OPTİK KOHERENS TOMOGRAFİ GÖRÜNTÜLERİNDEN YAŞA BAĞLI MAKULAR DEJENERASYON TİPLERİNİN YAPAY ZEKÂ KULLANILARAK TESPİTİ

Muhammed Akif Yenikaya
181450201

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Doktora Programı
Danışman: Dr. Öğr. Üyesi Erdal Güvenoğlu

İstanbul
T.C. Maltepe Üniversitesi
Lisansüstü Eğitim Enstitüsü
Haziran, 2022

OPTİK KOHERENS TOMOGRAFİ GÖRÜNTÜLERİNDEN YAŞA BAĞLI MAKULAR DEJENERASYON TİPLERİNİN YAPAY ZEKÂ KULLANILARAK TESPİTİ

Muhammed Akif Yenikaya
181450201
Orcid: 0000-0002-3624-722X

DOKTORA TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Doktora Programı
Danışman: Dr. Öğr. Üyesi Erdal Güvenoğlu

İstanbul
T.C. Maltepe Üniversitesi
Lisansüstü Eğitim Enstitüsü
Haziran, 2022



JÜRİ VE ENSTİTÜ ONAYI

Bu belge, Yükseköğretim Kurulu tarafından 19.01.2021 tarihli *"Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge"* ile bildirilen 6689 Sayılı Kişisel Verilerin Korunması Kanunu kapsamında gizlenmiştir.

ETİK İLKE VE KURALLARA UYUM BEYANI

Bu belge, Yükseköğretim Kurulu tarafından 19.01.2021 tarihli *"Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge"* ile bildirilen 6689 Sayılı Kişisel Verilerin Korunması Kanunu kapsamında gizlenmiştir.

TEŞEKKÜR

Bu tezi hazırlamamda bana yardımcı olan ve desteklerini her zaman hissettiğim kişi ve kurumlara bu sayfayı ayırarak teşekkür etmeyi borç bilirim. Çalışmam boyunca sunduğu ufuk açıcı kaynaklarla, bitmeyen ilgisiyle bu işi hakkıyla başaracağıma inanıp moral desteğini her zaman hissettiren ve çalışmam boyunca bana ışık tutan saygıdeğer hocam Dr. Öğr. Üyesi Erdal Güvenoğlu' na teşekkür ederim.

Donanım desteği sağlayan Kafkas Üniversitesi Uzaktan Eğitim Merkezi müdürü Prof. Dr. Erkan Tokucu hocama ve merkez çalışanlarına, verilerin sınıflandırılmasında büyük emeği geçen uzman göz hekimleri Dr. Reşadet Qurbanov ve Dr. Öğr. Üyesi Erdinç Bozkurt' a müteşekkirim.

Görev yaptığım Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi' nin akademik ve idari personellerine teşekkür ederim. Bilhassa, Yönetim Bilişim Sistemleri Bölüm Başkanımız Prof. Dr. Ötüken Senger hocamın bu tez süresince gösterdiği ilgi ve verdiği desteklerden dolayı teşekkür ederim. İçeriği düzenlememe tecrübeleriyle ışık tutan Doç. Dr. Gökhan Kerse hocama teşekkür ederim. Bu çalışmanın hazırlanma sürecinde manevi desteğini esirgemeyen değerli dostlarım Öğr. Gör. M. Burak Atalay' a ve Sahib Ramazanov' a teşekkürlerimi bir borç bilirim.

Destekleri ve sonsuz sevgileriyle her zaman yanımda olan hayattaki en büyük şansım olan canım aileme ne kadar minnet duyduğumu söylesem az kalacaktır.

Muhammed Akif Yenikaya

Haziran, 2022

ÖZ

OPTİK KOHERENS TOMOGRAFİ GÖRÜNTÜLERİNDEN YAŞA BAĞLI MAKULAR DEJENERASYON TİPLERİNİN YAPAY ZEKÂ KULLANILARAK TESPİTİ

Muhammed Akif Yenikaya
Doktora Tezi
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Doktora Programı
Danışman: Dr. Öğr. Üyesi Erdal Güvenoğlu
Maltepe Üniversitesi Lisansüstü Eğitim Enstitüsü, 2022

Bilim dünyasına girdiği ilk günden beri, yapay zekâ teknolojisi hızla gelişmeye devam etmektedir. Bilimsel araştırmalar ve çeşitli endüstrilerde olduğu gibi tıp teknolojileri de bu gelişmeden faydalanmaktadır. Bir tür yapay zekâ süreci olan derin öğrenme ise göz biliminde, veri analizi, bölümleme, otomatik teşhis ve olası sonuç tahminleri gibi amaçlar için kullanılmaktadır. Derin öğrenme ve Optik Koherens Tomografi (OKT) teknolojilerinin ilişkisi, göz hastalıklarının tespit edilmesi ve tanı koyma performansını iyileştirmek için güvenilir bir yöntemdir.

Bu çalışmanın amacı, bir derin öğrenme uygulaması geliştirerek Yaşa Bağlı Makular Dejenerasyon (YBMD) hastalığının erken teşhisini sağlamaktır. YBMD; kuru tip ve yaş tip olmak üzere iki gruba ayrılmaktadır. Bu çalışma kapsamında kuru tip YBDM ile yaş tip YBMD' nin Fibrovasküler PED ve Seröz PED olarak bilinen iki alt tipi incelenmiştir. Büyük hasarlara ve hatta körlüğe neden olabilecek bir hastalık olan yaş tip YBMD' nin erken teşhisi tedavi için önem taşımaktadır. Bu hastalıkla ilgili derin öğrenme ile yapılan önceki çalışmalar, sadece hastalığın var olup olmaması ile kısıtlı kalmış ve buna yönelik bir uygulama da geliştirilmemiştir. Bu çalışmada geliştirilen uygulamada hem hastalığın erken teşhisi hem de bu teşhis esnasında hastalığın tipi tespit edilebilecektir. Bu amaç doğrultusunda, derin öğrenme metotlarından ResNet50, AlexNet, GoogLeNet, Xception kullanılarak gerekli testler yapılmıştır. Bu testler içerisinden en yüksek doğruluk oranını yüzde 93.80 ile ResNet50 vermiştir. Bu sebeple geliştirilen uygulamada, ResNet50 ağının sağladığı sınıflandırma dosyası kullanılmıştır. YBMD hastalığının erken teşhisi ve hastalık tipinin belirlenmesi için geliştirilen bu uygulamanın etkili bir yöntem olduğu tespit edilmiştir.

Anahtar Sözcükler: Yaşa Bağlı Makular Dejenerasyon; Yapay Zekâ; Görüntü İşleme.

ABSTRACT

DETECTION OF AGE-RELATED MACULAR DEGENERATION TYPES FROM OPTICAL COHERENS TOMOGRAPHY IMAGES USING ARTIFICIAL INTELLIGENCE

Muhammed Akif Yenikaya
PhD Thesis
Computer Engineering Department
Computer Engineering PhD Programme
Thesis Advisor: Assistant Professor, Erdal Güvenoğlu
Maltepe University Graduate School, 2022

Since the first day it entered the world of science, artificial intelligence technology continues to develop rapidly. As with scientific research and various industries, medical technologies also benefit from this development. Deep learning, which is a kind of artificial intelligence process, is used in ophthalmology for purposes such as data analysis, segmentation, automatic diagnosis and possible outcome predictions. The relationship of deep learning and Optical Coherence Tomography (OCT) technologies is a reliable method for detecting eye diseases and improving diagnostic performance.

The aim of this study is to develop a deep learning application to provide early diagnosis of Age-Related Macular Degeneration (AMD). AMD; It is divided into two groups as dry type and wet type. In this study, two subtypes of dry AMD and wet AMD, known as Fibrovascular PED and Serous PED, were investigated. Early diagnosis of wet AMD, which is a disease that can cause great damage and even blindness, is important for treatment. Previous studies with deep learning on this disease have been limited only to the presence or absence of the disease, and no application has been developed for this. In the application developed in this study, both the early diagnosis of the disease and the type of the disease can be determined during this diagnosis. For this purpose, necessary tests were carried out by using deep learning methods ResNet50, AlexNet, GoogLeNet, Xception. Among these tests, ResNet50 gave the highest accuracy rate with 93.80 percent. For this reason, the classification file provided by the ResNet50 network is used in the developed application. It has been determined that this application, which was developed for the early diagnosis of AMD disease and to determine the type of disease, is an effective method.

Keywords: Age-Related Macular Degeneration; Artificial Intelligence; Image Processing.

İÇİNDEKİLER

JÜRİ VE ENSTİTÜ ONAYI ..... İİ
ETİK İLKE VE KURALLARA UYUM BEYANI ..... İİİ
TEŞEKKÜR ..... İV
ÖZ V
ABSTRACT ..... Vİ
İÇİNDEKİLER ..... Vİİ
ÇİZELGELER LİSTESİ ..... İX
ŞEKİLLER LİSTESİ X
KISALTMALAR ..... Xİİ
ÖZGEÇMİŞ ..... Xİ V
BÖLÜM 1. GİRİŞ 1
BÖLÜM 2. LİTERATÜR ÇALIŞMASI 4
BÖLÜM 3. MATERYAL VE YÖNTEM 10
3.1. Yaşa Bağlı Makula Dejenerasyonu 10
3.1.1. Kuru Tip Yaşa Bağlı Makular Dejenerasyon 10
3.1.1.1. Drusen 11
3.1.2. Yaş Tip Yaşa Bağlı Makular Dejenerasyon 11
3.1.2.1. Seröz PED 12
3.1.2.2. Fibrovasküler PED 13
3.2. Optik Koherens Tomografi 14
3.3. Amsler Izgarası 14
3.4. Yapay Zekâ 15
3.5. Makine Öğrenimi 17
3.5.1. Denetimli Makine Öğrenimi 18
3.5.2. Denetimsiz Makine Öğrenimi 19
3.6. Derin Öğrenme 19
3.6.1. Otomatik Kodlayıcı 20
3.6.2. Derin İnanç Ağı 21
3.6.3. Tekrarlayan Sinir Ağı 21
3.6.4. Evrişimli sinir ağları 22
3.6.4.1. ResNet 22
3.6.4.2. AlexNet 24
3.6.4.3. GoogLeNet 26
3.6.4.4. Xception 28
3.7. Eğitim Ortamı Donanım Özellikleri 31
3.8. Görüntü İşleme 32
3.8.1. Kirsch Operatörü 32
3.8.2. Gauss Yumuşatma Operatörü 33
BÖLÜM 4. GERÇEKLEŞTİRİLEN ÇALIŞMA VE PERFORMANS SONUÇLARI . 35
4.1. Kullanılan Veri Seti 35
4.2. Değerlendirme Metrikleri 36
4.2.1. Hata Matrisi 36
4.2.2. Doğruluk 38
4.2.3. Kesinlik 39

4.2.4. Duyarlılık 39
4.2.5. F-Skor 39
4.3. Veri Setinin Performans Karşılaştırması 40
4.3.1. ResNet50 Derin Öğrenme Modelinin Çalışma Sonuçları 40
4.3.2. AlexNet Derin Öğrenme Modelinin Çalışma Sonuçları 43
4.3.3. GoogLeNet Derin Öğrenme Modelinin Çalışma Sonuçları 45
4.3.4. Xception Derin Öğrenme Modelinin Çalışma Sonuçları 47
4.4. Gerçekleştirilen Uygulama 50
4.5. Gerçekleştirilen Uygulama Örnek Çıktıları 53
BÖLÜM 5. SONUÇ 58
KAYNAKÇA 60

TABLOLAR LİSTESİ

Tablo 3.1. ILSVRC 2014 için performans sergileyen takımların sonuçları 28

Tablo 3.2. Kullanılan donanım özellikleri 31

Tablo 4.1. Hata Matrisi 37

Tablo 4.2. ResNet50 ağının hesaplanan TP, FP, FN ve TN değerleri 42

Tablo 4.3. ResNet50 ağının hesaplanan parametreleri..... 42

Tablo 4.4. AlexNet ağının hesaplanan TP, FP, FN ve TN değerleri..... 44

Tablo 4.5. AlexNet ağının hesaplanan parametreleri..... 45

Tablo 4.6. GoogLeNet ağının hesaplanan TP, FP, FN ve TN değerleri 47

Tablo 4.7. GoogLeNet ağının hesaplanan parametreleri 47

Tablo 4.8. Xception ağının hesaplanan TP, FP, FN ve TN değerleri 49

Tablo 4.9. Xception ağının hesaplanan parametreleri..... 49

Tablo 4.10. Uygulamanın test sonucu elde edilen doğru sınıflandırma sayıları..... 57

ŞEKİLLER LİSTESİ

Şekil 3.1. Drusen OKT Görüntüsü 11

Şekil 3.2. Seröz PED OKT Görüntüsü 12

Şekil 3.3. Fibrovasküler PED OKT Görüntüsü 13

Şekil 3.4. Örnek OKT Görüntüsü 14

Şekil 3.5. Amsler Izgarası 15

Şekil 3.6. Yapay zekâ ve alt alanları hiyerarşik görüntüsü 16

Şekil 3.7. ResNet Mimarisi 23

Şekil 3.8. 18 ve 34 katmanlı sinir ağının hata oranı grafiği 23

Şekil 3.9. AlexNet mimarisi 24

Şekil 3.10. ImageNet görüntüsünde AlexNet' in en olası etiketleri 26

Şekil 3.11. GoogleNet mimarisi 27

Şekil 3.12. Basitleştirilmiş Inception modeli 29

Şekil 3.13. Inception modülünün ekstrem versiyonu 29

Şekil 3.14. Xception mimarisi akış ve modülleri 30

Şekil 3.15. Kirsch maskeleri 32

Şekil 3.16. Kirsch metodu uygulanmış görüntü 33

Şekil 3.17. Gauss filtresi uygulanmış görüntü 34

Şekil 4.1. Veri setinin kullanımı 35

Şekil 4.2. OKT cihazı görseli 36

Şekil 4.3. Derin öğrenme akış şeması 40

Şekil 4.4. ResNet50 derin öğrenme modelinin eğitim grafiği 41

Şekil 4.5. Eğitim sonucu ResNet50 derin öğrenme modeli hata matrisi 41

Şekil 4.6. AlexNet derin öğrenme modelinin eğitim grafiği 43

Şekil 4.7. Eğitim sonucu AlexNet derin öğrenme modeli hata matrisi 44

Şekil 4.8. GoogLeNet derin öğrenme modelinin eğitim grafiği 45

Şekil 4.9. Eğitim sonucu GoogLeNet derin öğrenme modeli hata matrisi 46

Şekil 4.10. Xception derin öğrenme modelinin eğitim grafiği 48

Şekil 4.11. Eğitim sonucu Xception derin öğrenme modeli hata matrisi 48

Şekil 4.12. Geliştirilen uygulama arayüzü 50

Şekil 4.13. OKT görüntüsü seçildikten sonra gelen ekranın görüntüsü 51

Şekil 4.14. Analiz esnasında oluşan ekran görüntüsü 52

Şekil 4.15. YBMD hastalığı bulunmayan OKT görüntsünün analiz sonrası çıktıları 53

Şekil 4.16. Drusen tipindeki OKT görüntüsünün analiz sonrası çıktıları 54

Şekil 4.17. Seröz PED tipindeki OKT görüntüsünün analiz sonrası çıktıları 55

Şekil 4.18. Fibrovasküler PED tipindeki OKT görüntüsünün analiz sonrası çıktıları ... 56

KISALTMALAR

AE : Otomatik Kodlayıcı (Autoencoder)

AUC : ROC Eğrisi Altındaki Alan (Area under the ROC Curve)

BoVW : Görsel Kelime Torbası (Bag of Visual Words)

CNV : Koroid Neovaskülarizasyonu (Choroid Neovascularization)

CPU : Merkezi İşlem Birimi (Central Process Unit)

DBN : Derin İnanç Ağı (Deep Belief Network)

DOCTRAP : Duke OKT Retina Analiz Programı (Duke OCT Retinal Analysis Program)

ESA : Evrişimli Sinir Ağları

FA : Floresein Anjiyogram (Fluorescein Angiogram)

FN : Yanlış negatif (False Negative)

FP : Yanlış pozitif (False Positive)

GPU : Grafik İşlemci Birimi (Graphics Processing Unit)

ICGA : İndosiyanin Yeşili Anjiyografi (Indocyanine Green Angiography)

ILM : İç Sınırlayıcı Zar (Internal Limiting Membrane)

ILSVRC : Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large Scale Visual Recognition Challenge)

LBP : Yerel İkili Modeller (Local Binary Patterns)

LSTM : Uzun-Kısa Süreli Bellek (Long short-term memory)

OKT : Optik Koherans Tomografi

PCA : Temel Bileşen Analizi (Principal Component Analysis)

PED : Pigment Epitel Dekolmanı (Pigment Epithelial Detachment)

PNN : Olasılıksal Sinir Ağı (Probabilistic Neural Network)

RBM : Kısıtlı Boltzmann Makinesi (Restricted Boltzmann Machine)

ReLU **:** Rektifiye Edilmiş Doğrusal Birimler (Rectified Linear Unit)

RF **:** Rastgele Orman (Random Forest)

RNN **:** Tekrarlayan Sinir Ağı (Recurrent Neural Network)

ROC **:** Alıcı İşlem Karakteristikleri (Receiver Operating Characteristic)

RPE **:** Retina Pigment Epiteli (Retinal Pigment Epithelium)

TN **:** Gerçek negatif (True Negative)

TP **:** Gerçek pozitif (True Positive)

VEGH **:** Vasküler Endotelyal Büyüme Faktörü (Vascular Endothelial Growth Factor)

YBMD **:** Yaşa Bağlı Makula Dejenerasyonu

ÖZGEÇMİŞ

Muhammed Akif Yenikaya

Bilgisayar Mühendisliği Anabilim Dalı

Eğitim

Derece	*Üniversite, Enstitü, Anabilim/Anasanat Dalı*
Y.Ls.	İzmir Ekonomi Üniversitesi, Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı
Ls.	Anadolu Üniversitesi, Yönetim Bilişim Sistemleri Anabilim Dalı
Lise	Kars Hüsnü M. Özyeğin Anadolu Lisesi

İş/İstihdam

Yıl	*Görev*
2022 -	Müdür Yardımcısı. Kafkas Üniversitesi Bilişim Teknolojileri Araştırma ve Uygulama Merkezi
2020 -	Araştırma Görevlisi. Kafkas Üniversitesi İİBF
2018- 20	Yazılım Geliştirme Mühendisi. Türkiye Finans Bankası
2017- 18	Yazılım Geliştirme Mühendisi. AdresGezgini

Yayınlar ve Diğer Bilimsel/Sanatsal Faaliyetler

Yenikaya Muhammed Akif, Güvenoğlu Erdal (2021). Prediction diabetic retinopathy from retinal fundus images via artificial neural network. Fourth Internatıonal Conference of Mathematıcal Scıences (ICMS 2020), Doi: 10.1063/5.0042204 (Yayın No: 7108165)

BÖLÜM 1. GİRİŞ

Dijitalleşen dünyada giderek önemi artan yapay zekânın, tıbbi testler ve teşhisler dahil olmak üzere çok çeşitli alanlarda uygulanabilir olduğu kanıtlanmıştır. Örneğin, mikroskobik incelemelerde yapay zekâ, etiketlenmemiş, sabitlenmiş veya canlı biyolojik örneklerin iletilen ışık mikroskobu görüntüleri üzerindeki belirli floresan etiketlerini güvenilir bir şekilde tahmin edebilmektedir. Tıbbi görüntüleme, doktorların teşhis koyabilmesi için hayati ipuçları sağlamaktadır. Grafik işleme birimlerinin geliştirilmesi ile de günümüzde yapay zekâ, Evrişimli Sinir Ağları (ESA) gibi yöntemlerle geliştirilmiş ve optimize edilmiş derin öğrenme adı verilen bir süreç aracılığıyla önemli görüntüleme verileri hızlı bir şekilde incelenip sınıflandırılabilmektedir [1].

Derin öğrenme tekniklerinden olan ResNet50, AlexNet, GoogleNet ve Xception gibi derin evrişimli sinir ağları, araştırma ekipleri tarafından göz dibi ve Optik Koherens Tomografi (OKT) görüntülerini otomatik olarak sınıflandırmak, görme bozuklukları [2] ve ayrıca diğer kötü huylu hastalıkları da tespit etmek amacıyla kullanılmaktadır [3].

Derin öğrenme tekniği kullanılarak görme bozuklukları için OKT görüntülerinin otomatik sınıflandırılması, göz doktorlarının bu tür belirtileri gözden kaçırdığı zamanlarda bile semptomların erken tespitine yol açma avantajına sahip olabilmektedir. Hızlı bir teşhis aynı zamanda tedavinin erken başlamasını da sağlamaktadır. OKT gibi görüntüleme yöntemlerinin ortaya çıkması ve artan kullanımıyla birlikte, yapay zekâ programları bu bol miktardaki OKT verisini analiz edebilmekte ve göz bilimi alanında klinik kararlar vermede yardımcı olmak için eşsiz bir araç olarak kullanılabilmektedir [4].

OKT görüntülemede, yüksek çözünürlüklü bir kesitsel doku görüntüsü oluşturmak için girişim desenleri kullanılmaktadır. Bu ise sağlayıcıların retinadaki ve diğer oküler dokulardaki patolojiyi teşhis etme becerilerini büyük ölçüde genişletmektedir. OKT görüntüleme kolay ve güvenli bir şekilde elde edilebildiğinden, bu teknoloji onu yapay zekâ için mükemmel bir hedef haline getiren büyük hacimlerde klinik görüntüler oluşturmaktadır. OKT yorumlamasında yapay zekânın hızlı bir biçimde ilerlemesiyle birlikte yakın zamanda göz bilimleri tanıları önemli ölçüde iyileştirilebilecektir [5].

Dünyanın dört bir yanındaki gruplar, gözün yapısal hastalıklarının teşhisine ve yönetimine yüksek doğrulukla yardımcı olan OKT gibi teşhis yöntemlerinden veri toplayan yapay zekâ programları geliştirmiş ve değerlendirmişlerdir. OKT' yi kullanan yapay zekâ programları, yakın gelecekte göz hastalıklarının teşhisinde ve yönetiminde önemli bir rol oynama potansiyeline sahip olacağı düşünülmektedir [6].

