

Göz Hastalıklarında Tanı Yöntemleri ve Derin Öğrenme Uygulamaları: Bir Literatür Çalışması


Araştırma Makalesi
10.65520/erciyesfen.1770680


Künye:


Sayı: 42

Yıl: 2026

Sayfa: 153-169

 Tayyip Özcan^a

 Hatice Türkođan^b

 Fatih Horozođlu^c

^a Doç. Dr., Erciyes Üniversitesi,
tozcan@erciyes.edu.tr

^b Yüksek Mühendis, Erciyes
Üniversitesi,
haticeozdemir2711@gmail.com

^c Prof. Dr., Erciyes Üniversitesi,
fhoroz@yahoo.com

* Sorumlu Yazar

Geliş Tarihi: 22.08.2025

Kabul Tarihi: 02.01.2026

Atıf:

Tayyip Özcan, Hatice Türkođan,
Fatih Horozođlu (2026). Göz
Hastalıklarında Tanı Yöntemleri ve
Derin Öğrenme Uygulamaları: Bir
Literatür Çalışması. *Erciyes University
Journal of Institute Of Science and
Technology*, 42, 153-169.
<https://doi.org/10.65520/erciyesfen.1770680>

Screened by

 iThenticate[®]
for Authors & Researchers



Except where otherwise noted, content
in this article is licensed under a
Creative Commons 4.0 International
license. Icons by Font Awesome.

Öz

Göz hastalıklarının erken teşhisi, görme kaybını önlemek ve hastaların yaşam kalitesini korumak açısından kritik öneme sahiptir. Son yıllarda, biyomedikal görüntüleme derin öğrenme yöntemlerindeki hızlı ilerleme, oftalmoloji alanında önemli uygulamalar bulmuştur. Fundus fotoğrafları, optik koherens tomografi ve retina görüntüleri kullanılarak geliştirilen modeller, diyabetik retinopati, glokom, yaşa bağlı makula dejenerasyonu ve diğer retina temelli hastalıkların otomatik teşhisinde yüksek doğruluk oranlarına ulaşmıştır. Bu derleme, göz hastalıklarını tespit etmek için kullanılan mevcut derin öğrenme yaklaşımlarını, kullanılan veri kümelerini, mimari farklılıkları ve performans ölçütlerini incelemektedir. Evrimsel sinir ağları, transfer öğrenme, hibrit modeller ve giderek artan şekilde görü dönüştürücü tabanlı yöntemler karşılaştırmalı olarak değerlendirilmektedir. Çalışma, alandaki son gelişmeleri özetlemeyi ve gelecekteki araştırmalara yön verecek öneriler sunmayı amaçlamaktadır.

Anahtar kelimeler: Göz Hastalıkları, Derin Öğrenme, Görüntü Analizi, Optik Koherens Tomografi, Fundus Fotoğrafçılığı



Diagnostic Methods and Deep Learning Applications in Eye Diseases: A Literature Review

Abstract

The early detection of eye diseases is critically important for preventing vision loss and maintaining patients' quality of life. In recent years, the rapid advancement of deep learning methods in biomedical imaging has found significant applications within the field of ophthalmology. Models developed using fundus photographs, optical coherence tomography, and retinal images have achieved high accuracy rates in the automated diagnosis of diabetic retinopathy, glaucoma, age-related macular degeneration, and other retina-based diseases. This review examines the current deep learning approaches used for detecting eye diseases, the datasets employed, architectural variations, and performance metrics. Convolutional neural networks, transfer learning, hybrid models, and, increasingly, vision transformer-based methods are comparatively evaluated. The study aims to summarize recent developments in the field and provide recommendations to guide future research.

Keywords: Ophthalmology, Deep Learning, Image Analysis, Optical



1. Giriş

İnsan görme kalitesinin tehlikeye girmesi, kişinin üretkenliğini ve genel yaşam kalitesini olumsuz etkilediđi için göz sađlığı bu nedenle bireylerin yaşam kalitesini doğrudan belirleyen temel unsurlardan biri olarak öne çıkmaktadır [1]. Dünya genelinde milyonlarca insan retinal anormalliklerden etkilenmekte ve bu hastalıklar erken dönemde teşhis edilip tedavi edilmediğinde kalıcı görme kaybına yol açabilmektedir. Diyabetik retinopati (Diabetic retinopathy, DR), glokom ve yaşa bađlı makula dejenerasyonu (Age-related macular degeneration, AMD) gibi göz hastalıkları çođunlukla ilerleyici bir süreç izlemekte, belirgin bulgular ise genellikle hastalığın ileri evrelerinde ortaya çıkmaktadır. Dolayısıyla, erken teşhise yönelik yöntemlerin geliştirilmesi yalnızca bireylerin görme sađlığının korunması açısından deđil, aynı zamanda toplum sađlığının sürdürülebilirliği ve sađlık sistemine yüklenen ekonomik maliyetlerin azaltılması bakımından da büyük önem taşımaktadır.

Göz hastalıklarının tanısında uzun yıllar boyunca temel olarak klinik muayeneler, fundus fotoğrafçılığı ve optik koherens tomografi (Optical Coherence Tomography, OCT) gibi görüntüleme teknikleri kullanılmıştır. Bu teknolojiler, doktorlara retinal yapılar hakkında ayrıntılı bilgiler sunarak hastalıkların değerlendirilmesinde önemli katkılar sağlamaktadır. Ancak göz hastalıklarının tanısında uzun yıllardır kullanılan fundus fotoğrafçılığı ve OCT gibi yöntemler, doktorlara retinal yapılar hakkında ayrıntılı bilgiler sađlasa da görüntülerin uzmanlar tarafından manuel olarak değerlendirilmesi, tanı sürecini yavaşlatmakta ve hata riskini artırmaktadır. Bu nedenle, bilgisayar destekli tanı sistemlerinin geliştirilmesi gerekliliđi ortaya çıkmıştır.

Son yıllarda yapay zekâ, özellikle de derin öğrenme tabanlı yaklaşımlar, göz hastalıklarının otomatik tespitinde ümit verici çözümler sunmaktadır [3]. Konvolüsyonel sinir ađları (Convolutional neural networks, CNN) ve transfer öğrenme yöntemleri, büyük veri setlerinden elde edilen görsel özellikleri öğrenerek yüksek doğrulukta teşhis gerçekleştirebilmektedir. Ayrıca, yapay zekâ tekniklerinin gelişmesiyle birlikte bu sistemler yalnızca sonuç odaklı deđil, aynı zamanda karar mekanizmalarını yorumlanabilir hale getirmektedir. Oftalmolojide derin öğrenme yöntemleri oftalmolojide erken teşhisin güvenilirliğini artırmakta, tanı süreçlerini hızlandırmakta ve klinik uygulamalara entegre edilme potansiyeli taşımaktadır.

Bu çalışmanın amacı, göz hastalıklarının teşhisinde kullanılan derin öğrenme yaklaşımlarını literatür ışığında incelemek, mevcut yöntemlerin güçlü ve zayıf yönlerini tartışmak ve gelecekte yapılacak araştırmalara yönelik kapsamlı bir çerçeve sunmaktır.

2. Göz Hastalıklarının Teşhisinde Kullanılan Yöntemler

Retinal görüntüleme üzerine yapılan çalışmalar, retina yapısının daha net ve detaylı görülmesini sađlamış; bu sayede hastalıkların erken teşhisi ve etkin yönetimi mümkün olmuştur. Fundus fotoğrafçılığı ve OCT günümüzde en yaygın kullanılan yöntemlerdir [4]. Bu bölümde, bu tekniklerin retinal hastalıkların tanısındaki rolleri ele alınmaktadır.

2.1. Optik koherens tomografi (OCT)


OCT, göz ve özellikle retina dokusunun mikroskopik detaylarını yüksek çözünürlükte görüntülemeye olanak tanıyan non-invaziv bir tıbbi görüntüleme yöntemidir. 1991 yılında oftalmolojiye tanıtılan OCT, düşük güçlü ışığın dokudan yansımaları ölçerek tomografik görüntüler oluşturmaktadır. Böylece retina katmanları, optik sinir başı ve koroid gibi yapıların ayrıntılı analizi yapılmaktadır.

TD-OCT (Time-Domain OCT – Zaman Alanlı OCT): İlk geliştirilen OCT teknolojisidir. Sınırlı tarama hızı ve çözünürlüğe sahiptir, ancak temel retinal yapıların görüntülenmesinde kullanılmıştır.

FD-OCT (Fourier-Domain OCT – Fourier Alanlı OCT): Daha hızlı ve hassas görüntüleme sađlayan bir yöntem olup iki alt gruba ayrılmaktadır. SD-OCT (Spectral-Domain OCT – Spektral Alanlı

OCT), yüksek çözünürlük ve hız sunarak özellikle retinal katman analizinde etkin biçimde kullanılmakta, ancak bazı koroidal yapıların ayrıntılı değerlendirilmesinde sınırlı kalmaktadır [5]. SS-OCT (Swept-Source OCT – Taranmış Kaynaklı OCT) ise daha uzun dalga boyu kullanarak derin doku penetrasyonu ve ultra yüksek çözünürlük sağlamakta, bu sayede mikro yapılar ile koroid morfolojisinin detaylı biçimde incelenmesine imkân vermektedir.

