkileyen önemli adımdır. Göz hastalıkları başlangıçta belirti vermeyebilir ve semptomları hafif olabilir. Semptomların önlenmesi ve göz sağlığının korunması için düzenli göz muayeneleri kritik öneme sahiptir. Düzenli göz muayeneleri ile hastalığın doğru analizi ve erken tespit edilmesi sağlanarak ileride daha büyük sorunlara yol açılması engellenebilir. Her göz hastalığı için farklı teşhis yöntemleri uygulanabilir. Hastanın özelliklerine ve gözün verdiği semptomlara göre bir teşhis oluşturulması önem taşımaktadır. Bu nedenle, hastalığın iyi bir şekilde analiz edilmesi etkili teşhis yöntemi sağlamaktadır.

Göz hastalıklarının sebepleri çevresel, yaş, travmalar, sağlık sorunları ve genetik etkene bağlıdır. En önemli etkenlerden çevresel ve genetik faktörler kişinin görme bozukluğuna sebep olmaktadır. Son yıllarda teknolojik aletlerin kullanımının artmasıyla orantılı bir şekilde görme bozuklukları da artış göstermektedir. Görme hastalıklarının yaş oranlarına bakıldığında oldukça küçük yaşlarda da görülmeye başlanmıştır. Görme bozukluğunun kolay fark edildiği en yaygın olarak bilinen sebeplerin başında, göze giren bir madde sonucu gözün hasar alması ve görmeyi zorlaştırması, gözün çok fazla ışığa maruz kalması, teknolojik cihazlara çok yakından bakılması, göz yaşı kanallarının tıkanması, şeker hastalığı kontrol edilmediği sürece görme kaybına yol açması, genetik faktörlerden aile bireylerinde bulunan göz hastalığının kişiye aktarılması, enfeksiyon, alerji ve vitamin eksikliğinden dolayı göz rahatsızlığı başlaması, bulunmaktadır [2]. Bilindiği gibi göz hastalıkları; göz zarı, göz merceği ve sinirler de meydana

gelen rahatsızlıklar sonucu ortaya çıkmaktadır. Rahatsızlardan bazıları katarakt, diyabetik-retinopati ve glokomdur. Katarakt, bir göz rahatsızlığı olup kişinin görme şeklini bulanıklaştırarak görme kalitesinin düşmesine sebep olur. Kişinin görme kalitesinin düşmesi önemli göz problemlerine yol açmaktadır. Katarakt sorunu zamanla ilerleyerek insanlarda daha ciddi görme sorununa sebep olur. Katarakt, başlangıçta hafif bir bulanık görme olarak başlasa da zamanla bu bulanıklık yoğunlaşır. Göz merceğinin bulanıklaşması ile görme kalitesi zamanla düşer. Hastalığın ilerleyen aşamaları ameliyat gerektirebilen bir durumdur. Ancak erken tanı ile bunun önüne geçilerek katarakt hastalığının ilerlemesi yavaşlatılabilir veya engellenebilir.

Göz hastalıklarından bir diğeri de diyabetik-retinopati göz hastalığıdır ve kişinin diyabet hastalığına sahip olması durumunda sadece insülin direnci gibi durumları etkilemekle kalmaz, aynı zamanda göz sağlığını da önemli ölçüde etkiler. Diyabet hastalığına bağlı olarak retinada meydana gelen hasarı tanımlayan bir göz hastalığı olan diyabetik-retinopati göz damarlarına büyük ölçüde zarar vermektedir. Hastalık ilerlediği zaman görme kaybına yol açmaktadır. Bu nedenle, diyabet hastalarının göz sağlığına özen göstermeleri ve düzenli göz muayenelerine gitmeleri önemlidir. Erken teşhis ve uygun tespit yöntemleri, göz hastalığının ilerlemesini yavaşlatabilir veya durdurabilir.

Glokom, diğer göz hastalıklarından biridir ve göz tansiyonu olarak da bilinir. Bu hastalık, bulanık görme, baş ağrıları ve zaman zaman göz içinde basınç hissi gibi belirtilerle kendini gösterebilir. Hastalar genellikle bu belirtileri hemen anlamayabilirler. Glokom hastalığı belirti vermeden ilerleyebilir ve kişi farkında olmadan görme kaybı yaşayabilir. Glokomun erken tespiti görme kaybını önlemek açısından büyük öneme sahiptir. Bu nedenle glokom gibi hastalıkların erken tespiti önemlidir. Erken ve doğru tespit uygulanmasıyla görme kaybının önlenmesine yardımcı olunabilir.

Dünya Sağlık Örgütü'nün 2021 verilerine göre, dünya genelinde görme kaybı ve görme bozukluğunun en az 2.2 milyar kişiyi etkilemektedir. Bunların 1 milyarı önlenabilir görme bozukluğuna sahiptir [3]. Yaşam kalitesini büyük ölçüde etkileyen görme bozukluğu kişilerin bulunduğu tüm alanları olumsuz yönde etkilemektedir. Dünya genelinde en az 450 milyon çocuk teşhis gerektiren bir görme sorunu yaşamaktadır [2]. Hastalık sürecinde doğru tespit yöntemi çok önemlidir. Yanlış hastalık tespiti yöntemleriyle kişilerde görme bozukluğu oranları artmaktadır. Kişiler yaşına ve gözündeki problemlere göre düzenli bir şekilde görme seviyesini ve göz sağlığını değerlendirebileceği kontroller yaptırmalıdır. Hastalığın tanısında uygulanan yöntemler gelişim gösterse de bazı durumlarda bunun yeterliliği konusunda sıkıntı yaşanmaktadır. Yanlış teşhis, hastalığın yanlış sınıflandırılmasına, hastanın yaşam kalitesinin düşmesine, doktorların iş yüklerinin artması ve zaman kayıplarına neden olabilir. Doğru teşhis

yöntemlerini desteklemek için de günümüzde birçok çalışma yapılmaktadır. Sağlık alanında teknolojilerinde gelişmesi ile yapay zeka teknolojilerinin göz hastalıklarının tanısında kullanılması büyük bir etkiye sahip olmuştur. Yapay zeka, kişilere göz hastalıklarının tespiti için daha hızlı ve daha kaliteli tespit yöntemi sağlamayı hedefleyebilir.

Bu tezin motivasyonu, sağlık alanında kullanılabilecek, hastanın yaşam kalitesini arttırabilecek bir sistemin yapay zeka modelleri ile tasarlanıp gerçekleştirilmesidir. Yapay zeka, göz görüntülerini analiz ederek göz hastalıklarını erken teşhis etme ve hastalığın ilerleme sürecini takip etme gibi birçok alanda yardımcı olabilir. Yapay zeka, büyük veri setleri üzerinde eğitildiğinde, göz hastalıklarının tespiti yönetiminde sağlık sektöründe büyük ölçüde önemli bir yere sahiptir. Göz hastalıklarında kullanılan yapay zeka ile yapılan çalışmalar, göz hastalıklarıyla mücadele konusunda yeni bir bakış açısı kazandırmayı amaçlamaktadır. Böylelikle göz problemi yaşayan kişilerin hastalık tanı süreçleri daha etkili bir şekilde yürütülür ve görme kaybı riski azaltılabilir.

1.2. Tez Çalışmasının Genel Katkıları

Bu bölümde, tez çalışmasının genel katkıları sunulmaktadır. Göz hastalığı tespiti yapan çalışmalarda Konvölüsyonel Sinir Ağları mimariler kullanılmıştır. Bu çalışmada CNN mimarilerinden farklı birden fazla model kullanılarak modellerin başarı performansları incelenmiştir.

Tez çalışmasının başka katkısı ise göz hastalığı sınıflandırılmasında CNN mimarilerinin karşılaştırılması alanındadır. CNN mimarilerinde farklı modeller, Otokodlayıcı ve makine öğrenmesi farklı algoritmalar kullanılarak sınıflandırma problemindeki başarı performansları kendi aralarında karşılaştırılmıştır. CNN, Otokodlayıcı ve makine öğrenmesi ile elde edilen başarı ölçütleri incelenmesi yapılmıştır.

Gözün ikili sınıflandırılma yapılarak normal ya da hastalıklı göz olup olmadığını belirlemek için bir yaklaşım geliştirilmektedir. Çoklu sınıflandırma da ise hastalıklardan katarakt, diyabetik-retinopati, glokom ve sağlıklı bireylerden veriler elde edilerek hastalıklı ya da normal göz tespiti yapılmaktadır. Veri kümesi oluşturulurken birçok kişinin göz hastalığı teşhisi sonucu elde edilen veriler alınarak hazırlanmıştır.

Genel olarak göz hastalıklarıyla ilgili yapılan çalışmalarda, geniş miktarda FFA görüntüsü içeren veri setleri sıklıkla kullanılmaktadır. Yapılan çalışmalarda genel olarak ikili sınıflandırmalar yapılmıştır. Bu çalışmada çoklu sınıflandırma çalışmalarında farklı hastalık çeşitlerine sahip veriler kullanılmıştır. Birden fazla veri setinin birleştirilip daha fazla örnek

sayısına sahip veri kümesinin kullanımı gerçekleştirilmiştir. Böylelikle hastalık tespit sınıflandırılmasında kişinin hangi hastalığa sahip olduğunun tespiti kolaylaşabilir.

1.3. Tez Planı

Bu tez şu şekilde düzenlenmiştir. Giriş ve tez çalışmasının katkıları bölümünde, göz hastalığı, göz hastalığı çeşitleri, derin öğrenme ve makine öğrenmesinin hastalık tespitine katkıları, derin öğrenme mimarileri hakkında detaylı bir bilgilendirme sunar. Alan bilgisi ve literatür bölümünde, göz hastalığı tespitinde uygulanan mevcut derin öğrenme ve makine öğrenme uygulamaları üzerine yapılan geçmiş çalışmalar ve kapsamlı bir literatür incelemesini sunar. Veri kümeleri bölümünde, göz hastalığı tespiti ve sınıflandırılmasında kullanılan veri kümelerine ait bilgiler sunulmuştur. Yöntemler bölümünde, göz hastalığı tespiti çalışmasında önerilen Konvolüsyonel Sinir Ağları mimarisi ve modelleri hakkında genel bilgileri, makine öğrenme yöntemleri ve özneteliklerin çıkarılması ve sınıflandırılmasını içermektedir. Deneysel sonuçlar bölümünde, deneysel kuruluma, kullanılan başarı ölçütlerine ve göz hastalığı tespiti ile sınıflandırması çalışmaları için detaylı analiz sonuçlarına yer verilmiştir. Sonuç bölümünde, deneylerden elde edilen sonuçlar yorumlanarak elde edilen kazanım ve yapılan katkılar belirlenmeye çalışılmıştır.

2. ALAN BİLGİSİ VE LİTERATÜR

Göz hastalığı sınıflandırma çalışmaları, yapay zeka teknolojilerinin kullanıldığı önemli alanlardan biridir. Katarakt, diyabetik-retinopati ve glokom gibi göz hastalıkları için yapılan sınıflandırma çalışmaları, göz hastalıklarının teşhisinde doğruluk oranlarını artırma ve hastalıkların daha erken aşamalarda teşhis edilmesini amaçlamaktadır. Geliştirilen bu sınıflandırma yöntemleri sayesinde, göz hastalığı teşhisinde önemli bir ilerleme potansiyeli ortaya çıkmaktadır.

Literatürde göz hastalığına bağlı olarak çeşitli çalışmalar bulunmaktadır.

Ağalday ve diğerleri., [4] renkli FFA görüntüler kullanılarak katarakt hastalığına otomatik tanı sistemi çalışması yapmışlardır. Çalışmada, Konvolüsyonel Sinir Ağları ve Derin Kalıntı Ağlar (DRN) kullanılarak sınıflandırma yapılmıştır. Veri kümesi Çin’de bulunan bir şirket Shangdong Medical Technology Co., Ltd. Şirketi tarafından farklı hastane ve tıp merkezlerinden elde edilen veriler toplanmıştır. Gerçek hasta bilgilerini temsil eden 5000 hastanın sağ ve sol gözüne ait 6392 renkli FFA görüntülerinden oluşmaktadır. Eğitim kümesinde 8 farklı hasta etiketine sahip verilerden farklı evrelere ait katarakt görüntüleri kullanılmıştır. Katarakt tespiti aşamasında, tüm verilerin %80’i eğitim ve doğrulama için ve ayrıca tüm verilerin %20’si test için rastgele kullanılmıştır. CNN ve DRN yöntemlerinin genel başarı ölçütleri karşılaştırıldığında DRN yönteminin daha yüksek başarı elde ettiğini görülmüştür. CNN yönteminde doğruluk oranı %89, DRN yönteminde doğruluk oranı %95 olarak hesaplanmıştır. Özçelik ve Altan, [5] Diyabetik Retinopati (DR) erken teşhis için FFA görüntüleri kullanılarak derin öğrenme tabanlı bir model geliştirmişlerdir. Modelin aşırı öğrenmesinin engellenebilmesi için FFA görüntülerine iki boyutlu sinyal işleme teknikleri uygulanmış ve derin öğrenme tekniklerinden ESA ve transfer öğrenmesi yöntemleri kullanılarak sınıflandırması ile geliştirilen model iki aşamalı olarak oluşturulmuştur. Kullanılan veri kümesinde sağlıklı (DR yok), hafif Non-Proliferatif DR (NPDR), orta NPDR, şiddetli NPDR ve Proliferatif DR (PDR) toplam 5 sınıf kullanılmıştır. Çalışmada, Asya Pasifik Tele-Oftalmoloji Derneği (Asia Pacific Tele-Ophthalmology Society-APTOS) tarafından düzenlenen veri seti kullanılmıştır. Veri kümesi toplam 5100 adet veriden oluşmakta ve bunların 900 tanesi test verisi olarak kullanılmıştır. FFA görüntüleri üzerinde 150×150 piksel boyutunda ölçeklendirme yapılarak, eğitim sırasında Adam optimizasyonu kullanılarak, öğrenme oranı 10-5, batch boyutu 32 ve döngü değeri 100 değerleri ayarlanmıştır. Modelde 10 kat çapraz doğrulama yöntemi kullanılarak hesaplamalar model performans metrikleri ile hesaplanmıştır. Önerilen modelin sınıflandırma performansı doğruluk %97.8 olarak ölçülmüştür.

Yalcin ve diğerkleri, [6] retina görüntülerinden diyabetik-retinopati görüntülerini kullanarak hastalık tespiti için derin öğrenme yaklaşımını kullanmışlardır. Çalışmada farklı retinal görüntüleri kullanarak görüntüleri boyutlandırıp standart hale getirmişlerdir. Sınıflandırma Konvolüsyonel Sinir Ağları modeli üzerinde yapılmıştır. %98.5 doğruluk oranında başarı elde etmişlerdir. Eğitime CPU ve GPU kullanmışlardır.