Yapay zekâ uygulamalarının sağlık hizmetlerinde rolünün artması muhtemel olmasına rağmen, yapay zekânın tıbba dahil edilmesiyle birlikte gelen birkaç sınırlama ve zorluk bulunmaktadır. Yapay zekâ programları genellikle klinik senaryolara bütünsel bir yaklaşım benimseyememekte ve genellikle yetenekli bir doktor tarafından dikkate alınan klinik bir karşılaşmanın sosyal ve psikolojik yönlerini tam olarak dikkate almamaktadır [7]. Yapay zekânın doğru sonuçlar üretmesi için referans standart olarak güçlü bir eğitim veri kümesi gerekmektedir. Bir yapay zekâ programı, iyi bir eğitim veri kümesi kullanarak tutarlı bir şekilde doğru sonuçlar üretebilse de gerçek dünya görüntüleri kullanan performansı doğru olmayabilir. Yapay zekâ uygulamaları, klinik tıpta gözlem ve karar verme sürecine özgü belirsizliği ve değişkenliği çoğu zaman bir araya getirememekte ve bu uygulamalar tek bir doktor tarafından mümkün olmayan bir düzeyde verileri analiz edip öğrenebilse de derin öğrenme algoritmalarının bir çıktı üretmeyi öğrendiği süreç tam olarak anlaşılmamaktadır. Bu süreç klinik karar vermede bir belirsizlik düzeyi getirmektedir. Bu nedenle, yakın gelecekte hastaların tedavisi için muhtemelen kullanacak teknolojiyi daha iyi anlamaya çalışmak gerekecektir [8].

Bu çalışmada, Yaşa Bağlı Makula Dejenerasyon (YBMD) hastalığının derin öğrenme yöntemleri kullanılarak tespiti ve sınıflandırılması amaçlanmaktadır. Bu amaçla kullanılacak olan derin öğrenme modelleri arasında karşılaştırma yapılacaktır. Bunu başarmak için elde edilen OKT görüntüleri ESA mimarisinin eğitimi için kullanılacak ve geliştirilecek olan uygulama hakkında değerlendirme sonuçları analiz edilecektir. Geliştirilen bu sınıflandırma algoritması sayesinde OKT görüntülerinden YBMD hastalık tiplerinin tahmini yapılabilecektir.

YBMD, 50 yaş ve üzerindeki kişilerde geri dönüşü olmayan körlüğün önde gelen nedenlerinden biridir [9,10]. Tam olarak tedavi edilmesi mümkün olmasa da erken tespit edilebilmekte ve tedavi aşamasında YBMD' nin ilerlemesini yavaşlatmak mümkün olabilmektedir. YBMD; kuru tip ve yaş tip olmak üzere iki tipe ayrılmaktadır. Kuru tip

YBMD' nda retina bozulmakta ve drusen adı verilen küçük sarımsı beyaz tortular oluşmaktadır. Yaş tip YBMD hastalığı ise retina altındaki anormal kan damarlarının büyümesi ile ilişkilidir. Bu anormal büyüyen kan damarları kişide ciddi görme kaybına neden olabilmektedir [11].

Hastalık erken evrelerde, yavaş ve asemptomatik olarak gelişmektedir. YBMD' nin tanımı çeşitli çalışmalarda farklılık gösterse de durum genellikle yaygın drusen ile karakterize olmakta ve sıklıkla pigment anormallikleriyle ilişkilendirilmektedir [12].

Rutin bir göz muayenesi ile YBMD hastalığı tespit edilebilmektedir. En yaygın erken belirtilerden biri drusen (retina altındaki küçük sarı noktalar) veya pigment kümelenmesidir. Tanı için hastanın bir dama tahtasına benzeyen düz çizgilerden oluşan bir desen olan amsler ızgarasına bakması istenebilmektedir. Düz çizgilerden bazıları hastaya dalgalı görünebilmekte veya bazı çizgilerin eksik olduğu fark edilebilmektedir. Bunlar, sarı nokta hastalığının belirtileri olabilmektedirler. Göz doktorunun YBMD hastalığını tespit etmesi durumunda, anjiyografi veya Optik Koherens Tomografi (OKT) adı verilen bir prosedür işlenebilmektedir. Anjiyografide, doktor koldaki bir damara boya enjekte etmekte ve boya retinadaki kan damarlarından akarken fotoğraf çekilmektedir. Makulada sıvı veya kan sızıntısı yapan yeni damar veya damarlar varsa, görüntüler hastalığın tam yerini ve türünü gösterebilmektedir [13].

BÖLÜM 2. LİTERATÜR ÇALIŞMASI

Geçmişte, derin öğrenme yoluyla Yaşa Bağlı Makular Dejenerasyon (YBMD) aşamalarının sınıflandırılmasıyla ilgili çeşitli çalışmalar yapılmıştır. Burlina [14], YBMD aşamaları sınıflandırması için derin evrişimli ağlar kullanmıştır. Düşündüğü dört aşama; normal, erken, orta ve ileri YBMD olmuştur. Burlina tarafından yapılan bir diğer çalışmada [15], önceden eğitilmiş derin sinir ağlarından hesaplanan görüntü özelliklerinin YBMD tespitindeki probleme olan uygunluğunu incelemiştir. AREDS veri kümesinden 5600' den fazla görüntü kullanan testler, iyi ön sonuçlar (yaklaşık %92 ile %95 arasında doğruluk) göstermektedir. Ayrıca Burlina ve arkadaşları, [16]' da otomatikleştirilmiş algoritmaların YBMD' nin mevcut yönetiminde uzman insan sınıflandırıcılarından bağımsız bir rol oynayabileceğini belirlemiştir.

Govindaiah ve arkadaşları [17], modifiye edilmiş on altı katmanlı bir derin sinir ağı kullanarak YBMD' nin iki grup sınıflandırması üzerinde deneyler yapmıştır. Yeterli sayıda görüntü ile açık bir şekilde derin bir sinir ağının eğitiminin, özellikle YBMD algılama ve taramada, önceden eğitilmiş bir ağ kullanmaktan daha iyi olduğunu belirlemiştir. Ayrıca, daha derin sinir ağlarının, yani VGG16' nın benzer çalışmalar için AlexNet gibi nispeten sığ ağlar diğer ağlardan daha iyi sonuçlar verdiği gözlemlenmiştir.

Grassmann ve arkadaşları [18], 13 farklı sınıf tanımlamış (9 Yaşa Bağlı Göz Hastalıkları Çalışması adımı, 3 geç YBMD aşaması ve 1 derecelendirilemeyen görüntüler sınıfı) ve bunları bir derin öğrenme algoritması kullanarak fundus görüntülerini sınıflandırmak için YBMD' nin aşamalarına ayırmışlardır. Oluşturdukları algoritma 55 yaşından büyük bireylerin fundus görüntü veri setini kullanan çalışmalarda uygun olduğunu ortaya koymuşlardır.

Arabi [19], erken YBMD, orta YBMD ve geç YBMD türlerinin tespiti için ilgili göz görüntüsündeki beyaz piksellerin toplam piksel sayısına yüzdesini kullanarak gözün kuru ve ıslak makula dejenerasyonunun otomatik olarak taranmasını önermiştir. Önerilen bu yöntem, üç kategoride her biri 10' luk 30 göz görüntüsü üzerinde denenmiş ve %97 oranında bir başarı sağlanmıştır.

Priya [20], olasılıklı sinir ağları sınıflandırıcısını kullanarak kuru ve ıslak YBMD hastalığını sınıflandırmıştır. YBMD hastalığının tespiti, Olasılıksal Sinir Ağı (Probabilistic Neural Network - PNN) yöntemi kullanılarak yapılmıştır. Sonuçlar, sınıflandırıcı için %94 duyarlılık ve %95 özgüllük olduğunu göstermiştir.

Van Grinsven [21], drusen' i saptayıp nicelendirerek ve hastalığı düşük riskli (YBMD yok veya erken YBMD yok) veya yüksek riskli (orta düzey YBMD) olarak tanımlamıştır. Gelişmiş YBMD' nin saptanması için bir makine öğrenme algoritması kullanmıştır.

Phan [22], bir teletıp ağının fundus görüntülerini, destek vektör makinesi ve rastgele orman algoritmaları kullanarak YBMD' nin farklı aşamalarına, yani YBMD olmayan, hafif YBMD, orta dereceli YBMD ve gelişmiş YBMD olarak sınıflandırmıştır.

Parvathi ve Devi [23], drusenleri güvenilir bir şekilde tespit etmek ve saymak amacıyla geliştirdiği iki yöntemi rapor etmişlerdir. Yöntemler, drusenlerin doku ve 3 boyutlu profilleri gibi morfolojik özelliklerinden yararlanmaktadır. Bu iki yöntemi kullanmanın sonuçlarını karşılaştırmış ve otomatik drusen analizi için önerilerde bulunmuştur.

Köse ve arkadaşları [24], retina fundus görüntülerinin sınıflandırılması için otomatik bir yöntem önermektedir. Makulanın sağlıksız bölgelerini belirleyen segmentli görüntünün ters görüntüsü oluşturmuşlardır. Yöntemin performansı, çeşitli kaliteli retina fundus görüntüleri üzerinde incelenmiştir. Bölümlenmiş görüntüler, hastalıktaki değişiklikleri takip etmek için aynı hastanın ardışık görüntüleri ile de karşılaştırılmıştır.

Lee ve arkadaşları [25], normal OKT görüntülerini YBMD hastalığı olan hastalardan gelen görüntülerden ayırmak için derin öğrenmenin kullanılıp kullanılamayacağını belirlemeye çalışmışlardır. Görüntüleri normal veya YBMD hastalığı olan şeklinde sınıflandırmak için bir derin sinir ağı eğitmişlerdir.

Hwang ve arkadaşları [26], YBMD hastalarından elde edilen 35.900 OKT görüntülerinden oluşan bir veri seti kullanmış ve bunları YBMD teşhisini koymak amacıyla üç tip evrişimli sinir ağını eğitmek için kullanmışlardır. Yapay zekâ platformunun algılama doğruluğu genellikle %90' dan daha yüksek, tıp öğrencilerinin bulgularından (%69.4 ve %68.9) önemli ölçüde üstün ($p<0.001$) ve retina uzmanlarının bulgularına (%92.73 ve %91.90) eşit olduğunu göstermiştir ($p = 0.99$).

Li ve ark. [27], derin öğrenme ağı olarak ResNet50 derin öğrenme mimarisini kullanarak COVNet' i sunmuşlardır. Model 3322 vakanın 4352 CT görüntüsü üzerinde eğitip test edilmiştir. Deneyler sonucunda duyarlılık, özgüllüğü ve AUC için sırasıyla %90, %96 ve %96 değerleri elde edilmiştir.

Jain ve ark. [28], ResNet101 derin öğrenme modelini kullanarak Covid-19 ve viral pnömoniyi röntgen görüntülerinden ayırt etmeye çalışılmıştır. Orijinal olarak 1215 X-ray görüntüsü içeren veri seti, veri büyütme ile 1832' ye yükseltilmiştir. Testler sonucunda %97.77 sınıflandırma doğruluğu elde edilmiştir.

Öztürk ve ark. [29] çalışmalarında 17 evrişim katmanından oluşan bir ağ kullanmışlardır. Her katmana farklı filtreler uygulanmıştır. Sınıflandırıcı olarak da DarkNet modelini tercih edilmiştir. Covid-19' u ayırt etmede ikili ve üçlü sınıflandırma probleminde sırasıyla %98.08 ve %87.02 başarı elde edilmiştir.

Derin öğrenme modelleri kullanılarak Albahli [30] tarafından yapılan çalışmada, kullanılan modelle Covid-19' a karşı diğer göğüs hastalıkları sınıflandırılmaya çalışılmıştır. ResNet152 ile %87' lik bir sınıflandırma doğruluğu elde edilmiştir.

Chiu ve ark. [31] tarafından, iç sınırlayıcı zar (Internal Limiting Membrane - ILM) ile retina pigment epiteli (Retinal Pigment Epithelium - RPE) arasında uzanan toplam retinanın ve RPE ile Bruch Membran arasında uzanan retina pigment epiteli ve drusen kompleksinin segmentasyonu için bir yöntem sunulmaktadır. Yöntemi doğrulamak için 20 ciltten çıkarılan 220 B taraması kullanılmıştır. Tüm hastalarda orta evrede ve druslu yaşa bağlı makula dejenerasyonu ve bazılarında coğrafi atrofi bulunmaktadır. Yöntem, grafik kesmeye dayanmaktadır. Bir ön işleme adımı olarak, dikdörtgen bir ortalama filtre aracılığıyla gürültü azaltma gerçekleştirilmiştir. Elde edilen görüntüden, ağırlık olarak

piksel değerleriyle bir grafik oluşturulmuştur. Her kenar için arama sırayla gerçekleştirilmiştir. Algoritma, tüm katmanları göz önünde bulundurarak ortalama 0.95 piksellik bir fark göstermiştir. Bu, iki uzman arasındaki segmentasyon farkından bile daha küçük bir değer olarak tespit edilmiş, Farsiu ve ark. [32] ile birlikte gerçekleştirilen bu çalışmalar, OKT segmentasyon araştırmasında kullanılmak üzere tasarlanmış DOCTRAP yazılımının (Duke OCT Retinal Analysis Program) geliştirilmesine atıfta bulunmaktadır.

Fang ve ark. [33] tarafından OKT görüntülerinde dokuz retina kenarını segmentlere ayırmak için evrişimli sinir ağlarını grafik arama algoritmalarıyla birleştiren bir çerçeve sunulmaktadır. Yöntem, eksüdatif olmayan YBMD' li kişilerden alınan yirmi göze ait 60 cilt (2915 B-taraması) ile doğrulanmıştır. ESA, sekiz katmanın kenarlarının konumunu tahmin etmek için katmanların kenarlarının özellikleriyle eğitilmiştir. Daha sonra bu değerler, sınırların nihai tanımı için bir grafik arama algoritmasından geçirilmiştir. Bulunan sonuçlar, DOCTRAP ve OCCTExplorer segmentasyon yazılımı tarafından elde edilen sonuçlarla karşılaştırılmıştır. Bu sonuçlar, OCCTExplorer yazılımı tarafından elde edilenlerden daha üstün, ancak yine de DOCTRAP yazılımı tarafından elde edilenlerden daha düşük olarak tespit edilmiştir.

Kugelman ve ark. [34] tarafından OKT görüntülerinde retina katmanlarının kenarlarını bölütlemek için bir yöntem önerilmiştir. Patoloji geçmişi olmayan pediatrik hastalar ile patolojileri bulunan orta seviye YBMD hastaları olmak üzere iki görüntü veritabanı kullanılmıştır. Yöntem olarak birinci tabandaki yedi katman sınırlarını ve ikinci tabandaki üç kenarı segmentlere ayırmak için parça tabanlı bir sınıflandırıcı olan Eğitimli Tekrarlayan Sinir Ağı (Recurrent Neural Network - RNN) kullanılmıştır. Sonuçlar, RNN mimarisinin net bir sıralı yapı sergileyen görüntü sınıflandırma görevleri için ESA' ya uygun bir alternatif olduğunu göstermiştir.

Yan ve ark. [35], çalışmalarında 1.351 denekten 31.262 fundus görüntüsü ve 52 YBMD ile ilişkili genetik varyant kullanmışlardır. Sonuçlar, genotiplerle birleştirilmiş fundus görüntülerinin, 0.85 ortalama eğrinin altındaki alan değeriyle geç YBMD ilerlemesini öngörebildiğini göstermiştir. Yalnızca fundus görüntülerini kullanan sonuçlar, 0.81' lik alıcı işletim karakteristik eğrisi değeri altında ortalama bir alan göstermiştir.

Srinivasan ve ark. [36], diyabetik makular edema, yaşa bağlı makula dejenerasyonu ve normal OKT görüntülerini ayırt etmek için bir sınıflandırma yaklaşımı önermişlerdir. Blok Eşleştirme 3D filtrelemeyi (BM3D) kullanarak ön işleme kullanılmıştır. Destek vektör makinası sınıflandırıcısı ile yönlendirilmiş gradyanların histogram (Histogram of Oriented Gradients - HOG) özellikleri çıkarılmıştır.

Lemaitre ve ark. [37], çalışmalarında BoVW (Görsel Kelime Torbası) modelleri kullanarak sözlük öğrenimi ile OKT görüntülerinin dokusunu yakalamak için Yerel İkili Modeller (Local Binary Patterns - LBP) özelliklerini kullanmışlardır. LBP özellik tanımlayıcıları için Rastgele Orman (Random forest - RF) sınıflandırıcısı kullanılmıştır. Bunun sonucunda %87.5' lik bir duyarlılık ve %75' lik bir özgüllük elde edilmiştir.

Perdomo ve ark. [38], çalışmalarında OCT-NET uçtan uca derin öğrenme modelini geliştirerek önemli bir referans noktası sağlamışlardır. Yöntem, %93.75' e varan bir doğruluk sağlamaktadır. OCT-NET modelinin yalnızca 12 katmandan oluşan basit bir mimariye sahip olması ve bu nedenle eğitilmesinin hızlı olması yönüyle bir avantaj sağlanmıştır.

Anushika ve ark. [39], fundus görüntülerinde makula tespiti için otomatik bir görüntüleme algoritması önermişlerdir. Önerilen çalışma, fundus görüntülerinde otomatik olarak makula tespiti için bir görüntüleme yöntemi sunmaktadır. Önerilen yöntem, makulanın doğru tespiti için stratejik pencereleme tabanlı bir yaklaşım içermektedir. Tüm fundus görüntüsünden makula aramak yerine, optik disk yardımıyla bir arama bölgesi düşünülmekte ve daha sonra çift pencere tabanlı yöntem kullanılarak bu arama bölgesinden makula tespit edilmektedir.

Narasimha-Iyer ve ark. [40], ıslak YBMD' yi izlemek için Floresein Anjiyogramlarından (FA) otomatik değişiklik analizi için bir yöntem üzerinde çalışmışlardır. Bu çalışma, FA boylamsal zaman serisindeki değişikliklerin tespiti ve sınıflandırılması için tam otomatik bir yaklaşım sunmaktadır.

Hijazi ve ark. [41], yaşa bağlı makula dejenerasyonunun taranması için veri madenciliği yaklaşımını kullanmışlardır. Önerilen yaklaşım, öznitelik bölütleme üzerine kurulmaması, bunun yerine tüm görüntü kodlamalarının kullanılmasıdır. Görüntülerden doğrudan ve dolaylı olarak çıkarılan istatistiksel parametreler şeklindeki özellikler dikkate alınmaktadır.

Naz ve ark. [42], OKT görüntülerini kullanarak YBMD tespiti için Retina Pigment Epiteli (RPE) katmanının otomatik segmentasyonu için bir yöntem önermişlerdir. Bu çalışma, Drusen tespiti için optik koherens tomografi görüntülerini kullanarak bir gözün RPE katmanını otomatik olarak segmentlere ayırmak için bir algoritma sunmaktadır.

Zheng ve ark. [43], renkli fundus fotoğrafları ile YBMD' yi sınıflandırmak için otomatik bir drusen tespit sistemi önermişlerdir. Sistem, öğrenme tabanlı drusen algılamayı ve görüntü gürültü giderme, aydınlatma düzeltme ve renk aktarımı için fundus görüntü analiz tekniklerini içermektedir.

Literatürde eksik olduğu değerlendirilen YBMD tiplerinin derin öğrenme aracılığı ile tespiti bu tez çalışmasının temelini oluşturmaktadır. Hastaneden etik onayları alınarak elde edilen veriler alanında uzman göz doktorları tarafından sınıflandırılacaktır. Derin öğrenme ağlarından olan Resnet50, Alexnet, GoogleNet ve Xception tarafından sınıflandırılmış bu veri seti eğitilecektir. Eğitim sonucunda başarı oranları değerlendirilecektir. Çalışma sonunda başarı oranı en yüksek olan derin öğrenme ağı kullanılarak bu hastalığın tiplerinin tespiti için bir uygulama geliştirilecektir.

BÖLÜM 3. MATERYAL VE YÖNTEM

Bu bölümde, çalışmada kullanılacak olan alana dair genel tanımlar, performans ölçüm kriterleri, yapay sinir ağları, görüntü işleme teknikleri gibi konular ele alınmış olup derin öğrenmede kullanılacak olan veri setinin hazırlanmasına yer verilmiştir.

3.1. Yaşa Bağlı Makula Dejenerasyonu

Merkezi retinanın ilerleyici kronik bir hastalığı olan YBMD, dünya çapında görme kaybının önde gelen nedenlerindendir. Görme kaybının çoğu hastalığın geç evrelerinde meydana gelmektedir. Bunlar, Neovasküler (yaş tip) YBMD ve coğrafi atrofidir (geç kuru tip). Neovasküler YBMD' de, koroid neovaskülarizasyonu nöral retinaya girerek sıvı, lipid ve kan sızdırmakta bu ise fibröz skarlaşmaya yol açmaktadır. Coğrafi atrofide, retina pigment epiteli, koryokapillaris ve fotoreseptörlerde ilerleyici atrofi meydana gelmektedir. YBMD' den kaynaklanan görme kaybı hastalığın bu ileri formlarından kaynaklanmaktadır [44].

3.1.1. Kuru Tip Yaşa Bağlı Makular Dejenerasyon

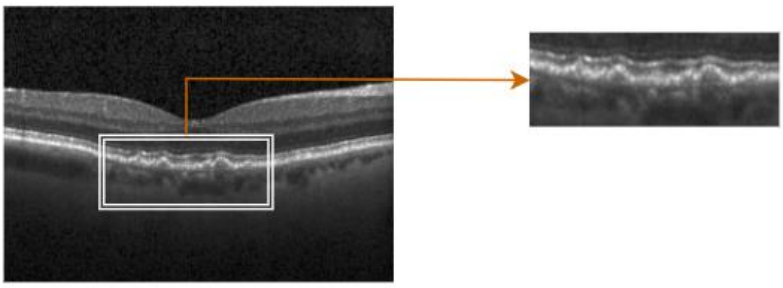
Makula dejenerasyonu vakalarının yaklaşık %85 ila %90' ı "kuru" (atrofik) tiptir [45]. "Kuru" YBMD, göz diplerinde herhangi bir kan veya serum sızıntısı içermemektedir. Görme kaybı bu aşamada da meydana gelebilmektedir. Bu "kuru" forma sahip hastalar iyi bir merkezi görüşe sahip olabilirler ancak dalgalı görme, sınırlı merkezi görüş alanı nedeniyle okuma güçlüğü, gece veya düşük aydınlatma koşullarında sınırlı görme gibi önemli fonksiyonel sınırlamalara sahip olabilmektedir [46,47].

"Kuru" tip makula dejenerasyonu, retinanın bozulması, makula altında drusen olarak bilinen küçük sarı birikintilerin oluşumu ile ilişkilidir. Bu ise makulada incelme ve kurumaya neden olarak makulanın işlevini kaybetmesine yol açmaktadır [48]. Merkezi görme kaybının miktarı, drusenin neden olduğu retina incelmesinin yeri ve miktarı ile doğrudan ilişkili olmaktadır.

Kuru tip yaşa bağlı makula dejenerasyonunun erken evresi, minimal düzeyde görme bozukluğuna sebep olabilmekte ve bu durum makulada büyük drusen ve pigment anormallikleri ile karakterize olmaktadır [49].

3.1.1.1. Drusen

Drusen, YBMD' nin özelliği olan ancak bununla benzersiz bir şekilde ilişkili olmayan retina altı yağ ve protein birikintileridir (Şekil 3.1). Genellikle yaşlı insanlara ait gözlerde bulunmakta olup fazla sayıda birleşik drusen, YBMD için önemli bir risk faktörü oluşturmaktadır [50].



