



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**RETİNA HASTALIKLARI TESPİTİ İÇİN YAPAY ZEKÂ
DESTEKLİ YENİ BİR HESAPLAMALI MODELİN
GELİŞTİRİLMESİ**

Hasan MEMİŞ

**Temmuz-2025
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**RETİNA HASTALIKLARI TESPİTİ İÇİN YAPAY ZEKÂ
DESTEKLİ YENİ BİR HESAPLAMALI MODELİN
GELİŞTİRİLMESİ**

Hasan MEMİŞ

**Danışman
Doç. Dr. Emrullah ACAR**

Diğer Jüri Yeleri

Doç. Dr. Ömer Türk

Doç. Dr. Musa YILMAZ

**Temmuz-2025
BATMAN**

TEZ KABUL VE ONAYI

Hasan MEMİŞ tarafından hazırlanan “Retina Hastalıkları Tespiti İçin Yapay Zekâ Destekli Yeni Bir Hesaplamalı Modelin Geliştirilmesi” adlı tez çalışması 30/06/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Ana Bilim/Ana Sanat Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Ömer Türk

.....

Danışman

Doç. Dr. Emrullah ACAR

.....

Üye

Doç. Dr. Musa YILMAZ

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

İmza

Hasan MEMİŞ

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

RETİNA HASTALIKLARI TESPİTİ İÇİN YAPAY ZEKÂ DESTEKLİ YENİ BİR HESAPLAMALI MODELİN GELİŞTİRİLMESİ

Hasan MEMİŞ

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Emrullah ACAR

2025, 68 Sayfa

Retina hastalıkları, dünya genelinde artan diyabet ve yaşa bağlı sağlık sorunlarıyla birlikte ciddi görme kaybına neden olan önemli sağlık problemleri arasında yer almaktadır. Erken teşhis ve etkin tedavi, bu hastalıkların yol açtığı kalıcı görme kaybını önlemede kritik rol oynamaktadır. Optik Koherens Tomografi (OCT) görüntüleme teknolojisi, retina tabakasındaki mikroskobik yapısal değişimleri invaziv olmayan bir şekilde yüksek çözünürlükle ortaya koyarak tanı ve tedavi süreçlerinde yaygın olarak kullanılmaktadır. Ancak, bu görüntülerin manuel olarak değerlendirilmesi zaman alıcı ve uzmanlık gerektiren bir süreçtir. Bu çalışmada, retina hastalıklarının OCT görüntüleri üzerinden otomatik teşhisi amacıyla yapay zekâ destekli yeni bir hesaplamalı model geliştirilmiştir. Geliştirilen sistem; görüntü doğrulama, ön işleme, derin öğrenme tabanlı sınıflandırma ve karar destek modüllerini içeren çok katmanlı ve modüler bir mimari üzerine inşa edilmiştir. Model eğitiminde, OCT-2017 açık erişimli veri setinden faydalanılmış ve CNV (Koroid Neovaskülerizasyonu), DME (Diyabetik Makula Ödemi), Drusen ve Normal olmak üzere dört farklı retina hastalık sınıfı hedeflenmiştir. Derin öğrenme tabanlı sınıflandırıcı olarak dört farklı mimari yapı test edilmiştir (GoogleNet, ResNet50, EfficientNet-B0 ve DenseNet-201). Yapılan karşılaştırmalı deneyler sonucunda, katmanlar arası yoğun bağlantı mekanizması ile öne çıkan DenseNet-201 mimarisi, en yüksek doğruluk oranını elde etmiş ve modelin nihai versiyonunda tercih edilmiştir. Eğitim ve test sonuçları doğruluk, hassasiyet, özgüllük, F1 skoru ve ROC eğrileri gibi istatistiksel metriklerle detaylı şekilde değerlendirilmiştir. Ayrıca, sisteme entegre edilen kullanıcı dostu arayüz aracılığıyla sağlık personellerine grafiksel ve sayısal tahmin sonuçları sunulularak klinik karar destek süreçlerine katkı sağlanması amaçlanmıştır. Geliştirilen sistemin sağlık yazılımları ve OCT cihazları ile entegrasyon potansiyeli de göz önünde bulundurularak gelecekte klinik uygulamalara yönelik genişletilebilir bir altyapı oluşturulmuştur.

Bu tez çalışması, hem yapay zekâ temelli karar destek sistemlerinin retina hastalıklarının erken teşhisinde etkinliğini ortaya koymakta hem de literatüre özgün veri yönetimi, güvenlik ve kullanıcı arayüzü bileşenleri ile katkı sunmaktadır.

Anahtar Sözcükler: Retina Hastalıkları, Optik Koherens Tomografi, Yapay Zekâ, Derin Öğrenme, CNN, GoogleNet, ResNet50, EfficientNet-B0, DenseNet-201, Karar Destek Sistemi.

ABSTRACT

MASTER THESIS

DEVELOPMENT OF A NEW COMPUTATIONAL MODEL SUPPORTED BY ARTIFICIAL INTELLIGENCE FOR DETECTION OF RETINAL DISEASES

Hasan Memiş

Batman University Graduate Education Institute

Electrical Electronical Engineering Department of Science

Advisor: Assoc. Prof. Dr. Emrullah ACAR

2025, 68 Pages

Retinal diseases are among the major health problems that cause serious vision loss, with diabetes and age-related health problems increasing worldwide. Early diagnosis and effective treatment play a critical role in preventing permanent vision loss caused by these diseases. Optical Coherence Tomography (OCT) imaging technology is widely used in diagnosis and treatment processes by non-invasively revealing microscopic structural changes in the retinal layer with high resolution. However, manual evaluation of these images is a time-consuming and specialized process. In this study, a new computational model supported by artificial intelligence is developed for automatic diagnosis of retinal diseases using OCT images. The system is built on a multi-layered and modular architecture that includes image validation, preprocessing, deep learning-based classification and decision support modules. The OCT-2017 open access dataset was used for model training, and four different retinal disease classes were targeted: CNV (Choroidal Neovascularization), DME (Diabetic Macular Edema), Drusen and Normal. Four different architectures were tested as deep learning-based classifiers (GoogleNet, ResNet50, EfficientNet-B0 and DenseNet-201). As a result of the comparative experiments, the DenseNet-201 architecture, which stands out with its dense inter-layer connection mechanism, achieved the highest accuracy rate and was preferred in the final version of the model. Training and test results were evaluated in detail with statistical metrics such as accuracy, sensitivity, specificity, F1 score and ROC curves. In addition, it is aimed to contribute to clinical decision support processes by presenting graphical and numerical prediction results to healthcare professionals through the user-friendly interface integrated into the system. Considering the integration potential of the developed system with health software and OCT devices, an expandable infrastructure has been created for future clinical applications.

This thesis not only demonstrates the effectiveness of artificial intelligence-based decision support systems in the early diagnosis of retinal diseases, but also contributes to the literature with its unique data management, security and user interface components.

Keywords: Retinal Diseases, Optical Coherence Tomography, Artificial Intelligence, Deep Learning, CNN, GoogleNet, ResNet50, EfficientNet-B0, DenseNet-201, Decision Support System.

ÖN SÖZ

Bilindiği üzere artan aşırı nüfusla beraber hastanelerimizin, dolayısıyla sağlık çalışanlarının yükü ve baktığı hasta sayısı ciddi bir şekilde artmış olup bu tez çalışmasında bunların yükünü azaltmak ve zamanlarından tasarruf yapmalarına yardımcı olmak en temel prensip edinilmiştir. Bu çalışmada çalışmanın en başından itibaren yardımlarını esirgemeyen sevgili aileme, kuzenim ve çok yakın arkadaşım Samsun Üniversitesi Yazılım Mühendisliği'nden yeni mezun olmuş olan Hasan Memiş'e ve engin fikirlerinden ve yardımlarından ötürü danışmanım sayın Doç. Dr. Emrullah Acar'a teşekkürlerimi sunmayı bir borç bilirim.

Hasan MEMİŞ
BATMAN-2025



İÇİNDEKİLER

ÖZET	viii
ABSTRACT.....	ix
ÖN SÖZ	x
İÇİNDEKİLER.....	xi
SİMGELER VE KISALTMALAR.....	xiii
ŞEKİLLER LİSTESİ	xiv
TABLolar LİSTESİ	xv
1. GİRİŞ.....	1
1.1. Gözün Anatomisi	2
1.1.1. Retinanın anatomik yapısı	3
1.1.2. OCT (Optik Koherens Tomografi)	4
1.1.3. Retinal hastalıklar	6
1.1.3.1. CNV (Koroid Neovaskülarizasyonları)	6
1.1.3.2. DME (Diyabetik Makula Ödemi)	6
1.1.3.3. Drusen	7
2. KAYNAK ARAŞTIRMASI	8
2.1. Tez Çalışması Konusun Amacı, Önemi ve Özgünlüğü	8
2.2. Literatür Çalışmaları	9
3. MATERYAL VE YÖNTEM.....	16
3.1. Önerilen Sistem Mimarisi	16
3.1.1. Veri seti oluşturma.....	17
3.1.2. Veri girişi, görüntü işleme ve doğrulama, ön işleme katmanı	18
3.1.3. Derin öğrenme tabanlı yapay zekâ modülü	19
3.1.4. Karar destek ve tahmin süreci.....	20
3.1.5. Kullanıcı arayüzü (UI)	20
3.1.6. Veri tabanı ve güvenlik katmanı	24
3.1.7. Sistem dağıtımı ve entegrasyon potansiyeli.....	24
3.2. Kullanılan Teknolojiler.....	25
3.2.1. HTML	25
3.2.2. CSS	26
3.2.3. Gradio	26
3.2.4. Tensorflow	26
3.2.5. MongoDB	27
3.3. Model Geliştirme Çalışmaları ve Sistem Temel Çalışma Prensipleri.....	28
3.4. Kullanılan Derin Öğrenme Mimari ve Modelleri	30
3.4.1. Evrişimsel sinir ağları (CNN)	30
3.4.1.1. Giriş katmanı.....	32
3.4.1.2. Evrişim katmanı.....	32
3.4.1.3. Düzleştirilmiş doğrusal birim katmanı	32
3.4.1.4. Havuzlama katmanı	33
3.4.1.5. Tam bağlantılı katman	33
3.4.1.6. Seyreltme katmanı	34

3.4.1.7. Sınıflandırma katmanı.....	35
3.4.2. GoogleNet.....	35
3.4.3. ResNet.....	36
3.4.4. EfficientNet.....	37
3.4.5. DenseNet.....	38
.....	38
4. BULGULAR.....	39
4. 1. TensorFlow ile Yapay Zekâ Destekli Model Geliştirme	39
4.1.1. Model eğitimi ve doğrulama.....	39
4.1.2. Çalışmada kullanılan model ve mimarilerin karşılaştırılması	39
4.1.3. Hata matrisi.....	44
4.1.4. Metrikler	47
4.1.4.1. Doğruluk	47
4.1.4.2. Hassasiyet	47
4.1.4.3. Özgüllük.....	48
4.1.4.4. Kesinlik.....	48
4.1.4.5. Yanlış Pozitif Oranı (False Positive Rate – FPR).....	48
4.1.4.6. F1 Skoru.....	49
4.1.5. DenseNet201’e ait ROC eğrileri.....	50
4.2. Tartışma	52
5. SONUÇLAR VE ÖNERİLER	54
5.1. Sonuç	54
5.2. Öneriler	54
5.2.1. Veri çeşitliliği ve miktarının artırılması.....	55
5.2.2. Modelin gerçek dünya koşullarında test edilmesi.....	56
5.2.3. Hibrit yöntemlerin kullanılması.....	56
5.2.4. Kullanıcı Ara yüzünün Geliştirilmesi	56
5.2.5. Gerçek zamanlı tahmin ve görselleştirme.....	56
5.2.6. Modelin sürekli eğitimi ve güncellenmesi.....	57
5.2.7. Multimodal veri entegrasyonu	57
5.2.8. OCT cihazına entegrasyonu.....	57
5.2.9. Sağlık sistemi yazılımlarına ve e-nabız’a entegrasyonu.....	57
KAYNAKLAR	59
EKLER	67

SİMGELER VE KISALTMALAR

AMD : Age-Related Macular Degeneration (Yaşa Bağlı Makula Dejenerasyonu)
AUC : Area Under Curve (Eğri Altındaki Alan)
CNV: Choroidal Neovascularisation (Koroid Neovaskülarizasyonu)
DME : Diabetic Macular Edema (Diyabetik Makula Ödemi)
DR : Diabetic Retinopathy (Diyabetik Retinopati)
FN : False Negative (Yanlış Negatif)
FP : False Positive (Yanlış Pozitif)
FPR : False Positive Rate (Yanlış Pozitif Oranı)
ICMLA : International Conference on Machine Learning and Applications
IECBES : IEEE-EMBS Conference on Biomedical Engineering and Sciences
OCT : Optical Coherence Tomography (Optik Koherens Tomografi)
TN : True Negative (Doğru Negatif)
TP : True Positive (Doğru Pozitif)
TPR : True Positive Rate (Doğru Pozitif Oranı)
AMD : Age-Related Macular Degeneration (Yaşa Bağlı Makula Dejenerasyonu)
AUC : Area Under Curve (Eğri Altındaki Alan)
BSON : Binary JSON (İkili JSON)
CNN : Convolutional Neural Network (Evrişimsel Sinir Ağı)
CNV : Choroidal Neovascularisation (Koroid Neovaskülarizasyonu)
CSS : Cascading Style Sheets (Basamaklı Stil Şablonları)
DME : Diabetic Macular Edema (Diyabetik Makula Ödemi)
DR : Diabetic Retinopathy (Diyabetik Retinopati)
F1 : F1 Score (F1 Skoru)
FPR : False Positive Rate (Yanlış Pozitif Oranı)
GAN : Generative Adversarial Network (Üretici Çekişmeli Ağ)
IEEE : Institute of Electrical and Electronics Engineers
MBT : Model-Based Transformer (Model Tabanlı Dönüştürücü)
NCC : National Conference on Communications (Ulusal İletişim Konferansı)
OCT : Optical Coherence Tomography (Optik Koherens Tomografi)
ROC : Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
LGN: Genikülat Çekirdek

ŞEKİLLER LİSTESİ

Şekil 1.1. Gözün anatomisi.....	2
Şekil 1.2. Görme olayı.....	3
Şekil 1.3. Retinanın histolojik şeması.....	4
Şekil 1.4. OCT Çalışma Prensibi.....	5
Şekil 3.1. Önerilen sistem mimarisi genel özellikleri.....	16
Şekil 3.2. OCT veri setine ait rastgele seçilmiş bazı örnekler.....	19
Şekil 3.3. Sistem web arayüzü.....	21
Şekil 3.4. Sistem articles (makaleler) arayüzü.....	22
Şekil 3.5. Sistem contact (iletişim) arayüzü.....	22
Şekil 3.6. Doktor işlem ara yüzü.....	23
Şekil 3.7. Örnek html kodları	25
Şekil 3.8. Tensorflow basit çalışma prensibi.....	27
Şekil 3.9. Sistem temel çalışma prensibi.....	30
Şekil 3.10. Evrişimli sinir ağı yapısı.....	31
Şekil 3.11. Relu fonksiyonun matris üzerindeki değişimleri.....	33
Şekil 3.12. Tam bağlantılı katman.....	34
Şekil 3.13. Seyreltme katmanı öncesi (a) ve Seyreltme katmanı sonrası (b) ağ yapısı...34	
Şekil 3.14. Sınıflandırma işlemi ve olasılık değerleri.....	35
Şekil 3.15. GoogleNet mimarisi.....	36
Şekil 3.16. ResNet ağı mimarisi.....	36
Şekil 3.17. EfficientNET mimarisi.....	37
Şekil 3.18. DenseNet mimarisi.....	38
Şekil 4.1. Modellerin train accuracy (eğitim doğruluğu) ve validation accuracy (doğrulama doğruluğu) karşılaştırması.....	40
Şekil 4.2. Modellerin F1 skoru karşılaştırması.....	40
Şekil 4.3. Model doğruluk ve kayıp eğrileri.....	41
Şekil 4.4. Hata matrisi.....	44
Şekil 4.5. Sınıf bazlı performans metrikleri.....	46
Şekil 4.6. Modele ait ROC eğrisi.....	50

TABLÖLAR LİSTESİ

Tablo 3.1. OCT-2017 Verilerin dağılımı.....	17
Tablo 3.2. Model eğitiminde kullanılan hiperparametreler.....	28
Tablo 3.3. Erken durdurma ölçütleri.....	28
Tablo 3.4. Düzleştirilmiş doğrusal birim fonksiyonları ve türevleri.....	33
Tablo 4.1. Performans sonuçları.....	49



1. GİRİŞ

Başta Türkiye olmak üzere dünyanın birçok yerinde insanların gerek beslenme alışkanlıklarının değişmesi gerek yaşamsal ve keyfi aktivitelerinin azalması, gerekse teknoloji ile aşırı haşır neşir olmaları insanların yaşam kalitelerini düşürmekle beraber ciddi sağlık problemlerini de meydana getirmiştir. Bu sağlık sorunlarının en başında gelenlerden biri de kısmi ya da tümüyle görme yetisi kaybıdır. Birkaç cümle öncesinden de zikredildiği gibi beslenme alışkanlıklarının değişmesi ve yaşam standartlarının düşmesi yüzünden insanlar diyabet olmakta ve bu durum ilerleyen yaşlarda ciddi görme kayıplarına sebep olmaktadır. Ayrıca gelişen teknoloji ile birlikte hayatımıza geçmişe nazaran oldukça yüksek bir seviyede ekranlar dahil olmuş ve gün içerisinde ekran karşısında aşırı derecede zaman harcanmaktadır. Bu da haliyle gözün aşırı yorulmasına ve ilerleyen zamanlarda ciddi bir şekilde görme problemlerine sebep olmaktadır (Resnikoff et al., 2020). Bu tez çalışmasının temel amacı sağlık konusunda uyarı ve tedbirlerden bahsetmekten ziyade günümüz teknolojisinin geldiği nokta itibarıyla yararlarından olabildiğince istifade etmektir. Özellikle yapay zekanın hayatımıza girmesinden sonra hemen hemen bütün alanlarda istifade edilirken sağlık alanında ciddi bir şekilde faydalanılmaktadır. Bu yüzden bu tez çalışmasının amacı güçlü ve doğruluk payı yüksek bir değerlendirme yapmakla beraber olabildiğince zaman tasarrufunda da bulunmaktadır.