Yıldırım ve diğerkleri, [7] FFA görüntülerinden glokom tespit etmeyi amaçlamışlardır. Konvolüsyonel Sinir Ağı modellerinden AlexNet, ResNet-18, VGG16, SqueezeNet ve GoogleNet kullanarak modellerin başarı ölçütlerini hesaplamışlardır. Çalışmada genel erişime açık glokom veri kümesinden 500 sağlıklı bireye ve 500 glokom hastasına toplam 1000 görüntü kullanılmıştır. Veriler FFA görüntülerinden oluşan Origa (-light) veri kümesinden alınmıştır. Alınan FFA görüntüleri %65 eğitim, %15 doğrulama, %20 test veri kümesi için ayrılmıştır. Modeller arasında sonuçlar değerlendirildiğinde, test veri kümesinde duyarlılık için en iyi sonucun %97.96 ile VGG16, özgüllük, doğruluk ve f-skor için en iyi sonucun sırasıyla %98.97, %97.98 ve %98 ile GoogleNet olduğu tespit edilmiştir.

Metin ve diğerkleri, [8] makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak Optik Koherans Tomografisi (OKT) görüntüleri üzerinde çalışmışlardır. OKT veri kümesi halkın kullanımına açık bir veri kümesi olup California San Diego üniversitesi, California Retinal Araştırma Vakfı, Shanghai First People's Hastanesi ve Beijing Tongren Göz Merkezinden alınan veri kümelerinden oluşmaktadır. Toplam 84.495 görüntü üzerinde çalışma yapılmıştır. ResNet50 ve MobileNetV2 modellerini eğitmek için veri kümesini %75'i eğitim, %10'nu doğrulama ve %15'i test olarak kullanmışlardır. Çalışmada bilgisayarlı görü ve görüntü işleme alanlarında sıklıkla kullanılan CNN kullanmışlardır. CNN modellerinden ResNet50 ve MobileNetV2 modellerini kullanarak modeller arasında performans değerlerini birlikte dikkate almışlardır. Model eğitim aşamasında doğrultulmuş biçimli doğrusal birim (Rectified Linear Unit, ReLU) ve softmax aktivasyon fonksiyonunu kullanmışlardır. Kullanılan modellerin ortalaması F1 skoru; Myopic Choroidal Neovascularization (MKV-CNV)) için %75, Drusen için %86, Diyabetik Makula Ödemi (Diabetic Macular Edema (DMÖ-DME)) için %90 ve normal yapıdaki retinalar için ise %96 olarak elde etmişlerdir.

Bistulfi ve diğerkleri, [9] yapay zeka yöntemlerini kullanarak görüntü işleme üzerinde çalışmışlardır. Derin öğrenme mimarilerinden ResNet50, DenseNet ve VggNet-16 gibi farklı mimarilerle derin öğrenme tekniğini uygulamışlardır. Göz görüntülerinden glokom hastalığının tespitine yardımcı olacak sistem geliştirmeyi amaçlamışlardır. Göz görüntülerinden 512 görüntüden oluşan glokom görüntüleri kullanmışlardır. Model eğitim aşamasında Softmax, ReLU ve Sigmoid gibi aktivasyon fonksiyonlarının görüntü sınıflandırması için fonksiyonlar

kullanmışlardır. Kullanılan modellerden ResNet50, DenseNet ve VggNet-16 mimarilerden üç mimarinin %80'nin üzerinde sonuçlar elde etmişlerdir.


Bulut ve diğerleri, [10] renkli FFA görüntüler kullanarak göz hastalıkları üzerinde çalışmışlardır. Göz hastalıklarının otomatik olarak sınıflandırılmasını, tedavi gerektiren ve tedavi gerektirmeyen retina bozukluklarını tanımlamayı amaçlamışlardır. Sınıflandırmada Konvolüsyonel Sinir Ağı metodolojisini kullanmışlardır. Konvolüsyonel Sinir Ağı mimarisinden EfficientNet -B6 modelini kullanmışlardır. Modelde, Akdeniz Üniversitesi (AU) Hastanesi Göz Hastalıkları Anabilim Dalı'ndan alınan 21.842 adet renkli FFA görüntüsü kullanmışlardır. Veri setinin %80'i eğitime, %20'si doğrulamada kullanılmıştır. EfficientNet-B6 modelinin test aşamasında genel veri kümeleri ve kendilerinin oluşturdukları Klinik büyük FFA (EyeCheckup) veri setini kullanılmıştır. EfficientNet-B6 modelinin performans sonuçlarını, test veri seti ile %94.39 hassasiyet, %86.04 özgüllük ve %86 doğruluk elde etmişlerdir.

Malik ve diğerleri, [11] makine öğrenme algoritmalarını kullanarak göz hastalıklarının teşhisi üzerinde çalışmışlardır. Karar ağacı, Rastgele Orman, Naive Bayes Sınıflandırıcısı ve yapay sinir ağı algoritmaları gibi farklı sınıflandırma algoritmaları kullanmışlardır. Göz hastalığının teşhisini kolaylaştırmak için verilerin uluslararası standart bir formatta kaydetmeyi amaçlamışlardır. Verileri kaydedilebileceği bir arayüz geliştirerek veri girişlerinin yapılmasını sağlamışlardır. Veri girişleri hasta verilerini, yaş, hastalık gibi özellikleri içeren bir sistem tasarlamışlardır. Sistem bu sayede semptomlar için yeni sınıflandırmalar ekleyerek kendi kendine öğrenmeyi sağlamak için tasarlanmıştır. Sınıflandırma sonuçlarında Rastgele Orman ve karar ağacı algoritmalarının tahmin oranı %90'ın üzerinde olduğunu ve diğer algoritmalarından daha iyi sonuçlar verdiğini görmüşlerdir.

Khan ve diğerleri, [12] gözün herhangi bir hastalığa sahip olup olmadığını tahmin ederek hastalık tiplerini sınıflandırma üzerinde çalışmışlardır. Derin öğrenme Konvolüsyonel Sinir Ağları modelinden VGG-19 mimarisini kullanmışlardır. Veri seti olarak sekiz farklı FFA sınıfına ait 5000 görüntüyü içeren ODIR veri setini kullanmışlardır. Scikit-learn kütüphanesinin eğitim-test ayırma yöntemini kullanarak %70 eğitim, %30 test için kullanmışlardır. Eğitim sonunda hastalıklı ve normal sınıflandırma sonuçları elde etmişlerdir. Normal ve patolojik miyopi sınıfı için %98,1, normal ve katarakt için %94,03, normal ve glokom için %90,94 doğruluk sonuçları elde etmişlerdir.

3. MATERYAL VE YÖNTEM

Göz hastalığı tespiti için tez kapsamında makine öğrenmesi ve derin öğrenme yöntemlerinde Python programlama dili kullanılmıştır. Yapılan çalışmada, Python dili için tamamen bulut tabanlı bir geliştirme ortamı olan Google Colab kullanılmıştır. Görüntü tanıma ve hastalık tespiti problemleri birer sınıflandırma problemi olarak tanımlanmıştır. Sınıflandırma yapısının genel diyagramı Şekil 3.1’ de gösterilmiştir.



Şekil 3.1. Sınıflandırma Yapısının Genel Diyagramı

Veri ön işleme adımı sınıflandırma için göz görüntüleri birleştirilerek veri kümesi oluşturulmuştur. Çeşitli kaynaklardan hastalıklı ve normal göz görüntüleri toplanarak, veriler eğitim, doğrulama ve test verisi olarak bölünmüştür. Oluşturulan veri kümesinde öznitelik vektörü oluşturulup öznitelik çıkarımı yapılmıştır. Sınıflandırma için seçilen modellerin eğitimi yapılmıştır. Model öğrenme adımından sonra gerçek sınıfları doğru tahmin etmesi sağlanarak öğrenme süreci gerçekleştirilmiştir. Eğitim ve doğrulama süreçlerinden sonra test verileri kullanılarak sınıflandırma yapılmıştır. Test veri setindeki hastalıklı ve normal göz görüntüleri üzerinde tahminler yapılarak tahminlerin performans metrikleri hesaplanmıştır.

Yapılan araştırmada derin öğrenme ve makine öğrenme algoritmalarından Python programlama dilindeki opencv, pandas, glob, skimage, numpy, scipy, matplotlib, tensorflow, keras, sklearn kütüphaneleri kullanılmıştır.

OpenCV, Intel'de 1999 yılında Gary Bradsky tarafından başlatılan ve ilk sürüm 2000 yılında çıkan bir çok bilgisayarlı görü algoritmasına sahip görüntü işlemede kullanılan açık kaynaklı bir kütüphanedir. OpenCV çeşitli platformlarda çalışır. C++, Python, Java vb. gibi çok çeşitli programlama dillerini destekler. OpenCV bir Python API'sidir ve OpenCV-Python, OpenCV C++ API, Python dilinin en iyi özelliklerini birleştirir [17].

Pandas 'ilişkisel' veya 'etiketli' verileri çalışmayı kolay ve sezgisel hale getirmek için tasarlanan veri çerçeveleme yapmak için kullanılan bir Python paketidir. Verilerin esnek şekilde yeniden şekillendirmesi ve döndürmesini, diğer Python ve numpy yapılarındaki düzensiz farklı dizinlenmiş verileri DataFrame nesnelerine dönüştürmesini kolaylaştırır [18].

Glob, belirli bir dosya modelini aramak ve benzer adlara sahip dosyaları okumak için kullanılır. Python'un standart kütüphanesidir. Python'da dosya yollarını arar ve eşleştirmesini sağlayan bir kütüphanedir [19].

Skimage veya Scikit-image, görüntü işlemede kullanılan açık kaynaklı bir Python kütüphanesidir. Veri işleme, boyutsal küçültme, sınıflandırma ve küme analizi gibi özelliklere sahip bir kütüphanedir. Görüntü işleme için algoritma koleksiyonu olan Numpy ve Scipy ile çalışır [20].

Numpy, N boyutlu dizi ve matris işleme kütüphanesidir. Yüksek performanslı ve çok boyutlu dizilerle çalışmayı sağlayan bir Python paketidir. Çok boyutlu dizi nesneleri, matematiksel fonksiyonlar üzerinde etkili hesaplamalar için kullanılan bir kütüphanedir. [21].

SciPy, matematik, bilim, mühendislik için kullanılan açık kaynaklı bir Python kütüphanesidir. Optimizasyon, sayısal entegrasyon ve sinyal işleme gibi özelliklerde kullanılır. SciPy, NumPy dizileriyle çalışacak şekilde oluşturulmuştur [22].

Sklearn (Scikit-learn), Python 'da kullanılan makine öğrenme algoritmasıdır. Numpy ve scipy ve matplotlib üzerinde kurulmuştur. 2D olarak oluşturulmuş dizilerin sınıflandırma, regresyon ve boyutsallık azaltma gibi alanlarda kullanılır [23].

Matplotlib, Python programlama dilinde geliştirilen ve özellikle NumPy dizileri üzerinde etkili bir şekilde çalışabilen, veri görselleştirmesi için kullanılan çok platformlu bir kütüphanedir [24].

Tensorflow, Google'ın AI organizasyonu içindeki Google Brain ekibinden araştırmacılar ve mühendisler tarafından geliştirilen açık kaynak kodlu bir kütüphanedir. Makine öğrenmesi ve derin öğrenmede kullanılır. Yüksek performanslı sayısal hesaplamalar yapmak için kullanılan açık kaynaklı bir yazılımdır [25]. Keras, Google mühendisi Francois Chollet tarafından geliştirilen açık kaynaklı bir derin öğrenme kütüphanesidir. Derin sinir ağlarıyla daha hızlı ve


kolay deneyler yapmayı sağlamak amacıyla kullanılır. Python'da yazılmış bir kütüphanedir [26].

3.1. Retinal Fundus Görüntüleri Veri Kümesi

Göz hastalıklarının artmasıyla birlikte hastalık tespit yöntemleri de geliştirilmektedir. Teknolojinin ilerlemesiyle birlikte kullanılan yöntemler de çeşitlenmiş ve hastalık tespiti daha kolay hale gelmiştir. Özellikle derin öğrenme ve makine öğrenmesi alanlarında yoğun çalışmalar yapılmaktadır. Bu alanlarda veri kümesi oluşturmak için birçok göz hastalığının görüntü analizi yapılmaktadır. Bu konuda araştırma gerçekleştiren kişiler açık kaynaklı veri üzerinde çalışmalarını yapmaktadır.


Bu çalışmada hem ikili sınıflandırma hem de çoklu sınıflandırma veri kümesi yapılarına odaklanılmaktadır. Veri kümesi, gözle ilgili çeşitli görüntülerden oluşmaktadır. Bu görüntüler, çeşitli kaynaklardan elde edilmiştir; hastane kayıtları, medikal görüntüleme cihazları, bilimsel araştırmalar ve benzeri kaynaklardan temin edilen veriler kullanılmıştır.

Mendeley veriseti [13-14], Ortak Shantou Uluslararası Göz Merkezi'nden (JSIEC)'den [15] gelen veriler ve Hint Diyabetik Retinopati Görüntü Veri Kümesi (IDRID), Oculus [16] verileri bir araya getirerek çoklu sınıflandırma probleminde kullanılan veri kümesinde, 1074 normal, 1007 glokom, 1098 diyabetik-retinopati ve 1038 katarakt verileri olmak üzere toplamda 4217 veri kullanılmıştır. İkili sınıflandırma probleminde kullanılan veri kümesinde, 1374 normal ve 1374 hastalıklı veriler olmak üzere toplamda 2748 veri kullanılmıştır. Mendeley ve IDRID, Oculus veri setlerinde katarakt, diyabetik-retinopati, glokom ve sağlıklı olmak üzere 4 farklı sınıf bulunmaktadır. Ortak Shantou Uluslararası Göz Merkezi'nden alınan veri seti 39 sınıfa ait 1000 FFA görüntüsüne sahiptir. İkili sınıflandırmada kullanılan veri setinde normal ve hastalıklı olmak üzere iki farklı sınıf bulunmaktadır. Şekil 3.2'de sağlıklı (a) ve hastalıklı (b) göze sahip kişilerden alınan verilerden örnek verilmiştir.




Şekil 3.2. Normal ve Hastalıklı Göz [13]


Kategorik sınıflandırmada kullanılan veri setinde normal, katarakt, diyabetik-retinopati ve glokom olmak üzere dört farklı sınıf bulunmaktadır. Şekil 3.3’de katarakt (a), diyabetik-retinopati (b), glokom (c), sağlıklı (d) göze sahip kişilerden alınan verilerden örnek verilmiştir. Veri kümesinin çoklu sınıflara göre dağılımı Şekil 3.4 ve ikili sınıflara göre dağılımı Şekil 3.5’te gösterilmiştir.