OCT Anjiyografisi (OCTA): OCT Anjiyografisi (OCTA), ekzojen boyaların enjeksiyonu olmaksızın retina ve koroid mikro damar yapısının görüntülenmesini sağlayan, noninvaziv ve OCT tabanlı bir görüntüleme yöntemidir [6]. OCTA, aynı pozisyonda gerçekleştirilen birden fazla B taramasındaki eritrosit hareketinden kaynaklanan sinyal değişikliklerini kullanarak damar yapısını görselleştirmektedir. Bu yöntem sayesinde damar yapıları hareket kontrastı ile ortaya koyulur ve damar yapısına ilişkin detaylı bilgiler elde edilmektedir. OCTA, yüksek çözünürlük ve derinlik bilgisi sunarak damar yapısının detaylı analizine imkân sağlar ve geleneksel yöntemlerle görülemeyen mikro damar yapılarını noninvaziv bir şekilde incelemeye olanak vermektedir.



Şekil 1. OCT ile Çekilen Retina Görüntüsü

2.2. Fundus fotoğrafçılığı

Fundus fotoğrafçılığı, gözün arka segmentini oluşturan retina, makula, optik disk ve koroid gibi yapıları ayrıntılı olarak görüntülemeye yönelik non-invaziv bir görüntüleme yöntemidir. Bu teknik, retina ve çevresindeki damar yapılarının morfolojik özelliklerini değerlendirmek, çeşitli göz hastalıklarının tanı ve takibinde klinik kararları desteklemek amacıyla kullanılmaktadır. Fundus fotoğrafları, oftalmologlara hastalığın evresini belirleme, tedaviye yanıtı izleme ve progresyonu takip etme imkânı sağlar.

Renkli Fundus Fotoğrafçılığı: Retinanın doğal renklerini yansıtan görüntüler elde edilmektedir. DR, hipertansif retinopati ve diğer vasküler patolojilerin değerlendirilmesinde yaygın olarak kullanılmaktadır.

Flaşlı Fundus Fotoğrafçılığı (Flash Fundus Photography): Retinayı aydınlatmak için kısa süreli ışık flaşı kullanılmaktadır. Daha parlak ve kontrastlı görüntü elde edilmesine olanak sağlamaktadır.

Kızılötesi Fundus Fotoğrafçılığı: Retina damarlarını ve pigment epitelini daha iyi görselleştirmek için yakın kızılötesi ışık kullanılmaktadır. Özellikle düşük ışık koşullarında avantaj sağlamaktadır.

Fluorescein Anjiyografi (FA): Ekzojen floresan boya damar sistemine enjekte edilerek retinal ve koroidal kan akışı izlenmektedir. Damar kaçaklarını ve neovaskülarizasyonu değerlendirmek için kullanılmaktadır.

Oksijen Satürasyon ve Autofloresans Görüntüleme: Retina dokusunun metabolik durumunu ve lipofuscin birikimini deđerlendirmek için özel filtreler ve dalga boyları kullanılmaktadır.



Şekil 2. Fundus Fotoğrafçılığı ile Çekilen Göz Fotođrafı (Infigo Eye Hospitals, 2024)

3. Hastalık Tespitinde Kullanılan Veri Tabanları

Bu bölümde, son zamanlarda literatürde algoritmaların performanslarını deđerlendirmek için kullanılan başlıca veri tabanları özetlenmektedir. Veri tabanları birçok retina hastalıklarına ait görüntüler içermektedir.

DRIVE (Digital Retinal Images for Vessel Extraction): DRIVE veri tabanı, retina damar segmentasyonu çalışmalarında yaygın olarak kullanılan standart bir veri setidir [7]. Hollanda'daki Sağlık Araştırmaları Enstitüsü tarafından oluşturulan bu veri tabanı, 40 adet renkli fundus görüntüsünden oluşur ve bunların yarısı eğitim, diđer yarısı test seti olarak ayrılmıştır. Her görüntü, uzmanlar tarafından damar yapıları açısından detaylı şekilde anotasyonlanmıştır. DRIVE, özellikle retinal damar segmentasyonu, damar yoğunluğu analizi ve otomatik vasküler yapının çıkarılması çalışmalarında referans veri seti olarak kullanılmaktadır.

STARE (Structured Analysis of the Retina): STARE, 400 retina görüntüsüne sahiptir ve bunların 40'ı elle segmentlere ayrılmış kan damarları ve atardamar/toplardamar etiketlemesi içerir. Tüm görüntüler uzmanlar tarafından etiketlenmiştir. Görüntü verileri PPM formatına sıkıştırılmıştır [8]. Optik sinir başı tanımlama algoritmaları da eklenmiştir. Toplam 44 patoloji tespit edilmiş ve 13 farklı anormallikle ilişkilendirilmiştir.

CHASE_DB1 (Child Heart and Health Study in England Database 1): CHASE_DB1, özellikle çocukların retinal damar yapısını incelemek amacıyla oluşturulmuş bir veri tabanıdır. 28 adet yüksek çözünürlüklü fundus görüntüsü içermektedir. Göz damarı kıvrımlılığı ile kardiyovasküler hastalık risk faktörleri arasındaki bağlantıyı belirlemek için 1000'den fazla çocukta retina görüntülemesi yapılmıştır [9].

DRIONS-DB: Optik disk segmentasyonu ve glom tespitine yönelik oluşturulmuş bir veri setidir. 110 adet fundus görüntüsü içerir ve optik disk anotasyonları uzmanlar tarafından yapılmıştır [10].

MESSIDOR: DR araştırmalarında yaygın olarak kullanılan Messidor veri tabanı, 1200'den fazla fundus görüntüsünden oluşur. Görüntüler, retinopatinin evresine göre sınıflandırılmıştır ve yapay zekâ modellerinin eğitim ve validasyonu için kullanılmaktadır [11].

APTOS: Asya Pasifik Tele Oftalmoloji Derneđi (APTOS) veri seti, farklı kameralarla çekilmiş, farklı boyutlarda 3662 görüntüden oluşan bir Kaggle veri setidir. Hindistan'daki Aravind Göz

Hastanesi tarafından oluşturulmuştur. Bu veri tabanında, eğitim setinin yalnızca temel gerçeği kamuya açıktır. Görüntüler beş ICDR sınıflandırmasına göre sınıflandırılmıştır. Veri seti oldukça dengesizdir ve görüntülerin çoğu (1805) normaldir. Yalnızca 183 görüntüde şiddetli Non-Proliferatif Diyabetik Retinopati (NPDR) vardır [12].

OCT-2017: OCT2017 veri tabanı, çok sınıflı bir problemde retina hastalıklarını tespit etmeyi amaçlayan algoritmalar için bir kıyaslama noktası sağlamak üzere oluşturulmuş, yüksek kaliteli, TIFF formatlı, herkese açık bir veri tabanıdır. Toplamda 84.452 OCT görüntüsünden oluşur ve dört ana sınıfa ayrılmıştır ve normal, Koroidal Neovaskülarizasyon (Choroidal neovascularization, CNV), Diyabetik Makula Ödemi (Diabetic macular edema, DME) ve Drusen olmak üzere dört hastalık evresi arasında ayırım yapmak üzere etiketlenmiştir [13].

Retinal OCT-C8: Retinal OCT-C8, OCT tabanlı görüntülerden oluşan, retina hastalıklarının tanısı ve değerlendirilmesi için tasarlanmış kapsamlı bir veri setidir. Bu veri tabanı, farklı retinal patolojilere ait yüksek çözünürlüklü kesitsel OCT görüntülerini içermektedir [14].

ODIR (Ocular Disease Intelligent Recognition): 5.000 hastaya ait yaş, cinsiyet ve fundus fotoğraflarını içeren yapılandırılmış bir veri tabanıdır. Her hastadan sol ve sağ göz görüntüsü alınmıştır ve toplamda 10.000 görüntü bulunmakta olup sağlıklı, katarakt, diyabet, glokom, amd, hipertansiyon, miyopi ve diğer hastalıklar olmak üzere sekiz göz hastalığı kategorisine göre etiketlenmiştir [15].

IOSTAR (Idiopathic Optic Nerve Head Swelling): IOSTAR, 30 adet 1024×1024 piksel çözünürlüğünde OCT görüntüsünden oluşan bir veri tabanıdır [16]. Görüntüler, retina damar segmentasyonu ve optik sinir başı analizi için anotasyonlanmıştır. Her görüntüde damar yapıları, arter/ven oranı ve optik disk bölgeleri etiketlenmiştir.

VAMPIRE (Vessel Assessment and Measurement Platform for Images of the Retina): VAMPIRE, retina damar özelliklerini ölçmek için kullanılan bir yazılım platformudur. Bu platform, damar genişliği, dallanma katsayısı gibi özellikleri ölçmektedir. Toplamda 210 retina görüntüsü üzerinde 2.310 ölçüm yapılmıştır [17].