Sağlık sorunlarını derecelendirmek ya bu sağlık sorunu bundan daha önemlidir, şundan daha önemli değildir diyebilmek pek mümkün olmamakla beraber başka sorunları tetikleyen veya bütün hayati fonksiyonları etkileyen sağlık sorunlarını da elbette göz ardı etmemek gerekir. Bu sayede belki erken denecek bir zaman sürecinde hastalık teşhis edilip tedaviyle iyileştirilebilir. Bu sayede bireylerin yaşam kalitesi iyileştirilip hayat standartları yükseltilebilir (Apaydın & Bilgin, 2010).

Yaşamsal fonksiyonlarımızın en başında hiç şüphesiz görme yetisi gelir. Görme ile birlikte insanın bulunduğu çevre anlam kazanır. Bunun yanı sıra görme yetisi sayesinde kas işlevleri kısıtlama olmadan yerine getirilir. Bu durum görme yetisini kaybetmiş bir insanın çok yavaş hareket etmesiyle açıklanabilir. Dolayısıyla görme yetisinde meydana gelebilecek sorunlar yaşam kalitemizi son derece olumsuz etkileyecektir. Aktivitelerimizi oldukça kısıtlayacak olup hayati fonksiyonlarımızı zar zor idame etmemize sebep olacaktır (Malkoç, 2005).


İnsan gözü, insanın çevre ile iletişimini sağlayan en işlevsel organıdır. Bir dizi karmaşık işlemten sonra görmeyi sağlayan ve karmaşık bir yapıda olan insan gözü koruyucu ve yapılardan meydana gelmektedir. Görme olayı o kadar hassas bir işlemdir ki görmeyi gerçekleştiren herhangi bir yapının zarar görmesi, kısmi bozulması ya da işlevini tamamen yitirmesi görmeyi son derece olumsuz etkilemektedir. Bundan dolayı gözde meydana gelebilecek olan bu sağlık sorunlarından korunmak için öncelikle gözü ve gözün yapısını iyi tanımak gerekir (Gökmen, 2003).

1.1. Gözün Anatomisi

Göz, görme olayının gerçekleştiği, dış dünya ile irtibatımızı sağlayan en karmaşık yapıya sahip duyu organımızdır. İnsan gözü kornea, iris, lens (mercek), sklera (sert tabaka), koroid (damar tabaka), retina, vitreus jeli, optik sinirler gibi temel yapılardan meydana gelmektedir (şekil 1.1.). Görme olayı da kısaca özetlenecek olursa nesneden gelen ışınlar korneadan geçip ışık yoğunluğuna göre küçülüp büyüyeabilen iristen geçerek lense gelir ve oradan ters görüntü olarak gözün arka kısımlarında bulunan retinanın üzerine düşer. Retina üzerindeki sarı beneğe düşen bu ışınlar bu tabakada bulunan fotoreseptörleri uyarak beyne değerlendirilmek üzere optik sinyaller gönderir ve bunun sonucunda bu sinyallerden anlamlı birer görüntü oluşturmaktadır (şekil 1.2.) (Berger, 2018).



Şekil 1.1. Gözün anatomisi (Gündoğan, 2018)



Şekil 1.2. Görme olayı (Okatan, 2021)


Tez çalışmasının asıl konusu retina hastalıkları olduğu için bu çalışmada en çok üstünde durulacak göz yapısı retinadır.

1.1.1. Retinanın anatomik yapısı

Retina, göz küresinin ışığın üstüne düştüğü en iç ve arka tarafında bulunan oldukça farklılaşmış nöroektodermal bir dokudur. Merkezi retina (makula) ve periferik retina olmak üzere iki ayrı bölgeden oluşmaktadır. Fotoreseptör hücre gövdeleri iç çekirdek katmanında bulunurken iki kutuplu yatay ve amakrin hücre gövdeleri de iç çekirdek katmanında bulunmaktadır (şekil 1.3.) (Curcio et al., 1990).

Görsel algı süreci, retinadaki fotoreseptör hücreleri tarafından başlatılır. Retinada iki temel fotoreseptör tipi bulunur: çubuk hücreleri (rodlar) ve koni hücreleri (koniler). Çubuk hücreleri düşük ışık şiddetinde bile yüksek duyarlılığa sahip olup, gece görüşü (skotopik görüş) ve siyah-beyaz tonlarının algılanmasından sorumludur. İnsan retinasında yaklaşık 120 milyon çubuk hücresi bulunur. Buna karşın, yaklaşık 6 milyon sayısında olan koni hücreleri ise parlak ışık koşullarında (fotopik görüş) çalışır ve renkli, yüksek çözünürlüklü görüntülerin algılanmasını sağlar (Purves et al., 2018). Üç tip koni hücresi mevcuttur ve her biri farklı dalga boylarındaki ışığa (kırmızı, yeşil ve mavi) duyarlıdır. Bu farklılık sayesinde insanlar geniş bir renk spektrumunu ayırt edebilir.

Fotoreseptör hücreleri, ışık uyarısını sinirsel sinyallere dönüştürerek ilk nörotransmisyonu başlatır. Bu sinyaller, bipolar ve gangliyon hücreleri aracılığıyla işlenerek optik sinir (nervus opticus) üzerinden beyne iletilir. Özellikle, gangliyon hücrelerinin aksonları bir araya gelerek optik siniri oluşturur. Bu sinir, görsel bilgiyi önce lateral genikülat çekirdek (LGN) gibi ara beyin yapılarında işler, ardından da görsel kortekse ileterek görsel algının oluşmasını sağlar (Bear et al, 2016). Retina bu yönüyle yalnızca ışığı algılayan bir yapı olmanın ötesinde, görsel bilgiyi ön işlemeye tabi tutan kompleks bir sinir ağı olarak değerlendirilir.




Şekil 1.3. Retinanın histolojik şeması (Erdoğan, 2022)

1.1.2. OCT (Optik Koherens Tomografi)

Optik koherens tomografi, doku katmanlarını yüksek çözünürlükte görüntülemeyi sağlayan yeni bir tıbbi cihazdır. Cihazdan gönderilen ve farklı doku katmanlarından yansarak gelen kızılötesi ışınların şiddetini ve gecikme zamanını hesaplayarak bir görüntü oluşturmaktadır. Bu yönüyle kısmen de olsa radar cihazlarının mantığına benzetilebilir. Radar cihazlarından farklı olarak yansıyan ışıklardan bir görüntü oluşturmaktadır (Gülsüm, 2023).

Kısaca temel çalışma mantığından bahsedilecek olursa, ışık kaynağından gelen ışınların beamsplitter adı verilen yarı geçirgen aynada ikiye ayrılarak bir kısmı referans

aynasına, diğer kısmı da hastanın gözüne gider. Göz katmanlarından yansıyan ışınlarla referans aynasından yansıyan ışınlar interferometrede birleştirilir. Böylece meydana gelen zaman kaybı hesaplanarak görüntüye dönüştürülür.



Şekil 1.4. OCT çalışma prensibi (Arjun, 2017)

Retina hastalıklarında erken tanı ve tedavi önemlidir ve uzmanlık gerektirir. Uzmanların OCT görüntülerinden hastalığı doğru bir şekilde teşhis etmesi zaman alır. (Bhende, 2018) Optik koherens tomografi (OCT), insan retinasında mikron ölçekli yapıyı yakalayabilen, invazif olmayan, yüksek çözünürlüklü bir görüntüleme tekniği olduğu için önemli bir retinal görüntüleme yöntemidir. OCT şu anda diyabetik retinopati (DR) ve yaşa bağlı maküler dejenerasyonun (AMD) teşhisi, prognozu ve tedavi yönetiminde etkilidir (Erdoğan, 2022). Diyabetik retinopati, gelişmiş dünyada çalışma çağındaki nüfus arasında körlüğün önde gelen nedenidir (Pekâlâ, M vd. 2019). Diyabetik makula ödemi (DME) ve diyabetik retinopati (DR) en sık görülen ciddi retina hastalıklarıdır. Her ikisi de geri dönüşü olmayan bir görme bozukluğuna neden olur. İlerleme ile birlikte DME ve DR'nin doğru tanımlanması, büyük ölçüde gelişmiş retinal görüntüleme tekniklerine bağlıdır. Optik koherens tomografi (OCT) görüntüleme, retinadaki küçük değişiklikleri görüntülemek ve yakalamak için yaygın olarak kullanılmaktadır (Aydın & Bilge, 2007).

1.1.3. Retinal hastalıklar

1.1.3.1. CNV (Koroid Neovaskülarizasyonları)

Koroid neovaskülarizasyonu (KNV), retina tabakası altında yeni damarların oluşumudur. Retina altında yeni kan damarlarının büyümesi ve görme bozukluklarına neden olması durumudur. Bu yeni damarlar, sızıntı yaparak retina dokusuna sıvı ve kan sızmasına neden olabilir, bu da görme bozukluğu ve skarlaşma ile sonuçlanabilir. CNV, yaşa bağlı makula dejenerasyonunun (YBMD) ileri evrelerinde yaygın olarak görülür (Dandekar et al., 2005).

Belirtiler:

- Görme alanında karanlık veya boş alanlar
- Düz çizgilerin dalgalı veya kırık görünmesi (metamorfopsi)
- Renkleri daha az parlak veya farklı görme
- Görme keskinliğinde azalma
- Ani görme kaybı

1.1.3.2. DME (Diyabetik Makula Ödemi)

Diyabetik Makula Ödemi, diyabetik retinopati'nin önemli bir komplikasyonudur. Retina'nın merkezinde bulunan ve net görmemizi sağlayan makulada sıvı birikmesi şeklinde tanımlanabilir. Makula, detayları net bir şekilde görmemizi sağlar ve sıvı birikmesi sonucu şişme ve kalınlaşma meydana gelir, bu da görme bozukluğuna veya kaybına yol açar (Bhende et al., 2018).

Belirtiler:

- Bulanık görme
- Çift görme
- Renk algısında değişiklikler
- Görüş alanında karanlık veya boş alanlar
- Okuma veya ince detayları görmede zorluk

1.1.3.3. Drusen

Drusen, retina pigment epiteli altında yaşı bağı olarak biriken sarımsı yağlı protein ve lipid birikintileridir. Drusen, yaşı bağı makula dejenerasyonunun (YBMD) erken bir belirtisi olabilir, ancak herkes için görme kaybına yol açmaz. Drusen genellikle iki türde bulunur: yumuşak drusen ve sert drusen (Deutman & Hansen, 1970).

Belirtiler:

- Görme alanında boş veya karanlık noktalar
- Renkleri daha az canlı görme
- Merkezde bulanık veya dalgalı görme



2. KAYNAK ARAŞTIRMASI

Önceki literatür çalışmalarına bakıldığında göz hastalıkları içinde en çok retina hastalıkları üzerinde durulduğu görülmektedir. Görüntünün asıl gerçekleştiği yerin retina olduğu düşünüldüğünde çalışmaların özellikle bu noktada yoğunlaşması olağan bir durum olarak görülmelidir. Buna binaen bu tez çalışmasının da retina hastalıklarından seçilmesi kaçınılmaz bir durum olarak görülmüştür.

2.1. Tez Çalışması Konusunun Amacı, Önemi ve Özgünlüğü

Retinal hastalıklar yaşamsal aktivitelerin ve yeme içme alışkanlıklarının değişmesi, teknolojinin gelişmesinin olumsuz etkileri ve artan psikolojik sorunların tetiklediği sağlık sorunlarının başında göz hastalıkları geldiği aşıkardır. Göz hastalıklarının içinde de retinal hastalıklarının payı oldukça yüksektir. Bir diğer gerçek şu ki insan nüfusu ve hastalıkları o kadar hızlı artmakta ki sağlık personellerinin hastaları tedaviye yeterince zaman ayıramamaktadır. Hastalara yeterince zaman ayrılmadığı için de tanı ve tedavi eksik kalmakta ve hastalık devam etmektedir. Bu tez çalışması da bu iki ana unsur temel amaç sayılarak sağlık sektörüne faydalı bir çalışma ya da faydalı bir çalışmanın öncülüğünü yapması amaçlanmıştır.

Önceki çalışmalar incelendiğinde bilgisayarın ve özellikle yapay zekanın hayatımıza etkin bir şekilde dahil olmasıyla beraber diğer sektörlerle beraber sağlık sektöründe bilgisayar elzem olmuştur. Bununla beraber yapay zekâ destekli çalışmalar tıbbi çalışmaları etkin bir şekilde kolaylaştırmıştır. Bu çalışmalarda kullanılan yapay zekâ temelli teknikler; morfolojik görüntü işleme, bölge büyütme, gaussian filtre, kenar algılama filtreleri, eşikleme, histogram analizi, çok katmanlı görüntü işleme gibi yöntemler kullanılmıştır. Bu tez çalışmasında her ne kadar diğer çalışmalara bazı yakın çalışma mantıkları içerse de bu çalışmayı diğerlerinden farklı kılan birçok noktası bulunmaktadır. Önceki çalışmalar incelendiğinde aralarındaki en büyük farklardan birinin çalışma/sistem tarafından analiz edilen her bir tomografik görsele bir “hash” değeri atanmasıdır. Böylelikle sisteme yanlışlıkla ya da farkında olmadan aynı görsel yüklenirse sistem tarafından kabul edilmemektedir. Böylece hem istenildiğinde veri tabanındaki görsel kolay bulunmuş olacak, hem de veri kalabalığından da kullanıcıyı kurtarmış olacaktır. Ayrıca yüklenen her tomografik görsel hasta adına kayıt altına alınmış olacaktır. Bir diğer fark da çalışmanın / sistemin OCT görüntüleri dışında farklı görsel kabul etmemesidir. Bu sayede sistem gereksiz analizlerden kurtarmış olup

sistemi meşgul etmekten kurtararak zaman kazandırmış olacaktır. En önemli farklardan biri de sağlık personeli için özel bir arayüz tasarlanmış olmasıdır. Bu sayede sağlık personeli sisteme hastaya ait tomografik görüntüyü yüklediğinde sistem yüksek doğruluk payıyla sonucunu bu arayüzde paylaşmaktadır. Bunu yaparken grafiksel ve oransal ifadeler şeklinde net ve kolay anlaşılır bir biçimde sunmaktadır. Ayrıca bir hastaya ait farklı zamanlar arasındaki grafikleri karşılaştırarak hastalığın gidişatı hakkında sağlık personeline sunmaktadır. Sağlık personelinin arayüzünün yanında bir de hasta arayüzü de sisteme eklenmiştir. Hasta bu arayüz sayesinde doktor ile kolaylıkla iletişime geçmektedir.