Şekil 3.3. Normal, Katarakt, Diyabetik-Retinopati ve Glokom göz [16]



Şekil 3.4. Veri Kümesinin Çoklu Sınıflara Göre Dağılımı



Şekil 3.5. Veri Kümesinin İkili Sınıflara Göre Dağılımı


3.2. Öznitelik Çıkarımı

Öznitelik çıkarımı, verinin düşük düzeyli özelliklerini daha yüksek düzeyli özniteliklere dönüştürülmesini sağlar. Öznitelik çıkarımı sayesinde verinin özü korunarak veri daha iyi bir şekilde temsil edilir ve veri boyutu azaltılır. Bu sayede gereksiz ve anlamsız veriler ortadan kaybolur. Doğru ve anlamlı özniteliklerin çıkarılması ile daha iyi performans sonuçları elde edilir.

Öznitelik çıkarımı, derin öğrenme ve makine öğrenme yöntemlerinde kullanılan önemli bir adımdır. Derin öğrenme modelleri, genellikle çok katmanlı sinir ağlarıdır. Derin öğrenme

içerisindeki öğrenilebilir ağırlıklar belirli bir görevi yerine getirme özelliğine sahiptir. Veri üzerinde eğitilerek veriye özgü özellikler belirlenir. Konvolüsyonel Sinir Ağları (CNN) modeli gibi konvolüsyonel katmanlara sahip olanlar, veri içerisindeki önemli özellikleri otomatik olarak tespit ederler. Bu sayede CNN, eğitimin tasarlanmış özelliklere ihtiyaç duymadan öznelik çıkarımını gerçekleştirir. Çok boyutlu girdi verilerini etkili bir şekilde modellemek için tasarlanmıştır. Farklı soyut düzeyleri temsil eden birçok katmanlı yapı aracılığıyla veri kümesindeki özellikleri öğrenilebilir [65].

Makine öğrenmesi yöntemlerinde sınıflandırma işlemi için manuel olarak öznelik çıkarımı yapılır. Makine öğrenmesinde öznelik çıkarımı için farklı yöntemler vardır. Bu yöntemlerden birisi de yönlü gradyanların histogramı (HOG) kullanılarak yapılan öznelikleri çıkarma yöntemidir. HOG, nesne tanıma ve görüntü işleme alanlarında kullanılır. HOG bir nesnenin yapısına ve şekline odaklanır. Görüntünün kenar ve şekil bilgilerini hesaplar ve görüntünün piksel değerlerinden daha anlamlı verileri yakalar [27]. Görüntüdeki önemli olmayan bölümler göz ardı edilir. HOG, görünümün şeklinin yoğunluk gradyanlarının dağılımını sağlar [67]. HOG görüntüyü gri tonlama ile dönüştürme (Şekil 3.6) görüntüyü hücrelere ayırma, hücrelerin gradyan yönlerini hesaplama, hücrelerin gradyan yönleri üzerinde histogram oluşturma, bloklara ve blok normalizasyonuna ayırma ve HOG vektörünü oluşturma adımlarından oluşur.




Şekil 3.6. HOG Öznelikleri İle Elde Edilmiş Bir Görüntü [28]


HOG öznelik vektörünü hesaplamak için önce yatay ve dikey gradyanları hesaplamak gerekir (3.1) [27]. Gradyanlar, görüntüdeki kenarları ve köşeleri tespit etmek için kullanılır

$$g_x = I * h_x \text{ ve } g_y = I * h_y \quad (3.1)$$

Filtrelenmiş bir görüntü oluşturulduktan sonra, her pikselin gradyan büyüklüğü ve yönü hesaplanır. Gradyan büyüklüğünün ve yönünün hesaplanması ile histogram oluşturulur. Histogram esas olarak 0, 20, 40, 60 ... 160 açılara karşılık gelen 9 kutudan oluşan bir vektördür [27]. Bu vektör, görüntünün kenar ve şekil özelliklerini temsil eder. İlk olarak, belirli bir hücredeki ilgili pikselin gradyan açısı veya yönelimi değeri incelenir. Şekil 4.2’de gösterilen mavi ile çevrelenmiş pikselin açısı 80 derece ve büyüklüğü 2’dir. Aralıklardan 0, 20, ..., 140 ve 160 dereceleri kapsayan 5. bölmeye 2 eklenir. Kırmızı ile çevrelenmiş gradian 10 derecelik bir açısı vardır ve 4’lük bir büyüklüğü vardır. 10 derece 0-20 arasında olduğu için 4 birimlik büyüklük ikiye bölünür (Şekil 3.7). Son olarak 8x8 hücrelerdeki tüm piksel ağırlıkları toplanır ve 9 bölmeli histogram oluşturulur (Şekil 3.8).




Şekil 3.7. HOG Öznitelik Vektörünün Oluşturulması [28]



Şekil 3.8. HOG Öznitelik Vektörünün Elde Edilmesi [28]


Otokodlayıcı (AE) denetimsiz öğrenme için kullanılır ve yapay sinir ağıdır [29]. Otokodlayıcı boyut indirgeme (dimensionality reduction) işlemi yaparak gereksiz verileri filtreler. Filtreme işlemi sırasında veri boyutu azaltılır. Bu işlemler sayesinde öznitelik çıkarma, nesne tanıma ve analizi gibi alanlarda sıkça uygulandığı görülmektedir. Otokodlayıcı veri sıkıştırma işlemlerinde kullanılabilir. Veri içindeki önemli inputları alarak öznitelik çıkartır. Sinir ağına girdi olarak verilen verileri alarak çıktı katmanına kopyalayarak taşır. Bu süreçte, veri boyutunu azaltır ve gereksiz verileri atar. Otokodlayıcı denetimsiz öğrenme modelinin özel bir durumu olarak girdi verisinin çıktı katmanında yeniden oluşturmak üzere eğitir [30]. Herhangi bir veriyi koda dönüştürmeyi otomatik olarak öğrenmeyi amaçlamaktadır. Görüntü ConvNet adı verilen bir kodlayıcıdan geçerek sıkıştırılır. ConvNet kod çözücü orijinal görüntüyü tekrar oluşturur.

Otokodlayıcı da her konvolüsyonel katman bir maksimum havuzlama katmanının boyutunu azaltarak takip eder. Kod çözücü (decoder) girdi verilerini yeniden yapılandırılmış bir görüntüye dönüştürür. Şekil 3.9’da Otokodlayıcı mimarisinin şeması gösterilmektedir.



Şekil 3.9. Otokodlayıcı Mimarisi Veri Sıkıştırma Şeması [31]


Otokodlayıcı yapısında kodlayıcı ve kod çözücü birbirlerine simetrik özelliktedir. Kodlayıcı (Encoder) ve Kod çözücü (Decoder) kısımlarından oluşur. Şekil 3.10'da Otokodlayıcı şemasında görüldüğü üzere kod çözücü, Otokodlayıcı modelindeki bir bileşen olup verileri yeniden oluşturma aşamasında kullanılır. Kodlayıcı verileri sıkıştırma adımında kullanılır.



Şekil 3.10. Otokodlayıcı Şeması [31]


3.3. Derin Öğrenme Yöntemleri

Derin öğrenme algoritmaları, büyük miktarda verileri analiz ederek görüntü işleme, ses ve metin türlerini işleme alanlarında kullanılır. Yapay zeka alanında kullanılan bir yöntem olup temelinde sinir ağı katmanlarından oluşur. Derin öğrenmenin temeli yapay sinir ağı yapısına dayanır. Yapay sinir ağları, insan beyninin sinir hücrelerinin çalışma şekline benzer yapıda çalışır [32]. Karmaşık problemlerin çözümünde ve yüksek seviyeli soyut problemlerin öğrenilmesinde kullanılır. Yapay sinir ağları, katmanlardan oluşmaktadır. Şekil 3.11'de bir katmanlı yapay sinir ağı gösterilmiştir. Tek katmanlı yapay sinir ağı girdi ve çıktı katmanlarından oluşur. Çok katmanlı yapay sinir ağları girdi katmanı, gizli katman ve çıktı katmanlarından oluşmaktadır.



Şekil 3.11. Yapay Sinir Ağı Bir Katman [32]

Yapay Sinir Ağı hücresi 5 bölümden oluşmaktadır. (Şekil 3.12) Bu bölümler girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu, çıktılarıdır. Girdiler nöronlara gelen ilk veriler olup dış dünyadan gelen verileri temsil eder. Girdi değerler ağırlık değerleri çarpılır ve toplama fonksiyonu (birleştirme fonksiyonu) oluşur. O bilgilerin net girdisi toplama fonksiyonunda oluşur. Aktivasyon fonksiyonunda toplama fonksiyonundan gelen bilgiler işlenir ve çıkış değeri üretir.




Şekil 3.12. Yapay Sinir Ağı Hücresi [33]

3.3.1. Konvolüsyonel Sinir Ağları

Derin öğrenme modellerinden biri olan CNN görüntü işleme, nesne tanıma problemlerinde, sınıflandırma ve tanıma işlemlerinde yaygın olarak kullanılır. CNN modeli ilk defa 1988’de Fukushima tarafından önerilen yöntemdir. [34]

CNN’ler, görüntü verilerinin özelliklerini çıkarmak için özel olarak tasarlanmış katmanlardan oluşur. Bu katmanlar konvolüsyonel katman, aktivasyon katmanı, havuzlama katmanı, tam

bağlı katman, sınıflandırıcı katmanlarından oluşur. Şekil 3.13'te CNN mimarisinin genel bakış açısı gösterilmektedir.




Şekil 3.13. Genel CNN Mimarisi [35]

CNN mimarisi katmanların birbirlerine bağlı bir şekilde tekrarlanarak oluşturulur. Katmanlar birbirlerine etkileşim halindedir. Konvolüsyonel ve havuzlama katmanlarının tekrarlanmasıyla CNN modeli derinlik kazanır. Daha yüksek düzeyde özellik öğrenir. Daha karmaşık örüntüleri tanır. CNN modeli eğitim sürecinde aktivasyon fonksiyonunu kullanır. Aktivasyon fonksiyonu (ReLU), ağırlık non-lineerlik öğrenmesine yardımcı olur. CNN modeli veri setine uyum sağlar ve sınıflandırmaya yönelik tahmin yapar.

a. Konvolüsyonel Katman

Sinir ağının temelini oluşturan konvolüsyonel katman görüntü işleme ve tanıma gibi görsel verilerin analizi için kullanılır. Özniteliklerin çıkarıldığı katmandır. Konvolüsyonel katman girdi verisini alarak belirli bir filtre uygular. Uygulanan filtreler tüm görüntü üzerinde dolaşır. Filtrenin değerleri ile filtrenin veri üzerindeki alanlar çarpılarak sonuçları toplanır. Bir sonraki aşama filtre veri üzerinde bir veya daha fazla sayıda piksel kadar kaydırılır. Filtreler önceki katmandan gelen görüntüler alır ve çıkış verisini oluşturur [36]. Bu işlem sonucunda öznitelik haritası oluşur. Aşağıdaki şekilde konvolüsyonel katmanda girdi verisi üzerinde yapılan işlemler görülmektedir (Şekil 3.14).




Şekil 3.14. İki Boyutlu Konvolüsyonel İşlemi [37]

b. Aktivasyon Fonksiyonu

Konvolüsyonel katmandan sonra gelerek katman çıktılarını belirli bir şekile dönüştürür. Konvolüsyonel ağı son katmanında softmax, sigmoid, hiperbolik tanjant gibi aktivasyon fonksiyonları kullanılır. Aktivasyon fonksiyonları her bir nöronun çıktısını hesaplar. Aktivasyon katmanında genellikle Eşitlik 3.2’de a yer alan Düzleştirilmiş Doğrusal Birim (ReLU) fonksiyonu kullanılmaktadır [36].

$$f(x) = \{ 0 \text{ eğer } x < 0 \text{ } x \text{ eğer } x \geq 0 \} \quad (3.2)$$


ReLU tüm pozitif değerler için doğrusal olup tüm negatif değerleri sıfırlayan bir fonksiyondur. Bu katman sayesinde ağ daha hızlı öğrenilmiş olur (Şekil 3.15).



Şekil 3.15. Düzleştirilmiş Doğrusal Birim Grafiği [70]

c. Havuzlama Katmanı


Havuzlama katmanı derin öğrenme ve sinir ağlarındaki ikinci katmandır. Konvolüsyonel katmandan sonra elde edilen öznitelik haritalarının daha küçük boyutlara indirgenir ve önemli özellikler çıkarılır. Veri boyutu azaltılarak daha az parametre kullanılır. Öznitelik haritası üzerinde belirlenen filtre matrisi iki işlemde gerçekleşir. Ortalama havuzlama her özellik haritasındaki bölgelerin ortalamasını alır. Maksimum havuzlama özellik haritasındaki bölgelerden en büyük değeri alır. (Şekil 3.16) Tam bağlı katmandan önce veriler tek boyuta indirgenir. İki boyutlu matris düzleştirme işlemi ile tek boyutlu vektör haline gelir [38].



Şekil 3.16. Ortalama ve Maksimum Havuzlama İşlemleri [39]

d. Tam Bağlı Katman

Havuzlama katmanından sonra tek boyuta indirgenen veriler yapay sinir ağlarına giriş olarak verilir. Tam bağlı katman çok katmanlı algılayıcı olarak çalışarak öğrenme süreci başlanır. (Şekil 3.17) Tam bağlı katmanlardaki nöronlar diğer katmanların nöronlarına tamamen bağlıdır. Bu aşamadan sonra sınıflandırma işlemi gerçekleşir. Sınıflandırma işleminde farklı sınıflandırıcılar kullanılmaktadır. Softmax sınıflandırıcısı girdi vektörünün ilgili sınıfa ait olma olup olmama olasılığını hesaplayan bir fonksiyondur [36].




Şekil 3.17. Tam Bağlı Katman [40]

3.3.2. Hazır Konvolüsyonel Sinir Ağları Mimarileri

Göz hastalığı sınıflandırması kapsamında DenseNet, EfficientNet, VGG, ResNet, Xception, mimarileri kullanılmıştır. Belirtilen hazır CNN mimarileri aşağıda açıklanmıştır.

a. DenseNet


DenseNet (Densely Connected Convolutional Network) CNN tabanlı derin öğrenme modeline sahiptir. DenseNet bloklardan oluşan CNN mimarilerinden biridir. Katmanlar arasında yoğun bloklar içerir. Yoğun bağlantılar ağın her bir katmandan çıkıp sonraki katmanlara ileri beslemeli olarak bağlanır. Her katman için, önceki tüm katmanların özellik haritaları girdi olarak alınır ve kendi özellik haritaları, sonraki tüm katmanlar için girdi olarak hizmet eder [41]. Bu sayede bilgi akışı kolaylaşır ve katmanlar arası geçişlerde önemli bilgilerin kaybolması engellenmiş olur. Şekil 3.18’de DenseNet mimarisinin genel yapısı gösterilmektedir. Bu tez çalışmasında DenseNet121 kullanılmıştır.