Şekil 3.1. Drusen OKT Görüntüsü

3.1.2. Yaş Tip Yaşa Bağlı Makular Dejenerasyon

Makula dejenerasyonu vakalarının yaklaşık %10-15' i yaş tiptedir. Yaş tip makula dejenerasyonunda, retina ve makula altında anormal kan damarları (koroidal neovaskülarizasyon veya CNV olarak bilinmektedir) büyümektedir. Bu yeni kan damarları daha sonra kanayabilmekte, sıvı sızdırabilmektedir. Bu ise makulanın şişmesine veya normalde düz konumunda iken yükselmesine neden olarak merkezi görüşü bozabilmektedir. Bu koşullar altında görme kaybı hızlı ve şiddetli olabilmektedir.

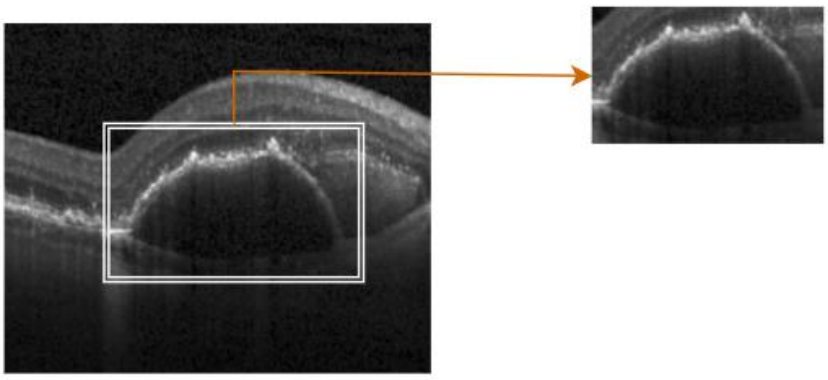
Yaş tipte YBMD hastalığından mustarip hastalar, makula altındaki kan veya sıvı nedeniyle görmelerinin merkezinde koyu renkli bir nokta (veya noktalar) görebilmektedir. Makula artık düzgün olmadığı için düz çizgiler dalgalı görünebilmektedir [51]. Ancak bazı hastalar neovaskülarizasyonun başlamasına rağmen bu tür değişiklikleri fark edememektedir. Bu nedenle yüksek risk altındaki hastalar için periyodik göz muayeneleri çok önem taşımaktadır. Bu çalışmada yaygın olarak görülen yaş tip YBMD tipleri olan Seröz PED ve Fibrovasküler PED konularına değinilmiştir.

3.1.2.1. Seröz PED

Retina Pigment Epitel Dekolmanı (PED), YBMD klinik spektrumunun bir parçasıdır. Bununla birlikte, literatürde farklı PED tipleri bildirilmiştir. Bunlar YBMD hastalığı ile ilişkili veya ilişkisizdir.

Seröz PED, RPE' nin keskin sınırlı, kubbe şeklindeki seröz yükselmesi alanı olarak tanımlanmaktadır. Seröz PED' in histopatolojisi, sıvı birikimi nedeniyle kalan bruch membranından üstteki RPE ile RPE bazal membranın ayrılması açısından tutarlı olmaktadır [52].

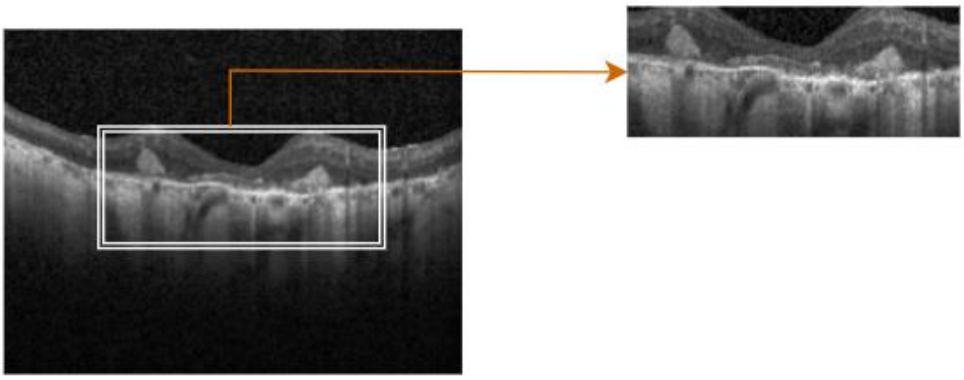
Seröz PED, Floresan Anjiyografi (FA), İndosiyanin Yeşili Anjiyografi (ICGA) veya OKT ile görüntülenebilmektedir. Fundus muayenesinde seröz PED, sarı ile turuncu renkli ve pürüzsüz bir yüzeye sahip RPE ve üstündeki nörosensör retinanın düzenli olarak ayrıldığı yuvarlak veya oval belirgin kubbe şeklinde bir alan olarak görünmektedir [53,54]. Şekil 3.2' de Seröz PED' e ait OKT görüntüsü verilmiştir.



Şekil 3.2. Seröz PED OKT Görüntüsü

3.1.2.2. Fibrovasküler PED

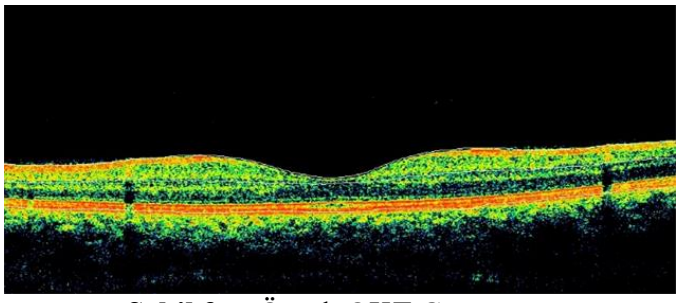
Gizli Koroidal Neovaskülarizayonun (Choroidal Neovascularization - CNV) en sık formu olan Fibrovasküler PED' ler, yüzey konturunda pürüzsüz veya düzensiz olabilen, ancak hiperreflektiflik alanlarının yanı sıra hiporeflektiflik cepleri içeren heterojen iç yansıtıcılığa sahip RPE yükselmeleri olarak tanımlanmaktadır. Posterior gölgeleme ile dairesel hiporeflektiflik alanlarının varlığı, fibrovasküler kompleks içindeki büyük damarlarla korele olduklarına inanıldığından, Fibrovasküler PED' lerin belirlenmesinde özellikle yardımcı olmaktadır. Fibrovasküler PED, OKT' de retina pigment epitelinin yükselmesi şeklinde izlenmektedir [55]. Şekil 3.3' te Fibrovasküler PED' e ait OKT görüntüsü verilmiştir.



Şekil 3.3. Fibrovasküler PED OKT Görüntüsü

3.2. Optik Koherens Tomografi

Cerrahi işlem gerektirmeyen bir görüntüleme testi olan OKT, retinanın enine kesit resimlerini çekmek için ışık dalgalarını kullanmaktadır. Şekil 3.4' te örneği verilen OKT görüntüsü aracılığı ile göz doktoru retinanın farklı katmanlarının her birini görebilmektedir. Bu ise göz doktorunun retinanın kalınlıklarını haritalandırmasına ve ölçmesine olanak tanımaktadır. Bu ölçümler tanıya yardımcı olmaktadır. Ayrıca retina hastalıkları için tedavi rehberliği sağlamaktadır. Bu retina hastalıkları YBMD veya diyabetik göz hastalığı gibi hastalıkları içermektedir [56].

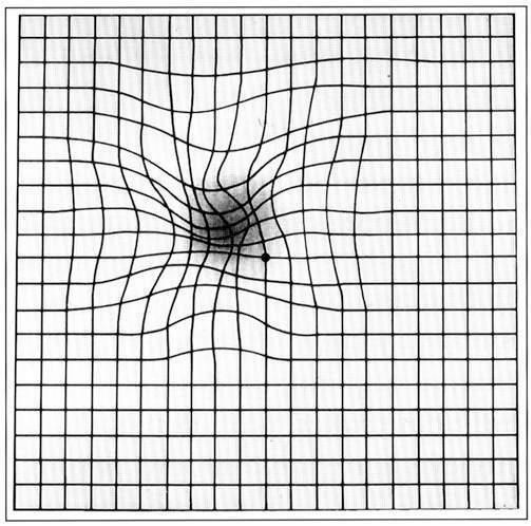


Şekil 3.4. Örnek OKT Görüntüsü

3.3. Amsler Izgarası

Amsler ızgarası, göz doktorlarının makulaya (retinanın merkezi kısmı) veya optik sinire verilen hasardan kaynaklanan görme sorunlarını tespit etmek için kullandıkları bir araçtır (Şekil 3.5). Hasarlar, makular dejenerasyon veya diğer göz hastalıklarından kaynaklanabilmektedir. Bu nedenle Amsler ızgarası bu sorunları tespit etmede faydalı olabilmektedir [57].

Makula dejenerasyonu veya diğer göz hastalıkları riski altında olan kişiler bu tabloyu evde kullanabilmektedir. Ancak tabloyu kullanmak, göz doktoruna düzenli ziyaretleri aksatmak gerektiği anlamına gelmemektedir. Yalnızca eğitimli bir göz doktorunun bulacağı işaretler, kolayca gözden kaçırılabilmektedir.



Şekil 3.5. Amsler Izgarası

3.4. Yapay Zekâ

Son on yılda bir dizi yapay zekâ tanımı ortaya çıkmış olsa da John McCarthy tarafından yayınlanan 2004 tarihli makalede yapay zekanın akıllı makineler, özellikle de akıllı bilgisayar programları yapma bilimi ve mühendisliği olduğu ileri sürülmüştür.

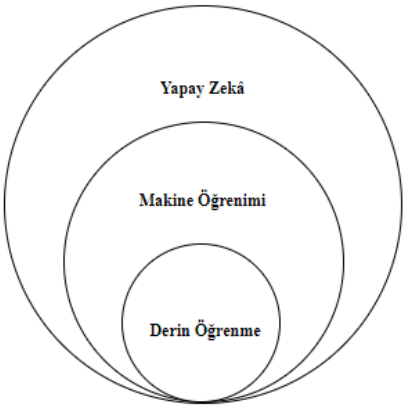
Yapay zekâ, insan zekâsı süreçlerinin makineler, özellikle bilgisayar sistemleri tarafından simülasyonudur. Yapay zekanın özel uygulamaları arasında uzman sistemler, doğal dil işleme, konuşma tanıma ve makine vizyonu yer almaktadır ayrıca yapay zekâ, işletmelere operasyonları hakkında daha önce farkında olmayabilecekleri içgörüler sunabilmekte ve bazı durumlarda görevleri insanlardan daha iyi yerine getirebilmektedir. İlgili alanların özellikle düzgün bir şekilde doldurulduğundan emin olmak için çok sayıda yasal belgeyi analiz etmek gibi tekrarlayan, detay odaklı görevler söz konusu olduğunda, yapay zekâ araçları genellikle işleri hızlı ve nispeten az hatayla tamamlamaktadır.

Yapay zekâ fütüristik bir vizyon değildir, çeşitli sektörlerle entegre edilebilen ve dağıtılabilen bir kavram olarak karşımıza çıkmaktadır. Finansal, ulusal güvenlik, sağlık, ceza adaleti, ulaşım ve akıllı şehirler gibi alanlar da buna dahildir. Yapay zekanın dünya üzerinde halihazırda bir etki yarattığı ve insan yeteneklerini önemli şekillerde artırdığı sayısız örnek bulunmaktadır [58].

Yapay zekâ araçları, tasarımcıların sağlık hizmetlerinde hesaplama karmaşıklığını geliştirmelerine de yardımcı olmaktadır. Örneğin Merantix, derin öğrenmeyi tıbbi konulara uygulayan bir Alman şirketidir. Bu şirket bilgisayarlı tomografi görüntülerinde insan vücudundaki lenf düğümlerini tespit eden bir uygulamaya sahiptir [59].

Yapay zekâ, yaşlı vatandaşların yüzde 10' unu etkileyen ve Amerika Birleşik Devletleri' nde her yıl 35 milyar dolara mal olan bir hastalık olan konjestif kalp yetmezliğine de uygulanmıştır. Yapay zekâ araçları, olası zorlukları önceden tahmin edebilmekte ve kaynakları hasta eğitimine, algılamaya ve hastaları hastanenin dışında tutan proaktif müdahalelerde de bulunabilmektedir [60].

Yapay zekâ bu gibi alanda yapılan çalışmalara genel bir isimlendirme olmuştur. Şekil 3.6' da yapay zekâ ve alt alanları hiyerarşik bir şekilde genelden özele olacak şekilde gösterilmektedir.



Şekil 3.6. Yapay zekâ ve alt alanları hiyerarşik görüntüsü

3.5. Makine Öğrenimi

Makine öğrenimi, insanların öğrenme şeklini taklit etmek için veri ve algoritmaların kullanımına odaklanan ve doğruluğunu kademeli olarak artıran bir yapay zekâ ve bilgisayar bilimi dalıdır. Makine öğrenimi, büyüyen veri bilimi alanının önemli bir bileşeni olan makine öğrenimi, istatistiksel yöntemlerin kullanılması yoluyla algoritmalar, sınıflandırmalar veya tahminler yapmak için eğitilmekte ve veri madenciliği projelerindeki temel bilgileri ortaya çıkarmaktadır. Bu iç görüler daha sonra uygulamalar ve işletmeler içinde karar vermeyi yönlendirerek ideal olarak temel büyüme ölçümlerini etkilemektedir [61].

Tipik makine öğrenimi algoritması genel anlamda karar süreci, hata işlevi, güncelleme veya optimize süreci olmak üzere üç bileşenden oluşmaktadır. Bunlar aşağıda açıklanmaktadır:

- Karar süreci: Verileri alan ve algoritmanızın bulmak istediği verilerdeki model türünde bir "tahmin" döndüren hesaplama tarifi veya diğer adımlardır.
- Hata işlevi: Tahminin ne kadar iyi olduğunu, bilinen örneklerle (mevcut olduğunda) karşılaştırarak ölçme yöntemidir.
- Güncelleme veya optimize süreci: Algoritmanın kaçırılana baktığı ve ardından karar sürecinin nihai karara nasıl ulaştığını güncellediği, böylece bir dahaki sefere kaçırmanın o kadar büyük olmayacağı süreçtir.

Günlük hayatta karşılaşılabilecek birkaç makine öğrenimi örnekleri aşağıda verilmiştir:

Konuşma tanıma: Otomatik konuşma tanıma, konuşma tanıma veya konuşmadan metne çevirme olarak da bilinen bu öğrenim insan konuşmasını yazılı bir biçimde işlemek için doğal dil işlemeyi kullanmaktadır. Birçok mobil cihaz, sesli arama yapmak için sistemlerine konuşma tanıma özelliğini (örneğin Siri gibi) dahil etmektedir.

Müşteri hizmetleri: Çevrimiçi sohbet robotları, müşteri yolculuğu boyunca insan aracıların yerini almaktadır. Sevkiyat gibi konularla ilgili sık sorulan soruları yanıtlamakta veya kişiselleştirilmiş tavsiyeler, çapraz satış ürünleri veya kullanıcılar için boyut önerileri sunarak web siteleri ve sosyal medya platformlarında müşteri etkileşimi hakkındaki düşüncelerimizi değiştirebilmektedirler. Örnekler arasında e-ticaret

sitelerinde bulunan mesajlaşma botları, Slack ve Facebook Messenger gibi mesajlaşma uygulamaları ve genellikle sanal asistanlar ve sesli asistanlar tarafından yapılan görevler sayılabilmektedir.

Bilgisayarla görme: Bu yapay zekâ teknolojisi, bilgisayarların ve sistemlerin dijital görüntülerden, videolardan ve diğer görsel girdilerden anlamlı bilgiler türetmesini sağlar ve bu girdilere dayanarak harekete geçebilir. Öneri sağlama yeteneği, onu görüntü tanıma görevlerinden ayırmaktadır. ESA tarafından desteklenen bilgisayarlı görme, sosyal medyada fotoğraf etiketleme, sağlık hizmetlerinde radyoloji görüntüleme ve otomotiv endüstrisinde kendi kendine giden arabalar gibi uygulamalara sahiptir.

Öneri motorları: Geçmiş tüketim davranışı verilerini kullanan yapay zekâ algoritmaları, daha etkili çapraz satış stratejileri geliştirmek için kullanılabilecek veri eğilimlerini keşfetmeye yardımcı olabilmektedir. Bu ise çevrimiçi perakendeciler için ödeme işlemi sırasında müşterilere ilgili eklenti önerileri yapmak için kullanılabilmektedir.

Otomatik hisse senedi ticareti: Hisse senedi portföylerini optimize etmek için tasarlanan yapay zekâ güdümlü yüksek frekanslı ticaret platformları, insan müdahalesi olmadan günde binlerce, hatta milyonlarca işlem yapabilmektedir. Makine öğrenmesinde denetimli ve denetimsiz olmak üzere yaygın olarak kullanılan iki metot bulunmaktadır.

3.5.1. Denetimli Makine Öğrenimi

Denetimli makine öğrenimi olarak da bilinen denetimli öğrenme, verileri sınıflandırmak veya sonuçları doğru bir şekilde tahmin etmek için algoritmaları eğitmek amacıyla etiketli veri kümelerinin kullanılması olarak tanımlanmaktadır. Girdi verileri modele beslenirken, model uygun şekilde takılana kadar ağırlıklarını ayarlamaktadır. Bu ise modelin fazla veya eksik uydurmayı önlemesini sağlamak için çapraz doğrulama sürecinin bir parçası olarak gerçekleşmektedir. Denetimli öğrenme, kuruluşların istenmeyen postaları gelen kutusundan ayrı bir klasörde sınıflandırmak gibi çeşitli gerçek dünya sorunlarını büyük ölçekte çözmesine yardımcı olmaktadır. Denetimli öğrenmede kullanılan bazı yöntemler arasında sinir ağları, naif bayes, doğrusal regresyon, lojistik regresyon, rastgele orman, destek vektör makinesi ve daha fazlası bulunmaktadır [62].

3.5.2. Denetimsiz Makine Öğrenimi

Denetimsiz makine öğrenimi olarak da bilinen denetimsiz öğrenme, etiketlenmemiş veri kümelerini analiz etmek ve kümelemek için makine öğrenimi algoritmalarını kullanmaktadır. Bu algoritmalar, insan müdahalesine ihtiyaç duymadan gizli kalıpları veya veri gruplamalarını keşfeder. Bilgilerdeki benzerlikleri ve farklılıkları keşfetme yeteneği, onu keşifsel veri analizi, çapraz satış stratejileri, müşteri segmentasyonu, görüntü ve örüntü tanıma için ideal çözüm haline getirmektedir. Ayrıca, boyutsallık azaltma işlemi yoluyla bir modeldeki özelliklerin sayısını azaltmak için kullanılmaktadır. Denetimsiz öğrenmede kullanılan diğer algoritmalar arasında sinir ağları, k-ortalama kümeleme, olasılıklı kümeleme yöntemleri ve daha fazlası bulunmaktadır [63].

3.6. Derin Öğrenme

Derin öğrenme, yapay sinir ağlarından geliştirilen yaygın bir makine öğrenimi alanıdır. Yapay sinir ağlarının araştırılması 1940’ lı yıllarda başlamıştır. McCulloch ve ark. [64], nöronların özelliklerini analiz ederek ve özetleyerek McCulloch-Pitts (MP) modelini, Hebb ve ark. [65] ise öğrenme süreci sırasında serebral nöronun adaptasyonunu açıklamak için bir hücre birleştirme teorisi önermiştir. Bu teori, sinir ağlarının gelişimi üzerinde önemli bir etkiye sahiptir. Daha sonra Rosenblatt ve ark. [66] algılayıcı algoritmasını icat etmiştir. Bu algoritma, denetimli öğrenmeye ait bir tür ikili sınıflandırıcıdır. Widrow, MP modeline dayalı tek katmanlı ve uyarlanabilir doğrusal elemanlı bir yapay sinir ağı önermiştir. Bununla birlikte, Hopfield [67] 1980’ lerin başında Hopfield ağını önermiştir. Bu ise yapay sinir ağını canlandırmıştır. Daha sonra Ackley ve ark. [68], benzetilmiş tavlama algoritmasını kullanarak Boltzmann makinesini önermiştir. 1990’ larda destek vektör makinesi [69] ve Boosting [70] gibi çeşitli sığ makine öğrenme yöntemleri birbiri ardına önerilmiştir.

Derin öğrenme modelleri genellikle katmanlarını bağlamak için hiyerarşik yapıları benimsemektedir. Bir alt katmanın çıktısı, basit doğrusal veya doğrusal olmayan hesaplamalar yoluyla bir üst katmanın girdisi olarak kabul edilebilmektedir. Bu modeller, verilerin düşük seviyeli özelliklerini yüksek seviyeli soyut özelliklere dönüştürebilmektedir. Bu özelliğinden dolayı, derin öğrenme modelleri, özellik temsilinde sığ makine öğrenimi modellerinden daha güçlü olabilmektedir. Geleneksel makine öğrenimi yöntemlerinin performansı genellikle kullanıcıların deneyimlerine dayanırken, derin öğrenme yaklaşımları verilere dayanmaktadır. Bu nedenle, derin öğrenme yaklaşımlarının kullanıcılara yönelik talepleri azalttığı görülebilmektedir. Bilgisayar teknolojisinin ilerlemesi bilgisayarların performansı hızla artmakta ve bu faktörler, derin öğrenmenin gelişmesi ve derin öğrenmenin makine öğreniminde yaygın bir yöntem haline gelmesini sağlamaktadır.

Başlangıcından günümüze kadar birçok derin öğrenme modeli geliştirilmiştir. Tipik modeller arasında Otomatik Kodlayıcı, Derin İnanç Ağı, Evrişimli Sinir Ağı ve Tekrarlayan Sinir Ağı bulunmakta olup bunlar aşağıda sırasıyla açıklanmıştır.

3.6.1. Otomatik Kodlayıcı

Otomatik kodlayıcı esas olarak karmaşık yüksek boyutlu verileri işlemek için kullanılmaktadır. Amacı ise boyutluluk indirgeme yoluyla bir veri kümesinin nasıl temsil edileceğini öğrenmektir. Otomatik kodlayıcı ayrıca Denoising Autoencoder [71] ve Sparse Autoencoder [72] gibi birçok gelişmiş yapıya sahiptir. Denoising Autoencoder, ağ ağırlıklarını eğitmek için rastgele gürültülü orijinal verileri kullanılır ve bu durum ayıklanan özelliklerin daha sağlam olmasını sağlar.

Sparse Autoencoder, gizli katmanların ve nöronların sayılarını artırmanın yanı sıra, yalnızca az sayıda gizli düğümün etkin durumda olduğu ve gizli düğümlerin çoğunun etkinleştirilmemiş durumda olduğu gizli düğümlerin etkinleştirme durumunu sınırlamaktadır.