Literatür ile ilişkili olarak bu tez çalışması kapsamında hesaplamalı bir tanı modelinin geliştirilmesi hedeflenmiştir ve başlıca katkılar aşağıdaki şekilde özetlenmiştir:

1. Evrimsel sinir ağlarına dayalı hesaplamalı yeni bir tanı sistemi geliştirilecektir. Bunun için gerekirse önişleme ya da hibrit bir yöntem oluşturulacaktır.
2. Özgün tanı sistemi kapsamında yapay zekâ ile birlikte segmentasyon da yapabilen bir model geliştirilecektir. Temel amaçlar:
 - a. Tanı ve segmentasyonu birlikte yapacak bir model geliştirme
 - b. Derin katman sayısını düşürme
 - c. Optimizasyon
 - d. Başarımı artırıcı ek yöntemler kullanılacaktır.
3. Geliştirilen model önceden eğitilmiş modeller ile karşılaştırılacaktır.
4. Model performansı, uzman personel görüşleriyle de karşılaştırılacaktır. Bu tez çalışmasındaki araştırma sorumuz OCT imgelerinden hesaplı bir model yardımıyla Retina hastalıkları teşhisini yüksek doğruluk ile yapılıp yapılmayacağını araştırmaktır.

2.2. Literatür Çalışmaları

Sinthanayothin ve ark. (1999), renkli fundus görüntülerini kullandıkları pikseller arasındaki yoğunluk değişiminden yararlanarak yapay sinir ağlarını yardımıyla sınıflandırıp kan damarlarının yerlerini tespit etmiştir.

Hipwell ve ark. (2000), görüntüleri dijital kırmızı-serbest fundus görüntülerinde DR'yi saptamak için otomatik bir teknik geliştirmiştir. Kavitha ve Shenbaga (2005), retina fundus görüntülerinde medyan filtreleme, morfolojik işlemler ve çok seviyeli eşikleme kullanarak OD'yi ve eksüdaları tespit etmek için hızlı, güvenilir ve etkili bir yöntem geliştirmiştir.

Demirezen (2008), Diyabetik Retinopati, Hipertansif Retinopati, Makula Dejenerasyonu, Alt Ven Dal Tıkanıklığı ve Vitre İçi Hemoraji gibi hastalıkları otomatik olarak tanımak için dalgacık temelli yapay sinir ağı mimarisi uygulamıştır.

Doğanay (2010), hipertansiyon gibi bazı kardiovasküler hastalıklar kan damarları üzerinde değişikliklere sebep olduğundan hipertansiyon hastaları için retina görüntülerinden atardamar daralmasını kullanarak otomatik tanı algoritması geliştirmiştir.

Kılınççeker (2011), tez çalışması kapsamında diyabetik retinopati hastalığının erken teşhisinde, retina damarlarının incelenmesi işlemi için damarların otomatik çıkarılmasına yönelik Radyal Tabanlı Fonksiyon Sinir Ağı sınıflandırıcısı kullanılarak yeni bir yöntem önermiştir. Bu tez çalışmada retina damarlarının çıkarılması ile %93.48 gibi benzer literatür çalışmalarına kıyasla yüksek bir değer elde edilmiştir.

Kanagasingam ve ark. (2014), yılında, yaşa bağlı makula dejenerasyonu için retina görüntü analizinin geliştirilmesi üzerine çalışma yapmışlardır. Bu çalışmayla, otomatik veya yarı otomatik yöntemlerin çoğunun, drusenlerin AMD'nin ilk klinik belirtilerinden biri olması nedeniyle, ağırlıklı olarak farklı görüntüleme teknikleri kullanılarak drusen derecelendirmesine odaklandığını tespit etmiştir. Ayrıca, gelecekteki retina görüntüleme sistemleri ve hastalığın ilerlemesini izlemek için yeni nesil AMD derecelendirme araçlarının potansiyeli de derlenmiştir.

Srinivasan ve ark. (2014), Yönlendirilmiş gradyan (HOG) ve destek vektör makinesine (SVM) dayalı bir sistemle yaşa bağlı maküler dejenerasyon (AMD) ve diyabetik maküler ödem (DME) gibi retinal hastalıkları yüksek doğruluk oranlarıyla teşhis etmeyi amaçlamıştır.

Gargeya ve ark. (2017), diyabetik hastalardan alınan fundus görüntülerini, sağlıklı ve Diyabetik Retinopati (DR) hastası olarak sınıflandırmak için ağaç tabanlı bir sınıflandırma modeli geliştirmişlerdir.

Alsaih ve ark. (2017), SD-OCT görüntülerinde diyabetik maküla ödemi (DME) sınıflandırması için makine öğrenme teknikleri üzerinde çalışma yapmışlardır. Bireysel ve birleşik özellikleri karşılaştırmanın yanı sıra, farklı gösterim yaklaşımları ve farklı sınıflandırıcılar değerlendirilmiştir. En iyi sonuçlar, PCA ve doğrusal destek vektör makinesi (SVM) kullanılarak temsil edilip sınıflandırıldığında LBP vektörleri için elde edilmiş ve %87,5'lik bir duyarlılık (SE) ve %87,5'lik bir özgüllük (SP) sonucu elde edilmiştir.

Hussain ve ark. (2018), spektral-domain optik koherens tomografi (SD-OCT) görüntülerinden elde edilen retinal özellikleri kullanarak yaşa bağlı makula

dejenerasyonu (AMD) ve diyabetik makula ödemi (DME) gibi hastalıkları sınıflandırmak üzere Random Forest algoritmasına dayalı bir model geliştirmiştir. 251 birey üzerinde yapılan deneylerde her veri kümesinde %95'in üzerinde doğruluk ve %96'nın üzerinde genel sınıflandırma başarısı elde edilmiştir.

Lu ve ark. (2018), Optik Koherens Tomografi Görüntülerinden Çok Kategorili Anormalliklerin Derin Öğrenme Tabanlı Otomatik Sınıflandırılması üzerinde çalışma yapmıştır. Kategorizasyon için 100 tek katmanlı evrişimli sinir ağı (ResNet) eğitmiş olup bu eğitim ve optimizasyon için 10 katlı çapraz doğrulama yöntemini uygulamışlar ve mükemmel denilecek seviyede sonuçlar elde etmişlerdir.

Motozawa ve ark. (2019), önerdikleri yaklaşım, iki hesaplamalı derin öğrenme modeline dayanmaktadır. 1621 hastadan toplanan AMD ve Normal OCT görüntülerinden oluşan veri setini transfer öğrenme yaklaşımı kullanılarak zamandan tasarruf ettiler ve modelin verimliliğini %99 çıkardılar.

Serener ve ark. (2019), OCT görüntülerinde kuru ve yaş AMD ayrımı için ResNet ve AlexNet modellerini kullanmıştır. ResNet ile kuru AMD için %99,5 doğruluk elde edilmiştir.

Qingge ve ark. (2019), Optik Koherens Tomografi Görüntülerinden Makula Hastalıklarının Belirlenmesi İçin Optimize Edilmiş Derin Evrişimsel Sinir Ağlarını kullanmışlardır. GoogLeNet, ResNet ve DenseNet gibi mimarilerden yararlanarak hem hesaplama yükünü azaltmış hem de sınıflandırma doğruluğunu da iyileştirdiğini de gözlemlemiştir.

Motozawa ve ark. (2019), normal ve AMD'li hastaların OCT görüntülerini sınıflandırmak amacıyla CNN ve transfer öğrenimi modelleri geliştirmiştir. Farklı görüntü gruplarında yapılan çalışmalarda %99 doğruluk oranı elde edilmiştir.

Perdomo ve ark. (2019), diyabetle ilişkili retina hastalıklarının sınıflandırılmasında Spectral Domain OCT (SD-OCT) görüntülerine özel tasarlanmış derin öğrenme modeli olan OCT-NET'i önermiştir. Model, B-tarama görüntülerini sınıflandırmakla kalmayıp, tahminin yapıldığı bölgeleri vurgulayarak klinik yorumlamaya katkı sağlamaktadır. SERI+CUHK veri kümesinde %93 doğruluk ve A2A veri kümesinde %99 AUC değeri ile başarılı sonuçlar elde edilmiştir.

Sertkaya ve ark. (2019), optik koherens tomografi (OCT) görüntülerinden Choroidal Neovascularization (CNV), Diyabetik Makula Ödemi (DME), Drusen ve sağlıklı retina durumlarını sınıflandırmak için derin öğrenme mimarileri kullanmıştır. LeNet, AlexNet ve VGG16 mimarileriyle yapılan deneylerde özellikle AlexNet ve VGG16 modellerinin başarılı sonuçlar verdiği rapor edilmiştir.

Berrimi ve ark. (2020), CNV, Drusen, DME ve AMD gibi retinal hastalıkların tespit edilmesi için Optik Koherens Tomografisi görüntülerini barındıran veri setinden faydalanan Evrişimsel Sinir Ağları (CNN) mimarisi kullanmışlardır.

Zhang ve ark. (2020), Optik Koheren Tomografi Görüntüsü ve Çok Ölçekli Derin Öğrenme ile Diyabetik Makula Ödemi ve Diğer Retina Hastalıklarının Belirlenmesi üzerinde çalışmalar yapmıştır. Evrişimsel sinir ağları (CNN) mimarisi ve çok ölçekli kenar tespit yöntemini kullanarak yüksek doğruluk oranlı sonuçlar elde etmiştir.

Sun ve ark. (2020), dikkat mekanizmasıyla güçlendirilmiş ResNet-50 CNN mimarisiyle iki boyutlu özellik haritalarını kullanarak makula hastalıklarının otomatik tanısını gerçekleştirmiştir. Duke veri setinde %98,17 doğruluk elde edilmiştir.

Yoo ve ark. (2021), çalışmalarında birden fazla veri kümesi birleştirilerek 9 sınıflı büyük bir veri kümesi elde edilmiştir. Önerilen yaklaşımda, derin öğrenme modelleri ile GAN modelinin hibritleştirilmesi sağlanmıştır. Görüntülere GAN tabanlı büyütme tekniği uygulandı. 84126 adet görüntüden oluşan bu veri setine uygulanan model %93,9 başarımlıdır.

Acar ve ark. (2021), katarakt hastalığının otomatik teşhisi için derin öğrenme tabanlı bir sistem geliştirmiştir. Çalışmada, fundus görüntülerinden oluşan veri seti üzerinde transfer öğrenme ile eğitilen VGGNet ve DenseNet mimarileri kullanılmış ve sırasıyla %97,94 ve %95,07 doğruluk elde edilmiştir. Sistem, düşük maliyetli ve etkili bir bilgisayar destekli teşhis aracı olarak önerilmiş ve tele-tıp uygulamalarına entegrasyon potansiyeli vurgulanmıştır.

Shi ve ark. (2021), coğrafik atrofinin OCT taramalarında tespitine yönelik olarak Med-XAI-Net adında bir derin öğrenme modeli önermiştir. OCT hacim taramaları üzerinde yapılan deneylerde %91,5 doğruluk oranına ulaşılmıştır.

Rajagopalan ve ark. (2021), CNV, Drusen, DME ve AMD gibi retinal hastalıkların tespit edilmesi için Optik Koherens Tomografisi görüntülerini barındıran veri setinden faydalanan Evrişimsel Sinir Ağları (CNN) mimarisi kullanmışlardır. CNN kullanılarak Optik Koherens Tomografi görüntülerinden retina bozukluklarının teşhisi üzerinde çalışma gerçekleştirmiştir. Gelecekte daha büyük taramalar için de etkili olabileceği öngörüsüyle yüksek doğruluk oranlı sonuçlar elde edilmiştir.

Draskovic ve ark. (2022), CNV, Drusen, DME ve AMD gibi retinal hastalıkların tespit edilmesi için Optik Koherens Tomografisi görüntülerini barındıran veri setinden faydalanan Evrişimsel Sinir Ağları (CNN) mimarisi kullanmışlardır. Derin evrişimli sinir ağı kullanılarak optik koherens tomografi görüntü tabanlı göz hastalıklarını tespit

etmeye çalışmıştır. Çalışma sırasında, AlexNet, VGG, Inception ve ResNet olmak üzere birkaç farklı mimari arasından sınıflandırmada en başarılı olduğu kanıtlanan evrişimli sinir ağı kullanılmıştır. OCT görüntülerine dayalı retina hastalıklarının sınıflandırılmasında uygulanabilen farklı mimarilerin analizi yapılmış ve farklı modellerin karşılaştırılmasıyla elde edilen test setinin değerlendirilmesi yüksek doğruluk oranlarıyla yapılmıştır.

Salaheldin ve ark. (2022), CNV, Drusen, DME ve AMD gibi retinal hastalıkların tespit edilmesi için Optik Koherens Tomografisi görüntülerini barındıran veri setinden faydalanarak Evrişimsel Sinir Ağları (CNN) mimarisi kullanmışlardır. Optik Koherens Tomografi Görüntülerini Kullanarak Retina Bozukluklarının Sınıflandırılması İçin Makine Öğrenmesine Dayalı Mimari üzerinde çalışma yapmışlardır. Destek vektör makinesi (SVM), K-en yakın komşu (K-NN), karar ağacı (DT) ve topluluk modeli (EM) gibi sınıflandırıcılarla ve özellik çıkarıcı olarak iki derin öğrenme yöntemi, Inception v3 ve SqueezeNet kullanılmaktadır. K-NN, sınıflandırma probleminde diğer sınıflandırıcılardan üstün olduğunu kanıtlamıştır.

Elsharif ve ark. (2022), Kermany veri setinden seçilen 40.000 OCT görüntüsünü kullanarak ResNet-50, VGG-16, MobileNet, Inception V3 ve Xception gibi farklı CNN mimarileriyle retina hastalıklarının sınıflandırmasını gerçekleştirmiştir. En iyi sonuç %96,21 test doğruluğu ile ResNet-50 modeliyle elde edilmiştir.

Elsharkawy ve ark. (2022), 3D-OCT retina katmanları kullanarak Diyabetik Retinopati (DR) tespiti bir yaklaşım sunmuşlardır. Çalışmada, 188 hastadan toplanan OCT görüntüleri kullanılarak testler yapılmıştır. Önerilen sistem, otomatik olarak segmente edilmiş 3D-OCT retina katmanlarından 3D-MGRF'ye dayalı daha yüksek dereceli bir mekânsal görünüm modeli tahmin etmiştir. Bu deneysel çalışmada önerilen model ile sırasıyla %96,8 doğruluğu elde edilmiştir.

Pin ve ark. (2022), 1304 adet OCT görüntüsünden oluşan AMD, DR ve Glokoma hastalığını tespit etmek için bir model oluşturdular. Oluşturdukları model %86 doğruluğa sahiptir. Transfer öğrenme yaklaşımı kullanan bu çalışma doğru değerlendirmeye katkı sağladığı tespit edilmiştir.

He ve ark. (2022), yaşa bağlı makula dejenerasyonunun tespitinde ResNet-50 tabanlı özellik çıkarımı ve Local Outlier Factor (LOF) algoritmasıyla sınıflandırma yapan bir sistem önermiştir. UCSD veri setiyle yapılan çalışmada %99,78 doğruluk oranı elde edilmiştir.