Şekil 3.18. Genel DenseNet Mimarisi [42]

b. EfficientNet

EfficientNet, derin öğrenmede görüntü işleme alanında kullanılan bir CNN modelidir. Model, derinliği, genişliği ve çözünürlüğü boyutlarını eşit şekilde ölçeklendirir. 2019 yılında Google araştırmacıları tarafından tanıtılmış olup CNN mimarileri arasında verimli etkiler sunmayı amaçlar. EfficientNet mimarisi, bileşik bir katsayı kullanarak her boyutu eşit şekilde ölçeklendirir. Giriş verilerinin genişliğini, çözünürlüğünü rastgele ölçekleme yapmaz [43]. Sabit ölçeklendirme katsayısıyla eşit şekilde ölçeklendirir. Şekil 3.19’da EfficientNet mimarisinin genel yapısı gösterilmektedir.




Şekil 3.19. Genel EfficientNet Mimarisi [44]

c. VGG

VGG (Visual Geometry Group), görüntü işleme, sınıflandırma ve tespit gibi alanlarda sıklıkla kullanılan bir CNN modelidir. 2014 yılında Oxford Üniversitesi’ndeki Visual Geometry Group tarafından geliştirilmiş olup, ILSVRC yarışmasında ikinci olmuştur. VGG mimarisi, 6 farklı modelde 11, 13, 16, 19 konvolüsyon katmanından oluşmaktadır [45]. Bu mimari 224x224 boyutunda görseller kullanarak 3 Tam Bağlı (Fully Connected) katmana


sahiptir. Her konvolüsyonel katmanlar, bir sonraki görüntüden daha küçük ve derin öznetelik haritası oluşturur. VGG mimarisinde, CNN mimarilerinde daha yüksek sınıflandırma doğruluğu elde etmek için ağın derinliği önemli bir bileşendir [45]. VGG modeli, konvolüsyonel katman ve tam bağlantılı katmanlardan oluşur ve ImageNet veri kümesi üzerinde eğitilir. Mimarinin yapısı Şekil 3.20.'de gösterilmiştir. Bu tez çalışmasında VGG16 kullanılmıştır.



Şekil 3.20. Genel VGG Mimarisi [46]

d. ResNet


Residual Network (ResNet), 2015 yılında Microsoft Research tarafından geliştirilmiştir ve ILSVRC yarışmasında birinci olmuştur. CNN mimarilerinden biri olup görüntü işleme, nesne tespiti ve sınıflandırma gibi alanlarda sıklıkla kullanılarak etkili sonuçlar verir. ResNet mimarisinin ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-152 gibi çeşitleri vardır [47]. ResNet mimarisi için ReLU aktivasyon fonksiyonunu içeren bir yapı kullanır. Bu mimari, bloklar içererek çeşitli konvolüsyonel katmanlarının bir araya gelmesiyle oluşur ve 49 konvolüsyonel katmanı ve 1 tam bağlantılı katmana sahiptir. ResNet modeli katmanlar arttıkça daha derin yapılarda daha başarılı sonuçlar verir. ResNet mimarisi 224x224x3 boyutundaki görüntüler kullanır. Mimarinin yapısı Şekil 3.21.'de gösterilmiştir. Bu tez çalışmasında ResNet-50 kullanılmıştır.



Şekil 3.21. Genel ResNet Mimarisi [48]

e. Xception

Xception mimarisi, "aşırı başlangıç" anlamına gelerek filtreleri derinlik haritasının her birine uygulayan modeldir. Google araştırmacıları tarafından geliştirilmiştir. Model derinlemesine ayrılabilen konvolüsyonelleri içeren derin bir sinir ağı mimarisine sahiptir [49]. Xception mimarisi, Inception mimarisini esas alarak ağı daha derin ve etkili şekilde öğrenmesini sağlar. Ağırlıklı olarak 1x1 konvolüsyonellerin kullanıldığı bir yapıya odaklanır [50]. Xception mimarisinde veriler, önce giriş akışından ardından sekiz kez tekrarlanan orta akıştan ve sonra çıkış akışından geçer [49]. Genellikle görüntü işleme gibi alanlarda kullanılarak sınırlı veri setlere sahip olan çalışmalarda iyi bir performans gösterir. Mimarinin yapısı Şekil 3.22.'de gösterilmiştir.



Şekil 3.22. Genel Xception Mimarisi [51]

3.4. Makine Öğrenme


Makine öğrenmesi matematiksel modelleri kullanarak bilgisayarların talimat almadan öğrenmelerine yardımcı olan bir süreçtir. Bu süreç, yapay zeka alanının bir alt aşaması olarak da ele alınır. Makine öğrenmesinde algoritmalar verilerdeki desenleri belirlemek için kullanır ve bu desenleri sayesinde tahmin yapabilen veri modelleri oluşturur. Makine öğrenmesi, artan veriler sayesinde önceki veriler arasından yeni veriler için en iyi modeli bulma prensibine dayanmaktadır [52]. Daha fazla çeşitli verilerle eğitildiğinde genellikle daha iyi sonuçlar verir ve daha kapsamlı bir şekilde öğrenilmiş olur. Makine öğrenmesi uygulama alanı oldukça geniştir ve birçok sektörde istatistik, veri madenciliği, doğal dil işleme, bilgisayar bilimleri ve tıp gibi alanlarda kullanılır. Tıp alanında, tıbbi görüntülerin analizi, hastalık teşhisi gibi alanlarda makine öğrenmesi algoritmaları kullanılır. Veri seti ve kullanılan algoritma, oluşturulan modelin en üst düzeyde performans göstermesi için özenle seçilir ve ayarlanır [53]. Performans ölçümleri, Makine öğrenmesinde kullanılan eğitim verilerinden ayrı bir test verisi kullanılarak değerlendirilmektedir.

3.4.1. Makine Öğrenme Algoritmaları

Göz hastalığı çalışması kapsamında SVM, NB, KNN, RF algoritmaları kullanılmıştır. Belirtilen makine öğrenme algoritmaları aşağıda açıklanmıştır.

a. Destek Vektör Makinesi (SVM)


SVM öğrenme algoritmaları arasında sınıflandırma ve regresyon problemlerinde kullanılan bir yöntemdir. Sınıflandırma problemlerinde öncelikle iki sınıf için kullanılır. Çoklu sınıflandırma problemleri için de kullanılabilir. SVM, her sınıf için bir karar sınırı belirler ve bu sınırlar arasındaki bölgedeki verileri sınıflandırır. SVM, verileri sınıflandırmak için hiperdüzlem kullanır [54]. Hiperdüzlem, özellik uzayında verileri ayıran bir düzlemdir. SVM, verileri sınıflandırmak için en uygun hiperdüzlemi bulmaya çalışır. Algoritmanın genel yapısı Şekil 3.23.'te gösterilmiştir.



Şekil 3.23. Destek Vektör Makinesi [55]

b. Naive Bayes Sınıflandırıcısı


Naive Bayes, makine öğrenimi ve veri madenciliği için en verimli ve etkili tümevarımsal öğrenme algoritmalarından biridir [56]. Naive Bayes, verileri analiz ederek belirli bir sınıfa ait olma olasılığını tahmin etmek için kullanılır. Naive Bayes sınıflandırıcısı, bayes karar yapısına dayalı bir sınıflandırma yöntemidir ve sınıflandırma hatalarını minimize etmeyi hedefler. Sınıflandırma işlemi sırasında, önceden belirlenmiş sınıflandırma kurallarına göre bu ağırlıkların toplamı hesaplanır. Hesaplanan toplam ağırlığa sahip sınıf örnek veri noktasının sınıfı olarak atanır. Naive Bayes algoritması, önceden etiketlenmiş bir eğitim veri setini kullanarak modelin eğitilmesini gerektirir. Eğitim sürecinde, algoritma, her sınıf için özelliklerin olasılık dağılımlarını hesaplar. Bu dağılımlar daha sonra, yeni bir örneğin sınıfını tahmin etmek için kullanılır [57]. Algoritmanın genel yapısı Şekil 3.24’te gösterilmiştir.



Şekil 3.24. Naive Bayes Sınıflandırıcısı [58]

c. En Yakın Komşu Algoritması (KNN)


KNN, makine öğrenmesinde sınıflandırma algoritmalarından biridir. Sınıflandırma problemlerini çözmek için kullanılır. KNN öğrenme algoritmaları arasında sınıflandırma ve regresyon problemlerinde kullanılan bir yöntemdir [59]. KNN algoritması veri noktalarını, yakın komşularına göre sınıflandırmak için kullanılır. Yeni karşılaşılan bir örnek, eğitim setinde yer alan örnekler arasında benzerliğe göre sınıflandırılır [66]. Test örneğine en yakın k tane örneklem genellikle Öklid, Manhattan, Chebychev veya Minkowski uzaklık ölçütleri kullanılarak bulunur. KNN algoritması sınıflandırma yaparken, yeni bir veri noktasını, komşularının sınıflarının çoğunluğuna göre sınıflandırır. Algoritmanın genel yapısı Şekil 3.25.'te gösterilmiştir.



Şekil 3.25. KNN En Yakın Komşu Algoritması [60]

d. Rastgele Orman (RF)

RF, sınıflandırma problemleri için kullanılan ve birden fazla karar ağacının bir araya getirilmesi ile oluşan öğrenme algoritmasıdır. RF, her ağacın rastgele değişkenler koleksiyonuna bağlı olduğu ağaç tabanlı bir topluluktur. Algoritma rastgele örneklem alma ve rastgele özellik seçimi yaparak birden fazla karar ağacı oluşturur ve bu ağaçların farklı özellik kümesi ve alt örneklem kümeleri üzerinde eğitilir [61]. Bir düğümü bölme işlemi sırasında, doğrudan en iyi özellik aramak yerine, rastgele bir özellik alt kümesinde en iyi özelliği aramak, daha farklı ağaçların oluşmasına olanak tanır [62]. Algoritmanın genel yapısı Şekil 3.26'da gösterilmiştir.



Şekil 3.26. Rastgele Orman Algoritması [63]

4. DENEYSEL SONUÇLAR

4.1. Deneysel Kurulum

Sınıflandırma adımı, hastalık tespiti için retinal fundus kullanılmıştır ve bu görüntülerin boyutu 224x224 piksel olarak ayarlanmıştır. Bu tez çalışmasında CNN mimarileri kullanarak görüntü özelliklerini öğrenme sırasında çeşitli katmanlarla işlemiştir.


Model eğitimi sırasında aşırı öğrenmeyi önlemek ve öğrenme oranının düşmemesi için keras kütüphanesinden ReduceLROnPlateau kullanılmıştır. ReduceLROnPlateau sayesinde model uzun süre gelişmeye devam ederken öğrenme oranının azalmaması için kullanılan bir tekniktir. Eğitimde 100 devir (epoch) sayısı kullanılmıştır. Eğitim sürecinde Adam Optimizer kullanılmıştır. Öğrenme oranı 0.001 olarak ayarlanıp her epoch'tan önce eğitim verileri karıştırılmıştır. Toplu normalleştirme (BatchNormalization) kullanılarak eğitim daha hızlı, daha yüksek öğrenme oranına sahip ve kararlı hale getirilmiştir. Relu ve softmax fonksiyonları tüm mimarilerde kullanılmaktadır.

Sınıflandırma işlemi ikili ve çoklu veri seti üzerinde yapılmıştır. Çalışmada 10 kat çapraz doğrulama ile sonuçlar elde edilmiştir.

Çapraz doğrulama, bir modelin performansını değerlendirmek için kullanılan bir tekniktir. K kat çapraz doğrulama, veri setinin k parçaya bölünmesi ve her bir parçanın sırayla test seti olarak kullanılmasıdır. Diğer k-1 parça, eğitim seti olarak kullanılır. Bu işlem k parçası kadar

tekrar edilir. Süreç tamamlandığında, her bir test için modelin performans değerlendirme ölçütlerinin ortalaması alınır ve genel bir performans skoru elde edilir.

Çalışmada deneyler 10 kat çapraz doğrulama ile gerçekleştirilmiştir (Şekil 4.1). Veri seti 10 eşit parçaya bölünüp ve her bir işlemde 10 farklı sonuç elde edilmiştir. 9 parça eğitim amacıyla kullanılırken, geriye kalan 1 parça test için ayarlanmıştır. Bu işlem, tüm parçaların sırayla test kümesi olarak hizmet vermesi için toplamda 10 defa tekrarlanmıştır.



Şekil 4.1. K-Kat Çapraz Geçerleme

Makine öğrenme algoritmalarından Destek Vektör Makinesi (SVM), Naive Bayes Sınıflandırıcısı (NB), K-En Yakın Komşu (KNN) ve Rastgele Orman (RF) sınıflandırıcıları kullanılmıştır. SVM algoritmasında verileri iki sınıfa ayırmak için lineer, RBF ve sigmoid çekirdek fonksiyonları kullanılmıştır. NB algoritmasında normal dağılım değeri kullanılarak başarı performansı metriği hesaplanmıştır. RF algoritmasında ağaç sayısı 200 ve 300 değerleri verilip sonuçlar alınmıştır. KNN algoritmasında ise k 3 ve 5 değerleri için sonuçlar elde edilmiştir.

CNN’de kullanılan otomatik öznitelik çıkarımı dışında HOG ve kodlayıcı (Encoder) yöntemleri kullanılarak manuel öznitelik çıkarımı yapılmıştır. Manuel öznitelik çıkarımları makine öğrenme algoritmalarını beslemek için kullanılmıştır. Kodlayıcı ve HOG öznitelikleri çıkartılıp SVM, NB, KNN ve RF algoritmalarında kullanılarak sonuçlar elde edilmiştir.

Her bir algoritmadan elde edilen sonuçlar ile algoritmaların performansları karşılaştırılmıştır.

Otokodlayıcı derin öğrenme mimarisi hiper parametreleri kullanılmıştır. Otokodlayıcı mimarisinde katman değerleri AE (64-128-256-512) olarak kullanılmıştır. Katman sayısına göre performans sonuçları elde edilmiştir.