EYEPACS-Kaggle: DR tespiti için kullanılan geniş bir fundus görüntü veri setidir. Toplamda 35.126 görüntü içerir ve 0 – No DR, 1 – Mild DR, 2 – Moderate DR, 3 – Severe DR ve 4 – Proliferative DR olmak üzere beş sınıfa ayrılmıştır [18].

Tablo 1. Hastalık Tespitinde Kullanılan Veri Tabanları

Veri Tabanı	Görüntü Sayısı	Hastalık/Kategori	Kullanım Alanı
DRIVE [7]	40 fundus görüntüsü	Damar yapısı	Retina damar segmentasyonu, damar yoğunluğu analizi, otomatik vasküler yapı çıkarımı
STARE [8]	400 fundus görüntüsü (40'ı detaylı anotasyonlu)	Damar segmentasyonu, arter/ven etiketleri	Retina damar segmentasyonu, optik sinir başı analizi, patoloji tespiti
CHASE_DB1 [9]	28 yüksek çözünürlüklü fundus görüntüsü	Çocuk retinal damar yapısı	Damar kıvrımlılığı analizi, kardiyovasküler risk faktörleri çalışmaları
DRIONS-DB [10]	110 fundus görüntüsü	Optik disk	Optik disk segmentasyonu, glokom tespiti
MESSIDOR [11]	1.200+ fundus görüntüsü	DR evreleri	DR tespiti, model eğitimi ve validasyonu
APTOS [12]	3.662 fundus görüntüsü	ICDR sınıflandırması (5 sınıf)	DR analizi, model geliştirme
OCT-2017	84.452 OCT	Normal, CNV, DME,	Çok sınıflı retina hastalık tespiti, derin

[13] Retinal OCT-C8	görüntüsü Yüksek çözünürlüklü OCT	Drusen Çeşitli retinal patolojiler	öđrenme modelleri için kıyaslama Retina hastalıklarının tanısı ve deđerlendirilmesi
[14] ODIR [15]	görüntüleri 10.000 fundus görüntüsü	8 göz hastalığı (Sađlıklı, Katarakt, Glokom, AMD, Hipertansiyon, Miyopi, Retinopati)	Derin öđrenme tabanlı sınıflandırma ve analiz
IOSTAR [16] VAMPIRE [17]	30 OCT görüntüsü 210 retina görüntüsü	Retina damarları ve optik sinir başı Damar genişliđi, tortuožite, dallanma katsayısı	Damar segmentasyonu, optik sinir başı analizi Retina damar morfolojisi analizi, kardiyovasküler risk çalıřmaları
EYEPACS- Kaggle [18]	35.126 fundus görüntüsü	0-4 DR evreleri	DR sınıflandırması, model eđitimi ve validasyonu

4. Literatür İncelemesi

Bu bölümde, göz hastalıklarının otomatik tanısı için son yıllarda geliştirilen derin öđrenme tabanlı yaklaşımlar, kullanılan görüntüleme modalitelerine göre sistematik bir şekilde incelenmektedir. Çalıřmaların çođu CNN mimarilerini ve transfer öđrenme tekniklerini kullanarak yüksek dođruluk oranları elde etmiştir. İnceleme, OCT görüntüleri ve Fundus görüntüleri kullanan çalıřmalar olarak iki ana başlıkta sunulmaktadır.

4.1. OCT görüntüleri kullanılarak yapılan çalıřmalar

Mohamed Elkholy ve arkadaşları [19], göz hastalıklarının erken teşhisi için retinal görüntülerden yararlanan bir derin öđrenme algoritması geliřtirmişlerdir. Bu çalıřmada OCT görüntüleri kullanılmış ve CNN modeli uygulanmıştır. Model, görüntülerden çıkarılan özellikleri kullanarak verileri dört farklı kategoriye ayırmıştır. Çalıřmanın temel amacı, kalıcı görme kaybına yol açabilen DME, Koroidal Neovasküler Membranlar (CNV) ve AMD belirtilerini yüksek dođrulukla tespit ederek erken müdahaleye olanak sağlamaktır. Elde edilen sonuçlar, yöntemin söz konusu hastalıkların sınıflandırılmasında oldukça başarılı olduđunu ortaya koymaktadır.

Puneet ve arkadaşları [20], Derin CNN ve transfer öđrenme yöntemlerini kullanarak OCT görüntülerinden CNV, DME ve Drusen gibi göz hastalıklarını sınıflandırmışlardır. Önerilen model, eđitim ve test verilerinde sırasıyla %97,79 ve %95,6 dođruluk oranı elde etmiştir. Bu yüksek başarı, DR taramalarında derin öđrenme tabanlı yaklaşımların etkin ve güvenilir bir çözüm sunduđunu göstermektedir.

Jongwoo Kim ve arkadaşları [21], OCT görüntülerinden retina hastalıklarının otomatik sınıflandırılmasına yönelik derin öđrenme tabanlı bir yöntem geliřtirmişlerdir. Çalıřmada, görüntüler CNV, DME, Drusen ve Normal olmak üzere dört sınıfa ayrılmıştır. İki farklı yaklaşım önerilmiştir: üç ikili CNN sınıflandırıcı ve dört ikili CNN sınıflandırıcı. VGG16, VGG19, ResNet50, ResNet152, DenseNet121 ve InceptionV3 gibi CNN mimarileri, ikili sınıflandırıcılar için özellik çıkarıcı olarak kullanılmıştır. En yüksek performans; CNV ve DME için VGG16, Drusen için VGG19, Normal sınıf için ise InceptionV3 ile elde edilmiştir. Model, %98,7 dođruluk, %98,7 duyarlılık ve %0,996 özgüllük oranlarına ulaşmıştır. Özellikle Normal sınıfı için %99,9 dođruluk oranı, yöntemin oftalmologlar için ikinci bir okuyucu olarak kullanılabileceđini göstermektedir.

Esra Hassan ve arkadaşları [22], OCT görüntülerinin otomatik sınıflandırılması için geliştirilmiş bir EOCT modeli önermişlerdir. Çalıřmada, modifiye edilmiş ResNet-50 ile Rastgele Orman AMD algoritması birleřtirilmiş ve Adam optimizasyon yöntemi ile modelin eđitimi gerçekleştirilmiştir. Bu yaklaşım, yaygın olarak kullanılan önceden eđitilmiş modellerle karşılaştırıldıđında verimliliđi artırmıştır. Deneysel sonuçlara göre model, duyarlılık, özgüllük ve kesinlik açısından sırasıyla 0,9836, 0,9615 ve 0,9740 deđerlerini elde etmiştir. Bu bulgular, EOCT modelinin OCT tabanlı retina hastalığı

sınıflandırmalarında yüksek doğruluk ve güvenilirlik sunduğunu ortaya koymaktadır.

Awais Khan ve arkadaşları [23], OCT görüntülerinden retina hastalıklarının otomatik tespiti ve sınıflandırılması için derin öğrenme tabanlı bir yöntem geliştirmişlerdir. Hedeflenen hastalıklar arasında AMD, Dal Retinal Ven Tıkanıklığı (Branch retinal vein occlusion, BRVO), Santral Retinal Ven Tıkanıklığı (Central retinal vein occlusion, CRVO), Santral Seröz Koryoretinopati (Central serous chorioretinopathy, CSC) ve DME yer almaktadır. Önerilen yöntem dört aşamadan oluşmaktadır: öncelikle DenseNet-201, InceptionV3 ve ResNet-50 gibi önceden eğitilmiş modeller veri setine uyarlanmış ve transfer öğrenme ile özellik çıkarımı yapılmıştır. Daha sonra çıkarılan özellikler işlenmiş ve en uygun özellikler Karınca Koloni Optimizasyonu (ACO) yöntemiyle seçilmiştir. Son aşamada, seçilen özellikler k-En Yakın Komşu (k-nearest neighbour, k-NN) ve Destek Vektör Makineleri (Support vector machines, SVM) ile sınıflandırılmıştır. Soonchunhyang Üniversitesi Bucheon Hastanesi'nden elde edilen OCT görüntülerinde, ACO kullanıldığında %99,1, ACO kullanılmadığında ise %97,4 doğruluk oranı elde edilmiştir. Bu sonuçlar, yöntemin mevcut tekniklere kıyasla daha üstün bir doğruluk ve performans sunduğunu göstermektedir.