Karthik ve ark. (2023), Optik koherens tomografi (OCT) görüntü sınıflandırması için evrişim sinir ağlarından faydalanmıştır. Model tasarımı için ensorFlow ve Scikit-learn Python kütüphanelerinden faydalanılırken veri görselleştirme ve sonuçların grafiksel gösterimi için Matplotlib ve Seaborn'dan faydalanılmakta ve geliştirdikleri modelde türevlerin kontrastını artırarak daha keskin özellik haritaları çıkartmaktadır. Grafiksel çalışma, karışıklık matrisleri ile parametrik bir çalışma, özellik haritalarının görselleştirilmesi, ablasyon çalışması ve son olarak istatistiksel testler gerçekleştirilmiştir.

Baharlouei ve ark. (2023), retinal anormalliklerin sınıflandırılması amacıyla dalgacık saçılma dönüşümü (wavelet scattering transform) kullanan CNN tabanlı bir yöntem geliştirmiştir. Heidelberg ve Duke veri setleri ile yapılan deneylerde en yüksek doğruluk Heidelberg setinde %97.1 olarak elde edilmiştir.

Kırık ve ark. (2023), SD-OCT görüntülerinden diyabetik makula ödemi (DME) tespit etmek amacıyla kodsuz bir makine öğrenmesi aracı olan Lobe uygulamasını kullanmış, bu araç önceden eğitilmiş ResNet-50 V2 modelini temel almıştır. Kendi topladıkları 895 görüntü üzerinde yapılan çalışmada %99.28 duyarlılık elde edilmiştir.

Aykat ve ark. (2023), CNV, DME ve Drusen hastalıklarını OCT görüntüleriyle tespit etmek amacıyla EfficientNetV2S ve Xception mimarilerini birleştirerek EffXceptNet adlı hibrit bir model önermiştir. %99.90 doğruluk, kesinlik ve duyarlılık oranı elde eden bu model, klasik CNN mimarilerinden daha başarılı bulunmuş ve erken tanıyla sağlık hizmeti maliyetlerinin azaltılabileceği vurgulanmıştır.

Kulyabin ve ark. (2024), OCTDL veri seti (2.064 görüntü) üzerinde ResNet50 ve VGG16 modellerini karşılaştırarak retina hastalıklarının sınıflandırılmasını gerçekleştirmiştir. En yüksek başarı %85.9 doğruluk oranı ile VGG16 modeliyle elde edilmiştir.

Borno ve ark. (2024), göz hastalıklarının güvenli şekilde tanınması amacıyla federated learning çerçevesinde optimize edilmiş DeiT tabanlı çok ölçekli yama gömme (multiscale patch embedding) ve LoRA mekanizmalarını birleştirerek gelişmiş bir hibrit model önermiştir. OCTDL ve Eye Disease Image veri setleri üzerinde gerçekleştirilen çalışmada %100 Top-5 doğruluk oranı elde edilmiştir.

Gueddena ve ark. (2024), yılında OCT görüntülerinde DME ve AMD'yi tespit etmek için derin öğrenmeye dayalı yeni bir yapay zeka sistemi üzerine çalışma yapmışlardır. Öğrenme ve sınıflandırma dahil olmak üzere CNN verimliliğinden yararlanarak, önceden eğitilmiş VGG16, VGG19, Inception_V3, sıfırdan özel bir

model, BCNN (VGG16) dahil olmak üzere çeşitli CNN'ler, BCNN (VGG19) ve BCNN (Inception_V3), AMD, DME ve Normal OCT görüntülerinin sınıflandırılması için geliştirilmiştir. Veri setlerinden yüksek doğruluk oranına sahip sonuçlar elde edilmiştir.

Gencer ve ark. (2025), EfficientNetB0 ve Xception mimarilerine Squeeze-and-Excitation (SE) bloklarını entegre ederek geliştirdikleri hibrit bir model ile OCT görüntülerinden retina hastalıklarını sınıflandırmayı hedeflemiştir. UCSD (yaklaşık 83.400 eğitim, 900 test görüntüsü) ve Duke (yaklaşık 300 eğitim, 100 test görüntüsü) veri setleriyle yapılan deneylerde, model %99.58 (UCSD) ve %99.18 (Duke) doğruluk oranlarına ulaşarak yüksek başarı sağlamıştır.


Burada adı geçen ve çalışmayı bir nebze olsun kısa tutmak amacıyla zikredilmeyen çalışmalarda da görüldüğü üzere en kapsamlı çalışmanın bu çalışma olduğu açıkça görülmektedir. Literatürdeki diğer çalışmalara kıyasla, söz konusu çalışma kapsam, metodolojik çeşitlilik ve performans açısından öne çıkmaktadır. Geliştirilen sistemin, gerekli etik izinlerin sağlanması ve altyapı entegrasyonlarının gerçekleştirilmesi halinde, sağlık bilişimi alanında klinik uygulamalara entegre edilebilir nitelikte olduğu ve bu sayede tanı süreçlerinde etkinliğin ve erken teşhis imkânlarının artırılmasına önemli katkılar sağlayabileceği değerlendirilmektedir.

3. MATERYAL VE YÖNTEM

3.1. Önerilen Sistem Mimarisi

Bu tez çalışmasında retina hastalıklarının tespiti amacıyla geliştirilen yapay zekâ tabanlı karar destek sistemi, çok katmanlı ve modüler bir mimariye sahiptir. Sistem, verinin toplanmasından modelin çıktı üretmesine kadar tüm işlem basamaklarını kapsayan kapsamlı bir hesaplamalı çerçeve sunmaktadır. Önerilen mimari, özellikle sağlık alanındaki yapay zekâ uygulamalarında sıklıkla karşılaşılan veri çeşitliliği, doğruluk, güvenlik, kullanılabilirlik ve entegrasyon gibi temel gereksinimleri karşılamayı hedeflemektedir.

Sistem mimarisi; veri girişi, ön işleme, yapay zekâ modeli, kullanıcı arayüzü, veri tabanı ve güvenlik katmanlarından oluşmaktadır. Her bir katman hem bağımsız hem de bütünleşik olarak çalışabilmekte, böylece sistemin ölçeklenebilirliğini ve esnekliğini artırmaktadır. Bu yapı sayesinde sistem, farklı kullanıcı ihtiyaçlarına ve değişen veri yapısına uyum sağlayabilecek şekilde tasarlanmıştır.



Şekil 3.1. Önerilen sistem mimarisi genel özellikleri

3.1.1. Veri seti oluřturma

OCT-2017 veri seti, Optik Koherens Tomografi (OCT) adı verilen tıbbi bir görüntüleme tekniğı kullanılarak elde edilen retinal görüntülerden oluřmaktadır. Retinal OCT, gözün retinasının yüksek çözünürlüklü kesit görüntülerini elde etmek için kullanılan bir yöntemdir. Retina, görme duyusundan sorumlu olan gözün arka kısmın yer alan önemli bir tabakadır. Bu görüntüler, çeřitli göz hastalıklarını tespit etmek ve teşhis etmek için kullanılabilir.

Veri seti Kaggle platformunda yayımlanmıştır. Veri seti, DME (Diyabetik Makula Ödemi), Drusen, CNV (Koroid Neovasküler Membran) ve Normal olmak üzere dört farklı retinal hastalık kategorisinden görüntüler içerir.

Tablo 3.1.de veri setindeki kayıtların eğitim ve seti olarak kullanılmasına ilişkin detaylara yer verilmiştir. Bu çerçevede:


- CNV: Koroid Neovasküler Membran kategorisinde 37.205 adet eğitim görüntüsü ve 242 adet test görüntüsü bulunmaktadır.
- DME: Diyabetik Makula Ödemi kategorisinde 11.350 adet eğitim görüntüsü ve 242 adet test görüntüsü bulunmaktadır.
- DRUSEN: Drusen kategorisinde 8.616 adet eğitim görüntüsü ve 242 adet test görüntüsü bulunmaktadır.
- NORMAL: Normal kategorisinde 26.318 adet eğitim görüntüsü ve 242 adet test görüntüsü bulunmaktadır.

Tablo 3.1. OCT-2017 Verilerin dağılımı

Sınıf	Eğitim Verisi	Test Verisi
CNV	37.205	242
DME	11.350	242
DRUSEN	8.616	242
NORMAL	26.318	242

Dipnot: veri seti linki: <https://www.kaggle.com/datasets/paultimothymooney/kermany2018>

Tablo 3.1.den anlaşılacağı üzere, veri seti her hastalık kategorisi için dengeli (balanced) bir şekilde dağıtılmıştır. Her kategoride eğitim için kullanılan görüntü sayısı, test için kullanılan görüntü sayısından önemli ölçüde fazladır. Bu durum, derin öğrenme modellerini eğitmek için uygun bir veri seti olduğunu göstermektedir.



Şekil 3.2. OCT veri setine ait rastgele seçilmiş bazı örnekler (Mooney, 2018)

3.1.2. Veri girişi, görüntü işleme ve doğrulama, ön işleme katmanı

Sistem, OCT cihazları aracılığıyla elde edilen retinal görüntülerin sınıflandırılmasını hedeflemektedir. Kullanıcılar (doktorlar veya hastalar) sistemi kullanırken, görüntüleri üç farklı yöntemle (dosya yükleme, kamera ile yakalama veya pano üzerinden yapıştırma) sisteme dahil edebilmektedir. Görüntü yüklendikten sonra, sistem ilk olarak görüntünün geçerliliğini kontrol etmekte ve yalnızca OCT formatına uygun olan görüntüler işleme alınmaktadır. Bu doğrulama süreci, sistemin hatalı veri ile eğitilmesini veya analiz yapılmasını önlemektedir.

Görüntü doğrulayıcı katman, yüklenen verinin gerçek bir OCT görüntüsü olup olmadığını kontrol eder. Ardından, görüntü üzerinde temel ön işleme adımları gerçekleştirilir. Bu işlemler arasında boyutlandırma, normalleştirme ve renk kanallarının yeniden düzenlenmesi gibi işlemler yer almaktadır. Bu süreç, modelin girişine uygun standart bir format sağlar ve eğitim sırasında karşılaşılan sapmaları azaltır.

Görüntü piksellerden oluşur ve görüntü üzerindeki herhangi bir noktanın piksel değeri o noktaya ait görüntü rengi veya koyuluğu hakkında bilgi verir. Görüntü işlenirken de işlenen görüntünün referans görüntüyle bir takım matematiksel işlemlerle karşılaştırılması yapılır. Bu sayede benzerlikleri veya farklılıklarından yola çıkarak sınıflandırılması mümkün olur. Bu tez çalışması için de çok sayıda çeşitli görüntü işleme algoritması kullanılmamıştır ancak yüklenen görüntünün bir röntgen görüntüsü olup olmadığını bir fonksiyon ile kontrol edip öyle işleme devam edebilecek şekilde düzenlenmiştir. Bu sayede de sistemi gereksiz ve alakasız imaj dosyalarını işlemekten kurtarmış olup performans ve zaman tasarrufu sağlama amaçlanmıştır.

3.1.3. Derin öğrenme tabanlı yapay zekâ modülü

Modelin temelini, Evrimsel Sinir Ağları (CNN) oluşturmaktadır. Bu kapsamda GoogleNet, ResNet50, EfficientNet-B0 ve DenseNet-201 gibi farklı derin öğrenme mimarileri test edilmiş ve performansları karşılaştırılmıştır. Yapılan deneysel çalışmalar sonucunda en yüksek başarı oranı DenseNet-201 modeli ile elde edilmiştir. DenseNet mimarisi, her katmanın çıktısını sonraki tüm katmanlara ileterek bilgi kaybını en aza indirmekte ve öğrenme sürecini hızlandırmaktadır. Bu katmana ait detaylı bir araştırma tez çalışmasının kullanılan derin öğrenme mimari ve modelleri başlığı adı altında anlatılmakta ve sonuçlar ise tez çalışmasının bulgular bölümünde tablo ve grafiklerle detaylı olarak irdelenmektedir.

Model, eğitim sürecinde OCT-2017 veri setinden elde edilen 83.000+ görüntü ile eğitilmiş, daha sonra etiketlenmiş test görüntüleriyle doğrulanmıştır. Eğitim süreci boyunca erken durdurma (early stopping), öğrenme oranı planlaması ve optimizasyon teknikleri (örneğin ADAM algoritması) kullanılarak modelin aşırı öğrenmeden kaçınması sağlanmıştır.

Model eğitim sürecinde, ağırlıkların güncellenmesinde optimizasyon algoritması olarak Adam (Adaptive Moment Estimation) algoritması tercih edilmiştir. Adam algoritması, klasik Stochastic Gradient Descent (SGD) yöntemine kıyasla daha hızlı ve kararlı bir öğrenme süreci sunmaktadır. Bu algoritma, geçmişteki gradyanların ortalamasını (momentum) ve gradyan karelerinin ortalamasını (adaptive learning rate) eş zamanlı olarak dikkate alarak, her parametre için ayrı ayrı adaptif öğrenme oranları belirlemektedir. Bu özellik, özellikle yüksek boyutlu ve karmaşık veri setlerinde (bu çalışmada kullanılan OCT-2017 veri seti gibi) modelin öğrenme sürecini hızlandırmakta ve aşırı öğrenme (overfitting) problemini azaltmaktadır.

Adam algoritması aşağıdaki temel adımlar ile çalışır (Kingma & Ba, 2015):

- İlk ve ikinci moment tahminleri hesaplanır.
- Bu moment tahminleri öngerçekleştirilmiş (bias-corrected) hale getirilir.
- Öğrenme oranı, her parametre için bu tahminlere göre dinamik olarak ayarlanır.
- Ağırlıklar, güncellenmiş öğrenme oranlarına göre optimize edilir.

3.1.4. Karar destek ve tahmin süreci

Doğrulan görüntüler yapay zekâ modeline iletdikten sonra, model her bir görüntüyü dört farklı sınıftan biri (CNV, DME, Drusen, Normal) olarak sınıflandırır. Bu tahminler, Softmax fonksiyonu ile 0-1 arasında olasılık değerleriyle sunulur. Model aynı zamanda F1 skoru, doğruluk (accuracy), hassasiyet (sensitivity), özgüllük (specificity) gibi metriklerle performansını ölçer. Bu katmana ait sonuçlar tez çalışmasının bulgular bölümünde tablo ve grafiklerle detaylı olarak irdelenmektedir.

3.1.5. Kullanıcı arayüzü (UI)


Sistem kullanıcıları için özel olarak geliştirilen arayüz, Python dilinde Gradio kütüphanesi kullanılarak tasarlanmıştır. Retina hastalıkları sınıflandırması yapan doktor web ara yüzünde gradio kütüphanesi ile gelen 3 farklı görüntü yükleme seçeneği mevcuttur. Kullanıcı ister bilgisayardan veya başka bir cihazdan direkt kendi dosyalarından seçip yükleyebilir ya da görüntüyü kamera ile yükleyebilir ya da herhangi bir yerden kopyaladığı görüntüyü direkt yapıştırıp işleme sokabilir.

Doktorlar için tasarlanan arayüzde yüklenen görüntüler sınıflandırılır, sonuçlar hem grafiksel hem de tablolı formatta sunulur. Sistem aynı zamanda geçmişte yüklenmiş görüntüleri analiz ederek hastalığın ilerleyişi hakkında zaman serisi temelli karşılaştırmalar yapabilmektedir. Hasta arayüzü ise daha basitleştirilmiş olup, doktor-hasta iletişimini destekleyici özellikler içermektedir.

Kullanıcı arayüzü oldukça sade, anlaşılır ve kullanıcı dostu bir yapıya sahiptir. Web sitesine giriş yaptıktan sonra doktor paneline erişim açık ve nettir. Doktor arayüzü dört temel bölümden oluşmaktadır: birinci bölümde kullanıcı tarafından görüntü yüklemesi gerçekleştirilir; ikinci bölümde yüklenen görüntüye ait hastalık etiketi sunulur; üçüncü bölümde sınıflandırma sonucuna ilişkin tahminler dinamik bir grafik aracılığıyla görselleştirilir; dördüncü ve son bölümde ise hastalık tahmin oranları tablo formatında kullanıcıya sunulur. Sistemin bu yapılandırması, kullanım kolaylığı


sağlayarak sağlık profesyonellerinin ve diğer kullanıcıların herhangi bir teknik bilgiye ihtiyaç duymadan sistemi etkin biçimde kullanmalarını mümkün kılmaktadır. Web arayüzü üzerinde sistemin nasıl çalıştığını açıklayan detaylı bilgiler yer almakta olup, bu sayede ek bir eğitim materyali ya da rehber gerekliliği duyulmamaktadır.