4.2. Başarı Ölçütleri

Kullanılan modellerin başarı değerlendirmesinde ölçüt olarak doğruluk, duyarlılık, kesinlik, F1-Puanı ve Matthews Korelasyon Katsayısı (MCC) kullanılmıştır. Sınıflandırma elde edilen sonuçlar Gerçek Pozitif (TP), Gerçek Negatif (TN), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) metriklerinden oluşur. Tablo 4.1.'de sınıflandırma bölümünde kullanılan karmaşıklık matrisi (confusion matrix) gösterilmiştir. Karmaşıklık matrisi, bir sınıflandırma problemi için gerçek ve tahmin edilen sınıflardan oluşan bir matristir. Karmaşıklık matrisi, sınıflandırma modelinin performansını daha ayrıntılı değerlendirir. TP, pozitif örneklerin doğru olarak sınıflandırılması, TN, negatif örneklerin doğru olarak sınıflandırılması, FP, negatif örneklerin yanlış olarak sınıflandırılması ve FN, pozitif örneklerin yanlış olarak sınıflandırılması durumlarıdır.

Tablo 4.1. Sınıflandırma Karmaşıklık Matrisi

		Doğru Sınıf	
		Pozitif	Negatif
Tahmin Edilen Sınıf	Pozitif	Doğru Pozitif (TP)	Yanlış Negatif (FN)
	Negatif	Yanlış Pozitif (FP)	Doğru Negatif (TN)

Doğruluk, sınıflandırma modelin doğru olarak tahmin edilen örnek sayısının veri kümesinde yer alan tüm örnek sayısına bölünmesi ile hesaplanır. Doğruluk metriği sınıflandırma başarısı için önemli bir ölçüm metriği olup, modelin ne kadar başarılı belirlemek için kullanılır. Doğruluk eşitliği 4.1'de gösterilmiştir.

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

Duyarlılık (TPR), sınıflandırma modelinin gerçek pozitif oranını (TPR) ifade eden bir metriktir. Modeldeki test verilerinden hastalıklı bireyleri doğru tahmin edebilmesini ölçen bir performans metriğidir. Sınıflandırmada doğru hastalığa sahip kişilerin (gerçek pozitif sayısı), sınıfı yanlışlıkla negatif olarak sınıflandırılan örneklerin sayısı ile gerçek pozitif sayısının toplamının oranıdır. Duyarlılık eşitliği 4.2’de gösterilmiştir.

$$\text{Duyarlılık (TPR)} = \frac{TP}{TP + FN} \quad (4.2)$$

Kesinlik (PPV), sınıflandırma modelinde pozitif olarak tahmin edilen örneklerin doğrunu ölçen bir performans metriğidir. Sınıflandırmada yanlış olarak pozitif olarak değerlendirilen verileri tahmin eder. Sınıflandırmada doğru hastalığa sahip kişilerin (gerçek pozitif sayısı), sınıfı yanlışlıkla pozitif olarak sınıflandırılan örneklerin sayısı ile gerçek pozitif sayısının toplamının oranıdır. Kesinlik eşitliği 4.3’te gösterilmiştir.

$$\text{Kesinlik (PPV)} = \frac{TP}{TP + FP} \quad (4.3)$$

F1-Puanı, kesinlik ve duyarlılık metriklerinden oluşan bir performans metriğidir. F1-Puanı, sınıflandırma modelin hem yanlış pozitiflerini hem de yanlış negatifleri en aza indirme ye odaklanır. Kesinlik ile duyarlılığın çarpımının, kesinlik ile duyarlılığın toplamının oranından çıkan sonucun 2 katına eşittir. F1-Puanı eşitliği 4.4’te gösterilmiştir.

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

MCC, genel bir performans ölçüm metriğidir. Sınıflandırmanın performanslarını ölçmek için kullanılır. MCC eşitliği 4.5’te gösterilmiştir.

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (4.5)$$

4.3. Analiz Sonuçları

4.3.1.CNN Modelinden Elde Edilen Sonuçlar

Tez çalışmasında CNN mimarilerinden EfficientNet, DenseNet, Xception, VGG ve ResNet mimarileri kullanılmıştır. Bu bölümde ilgili mimariler ile elde edilen sonuçlar verilmiştir.

a. İkili (Binary) Problem

CNN mimarileri kullanılarak hasta ve normal sınıflar olmak üzere ikili sınıflandırma probleminde ile elde edilen 10-kat çapraz geçерleme deneylerinin sonuçları Tablo 4.2’de verilmiştir. Sınıflandırma değерlendirme ölçütü olarak karmaşıklık matrislerinden elde edilen doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC kullanılmıştır.


Tablo 4.2. İkili sınıflandırma 10-kat çapraz geçерleme ile elde edilen sonuçlar

	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
EfficientNet	92.77	93.68	94.01	93.65	87.96
DenseNet	86.90	86.88	87.80	86.81	74.67
Xception	72.29	72.26	72.77	72.14	45.03
VGG	82.21	82.22	82.47	82.18	64.71
ResNet	73.92	73.91	74.09	73.87	48.00


Tablo 4.2’ye göre doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC açısından en iyi performans CNN mimarilerinden EfficientNet mimarisi ile elde edilmiştir. EfficientNet mimarisinin doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC değерlerinin sonuçları sırasıyla %92.77, %93.68, % 94.01, %93.65, %87.96 ile elde edilmiştir. DenseNet ile VGG mimarileri ve Xception ile ResNet mimarileri birbirlerine yakın sonuçlar vermiştir. Diğер performans metriklerine bakıldığında Xception mimarisi diğер mimariler arasında en düşük performans

değerlerini vermiştir. Xception mimarisinin doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC değerlerinin sonuçları sırasıyla %73.92, %73.91, % 74.09, %73.87, %48.00 ile elde edilmiştir. İkili sınıflandırma probleminde kullanılan veri kümesinde CNN mimarilerinden EfficientNet, DenseNet, Xception, VGG, ResNet ile edilen karmaşıklık matrisi sırasıyla Şekil 4.2, Şekil 4.3, Şekil 4.4, Şekil 4.5 ve Şekil 4.6’da verilmiştir.


EfficientNet mimarisinin en yüksek sonuçlar vermesi derinlik ve genişlik ölçeklendirmesinin optimize edilerek kullanılmasıdır. Bu sayede model daha iyi öğrenme yeteneğine sahip olur. Hesaplama verimliliği artar ve doğruluk oranları iyi sonuçlar verir. Xception mimarisi, diğer CNN mimarileri ile kıyaslandığında daha sınırlı bir model öğrenme yeteneğine sahiptir. Bu sebeple model öğrenme yeteneğini azaltarak performans değerlerinde düşük sonuçlar verebilir. DenseNet ve VGG mimarileri daha karmaşık görsel özellikleri öğrenme yeteneğine sahiptir. DenseNet ve VGG mimarilerinin sonuçlarına bakıldığında kabul edilebilir bir sonuç olarak yorumlanabilir.




Şekil 4.2. EfficientNet Karmaşıklık Matrisi




Şekil 4.3. DenseNet Karmaşıklık Matrisi



Şekil 4.4. Xception Karmaşıklık Matrisi



Şekil 4.5. VGG Karmaşıklık Matrisi



Şekil 4.6. ResNet Karmaşıklık Matrisi

b. Çoklu Sınıflandırma Problemi


CNN modelinden DenseNet, VGG, ResNet, Xception ve EfficientNet mimarileri kullanılmış ve katarakt, diyabetik-retinopati, glokom ve normal veriler birleştirilip veri kümesi oluşturulmuştur. Çoklu sınıflandırma problemi ile elde edilen 10-kat çapraz geçişleme deneylerinin sonuçları Tablo 4.3.'te verilmiştir.

Tablo 4.3. Çoklu sınıflandırma 10-kat çapraz geçirme ile elde edilen sonuçlar


	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
EfficientNet	88.59	91.49	87.65	89.42	84.87
DenseNet	83.17	82.34	85.16	83.56	77.65
Xception	66.02	63.49	68.24	64.58	54.92
VGG	83.37	87.29	82.15	84.62	77.91
ResNet	62.98	69.16	58.23	62.63	51.13

Tablo 4.3'e göre çoklu veri kümesi kullanılarak 10-kat çapraz geçirme ile oluşturulan performans metrikleri gösterilmiştir. Doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC açısından en iyi performans CNN mimarilerinden EfficientNet mimarisi ile elde edilmiştir. EfficientNet mimarisinin doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC değerlerinin sonuçları sırasıyla %88.59, %91.49, % 87.65, %89.42 %84.87 ile elde edilmiştir. DenseNet ve VGG mimarileri birbirlerine yakın sonuçlar vermiştir. Diğer performans metriklerine bakıldığında ResNet mimarisi diğer mimariler arasında en düşük performans değerlerini vermiştir. ResNet mimarisinin doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC değerlerinin sonuçları sırasıyla %62.98, %69.15, % 58.23, %62.63, %51.13 ile elde edilmiştir.


Çoklu sınıflandırma probleminde kullanılan veri kümesinde CNN mimarilerinden EfficientNet, DenseNet, Xception, VGG, ResNet ile edilen karmaşıklık matrisi sırasıyla Şekil 4.7, Şekil 4.8, Şekil 4.9, Şekil 4.10 ve Şekil 4.11'de verilmiştir. Karmaşıklık matrisinden elde edilen sonuçlar incelendiğinde ResNet mimarisinin performans sonuçlarının diğer mimarilere göre iyi olmamasının nedeni, model eğitim verisine uyum sağlayamamış ve daha iyi öğrenememiş olabilir.




Şekil 4.7. EfficientNet Karmaşıklık Matrisi




Şekil 4.8. DenseNet Karmaşıklık Matrisi



Şekil 4.9. Xception Karmaşıklık Matrisi



Şekil 4.10. VGG Karmaşıklık Matrisi



Şekil 4.11. ResNet Karmaşıklık Matrisi

CNN mimarilerinden DenseNet, VGG, ResNet, Xception ve EfficientNet mimarileri kullanılmıştır. Kullanılan CNN mimarilerin tercih edilme sebebi, sınıflandırma problemlerinde kullanılıp daha iyi öğrenme ve genelleme yeteneğine sahip olmalarıdır. Kullanılan her mimari, belirli avantajlara ve dezavantajlara sahip olabilir. DenseNet mimarisinin doğruluk oranı, ikili sınıflandırmada %86.90 ve çoklu sınıflandırmada %83.17 olarak elde edilmiştir. DenseNet mimarisi bağlantılı katmanlar içererek her katman bir önceki katman ile beslenir. Bu sayede özellikler daha etkili bir şekilde kullanılır ve daha düşük maliyetle daha iyi performans sonuçları elde edilebilir. DenseNet mimarisi kullanımın çok fazla pozitif yanı olsa da negatif yanı, yoğun katmanlar sayesinde model için daha fazla bellek tüketimi ve hesaplama gücü gerekebilir. EfficientNet mimarisinin doğruluk oranı, ikili sınıflandırmada %92.77 ve çoklu sınıflandırmada %88.59 olarak elde edilmiştir. EfficientNet mimarisi, ölçeklendirme yöntemini kullanır. Bu sayede genişlik, derinlik ve çözünürlüğü optimize ederek daha iyi performans sonuçları elde edilebilir. EfficientNet mimarisi kullanımın çok fazla pozitif yanı olsa da negatif yanı, diğer modellere kıyasla belirli veri setleri veya uygulamalar için gereğinden fazla karmaşık olabilir. Bu sebeple modelin eğitimi daha fazla kaynak gerektirebilir. ResNet mimarisinin doğruluk oranı, ikili sınıflandırmada %73.92 ve çoklu sınıflandırmada %62.98 olarak elde edilmiştir. ResNet mimarisi, veri seti ve problem gereksinimlerine göre diğer modellere bakılarak sınıflandırmada daha iyi genelleme yeteneğine sahip olabilir. ResNet mimarisi kullanımın çok fazla pozitif yanı olsa da negatif yanı, yetersiz veri durumunda ağır genelleme yeteneği zayıflayarak daha düşük performans sonuçları elde edilebilir. VGG mimarisinin doğruluk oranı, ikili sınıflandırmada %82.21 ve çoklu sınıflandırmada %83.37

olarak elde edilmiştir. VGG mimarisi, özellik çıkarımı sırasında farklı filtre boyutlarını kullandığından görseldeki özellikleri daha ayrıntılı öğrenebilir. Bu sayede performans sonuçlarında daha iyi sonuçlar elde edilebilir. VGG mimarisi kullanımın çok fazla pozitif yanı olsa da negatif yanı, fazla miktarda eğitim verisi olmadığında modelin genelleme yeteneği azabilir. Genellikle fazla miktara sahip veri kümelerinde başarı oranları daha fazla olduğu görülmüştür. Xception mimarisinin doğruluk oranı, ikili sınıflandırmada %72.29 ve çoklu sınıflandırmada %66.02 olarak elde edilmiştir. Xception mimarisi, diğer mimarilere kıyasla daha az parametreye sahiptir. Bu sayede model daha hızlı öğrenebilir ve daha hızlı tahmin edebilir. Xception mimarisi kullanımın pozitif yanları olsa da negatif yanı, bazı sınıflandırma problemlerinde diğer mimarilere kıyasla daha düşük performans sonuçları verebilir.

İkili ve çoklu sınıflandırma problemlerinde elde edilen sonuçlara bakıldığında, iki sınıflandırma problemlerinde çıkan sonuçların daha başarılı olduğu gözlemlenmiştir. EfficientNet mimarisinin doğruluk oranı, ikili sınıflandırmada %92.77 ve çoklu sınıflandırmada %88.59 olarak elde edilmiştir. İkili sınıflandırmada, sınıf sayısı az olduğundan dolayı modelin karar vermesi ve sınıf ayrımı yapması daha kolaydır. Çoklu sınıflandırmada sınıf sayısı arttıkça modelin öğrenmesi daha karmaşık hale gelebilir. Sınıf sayısı fazla olduğundan model zor karar verebilir ve modelin genelleme yeteneği düşebilir. Birden fazla göz hastalığı içeren çoklu sınıflandırma problemlerinde, her sınıfın diğerine göre ayrılması kolay olmayabilir ve yanlış sınıflandırılma riski artabilir.


4.3.2. Makine Öğrenmesinden Elde Edilen Sonuçlar

Makine öğrenmesi için HOG ve kodlayıcı (Encoder) öznitelikleri kullanılarak yapılan algoritma deneylerinin sonuçları verilmiştir. HOG ve kodlayıcı ile elde edilen sonuçlar karşılaştırılmıştır. Makine öğrenmesi algoritmalarından SVM, RF, NB ve KNN algoritmaları kullanılmıştır.