Tahira Nazir ve arkadaşları [24], DR ve DME lezyonlarının otomatik tespiti ve sınıflandırılması için yeni bir yaklaşım önermişlerdir. Çalışma iki temel aşamadan oluşmaktadır: veri seti hazırlığı ve özellik çıkarımı ile özel olarak geliştirilmiş bir CenterNet tabanlı modelin eğitimi. İlk aşamada şüpheli bölgeler anotasyonlarla belirlenmiş, ardından DenseNet-100 kullanılarak özellik çıkarımı yapılmıştır. Daha sonra, CenterNet mimarisi ile lezyonlar hem lokalize edilmiş hem de sınıflandırılmıştır. Yöntem, APTOS-2019 ve IDRiD veri setlerinde sırasıyla %97,93 ve %98,10 doğruluk sağlamıştır. Ayrıca EYEPACS ve Diaretdb1 veri setleri üzerinde çapraz doğrulama yapılmıştır. Elde edilen nicel ve nitel bulgular, CenterNet'in küçük lezyonları tespit etme ve aşırı öğrenmeye karşı dirençli olma özellikleri sayesinde mevcut yöntemlerden daha üstün bir performans sunduğunu göstermektedir. Bu bağlamda, önerilen yaklaşım DR ve DME lezyonlarının doğru ve güvenilir biçimde sınıflandırılmasına katkı sağlamaktadır.

eifedine Kadry ve arkadaşları [25], AMD otomatik tespiti için derin öğrenme tabanlı bir sistem geliştirmişlerdir. Yöntem, derin ve el ile tasarlanmış özelliklerin ardışık biçimde birleştirilmesini içermektedir. Süreç; veri ön işleme, VGG16 ile derin özellik çıkarımı, Local Binary Pattern (LBP), Pyramid Histogram of Oriented Gradients (PHOG) ve Discrete Wavelet Transform (DWT) gibi el ile tasarlanmış özelliklerin çıkarımı, Mayfly Algoritması ile en uygun özelliklerin seçimi ve özelliklerin ikili sınıflandırıcıya aktarılması aşamalarını kapsamaktadır. Test görüntülerinden çıkarılan el ile tasarlanmış özellikler, VGG16'dan elde edilen derin özelliklerle birleştirilmiş ve sistem hem fundus retinal görüntüler hem de OCT görüntüleri üzerinde değerlendirilmiştir. Beş katlı çapraz doğrulama ile yapılan sınıflandırmada doğruluk oranları fundus görüntüleri için %97,08, OCT görüntüleri için ise %97,50 olarak bulunmuş; ayrıca VGG19, ResNet50 ve AlexNet ile karşılaştırılmıştır. Sonuçlar, önerilen yaklaşımın AMD tespitinde yüksek doğruluk sağladığını ortaya koymaktadır.

Akash Tayal ve arkadaşları [26], yapay zekâ tabanlı bir derin öğrenme çerçevesi kullanarak OCT görüntülerinden dört sınıflı göz hastalığı sınıflandırması için bir tanı sistemi geliştirmişlerdir. Model, DME, drusen, CNV ve normal durumları otomatik olarak tespit etmektedir. Çerçeve, retina OCT görüntüleri ön işleme tabi tutulmuş; gürültü azaltma, kontrast artırma, kontur tabanlı kenar çıkarımı ve retina katmanlarının segmentasyonu gerçekleştirilmiştir. Elde edilen veri, beş, yedi ve dokuz katmanlı üç farklı CNN modeli ile analiz edilmiş ve retinal katmanlardan yararlı bilgiler çıkarılarak göz deformiteleri tahmin edilmiştir. Deneysel sonuçlar, modelin manuel oftalmolojik tanımlarla karşılaştırıldığında %0,965 doğruluk, %0,960 duyarlılık ve %0,986 özgüllük oranlarına ulaştığını göstermektedir.

Pawan Kumar Upadhyay ve arkadaşları [27], OCT görüntülerinden CNV, DME, drusen ve normal durumların sınıflandırılması için CNN tabanlı bir yöntem önermişlerdir. Model, üç temel soruna çözüm getirmektedir: (1) her retinal hastalık sınıfına özgü düzensiz örüntülerin daha derin tespiti, (2) ağın giriş ve çıkışları arasındaki tutarlılığın korunması ve (3) ağ katmanlarının uyumlu biçimde birleştirilerek görüntü özelliklerinin akışının kolaylaştırılması. Beş katmanlı CNN mimarisi üzerine kurulan modelde, her aktivasyon katmanının ardından batch normalizasyon uygulanmıştır. Önerilen

yaklaşım, retinal hastalık tespitinde %97,19 doğruluk sağlamış ve standart yöntemlerle karşılaştırıldığında daha üstün performans göstermiştir. Bu sistem, klinik alanda oftalmolojik tanı süreçlerine anlamlı katkılar sunabilecek potansiyele sahiptir.

P. Glaret Subin ve arkadaşları [28], AMD, katarakt, DR ve glokom gibi yaşa bađlı göz hastalıklarının erken dönemde tespitine odaklanmışlardır. Çalışmada, çevrimiçi veri setlerinden elde edilen fundus görüntüleri maksimum entropi dönüşümü ile ön işleme tabi tutulmuş ve CNN'e aktarılmıştır. Özellik çıkarımı ve ađ hiperparametrelerinin optimizasyonu için Çiçek Tozlaşma Optimizasyon Algoritması (FPOA) uygulanmış, böylece doğruluk ve işlem hızı artırılmıştır. CNN çıktıları, hastalık sınıflandırması için Çok Sınıflı Destek Vektör Makinesi'ne (MSVM) iletilmiştir. Önerilen Çoklu Hastalık Tespit Sistemi (CNN-MDD), Ocular Disease Intelligent Recognition (ODIR) veri setinde test edilmiş ve %98,30 kesinlik, %95,27 doğruluk, %95,21 özgüllük, %93,3 duyarlılık ve yüksek F1 skoru elde etmiştir. Bu bulgular, yöntemin göz hastalıklarının otomatik tespiti ve erken tanısında klinisyenlere önemli ölçüde destek olabileceđini göstermektedir.

Umer Sadiq Khan ve arkadaşları [29], DR başta olmak üzere dört farklı retinal hastalığın OCT görüntülerinden sınıflandırılması için hibrit bir öğrenme modeli geliştirmişlerdir. Model, ResNet50 ve EfficientNetB0 mimarilerinin güçlü yönlerini birleştirmekte; öncelikle ImageNet üzerinde ön eğitimden geçirilip daha sonra halka açık OCT veri setleri üzerinde ince ayar yapılmaktadır. Bu yaklaşım, karmaşık görüntü örüntülerinin ayırt edilmesini ve farklı bölgelerden hiyerarşik tahmin çıkarılmasını mümkün kılmaktadır. Aşırı öğrenmeyi önlemek amacıyla temel modelin tam bađlı katmanı çıkarılmış ve iki öğrenme tahminini birleştiren bir concatenate katmanı eklenmiştir. Toplam 84.452 OCT görüntüsünden oluşan veri seti üzerinde yapılan değerlendirmelerde %97,50 genel doğruluk elde edilmiştir. Ayrıca modelin yorumlanabilirliğinin sağlanması, klinik uygulamalarda retinal hastalıkların tanısında yüksek doğruluk ve verimlilikle kullanılabilmesini göstermektedir.

Gauri Naik ve arkadaşları [30], OCT görüntülerinden göz hastalıklarının etkin tespiti için yeni bir yöntem geliştirmişlerdir. Bu yöntem, hastaları normal ya da CNV, DME, DR ve drusen gibi spesifik durumlara sahip olarak sınıflandırmaktadır. Ayrıca, makine öğrenmesi ve derin öğrenme tekniklerini kullanan uçtan uca bir web uygulaması da geliştirilmiştir. Hastalar ham OCT görüntülerini sisteme yüklemekte; bu görüntüler, özel olarak eğitilmiş bir U-Net modeli ile segmentasyona tabi tutulmaktadır. Segment edilen görüntüler, InceptionV3 ve Xception ağlarından oluşan ve self-attention katmanı ile güçlendirilmiş bir ansambl modele aktarılmaktadır. Self-attention mekanizması, bireysel modellerin özellik haritalarını kullanarak sınıflandırma doğruluđunu artırmaktadır. Ansambl modelin çıktılarının birleştirilmesiyle göz hastalıkları tahmin ve sınıflandırması yapılmış; gerçekleştirilen deneyler ve optimizasyonlar, yöntemin yüksek doğrulukla hastalık tespitinde etkin olduđunu göstermiştir.

Kalla Bharath Vardhan ve arkadaşları [31], DR, katarakt ve glokom gibi erken dönemde belirti göstermeyen göz hastalıklarının otomatik tespiti için derin öğrenme tabanlı yöntemleri incelemişlerdir. Erken tanı, görme kaybının önlenmesi ve iyileşme oranının artırılması açısından kritik öneme sahiptir. Geleneksel yöntemler zaman alıcı olup uzmanlık gerektirirken, derin öğrenme algoritmaları göz görüntülerinden hastalığa işaret eden özellikleri otomatik olarak öğrenme avantajı sunmaktadır. Veri ve hesaplama gereksinimlerini azaltmak amacıyla çalışmada transfer öğrenme teknikleri ile VGG19, InceptionV3 ve ResNet50 mimarileri kullanılmıştır. Sonuçlar, bu modellerin sırasıyla %90,33, %89,8 ve %99,94 doğruluk sağladığını ortaya koymuştur. Ayrıca VGG19 için kesinlik, duyarlılık ve F1 skoru sırasıyla %79,17, %79,17 ve %78,21; InceptionV3 için %82,56, %82,38 ve %82,11; ResNet50 için ise %96,28, %96,2 ve %96,24 olarak kaydedilmiştir. Bulgular, transfer öğrenme ile desteklenen CNN modellerinin özgün CNN mimarilerine göre daha yüksek performans sunduđunu göstermektedir.