Tez çalışması için tasarlanan yapay zekâ modeli bir dizi karmaşık işlem gerektiriyor gibi görünse de oluşturulan arayüz sayesinde kullanımı son derece basitleştirilmiştir. Kullanıcı ister hasta isterse sağlık personeli olsun (doktor, radyoloji uzmanı vs.) kendileri için tasarlanan arayüzü herhangi bir eğitim veya eğitim materyali gerektirmeden kullanabilecek düzeyde basittir.




Şekil 3.3. Sistem web arayüzü

Sistem ilk açıldığında kullanıcıyı şekil 3.3.teki gibi bir arayüz karşılamaktadır. Bu ilk sayfada çalışmada konuya dahil olan hastalıklar ve belirtileri özetlenmiştir. Arayüzde dört ayrı kısım bulunmaktadır ve doktor ara yüzü haricinde geri kalan kısımlarının tamamında HTML ve CSS kullanılmıştır. Ana sayfa kısmında hastalıkların tanımları, belirtileri ve hastalıkların röntgen çıktıları karşılaştırılmıştır. Articles kısmında ise bu çalışmada faydalanılan ve literatür taramasının yapıldığı makaleler bulunmaktadır. Contact bölümü ile doktor veya geliştirici ile bağlantı sağlanmaktadır.



Şekil 3.4. Sistem Articles (makaleler) arayüzü


Şekil 3.4.te görülen arayüzde çalışma esnasında istifade edilen makaleler veya bu konuda çalışma yapmak isteyen kişilerin faydalanabileceği faydalı makaleler listelenmektedir.



Şekil 3.5. Sistem contact (iletişim) arayüzü

Contact kısmı ile sistemi kullanırken oluşan herhangi bir aksaklık durumunda veya bu çalışmaya benzer çalışmalar yapmak istenildiğinde geliştirici ile kolay bir şekilde iletişime geçebilmek için şekil 3.5.te görüldüğü gibi bir Contact form

bulunmaktadır. Ayrıca hastalar da contact kısmı ile kendi mail adresini de girmek kaidesiyle kendi şikayetlerini veya aklına takılan bir durumu doktoruna sorabilmektedir. Sistem üzerinden beyan edilen fikir, şikâyet ya da istekler doktora mail aracılığıyla iletilmektedir. Sistem geliştirilme aşamasında olduğu için haliyle bazı teknik aksaklıklar meydana gelebilmektedir. Dolayısıyla contact bölümünden geliştiriciye bilgi verilebilmektedir.



Şekil 3.6. Doktor işlem ara yüzü

Şekil 3.6.da görülen bölümdeki arayüz kısmında da görüntünün yüklenip işlendiği kısımdır. Bu ara yüz kısmını tamamen gradio ile geliştirilmiştir. 3 farklı görüntü yükleme seçeneği mevcut, kullanıcı görüntüyü direk cihazdan yükleyip işleyebilir ya da kamera açıp görüntüyü gösterip işleme sokabilir ya da görüntüyü kopyalayıp direk yapıştırılabilir. Görüntüyü verdikten sonra görüntünün geçerli olup olmadığı kontrol edilir görüntü geçersiz ise işlem yapılmaz, görüntü doğrulandıktan sonra ise görüntünün hangi hastalık sınıfına ait olduğunu etiketi ve görüntüye ait doğruluk oranları bir grafik ve tabloda görüntülenir. Tüm işlemler tamamlandıktan sonra görüntü id'si, hash değeri, görüntünün kendisi ve görüntüye ait bulunan hastalık sınıfı otomatik olarak veri tabanına kaydedilir.

3.1.6. Veri tabanı ve güvenlik katmanı

MongoDB kullanılarak yapılandırılmış olan veri tabanı, her yüklenen görüntüye sistem tarafından benzersiz bir hash değeri atamakta ve bu sayede veri tekrarının önüne geçilmektedir. Sistem, aynı görüntünün yeniden yüklenmesi durumunda bu hash değeri aracılığıyla daha önce işlenip işlenmediğini kontrol etmekte, eğer görüntü önceden kaydedilmişse analiz yapılmakta ancak veri tabanına tekrar kaydedilmemektedir. Bu yapı sayesinde veri tabanında gereksiz veri yığınları oluşmasının önüne geçilmekte, sistem performansı korunmakta ve daha düzenli bir veri yapısı sağlanmaktadır. Ayrıca bu yöntem, yeni ve özgün veri setlerinin oluşturulmasına da katkı sunmakta; araştırma ve model eğitimi süreçlerinde daha temiz ve tekrarsız veri kümeleri elde edilmesine olanak tanımaktadır. Veriler, hasta mahremiyetine saygı ilkesi doğrultusunda tamamen gizli biçimde MongoDB üzerinde saklanmakta ve erişim yalnızca yetkilendirilmiş kullanıcılarla sınırlandırılmaktadır. Böylece hem veri bütünlüğü hem de hasta gizliliği güvence altına alınmaktadır.

Veri tabanı yönetimini MongoDB veri tabanının sahip olduğu özellikler ile kolay bir şekilde yapılmıştır. Veri tabanı bağlantısını ara yüze entegre edildikten sonra otomatik bir şekilde veri tabanını oluşturulmuştur. Veri tabanında bulunan tabloda yüklenen her görüntüye ait 4 tane değer bulunmaktadır. Bunlar görüntünün id 'si, hash değeri, görüntünün kendisi ve görüntüye ait hastalık etiketi bulunmaktadır.

Sağlık sektörü en çok mahremiyet, dikkat ve hassasiyet gerektiren bir sektör olduğu için hasta verilerinin gizliliği ve güvenliği en üst düzeyde tutulmalıdır. Bu yüzden sistemdeki verilerin gizliliği ve bütünlüğünü sağlamak için en üst düzey güvenlik önlemleri alınmalıdır. Sistem şu an için herhangi bir kullanıcı giriş ekranına sahip olmadığından kullanıcı bazlı önlem alınmamıştır ancak görüntülerin güvenli bir şekilde tutulabilmesi için her görüntünün değerini hashlenmiş ve MongoDB' nin sağladığı güvenlik önlemleri kullanılmıştır.

3.1.7. Sistem dağıtımı ve entegrasyon potansiyeli

Sistem, sağlık kuruluşlarındaki mevcut bilgi sistemlerine (örneğin hastane otomasyon yazılımları, e-Nabız gibi platformlara) entegre edilebilecek şekilde geliştirilmeye açıktır. Aynı zamanda, OCT cihazlarına gömülü sistem olarak entegre edilmesi halinde gerçek zamanlı tanı desteği sağlayabilir.

3.2. Kullanılan Teknolojiler

Bu tez çalışmasında başlıca kullanılan teknolojiler aşağıda sıralanmıştır:

1. HTML
2. CSS
3. Gradio
4. Tensorflow
5. MongoDB

3.2.1. HTML

İnternet üzerinden kullanıcıya yazı, görsel, animasyon vb. araçlarla bilgi veren veya hizmet etmeyi amaçlayan sayfalara web sayfası denilmektedir. Web sayfaları aracılığıyla bilgi ve hizmet sunan bu sayfalar ve dokümanlar topluluğuna da web sayfası denir. HTML ise web sayfalarının iskeletini oluşturan işaretleme dilidir. HTML, sayfanın içeriğini ve yapısını tanımlamak için kullanılır. Bir web sayfası içindeki metnin (text) yapısını, biçimini ve genel görünümünü tanımlayarak kullanıcının ya da ziyaretçinin kullanıma hazır hale getirir. HTML öğeleri, başlıklar, paragraflar, bağlantılar, resimler ve diğer içerik türlerini tanımlamak için kullanılır. Her HTML belgesi, kök elemanı olan <html> etiketiyle başlar ve bu etiketin içinde <head> ve <body> etiketleri bulunur. <head> etiketi, sayfa hakkında meta bilgiler içerirken, <body> etiketi sayfanın görünen içeriğini barındırır. Şekil 3.3.te html temel yapısını görmek için basit bir örnek html kodları gösterilmektedir (A. Sharma, & A. Sharma, 2018).

```
<html>
  <head>
    <title>Basit bir HTML metni başlığı</title>
  </head>
  <body>
    <h1>HTML, Web'in dilidir.</h1>
    <p>Bu metnin ilk paragrafıdır.</p>
    <p>Bu da ikinci paragraftır.</p>
  </body>
</html>
```

Şekil 3.7. Örnek HTML kodları (Çukurova Üniversitesi,2015)

3.2.2. CSS

CSS, web sayfalarının görünümünü ve düzenini tanımlamak için kullanılan stil dilidir. CSS, HTML öğelerinin nasıl görüneceğini belirlemek için kullanılır. Renkler, yazı tipleri, boşluklar, kenarlıklar ve düzen gibi görsel stilleri tanımlayabilir. CSS, HTML belgelerine yerleştirilebilir, dâhili olarak tanımlanabilir veya harici bir dosya olarak bağlanabilir. CSS, özellikle dinamik web sitesi tasarımlarının en elzem yazılım dilidir. Web sayfalarının yapılarını içerik kısmı, biçimlendirme kısmı ve dinamik kısım şeklinde 3 kısıma ayırabiliriz. İçerik kısmı, genelde metinlerden oluşsa da resim, animasyon ve video gibi elemanları da içeren HTML kodlarını içeren sayfa asıl içeriğini oluşturan birimleri oluşturma kısmıdır. Biçimlendirme kısmı, içerik kısmını kullanıcıya nasıl görüntüleneceğini gösteren, biçimini belirleyen kısımdır. Kullanıcının ilgisini cezbeden gerekli elemanları içerir. Dinamik kısım, etkileşimli sayfalar oluşturmak için JavaScript ile yapılan dinamik işlemleri içerir (Çimeliler & Çelik, 2008; Bos et al., 2011).


3.2.3. Gradio

Gradio, makine öğrenimi ve derin öğrenme modelleri için hızlı ve etkileşimli kullanıcı ara yüzleri (UI) oluşturmayı kolaylaştıran bir Python kütüphanesidir. Bu kütüphane, kullanıcıların modelleriyle web tabanlı ara yüzler üzerinden etkileşime geçmelerini sağlar, böylece anında geri bildirim alabilirler. Gradio, metin, görüntü, ses gibi çeşitli veri türlerini destekler ve birkaç satır kodla kolayca kullanılabilir. Araştırmacılar ve geliştiriciler, Gradio sayesinde modellerini hızla prototip haline getirebilir ve kullanıcı geri bildirimlerini toplayabilir. Ayrıca, Gradio ile oluşturulan ara yüzler geçici bir URL ile paylaşılabilir, bu da model demolarının kolayca başkalarıyla paylaşılmasını sağlar (Abid et al., 2019).

3.2.4. Tensorflow

Yapay zekâ modeli için TensorFlow tercih edilmiştir. Tensorflow, derin öğrenme ve yapay zekâ projeleri için açık kaynaklı bir kütüphanedir. Verilerin çok boyutlu dizisini temsil eden tensör terimi ile bu tensörlerin işlem akışını temsil eden flow kelimelerinden oluşan yapıdır. Yapısal esneklik ve yüksek performansıyla öne çıkan Tensorflow, çeşitli derin öğrenme modellerinin oluşturulmasını, eğitilmesini ve

dağıtılmasını sağlar. Tensorflow 'un geniş bir topluluğa sahip olması, yeni başlayanlar için kolaylıkla öğrenilebilir bir kaynak olmasını sağlar. Bu tez çalışmasında Tensorflow, OCT retina hastalıkları sonuçlarından elde edilen görüntülerin analiz edilmesi ve kanserli hücrelerin sınıflandırılması için kullanılmıştır (Liu & Grana, 2019).



Şekil 3.8. Tensorflow basit çalışma prensibi (Bakshi,2024)

3.2.5. MongoDB

Veri tabanı, bir olgu, bir çalışma hakkındaki bilgilerin, bir diğer tanımla verilerin saklandığı ve sonradan kullanılmak, işlenmek üzere çeşitli işlemlerin yapılabildiği yapılardır. Temelde ilişkisel ve ilişkisel olmayan olmak üzere ikiye ayrılır. İlişkisel veri tabanı, birbiriyle ilişkili olan verilerin tablolar şeklinde tutulduğu veri tabanıdır. İlişkisel olmayan veri tabanı da veriler arasında bir ilişki bulunmadığından tablolar şeklinde değil de iyileştirilmiş bir depolama modeli kullanıldığı veri tabanıdır. NoSQL veri tabanları yoğun okuma ve yazma işlemlerini ilişkisel veri tabanlarında göre oldukça pratik ve hızlı yapabildiği için en çok tercih edilmektedir. MongoDB, açık kaynaklı, belge tabanlı (document-oriented) bir NoSQL veri tabanıdır. Geleneksel ilişkisel veri tabanlarından farklı olarak, MongoDB verileri tablo yerine belge formatında (genellikle BSON- Binary JSON) saklar. Bu sayede, esnek ve dinamik şema yapıları kullanılabilir, yani her belge farklı bir yapıya sahip olabilir (Matallah et al., 2021; Yıldız et al., 2021).

3.3. Model Geliştirme Çalışmaları ve Sistem Temel Çalışma Prensibi

Model geliştirme çalışmaları kapsamında evrimsel sinir ağlarından istifade edilmiştir. Bu çerçevede model eğitimi için kullanılan hiper-parametrelere Tablo 3.2.de yer verilmiştir.

Tablo 3.2. Model eğitiminde kullanılan hiperparametreler

Mini Toplu Boyutu (mini batch size)	64
Maksimumu çağ (epoch)	128
Başlangıç öğrenme oranı	0.001
Optimizasyon algoritması	ADAM

Tablo 3.2. bir derin öğrenme modelinin eğitimi için kullanılan hiperparametreleri göstermektedir. Hiperparametreler, modelin öğrenme şeklini ve performansını etkileyen yapılandırma ayarlarıdır. Mini toplu boyutu her bir parametre güncellemesi için kullanılan veri örneklerinin sayısını gösterir. 64 değeri, her güncelleme için 64 görüntü örneğinin kullanılacağı anlamına gelir. Maksimumu çağ, modelin eğitildiği toplam iterasyon sayısını gösterir. 128 değeri, modelin 128 kez tüm veri kümesi üzerinden geçeceği anlamına gelir. Başlangıç öğrenme oranı, modelin parametrelerini güncellerken kullandığı öğrenme oranını gösterir. 0.001 değeri, modelin parametrelerini güncellerken küçük adımlar atacağı anlamına gelir. Optimizasyon algoritması, modelin parametrelerini güncellemek için kullanılan algoritmayı gösterir. ADAM, yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Seçilen hiperparametreler, nispeten küçük bir mini toplu boyutu, yüksek bir maksimum çağ ve düşük bir başlangıç öğrenme oranı ile genel olarak muhafazakârdır. Bu, modelin aşırı uyum riskini azaltmaya ve genel performansı optimize etmeye yardımcı olabilir.


Tablo 3.3 Erken durdurma ölçütleri

Monitör	Val._loss (doğruluk kaybı)
patience	6
restore_best_weight	True

Tablo 3.3.te erken durdurma ölçütlerine yer verilmiştir. İzleme kriteri EarlyStopping callback fonksiyonunun hangi metrik değerini izleyeceğini belirler. Burada 'val_loss' değeri seçilmiş olup, bu, modelin doğrulama (validation) kayıp değerini izlemeyi sağlar. *patience=6*, EarlyStopping callback fonksiyonunun kaç epoch boyunca iyileşme görmeden eğitime devam edeceğini belirler. Burada *patience=6* değeri seçilmiş olup, bu, doğrulama kaybında 6 epoch boyunca iyileşme görülmezse eğitimin durdurulacağı anlamına gelir. *restore_best_weight*, EarlyStopping callback fonksiyonunun en iyi model ağırlıklarını geri yükleyip yüklemeyeceğini belirler. Burada True değeri seçilmiş olup, bu, doğrulama kaybı en düşük değere ulaştığı epoch'a ait model ağırlıklarının eğitimin durdurulması durumunda geri yüklenmesini sağlar. Böylelikle en iyi genelleştirme performansını veren ağırlıkların modele yüklenmesi sağlanır.