3.6.2. Derin İnanç Ağı

Derin İnanç Ağı, birkaç Kısıtlı Boltzmann Makinesi (Restricted Boltzmann Machine - RBM) tarafından yığılmış bir tür sinir ağıdır. RBM, Boltzmann makinesinden gelen bir tür üretken stokastik sinir ağı modelidir. RBM, Boltzmann makinesinin iki katmanlı nöron yapısını miras almış olsa da aynı katmandaki nöronlar arasında hiçbir bağlantı bulunmamakta yalnızca görsel katman ile gizli katman arasındaki bağlantının tamamını bulundurmaktadır [73].

RBM' nin gizli katmanlarının sayısını artırdıktan sonra, derin Boltzmann makinesi alınabilir. Ardından derin inanç ağı modelinin alınabilmesi için görsel katmanın yanında yukarıdan aşağıya yönlendirilmiş bir bağlantı benimsenmektedir. Ağı eğitirken, ağ ağırlıklarını almak için açgözlü denetimsiz katman bazında ön eğitim yöntemi kullanılabilmektedir. Alt katmanın çıktısı üst katmanın girdisi olarak kullanıldığında tek seferde yalnızca bir katman eğitilmektedir. Ardından, tüm ağa ince ayar yapmak için geri yayılım algoritması kullanılmaktadır [74].

3.6.3. Tekrarlayan Sinir Ağı

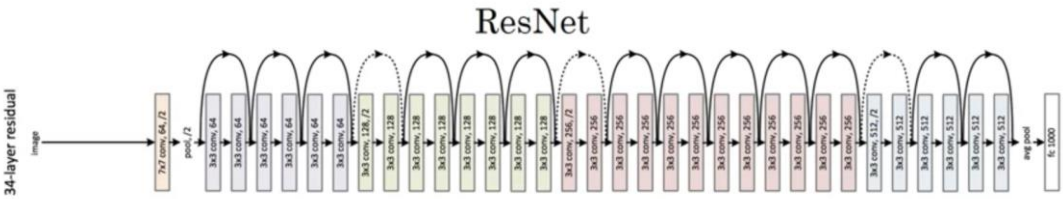
Tekrarlayan Sinir Ağı (Recurrent Neural Network - RNN), bir tür yapay sinir ağıdır. RNN' de ileri beslemeli sinir ağı yapısına sahip olmanın yanı sıra yönlendirilmiş çevrimler de bulunmaktadır. Bu yapı, bilginin ağda dolaşmasına izin verir. Böylece her zamanın çıktısı sadece o andaki girdiyle değil, önceki zaman damgalarındaki girdiyle de ilişkili olmaktadır. Geleneksel RNN, zaman serisi verileriyle başa çıkabilmesine rağmen, geri yayılım sürecinde gradyan kaybolması konusunda ciddi bir sorun bulunmaktadır. Bu nedenle RNN çoğu durumda yalnızca kısa süreli bellek için kullanılabilmektedir. Bu sorunu çözmek için, Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) gibi çeşitli gelişmiş yapılar ortaya koymaya başlanmıştır. Geleneksel RNN' den farklı olarak LSTM, bir bellek hücresine ve bir giriş-çıkış kapısı yapısına sahiptir. Bellek hücresi, bilgileri kaydetmek için kullanılırken giriş-çıkış kapısı, bilginin bellek hücresine girip giremeyeceği belirlenmektedir. Bu özelliklerinden dolayı LSTM, uzun süreli bellek görevlerinde RNN' den daha iyi bir performansa sahip olmaktadır [75].

3.6.4. Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (ESA), görüntü tanıma ve sınıflandırma gibi alanlarda çok güçlü olduğu saptanan belirli bir mimariye sahip derin öğrenme modelidir [76,77]. ESA' ların yüzleri, nesneleri ve trafik işaretlerini insanlardan daha iyi tanımladığı ve bu nedenle robotlarda ve sürücüsüz arabalarda bulunabileceği belirlenmiştir. ESA' lar denetimli bir öğrenme yöntemi olduğundan ilgili sınıflarla etiketlenmiş veriler kullanılarak eğitilmektedir. Esasen, giriş nesneleri ve sınıf etiketleri arasındaki ilişkiyi öğrenen ESA' lar ayrıca özelliklerin çıkarıldığı gizli katmanlar ve işlemenin sonunda gerçek sınıflandırma görevi için kullanılan tamamen bağlantılı katmanlar olmak üzere ikiye ayrılmaktadır. Normal sinir ağlarının aksine, ESA' nın gizli katmanlarının belirli bir mimarisi vardır. Normal sinir ağlarında her katman bir dizi nöron tarafından oluşturulmakta ve bir katmanın bir nöronu, önceki katmanın her bir nöronuna bağlanmaktadır. Bir katmandaki nöronlar, önceki katmanın tüm nöronlarına bağlı olmak yerine yalnızca az sayıda nörona bağlı olduğundan ESA' daki gizli katmanların mimarisi biraz daha farklılık gösterir. Yerel bağlantılara ve yerel nöron çıktılarını tek bir değerde özetleyen ek havuzlama katmanlarına yönelik bu kısıtlama, dönüşümle değişmeyen özelliklerle ayrıca daha basit bir eğitim prosedürü ve daha düşük bir model karmaşıklığı ile sonuçlanmaktadır [78]. Bu bölümde çalışmada kullanılan ESA modellerinden olan ResNet, AlexNet, GoogLeNet ve Xception' dan bahsedilmektedir.

3.6.4.1. ResNet

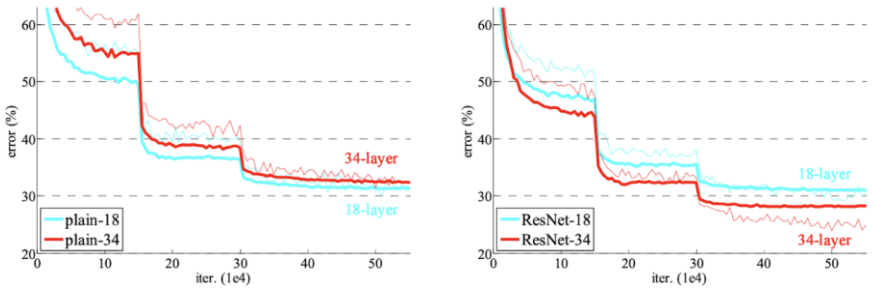
Residual Network' ün kısaltması olan ResNet, Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından "Görüntü Tanıma İçin Derin Artık Öğrenme" başlıklı makalede 2015 yılında tanıtılan özel bir sinir ağı türüdür. Çoğunlukla karmaşık bir sorunu çözmek için derin sinir ağlarında bazı ek katmanları yığılmakta ve bu da daha iyi doğruluk ve performans sağlamaktadır. Daha fazla katman eklemenin ardındaki önsezi, bu katmanların giderek daha karmaşık özellikleri öğrenmesidir. Örneğin, görüntülerin tanınması durumunda, birinci katman kenarları algılamayı, ikinci katman dokuları tanımlamayı ve benzer şekilde üçüncü katman nesneleri algılamayı öğrenebilmektedir [79]. Şekil 3.7' de ResNet mimarisine ait görüntü verilmiştir.



Şekil 3.7. ResNet Mimarisi [79]

ImageNet veri kümesinden alınan örnekler 224 × 224' e yeniden ölçeklenmekte ve piksel başına ortalama çıkarma ile normalleştirilmektedir. Optimizasyon için 256 mini parti boyutu ile stokastik gradyan inişi kullanılmaktadır. Öğrenme oranı 0.1' den başlamakta ve hata arttığında 10' a bölünmektedir ve modeller 60 × 104 iterasyona kadar eğitilmektedir. Ağırlık düşüşü ve momentum sırasıyla 0.0001 ve 0.9' a ayarlanmıştır.

ResNet, daha derin mimarilerle son derece iyi performans göstermektedir. Şekil 3.8' de iki adet 18 ve 34 katmanlı sinir ağının hata oranını gösteren bir resim verilmiştir. Soldaki grafik düz ağları gösterirken, sağdaki grafik ise ResNet eşdeğerlerini göstermektedir. Görüntüdeki ince kırmızı eğri eğitim hatasını, kalın eğri ise doğrulama hatasını temsil etmektedir [80].

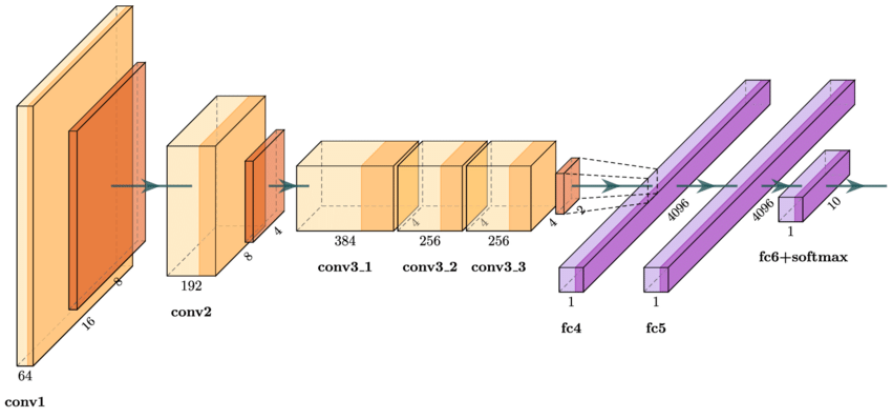


Şekil 3.8. 18 ve 34 katmanlı sinir ağının hata oranı grafiği [80]

3.6.4.2. AlexNet

Şekil 3.9' da verilen AlexNet mimarisi, sekiz katmandan oluşmaktadır. Bunlar beş evrişimsel katman ve üç tam bağlantılı katmanıdır. Ancak AlexNet' i özel yapan ise ESA' ya getirilen yeni yaklaşımlardır [81]. Bunlar:

- Doğrusal olmayan ReLU: AlexNet' te standart olarak kullanılan tanh işlevi yerine Rektifiye Edilmiş Doğrusal Birimler (Rectified Linear Unit - ReLU) kullanılmaktadır. ReLU' nun bir avantajı ise eğitim süresidir. CIFAR-10 veri kümesinde %25 hataya ulaşabilen ReLU kullanılan bir evrişimli sinir ağı, tanh kullanan bir evrişimli sinir ağından altı kat daha hızlı olmaktadır.
- Çoklu GPU' lar: AlexNet' in ileri sürüldüğü dönemlerde GPU' lar hala üç gigabayt bellekle çalışması ve eğitim setinde 1,2 milyon görüntü bulunması oldukça zor bir işlem olarak karşımıza çıkmaktaydı. AlexNet, modelin nöronlarının yarısını bir GPU' ya ve diğer yarısını başka bir GPU' ya koyarak çoklu GPU eğitimine izin vermektedir. Bu sadece daha büyük bir modelin eğitilebileceği anlamına gelmemekte, aynı zamanda eğitim süresini de kısaltmaktadır.



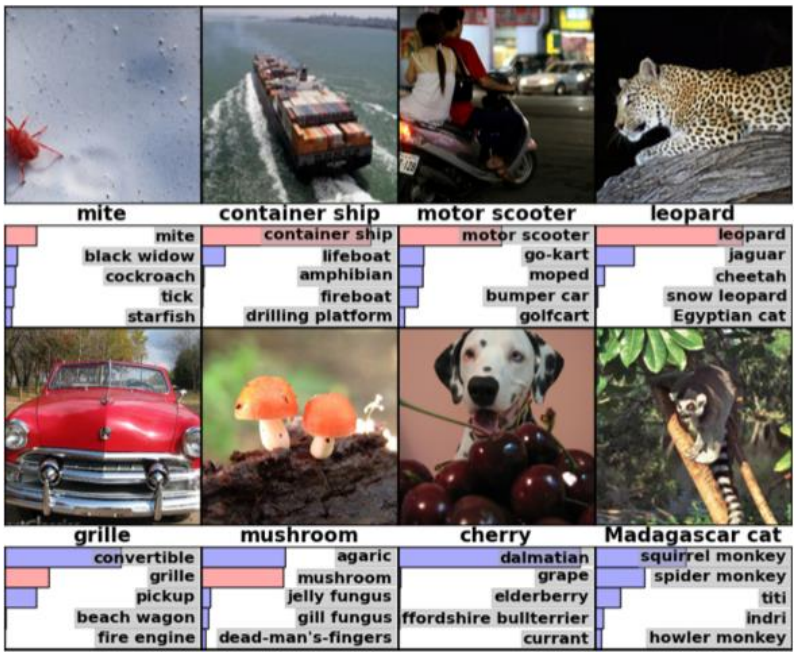
Şekil 3.9. AlexNet mimarisi [81]

AlexNet, fazla uyum açısından önemli bir sorun olan 60 milyon parametreye sahip olup aşırı uyumu azaltmak amacıyla iki yöntem kullanılmaktadır. Bunlar:

- Veri Büyütme: Verileri daha çeşitli hale getirmek için etiket koruyucu dönüşüm kullanılmıştır. Spesifik olarak, eğitim setini 2048 kat artıran görüntü çevirileri ve yatay yansımalar oluşturulmuştur. Ayrıca RGB kanallarının yoğunluğunu değiştirmek için RGB piksel değerleri üzerinde Temel Bileşen Analizi (PCA) gerçekleştirilmiştir ve bu da ilk 1 hata oranını %1' den fazla azaltmıştır.
- Dropout: Bu teknik, önceden belirlenmiş bir olasılıkla (örneğin %50) nöronların "kapatılmasından" oluşmaktadır. Bu ise her yinelemenin, her bir nöronu diğer rastgele nöronlarla kullanılabilecek daha sağlam özelliklere sahip olmaya zorlayan, model parametrelerinin farklı bir örneğini kullandığı anlamına gelmektedir. Bununla birlikte dropout, modelin yakınsaması için gereken eğitim süresini de artırmaktadır.

ImageNet yarışmasının 2010 versiyonunda en iyi model %47.1 ile ilk 1 hata ve %28.2 ile ilk 5 hata elde ederken AlexNet, bu modeli %37.5' lik ilk 1 hata ile ve %17' lik ilk 5' lik hata ile büyük ölçüde geride bırakmıştır. Merkez dışı nesneleri tanıyabilen AlexNet, 2012 ImageNet yarışmasını, ikinci sırada yer alan %26.2' lik ilk 5 hata oranına kıyasla, %15.3' lük ilk 5 hata oranıyla kazanmıştır [82].

Şekil 3.10' da sekiz adet ImageNet görüntüsünde AlexNet' in en olası etiketleri görülmektedir. Her görüntünün altına doğru etiket yazılmakta ve her etikete atanan olasılık da çubuklarla gösterilmektedir.



Şekil 3.10. ImageNet görüntüsünde AlexNet' in en olası etiketleri [82]

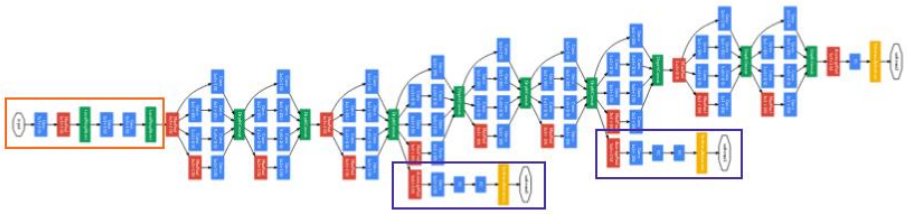
AlexNet, çok zorlu veri kümelerinde yüksek doğruluklar elde eden güçlü bir model olarak karşımıza çıkmaktadır. Ancak, evrişim katmanlarından herhangi birinin kaldırılması AlexNet' in performansını büyük ölçüde düşürebilmektedir. AlexNet, herhangi bir nesne algılama görevi için önde gelen bir mimaridir. Ayrıca yapay zekâ sorunlarının bilgisayarlı görme sektöründe çok büyük uygulamaları olabilmektedir. Derin öğrenmeyi daha yaygın olarak uygulanabilir hale getirmede önemli bir payı olan AlexNet, derin öğrenmeyi doğal dil işleme ve tıbbi görüntü analizi gibi bitişik alanlara getirmesiyle de karşımıza çıkabilmektedir.

3.6.4.3. GoogLeNet

Inception ağı özellikle evrişimli sinir ağları için, sinir ağları alanlarındaki en büyük atılımlardan biri olarak karşımıza çıkmaktadır. Inception ağının şu ana kadar Inception versiyon 1, 2 ve 3 olarak adlandırılan üç versiyonu bulunmaktadır. İlk versiyon sahaya 2014 yılında girerek GoogLeNet adını almıştır. GoogLeNet, Google' da çalışmakta olan bir ekip tarafından geliştirilmiştir. Bu ağ, ImageNet Large Scale Visual Recognition Challenge' de (ILSVRC) sınıflandırma ve algılama için yeni bir teknoloji oluşturmaktan sorumlu olmuştur. Bir ağ, çok sayıda derin katmanla oluşturulmuş olsa da

fazla uyum sorunuyla karşı karşıya kalabilmektedir. Bu sorunu çözmek için, ‘Evrişimlerle daha derine inmek’ araştırma makalesinin yazarları, aynı düzeyde çalışabilen birden çok boyutta filtrelere sahip olma fikriyle GoogLeNet mimarisi önermiştir. Bu fikirle, ağ derinleşmek yerine daha da genişlemektedir [83].

GoogLeNet mimarisi, 27 havuz katmanı dâhil olmak üzere 22 katman derinliğindedir. Toplamda doğrusal olarak yığılmış 9 başlangıç modülü vardır. Başlangıç modüllerinin uçları, küresel ortalama havuzlama katmanına bağlanmaktadır. Şekil 3.11’ de, tam GoogLeNet mimarisinin yakınlaştırılmış bir görüntüsü verilmiştir.



Şekil 3.11 GoogleNet mimarisi [83]

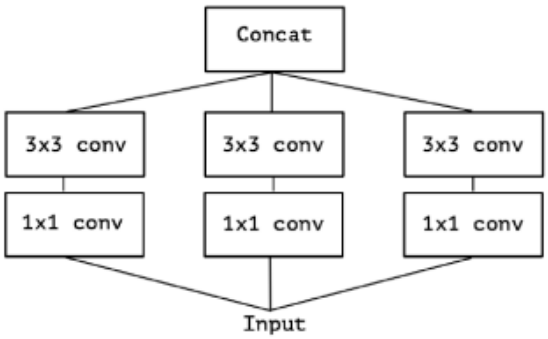
GoogleNet, yeterli miktarda model ve veri paralelliği ile dağıtılmış makine öğrenimi sistemleri kullanılarak eğitilmiştir. Eğitim, 0.9 momentumlu asenkron stokastik gradyan inişi ve öğrenme oranını her 8 devirde %4 azaltan sabit bir öğrenme oranı programı kullanılmıştır. Tablo 3.1’ de ILSVRC 2014 için performans sergileyen takımların sonuçları sunulmuş olup GoogLeNet, %6.67 hata oranı ile ilk sırada yer almıştır.

Tablo 3.1. ILSVRC 2014 için performans sergileyen takımların sonuçları

Takım	Yıl	Sıra	Hata (İlk 5)	Harici verileri kullanır
SuperVision	2012	1	%16.4	Hayır
SuperVision	2012	1	%15.3	Imagenet 22k
Clarifai	2013	1	%11.7	Hayır
Clarifai	2013	1	%11.2	Imagenet 22k
MSRA	2014	3	%7.35	Hayır
VGG	2014	2	%7.32	Hayır
GoogLeNet	2014	1	%6.67	Hayır

3.6.4.4. Xception

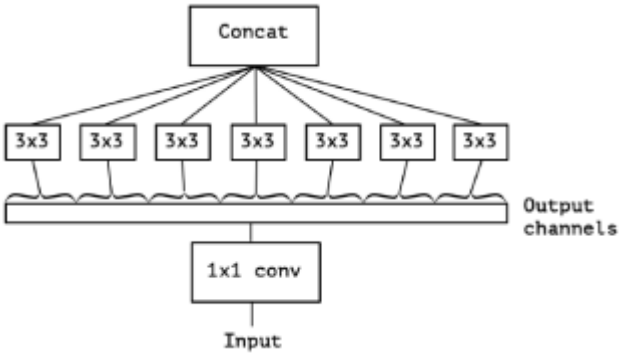
Xception adı extreme inception' dan gelmektedir. Bu nedenle öncelikle Inception' dan kısaca bahsetmek Xception mimarisini anlamaya yardımcı olacaktır. Nesne tanıma veya görüntü sınıflandırmasında algılanacak nesne bazı görüntülerde büyük, bazı görüntülerde ise küçük olabilmektedir. Başka bir deyişle, nesnenin boyutu farklı görüntülerde farklı boyutlarda olabilmektedir. Farklı nesne boyutları, evrişim süreci için filtre boyutunu belirlemeyi zorlaştırabilmektedir. Görüntülerde büyük görünen nesneler için büyük bir filtre boyutu, küçük nesneler için ise küçük bir filtre boyutu tercih edilmelidir. Inception mimarisi, girişte farklı boyutlarda birden fazla filtre kullanılmasını önererek, farklı büyüklükteki nesnelerin neden olduğu sorunlara çözüm sunmaktadır. Ayrıca bu modülün çıktısının tekrar başka bir başlangıç modülüne gönderilmesi önerilmektedir [84]. Şekil 3.12' de basitleştirilmiş bir Inception modülü verilmiştir.



Şekil 3.12. Basitleştirilmiş Inception modeli [84]

Xception mimarisinde, Inception mimarisinden farklı olarak, derinlemesine ayrılabilir evrişim ile hemen hemen aynı bir evrişim işlemi kullanılmaktadır. Bu tür evrişim, derin bir evrişim ve onu takip eden noktasal bir evrişim içermektedir. Derinlemesine evrişimde her filtre bağımsız olarak giriş görüntüsünün yalnızca bir kanalını işlemekte ve noktasal evrişimde, 1x1 boyutlu filtre, girişin her bir noktasını yinelemektedir.

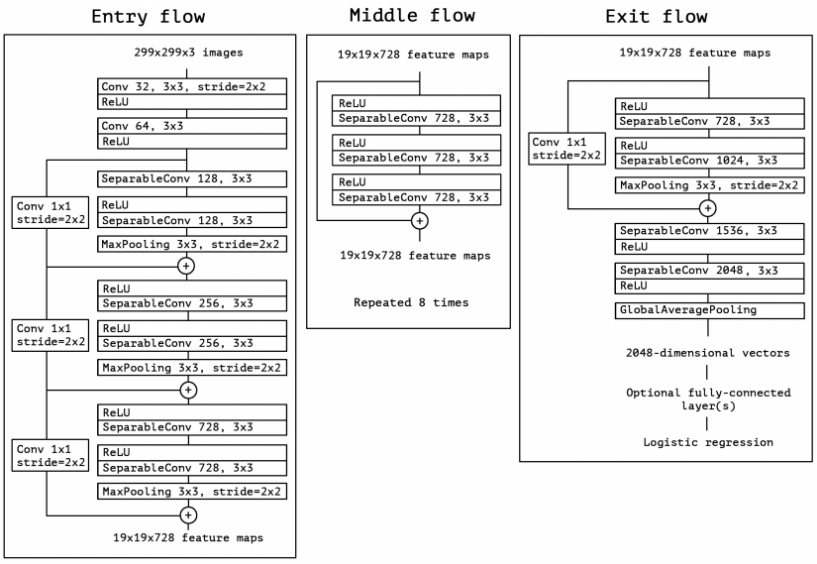
Xception mimarisindeki modül, farklı sırada derinlemesine ayrılabilir evrişim kullanılmaktadır. Şekil 3.13' te görüldüğü gibi, önce 1x1 evrişim, ardından kanal bazında uzaysal evrişim kullanılmaktadır.