Shreemat Kumar Dash ve arkadaşları [32], glokom, DR, katarakt, ambliyopi ve makula dejenerasyonu gibi farklı göz hastalıklarının otomatik tanısında derin öğrenme uygulamalarını inceleyen 99 güncel çalışmayı kapsamlı bir şekilde analiz etmişlerdir. Bu inceleme, CNN, Tekrarlayan Sinir Ağları (RNN) ve hibrit modellerin yanı sıra fundus fotoğrafçılığı, OCT ve görme alanı testleri gibi farklı görüntüleme yöntemlerini ele almıştır. Derin öğrenmenin oftalmolojik tanıya getirdiđi yenilikler;

doğruluk, verimlilik ve erişilebilirlikte önemli artışlar sağlamış ve klinik süreçlerde devrim niteliğinde gelişmelere öncülük etmiştir.

Sara El-Ateif ve arkadaşları [33], VGG19, DenseNet121, InceptionV3, InceptionResNetV2, Xception, ResNet50V2 ve MobileNetV2 gibi yedi CNN mimarisini göz hastalıklarının sınıflandırılmasında karşılaştırmışlardır. Üç farklı veri kümesi (DHS, FFA, Macula) üzerinde yapılan deneylerde DenseNet121 (%99,57) ve ResNet50V2 (%99,51) en başarılı tekli modalite modelleri olmuştur. Ayrıca geç füzyon yöntemleri tekli modellere kıyasla daha yüksek doğruluk sağlamış; özellikle ResNet50V2 geç füzyon modeli tüm veri kümelerinde %100 doğruluk ile en yüksek performansı göstermiştir.

Neetha George ve arkadaşları [34], OCT görüntülerinden retina ve koroid hastalıklarını sınıflandırmak ve şiddetini belirlemek için iki aşamalı CNN tabanlı bir model geliştirmişlerdir. İlk aşamada sağlıklı, drusen, pachychoroid ve makula ödemi sınıfları ayırt edilmiştir. İkinci aşamada ise pachychoroid hastalıklarının şiddeti ve makula ödeminin derecesi analiz edilmiştir. VGG16 ve U-Net tabanlı hibrit yaklaşım, insan uzmanların değerlendirmeleriyle kıyaslanabilir düzeyde başarılı sonuçlar ortaya koymuştur.

Guilherme Aresta ve arkadaşları [35], tarama programlarında ve geniş retrospektif çalışmalarda normal gözlerden farklı patolojik bulgulara sahip OCT hacimlerini tanımlamaya yönelik genel amaçlı bir yapay zekâ sistemi geliştirmişlerdir. Model yalnızca normal vakalarla eğitilmiş, test aşamasında ise anomali skoru ve bölgesel anomali haritaları üretmiştir. 3358 hasta ve ek harici veri setleri üzerinde yapılan testlerde, model hacim bazında 0,94 AUC, harici setlerde ise 0,81–0,87 AUC performansı göstermiştir. Bu sonuçlar, modelin DME ve AMD evreleri gibi farklı patolojilerde güvenilir ve tutarlı çıktılar üretebildiğini kanıtlamaktadır.

D. Arul Pon Daniel ve arkadaşları [36], 775 hastadan elde edilen 37.138 OCT görüntüsü üzerinde geliştirdikleri derin öğrenme modellerini test etmişlerdir. Modeller, ikili sınıflandırmada %98'in üzerinde doğruluk, duyarlılık, özgüllük ve F1 skoru sağlamış; çok sınıflı sınıflandırmada ise AMD ve vitreomaküler traksiyon sendromunu yüksek başarıyla tespit etmiştir. Ayrıca lezyonların konumlandırılmasında %87–98 aralığında doğruluk elde edilmiş, bu da modellerin klinisyenlere güçlü bir tanısal destek sunabileceğini göstermektedir.

Alina Mushtaq ve arkadaşları [37], göz hastalıklarının tanınmasında derin öğrenme tabanlı InceptionV3 mimarisini kullanarak etkili ve pratik bir tanı aracı geliştirmişlerdir. Model, retina görüntülerinden kritik bilgileri yakalayarak yüksek doğrulukta hastalık tespiti sağlamış ve bazı durumlarda uzman hekimlerden daha iyi performans göstermiştir. Ayrıca yöntemin düşük maliyetli, ölçeklenebilir ve erken tanı imkânı sunarak sağlık hizmetlerindeki eşitsizlikleri azaltma potansiyeli vurgulanmaktadır.

Bazı çalışmalara ait özet bilgiler Tablo 2 ile sunulmuştur.

Tablo 2. OCT görüntüler kullanarak yapılan çalışmalar

Çalışma	Yöntem	Kategoriler	Doğruluk (%)
Elkholy ve ekibi [19]	CNN	DME, CNV, AMD	97
Puneet ve ekibi [20]	Deep CNN, Transfer Öğrenme	CNV, DME, Drusen	95,60
Kim ve ekibi [21]	CNN (VGG16, ResNet, InceptionV3 vb.)	CNV, DME, Drusen, Normal	98,70
Khan ve ekibi [23]	DenseNet, InceptionV3, ResNet-50 + ACO + k-NN/SVM	AMD, BRVO, CRVO, CSC, DME	99,10
Nazir ve ekibi [25]	CenterNet	DR, DME	97,93
Subin ve ekibi [28]	CNN-MDD	AMD, katarakt, DR, glokom	95,27

4.2. Fundus görüntüleri kullanılarak yapılan çalışmalar

Shumoos Al-Fahdawi ve arkadaşları [38], Fundus-DeepNet adını verdikleri çoklu etiketli derin öğrenme sistemini geliştirmiş ve sekiz farklı göz hastalığını yüksek doğrulukla sınıflandırmıştır. Model, ileri seviye ön işleme teknikleri ile HRNet, Attention Block ve SENet Block gibi güçlü mimarileri birleştirmiş; sınıflandırma aşamasında DRBM ve Softmax kullanarak OIA-ODIR veri setinde %92'nin üzerinde başarı elde etmiştir.

Glokom tespitine yönelik çalışmada Murali Govindan ve arkadaşları [39], CNN tabanlı hibrit bir model önermiştir. ResNet50 ve InceptionV3'ün birleşiminden oluşan yöntem, ORIGA, STARE ve REFUGE veri setlerinde oldukça yüksek F1 skorları elde ederek klinik kullanım potansiyelini ortaya koymuştur.

Veri seti geliştirmeye odaklanan Shayla Sharmin ve arkadaşları [40], sekiz ay boyunca iki göz hastanesinden 5335 fundus ve ön segment görüntüsü toplamış ve dokuz farklı sınıfa ayrılan kapsamlı bir veri tabanı sunmuştur. Bu kaynak, otomatik sınıflandırma sistemlerinin geliştirilmesinde araştırmacılara önemli katkı sağlamaktadır.

Sayyid Kamran Hussain ve arkadaşları [41], göz hastalıklarının sınıflandırılması için CNN tabanlı yeni bir model ve özel kayıp fonksiyonları önermişlerdir. Model; evrişim katmanı, global ortalama havuzlama ve tam bağlı katmandan oluşmakta olup, RFCI görüntüleri (299×299×3) üzerinde düşük seviye özellikleri (örneğin kenarlar ve eğriler) etkili bir şekilde yakalayabilmektedir. Önerilen yöntem, DenseNet-169, EfficientNet-B7, ResNet-101, Inception-V3 ve VGG-19 gibi temel modellerle karşılaştırılmış ve üçlü çapraz doğrulama testlerinde özellikle Katarakt, AMD ve Glokom sınıflarında yüksek sınıflandırma başarısı elde etmiştir.

Qing-Qing Tang ve arkadaşları [42], ultra geniş alan fundus görüntülerinde derin öğrenme uygulamalarını inceleyerek avantajlarını, sınırlılıklarını ve olası çözümleri özetlemişlerdir. Literatür taraması sonucunda 4358 makale arasından 23 çalışma seçilmiş ve analiz edilmiştir. Bulgular, derin öğrenmenin DR, glokom, AMD, retina ven tıkanmaları, retina dekolmanı ve diğer periferik retina hastalıklarını yüksek doğrulukla tespit edebildiğini göstermektedir. Ultra geniş alan fundus taramaları, tek pozlamada 200° retina görüntüsü sağlayarak fundus fotoğraflarına kıyasla daha geniş bir retinal alanın gözlemlenmesine imkân tanımaktadır.

Yovel Rom ve arkadaşları [43], DR göstergesi olmadan diyabet tespit edebilen bir yapay zeka modeli geliştirilmişlerdir. EyePACS veri setindeki 47.076 fundus görüntüsü üzerinde eğitilen model, hastaları hastalık sürelerine göre kohortlara ayırarak analiz etmiştir. Model, hasta başına AUC değeri 0,86 ve görüntü başına 0,83 elde ederek diyabeti non-invaziv olarak başarıyla tespit etmiştir. Bu yöntem, diyabetin erken dönemde ve kolay erişilebilir ortamlarda teşhis edilmesine imkân tanıyarak, henüz teşhis edilmemiş birçok hastanın saptanmasına katkı sağlamaktadır.