Özetle, bu callback yaklaşımı modelin eğitim verisine aşırı uyum sağlamasını önler ve modelin daha iyi genelleştirme yeteneği kazanmasına yardımcı olur. Ayrıca, modelin gereğinden fazla eğitilmesini engelleyerek eğitim süresini kısaltır.

En verimli modelin dağıtımı için bir model geliştirilmiştir. Bu amaçla, Python programlama dili için geliştirilen Gradio kütüphanesi kullanılmıştır. Sistemin temel çalışma prensibi, Şekil 3.9.da bir sıra diyagramıyla gösterilmektedir. Bu diyagram, bir istemcinin (doktor, uzman personel veya diğer hizmet) bir karar destek isteğini Gradio aracılığıyla gönderme sürecini açıklar. Süreç, istemcinin Gradio'ya istek göndermesiyle başlar. Eğer yüklenen veri görüntü formatında ise istek Görüntü Doğrulayıcı katmanına iletilir. Görüntü biçimi desteklenmiyor, yüklenen görüntü renkli veya OCT görüntüsü değilse desteklenmeyen imaj uyarısıyla kullanıcıya geri bildirim sağlar. Eğer desteklenen bir görünüş ise doğrulayıcı, OCT retina görüntüsünün doğruluğunu kontrol eder. Ardından, yapay zekâ modeli, girdi görüntüsüne dayanarak bir tahminde bulunur. Tahmin süreci sırasında, Yapay Zekâ Modeli verileri kullanarak tahmin yapar. Son olarak, tahmin sonucu ve görüntü veri tabanına kaydedilir ve Gradio aracılığıyla istemciye gönderilir. Ancak, gönderilen görüntü geçerli değilse, yani desteklenmeyen bir format veya yapıya sahipse, Doğrulayıcı istemciye Desteklenmeyen Medya Türü (415) hatasıyla yanıt verir. Benzer şekilde, gelen belirteç geçersizse, bu şekilde, bir doktor veya diğer uzman veya hizmet, karar destek sistemine bir istek gönderebilir ve bir tahmin alabilir. Ayrıca tekrar değinilecek olursa yüklenen görüntü daha önce değerlendirmeye tabi tutulmuşsa görüntü tekrar değerlendirilir ve görüntünün sonuç çıktısı tekrar alınır fakat daha önce kendisine verilen hash değeriyle kaydedildiği için veri kalabalığını önlemek amacıyla tekrar veri tabanına kaydedilmez.



Şekil 3.9. Sistem temel çalışma prensibi

3.4. Kullanılan Derin Öğrenme Mimari ve Modelleri

3.4.1. Evrişimsel sinir ağları (CNN)

Yapay zekâ, insanın aciz kaldığı matematiksel vb. işlemler ve insana özgü olayları yorumlama, tecrübelerden faydalanma, öğrenme ve çıkarım yapabilme gibi özellikleri akıl ve mantık gerektiren işlemlerin makinelerle kazandırılması işlemleridir. İnsan beyninin bir modellemesi olan yapay zekâ ile insani ve insan üstü yetilerin makinelerle kazandırılma çabasıdır denilebilir. Makine öğrenmesi, kullanıcıların yazdığı kodlardan yola çıkarak kullanıcıdan komut beklemeden ya da yeni kodlar yazmasına gerek kalmadan işlemleri kendi kendine öğrenmesidir. Derin öğrenme, oldukça büyük verileri ve algoritmaları çözümlemeye yetersiz kalan makine öğrenmesine karşın çok sayıda gizli katmandan oluşan ve bir gizli katmanın çıktısının bir sonraki gizli katmanın girdisi olacak şekilde sonuç katmanından sonuç alınan makine öğrenmesinin bir alt kümesidir (Özdemir & Türkoğlu, 2022).



Şekil 3.10. Evrişimli sinir ağı yapısı (Mathworks, 2023)

Evrişimsel Sinir Ağları (CNN), büyük ağ modellerinde daha az parametreye ve daha az eğitime ihtiyaç duyan, derin öğrenme mimarilerinden olan çok katmanlı ileri yönlü bir yapay sinir ağıdır. Görüntü işlemlerinde analiz, nesne tanıma ve doğal dil işlemlerinde kullanılmaktadır. İlk başlarda donanımsal eksikliklerden dolayı istenileni karşılayamadığı için nesne tanıma için kullanılırken sonraları grafiksel işlem birimlerinin gelişmesiyle görüntü işleme ve tanıma, ses işleme, bilgisayarla görme, yüz tanıma, metin işleme ve sınıflandırma gibi alanlarda sıklıkla tercih edilmesine ve popülerliğinin artmasına sebep olmuştur. Gelişen teknoloji ile beraber verilerin kalabalıklaşması ve karmaşık hale gelmesi evrişimsel sinir ağlarının önemini gözler önüne sermiş ve kullanımını arttırmıştır. Evrişimsel sinir ağları hiyerarşik bir şekilde bulunduğu katmanda öğrendiklerini bir önceki katmanda öğrendiklerine ekleyip üst üste koyarak ilerlediği için tam bağlı katmanlara göre karmaşık verilerde daha iyi performans göstermektedir. CNN mimarileri sırasıyla; giriş katmanı (Input Layer), evrişim katmanı (Convolution Layer), düzleştirilmiş doğrusal birim katmanı (RELU), havuzlama katmanı (Pooling Layer), tam bağlantılı katman (Fully Connected Layer), Seyreltme katmanı (Dropout Layer) ve sınıflandırma katmanından (Classification Layer) oluşmaktadır (Şekil 3.6.). Katmanların sayısı, modeli, projeyi tasarlayan kişinin çalışmasına bağlıdır. Evrişimsel sinir ağlarında farklı özelliklerin kendini otomatik olarak eğitmesinden dolayı geleneksel tekniklere göre eğitime tabi tutulacak filtreleri oluşturmak için çok daha az ön işleme ihtiyaç duyulmaktadır (Urmamen, 2023).

3.4.1.1. Giriş katmanı


CNN'nin ilk katmanı olan giriş katmanında veriler katmanlara aktarılır. Aktarılabak verilerin büyüklüğü sistem performansını etkilediğı gibi süresini de etkilemektedir. Veri ne kadar büyükse sistem çok daha performanslı çalışır ve etkili sonuçlar alınır fakat işlem süresi uzar ve çok bellek gerekir. Diğer taraftan veri küçükse düşük bellekle ve kısa sürede sonuç alınır fakat büyük verilere nazaran sonuçların doğruluk payı düşüktür (Glorot et al., 2011).

3.4.1.2. Evrişim katmanı

Görüntünün özelliklerini tanıyan ve dönüşüm katman olarak da bilinen evrişim katmanı sistemin ana yapı taşı olan katmandır. Verilen iki fonksiyonun ne kadar örtüştüğünü belirleyen matematiksel işlemlerin gerçekleştiğı katmandır. Bu katman sayesinde görüntü detayları öğrenilerek öğrenme işlemi gerçekleştirilir. Girdi görüntüsü olarak değerlendirilen ilk parametre ve filtre olan kabul edilen ikinci parametreden oluşan iki fonksiyonun matematiksel ifadesidir. Matris formunda olan filtreler, tüm görüntüyü yatay ve dikey olarak dolaştıktan sonra skaler değerler oluşturur ve işlem sonucunda üretilen bu skaler değerler matris formunda olup giriş nitelik matrisinin çıktı nitelik matrisi oluşturur. Her kaydırma işleminde bir dizi çarpma ve toplama matematiksel işlemlerden sonra görüntü detaylarının çıkarımı sağlanır (Bayram, 2020).

3.4.1.3. Düzleştirilmiş doğrusal birim katmanı

Bu işlem için düzleştirilmiş doğrusal birim (Rectified Linear Unit-ReLu), sigmoid ve hiperbolik tanjant gibi fonksiyonlar kullanılmaktadır. ReLu'nun diğer fonksiyonlara göre matematiksel yükünün ağır olmaması çok katmanlı ağlarda sıklıkla tercih edilmesine sebep olmaktadır. Bir transfer fonksiyonu olan Relu fonksiyonu aracılığıyla yalnızca pozitif aktivasyon alanlarının elde edilmesini sağlayarak girdinin bir sonraki katman için önemli olmayan nöronların eliminasyonunu sağlayan mekanizmadır. ReLu fonksiyonu görüntü üzerindeki negatif pikselleri sıfıra (0) çekerek doğrusal olmama özelliğı kazandırmaktadır. Bu sayede doğrusal olmayan girdilerin öğrenilmesi de sağlanmaktadır (İnik & Ülker, 2017).



Şekil 3.11. Relu fonksiyonun matris üzerindeki değişimleri (Hijazi, 2015)

Tablo 3.4. Düzleştirilmiş doğrusal birim fonksiyonları ve türevleri (Salman, 2018)


Aktivasyon Fonksiyonu	Matematiksel Denklemi
RELU	$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}, f'(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$
Sigmoid	$f(x) = \frac{1}{1+e^x}, f'(x) = f(x)(1 - f(x))$
Tanh	$f(x) = \tanh(x) = \frac{1}{1+e^{-2x}}, f'(x) = 1 - f(x)^2$

3.4.1.4. Havuzlama katmanı

Havuzlama katmanı, büyük veri kümelerinde girdinin boyutunu veri kaybı olmadan küçülterek bir sonraki katmana hazırlar. Bu katmanda öğrenme gerçekleşmez fakat girdi boyutu küçüldüğü için zamandan ve maliyetten tasarruf etmeyi amaçlar. Evrişim katmanının çalışma mantığına benzer bir şekilde filtreler aracılığıyla gezdirme işlemi sırasında görüntünün piksellerinin ortalamasını (ortalama havuzlama) ve en büyük piksel değerlerini (maksimum havuzlama) alarak işlem sonucunda çıktı matrisi oluşturur (İnik & Ülker, 2017).

3.4.1.5. Tam bağlantılı katman


Tam bağlantılı katman, matris verilerinin düzleştirme işleminden sonra her girdinin tüm nöronlara bağlı olduğu katmandır. Özellik çıkarımından ziyade sınıflandırma işleminin başlangıcı olarak kabul edilen bu katmanla evrişim katmanında gözden kaçan ve öğrenilemeyen bazı özellikleri öğrenmeyi amaçlamaktadır (Demir & Yılmaz, 2021).



Şekil 3.12. Tam bağlantılı katman (Zadeh ve Ramsun, 2019)

3.4.1.6. Seyreltme katmanı


Sadece modelin eğitimi sırasında kullanılan seyreltme katmanları, ağı yükünü hafifletmek ve aşırı uyumun önlenmesini sağlayarak gerçekçi bir sonucun önüne geçmek amacıyla kullanılan katmandır. Nöronların rastgele ağıdan kaldırılmasıyla ağın hesaplama yükünü de azaltmaktadır. Eğer bu nöronlar kaldırılmasa işlem süresi çok uzar ve ayrıca gerçeğe çok yakın sonuçlar elde edilir. Bu da makine farkını ortadan kaldıracığı için pek de tercih edilmeyen bir sonuçtur (Türkoğlu et al., 2020).



Şekil 3.13. Seyreltme katmanı öncesi (a) ve Seyreltme katmanı sonrası (b) ağ yapısı (Srivastava, 2014)

3.4.1.7. Sınıflandırma katmanı


Son katman olan sınıflandırma katmanı, istenilen sınıflandırma adedi kadar 0 ile 1 arasında çıkış veya sonuç veren katmandır. Softmax fonksiyonu kullanıldığında 0 ile 1 arasında olasılık değeri ile sınıflara ait olma olasılığını verir. Bu tanımlardan yola çıkarak örnek vermek gerekirse şekil 3.14.te de görüldüğü üzere yüklenen görüntünün kediye mi köpeğe mi ait olduğunu anlamak için yapılan sınıflandırmada 0 ile 1 arasında görüntünün hangisine ait olduğu olasılığı şeklinde iki çıkış verir (İnik & Ülker, 2017).



Şekil 3.14. Sınıflandırma işlemi ve olasılık değerleri (Kadiroğlu, 2019)

3.4.2. GoogleNet


Konvülasyon ve havuzlama katmanlarını üst üste yığmaktan kurtaran bir CNN yapısı olan GoogleNet, içeriğindeki başlangıç modülleri yüzünden yapısı karmaşıktır. Bütün katmanları yığınlamak ve filtrelemek, güçlü bir bellek ve hesaplama maliyeti doğuracağından, bu durumun getireceği sıkıntıları bertaraf etmek için modülleri birbirine paralel bağlayarak kullanmıştır (Özküçük et al., 2022). Bu model ile CNN'deki doğrusal olan filtrelerin doğrusal olmayan aktivasyon fonksiyonları kullanılarak öğrenme yeteneklerinin artırılması amaçlanmıştır. Derinlemesine 22 katmandan oluşan GoogleNet mimarisinde paralel işlemler parametre sayısını, çıkış boyutunun büyüklüğü ve işlem karmaşıklığının yaratacağı sıkıntıları gidermek için, paralel Naive Inception evrişim katmanları öncesine (1×1) boyutundaki evrişim katmanları eklenerek boyutları azaltılır (Kızrak & Bolat, 2018).



Şekil 3.15. GoogleNet mimarisi (Szegedy et al., 2015)

3.4.3. ResNet


Ağlar derinleştikçe eğitimi zorlaştıran ve performans düşüklüğüne sebep olan, kaybolan gradyan olarak isimlendirilen problemi giderme amacıyla 2016 senesinde Kaiming He, Xiangyu Zhang ve arkadaşları tarafından tasarlanmış mimaridir (Güzel et al., 2025). En fazla 152 katmandan oluşan bu mimariyi diğer mimarilerden ayıran en önemli fark gradyan kaybını ortadan kaldırmak amacıyla residual bloklar içermesi ve ayrıca direk olarak eşleştirmeleri analiz edip öğrenmek yerine giriş ve çıkış parametreler arasındaki farkları karşılaştırıp daha gelişmiş öğrenme sağlamasıdır. ResNet18, ResNet34, ResNet50, ResNet101 ve ResNet152 gibi farklı katmanlardan oluşan versiyonları bulunmaktadır. Şekil 3.11.de de görüldüğü üzere çıktı özelliği haritası için katmanları aynı filtre olan düz ağ temelli ve özellik haritası yarıya indirildiğinde filtre sayısı iki katına çıkan iki farklı mimarisi bulunmaktadır (Arıca & Kaya, 2023).



Şekil 3.16. ResNet ağı mimarisi (Zhang et al. 2016)

3.4.4. EfficientNet


Bellek gereksinimi ve hesaplama işlemleri açısından kelime anlamından da anlaşılacağı üzere oldukça verimli olan bu mimari, görüntü sınıflandırma çalışmalarında son teknolojilerle uyumlu ve efektif bir şekilde performans sağlanması amacıyla 2016 yılında Google tarafından kullanıma sunulmuştur. En uygun performans ve maksimum düzeyde verimlilik için ağın derinliğini, büyüklüğünü ve çözünürlüğünü dengeli bir şekilde ölçeklendiren bu mimari, ağın hesaplama ve bellek gereksinimlerini minimum düzeye indirmek için dizayn edilmiş evrişimli katmanlar, darboğaz katmanları ve ters artık blokları içermektedir (Salati et al., 2025). EfficientNet, geleneksel konvolüsyonel sinir ağı (CNN) modellerine göre daha az parametreyle yüksek doğruluk elde etmeyi amaçlayan bir mimaridir. Bu yapı, şekil 3.12.de de görüldüğü üzere modelin genişliğini, derinliğini ve giriş görüntüsünün çözünürlüğünü aynı anda dengeli bir şekilde ölçeklendiren bir stratejiye sahiptir. Genişlik ölçeklemesi, her katmandaki filtre sayısını artırarak modelin daha fazla özellik yakalamasını sağlarken; derinlik ölçeklemesi, daha fazla katman ekleyerek karmaşık örüntülerin öğrenilmesine katkıda bulunur. Çözünürlük ölçeklemesi ise giriş verisinin çözünürlüğünü yükselterek daha küçük ve ayrıntılı yapıların analiz edilmesini mümkün kılar (Kılınç, 2024).