Şekil 3.13. Inception modülünün ekstrem versiyonu [84]

Xception mimarisi üç yapıdan oluşmaktadır bunlar giriş akışı, orta akış ve çıkış akışıdır. Bu üç yapı toplamda 36 evrişim katmanı içeren 14 modülden (sırasıyla 4, 8 ve 2 modül) oluşmaktadır. Modüllerde giriş akışının ilk modülü ve çıkış akışının son modülü dışında kalan bağlantılar bulunmaktadır. Xception mimarisi, 4 modül içeren ve her modülün iki evrişim katmanına sahip olduğu giriş akışı ile başlamaktadır. Birinci modülde 3x3 filtre boyutunda 32 ve 64 filtre ile evrişim gerçekleştirilmektedir. Bu akıştaki diğer üç modülde ise 3x3 filtre boyutunda 128, 256 ve 728 filtreler ile ayrılabilir evrişim gerçekleştirilmektedir.

Giriş akışı, 299x299x3 boyutundaki görüntüleri girdi olarak kabul etmekte ve çıktıda 19x19x728 boyutunda bir özellik haritası oluşturmaktadır. Orta akışta, 3x3 boyutunda 728 filtre ile üç ayrılabilir evrişim işlemi 8 kez tekrarlanmaktadır. Orta akış, çıktıda 19x19x728 özellik haritası oluşturmaktadır. Orta akışın çıktısı olan özellik haritası, çıkış akışına girdi olarak verilmektedir. Çıkış akışının iki modülü bulunmaktadır. İlk modülde 3x3 boyutlarında 728 ve 1024 filtreler ile ayrılabilir evrişim, son modülde ise 1536 ve 2048 filtreler ile gerçekleştirilmektedir. Daha sonra, tam bağlantılı katmanların eklenmesiyle mimari sonlandırılmaktadır. Xception mimarisi ile ilgili akışlar ve modüller Şekil 3.14’ te verilmiştir.



Şekil 3.14. Xception mimarisi akış ve modülleri [84]

3.7. Eğitim Ortamı Donanım Özellikleri

Yapay sinir ağlarının eğitiminde kullanılan bilgisayara ait donanım özellikleri Tablo 3.2' de verilmiştir.

Tablo 3.2. Kullanılan donanım özellikleri

İşletim Sistemi	Windows 10
İşlemci	Intel(R) Xeon(R) E-2124 CPU @ 3.30GHz 3.31 GHz
RAM	128 GB
Ekran Kartı	NVidia RTX 4000 Quadro 8GB GDDR6
Sistem Türü	64 bit işletim sistemi, x64 tabanlı işlemci

3.8. Görüntü İşleme

Geliştirilen uygulamada hastalığın göz doktorları tarafından daha net bir şekilde ayırt edilebilmesi amacıyla OKT görüntüleri üzerinde birtakım görüntü işleme teknikleri uygulanmıştır. Bu bölümde geliştirilen uygulamada kullanılan görüntü işleme teknikleri hakkında bilgi verilmiştir.

3.8.1. Kirsch Operatörü

Adını bilgisayar bilimcisi Russell A. Kirsch' ten alan Kirsch operatörü veya Kirsch' in pusula çekirdeği, önceden belirlenmiş birkaç yönde maksimum kenar kuvvetini bulan doğrusal olmayan bir kenar algılamadır [85]. Operatör tek bir çekirdek maskesi almakta ve onu 8 pusula yönü boyunca Kuzey (N), doğu (E), güney (S), batı (W), kuzey batı (NW), güney batı (SW), güney doğu (SE) ve kuzey doğu (NE) olmak üzere 45 derecelik artışlarla döndürmektedir [86]. Kirsch maskeleri Şekil 3.15' te verilmiştir.

$$N=\begin{bmatrix}-3 & -3 & 5\\ -3 & 0 & 5\\ -3 & -3 & 5\end{bmatrix}\quad W=\begin{bmatrix}5 & 5 & 5\\ -3 & 0 & -3\\ -3 & -3 & -3\end{bmatrix}\quad S=\begin{bmatrix}5 & -3 & -3\\ 5 & 0 & -3\\ 5 & -3 & -3\end{bmatrix}\quad E=\begin{bmatrix}-3 & -3 & -3\\ -3 & 0 & -3\\ 5 & 5 & 5\end{bmatrix}$$

$$NW=\begin{bmatrix}-3 & 5 & 5\\ -3 & 0 & 5\\ -3 & -3 & -3\end{bmatrix}\quad SW=\begin{bmatrix}5 & 5 & -3\\ 5 & 0 & -3\\ -3 & -3 & -3\end{bmatrix}\quad SE=\begin{bmatrix}-3 & -3 & -3\\ 5 & 0 & -3\\ 5 & 5 & -3\end{bmatrix}\quad NE=\begin{bmatrix}-3 & -3 & -3\\ -3 & 0 & 5\\ -3 & 5 & 5\end{bmatrix}$$

Şekil 3.15. Kirsch maskeleri [86]

Tüm yönlerdeki maksimum büyüklükler hesaplanmakta ve kenar büyüklüğü olarak adlandırılmaktadır. Her maskeleme tarafından kullanılan bu 8 maske, belirli kenar yönlerine büyük tepki vermektedir. Tüm 8 yönün maksimum ve minimum değeri bu noktanın çıkış değerine ayarlanmaktadır. Böylece maksimum ve minimum değerlerin ortalaması bulunmaktadır [87]. Kirsch metodu uygulanmış görüntü ve orijinal görüntüsü Şekil 3.16' da verilmiştir.



Şekil 3.16. Kirsch metodu uygulanmış görüntü

3.8.2. Gauss Yumuşatma Operatörü

Günümüzde herhangi bir cerrahi müdahale olmadan iç organları görselleştirmek mümkün hale gelmiştir. Bununla birlikte, gürültünün varlığı kaçınılmaz olmaktadır. Bazen gürültü, görüntü alma sürecinin doğasında vardır. Örneğin aşırı gürültü nedeniyle görüntüde küçük bir tümör gibi küçük bir yapı kaybolursa, bu uzmanın teşhisini etkileyebilmektedir. Bu nedenle, verilerin kullanılmadan önce filtrelenmesi gerekmektedir [88].

Gauss filtresi, bir görüntüdeki gürültüyü yumuşatmak, bulanıklaştırma veya ortadan kaldırmak amacıyla kullanılan birçok bilgisayarlı görü algoritmasının ön işleme aşaması olarak kullanılan bir evrişim tekniğidir [89]. Gauss filtresi, piksel değerinin Gauss işlevi kullanılarak hesaplandığı doğrusal bir düşük geçiş filtresidir.

2 Boyutlu (2D) gauss işlevi, Denklem 3.1' de gösterildiği gibi tanımlanan iki adet tek boyutlu (1D) gauss işlevinin ürünüdür [90].

$$G(x,y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \tag{3.1}$$

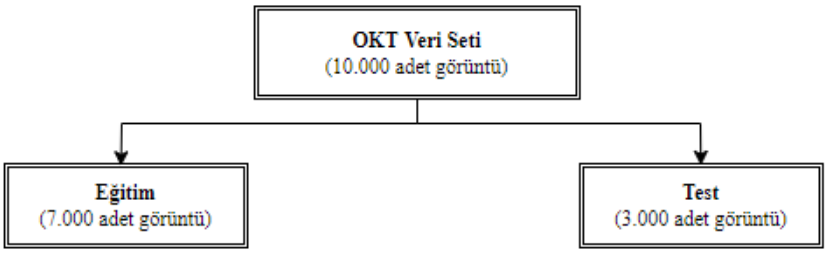
Verilen denklemde (x,y) koordinatlardır ve σ hauss dağılımının standart sapmasıdır. Gauss filtresi uygulanmış örnek görüntü ve orijinal görüntüsü Şekil 3.17' de verilmiştir.



Şekil 3.17 Gauss filtresi uygulanmış görüntü

BÖLÜM 4. GERÇEKLEŞTİRİLEN ÇALIŞMA VE PERFORMANS SONUÇLARI

Bu çalışmada, YBMD hastalığı bulunan ve bulunmayan vakaların göze ait etiketlenmiş OKT görüntüleri ResNet50, AlexNet, GoogLeNet ve Xception derin öğrenme modelleri kullanılarak eğitilmiş ve test edilmiştir. Kullanılan modeller, derin öğrenme kütüphaneleri aracılığı ile Matlab geliştirme ortamı üzerinde eğitilmiş ve test edilmiştir. Veri seti Şekil 4.1' de gösterildiği gibi bilgisayarlı görüde en uygun oran olarak belirtilen %70 eğitim ve %30 test oranında bölünmüştür [91].



Şekil 4.1. Veri setinin kullanımı

4.1. Kullanılan Veri Seti

Çalışmada kullanılan göze ait 50.000 adet OKT görüntü veri seti Kafkas Üniversitesi Sağlık Araştırma ve Uygulama Merkezi' nin ilgili biriminden etik kurul izinleri alınarak temin edilmiştir. Veri setinde bulunan toplam 50.000 adet görüntü anonimleştirilerek alanında uzman göz doktorları aracılığı ile hastalık tespit edilen 2.500 adet Drusen, 2.500 adet Fibrovasküler PED, 2.500 adet Seröz PED ve hastalık tespit edilmeyen 2.500 adet Normal olmak üzere eşit sayıda 4 adet kategoriye ayrılmıştır. Veri setinin temin edildiği OKT cihazı görüntüsü Şekil 4.2' de verilmiştir.



Şekil 4.2. OKT cihazı görseli

4.2. Değerlendirme Metrikleri

Çalışmada kullanılacak modellerin eğitim süreci sonunda elde edilen başarı ve performansının ölçümlere uygun olarak değerlendirilmesi gerekmektedir. Bu nedenle modellerin performansları farklı değerlendirme metrikleri ile gösterilmektedir. Bu bölümde çalışma için kullanılacak modellerin değerlendirilmeleri amacıyla gereken araçlar hakkında bilgiler verilmiştir.

4.2.1. Hata Matrisi

Hata matrisi, bir sınıflandırma algoritmasının performansını özetlemek için kullanılan bir tekniktir. Her sınıfta eşit olmayan sayıda gözlem varsa veya veri kümesinde ikiden fazla sınıf varsa, sınıflandırma doğruluğu tek başına yanıltıcı olabilmektedir. Hata matrisini hesaplamak, sınıflandırma modelinin neyi doğru yaptığı ve ne tür hatalar yaptığı konusunda fikir vermektedir [92].

Hata matrisi, bir sınıflandırma sistemi tarafından yapılan gerçek ve tahmin edilen sınıflandırmalar hakkında bilgi içermektedir. Bu tür sistemlerin performansı genellikle matristeki veriler kullanılarak değerlendirilmektedir. Tablo 4.1’ de iki sınıflı bir sınıflandırıcı için hata matrisi verilmiştir.

Tablo 4.1. Hata Matrisi

		Tahmin Edilen Sınıf	
		Negatif	**Pozitif**
Gerçek Sınıf	**Negatif**	a	b
	Pozitif	c	d

- a, bir örneğin negatif olduğuna dair doğru tahminlerin sayısı,
- b, bir örneğin pozitif olduğuna dair yanlış tahminlerin sayısı,
- c, bir örneğin negatif olduğu tahminlerin yanlış sayısıdır ve
- d, bir örneğin pozitif olduğu doğru tahminlerin sayısıdır.

Doğruluk, doğru olan toplam tahmin sayısının oranıdır. Denklem 4.1' de doğruluk değerinin hesaplanma formülü verilmiştir.

$$Doğruluk = \frac{a + d}{a + b + c + d} \tag{4.1}$$

Gerçek pozitif oran (TP), doğru bir şekilde tanımlanmış pozitif vakaların oranıdır. Denklem 4.2' de gerçek pozitif oran değerinin hesaplanma formülü verilmiştir.

$$\text{Gerçek Pozitif Oran} = \frac{d}{c + d} \tag{4.2}$$

Yanlış pozitif oranı (FP), yanlış bir şekilde pozitif olarak sınıflandırılan negatif vakaların oranıdır. Denklem 4.3' te yanlış pozitif oran değerinin hesaplanma formülü verilmiştir.

$$\text{Yanlış Pozitif Oran} = \frac{b}{a+b} \tag{4.3}$$

Gerçek negatif oran (TN), doğru şekilde sınıflandırılan negatif vakaların oranıdır. Denklem 4.4' te gerçek negatif oran değerinin hesaplanma formülü verilmiştir.

$$\text{Gerçek Negatif Oran} = \frac{a}{a+b} \tag{4.4}$$

Yanlış negatif oranı (FN), yanlış bir şekilde negatif olarak sınıflandırılan pozitif vakaların oranıdır. Denklem 4.5' te yanlış negatif oran değerinin hesaplanma formülü verilmiştir.

$$\text{Yanlış Negatif Oran} = \frac{c}{c+d} \tag{4.5}$$

Son olarak, kesinlik (P), tahmin edilen pozitif vakaların doğru olan oranıdır. Denklem 4.6' da kesinlik oran değerinin hesaplanma formülü verilmiştir.

$$\text{Kesinlik} = \frac{d}{b+d} \tag{4.6}$$

4.2.2. Doğruluk

Doğruluk (Accuracy), doğru tahmin edilen değerlerin toplam tahmin değerlerine oranı olarak tanımlanmaktadır. Denklem 4.7' de doğruluk değerinin hesaplanma formülü verilmiştir.

$$Doğruluk = \frac{Doğru\ Tahminler}{Toplam\ Tahminler} \tag{4.7}$$

4.2.3. Kesinlik

Kesinlik (Precision), gerçek pozitif değerinin gerçek pozitif ve yanlış pozitif değerinin toplamına oranı olarak tanımlanmaktadır. Denklem 4.8' de doğruluk değerinin hesaplanma formülü verilmiştir.

$$Kesinlik = \frac{Gerçek\ Pozitif}{Gerçek\ Pozitif + Yanlış\ Pozitif} \tag{4.8}$$

4.2.4. Duyarlılık

Duyarlılık (Sensivity), gerçek pozitif değerinin gerçek pozitif ve yanlış negatif değerinin toplamına oranı olarak tanımlanmaktadır. Denklem 4.9' da duyarlılık değerinin hesaplanma formülü verilmiştir.

$$Duyarlılık = \frac{Gerçek\ Pozitif}{Gerçek\ Pozitif + Yanlış\ Negatif} \tag{4.9}$$

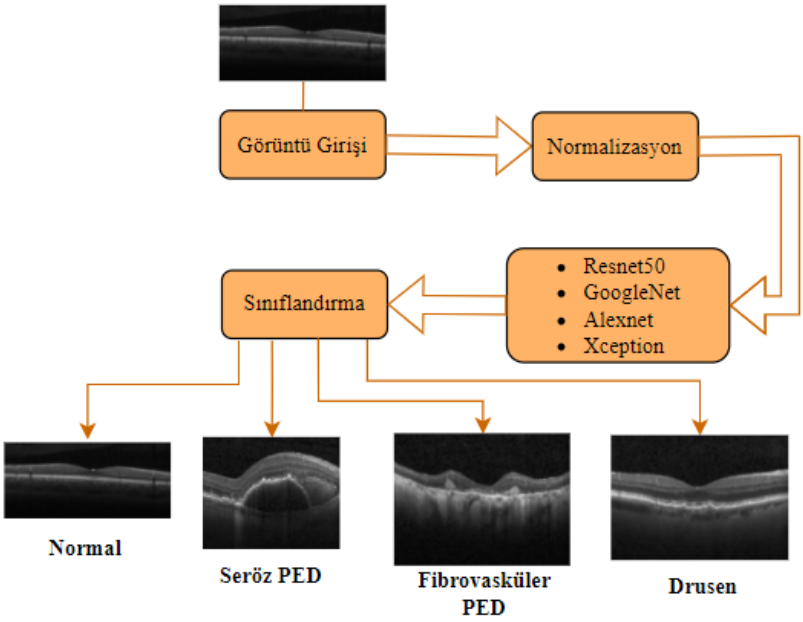
4.2.5. F-Skor

Bilgi erişim topluluğunda iyi bilinen bir kriter, kesinlik ve hatırlamanın harmonik ortalaması olarak tanımlanan F-skorudur. Denklem 4.10' da F-skor değerinin hesaplanma formülü verilmiştir.

$$F\ Skor = \frac{2 * Gerçek\ Pozitif}{(Gerçek\ Pozitif + Yanlış\ Negatif) + (Gerçek\ Pozitif + Yanlış\ Pozitif)} \tag{4.10}$$

4.3. Veri Setinin Performans Karşılaştırması

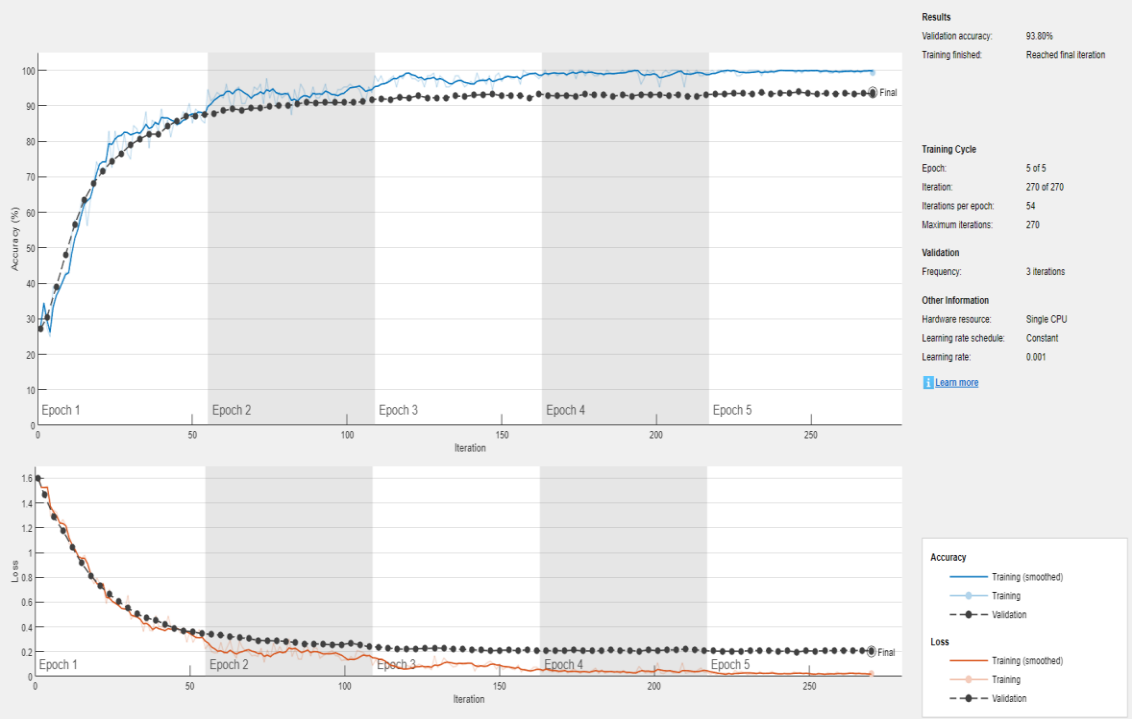
Elde edilen veri seti Bölüm 3.6' da ayrıntılı bir şekilde anlatılan ResNet50, GoogLeNet, AlexNet ve Xception derin öğrenme modelleri ile eğitilmiş ve sınıflandırılmıştır. Derin öğrenme akış şeması Şekil 4.3' te verilmiştir. Bu bölümde ayrıca eğitilen derin öğrenme ağlarının performans sonuçları hakkında ayrıntılı analiz sonuçları hakkında bilgi verilmektedir.



Şekil 4.3. Derin öğrenme akış şeması

4.3.1. ResNet50 Derin Öğrenme Modelinin Çalışma Sonuçları

Elde edilen veri seti ile ResNet50 derin öğrenme modelinin en iyi doğruluk sonucuna ulaşması amacı ile yığın boyutu 270 ve epok sayısı 5 olacak şekilde eğitim süreci başlatılmıştır. Süreç yaklaşık olarak 18 saat 16 dakika sürmüş ve başarı olarak %93.80 doğruluk oranı elde edilmiştir. Buna göre ResNet50 modeli kullanılan veri setinde bulunan OKT görüntülerini %93.80 oranında sınıflandırma yapabilmiştir. Şekil 4.4' te kullanılan veri setinin ResNet50 derin öğrenme modeli kullanılarak eğitimi sonunda elde ettiği doğruluk ve kayıp oranının grafiği verilmiştir.



Şekil 4.4. ResNet50 derin öğrenme modelinin eğitim grafiği

Beklenildiği gibi doğruluk oranının her bir devirde arttığı ve kayıp oranının her bir devir sonrası azaldığı görülmüştür. Ayrıca eğitim sonucu ResNet50 modeline ait hata matrisi Şekil 4.5' te verilmiştir.



Şekil 4.5. Eğitim sonucu ResNet50 derin öğrenme modeli hata matrisi

ResNet50 modeli ile eğitim sonucu oluşturulan hata matrisinde kategori özelinde başarı oranları görülmektedir. Tablo 4.2' de ise Bölüm 4.2.1' de detaylı açıklaması yapılan kategorilere ait TP, FP, FN ve TN değerleri verilmiştir.