Rakesh Chandra Joshi ve arkadaşları [44], retina damar segmentasyonu ve çok sınıflı fundus sınıflandırması için VisionDeep-AI adlı kapsamlı bir derin öğrenme çerçevesi geliştirmişlerdir. Model, U-Net tabanlı çift yönlü özellik piramit ağı kullanarak damarları yüksek doğrulukla (%97,73) segmentlemiş ve çok ölçekli özellik füzyonu ile dört sınıflı sınıflandırmada %81,50 test doğruluğu ve %93,83 özgüllük sağlamıştır. Veri artırımıyla aşırı uyum önlenmiş ve genelleme yeteneği artırılmıştır. Elde edilen sonuçlar, VisionDeep-AI'nin fundus görüntü analizi ve retina hastalıklarının sınıflandırılması için güçlü, güvenilir ve verimli bir araç olduğunu göstermektedir.

Rajeshwar Patil ve arkadaşları [45], glokom tanısı için otomatik bir derin öğrenme yöntemi önermişlerdir. Kaggle'daki glakom veri setleri üzerinde yapılan deneylerde, transfer learning tabanlı önceden eğitilmiş modeller (DenseNet169, MobileNet, InceptionV3, Xception, ResNet152V2, VGG19) kullanılmıştır. En iyi performans DenseNet169 modeli ile elde edilmiş olup, doğruluk 0,9936, precision 0,9937 ve recall 0,9936 olarak ölçülmüştür. Sonuçlar, önerilen modelin mevcut çalışmalara kıyasla daha yüksek doğruluk sağladığını göstermektedir.

Rajneesh Kumar Patel ve arkadaşları [46], glokom tanısı için otomatik ve etkili bir yöntem önermişlerdir. Fundus görüntüleri kırmızı, yeşil ve mavi kanallara ayrılmış ve yeşil kanal işleme için

seçilmiştir. Bu kanal, Flexible Analytical Wavelet Transform (FAWT) ile alt bantlara ayrılmış, ardından modifiye Gauss-Kuzmin tabanlı Gabor (GKDG) filtresi ve NCA ile özellik çıkarımı ve boyut indirgeme yapılmıştır. Elde edilen özellikler student t-değeri ile derecelendirilmiş ve LS-SVM sınıflayıcı (linear, gradient descent, Morlet ve Mexican-hat kernel) ile glakom sınıflandırması gerçekleştirilmiştir. On katlı çapraz doğrulama sonucunda model, doğruluk %95,84, özgülük %97,17 ve duyarlılık %94,55 ile mevcut yöntemlere kıyasla üstün performans göstermiştir.

Satyabrata Lenka ve arkadaşları [47], glokom tespiti ve fundus görüntüsü segmentasyonu için çok görevli (multi-task) derin öğrenme tabanlı bir model geliştirmişlerdir. Model, hem optik disk(OD) ve optik cup (OC) segmentasyonu hem de glokom sınıflandırması görevlerini eş zamanlı olarak öğrenmektedir. Önerilen model, encoder kısmında MobileNetV2, decoder kısmında Graph Convolution Network (GCN) ve ROI odaklı özellik çıkarımı için dikkat modülü (AM) içeren modifiye edilmiş bir U-Net mimarisi kullanmaktadır. Çalışma, ORIGA, REFUGE ve DRISTI-GS veri setleri üzerinde uygulanmış ve mevcut yöntemlerle karşılaştırılmıştır. Sonuçlar, glokom tespiti için %97,43 doğruluk ve 0,985 AUROC, segmentasyon için ise OD ve OC'de sırasıyla %97,95 ve %96,11 dice katsayısı elde ederek yüksek performans göstermiştir. Bu model, hem doğru glokom sınıflandırması hem de kaliteli retina yapı segmentasyonu sağlamaktadır.

P. Rayavel ve arkadaşları [48], DR tespiti ve sınıflandırması için DCDR-RFI-DSQN-PRO yöntemini önermiştir. Bu yöntem, EyePACS fundus görüntüleri kullanılarak gerçekleştirilmiş olup, ön işleme aşamasında Regularized Bias-Aware Ensemble Kalman Filter (RBAEKF) ile görüntü kalitesi artırılmış ve gürültü azaltılmıştır. Özellik çıkarımı aşamasında, gri seviye istatistiksel özellikler ve doku özellikleri Time-Frequency Synchroextracting Transform (TFSET) yöntemi ile elde edilmiştir. Çıkarılan bu özellikler, Deep Spiking Q Network (DSQN) aracılığıyla DR'yi No DR, Mild, Moderate, Severe ve PDR olmak üzere sınıflandırmak için kullanılmıştır. DSQN'nin parametre optimizasyonunu iyileştirmek amacıyla Partial Reinforcement Optimizer (PRO) uygulanmıştır. Sonuçlar, önerilen yöntemin mevcut modellere kıyasla F1-skorunda %20'den fazla, ROC değerinde %10-26, özgülükte %11-26 ve hassasiyette %20'den fazla iyileşme sağladığını göstermektedir. Böylece, yöntem DR tespitinde ve sınıflandırmasında daha yüksek doğruluk ve güvenilirlik sunmaktadır.

Mohammad Mahdi Aghabeigi Alooghareh ve arkadaşları [49], retinanın hem göz hem de sistemik hastalıkların belirlenmesinde bir biyobelirteç olma özelliğinden hareketle, yapay zekâ tabanlı tarama ve risk değerlendirme araçlarını incelemiştir. Çalışmada BRSET veri kümesi kullanılarak altı farklı ileri düzey derin öğrenme modeli, CNN ve Vision Transformer mimarileriyle değerlendirilmiştir. Modellerin performansı, precision, recall, F1-score, accuracy ve AUC metrikleri üzerinden ölçülmüştür. Sonuçlar, özellikle Swin-L modeli için yüksek performans göstermiştir. Ayrıca, gradient tabanlı saliency haritaları ile karar mekanizmaları görselleştirilerek yorumlanabilirlik artırılmıştır. Bulgular, derin öğrenme ve özellikle Vision Transformer mimarilerinin retina ve sistemik hastalıkların doğru, yorumlanabilir ve klinik açıdan anlamlı tarama araçları geliştirilmesinde yüksek potansiyele sahip olduğunu ortaya koymuştur.

Shajila Beegam ve arkadaşları [50], DR, katarakt ve glokom gibi göz hastalıklarının erken ve doğru tespiti için CNN tabanlı çok sınıflı bir sınıflandırma yöntemi önermiştir. Geliştirilen 9 katmanlı CNN modeli, fundus görüntülerinden normal ve patolojik özellikleri otomatik olarak ayırt edebilmektedir. Modelin performansını artırmak amacıyla ön işleme teknikleri ve hiperparametre optimizasyonu uygulanmıştır. Farklı öğrenme oranı ve batch boyutlarıyla test edilen model, %89-96 arasında test doğruluğu ve neredeyse %100 eğitim doğruluğu elde etmiştir. Sonuç olarak, önerilen CNN modeli göz hastalıklarının tanısında hekimlere hızlı ve doğru destek sağlayacak güçlü bir araç olarak öne çıkmaktadır.

E. Priya ve arkadaşları [51], DR, glokom, katarakt ve AMD gibi görme kaybına yol açabilen hastalıkların fundus görüntülerinden otomatik tespiti için bir sistem geliştirmeyi amaçlamıştır. Sistem, Kaggle, EyePACS ve Messidor gibi açık kaynaklardan toplanan etiketli görüntüler ile eğitilmiştir. Görseller, yeniden boyutlandırma, kontrast artırma ve temel dönüşümler gibi ön işlemlerden geçirilmiştir. Model, yerel bir CNN ile transfer öğrenmeye dayalı ResNet50 mimarisini bir arada kullanmaktadır. Görüntülerden önemli özellikleri kademeli olarak çıkarırken, aşırı öğrenmeyi

önlemek için stabilite artırıcı yöntemler de uygulanmıştır. Ayrıca sistem, Django framework kullanılarak geliştirilen web tabanlı bir arayüz ile kullanıcıya gerçek zamanlı tanısai geri bildirim sunmaktadır.

Sara Ejaz ve arkadaşları [52], retina görüntülerinden göz hastalıklarını erken tespit etmek amacıyla derin öğrenme tabanlı bir yöntem geliştirmiştir. Çalışmada amaç, CNN tabanlı hibrit bir model kullanarak non-invaziv biçimde retina hastalıklarını sınıflandırmaktır. RFMiD veri seti kullanılmış ve performansı artırmak için veri artırma, yeniden boyutlandırma, kırma ve one-hot encoding gibi ön işleme yöntemleri uygulanmıştır. Model, iki ayrı CNN blođu aracılığıyla derin özellikler çıkarmakta ve bu özellikler Canonical Correlation Analysis (CCA) yöntemiyle birleştirilmektedir. Modelin etkinliğini test etmek için sekiz farklı sınıflandırma algoritması kullanılmıştır. Sonuçlar, ensemble learning yönteminin %93,39 doğruluk oranı ile en iyi performansı sağladığını göstermektedir.

Bazı çalışmalara ait özet bilgiler Tablo 3 ile sunulmuştur.