Şekil 3.17. EfficientNET mimarisi (Tan & Le, 2019)

3.4.5. DenseNet

Görüntülerin sınıflandırılması ve retina hastalıklarının tespiti için DenseNet201 yapay zekâ modeli ile görüntüler eğitilmiştir. DenseNet-201, 224 genişliği, sonraki 224 değeri yüksekliği ve 3 değeri derinliği (renk kanalları sayısını) ifade edecek şekilde $224 \times 224 \times 3$ giriş boyutuna sahiptir. DenseNet201, her katmanın tüm önceki katmanlardan gelen özellikleri giriş olarak aldığı, böylece bilgi akışını ve gradyan yayılımını iyileştiren bir derin öğrenme modelidir. Bu yoğun bağlantı yapısı, modeli daha verimli hale getirir ve daha az parametreyle yüksek performans sağlar. Çalışmada DenseNet201 modeli ile yapılan testlerde başarılı bir şekilde sonuçlar elde edilmiştir. Modelin tercih edilmesinin en temel sebebi diğer denseNet modellerine göre daha fazla katmana sahip olmasıdır. 201 katmana sahip olmasından dolayı çok daha katmanda model eğitilebilmekte ve çok daha doğruluk oranı yüksek sonuçlar elde edilebilmektedir. Klasik evrimsel sinir ağı modellerinde katmanlar bir katmanın çıkışı diğerinin girişine bağlı olacak şekilde bağlı olmasına karşın DenseNet mimarisinde önceki tüm katmanların çıkışları, herhangi bir katman için giriş olarak verilebildiği için performans ve doğruluk bakımından çok daha etkin sonuçlar vermektedir.



Şekil 3.18. DenseNet mimarisi (Shuwam, 2023)

4. BULGULAR


4. 1. TensorFlow ile Yapay Zekâ Destekli Model Geliştirme

4.1.1. Model eğitimi ve doğrulama


Model geliştirme çalışmaları sırasında GoogleNet, Resnet(ResNet50), EfficientNet (EfficientNetB0) ve DenseNet (Densenet201) gibi çok sayıda derin öğrenme modeli kullanılmıştır. Aşağıda detaylı yapılan karşılaştırma ve analizlerden de anlaşılacağı üzere en verimli sonuçlar ise DenseNet-201 modeli ile elde edilmiştir. Bundan dolayıdır ki yapılan çalışmadaki grafik ve analizler çoğunlukla DenseNet-201 modeli ile ilgili olmuştur.

4.1.2. Çalışmada kullanılan model ve mimarilerin karşılaştırılması

Train accuracy (Eğitim doğruluğu), modelin, eğitim verisi üzerinde ne kadar doğru tahmin yaptığını gösterir. Yani modelin, öğrenme sırasında gördüğü verilerdeki başarısıdır. Validation accuracy (Doğrulama doğruluğu), modelin, görmediği (doğrulama) veriler üzerindeki başarısını gösterir. Bu, modelin genelleme yeteneğini değerlendirir. Train accuracy yüksek ama validation accuracy düşükse, aşırı öğrenme (overfitting) olabilir. İkisi de düşükse, yetersiz öğrenme (underfitting) olabilir. İkisi de yüksekse ve birbirine yakınsa, model iyi öğrenmiş ve genelleme yapabiliyor demektir. Bu bilgilerden yola çıkarak şekil 4.1.deki grafik için DenseNet-201 modelinin açık ara diğer modeller arasında en başarılı sonucu verdiği anlaşılmaktadır. En düşük doğruluk performansının da EfficientNetB0 ve GoogleNet modellerinde olduğu görülmektedir. Ayrıca şekil 4.2.deki F1 skoru karşılaştırma grafiğindeki en yüksek F1 skoruna sahip model olan Densenet201 hem precision (hassasiyet) hem de recall (duyarlılık) açısından oldukça dengeli ve başarılı sonuç verdiğiinden bu model, sınıflar arasında ayrımı en iyi yapabilen model olarak öne çıkıyor. EfficientNetB0, 0.83'lük bir oran ile en düşük F1 skoruna sahip model olduğundan bu model diğerlerine kıyasla daha az başarılı olduğu görülmektedir. Bu parametre ve buna benzer birçok parametrede açıkça görülmüştür ki bu çalışmada denenen modeller arasında en iyi sonucu Densenet201 modelinin gösterdiği görülmektedir.



Şekil 4.1. Modellerin train accuracy (eğitim doğruluğu) ve validation accuracy (doğrulama doğruluğu) karşılaştırması




Şekil 4.2. Modellerin F1 skoru karşılaştırması

Katman sayısı ve parametre sayısı, bir derin öğrenme modelinin karmaşıklığını, kapasitesini ve uygulama alanını doğrudan etkileyen iki kritik özelliktir. Katman sayısının fazla olması daha karmaşık örüntüleri öğrenme potansiyeli demektir. Özellikle görüntü işleme gibi görevlerde düşük seviyede kenarları, orta seviyede şekilleri, yüksek seviyede nesneleri tanımakta başvurulur. Yüksek parametre sayısı da modelin daha fazla bilgi öğrenmesini sağlar. Ancak, fazla parametre demek daha fazla veri ihtiyacı daha çok bellek ve hesaplama gücü (örneğin GPU) demektir. Densenet201 modeli, 201

katman ile söz konusu modeller arasında en fazla katmana sahipken GoogleNet 22 katman, Resnet(ResNet50) 50 katman, EfficientNet (EfficientNetB0) 82 katmandan oluşmaktadır. Ayrıca DenseNet (Densenet201) yaklaşık 20 milyon parametre, GoogleNet yaklaşık 7 milyon parametre, Resnet(ResNet50) yaklaşık 25,6 milyon parametre, EfficientNet (EfficientNetB0) yaklaşık 5,3 milyon parametre ile eğitim yapmaktadır. Yukarıdaki bilgiler, bu gibi çalışmalar açısından en uygun modelin DenseNet-201 olduğuna işaret ediyor. Fakat bununla beraber her zaman en iyi sonucun DenseNet-201 modeli tarafından verildiği kesin bir şekilde iddia edilemez. Bu durumu verinin büyüklüğü ve karmaşıklığı, verilerin dengesizliği, öğrenmeyi gerçekleştiren makinenin, bilgisayarın donanımı vs. birçok parametre ve unsur etkilemektedir.

Gerek yukarıdaki akademik bilgilerden gerekse yapılan işlemlerin, çalışmaların sonucundan görüldüğü gibi en iyi performans ve sonucu veren modelin Densenet201 modeli olduğu görülmektedir. Çalışmanın bundan sonraki teknik bilgileri, sonuçları ve grafik gibi çalışmaları Densenet201 modeli ile ilgili çalışmalar olacaktır. Şekil 4.3.te DenseNet-201 modeline model eğitimi e doğrulama sürecinde elde edilen doğruluk ve kayıp eğrilerine yer verilmiştir.



Şekil 4.3. DenseNet201'e ait doğruluk ve kayıp eğrileri

Şekil 4.3, DenseNet201 modelinin eğitim (train) ve doğrulama (validation) kayıp (loss) eğrilerini göstermektedir. Bu eğriler, modelin eğitim süreci boyunca nasıl performans gösterdiğini ve zamanla nasıl geliştiğini analiz etmek için kullanılır. Eğitim kayıp eğrisinin genel eğilimi, modelin eğitim verisi üzerinde kademeli olarak daha iyi performans gösterdiğini göstermektedir. Başlangıçta eğri oldukça diktir, bu da modelin

hatalı olduğunu ve daha fazla öğrenmesi gerektiğini gösterir. Eğitim ilerledikçe eğri düzleşmeye başlar, bu da modelin daha az hata yaptığını ve daha iyi genelleme yeteneği kazandığını gösterir. Doğrulama kayıp eğrisi, modelin eğitim verisi dışındaki veriler üzerindeki performansını gösterir. Eğitim eğrisiyle karşılaştırıldığında, doğrulama eğrisi daha dalgalıdır. Bu, modelin eğitim verisine aşırı uyum riski altında olduğunu ve eğitim verisi dışındaki veriler üzerinde iyi genelleme yeteneğine sahip olmadığını gösterebilir. Eğitim ve doğrulama kayıpları arasındaki fark, modelin ne kadar iyi genellediğini gösteren bir göstergedir. Fark küçükse, modelin eğitim verisi dışındaki veriler üzerinde de iyi performans göstermesi muhtemeldir. Fark büyükse, modelin eğitim verisine aşırı uyum riski altında olduğu ve eğitim verisi dışındaki veriler üzerinde iyi genelleme yeteneğine sahip olmadığı anlamına gelebilir.

Model geliştirme çalışmalarına ilişkin bir diğer önemli konu her ne kadar model eğitimi için maksimum çağ sayısı 128 olarak belirlenmiş olsa da henüz 20. çağa gelmeden eğitim sürecinin tamamlandığı gözlemlenmektedir. Bunun temel sebebi eğitimin çok uzun sürmesini ve buna karşın yeterli genelleştirme performansı artışının sağlanmaması probleminin önüne geçmektir. Bu çerçevede erken durma kriteri dikkate alınmıştır.

Derin öğrenme modellerinin eğitimi sırasında karşılaşılan en önemli problemlerden biri, modelin eğitim verisine aşırı uyum sağlamasıdır. Bu durum “aşırı öğrenme” (overfitting) olarak adlandırılmakta ve modelin yeni, daha önce görmediği veriler üzerindeki genelleme yeteneğini ciddi şekilde azaltmaktadır. Bu sorunu önlemek amacıyla çeşitli düzenleme (regularization) yöntemleri geliştirilmiştir. Bu yöntemlerden biri olan erken durdurma (early stopping), eğitim sürecini dinamik bir şekilde izleyerek modelin doğrulama verisi üzerindeki performansına göre eğitimi otomatik olarak sonlandırmaktadır.

Erken durdurma tekniğinde, eğitim sırasında her bir epoch sonunda modelin doğrulama seti üzerindeki kayıp değeri takip edilir. Eğer doğrulama kaybı (validation loss), belirli bir ardışık epoch boyunca iyileşme göstermiyorsa — yani sabit kalıyor ya da artıyorsa — modelin daha fazla eğitilmesi aşırı öğrenmeye yol açabileceğinden eğitim işlemi durdurulur. Bu süreçte genellikle bir “patience” parametresi tanımlanır; örneğin 5 epoch boyunca gelişme olmaması durumunda model eğitimi sonlandırılabilir. Bu sayede model, doğrulama verisinde en iyi sonucu verdiği noktada “dondurulmuş” olur.

Bu tez çalışmasında model için toplam 128 epoch’luk bir eğitim döngüsü tanımlanmış olmasına rağmen, Şekil 4.3.te yalnızca ilk 15 epoch’a ait doğruluk ve kayıp

eğrileri yer almaktadır. Bu durum, sistemde erken durdurma mekanizmasının aktif olduğunu ve eğitim sürecinin doğrulama seti üzerinde istenilen gelişme gözlemlenmediği için otomatik olarak 15. epoch civarında sonlandırıldığını göstermektedir. Dolayısıyla modelin gereksiz yere eğitilmesinin önüne geçilmiş, eğitim süresi kısaltılmış ve hesaplama kaynakları etkin biçimde kullanılmıştır.

Şekil 4.3.te gözlemlenen eğilimler de bu durumu doğrulamaktadır. Eğitim doğruluğu eğrisi sürekli bir artış eğilimindeyken 15. epochdan sonra bir noktada plato noktasına ulaşmakta ve ardından ya sabit kalmakta ya da hafifçe düşmektedir. Eğitim doğruluğuna yakın bir eğilimle doğrulama doğruluğu da önceden zikzaklı bir artış eğilimi göstermekte ve nispeten daha erken sayılmasa da o da 15. epochdan sonra bir istikrara ulaşmakla beraber eğitim sonuna kadar bu istikrarını korumaktadır. Benzer şekilde, eğitim kaybı eğrisi istikrarlı bir şekilde azalmaya devam ederken yine 15. epochdan sonra bir istikrara ulaşmakla beraber eğitim sonuna kadar bu istikrarını korumaktadır. Doğrulama kaybı grafiği de zikzaklı bir azalıştan sonra belirli bir eşik değerde durmakta ve ilerleyen epoch'larda azalış eğilimi göstermektedir. Bu durum, modelin eğitim verisine aşırı uyum sağlamaya başladığını ve genelleme gücünün zayıfladığını göstermektedir. Bu eğilim üzerine erken durdurma mekanizması tetiklenmiş ve eğitim süreci ideal noktada sonlandırılmıştır.

Bu bağlamda, erken durdurma yöntemi, bu çalışmada kullanılan modelin doğruluk ve kayıp değerleri göz önüne alındığında son derece işlevsel bir rol oynamıştır. Modelin aşırı öğrenmeye maruz kalmadan optimum doğruluk düzeyinde eğitilmesi sağlanmış, böylece hem doğrulama başarımı korunmuş hem de eğitim verimliliği artırılmıştır. Aynı zamanda bu mekanizma, sistemin daha sağlam ve genellenebilir sonuçlar üretmesini desteklemiştir.

Elbette, aşağıda verdiğim metin, madde madde açıklanan avantajların tamamını içeren ve akademik üslupla yazılmış tek bir bütünlük paragraftır:

Bu tez çalışmasında kullanılan erken durdurma (early stopping) yöntemi, modelin eğitim sürecinde çeşitli açılardan önemli avantajlar sağlamıştır. Özellikle sınırlı ve dengesiz OCT görüntü veri seti nedeniyle modelin eğitim verisine aşırı uyum sağlama riski göz önünde bulundurulduğunda, erken durdurma mekanizması modelin doğrulama kaybında belirgin bir iyileşme gözlemlenmediği noktada eğitimi sonlandırarak aşırı öğrenmenin (overfitting) önüne geçmiştir. Bu sayede modelin genelleme yeteneği korunmuş ve farklı veri üzerinde daha güvenilir sonuçlar üretmesi sağlanmıştır. Ayrıca, eğitim süreci başlangıçta 128 epoch olarak belirlenmiş olmasına rağmen modelin en yüksek doğrulama performansını yaklaşık 15. epoch'ta elde

etmesiyle birlikte, erken durdurma yöntemi sayesinde gereksiz eğitim süresi ve kaynak tüketimi engellenmiştir. Bu durum, eğitim süresinin optimize edilmesini ve hesaplama kaynaklarının daha verimli kullanılmasını sağlamıştır. Sistem klinik kullanım amacıyla geliştirildiği için, modelin yeni ve daha önce görülmemiş veriler üzerindeki başarısı büyük önem taşımaktadır; erken durdurma bu başarının elde edilmesine katkı sunmuştur. Bununla birlikte, eğitim doğruluğu artış gösterirken doğrulama doğruluğunun belirli bir noktadan sonra sabitlenmesi ve doğrulama kaybının artış eğilimine girmesi, modelin öğrenmede kritik bir eşik noktasına ulaştığını göstermiştir. Bu eşikte eğitimin sonlandırılması, grafiklerin daha dengeli ve yorumlanabilir bir yapıya kavuşmasını sağlamıştır. Ayrıca, sınırlı sayıda görüntü içeren veri setinden maksimum verimin elde edilmesi açısından erken durdurma, modelin ezber yapmasına değil genellemeye odaklanmasına yardımcı olmuştur. Bu nedenlerle, erken durdurma mekanizması bu çalışmada kullanılan modelin güvenilirliğini, verimliliğini ve klinik uygulamaya uygunluğunu önemli ölçüde artırmıştır.

4.1.3. Hata matrisi

Karışıklık matrisi, bir sınıflandırma modelinin performansını özetleyen, veri kümesi için gerçek ve tahmin edilen sınıf etiketlerini tablolardır.