Tablo 4.2. ResNet50 ağının hesaplanan TP, FP, FN ve TN değerleri

	Drusen	Fibrovasküler Ped	Normal	Seröz Ped	Genel
TP	677	720	714	703	2.814
FP	73	30	36	47	186
FN	54	35	50	38	177
TN	2.187	2.215	2.200	2.212	0

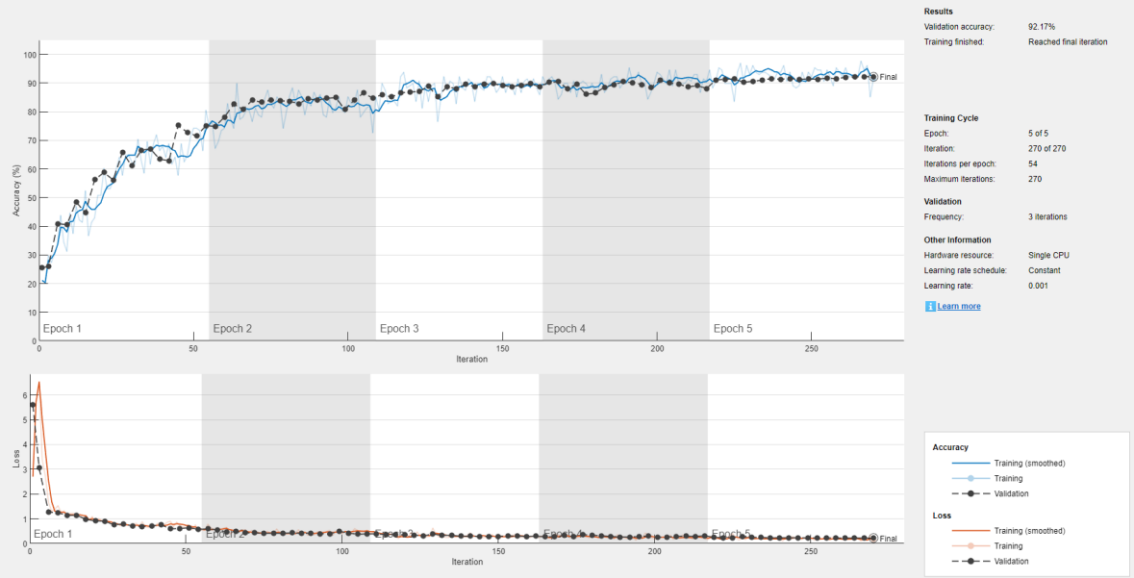
Resnet50 derin öğrenme modeline ait doğruluk, duyarlılık, kesinlik ve F-skor değerleri hakkında bilgi Tablo 4.3' te verilmiştir.

Tablo 4.3. ResNet50 ağının hesaplanan parametreleri

Ağ	Doğruluk	Duyarlılık	Kesinlik	F-Skor
Resnet50	0.93	0.94	0.93	0.94

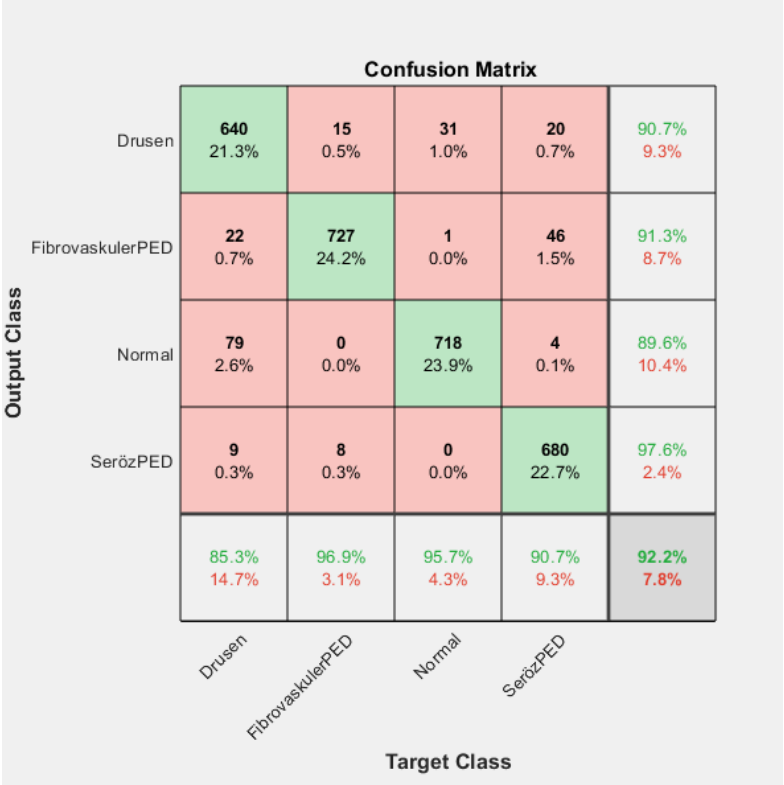
4.3.2. AlexNet Derin Öğrenme Modelinin Çalışma Sonuçları

Elde edilen veri seti ile AlexNet derin öğrenme modelinin en iyi doğruluk sonucuna ulaşması amacı ile yığın boyutu 270 ve epok sayısı 5 olacak şekilde eğitim süreci başlatılmıştır. Süreç yaklaşık olarak 2 saat 10 dakika sürmüş ve başarı olarak %92.17 doğruluk oranı elde edilmiştir. Buna göre AlexNet modeli kullanılan veri setinde bulunan OKT görüntülerini %92.17 oranında sınıflandırma yapabilmiştir. Şekil 4.6' da kullanılan veri setinin AlexNet derin öğrenme modeli kullanılarak eğitimi sonunda elde ettiği doğruluk ve kayıp oranının grafiği verilmiştir.



Şekil 4.6. AlexNet derin öğrenme modelinin eğitim grafiği

Beklenildiği gibi doğruluk oranının her bir devirde arttığı ve kayıp oranının her bir devir sonrası azaldığı görülmüştür. Ayrıca eğitim sonucu AlexNet modeline ait hata matrisi Şekil 4.7' de verilmiştir.



Şekil 4.7. Eğitim sonucu AlexNet derin öğrenme modeli hata matrisi

AlexNet modeli ile eğitim sonucu oluşturulan hata matrisinde kategori özelinde başarı oranları görülmektedir. Ayrıca Tablo 4.4' te kategorilere ait Bölüm 4.2.1' de detaylı açıklaması yapılan TP, FP, FN ve TN değerleri verilmiştir.

Tablo 4.4. AlexNet ağının hesaplanan TP, FP, FN ve TN değerleri

	Drusen	Fibrovasküler Ped	Normal	Seröz Ped	Genel
TP	640	727	718	680	2.765
FP	110	23	32	70	235
FN	66	69	83	17	235
TN	2.184	2.181	2.167	2.233	0

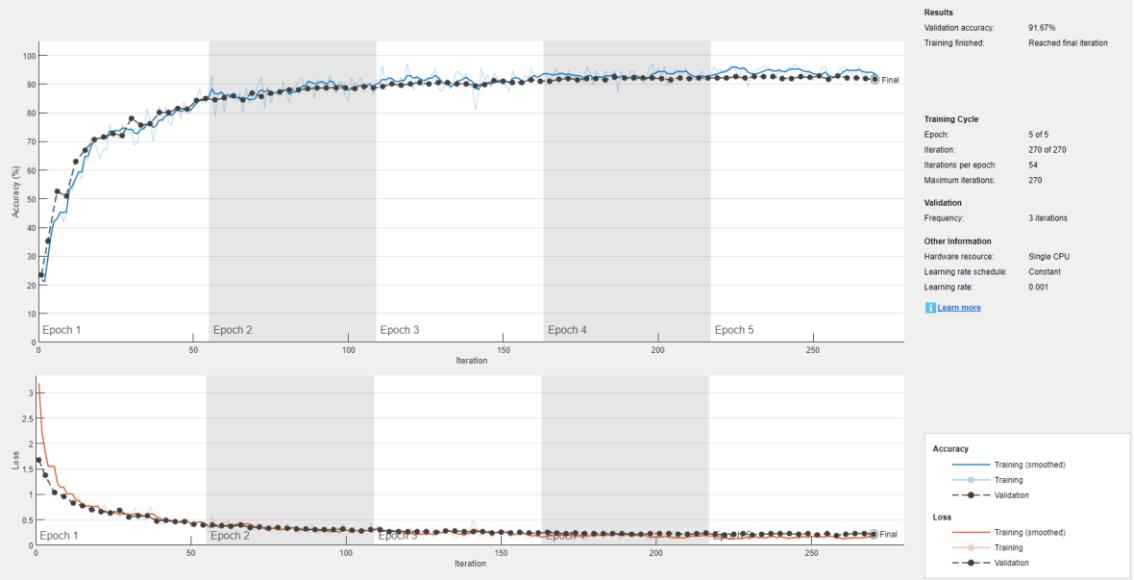
AlexNet derin öğrenme modeline ait doğruluk, duyarlılık, kesinlik ve F-skor değerleri hakkında bilgi Tablo 4.5' te verilmiştir.

Tablo 4.5. AlexNet ağının hesaplanan parametreleri

Ağ	Doğruluk	Duyarlılık	Kesinlik	F-Skor
AlexNet	0.92	0.92	0.92	0.92

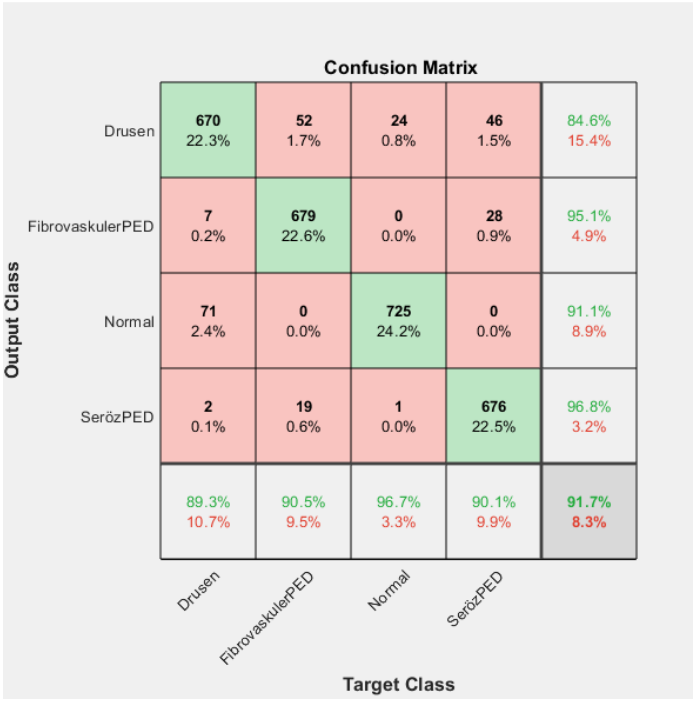
4.3.3. GoogLeNet Derin Öğrenme Modelinin Çalışma Sonuçları

Elde edilen veri seti ile GoogLeNet derin öğrenme modelinin en iyi doğruluk sonucuna ulaşması amacı ile yığın boyutu 270 ve epok sayısı 5 olacak şekilde eğitim süreci başlatılmıştır. Süreç yaklaşık olarak 3 saat 51 dakika sürmüş ve başarı olarak %91.67 doğruluk oranı elde edilmiştir. Buna göre GoogLeNet modeli kullanılan veri setinde bulunan OKT görüntülerini %91.67 oranında sınıflandırma yapabilmiştir Şekil 4.8' de kullanılan veri setinin GoogLeNet derin öğrenme modeli kullanılarak eğitimi sonunda elde ettiği doğruluk ve kayıp oranının grafiği verilmiştir.



Şekil 4.8. GoogLeNet derin öğrenme modelinin eğitim grafiği

Beklenildiği gibi doğruluk oranının her bir devirde arttığı ve kayıp oranının her bir devir sonrası azaldığı görülmüştür. Ayrıca eğitim sonucu GoogLeNet modeline ait hata matrisi Şekil 4.9' da verilmiştir.



Şekil 4.9. Eğitim sonucu GoogLeNet derin öğrenme modeli hata matrisi

GoogLeNet modeli ile eğitim sonucu oluşturulan hata matrisinde kategori özelinde başarı oranları görülmektedir. Ayrıca Tablo 4.6' da kategorilere ait Bölüm 4.2.1' de detaylı açıklaması yapılan TP, FP, FN ve TN değerleri verilmiştir.

Tablo 4.6. GoogLeNet ağının hesaplanan TP, FP, FN ve TN değerleri

	Drusen	Fibrovasküler Ped	Normal	Seröz Ped	Genel
TP	670	679	725	676	2.750
FP	80	71	25	74	250
FN	122	35	71	22	250
TN	2.128	2.215	2.179	2.228	0

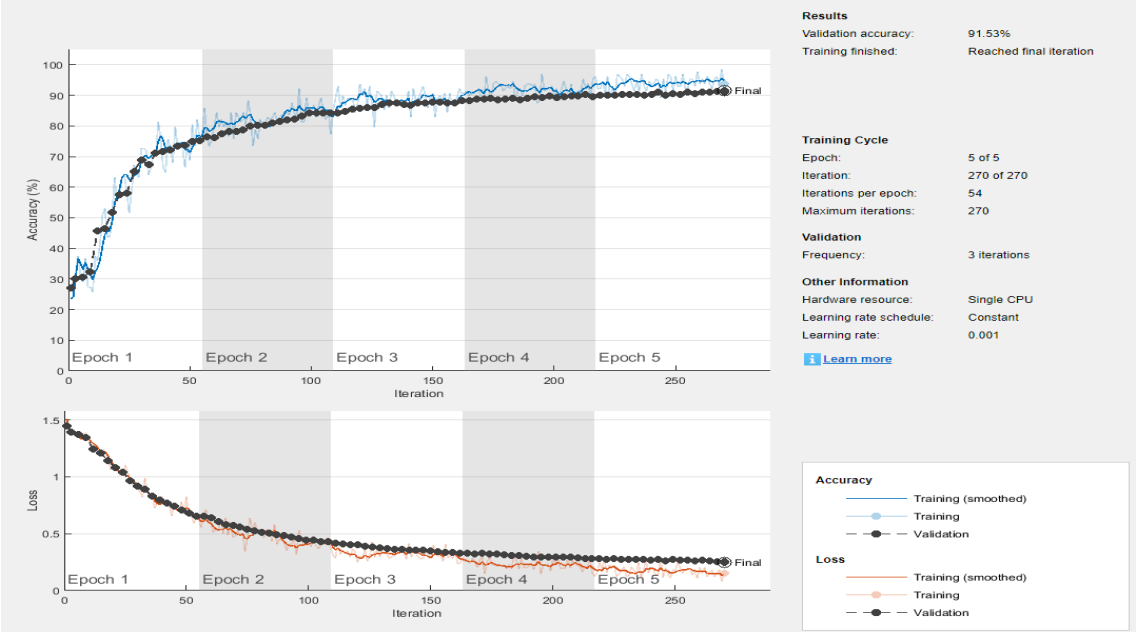
GoogLeNet derin öğrenme modeline ait doğruluk, duyarlılık, kesinlik ve F-skor değerleri hakkında bilgi Tablo 4.7' de verilmiştir.

Tablo 4.7. GoogLeNet ağının hesaplanan parametreleri

Ağ	Doğruluk	Duyarlılık	Kesinlik	F-Skor
GoogLeNet	0.91	0.91	0.91	0.91

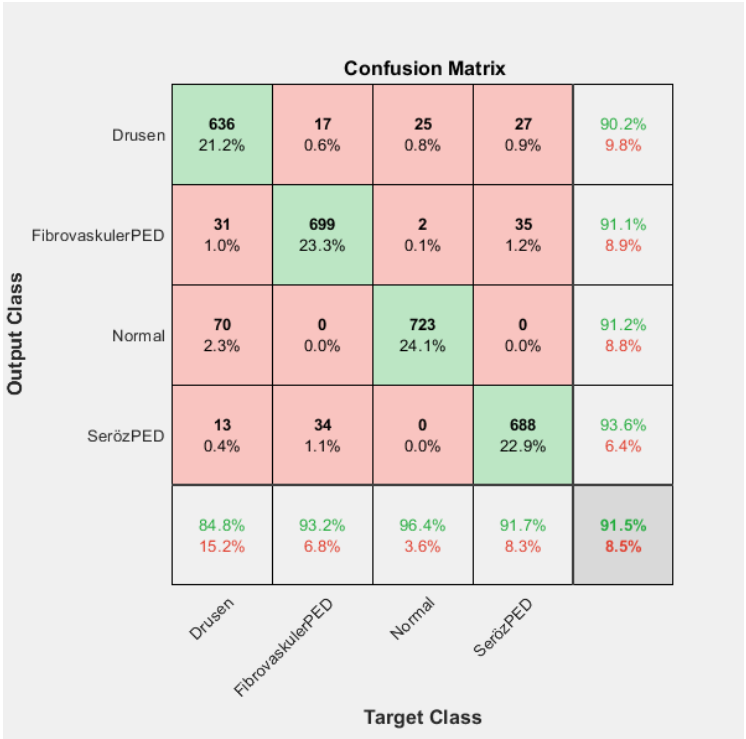
4.3.4. Xception Derin Öğrenme Modelinin Çalışma Sonuçları

Elde edilen veri seti ile Xception derin öğrenme modelinin en iyi doğruluk sonucuna ulaşması amacı ile yığın boyutu 270 ve epok sayısı 5 olacak şekilde eğitim süreci başlatılmıştır. Süreç yaklaşık olarak 30 saat 55 dakika sürmüş ve başarı olarak %91.53 doğruluk oranı elde edilmiştir. Buna göre Xception modeli kullanılan veri setinde bulunan OKT görüntülerini %91.53 oranında sınıflandırma yapabilmiştir. Şekil 4.10' da kullanılan veri setinin Xception derin öğrenme modeli kullanılarak eğitimi sonunda elde ettiği doğruluk ve kayıp oranının grafiği verilmiştir.



Şekil 4.10. Xception derin öğrenme modelinin eğitim grafiği

Beklenildiği gibi doğruluk oranının her bir devirde arttığı ve kayıp oranının her bir devir sonrası azaldığı görülmüştür. Ayrıca eğitim sonucu Xception modeline ait hata matrisi Şekil 4.11' de verilmiştir.



Şekil 4.11. Eğitim sonucu Xception derin öğrenme modeli hata matrisi

Xception modeli ile eğitim sonucu oluşturulan hata matrisinde kategori özelinde başarı oranları görülmektedir. Ayrıca Tablo 4.8' de kategorilere ait Bölüm 4.2.1' de detaylı açıklaması yapılan TP, FP, FN ve TN değerleri verilmiştir.

Tablo 4.8. Xception ağının hesaplanan TP, FP, FN ve TN değerleri

	Drusen	Fibrovasküler Ped	Normal	Seröz Ped	Genel
TP	636	699	723	688	2746
FP	114	51	27	62	254
FN	69	68	70	47	254
TN	2250	2182	2180	2203	0

Xception derin öğrenme modeline ait doğruluk, duyarlılık, kesinlik ve F-skor değerleri hakkında bilgi tabloda verilmiştir.

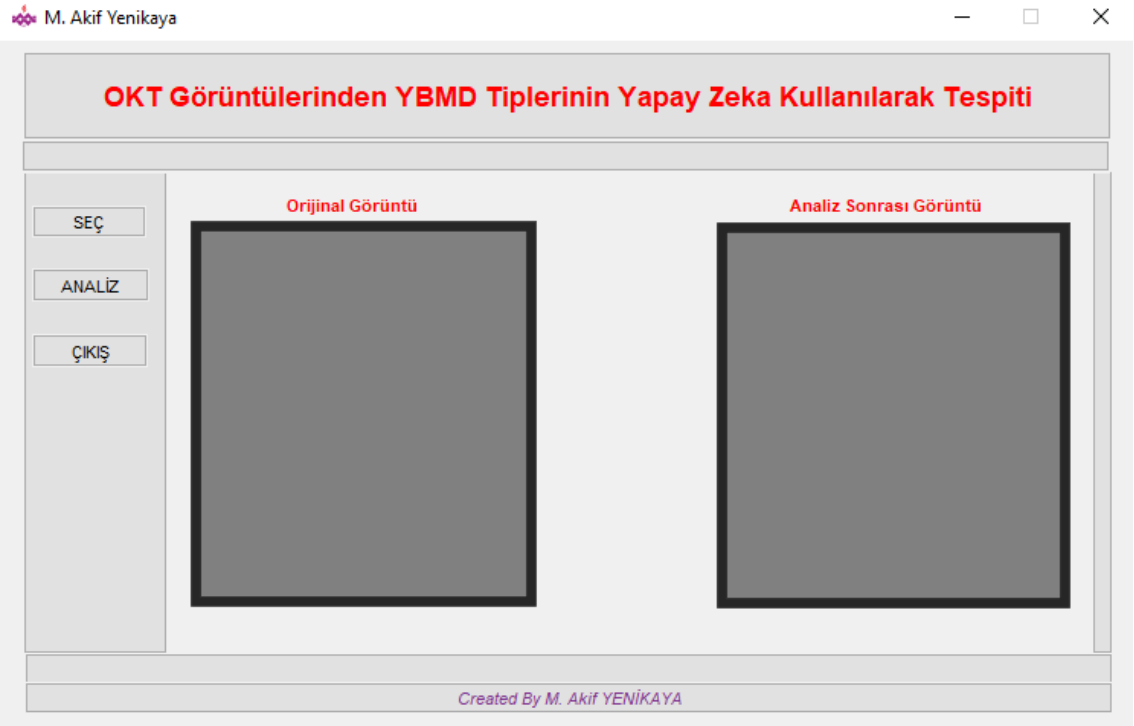
Tablo 4.9. Xception ağının hesaplanan parametreleri

Ağ	Doğruluk	Duyarlılık	Kesinlik	F-Skor
Xception	0.91	0.91	0.91	0.91

Modellerle ilgili yapılan deney sonuçlarına göre ResNet50, Alexnet, GoogleNet ve Xception derin öğrenme modelleri ortalama doğruluk değerleri sırasıyla %93.8, %92.17, %91.67 ve %91.53 olarak elde edilmiştir. ResNet50 diğer üç yönteme göre kullanılan veri setinde daha iyi sonuçlar verdiği tespit edildiğinden dolayı geliştirilen uygulamada ResNet50 modeli kullanılmıştır.

4.4. Gerçekleştirilen Uygulama

Matlab geliştirme ortamı kullanılarak YBMD hastalığının ve hastalık tiplerinin erken teşhisi için uzmanlara yardımcı olacak bir uygulama geliştirilmiştir. Uygulama gerçekleştirme aşamasında çalışmada doğruluk oranı en yüksek olarak tespit edilen ResNet50 derin öğrenme modelinin eğitim sonrasında çıktı olarak elde edilen sınıflandırma dosyası kullanılmıştır. Geliştirilen uygulamanın arayüzü Şekil 4.12' de verilmiştir.