Tablo 4.4. HOG özniteliklerinin KNN ile ikili sınıflandırılması

k-en yakın komşu	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
k=3	77.82	77.81	80.85	77.27	58.61
k=5	78.12	78.18	82.11	77.51	60.19

HOG özniteliklerinin Öklid uzaklığını kullanan KNN ile ikili sınıflandırmada elde edilen deney sonuçları Tablo 4.4'te verilmiştir. Tablo 4.4'e göre en yakın komşu sayısı olan k parametresi 5 seçildiğinde doğruluk, duyarlılık, kesinlik, F1-Puanı, MCC değerleri sırasıyla %78.12, %77.81, %80.85, %77.27 ve %58.61 verilmiştir. 3 ve 5 parametrelerinin doğruluk, duyarlılık, kesinlik ve F1-Puanı sonuçları birbirine yakınlık göstermiştir. Şekil 4.12 ve Şekil 4.13'te KNN ikili sınıflandırma için karmaşıklık matrisleri verilmiştir.



Şekil 4.12. KNN (3) Karmaşıklık Matrisi



Şekil 4.13. KNN (5) Karmaşıklık Matrisi


HOG, görüntülerin şekil ve kenar özelliklerini yakalamak için tasarlandığından göz görüntülerinde renk ve yüksek seviyeli özelliklere duyarlı olarak öznitelik çıkarımı yapmış olabilir. Bu durumda KNN algoritması kabul edilebilir performans sonuçları vermiştir.

Tablo 4.5. HOG özniteliklerinin KNN ile çoklu sınıflandırılması

k-en yakın komşu	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
k=3-5	71.57	71.56	70.82	70.93	62.19

HOG özniteliklerinin Öklid uzaklığını kullanan KNN ile çoklu sınıflandırmada elde edilen deney sonuçları Tablo 4.5'te verilmiştir. Tablo 4.5'e göre en yakın komşu sayısı olan k parametresi 3 ve 5 seçildiğinde doğruluk, duyarlılık, kesinlik, F1-Puanı, MCC değerleri

sırasıyla %71.57, %71.56, %70.82, %70.93 ve %62.19 verilmiştir. Şekil 4.14'te KNN çoklu sınıflandırma için karmaşıklık matrisi verilmiştir.



Şekil 4.14. KNN Karmaşıklık Matrisi


HOG özniteliklerini kullanılarak KNN ile ikili ve çoklu sınıflandırma problemlerinde elde edilen sonuçlara bakıldığında, iki sınıflandırma problemlerinde çıkan sonuçların daha başarılı olduğu gözlemlenmiştir. HOG, çoklu sınıflandırmada sınıflar arası ayrımları iyi yapamamış olabilir. Çoklu sınıflandırma problemleri genellikle daha karmaşık bir yapıda olduğundan HOG öznitelik çıkarımında zorlanmış olabilir. Bu durum KNN algoritmasının performans sonucunu düşürmüş olabilir.

Tablo 4.6. HOG özniteliklerinin SVM ile ikili sınıflandırılması


SVM	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
Lineer	92.37	92.36	92.38	92.36	84.74
RBF	92.36	92.36	92.37	92.36	84.72
Sigmoid	83.63	83.63	83.65	83.63	67.29

HOG özniteliklerinin SVM sınıflandırıcısını beslemesiyle ikili sınıflandırma problemi ile elde edilen deney sonuçları Tablo 4.6'da verilmiştir. Tablo 4.6'ya göre lineer çekirdeği doğruluk,


duyarlılık, kesinlik, F1-Puanı ve MCC değerleri sırasıyla %92.37, %92.36, %92.38, %92.36 ve %84.47 ile en yüksek değerleri vermiştir. Tüm çekirdeklerin sonuçlarına genel olarak bakıldığında lineer ve RBF çekirdekleri birbirlerine çok yakın sonuçlar verildiği gözlemlenmiştir. SVM algoritması kullanılarak ikili sınıflandırma ile edilen karmaşıklık matrisleri Şekil 4.15, Şekil 4.16 ve Şekil 4.17’de verilmiştir.



Şekil 4.15. RBF Karmaşıklık Matrisi



Şekil 4.16. Linear Karmaşıklık Matrisi




Şekil 4.17. Sigmoid Karmaşıklık Matrisi

HOG öznitelik çıkarımıyla SVM algoritmasının karmaşıklık matrislerine baktığımızda, oranlar genellikle birbirlerine çok yakın veya benzer görünmektedir. Veri seti doğrusal olarak ayrılamayıp ve tüm çekirdek tipleri için benzer sonuçlar elde edilirse, bu durum algoritmanın performansını olumsuz etkileyebilir ve sonuç olarak düşük performans değerleri elde edilebilir.


Tablo 4.7. HOG özniteliklerinin SVM ile çoklu sınıflandırılması

SVM	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
Linear	78.43	78.43	78.63	78.36	71.35
RBF	81.51	81.51	81.34	81.40	75.35
Sigmoid	76.06	76.06	75.91	75.61	68.28


HOG özniteliklerinin SVM sınıflandırıcısını beslemesiyle çoklu sınıflandırma problemi ile elde edilen deney sonuçları Tablo 4.7’de verilmiştir. Tablo 4.7.’ye RBF çekirdek fonksiyonu kullanıldığında sınıflandırıcının doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC ile en yüksek sonuçlar sırasıyla %81.51, %81.51, %81.34, %81.40 ve %75.35 ile elde edilmiştir. Genel doğruluğa bakıldığında linear ve sigmoid çekirdekleri ile elde edilen sonuçlar birbirlerine yakındır. SVM algoritması kullanılarak çoklu sınıflandırma ile edilen karmaşıklık matrisleri Şekil 4.18, Şekil 4.19 ve Şekil 4.20’de verilmiştir.



Şekil 4.18. Linear Karmaşıklık Matrisi



Şekil 4.19. Sigmoid Karmaşıklık Matrisi




Şekil 4.20. RBF Karmaşıklık Matrisi

Tablo 4.8. HOG özniteliklerinin NB ile ikili sınıflandırılması

NB kernel	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
KDE	61.45	61.45	70.82	56.62	31.01

HOG öznitelikleri ile NB'yi beslemek için kullanıldığında ikili sınıflandırmada elde edilen sonuçlar Tablo 4.8.'de verilmiştir. Tablo 4.8'e göre ikili sınıflandırmada NB algoritmasının doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC değerleri sırasıyla %61.45, %61.45, %70.82, %56.62 ve %31.01 değerlerini vermiştir. Karmaşıklık matrisi, NB algoritması kullanılarak Şekil 4.21'de verilmiştir.




Şekil 4.21. NB Karmaşıklık Matrisi

Tablo 4.9. HOG özniteliklerinin NB ile çoklu sınıflandırılması

NB kernel	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
KDE	49.05	49.05	51.80	45.46	35.36

HOG öznitelikleri ile NB'yi beslemek için kullanıldığında çoklu sınıflandırmada elde edilen sonuçlar Tablo 4.9'da verilmiştir. Tablo 4.9'a göre çoklu sınıflandırmada NB algoritmasının doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC değerleri sırasıyla %49.05, %49.05, %51.80 %45.46 ve %35.36 değerlerini vermiştir. Karmaşıklık matrisi, NB algoritması kullanılarak Şekil 4.22'de verilmiştir.




Şekil 4.22. NB Karmaşıklık Matrisi

HOG özniteliklerini kullanılarak NB ile ikili ve çoklu sınıflandırma problemlerinde elde edilen sonuçlara bakıldığında, iki sınıflandırma problemlerinde çıkan sonuçların daha başarılı olduğu gözlemlenmiştir. Sonuçlar incelendiğinde çoklu sınıflandırma sonuçları algoritmanın güvenilirliği açısından başarısız olarak yorumlanabilir. Böyle bir sonucun ortaya çıkmasının nedeni NB algoritması HOG öznitelik vektörlerini bir arada gözlemlendiğinde birbirinden bağımsız olarak varsayar. Bu durum algoritmanın performansını etkileyebilir.


Tablo 4.10. HOG özniteliklerinin RF ile ikili sınıflandırılması

Ağaç Sayısı	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
200	91.63	91.63	92.12	91.60	83.76
300	91.97	91.36	92.74	91.97	84.56

HOG öznitelikleri ile RF'yi beslemek için kullanıldığında elde edilen sonuçlar Tablo 4.10.'da verilmiştir. Buna göre ağaç sayısı 300 olarak seçildiğinde RF sınıflandırıcısı doğruluk %91.97, duyarlılık %91.36, kesinlik %92.74, F1-Puanı %91.97 ve MCC %84.56 değerleri vermiştir. Karmaşıklık matrisleri, RF algoritması kullanılarak Şekil 4.23 ve Şekil 4.24'te verilmiştir.



Şekil 4.23. RF (200) Karmaşıklık Matrisi




Şekil 4.24. RF (300) Karmaşıklık Matrisi


Tablo 4.11. HOG özniteliklerinin RF ile çoklu sınıflandırılması

Ağaç Sayısı	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
200	82.46	82.46	82.20	82.24	76.66
300	83.41	83.41	83.20	83.22	77.91

HOG öznitelikleri ile RF'yi beslemek için kullanıldığında çoklu sınıflandırmada elde edilen sonuçlar Tablo 4.11.'de verilmiştir. Buna göre ağaç sayısı 300 olarak seçildiğinde RF sınıflandırıcısı doğruluk %83.41, duyarlılık %83.41, kesinlik %83.20, F1-Puanı %83.22 ve MCC %77.91 değerleri vermiştir. Karmaşıklık matrisleri, RF algoritması kullanılarak Şekil 4.25 ve Şekil 4.26'da verilmiştir.



Şekil 4.25. RF (200) Karmaşıklık Matrisi




Şekil 4.26. RF (300) Karmaşıklık Matrisi

HOG özniteliklerini kullanılarak RF ile ikili ve çoklu sınıflandırma problemlerinde elde edilen sonuçlara bakıldığında, iki sınıflandırma problemlerinde çıkan sonuçların daha başarılı olduğu gözlemlenmiştir. Sonuçlar incelendiğinde RF algoritması için sonuçlar sınıflandırıcı güvenilirliği açısından başarılı olarak yorumlanabilir. HOG öznitelik çıkarımı sırasında verinin düzgün bir şekilde ön işlenmesi, RF algoritmasının performansını olumlu etkilemiş olabilir.


Tablo 4.12. Encoder özniteliklerinin KNN ile ikili sınıflandırılması

k-en yakın komşu	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
k=3	53.45	53.45	53.48	53.39	6.95
k=5	57.00	56.72	56.73	56.72	13.46

Kodlayıcı özniteliklerinin Öklid uzaklığını kullanan KNN sınıflandırıcısını beslemesiyle elde edilen deney sonuçları Tablo 4.12’de verilmiştir. İkili sınıflandırma probleminde, Tablo 4.12’ye göre en yakın komşu sayısı olan k parametresi 5 seçildiğinde doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC değerleri sırasıyla %57.00, %56.72, %56.73, %56.72 ve %13.46 elde edilmiştir. KNN algoritması kullanılarak ikili sınıflandırma ile edilen karmaşıklık matrisleri Şekil 4.27 ve Şekil 4.28’de verilmiştir.



Şekil 4.27. KNN (3) Karmaşıklık Matrisi



Şekil 4.28. KNN (5) Karmaşıklık Matrisi


Kodlayıcı öznitelikleri kullanılarak, KNN algoritmasının sınıflandırma probleminde elde edilen sonuçlara bakıldığında düşük sonuçlar verdiği gözlenmiştir. KNN algoritmasının düşük sonuçlar vermesinin nedenlerinden biri, kodlayıcı yapısının veriyi daha düşük boyutlu bir yapıya sıkıştırmasından kaynaklı olabilir. Sıkıştırma sırasında, kodlayıcı tarafından çıkartılan öznitelikler yetersiz kaldığında KNN algoritmasının doğru karar verme oranı düşebilir. Bu durumda önemli öznitelikler kaybolabilir ve algoritmanın performansını olumsuz etkileyebilir.

Tablo 4.13. Encoder özniteliklerinin SVM ile ikili sınıflandırılması


SVM	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
Linear	51.00	51.90	50.91	50.89	0.18
RBF	46.18	46.18	45.92	45.16	0.19
Sigmoid	55.27	55.27	55.28	55.26	10.54

Encoder özniteliklerinin SVM sınıflandırıcısını beslemesiyle ikili sınıflandırma problemi ile elde edilen deney sonuçları Tablo 4.13'te verilmiştir. Tablo 4.13'e göre sigmoid çekirdeği doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC değerleri sırasıyla %55.27, %55.27, %55.28, %55.26 ve %10.54 ile diğer çekirdekler arasında en yüksek değerleri vermiştir. Tüm algoritma


sonuçlarına bakıldığında linear ve sigmoid çekirdekleri birbirlerine yakın sonuçlar verildiği gözlemlenmiştir. SVM algoritması kullanılarak ikili sınıflandırma ile edilen karmaşıklik matrisleri Şekil 4.29, Şekil 4.30 ve Şekil 4.31’de verilmiştir.



Şekil 4.29. Sigmoid Karmaşıklik Matrisi



Şekil 4.30. Linear Karmaşıklik Matris




Şekil 4.31. RBF Karmaşıklik Matrisi

Tablo 4.14. Encoder özniteliklerinin NB ile ikili sınıflandırılması

NB kernel	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
KDE	43.00	43.00	42.23	42.70	-0.14

Tablo 4.14.'e göre kernel yoğunluk tahmini kullanan NB sınıflandırıcısı doğruluk %43.00 duyarlılık %43.00, kesinlik %42.23, F1-Puanı %42.70 ve MCC %-0.14 değerleri vermiştir. NB algoritması kullanılarak ikili sınıflandırma ile edilen karmaşıklık matrisi Şekil 4.32'de verilmiştir. Karışık matrisi ile elde edilen sonuçlar, kernel yoğunluk tahmini için sonuçlar sınıflandırıcı güvenilirliği açısından başarısız olarak yorumlanabilir.




Şekil 4.32. NB Karmaşıklık Matrisi


Tablo 4.15. Encoder özniteliklerinin RF ile ikili sınıflandırılması

RF	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
200	49.81	49.81	49.25	49.81	20.08
300	51.27	51.27	51.28	51.28	25.49

Encoder özniteliklerinin RF sınıflandırıcısını beslemesiyle ikili sınıflandırma problemi ile elde edilen deney sonuçları Tablo 4.15’te verilmiştir. Tablo 5.15’e 200 ve 300 ağaçlarının doğruluk oranları incelendiğinde sırasıyla %51.08 ve %52.02 değerlerinin elde edildiği gözlenmiştir. RF ağaçlarının sonuçlarına genel olarak bakıldığında birbirlerine yakın sonuçlar verildiği gözlemlenmiştir. RF algoritması kullanılarak ikili sınıflandırma ile edilen karmaşıklık matrisleri Şekil 4.33 ve Şekil 4.34’te verilmiştir.