Tablo 3. Fundus görüntüler kullanarak yapılan çalışmalar

Çalışma	Yöntem	Kategoriler	Dođruluk (%)
Al-Fahdawi ve ekibi [38]	Fundus-DeepNet (HRNet, Attention Block, SENet Block, DRBM/Softmax)	8 kategori	> 92
Joshi ve ekibi [44]	VisionDeep-AI (U-Net tabanlı BFP ađı)	Çok sınıflı fundus sınıflandırılması	81,50
Patil ve ekibi [45]	Transfer Öğrenme (DenseNet169, InceptionV3, VGG19 vb.)	Glokom tanısı	99,36
Patel ve ekibi [46]	LS-SVM	Glokom tanısı	95,84
Beegam ve ekibi [50]	CNN + Ön işleme + Hiperparametre Optimizasyonu	DR, katarakt, glokom	89-96

5. Bulgular

Bu bölüm, dördüncü kısımda sunulan literatür incelemesi temelinde, göz hastalıklarının tespitine yönelik derin öğrenme uygulamalarının genel eğilimlerini, elde edilen başarıları ve karşılaşılan zorlukları özetlemektedir. Analiz, mevcut yöntemlerin güçlü ve zayıf yönleri ile alandaki gelecekteki araştırmalara yön verecek bilimsel boşluklar üzerine odaklanmaktadır.

Güçlü ve Zayıf Yönler

İncelenen literatür, göz hastalıklarının erken teşhisi için derin öğrenme tabanlı yaklaşımların güçlü bir potansiyele sahip olduğunu göstermektedir. Çalışmaların çoğunda yüksek doğruluk oranları elde edilmiş, özellikle CNN ve Vision Transformer gibi derin mimarilerle görsel özelliklerin başarılı bir şekilde çıkarıldığı görülmüştür. Hibrit modellerin (CNN + CCA, ResNet + Transfer Öğrenme vb.) kullanımı, farklı özellik çıkarım yöntemlerinin birleşimi sayesinde daha dengeli ve güçlü performanslar sunmuştur.

Bununla birlikte, mevcut çalışmaların önemli bir kısmında sınırlı sayıda veri seti kullanılmış, bu da modellerin genellenebilirliğini kısıtlamaktadır. Ayrıca, bazı modeller yüksek doğruluk oranları elde etmesine rağmen aşırı öğrenme riski taşımaktadır. Klinik uygulamalara uyarlanabilirlik açısından ise modellerin yorumlanabilirlik düzeyi ve farklı hasta gruplarına karşı dayanıklılığı halen zayıf kalmaktadır.

Literatürdeki Boşluklar

Literatürde göze çarpan en önemli boşluklardan biri, geniş ve çeşitlendirilmiş veri setlerinin yetersizliğidir. Mevcut çalışmalar genellikle tek bir hastalığa odaklanmış olup, çoklu hastalıkların aynı

anda tanınmasına yönelik araştırmalar sınırlıdır. Ayrıca, mevcut modellerin büyük çoğunluğu laboratuvar koşullarında yüksek başarı elde etse de, gerçek klinik senaryolarda performanslarının test edilmediği görülmektedir. Yorumlanabilir yapay zeka yaklaşımlarının sınırlı düzeyde kullanılması da önemli bir eksikliklerdir. Bu durum, hekimlerin yapay zeka tabanlı sistemlere güvenini sınırlayabilir.

6. Tartışma ve Sonuç

Son yıllarda retinal görüntüleme ve yapay zekâ alanındaki gelişmeler, göz hastalıklarının erken teşhisinde önemli bir değişikliğine işaret etmektedir. Bu derleme makalesinde ele alınan çalışmalar, özellikle CNN ve hibrit derin öğrenme modellerinin, yaygın göz hastalıklarının tespitinde ne ölçüde etkili olabileceğini göstermektedir. Genel olarak, bu modellerin yüksek doğruluk, duyarlılık ve özgüllük değerleri, geleneksel yöntemlerle kıyaslandığında hem erken tanı hem de büyük veri setleri üzerinde ölçeklenebilirlik açısından avantaj sağladığını ortaya koymaktadır.

Sonuç olarak, derlenen literatür, derin öğrenme tabanlı yöntemlerin retinal hastalıkların erken teşhisinde umut verici bir araç olduğunu göstermektedir. Ancak, veri setlerinin çeşitlendirilmesi, modellerin yorumlana bilirliğinin artırılması ve klinik ortamda uygulanabilirliğinin test edilmesi, bu teknolojilerin geniş ölçekte benimsenmesi için kritik öneme sahiptir. Gelecekteki araştırmalar, özellikle çok merkezli ve çok modelli veri entegrasyonuna odaklanarak hem doğruluk hem de güvenilirlik açısından daha güçlü ve sürdürülebilir çözümler sunabilir.



Hakem: Dış, Bağımsız.

Teşekkür:

-

Beyanname:

1. Özgünlük Beyanı:

Bu çalışma özgündür.

2. Yazar Katkıları:

Fikir: TO,HT,FH; **Kavramsallaştırma:** TO,HT,FH; **Literatür Taraması:** HT; **Veri Toplama:** TO,HT,FH; **Veri İşleme:** TO,HT,FH; **Analiz:** TO,FH; **Yazma - orijinal taslak:** TO,HT; **Yazma - inceleme ve düzenleme:** TO,HT,FH.

3. Etik Kurul İzni:

Etik Kurul İzni gerekmemektedir.

4. Finansman/Destek:

Bu çalışma, herhangi bir finansman ya da destek almamıştır.


5. Çıkar Çatışması:

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan etmektedirler.

6. Üretken Yapay Zeka Beyanı:

Çalışmanın hiçbir safhasında yapay zeka araçlarından faydalanılmamıştır.

7. Sürdürülebilir Kalkınma Amaçları:



KAYNAKÇA

- [1] Jain, L., Murthy, H. S., Patel, C., & Bansal, D. (2018, December). Retinal eye disease detection using deep learning. In 2018 Fourteenth International Conference on Information Processing (ICINPRO) (pp. 1-6). IEEE.
- [2] Qummar, S., Khan, F. G., Shah, S., Khan, A., Shamshirband, S., Rehman, Z. U., & Jadoon, W. (2019). A deep learning ensemble approach for diabetic retinopathy detection. *Ieee Access*, 7, 150530-150539.
- [3] Rajagopalan, N., Narasimhan, V., Kunnnavakkam Vinjimoor, S., & Aiyer, J. (2021). RETRACTED ARTICLE: Deep CNN framework for retinal disease diagnosis using optical coherence tomography images. *Journal of Ambient Intelligence and Humanized Computing*, 12(7), 7569-7580.
- [4] Li, Y., Xia, X., & Paulus, Y. M. (2018, April). Advances in retinal optical imaging. In *Photonics* (Vol. 5, No. 2, p. 9). MDPI.
- [5] Yu, S., Lu, J., Cao, D., Liu, R., Liu, B., Li, T., ... & Lu, L. (2016). The role of optical coherence tomography angiography in fundus vascular abnormalities. *BMC ophthalmology*, 16(1), 107.
- [6] Chalam, K. V., & Sambhav, K. (2016). Optical coherence tomography angiography in retinal diseases. *Journal of ophthalmic & vision research*, 11(1), 84.
- [7] Staal, J., Abràmoff, M. D., Niemeijer, M., Viergever, M. A., & Van Ginneken, B. (2004). Ridge-based vessel segmentation in color images of the retina. *IEEE transactions on medical imaging*, 23(4), 501-509.
- [8] Hoover, A. D., Kouznetsova, V., & Goldbaum, M. (2000). Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. *IEEE Transactions on Medical imaging*, 19(3), 203-210.
- [9] Jordan, K. C., Menolotto, M., Bolster, N. M., Livingstone, I. A., & Giardini, M. E. (2017). A review of feature-based retinal image analysis. *Expert Review of Ophthalmology*, 12(3), 207-220.
- [10] "DRIONS-DB Retinal Image Database — bob.db.drionsdb 1.0.1 documentation." <https://www.idiap.ch/software/bob/docs/bob/bob.db.drionsdb/master/index.html> (Eriřim Tarihi: 10.12.2024).
- [11] "Messidor - ADCIS." <http://www.adcis.net/en/third-party/messidor/> (Eriřim Tarihi: 11.09.2025).
- [12] Alyoubi, W. L., Abulkhair, M. F., & Shalash, W. M. (2021). Diabetic retinopathy fundus image classification and lesions localization system using deep learning. *Sensors*, 21(11), 3704.
- [13] Ibrahim, A., "OCT2017." <https://www.kaggle.com/datasets/namaneanasibrahim/oct2017> (Eriřim Tarihi: 15.09.2024).
- [14] Naren, O. S., "Retinal OCT Image Classification - C8. " www.kaggle.com/datasets/obulisainaren/retinal-oct-c8 (Eriřim Tarihi: 23.05.2025).
- [15] Larxel, "Ocular Disease Recognition. " <https://www.kaggle.com/datasets/andrewmvd/ocular-disease-recognition-odir5k> (Eriřim Tarihi: 03.11.2024).
- [16] Zhang, J., Dashtbozorg, B., Bekkers, E., Pluim, J. P., Duits, R., & ter Haar Romeny, B. M. (2016). Robust retinal vessel segmentation via locally adaptive derivative frames in orientation scores. *IEEE transactions on medical imaging*, 35(12), 2631-2644.
- [17] Perez-Rovira, A., MacGillivray, T., Trucco, E., Chin, K. S., Zutis, K., Lupascu, C., ... & Dhillon, B. (2011, August). VAMPIRE: Vessel assessment and measurement platform for images of the REtina. In 2011 Annual International Conference of the IEEE Engineering in Medicine and