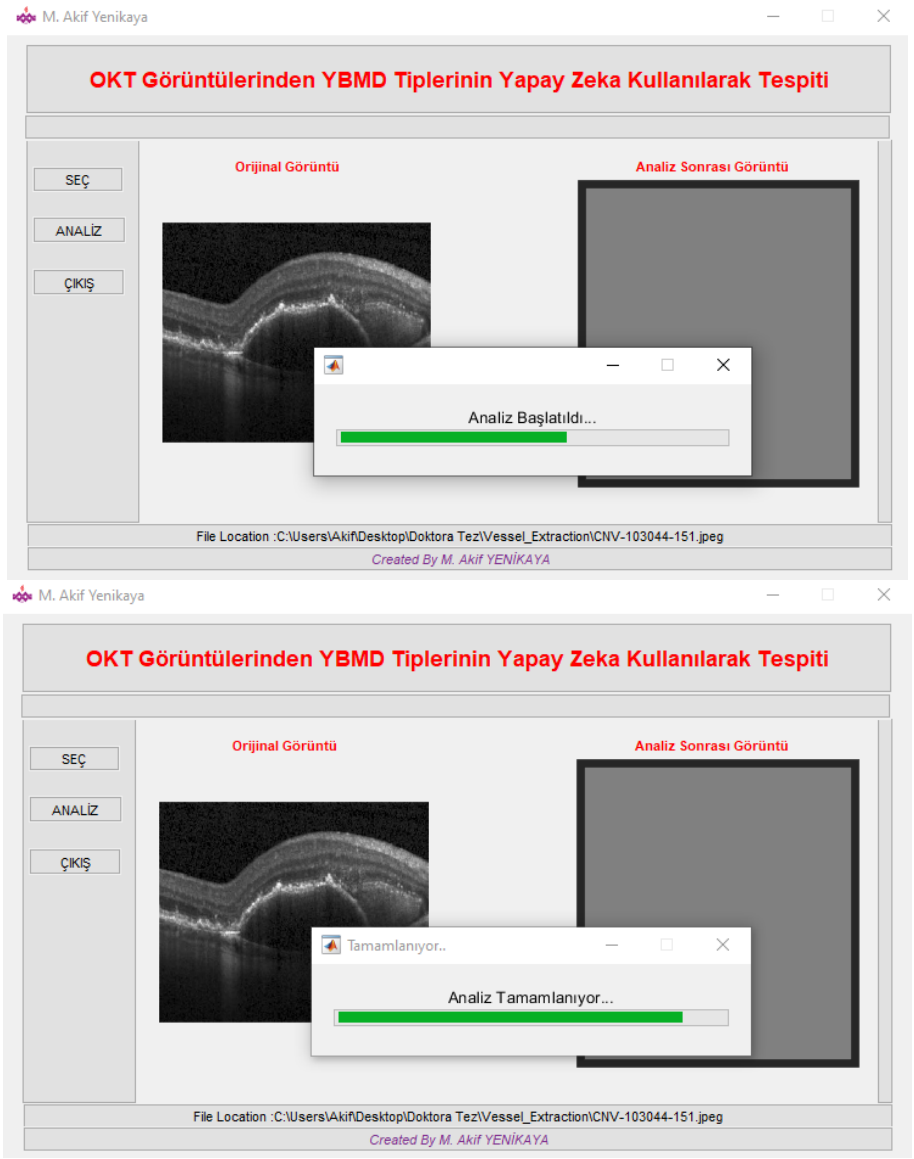
Şekil 4.12. Geliştirilen uygulama arayüzü

Uygulamada bulunan ‘SEÇ’ butonuna tıklandığı zaman açılan ekranda analizinin yapılması istenilen OKT görüntüsü seçilmektedir. OKT görüntüsü seçildikten sonra gelen ekranın görüntüsü Şekil 4.13’ te verilmektedir.



Şekil 4.13. OKT görüntüsü seçildikten sonra gelen ekranın görüntüsü

Seçilen OKT görüntüsü uygulamadaki ‘Orijinal Görüntü’ alanına boyutları otomatik bir şekilde ayarlanarak aktarılmaktadır. Sonraki aşamada ‘ANALİZ’ butonuna tıklanıldığı zaman analiz başlamaktadır. Analiz durumunun tespit edilmesi amacıyla uygulamada Şekil 4.14’ te gösterilen işlem durumunu belirten araçlar kullanılmıştır.

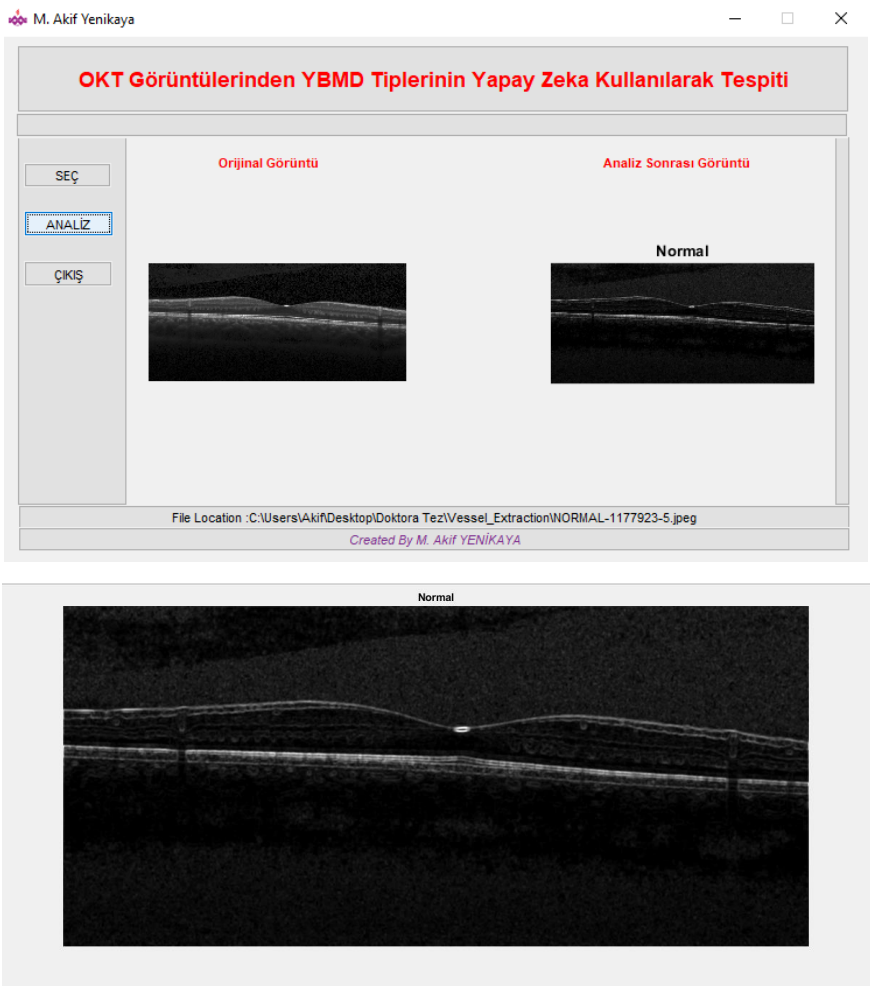


Şekil 4.14. Analiz esnasında oluşan ekran görüntüsü

4.5. Gerçekleştirilen Uygulama Örnek Çıktıları

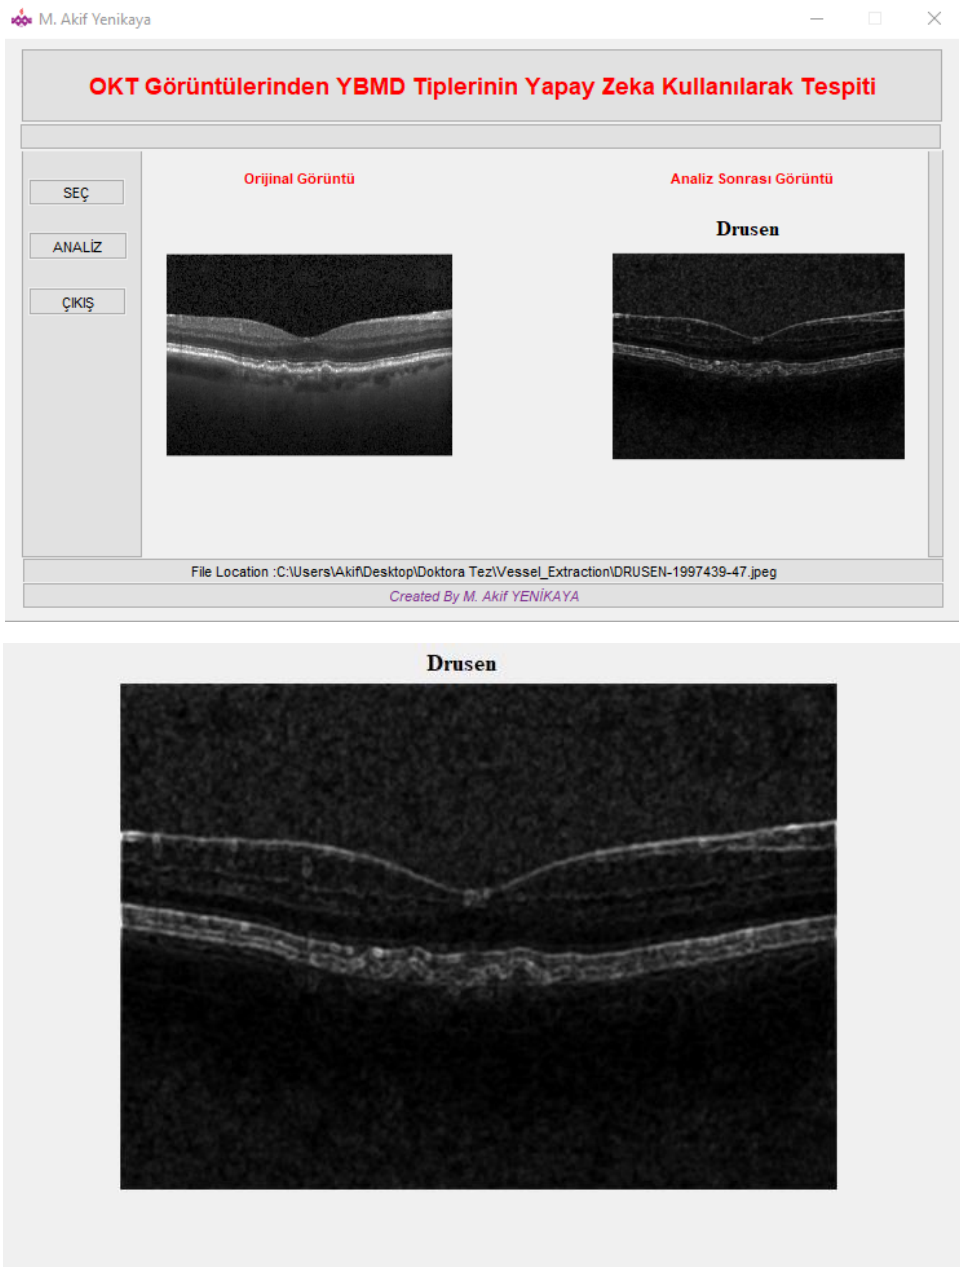
Uygulama çıktısında Bölüm 3.8’ de ayrıntılı bir şekilde anlatılan görüntü işleme teknikleri uygulanmış görüntü, boyutları otomatik bir şekilde ayarlanarak ‘Analiz Sonrası Görüntü’ alanına aktarılmaktadır. YBMD hastalığının bulunup bulunmaması, bulunuyor ise bu hastalığın tiplerine göre tespit edilen durum görüntünün üzerine gelecek şekilde ayarlanmıştır.

Derin öğrenme modellerinin eğitimi için kullanılan veri seti haricindeki test görüntülerinden örnek alınan bir YBMD hastalığı bulunmayan OKT görüntüsünün analiz sonrası program çıktıları Şekil 4.15’ de verilmiştir.



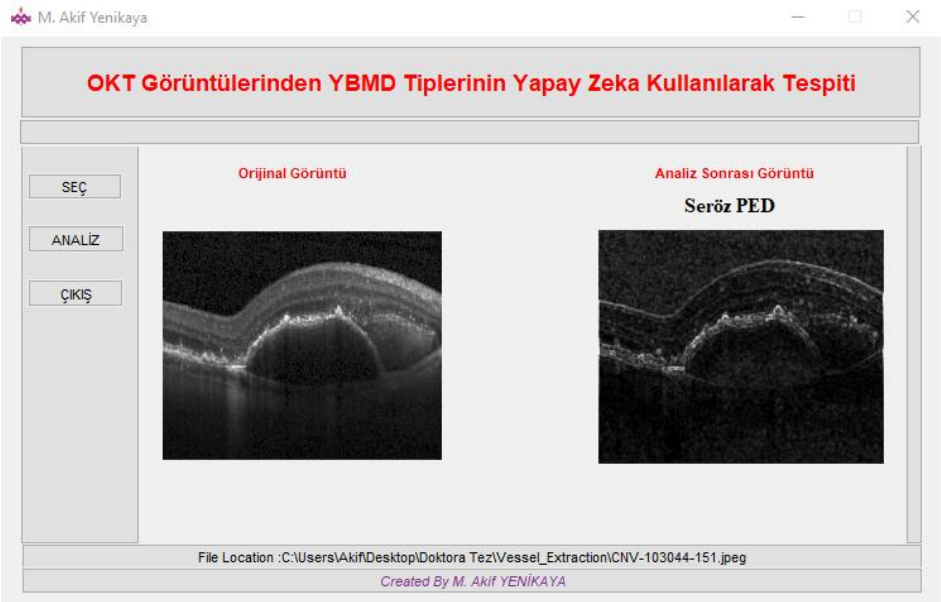
Şekil 4.15. YBMD hastalığı bulunmayan OKT görüntsünün analiz sonrası çıktıları

Derin öğrenme modellerinin eğitimi için kullanılan veri seti haricindeki test görüntülerinden örnek alınan YBMD hastalığının Drusen tipindeki OKT görüntüsünün analiz sonrası program çıktıları Şekil 4.16’ da verilmiştir.



Şekil 4.16. Drusen tipindeki OKT görüntüsünün analiz sonrası çıktıları

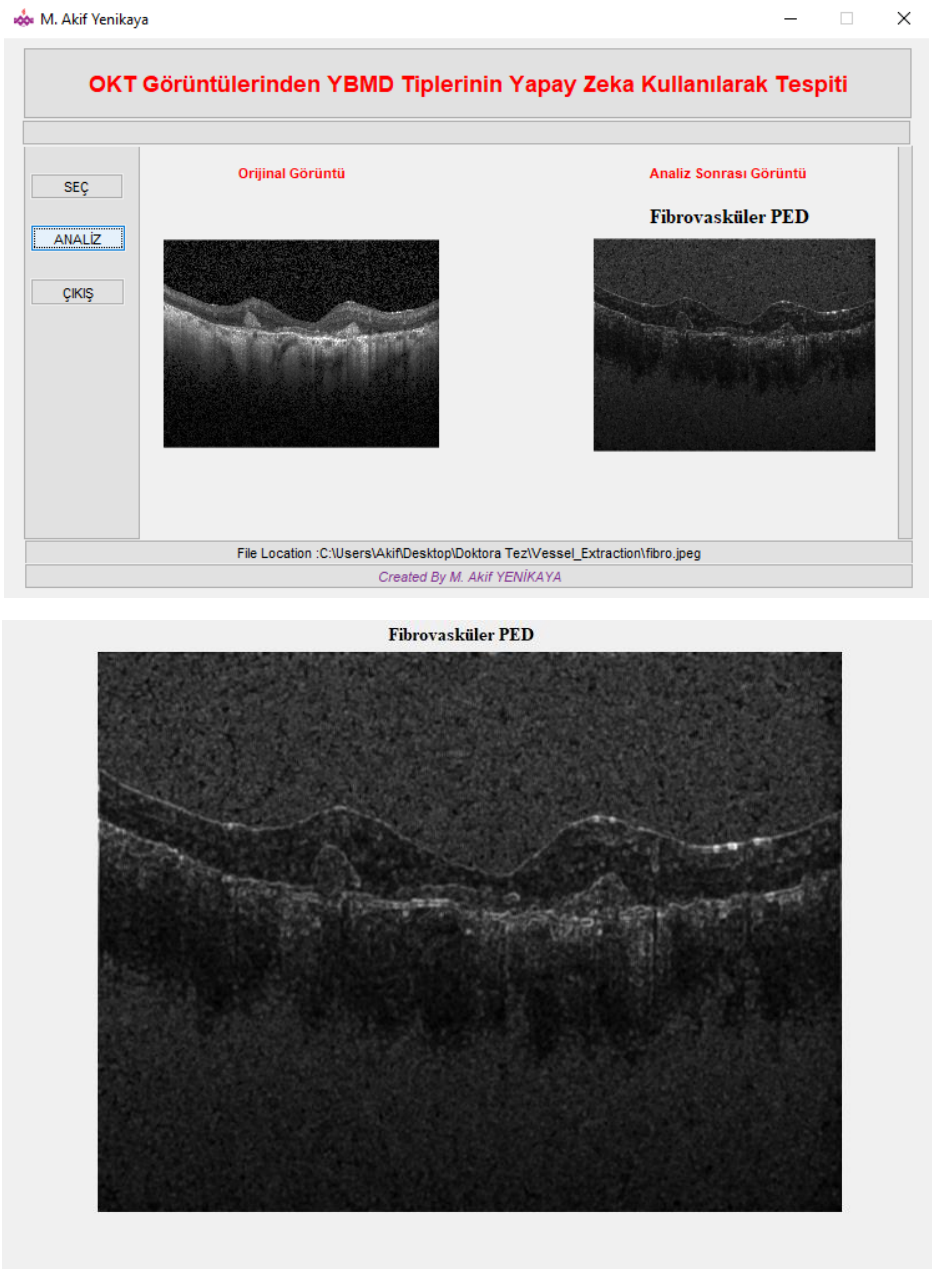
Derin öğrenme modellerinin eğitimi için kullanılan veri seti haricindeki test görüntülerinden örnek alınan YBMD hastalığının Seröz PED tipindeki OKT görüntüsünün analiz sonrası program çıktıları Şekil 4.17' de verilmiştir.





Şekil 4.17. Seröz PED tipindeki OKT görüntüsünün analiz sonrası çıktıları

Derin öğrenme modellerinin eğitimi için kullanılan veri seti haricindeki test görüntülerinden örnek alınan YBMD hastalığının Fibrovasküler PED tipindeki OKT görüntüsünün analiz sonrası program çıktıları Şekil 4.18' de verilmiştir.



Şekil 4.18. Fibrovasküler PED tipindeki OKT görüntüsünün analiz sonrası çıktıları

Geliştirilen uygulama, derin öğrenme modellerinin eğitimi için kullanılan veri seti haricindeki test görüntülerinden rastgele seçilen 100 adet Normal, 100 adet Drusen, 100 adet Fibrovasküler PED ve 100 adet Seröz PED OKT görüntüsü ile test edilmiştir. Tablo 4.10' da bu görüntülerin kaç adetinin doğru sınıflandırma yapıldığına dair sonuçlar verilmiştir.

Tablo 4.10. Uygulamanın test sonucu elde edilen doğru sınıflandırma sayıları

	Normal (Adet)	**Drusen (Adet)**	**Fibrovasküler PED (Adet)**	**Seröz PED (Adet)**
Doğru Sınıflandırılan Görüntü Sayısı	93	91	95	93

Geliştirilen uygulama üzerinde örnek OKT görüntüleri ile yapılan testler sonucunda ortalama başarı oranının %93 olduğu görülmektedir. Elde edilen bu başarı oranı ResNet50 derin öğrenme modelinden elde edilen başarı oranı ile paralellik göstermektedir.

BÖLÜM 5. SONUÇ

Dünya çapında geri dönüşü olmayan görme bozukluğunun önde gelen nedenlerinden biri olan YBMD' nin, tedavi edilmesi tam olarak mümkün olmasa da bu durum erken tespit edilebilmekte ve tedavi aşamasında YBMD' nin ilerlemesini yavaşlatmak mümkün olabilmektedir. Erken tanı ve tedavi, YBMD' den muzdarip hastaların fonksiyonel görmelerini sürdürmeleri için önem arz etmektedir. YBMD veya diyabetik göz hastalığı gibi retina hastalıklarının erken tanı ve tedavisi için OKT gibi görüntüleme yöntemleri rehberlik etmektedir.

OKT gibi görüntüleme yöntemlerinin ortaya çıkması ve artan kullanımıyla birlikte, yapay zekâ programları OKT verisini analiz edebilmekte ve göz bilimi alanında klinik kararlar vermede yardımcı olmak için eşsiz bir araç olarak kullanılabilmekte ve YBMD tespiti için yapay zekâ tabanlı araçların uygulanması, hastalığın yönetiminde önemli faydalar sağlayabilmektedir. Ayrıca derin öğrenme tekniği kullanılarak görme bozuklukları için OKT görüntülerinin otomatik sınıflandırılması, göz doktorlarının gözden kaçırdığı semptomların erken tespitine de olanak verebilmektedir.

Literatürde eksik olduğu değerlendirilen YBMD tiplerinin derin öğrenme aracılığı ile tespiti bu tez çalışmasının temelini oluşturmaktadır. Bu çalışmada, bir derin öğrenme uygulaması geliştirerek YBMD hastalığının erken teşhisi sağlanmaya çalışılmıştır. Çalışma kapsamında YBMD hastalığı bulunan ve bulunmayan göze ait 50.000 adet OKT görüntü veri seti temin edilmiştir. Veri setinde bulunan toplam 50.000 adet görüntü anonimleştirilerek alanında uzman göz doktorları aracılığı ile hastalık tespit edilen 2.500 adet Drusen, 2.500 adet Fibrovasküler PED, 2.500 adet Seröz PED ve hastalık tespit edilmeyen 2.500 adet Normal olmak üzere eşit sayıda 4 adet kategoriye ayrılmıştır.

Çalışmada göze ait etiketlenmiş OKT görüntüleri ResNet50, AlexNet, GoogLeNet ve Xception derin öğrenme modelleri kullanılarak derin öğrenme kütüphaneleri aracılığı ile Matlab geliştirme ortamı üzerinde eğitilmiş ve test edilmiştir. Yapılan bu işlem sonrası ResNet50 modeli kullanılan veri setinde bulunan OKT görüntülerini %93.80, AlexNet modeli %92.17, GoogLeNet modeli %91.67 ve Xception modeli %91.53 oranında sınıflandırma yapabilmiştir. Diğer modellere oranla nispeten

daha başarılı (%93.80) olduğu belirlenen ResNet50 modeli, bu çalışmada YBMD tespiti için önerilmiştir.

Geliştirilen bu uygulamada ayrıca hastalığın göz doktorları tarafından daha net bir şekilde ayırt edilebilmesi amacıyla OKT görüntüleri üzerinde Kirsch operatörü kullanılmıştır. Görüntü üzerinde kenarlar Kirsch operatörü kullanılarak belirlendikten sonra görüntü üzerinde varlığı kaçınılmaz olan gürültüleri temizlemek amacıyla Gauss filtresi kullanılmıştır.

Elde edilen performans değerlerinin, diğer sağlık tesislerinin ilgili birimlerinden alınacak olan çeşitli hastalara ait OKT görüntüleri kullanılarak veri seti genişletildiğinde daha da artması öngörülmektedir. Çalışmada geliştirilen uygulamanın öncelikli kullanım amacı göz doktorlarına tıbbi kararlar vermede yardımcı olmasıdır. Buna ek olarak kırsal alanlarda göz doktoru eksikliğini giderme konusunda da umut verici olacağı düşünülmektedir.

KAYNAKÇA

[1] R. Kapoor, B. T. Whigham ve L. A. Al-Aswad, "Artificial Intelligence and Optical Coherence Tomography Imaging," *Asia-Pacific Journal of Ophthalmology (Philadelphia, Pa.)*, 8(2), 187-194, 2019, https://doi.org/10.22608/APO.201904

[2] S. Kaymak ve A. Serener, "Automated Age-Related Macular Degeneration and Diabetic Macular Edema Detection on OCT Images using Deep Learning," 265-269, 2018, 10.1109/ICCP.2018.8516635.