Şekil 4.33. RF (200) Karmaşıklık Matrisi



Şekil 4.34. RF (300) Karmaşıklık Matrisi

4.3.3. Otokodlayıcı İle Elde Edilen Sonuçlar

Otokodlayıcı derin öğrenme mimarisi hiper parametreleri kullanılarak sonuçlar verilmiştir. Bu bölümde veri kümesinin ikili ve çoklu sınıflandırma için sonuçlar verilmektedir.


a. İkili (Binary) Problem

Otokodlayıcı mimarisi kullanılarak, hasta ve normal sınıfların bulunduğu ikili veri seti üzerinde gerçekleştirilen 10-kat çapraz geçerleme deneylerinin sonuçları Tablo 4.16’da verilmiştir.

Tablo 4.16. Otokodlayıcı ikili sınıflandırma ile elde edilen sonuçlar

Otokodlayıcı mimarisi	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
AE (64-128-256-512)	81.09	81.07	81.25	81.06	62.33

Otokodlayıcı ile yapılan deneyde, gizli birim sayısında her katman için ayrı bir gizli birimden oluşan kodlayıcı ile mimari oluşturulmuştur. “AE (64-128-256-512)” mimarinin 64-128-256 - 512 katmandan oluşan 4 kodlayıcı ile özneteliklerin çıkarıldığını ifade etmektedir. Kodlama katmanından gelen sıkıştırılmış görüntüler, 512-256-128-64 aralığındaki kod çözücü katmanlarını kullanarak verileri orijinal haline getirir. Tablo 4.16’da çıkan sonuçlara göre, Otokodlayıcı uygulanan modelde doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC değerlerinin sırasıyla %81.09, %81.07, %81.25, %81.06, %62.33 değerleri ile performans sonuçları verilmiştir. Otokodlayıcı ile edilen karmaşıklık matrisi Şekil 4.35’te verilmiştir. İkili sınıflandırma probleminde, sınıflandırma için tahmin yapma durumunda %81.09 doğruluk oranı kabul edilebilir sonuç olarak değerlendirilir. Performans metriklerinden edilen sonuçlar incelendiğinde, sonucunun kabul edilebilir sonuç olmasının nedeni, otokodlayıcı yapısı görüntülerin temel özelliklerini yakalamak için iyi tasarlanmıştır. Görüntülerin önemli özelliklerini yakalamada çeşitli özellikleri öğrenebilir ve sınıflandırma sonuçları başarılı olabilir. Göz görüntülerinin normal ve hastalıklı olarak sınıflandırılmasında daha fazla katman içeren modellerin kullanılması genellikle daha iyi sonuçlar verebilir.



Şekil 4.35. Otokodlayıcı İkili Sınıflandırma Karmaşıklık Matrisi


b. Çoklu Sınıflandırma Problemi

Otokodlayıcı mimarisi çoklu sınıflandırma probleminde katarakt, diyabetik-retinopati, glokom ve normal veriler birleştirilip veri kümesi oluşturulmuştur. Tablo 4.17’de katmanlar arasında doğruluk, duyarlılık, kesinlik, F1-Puanı, MCC 10-kat çapraz geçerleme sonucu çıkan sonuçlar verilmiştir. Çoklu sınıflandırma probleminde Otokodlayıcı mimarisi doğruluk, duyarlılık, kesinlik, F1-Puanı ve MCC değerlerinin sırasıyla %69.43, %51.90, %82.44, %51.47, %62.53 sonuçları elde edilmiştir. Çıkan sonuçlara göre, Otokodlayıcı mimarisi sınıflandırıcı çoklu sınıflandırmada uygulanan modelde güvenilirliği açısından çok başarılı olmadığı görülmektedir.

Tablo 4.17. Otokodlayıcı çoklu sınıflandırma ile elde edilen sonuçlar

Otokodlayıcı mimarisi	Doğruluk %	Duyarlılık %	Kesinlik %	F1- Puanı %	MCC %
AE (64-128-256-512)	69.43	51.90	82.44	51.47	62.53

Otokodlayıcı mimarisi çoklu sınıflandırma probleminde karmaşıklık matrisi Şekil 4.36’da verilmiştir. Otokodlayıcı yapısı genellikle öznitelik çıkarımına yönelik olmasına rağmen, sınıflandırma problemlerinde düşük sonuçlar verebilir. Bu durumun nedeni, görüntülerdeki özelliklerin ayrıntılı bir şekilde yakalayamaması olabilir. Çoklu sınıflandırma problemlerinde, sınıflar arasındaki farklılıkları model anlamakta zorluk çekebilir ve düşük sonuçlar elde edilebilir.



Şekil 4.36. Otokodlayıcı Çoklu Sınıflandırma Karmaşıklık Matrisi

5. TARTIŞMA VE SONUÇLAR

Görme kusurları günlük yaşam rutinlerimizi devam ettirme ve sağlıklı bir şekilde iletişim kurabilmemizi sağlayan hayati faktörlerden biridir. Kişinin önemli yaşamsal organlarından biri olan gözler, kişinin yaşam kalitesini büyük ölçüde etkiler. Görme kusurları insan hayatını önemli ölçüde etkileyecek seviyeye gelmeden doğru bir muayene ile erken teşhis edilmelidir. Dünya Sağlık Örgütü'nün son verilerine göre, tüm dünyada yaklaşık 13,5 milyon insan ciddi görme bozukluğu veya yasal körlük yaşıyor ve bu eğilimin ileri yaşlarda arttığı görülmektedir. Bununla birlikte, görme bozukluğu birçok gelişmekte olan ülkede önemli bir halk sağlığı sorunu olmaya devam etmektedir [64].

Erken ve doğru teşhis ile görme problemlerinin önüne geçilir. Günümüzde ortaya çıkan birçok teşhis yöntemi ile çeşitli göz hastalıkları tespit edilir. Yaşamın artık her alanında kullanılan teknoloji göz hastalıkları tespitinde de büyük önem taşır. Teşhis için kullanılan teknolojiler ile ilgili çalışmalar günümüzde artmaktadır. Bu çalışmalarının temel amacı en hızlı ve en güvenilir yöntemi bulmaktır.

Bu çalışmada, katarakt, diyabetik-retinopati, glokom ve sağlıklı kişilerden elde edilen görüntüler kullanılarak, göz hastalığı tespiti problemleri ele alınmıştır. İlgili problemleri

çözmek için, ikili ve kategorik sınıflandırma tabanlı bir yaklaşım geliştirilmiştir. Bu yaklaşım farklı göz hastalıklarına sahip kişilerde bulunan veri kümesinden çeşitli veriler alınarak özniteliklerin çıkarılması prensibine dayanmaktadır. Çeşitli veri kümeleri birleştirilerek yeni bir veri kümesi elde edilmiş ve çalışmalar yapılmıştır. Yapılan çalışmada, göz hastalığı tespiti ve sınıflandırma problemlerine çözüm bulmak amacıyla derin öğrenme ve makine öğrenme yöntemlerinin bir araya getirildiği bir çalışma gerçekleştirilmiştir. Göz hastalığı tespiti aşamasında, CNN mimarilerinin sonuçları ile makine öğrenme yöntemlerinin sonuçları karşılaştırılmıştır. Makine öğrenmesi algoritması sınıflandırılmasında HOG ve Kodlayıcı öznitelik çıkarımı kullanılmış olup çıkan sonuçlar değerlendirilmiştir. CNN mimarileri mevcut veri kümesi ile eğitilerek mimariler arasında çıkan sonuçlar karşılaştırılmıştır.

CNN modelinde önerilen mimariler arasında en yüksek performans sonucunu EfficientNet vermiştir. HOG öznitelik çıkarımı ile makine öğrenmesinde, ikili sınıflandırma probleminde en yüksek performans sonucunu gösteren algoritma SVM, çoklu sınıflandırma probleminde ise RF olmuştur. CNN modelinin doğruluk başarısı ikili sınıflandırma probleminde %92.77 ve çoklu sınıflandırma probleminde %88.59 olarak hesaplanmıştır. Makine öğrenmesi ikili sınıflandırma probleminde en yüksek %92.37 ve çoklu sınıflandırma probleminde en yüksek %83.41 sonuçları elde edilmiştir. Elde edilen sonuçlar genel olarak incelendiğinde, CNN modeli ile sınıflandırma problemlerinin daha başarılı sonuçlar verdiği gözlemlenmiştir. Bu durumun sebebi, derin öğrenme mimarilerinin büyük veri kümelerinde daha iyi öğrenme yeteneğine sahip olmaları ve daha karmaşık yapılar için kullanılmasıdır. Bazı makine öğrenme yöntemleri, derin öğrenme gibi transfer öğrenme yeteneklerine sahip değildir. Transfer öğrenme, genel bir görevde öğrenilen temsillerin daha özgül bir görevde kullanılmasını içerir ve bu tür bir yaklaşım makine öğrenme modelleri için sınırlı olabilir. Veri setinde kullanılan görüntülerin boyutları yüksek olduğundan makine öğrenme algoritmaları bu verileri işlemekte zorlanmış olabilir. Görüntü verileri üzerinde işlem yapmak daha karmaşık ve zor hale geldiğinden dolayı makine öğrenme algoritmalarının performansları olumsuz etkilenmiş olabilir. Makine öğrenmesi göz görüntülerini manuel öznitelik çıkarımı sırasında, gözün önemli özelliklerini iyi yakalayamamış olabilir. CNN modeli öznitelik çıkarımını otomatik yaptığından gözdeki önemli özellikleri daha iyi yakalama yeteneğine sahip olabilir.

Makine öğrenmesi ve otokodlayıcı ile elde edilen sınıflandırma problemlerindeki performans sonuçları karşılaştırıldığında, makine öğrenmesinin daha yüksek başarı oranına sahip olduğu gözlemlenmiştir. HOG öznitelik çıkarımı ile makine öğrenmesi algoritmalarının ikili sınıflandırma probleminde başarı oranı %80-90 arasında iken otokodlayıcı yöntemlerinde bu oran %81.09 olarak hesaplanmıştır. Çoklu sınıflandırma probleminde ise başarı oranı %70-80

arasında iken otokodlayıcı yöntemlerinde bu oran %69.43 olarak hesaplanmıştır. Otokodlayıcı yönteminin daha düşük sonuçların elde edilmesinin nedeni, karmaşık ve yüksek boyutlu veri setlerinde öğrenme yeteneği sınırlı olabilir ve düşük performans gösterebilir.

CNN, Makine öğrenmesi ve otokodlayıcı yöntemleriyle yapılan ikili sınıflandırma ve çoklu sınıflandırma karşılaştırmalarında, ikili sınıflandırma yönteminin daha yüksek başarı sonuçları verdiği gözlemlenmiştir. İkili sınıflandırmada, iki sınıf arasındaki farkları öğrenmek daha kolay olabilir ve model daha iyi öğrenme yeteneğine sahip olmuş olabilir. Kullanılan yöntemler, ikili sınıflandırma probleminde daha iyi genelleme yapmış ve veri kümesini daha iyi öğrenmiş olabilir.

Karmaşıklık matrislerinin başarı performansları incelendiğinde, CNN modelinin diğer yöntemlere kıyasla doğruluk oranlarında başarılı sonuçlar verdiği görülmüştür. Çoklu sınıflandırma problemlerinde karmaşıklık matrisleri incelendiğinde, kullanılan yöntemler tarafından iyi tahmin edilen sınıfın diyabetik-retinopati ve en kötü tahmin edilen sınıfın glokom olduğu gözlemlenmiştir. Veri setinde diyabetik-retinopati görüntüleri daha belirgin ve ayırt edici olabilir. Bu durumda model özellikleri daha kolay öğrenebilmiş ve ayırt edebilmiş olabilir. Makine öğrenmesi öznitelik çıkarım yöntemleri olan HOG ve kodlayıcı yöntemleri karşılaştırıldığında, birbirlerine HOG yönteminin daha iyi sonuçlar verdiği görülmüştür. Kodlayıcı yönteminin daha düşük sonuçlar vermesi, katman sayısı ve boyutundan kaynaklı olabilir. Kullanılan katman ve boyut verinin karmaşıklığına uygun olmayabilir ve bu durum kodlayıcının performans sonucunu olumsuz etkilemiş olabilir. Kodlayıcılar veriyi sıkıştırma sırasında anlamlı verilerin bir kısmını kaybedilir ve bu durum modelinin performansını düşürebilir.

Göz hastalığının sınıflandırılması ve tahmininde, literatür incelemelerinde öne çıkan geleneksel makine öğrenmesi yöntemleri (SVM, KNN, NB, RF) ve derin öğrenme modeli CNN kullanılmıştır. CNN modeli görsel sınıflandırma alanında daha yaygın kullanılmaktadır. Göz hastalığı tespiti için retinal fundus verileri kullanılarak, ikili ve çoklu sınıflandırma problemlerine kullanılan CNN mimarileri ve makine öğrenmesi algoritmaları önerilmiştir. Önerilen CNN mimarilerinden, ikili sınıflandırma %90 üzerinde ve çoklu sınıflandırmada %88 oranında doğruluk başarı oranı elde edilmiştir. Literatür ile kıyaslamalarda ikili ve çoklu sınıflandırmalar için kıyaslamalar yapılmıştır. Çoklu kıyaslamalarda literatür doğruluk başarı oranı %81- %86 arasında sonuçlar alınırken, çalışmada CNN modeli %88 başarı oranında sonuç almıştır [10,65,69]. EfficientNet mimarisi kullanılarak gerçekleştirilen normal ve hastalıklı ikili sınıflandırma probleminde %92.77 doğruluk puanı elde edilerek en yüksek sonuca ulaşılmıştır.

Önerilen sistem ileriki çalışmalarda göz hastalığı tespiti için ön adım niteliğindedir. Derin öğrenme ve makine öğrenmesi algoritmaları kullanılarak retinal fundus görüntüleri incelenmesi ile sonuçlar elde edilmiştir. Derin öğrenme ile hesaplanan sonuçlar ümit verici olmakla birlikte, gelecekte yapılacak çalışmalarda daha fazla retinal fundus görüntüsü kullanılarak ve farklı modeller ile çalışılarak ilgili problem için kesin ve doğru sonuçlar elde edilmeye çalışılacaktır. Geleceğe yönelik planlar, veri seti büyüklüğünün ve göz kategorisi sınıflarının arttırılması üzerine kuruludur. Renk körlüğü, miyop ve astigmat gibi hastalıklar da veri kümesine eklenerek, kategori sayısının arttırılması ile daha detaylı çalışmalar yapılabilecek ve daha iyi sonuçlar elde edilebilecektir.