- Biology Society (pp. 3391-3394). IEEE.
- [18] Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., ... & Webster, D. R. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, 316(22), 2402-2410.
- [19] Elkholy, M., & Marzouk, M. A. (2024). Deep learning-based classification of eye diseases using Convolutional Neural Network for OCT images. *Frontiers in Computer Science*, 5, 1252295.
- [20] Puneet, Kumar, R., & Gupta, M. (2022). Optical coherence tomography image based eye disease detection using deep convolutional neural network. *Health Information Science and Systems*, 10(1), 13.
- [21] Kim, J., & Tran, L. (2021, October). Retinal disease classification from oct images using deep learning algorithms. In *2021 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB)* (pp. 1-6). Ieee.
- [22] Hassan, E., Elmougy, S., Ibraheem, M. R., Hossain, M. S., AlMutib, K., Ghoneim, A., ... & Talaat, F. M. (2023). Enhanced deep learning model for classification of retinal optical coherence tomography images. *Sensors*, 23(12), 5393.
- [23] Khan, A., Pin, K., Aziz, A., Han, J. W., & Nam, Y. (2023). Optical coherence tomography image classification using hybrid deep learning and ant colony optimization. *Sensors*, 23(15), 6706.
- [24] Nazir, T., Nawaz, M., Rashid, J., Mahum, R., Masood, M., Mehmood, A., ... & Hussain, A. (2021). Detection of diabetic eye disease from retinal images using a deep learning based CenterNet model. *Sensors*, 21(16), 5283.
- [25] Kadry, S., Rajinikanth, V., González Crespo, R., & Verdú, E. (2022). Automated detection of age-related macular degeneration using a pre-trained deep-learning scheme. *The Journal of Supercomputing*, 78(5), 7321-7340.
- [26] Tayal, A., Gupta, J., Solanki, A., Bisht, K., Nayyar, A., & Masud, M. (2022). DL-CNN-based approach with image processing techniques for diagnosis of retinal diseases. *Multimedia systems*, 28(4), 1417-1438.
- [27] Upadhyay, P. K., Rastogi, S., & Kumar, K. V. (2022). Coherent convolution neural network based retinal disease detection using optical coherence tomographic images. *Journal of King Saud University-Computer and Information Sciences*, 34(10), 9688-9695.
- [28] Muthukannan, P. (2022). Optimized convolution neural network based multiple eye disease detection. *Computers in Biology and Medicine*, 146, 105648.
- [29] Khan, U. S., & Khan, S. U. R. (2025). Boost diagnostic performance in retinal disease classification utilizing deep ensemble classifiers based on OCT. *Multimedia Tools and Applications*, 84(19), 21227-21247.
- [30] Naik, G., Narvekar, N., Agarwal, D., Nandanwar, N., & Pande, H. (2024, March). Eye disease prediction using ensemble learning and attention on oct scans. In *Future of Information and Communication Conference* (pp. 21-36). Cham: Springer Nature Switzerland.
- [31] Vardhan, K. B., Nidhish, M., & Shameem, D. N. (2024). Eye disease detection using deep learning models with transfer learning techniques. *ICST Transactions on Scalable Information Systems*, 11, 1-13.
- [32] Dash, S. K., Sethy, P. K., Das, A., Jena, S., & Nanthaamornphong, A. (2024). Advancements in deep learning for automated diagnosis of ophthalmic diseases: a comprehensive review. *IEEE Access*.
- [33] El-Ateif, S., & Idri, A. (2024). Eye diseases diagnosis using deep learning and multimodal medical eye imaging. *Multimedia Tools and Applications*, 83(10), 30773-30818.

- [34] George, N., Shine, L., Abraham, B., & Ramachandran, S. (2024). A two-stage CNN model for the classification and severity analysis of retinal and choroidal diseases in OCT images. *International Journal of Intelligent Networks*, 5, 10-18.
- [35] Aresta, G., Araújo, T., Schmidt-Erfurth, U., & Bogunović, H. (2025). Anomaly Detection in Retinal OCT Images With Deep Learning-Based Knowledge Distillation. *Translational Vision Science & Technology*, 14(3), 26-26.
- [36] Daniel, D. A. P., Santhana Sagaya Mary, A., & Chidambaranathan, S. (2025). Deep Learning-Based Neuro Computing to Classify and Diagnosis of Ophthalmology by OCT. *Integrating Neurocomputing with Artificial Intelligence*, 159-173.
- [37] Mushtaq, A., Kumar, K. K., & Subhashini, R. (2025, July). Ocular disease recognition using deep learning. In *AIP Conference Proceedings* (Vol. 3257, No. 1, p. 020144). AIP Publishing LLC.
- [38] Al-Fahdawi, S., Al-Waisy, A. S., Zeebaree, D. Q., Qahwaji, R., Natiq, H., Mohammed, M. A., ... & Deveci, M. (2024). Fundus-deepnet: Multi-label deep learning classification system for enhanced detection of multiple ocular diseases through data fusion of fundus images. *Information Fusion*, 102, 102059.
- [39] Govindan, M., Dhakshnamurthy, V. K., Sreerangan, K., Nagarajan, M. D., & Rajamanickam, S. K. (2024). A framework for early detection of glaucoma in retinal fundus images using deep learning. *Engineering Proceedings*, 62(1), 3.
- [40] Sharmin, S., Rashid, M. R., Khatun, T., Hasan, M. Z., & Uddin, M. S. (2024). A dataset of color fundus images for the detection and classification of eye diseases. *Data in Brief*, 57, 110979.
- [41] Hussain, S. K., Ramay, S. A., Shaheer, H., Abbas, T., Mushtaq, M. A., Paracha, S., & Saeed, N. (2024). Automated classification of ophthalmic disorders using color fundus images. *Volume*, 12, 1344-1348.
- [42] Tang, Q. Q., Yang, X. G., Wang, H. Q., Wu, D. W., & Zhang, M. X. (2024). Applications of deep learning for detecting ophthalmic diseases with ultrawide-field fundus images. *International Journal of Ophthalmology*, 17(1), 188.
- [43] Rom, Y., Aviv, R., Cohen, G. Y., Friedman, Y. E., Ianchulev, T., & Dvey-Aharon, Z. (2024). Diabetes detection from non-diabetic retinopathy fundus images using deep learning methodology. *Heliyon*, 10(16).
- [44] Joshi, R. C., Sharma, A. K., & Dutta, M. K. (2024). VisionDeep-AI: Deep learning-based retinal blood vessels segmentation and multi-class classification framework for eye diagnosis. *Biomedical Signal Processing and Control*, 94, 106273.
- [45] Patil, R., & Sharma, S. (2024). Automatic glaucoma detection from fundus images using transfer learning. *Multimedia Tools and Applications*, 83(32), 78207-78226.
- [46] Patel, R. K., Chouhan, S. S., Lamkuche, H. S., & Pranjali, P. (2024). Glaucoma diagnosis from fundus images using modified Gauss-Kuzmin-distribution-based Gabor features in 2D-FAWT. *Computers and Electrical Engineering*, 119, 109538.
- [47] Lenka, S., Mayaluri, Z. L., & Panda, G. (2025). Glaucoma detection from retinal fundus images using graph convolution based multi-task model. *e-Prime-Advances in Electrical Engineering, Electronics and Energy*, 11, 100931.
- [48] Rayavel, P., Priyadharshini, S. A., Midhunadharshini, G., & Divyedharshini, G. (2025). Detection and classification of diabetic retinopathy in retinal fundus images using deep spiking Q Network optimized with partial reinforcement optimizer. *Computers in Biology and Medicine*, 196, 110863.

- [49] Aghabeigi Alooghareh, M. M., Sheikhey, M. M., Sahafi, A., Pirnejad, H., & Naemi, A. (2025). Deep Learning for Comprehensive Analysis of Retinal Fundus Images: Detection of Systemic and Ocular Conditions. *Bioengineering*, 12(8), 840.
- [50] Beegam, S., Kalra, M., Bhowmik, A., & Panda, J. K. (2025). Deep Learning Framework for Multiclass Detection of Ocular Diseases in Fundus Images.
- [51] Priya, E., Dhinesh, M., Rohitkumar, G., & Dheena, M. (2025, May). Harnessing Deep Learning Models in Fundus Imaging for Early Diagnosis in Eye Disorders. In *2025 Fourth International Conference on Smart Technologies, Communication and Robotics (STCR)* (pp. 1-5). IEEE.
- [52] Ejaz, S., Zia, H. U., Majeed, F., Shafique, U., Altamiranda, S. C., Lipari, V., & Ashraf, I. (2025). Fundus image classification using feature concatenation for early diagnosis of retinal disease. *Digital Health*, 11, 20552076251328120.