[3] S. Kaymak, P. Esmaili ve A. Serener, "Deep Learning for Two-Step Classification of Malignant Pigmented Skin Lesions," 1-6, 2018, 10.1109/NEUREL.2018.8587019.

[4] J. S. Schuman, T. Pedut-Kloizman, E. Hertzmark, M. R. Hee, J. R. Wilkins, J. G. Coker, C. A. Puliafito, J. G. Fujimoto ve E. A. Swanson, "Reproducibility of nerve fiber layer thickness measurements using optical coherence tomography," *Ophthalmology*, 103(11),1889–1898, 1996, https://doi.org/10.1016/s0161-6420(96)30410-7

[5] R. Kapoor, B. Whigham ve L. Al-Aswad, "Artificial Intelligence and Optical Coherence Tomography Imaging," *Asia-Pacific Journal of Ophthalmology*, 8, 2019, 10.22608/APO.201904.

[6] T. Stevens, "Optical Coherence Tomography of Ocular Diseases," *Archives of ophthalmology*, 123. 292, 2005, 10.1001/archopht.123.2.292-a.

[7] R. Kapoor, S. P. Walters ve L. A. Al-Aswad, "The current state of artificial intelligence in ophthalmology," *Survey of ophthalmology*, 64(2), 233–240, 2019, https://doi.org/10.1016/j.survophthal.2018.09.002

[8] D. Ting, L. R. Pasquale, L. Peng, J. P. Campbell, A. Y. Lee, R. Raman, G. Tan, L. Schmetterer, P. A. Keane ve T. Y. Wong, "Artificial intelligence and deep learning in ophthalmology," *The British journal of ophthalmology*, 103(2), 167–175, 2019, https://doi.org/10.1136/bjophthalmol-2018-313173

[9] D. Pascolini, S. P. Mariotti, G. P. Pokharel, R. Pararajasegaram, D. Etya'ale, A. D. Négrel ve S. Resnikoff, "2002 global update of available data on visual impairment: a compilation of population-based prevalence studies," *Ophthalmic epidemiology*, 11(2), 67–115, 2004, https://doi.org/10.1076/opep.11.2.67.28158

[10] N. Congdon, B. O'Colmain, C. C. Klaver, R. Klein, B. Muñoz, D. S. Friedman, J. Kempen, H. R. Taylor, P. Mitchell ve Eye Diseases Prevalence Research Group, "Causes and prevalence of visual impairment among adults in the United States," *Archives of ophthalmology (Chicago, Ill. : 1960)*, 122(4), 477–485, 2004, https://doi.org/10.1001/archopht.122.4.477

[11] A. Serener ve S. Serte, "Dry and Wet Age-Related Macular Degeneration Classification Using OCT Images and Deep Learning," *2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)*, 1-4, 2019.

[12] Age-Related Eye Disease Study Research Group, "A randomized, placebo-controlled, clinical trial of high-dose supplementation with vitamins C and E, beta carotene, and zinc for age-related macular degeneration and vision loss: AREDS report no. 8," *Archives of ophthalmology (Chicago, Ill. : 1960)*, 119(10), 1417–1436, 2001, https://doi.org/10.1001/archopht.119.10.1417

[13] J. G. O'Shea, "Age-related macular degeneration: a leading cause of blindness," *The Medical journal of Australia*, 165(10), 561–564, 1996.

[14] P. Burlina, K. D. Pacheco, N. Joshi, D. E. Freund ve N. M. Bressler, "Comparing humans and deep learning performance for grading AMD: A study in using universal deep features and transfer learning for automated AMD analysis," *Computers in biology and medicine*, 82, 80–86, 2017, https://doi.org/10.1016/j.compbiomed.2017.01.018

[15] P. Burlina, D. Freund, N. Joshi, Y. Wolfson ve N. Bressler, "Detection of age-related macular degeneration via deep learning," 184-188, 2016, 10.1109/ISBI.2016.7493240.

[16] P. Burlina, N. Joshi, M. Pekala, K. D. Pacheco, D. E. Freund ve N. M. Bressler, "Automated Grading of Age-Related Macular Degeneration From Color Fundus Images Using Deep Convolutional Neural Networks," *JAMA ophthalmology*, 135(11), 1170–1176, 2017, https://doi.org/10.1001/jamaophthalmol.2017.3782

[17] A. Govindaiah, A. Hussain, R. T. Smith ve A. Bhuiyan, "Deep convolutional neural network based screening and assessment of age-related macular degeneration from fundus images," 1525-1528, 2018, 10.1109/ISBI.2018.8363863.

[18] F. Grassmann, J. Mengelkamp, C. Brandl, S. Harsch, M. E. Zimmermann, B. Linkohr, A. Peters, I. M. Heid, C. Palm ve B. Weber, "A Deep Learning Algorithm for Prediction of Age-Related Eye Disease Study Severity Scale for Age-Related Macular Degeneration from Color Fundus Photography," *Ophthalmology*, 125(9), 1410–1420, 2018, https://doi.org/10.1016/j.ophtha.2018.02.037

[19] P. M. Arabi, V. Deepa, T. S. Naveen ve D. Samanta, "Machine vision for screening of age-related macular degeneration using fundus images," *8th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, pp. 3–6, 2017.

[20] R. P. Kandan ve P. Aruna, "Automated diagnosis of Age-related macular degeneration from color retinal fundus images," 2, 2011, 10.1109/ICECTECH.2011.5941690.

[21] M. J. van Grinsven, Y. T. Lechanteur, J. P. van de Ven, B. van Ginneken, C. B. Hoyng, T. Theelen ve C. I. Sánchez, "Automatic drusen quantification and risk assessment of age-related macular degeneration on color fundus images," *Investigative ophthalmology & visual science*, 54(4), 3019–3027, 2013, https://doi.org/10.1167/iovs.12-11449

[22] T. V. Phan, L. Seoud, H. Chakor ve F. Cheriet, "Automatic Screening and Grading of Age-Related Macular Degeneration from Texture Analysis of Fundus Images," *Journal of ophthalmology*, 2016, 5893601. https://doi.org/10.1155/2016/5893601

[23] S. S. Parvathi ve N. Devi, "Automatic drusen detection from colour retinal images," *Proceedings of the International Conference on Computational Intelligence and Multimedia Applications*, pp. 377–381, IEEE, Sivakasi, India, 2007.

[24] C. Köse, U. Sevik, O. Gençalioğlu, C. Ikibaş ve T. Kayikiçioğlu, "A statistical segmentation method for measuring age-related macular degeneration in retinal fundus images," *Journal of medical systems*, 34(1), 1–13, 2010, https://doi.org/10.1007/s10916-008-9210-4

[25] C. S. Lee, D. M. Baughman ve A. Y. Lee "Deep learning is effective for the classification of OCT images of normal versus Age-related Macular Degeneration," *Ophthalmology. Retina*, 1(4), 322–327, 2017, https://doi.org/10.1016/j.oret.2016.12.009

[26] D. K. Hwang, C. C. Hsu, K. J. Chang, D. Chao, C. H. Sun, Y. C. Jheng, A. A. Yarmishyn, J. C. Wu, C. Y. Tsai, M. L. Wang, C. H. Peng, K. H. Chien, C. L. Kao, T. C. Lin, L. C. Woung, S. J. Chen ve S. H. Chiou, "Artificial intelligence-based decision-making for age-related macular degeneration," *Theranostics*, 9(1), 232–245, 2019, https://doi.org/10.7150/thno.28447

[27] L. Li, L. Qin, Z. Xu, Y. Yin, X. Wang, B. Kong, J. Bai, Y. Lu, Z. Fang, Q. Song, K. Cao, D. Liu, G. Wang, Q. Xu, X. Fang, S. Zhang, J, Xia ve J. Xia, "Using Artificial Intelligence to Detect COVID-19 and Community-acquired Pneumonia Based on Pulmonary CT: Evaluation of the Diagnostic Accuracy," *Radiology*, 296(2), E65–E71, 2020, https://doi.org/10.1148/radiol.2020200905

[28] G. Jain, D. Mittal, D. Thakur ve M. K. Mittal, "A deep learning approach to detect Covid-19 coronavirus with X-Ray images," *Biocybernetics and biomedical engineering*, 40(4), 1391–1405, 2020, https://doi.org/10.1016/j.bbe.2020.08.008

[29] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim ve U. Rajendra Acharya, "Automated detection of COVID-19 cases using deep neural networks with X-ray images," *Computers in biology and medicine*, 121, 103792, 2020, https://doi.org/10.1016/j.compbiomed.2020.103792

[30] S. Albahli, "A Deep Neural Network to Distinguish COVID-19 from other Chest Diseases Using X-ray Images," *Current medical imaging*, 17(1), 109–119, 2021, https://doi.org/10.2174/1573405616666200604163954

[31] S. J. Chiu, J. A. Izatt, R. V. O'Connell, K. P. Winter, C. A. Toth ve S. Farsiu, "Validated automatic segmentation of AMD pathology including drusen and geographic atrophy in SD-OCT images," *Investigative ophthalmology & visual science*, 53(1), 53–61, 2012, https://doi.org/10.1167/iovs.11-7640

[32] S. Farsiu, S. Chiu, J. Izatt ve C. Toth, "Fast detection and segmentation of drusen in retinal optical coherence tomography images – art," *Progress in Biomedical Optics and Imaging - Proceedings of SPIE*, 6844, 2008, 10.1117/12.768624.

[33] L. Fang, D. Cunefare, C. Wang, R. H. Guymer, S. Li ve S. Farsiu, "Automatic segmentation of nine retinal layer boundaries in OCT images of non-exudative AMD patients using deep learning and graph search," *Biomedical optics express*, 8(5), 2732–2744, 2017, https://doi.org/10.1364/BOE.8.002732

[34] J. Kugelman, D. Alonso-Caneiro, S. A. Read, S. J. Vincent ve M. J. Collins, "Automatic segmentation of OCT retinal boundaries using recurrent neural networks and graph search," *Biomedical optics express*, 9(11), 5759–5777, 2018, https://doi.org/10.1364/BOE.9.005759

[35] Q. Yan, D. E. Weeks, H. Xin, A. Swaroop, E. Y. Chew, H. Huang, Y. Ding ve w. Chen, "Deep-learning-based Prediction of Late Age-Related Macular Degeneration Progression," *Nature machine intelligence*, 2(2), 141–150, 2020, https://doi.org/10.1038/s42256-020-0154-9

[36] P. P. Srinivasan, L. A. Kim, P. S. Mettu, S. W. Cousins, G. M. Comer, J. A. Izatt ve S. Farsiu, "Fully automated detection of diabetic macular edema and dry age-related macular degeneration from optical coherence tomography images," *Biomedical optics express*, 5(10), 3568–3577, 2014, https://doi.org/10.1364/BOE.5.003568

[37] O. Perdomo Charry, J. Otálora Montenegro, F. González, F. Meriaudeau ve H. Müller, "OCT-NET: A convolutional network for automatic classification of normal and diabetic macular edema using sd-oct volumes," *Proceedings / IEEE International Symposium on Biomedical Imaging: from nano to macro. IEEE International Symposium on Biomedical Imaging.* 1. 1423-1426, 2018, 10.1109/ISBI.2018.8363839.

[38] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhouck ve A. Rabinovich, "Going deeper with convolutions," *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 1-9, 2015, 10.1109/CVPR.2015.7298594.

[39] S. Anushikha, S. Namita, I. Ashish, K. D. Malay, "An Automated Imaging Algorithm for Macula Detection in Fundus Images," *IEEE*, 978-1-5090-3251-8/16, 2016.

[40] H. Narasimha-Iyer, A. Can, B. Roysam ve J. Stern, "Automated Change Analysis From Fluorescein Angiograms for Monitoring Wet Macular Degeneration," *Proceedings of the 28th IEEE EMBS Annual International Conference New York City*, USA, Aug 30-Sept 3, 2006, 1- 4244-0033-3/06/©2006 IEEE.

[41] M. H. A. Hijazi, F. Coenen ve Y. Zheng, "Age-Related Macular Degeneration Screening Using Data Mining Approaches," *1st International Conference on Artificial Intelligence, Modelling and Simulation*, 2013, pp. 299-303, doi: 10.1109/AIMS.2013.55.

[42] S. Naz, A. Ahmed, M. U. Akram, S. A. Khan, "Automated Segmentation of RPE Layer for the Detection of Age Macular Degeneration Using OCT Images" 978-1-4673-8910-5/16/©2016 IEEE.

[43] Y. Zheng, B. Vanderbeek, E. Daniel, D. Stambolian, M. Maguire, D. Brainard, J. Gee, “An automated drusen detectıon system for classıfyıng age-related macular degeneratıon wıth color fundus photographs,” *2013 IEEE 10th International Symposium on Biomedical Imaging: From Nano to Macro San Francisco*, CA, USA, April 7-11, 2013, 978-1-4673-6455-3/13/©2013 IEEE.

[44] L. S. Lim, P. Mitchell, J. M. Seddon, F. G. Holz ve T. Y. Wong, “Age-related macular degeneration,” *Lancet*, 379(9827), 1728–1738, 2012, https://doi.org/10.1016/S0140-6736(12)60282-7

[45] J. M. Seddon ve C. A. Chen, “The epidemiology of age-related macular degeneration,” *International ophthalmology clinics*, 44(4), 17–39, 2004, https://doi.org/10.1097/00004397-200404440-00004

[46] J. S. Sunness, G. S. Rubin, C. A. Applegate, N. M. Bressler, M. J. Marsh, B. S. Hawkins ve D. Haselwood, “Visual function abnormalities and prognosis in eyes with age-related geographic atrophy of the macula and good visual acuity,” *Ophthalmology*, 104(10), 1677–1691, 1997, https://doi.org/10.1016/s0161-6420(97)30079-7

[47] R. L. Steinmetz, R. Haimovici, C. Jubb, F. W. Fitzke ve A. C. Bird, “Symptomatic abnormalities of dark adaptation in patients with age-related Bruch's membrane change,” *The British journal of ophthalmology*, 77(9), 549–554, 1993, https://doi.org/10.1136/bjo.77.9.549

[48] H. R. Coleman, C. C. Chan, F. L. Ferris, ve E. Y. Chew, “Age-related macular degeneration,” Lancet, 372(9652), 1835–1845, 2008, https://doi.org/10.1016/S0140-6736(08)61759-6

[49] A. C. Bird, N. M. Bressler, S. B. Bressler, I. H. Chisholm, G. Coscas, M. D. Davis, P. T. de Jong, C. C. Klaver, B. E. Klein ve R. Klein, “An international classification and grading system for age-related maculopathy and age-related macular degeneration,” *The International ARM Epidemiological Study Group. Survey of ophthalmology*, 39(5), 367–374, 1995, https://doi.org/10.1016/s0039-6257(05)80092-x

[50] P. T. Johnson, G. P. Lewis, K. C. Talaga, M. N. Brown, P. J. Kappel, S. K. Fisher, D. H. Anderson ve L. V. Johnson, "Drusen-associated degeneration in the retina," *Investigative ophthalmology & visual science*, 44(10), 4481–4488, 2003, https://doi.org/10.1167/iovs.03-0436

[51] A. M. Fine, M. J., Elman, J. E. Ebert, P. A. Prestia, J. S. Starr ve S. L. Fine, "Earliest symptoms caused by neovascular membranes in the macula," *Archives of ophthalmology (Chicago, Ill.: 1960)*, 104(4), 513–514, 1986, https://doi.org/10.1001/archopht.1986.01050160069013

[52] R. P. Murphy, J. H. Yeo, W. R. Green ve A. Patz, "Dehiscences of the pigment epithelium," *Transactions of the American Ophthalmological Society*, 83, 63–81, 1985.

[53] W. R. Green, P. J. McDonnell ve J. H. Yeo, "Pathologic features of senile macular degeneration," *Ophthalmology*, 92(5), 615–627, 1985.

[54] L. A. Yannuzzi, "Décollement de l'épithélium pigmentaire [Retinal pigment epithelial detachment]," *Journal francais d'ophtalmologie*, 12(11), 761–774, 1989.

[55] F. Coscas, G. Coscas, E. Souied, S. Tick ve G. Soubrane, "Optical coherence tomography identification of occult choroidal neovascularization in age-related macular degeneration," *American journal of ophthalmology*, 144(4), 592–599, 2007, https://doi.org/10.1016/j.ajo.2007.06.014

[56] J. G. Fujimoto, C. Pitris, S. A. Boppart ve M. E. Brezinski, "Optical coherence tomography: an emerging technology for biomedical imaging and optical biopsy," *Neoplasia (New York, N.Y.)*, 2(1-2), 9–25, 2000, https://doi.org/10.1038/sj.neo.7900071

[57] K. Tripathy ve B. Salini, "Amsler Grid," *StatPearls Publishing*, 2022.

[58] D. M. West, The future of work: Robots, AI, and automation, 2018.

[59] R. Rothe, "Applying Deep Learning to Real-World Problems," Medium, May 23, 2017.

[60] E. Horvitz, “Reflections on the Status and Future of Artificial Intelligence,” Testimony before the U.S. Senate Subcommittee on Space, Science, and Competitiveness, November 30, 2016, p. 5.

[61] D. Yadhav, Machine Learning: Trends, Perspective, and Prospects Machine Learning: Trends, Perspective, and Prospects, 2020

[62] O. Kaynar, Y. Görmez, M. Yildiz ve A. Albayrak, “Makine Öğrenmesi Yöntemleri ile Duygu Analizi,” 2016.

[63] T. Ayodele, Machine Learning Overview. 10.5772/9374, 2010.

[64] W. S. McCulloch ve W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” *Bulletin of mathematical biology*, 52(1-2), 99–97. [65] D. O. Hebb, "The organization of behavior", J. Appl. Behav. Anal., vol. 25, pp. 575-577, 1949.

[66] F. Rosenblatt, “The perceptron: a probabilistic model for information storage and organization in the brain,” *Psychological review*, 65(6), 386–408, 1958, https://doi.org/10.1037/h0042519

[67] J. J. Hopfield, “Neural networks and physical systems with emergent collective computational abilities,” *Proceedings of the National Academy of Sciences of the United States of America*, 79(8), 2554–2558, 1982, https://doi.org/10.1073/pnas.79.8.2554

[68] D. H. Ackley, G. E. Hinton ve T. J. Sejnowski, “A learning algorithm for boltzmann machines”, *Cognitive Sci.*, vol. 9, pp. 147-169, 1985.

[69] C. Cortes ve V. Vapnik, “Support-Vector Networks”, *Mach. Learn.*, vol. 20, pp. 273-297, 1995.

[70] Y. Freund ve R. E. Schapire, “A decision-theoretic generalization of online learning and an application to boosting,” *J. comput. Syst. Sci.*, vol. 55, no. 1, pp. 119-139, 1997.

[71] P. Vincent, H. Larochelle, Y. Bengio ve P. A. Manzagol, "Extracting and composing robust features with denoising autoencoders," *Proceedings of the 25th international conference on Machine learning*, pp. 1096-1103, 2008.

[72] A. Ng, "Sparse autoencoder", *CS294A Lecture Notes Stanford Univ.* California, pp. 72, 2011.

[73] Y. Hua, J. Guo ve H. Zhao, "Deep Belief Networks and deep learning," *Proceedings of 2015 International Conference on Intelligent Computing and Internet of Things*, 2015, pp. 1-4, doi: 10.1109/ICAIOT.2015.7111524.

[74] G. E. Hinton, "Deep belief networks," *Scholarpedia*, 4(5), 5947, 2009.

[75] L. R. Medsker ve L. C. Jain, "Recurrent neural networks," *Design and Applications*, 5, 64-67, 2001.

[76] D.H. Hubel ve T. N. Wiesel, "Receptive fields and functional architecture of monkey striate cortex," *J Physiol*, 195:215–243, 1968.

[77] K. Fukushima, "Neocognitron: a self organizing neural network model for a mechanism of pattern recognition unaffected by shift in position," *Biol Cybern*, 36:193–202, 1980.

[78] Y. LeCun, Y. Bengio ve G. Hinton, "Deep Learning," *Nature*. 521. 436-44, 2015, 10.1038/nature14539.

[79] S. Targ, D. Almeida ve K. Lyman, "Resnet in resnet: generalizing residual architectures," arXiv preprint arXiv:1603.08029, 2016.

[80] K. He, X. Zhang, S. Ren ve J. Sun, "Deep Residual Learning for Image Recognition," 2015.

[81] N. Strisciuglio, A. M. Lopez ve N. Petkov, "Enhanced robustness of convolutional networks with a push–pull inhibition layer," *Neural Computing and Applications*. 32. 1-15, 2020, 10.1007/s00521-020-04751-8.

[82] A. Krizhevsky, I. Sutskever ve G. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” *Neural Information Processing Systems*, 25, 2012, 10.1145/3065386.

[83] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke ve A. Rabinovich, “Going deeper with convolutions,” *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 1-9, 2015, 10.1109/CVPR.2015.7298594.

[84] F. Chollet, “Xception: Deep learning with depthwise separable convolutions,” arXiv, arXiv:1610.02357v3, 2017. https://arxiv.org/abs/1610.02357

[85] R. A. Kirsch, “Computer determination of the constituent structure of biological images,” *Computers and Biomedical Research*, 4, 3, June 1971, pp. 315–328.

[86] K. Thiruvenkadam, J. Prasanna ve K. Sakthivelu, “Modified Kirsch's Method for Edge Based Image Segmentation,” 2005.

[87] D. S. Mani ve C. Nagaraju, "Face recognition based on kirsch compass kernel operator," *2017 International Conference on Communication and Signal Processing (ICCSP)*, 2017, pp. 1322-1324, doi: 10.1109/ICCSP.2017.8286597.

[88] E. S. Gedraite ve M. Hadad, "Investigation on the effect of a Gaussian Blur in image filtering and segmentation," *Proceedings ELMAR-2011*, 2011, pp. 393-396.

[89] M. S. Chauhan, “Optimizing Gaussian Blur Filter using CUDA Parallel Framework,” *Information Technology Department, College of Applied Sciences. Ibri, Sulatanate of Oman*, 2018.

[90] Jan Novák et al, GPU Computing: Image Convolution. Karlsruhe Institute of Technology.

[91] O. Polat, “Detection of Covid-19 from Chest CT Images using Xception Architecture: A Deep Transfer Learning based Approach,” *Sakarya University Journal of Science*. 25. 813-823, 2021, 10.16984/saufenbilder.903886.

[92] R. Jaeschke, G. H. Guyatt ve D. L. Sackett, “Users' guides to the medical literature. III. How to use an article about a diagnostic test. B. What are the results and will they help me in caring for my patients?” *The Evidence-Based Medicine Working Group*, 271(9), 703–707, 1994, https://doi.org/10.1001/jama.271.9.703