KAYNAKLAR

- [1] World Health Organization, “World Report on Vision,” Oct. 2019. Available: <http://who.int/publications/i/item/world-report-on-vision> (Son Erişim: 30 Mayıs 2023)
- [2] ÇEVİK, İ. et al. (2021) ‘Lifelong Eye Health: “Vision 2020: The right to sight”’, *ESTÜDAM Halk Sağlığı Dergisi*, 6(3), pp. 310–321. doi:10.35232/estudamhsd.891156.
- [3] Child eye health (2022) The International Agency for the Prevention of Blindness. Available at: <https://iapb.org/learn/vision-atlas/magnitude-and-projections/child-eye-health/> (Son Erişim: 30 Mayıs 2023).
- [4] Ağalday, F. and Çınar, A. (2021) ‘Derin öğrenme Mimarilerini kullanarak katarakt tespiti’, *European Journal of Science and Technology*. doi:10.31590/ejosat.1012694.
- [5] Özçelik, Y.B. and Altan, A. (2021) ‘Diyabetik Retinopati Teşhisi için Fundus Görüntülerinin Derin öğrenme Tabanlı Sınıflandırılması’, *European Journal of Science and Technology*. doi:10.31590/ejosat.1011806.
- [6] Yalçın, N., Alver, S. and Uluhatun, N. (2018) ‘Classification of retinal images with deep learning for early detection of diabetic retinopathy disease’, *2018 26th Signal Processing and Communications Applications Conference (SIU)*. doi:10.1109/siu.2018.8404369.
- [7] Yıldırım, Ö. and Altunbey Özbay, F. (2022) ‘Fundus Görüntülerinden Derin öğrenme teknikleri ile Glokom Hastalığının tespiti’, *European Journal of Science and Technology*. doi:10.31590/ejosat.1216404.
- [8] Batuhan Metin, Bahadır Karasulu, F. (2022) ‘Derin Öğrenme Modellerini Kullanarak İnsan Retinasının Optik Koherans Tomografi Görüntülerinden Hastalık Tespiti’, *Veri Bilimi Dergisi. Veri Bilim Derg.*, 5(2), 9-19, 2022
- [9] Bistulfi, T.M., Monteiro, M.M. and de Almeida Monte-Mor, J. (2023) ‘An approach to assist ophthalmologists in glaucoma detection using Deep Learning’, *Advances in Intelligent Systems and Computing*, pp. 237–245. doi:10.1007/978-3-031-28332-1_27.
- [10] Bulut, B., Kalın, V., Berktaş Güneş, B., & Khazin, R. (2022). Classification of Eye Disease from Fundus Images Using EfficientNet. *Artificial Intelligence Theory and Applications*, 2(1), 1-7.
- [11] Malik, S. et al. (2019) ‘Data driven approach for eye disease classification with Machine Learning’, *Applied Sciences*, 9(14), p. 2789. doi:10.3390/app9142789.
- [12] Khan, M.S. et al. (2022) ‘Deep learning for ocular disease recognition: An inner-class balance’, *Computational Intelligence and Neuroscience*, 2022, pp. 1–12. doi:10.1155/2022/5007111.
- [13] Shahzad, Khuram (2023), “eyes disease”, *Mendeley Data*, V1, doi: 10.17632/t94tfnxzs7.1
- [14] Kaur, Palwinder (2022), “Bajwa Hospital (Multi Eye Disease Dataset)”, *Mendeley Data*, V3, doi: 10.17632/rgwpd4m785.3
- [15] Cen, L.-P. et al. (2021) ‘Automatic detection of 39 fundus diseases and conditions in retinal photographs using Deep Neural Networks’, *Nature Communications*, 12(1). doi:10.1038/s41467-021-25138-w.
- [16] Eye diseases classification using Deep Learning’ (2023) *International Research Journal of Modernization in Engineering Technology and Science*. doi:10.56726/irjmets34476.
- [17] Song, J., Jeong, H. and Jeong, J. (2022) ‘Performance optimization of object tracking algorithms in opencv on gpus’, *Applied Sciences*, 12(15), p. 7801. doi:10.3390/app12157801.
- [18] Pandas (2023) PyPI. Available at: <https://pypi.org/project/pandas/>. (Son Erişim: 26 Temmuz 2023)

- [19] Glob Module in python: Explained (2022) Built In. Available at: <https://builtin.com/software-engineering-perspectives/glob-in-python> (Son Erişim: 26 Temmuz 2023)
- [20] Walt, S. et al. (2014) ‘Scikit-image: Image processing in python’, *PeerJ*, 2. doi:10.7717/peerj.453.
- [21] Python numpy (2023) GeeksforGeeks. Available at: <https://geeksforgeeks.org/python-numpy/> (Son Erişim: 26 Temmuz 2023)
- [22] Scipy (2023) PyPI. Available at: <https://pypi.org/project/scipy/> (Son Erişim: 26 Temmuz 2023)
- [23] Scikit learn tutorial Online Tutorials, Courses, and eBooks Library. Available at: https://tutorialspoint.com/scikit_learn/index.htm (Son Erişim: 26 Temmuz 2023)
- [24] Introduction to matplotlib (2023) GeeksforGeeks. Available at: <https://geeksforgeeks.org/python-introduction-matplotlib/> (Son Erişim: 26 Mayıs 2023)
- [25] Tensorflow (2023) PyPI. Available at: <https://pypi.org/project/tensorflow/> (Son Erişim: 26 Temmuz 2023)
- [26] Joseph, F.J., Nonsiri, S. and Monsakul, A. (2021) ‘Keras and tensorflow: A hands-on experience’, *Advanced Deep Learning for Engineers and Scientists*, pp. 85–111. doi:10.1007/978-3-030-66519-7_4.
- [27] Dalal, N. and Triggs, B(2005) ‘Histograms of oriented gradients for human detection’, *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05)*. doi:10.1109/cvpr.2005.177.
- [28] Mallick, S. (2021) Histogram of oriented gradients explained using opencv, LearnOpenCV. Available at: <https://learnopencv.com/histogram-of-oriented-gradients/> (Son Erişim: 26 Mayıs 2023)
- [29] Y. Bengio, «Learning Deep Architectures for AI,» *Found. trends Mach. Learn*, cilt vol. 2, no. no. 1, p. 1–127, 2009.
- [30] Gómez Blas, N. et al. (2020) ‘Image classification with convolutional neural networks using Gulf of Maine Humpback Whale Catalog’, *Electronics*, 9(5), p. 731. doi:10.3390/electronics9050731.
- [31] Otokodlayıcı (2022) Wikipedia. Available at: <https://tr.wikipedia.org/wiki/Otokodlay%C4%B1c%C4%B1> (Son Erişim: 26 Mayıs 2023)
- [32] Yapay Sinir Ağları (2023) Wikipedia. Available at: https://tr.wikipedia.org/wiki/Yapay_sinir_a%C4%9Flar%C4%B1 (Son Erişim: 26 Temmuz 2023)
- [33] GTech (2021) Yapay Sinir Ağları Ve Uygulamaları: GTECH, G Teknoloji. Available at: <https://gtech.com.tr/yapay-sinir-aglari-ve-uygulamaları-1/> (Son Erişim: 26 Mayıs 2023)
- [34] K. Fukushima, “Neocognitron: A hierarchical neural network capable of visual pattern recognition,” *Neural Networks*, vol. 1, no. 2, pp. 119–130, 1988.
- [35] Ergin, T. (2020) Convolutional Neural Network (convnet yada CNN) Nedir, Nasıl çalışır?, Medium. Available at: <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad> (Son Erişim: 22 Mayıs 2023)
- [36] Ö. İnik, E. Ülker. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. 2017 Available at: <https://dergipark.org.tr/tr/download/article-file/380999> (Son Erişim: 22 Mayıs 2023)
- [37] Mızrak Ph.D. (2020) Derine Daha DERİNE: Evrişimli Sinir Ağları, Medium. Available at: <https://ayyucekizrak.medium.com/deri-CC%87ne-daha-deri-CC%87ne-evri-C5%9Fimli-sinir-a%C4%9Flar%C4%B1-2813a2c8b2a9>. (Son Erişim: 26 Temmuz 2023)
- [38] Narin, A., Kaya, C. and Pamuk, Z. (2021) ‘Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks’, *Pattern Analysis and Applications*, 24(3), pp. 1207–1220. doi:10.1007/s10044-021-00984-y.

- [39] Yani, M., Budhi Irawan, S., Si., and Casi Setiningsih, S.T., M.T. (2019) ‘Application of transfer learning using convolutional neural network method for early detection of terry’s nail’, *Journal of Physics: Conference Series*, 1201(1), p. 012052. doi:10.1088/1742-6596/1201/1/012052.
- [40] Sakar, H.G. (2021) Evrişimli Sinir ağıları (Convolutional Neural Networks-CNN), Medium. Available at: <https://hilalgozutok.medium.com/evri%C5%9Fimli-sinir-a%C4%9Flar%C4%B1-convolutional-neural-networks-cnn-e61470e9bdb1> (Son Erişim: 26 Temmuz 2023)
- [41] Huang, W., Peng, G. and Tang, X. (2019) *A limit of densely connected convolutional networks V1*. doi: 10.17504/protocols.io.8j6hure.
- [42] Li, X. et al. (2020) ‘Classification of breast cancer histopathological images using interleaved DenseNet with Senet (idsnet)’, *PLOS ONE*, 15(5). doi:10.1371/journal.pone.0232127.
- [43] Tan, M., Le, Q.V., “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks”, *Proceedings of the 36th International Conference on Machine Learning*, 6105– 6114, 2019
- [44] Wisdomml (2023) EfficientNet and its performance comparison with other Transfer Learning Networks, Wisdom ML. Available at: <https://wisdomml.in/efficientnet-and-its-performance-comparison-with-other-transfer-learning-networks/> (Son Erişim: 26 Temmuz 2023)
- [45] Simonyan, K., & Zisserman, A. (2014). *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556.
- [46] Ren, Y. et al. (2018) ‘Learning better deep features for the prediction of occult invasive disease in ductal carcinoma in situ through transfer learning’, *Medical Imaging 2018: Computer-Aided Diagnosis*. doi:10.1117/12.2293594.
- [47] He, K. et al. (2016) ‘Deep residual learning for image recognition’, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. doi:10.1109/cvpr.2016.90.
- [48] S. Wu, S. Zhong, and Y. Liu, “Deep residual learning for image steganalysis,” *Multimed. Tools Appl.*, pp. 1–17, 2017.
- [49] Chollet, F. (2017) ‘Xception: Deep learning with depthwise separable convolutions’, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. doi:10.1109/cvpr.2017.195.
- [50] Pujari, S.D., Pawar, M.M. and Wadekar, M. (2021) ‘Multi-classification of breast histopathological image using xception: Deep learning with depthwise separable convolutions model’, *Techno-Societal* 2020, pp. 539–546. doi:10.1007/978-3-030-69921-5_54.
- [51] Westphal, E. and Seitz, H. (2021) ‘A machine learning method for defect detection and visualization in selective laser sintering based on Convolutional Neural Networks’, *Additive Manufacturing*, 41, p. 101965. doi:10.1016/j.addma.2021.101965.
- [52] ÇELİK, Ö. (2018) ‘A research on machine learning methods and its applications’, *Journal of Educational Technology and Online Learning*, 1(3), pp. 25–40. doi:10.31681/jetol.457046.
- [53] ATALAY, M. and ÇELİK, E. (2017) ‘Büyük Veri Analizinde Yapay Zekâ ve makine öğrenmesi uygulamaları - artificial intelligence and machine learning applications in Big Data Analysis’, *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, pp. 155–172. doi:10.20875/makusobed.309727.
- [54] Burges, C. J. (1998). A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2), 121-167.
- [55] AKCA, M.F. (2020) Destek Vektör Makineleri Nedir? (Makine öğrenmesi serisi-2), Medium. Available at: <https://medium.com/deep-learning-turkiye/nedir-bu-destek-vekt%C3%B6r-makineleri-makine-%C3%B6%C4%9Frenmesi-serisi-2-94e576e4223e> (Son Erişim: 26 Temmuz 2023)

- [56] Zhang, H. (2004). The optimality of naive Bayes. *Proceedings of the 17th International FLAIRS Conference*, 562-567.
- [57] Bektaş, B., Babur, S., Turhal, U., Köse, E., Makine öğrenmesi yardımıyla optik karakter tanıma sistemi. *5.Uluslar Arası Matbaa Teknolojileri Sempozyumu*, İstanbul, 2016.
- [58] Chaudhuri, K.D. (2023) Building naive Bayes classifier from scratch to perform sentiment analysis, Analytics Vidhya. Available at: <https://analyticsvidhya.com/blog/2022/03/building-naive-bayes-classifier-from-scratch-to-perform-sentiment-analysis/> (Son Erişim: 26 Temmuz 2023)
- [59] Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185.
- [60] Tafralı. (2022). K-en yakın komşu algoritması nasıl çalışır? Miuul Not Defteri. Available at: <https://miuul.com/not-defteri/k-en-yakin-komsu-algoritmasi-nasil-calisir> (Son Erişim: 26 Temmuz 2023)
- [61] Cutler, A., Cutler, D. R., & Stevens, J. R. (2007). Random forests. *Ensemble Machine Learning: Methods and Applications*, 157-175.
- [62] Géron, A., Hands-On machine learning with Scikit-Learn and TensorFlow concepts. *O'Reilly Yayıncılık*, 2017.
- [63] Öztürk, Python Ile Sınıflandırma analizleri – Rastgele Orman. Available at: <https://miracozturk.com/python-ile-siniflandirma-analizleri-rastgele-orman-random-forest-algoritmasi/> (Son Erişim: 26 Temmuz 2023)
- [64] Yan, F. et al. (2017) ‘Artemisinin protects retinal neuronal cells against oxidative stress and restores rat retinal physiological function from light exposed damage’, *ACS Chemical Neuroscience*, 8(8), pp. 1713–1723. doi:10.1021/acscchemneuro.7b00021.
- [65] S. Bagui, D. Nandi, S. Bagui, and R. J. White, “Machine Learning and Deep Learning for Phishing Email Classification using One-Hot Encoding,” *J. Comput. Sci.*, vol. 17, no. 7, 2021.
- [66] Mitchell, T., “*Machine Learning*”, McGraw Hill, New York, (1997)
- [67] Dalal, N. and Triggs, B. ‘Histograms of oriented gradients for human detection’, *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. doi:10.1109/cvpr.2005.177.
- [68] Sarki, R. et al. (2018) ‘Convolutional neural network for multi-class classification of Diabetic Eye Disease’, *ICST Transactions on Scalable Information Systems*, p. 172436. doi:10.4108/eai.16-12-2021.172436.
- [69] Sarki, R. et al. (2020) ‘Automated detection of mild and multi-class diabetic eye diseases using Deep Learning’, *Health Information Science and Systems*, 8(1). doi:10.1007/s13755-020-00125-5.
- [70] What is the role of rectified linear (ReLU) activation function in CNN? Quora. Available at: <https://quora.com/What-is-the-role-of-rectified-linear-ReLU-activation-function-in-CNN>(Son Erişim: 26 Temmuz 2023)