CNV	241	1	0	0
DME	7	224	3	8
DRUSEN	27	0	214	1
NORMAL	0	1	6	235
	CNV	DME	DRUSEN	NORMAL

Şekil 4.4. DenseNet201'e ait Hata matrisi

Modelin gerçek ve tahmin edilen sınıf etiketlerine göre dört kategoriye ayırır: doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN). Doğru Pozitif (TP), model tarafından doğru olarak pozitif olarak tahmin edilen örneklerle karşılık gelir. Doğru Negatif (TN), model tarafından doğru olarak negatif olarak tahmin edilen örneklerin sayısıdır. Benzer şekilde, Yanlış Pozitif (FP), model tarafından yanlışlıkla pozitif olarak tahmin edilen örneklerin (Tip I hata) sayısıdır. Son olarak, Yanlış Negatif (FN) ise model tarafından yanlışlıkla negatif olarak tahmin edilen örneklerin (Tip II hata) sayısıdır. Başka bir deyişle, genel bir ifadeyle doğru pozitif hasta olup hastalığı doğru teşhis edilen, doğru negatif hasta olmayıp hasta değildir teşhisi konulan, yanlış pozitif hasta olmadığı halde hasta olarak teşhis edilen ve yanlış negatif ise hasta olana hasta değil teşhisi konulan şeklinde sadeleştirilebilir.


Bu sınıflandırma modeline ait hata matrisi, dört sınıfın (CNV, DME, DRUSEN ve NORMAL) sınıflandırma performansını açıkça göstermektedir. CNV sınıfına ait 242 örnekten 241'i doğru şekilde sınıflandırılmış, yalnızca 1 örnek DME olarak yanlış tahmin edilmiştir. Bu durum, modelin CNV sınıfında çok yüksek doğrulukla çalıştığını göstermektedir. Modelin bu sınıftaki doğruluk oranı %99,58 olup, F1 skoru %93,2 seviyesindedir. Ancak hassasiyet (precision) %87,6 olarak daha düşüktür, bu da bazı diğer sınıfların CNV olarak yanlış etiketlendiğini göstermektedir.

DME sınıfı incelendiğinde, modelin 224 örneği doğru sınıfladığı, 18 örneği ise hatalı sınıflandırdığı görülmektedir. Bu hataların çoğu CNV (7 örnek) ve NORMAL (8 örnek) sınıflarına kaymıştır. DME için precision %99,1 gibi oldukça yüksek bir değerle başarılı görünse de recall değeri %92,56 ile biraz daha düşüktür. Bu, modelin DME sınıfını tahmin ederken yüksek doğrulukta ancak bazı örnekleri kaçırdığını gösterir. F1 skoru ise %95,72'dir.

DRUSEN sınıfı model için görece daha fazla zorluk yaratmıştır. 214 örnek doğru tahmin edilse de, 27 örnek CNV olarak yanlış sınıflandırılmıştır. Bu, DRUSEN ile CNV arasında görsel ya da yapısal bir benzerlik olabileceğini düşündürmektedir. DRUSEN sınıfı için precision %95,96 gibi oldukça yüksek olmasına rağmen, recall değeri %88,42'ye düşmüş ve F1 skoru %92.04 olarak hesaplanmıştır. Bu da modelin DRUSEN sınıfındaki başarısının diğerlerine göre daha az olduğunu gösterir.

NORMAL sınıfında ise model oldukça başarılıdır. 235 örnek doğru sınıflanmış, yalnızca 7 örnek (1 DME, 6 DRUSEN) yanlış tahmin edilmiştir. Bu sınıf için precision %96,3 ve recall %96,3 seviyelerinde hesaplanmış olup, F1 skoru da %96,3 gibi yüksek bir değerdedir. Bu, modelin NORMAL sınıfını ayırt etmede yüksek doğruluk ve güvenilirlikle çalıştığını gösterir.

Genel olarak modelin doğruluğu (accuracy) %94,42 olarak ölçülmüştür. Bu oldukça başarılı bir sınıflandırma performansına işaret etmektedir.



Şekil 4.5. Sınıf bazlı performans metrikleri

Yukarıdaki grafikte, her bir sınıf için Precision (Kesinlik), Recall (Duyarlılık) ve F1-Skoru oranları görselleştirilmiştir.

- CNV sınıfında, recall değeri %99.6 ile çok yüksekken, precision %87.6'da kalmıştır. Bu durum modelin CNV sınıfını fazla tahmin ettiğini, ancak bazılarının yanlış tahmin olduğunu gösterir.
- DME sınıfında, precision %99.1 ile en yüksek değerdeyken recall %92.6 seviyesindedir, yani model doğru tahmin ettiğinde çok isabetlidir.
- DRUSEN sınıfında, precision yüksek (%95.9) olmasına rağmen recall %88.4 seviyesindedir; bu da modelin bazı DRUSEN örneklerini kaçırdığını gösterir.
- NORMAL sınıfında, tüm metrikler birbirine oldukça yakındır ve %96-97 seviyelerindedir. Bu da modelin NORMAL sınıfında dengeli ve başarılı performans sergilediğini gösterir.

Precision, recall ve F1 skoru metrikleri, sınıflandırma problemlerinde modelin performansını sınıf bazında değerlendirmek için en sık tercih edilen ölçütlerdir. Precision, modelin pozitif tahminlerinin doğruluğunu; recall, gerçek pozitiflerin ne kadarının doğru tahmin edildiğini; F1 skoru ise bu iki metriğin dengeli bir birleşimini sunar. Bu metrikler, özellikle dengesiz veri kümelerinde ve çok sınıflı senaryolarda

doğruluk (accuracy) gibi genel ölçütlerin yetersiz kaldığı durumlarda daha anlamlı sonuçlar verir. Bu nedenle, sınıf bazlı değerlendirmelerde temel performans göstergeleri olarak kullanılırlar.

4.1.4. Metrikler

Yapılan çalışmanın sınıflandırma performansını, diğer bir deyişle başarısını değerlendirmek için bazı metrik değerler kullanılmaktadır. Doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) unsurlarının matematiksel olarak birbirlerine oranı çalışmanın başarısını göstermek için bazı metrik sonuçların elde edilmesini sağlar. Doğruluk (accuracy), hassasiyet (sensitivity), duyarlılık (recall) özgüllük (specificity), kesinlik (precision), yanlış pozitif oranı (false positive rate), F1 skor gibi bazı metriklerin bilgisine sahip olunması çalışma performansı hakkında hüküm sahibi olunmasına büyük katkı sağlayacaktır (G. Gencer ve K. Gencer, 2024).

4.1.4.1. Doğruluk

Sistemin doğru tahmin etme performansını değerlendirmeye yarayan bu parametreyi bulabilmek için denklem 4.1.de de görüldüğü üzere sistemin doğru tahmin ettiği değerlerin toplam değerlerin oranının hesaplanması gerekir. Elde edilen sonuç ne kadar yüksekse modelin doğru tahmin etmesinin o kadar iyi olduğu bilgisini verir. Özellikle dengeli veri kümelerinde faydalı bir ölçüt olmakla birlikte, sınıf dağılımının dengesiz olduğu durumlarda yanıltıcı sonuçlar verebilir. Denklemde 100 ile çarpılmasının sebebi bazı çalışmalarda kesirli ifade olarak değil de yüzdelik ifade kullanılmasından kaynaklanmaktadır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+YP+YN} * 100 \quad (4.1)$$

4.1.4.2. Hassasiyet

Ne kadar doğru tahmin edildiği oranını gösteren hassasiyet, denklem 4.2.de de görüldüğü üzere doğru pozitif tahminlerinin tüm doğru tahminlere oranıyla bulunur. Ayrıca pozitif tahmin edici oran olarak da adlandırılmaktadır. Modelin pozitif sınıfları ne ölçüde doğru şekilde tanımlayabildiğini gösterir. Bu metrik, yanlış negatiflerin

sayısını azaltmaya yönelik uygulamalarda, örneğin tıbbi tanılarda oldukça önemlidir. Düşük hassasiyet, modelin birçok gerçek pozitif örneği atladığını gösterir.

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

4.1.4.3. Özgüllük

Doğru sınıflandırılmış negatif örneklerin oranını gösteren özgüllük parametresi denklem 4.4.te de görüldüğü gibi gerçek negatif değerlerin gerçek negatif değerlerle yanlış pozitif değerlerin toplamına bölümüyle elde edilir. Negatif sınıfların doğru biçimde tanımlanma oranıdır ve özellikle yanlış pozitiflerin azaltılmasının kritik olduğu uygulamalarda değer taşır. Özgüllüğü yüksek bir model, negatif sınıflarda hatalı alarmları azaltır.

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (4.3)$$

4.1.4.4. Kesinlik

Kesinlik, denklem 4.5.te görüldüğü üzere gerçek pozitif olarak tespit edilen değerlerin pozitif olarak tanı konulan değerlere bölümüyle bu oran saptanmaktadır. Modelin pozitif olarak tahmin ettiği örneklerin gerçekten pozitif olma oranını gösterir. Bu metrik, pozitif tahminlerin güvenilirliğini ölçer ve özellikle pozitif bir sınıfın yanlış tahmininin yüksek maliyetli olduğu durumlarda öne çıkar.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (4.4)$$

4.1.4.5. Yanlış Pozitif Oranı (False Positive Rate – FPR)

Negatif örneklerin model tarafından pozitif olarak yanlış sınıflandırılma oranını ifade eder. ROC eğrisinde yatay eksen oluşturur ve özgüllüğün tamamlayıcısıdır. Denklem 4.3.te gösterildiği gibi hesaplanmaktadır.

$$\text{FPR} = \frac{FP}{FP+TN} \quad (4.5)$$

4.1.4.6. F1 Skoru

Sınıflandırıcıların performansını görmek ve başarısını karşılaştırmak için sıklıkla başvurulanan F1 skoru, kesinlik ve hassasiyet parametrelerinin harmonik ortalamalarının hesaplanmasıyla elde edilmektedir. Denklem 4.6.da F1 skorunun hesaplanması denklemi verilmiştir. Bu metrik, özellikle sınıf dağılımının dengesiz olduğu durumlarda genel başarıyı özetleyen dengeli bir ölçüm sağlar. F1 skoru, yüksek başarı için hem hassasiyetin hem de kesinliğin yüksek olmasını gerektirir.

$$F1 \text{ Skoru} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (4.6)$$

Bu metriklerin birlikte değerlendirilmesi, yalnızca genel doğruluğun değil, modelin pozitif ve negatif sınıflar üzerindeki ayırım yeteneğinin de detaylı biçimde anlaşılmasını sağlar. Böylelikle modelin hangi sınıflarda güçlük yaşadığı, nerelerde optimize edilmesi gerektiği ve klinik ya da endüstriyel uygulamalarda ne ölçüde güvenilir olduğu ortaya konulabilir (Aykat & Şenan, 2023).


Tablo 4.1. DenseNet201'e ait Performans sonuçları

Metrikler	Değerler
Doğruluk (Accuracy)	0.9442
Hassasiyet (Sensitivity)	0.9442
Özgüllük (Specificity)	0.9814
Kesinlik (Precision)	0.9475
Yanlış Pozitif Oranı (False positive rate)	0.0185
F1 skor	0.9442

Tablo 4.1. DenseNet201'e ait performans sonuçları tablosu, sınıflandırma modelinin başarı ölçütlerini göstermektedir. Doğruluk (Accuracy), modelin doğru tahmin etme oranıdır ve %94.42'dir. Bu, tüm sınıfların doğru bir şekilde sınıflandırıldığını belirtir. Hassasiyet (Sensitivity), modelin gerçek pozitifleri doğru bir şekilde tanıma yeteneğidir ve %94.42'dir. Bu, modelin pozitif olarak tahmin ettiği tüm gerçek pozitiflerin yüzde kaçının doğru olduğunu gösterir. Özgüllük (Specificity), modelin gerçek negatifleri doğru bir şekilde tanıma yeteneğidir ve %98.14'tür. Bu, modelin negatif olarak tahmin ettiği tüm gerçek negatiflerin yüzde kaçının doğru

olduğunu gösterir. Kesinlik (Precision), modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğudur ve %94.75'tir. Bu, modelin pozitif olarak sınıflandırdığı örneklerin yüzde kaçının gerçekten pozitif olduğunu gösterir. Yanlış Pozitif Oranı (False positive rate), modelin gerçek negatiflerini yanlışlıkla pozitif olarak sınıflandırma oranıdır ve %1.85'tir. Bu, modelin negatif olarak sınıflandırdığı örneklerin yüzde kaçının aslında pozitif olduğunu gösterir. F1 skoru, duyarlılık ve kesinlik arasında denge sağlayan bir metriktir ve %94.42'dir. Bu, bir sınıflandırma modelinin hassasiyet ve kesinlik arasındaki dengeyi ne kadar iyi sağladığını gösterir. Genel olarak, bu sonuçlar modelin iyi bir performans sergilediğini göstermektedir. Yüksek doğruluk, hassasiyet, özgüllük ve kesinlik, modelin hem pozitif hem negatif sınıfları doğru bir şekilde sınıflandırdığını gösterir. Ancak, yanlış pozitif oranı da göz önünde bulundurulmalıdır çünkü düşük yanlış pozitif oranı model değerlendirmesi açısından önemlidir ve bu değerin olabildiği kadar düşük olması arzu edilir.

4.1.5. DenseNet201'e ait ROC eğrileri



Şekil 4.6. DenseNet201'e ait ROC eğrisi

Şekil 4.6.da DenseNet201 modeline ait ROC eğrisine yer verilmiştir. ROC eğrileri, ikili sınıflandırma modellerinin performansını değerlendirmek için yaygın bir

şekilde kullanılır. Eksen üzerinde gerçek pozitif oranını (TPR), yatay ekseninde ise yanlış pozitif oranını (FPR) gösterirler. TPR, duyarlılık veya geri çağırma olarak da bilinir, model tarafından doğru olarak tanımlanan pozitif örneklerin oranıdır. FPR, model tarafından yanlışlıkla pozitif olarak tanımlanan negatif örneklerin oranıdır. İdeal bir ROC eğrisi, grafiğin sol kenarını ve üst kısmını takip ederek sol üst köşede (0, 1) noktasına ulaşır. Bu, modelin tüm pozitif örnekleri doğru sınıflandırdığını (TPR = 1) ve negatif örneklerin hiçbirini yanlış sınıflandırmadığını (FPR = 0) gösterir. ROC eğrisi altında kalan alan (AUC), modelin performansını tüm olası sınıflandırma eşikleri boyunca özetleyen sayısal bir ölçüdür. Modelin rastgele seçilmiş bir pozitif örneği, rastgele seçilmiş bir negatif örnekten daha üst sıraya yerleştirme olasılığını temsil eder. 1 AUC mükemmel bir sınıflandırıcıya karşılık gelirken, 0.5 AUC ise rastgele tahmine eşdeğerdir (Fawcett, 2006). ROC eğrisinde, farklı sınıfların (CNV, DME, DRUSEN ve NORMAL) tüm eğrileri sol üst köşede yer almakta olup 1.00 gibi mükemmel AUC değerlerine sahiptir. Bu, CNN modelinin bu sınıflar arasında sınıflandırma yaparken çok iyi performans gösterdiğine işaret etmektedir.

Bu tez çalışmasında Şekil 4.6'da verilen ROC eğrisi, modelin sınıflandırma performansını değerlendirmek amacıyla kullanılmıştır. Çalışmada dört ayrı sınıf (CNV, DME, Drusen ve Normal) bulunmakta olup, bu tür çok sınıflı sınıflandırma problemlerinde yaygın olarak kullanılan yöntem, her bir sınıfın “one-vs-rest” yaklaşımıyla ele alınarak elde edilen ROC eğrilerinin tek bir grafik üzerinde birlikte sunulmasıdır. Bu yaklaşım, sınıflar arası ayırt edicilik performansının karşılaştırmalı biçimde değerlendirilmesini kolaylaştırmakta ve modelin genel tanı gücünü daha bütüncül bir biçimde ortaya koymaktadır.

Akademik literatürde bu yöntem sıkça tercih edilmiştir. Örneğin Lu ve ark. (2018), geliştirdikleri çok sınıflı derin öğrenme tabanlı sistemin performansını değerlendirmek amacıyla, tüm sınıflara ait ROC eğrilerini tek bir grafikte sunarak modelin genel ayırt edicilik gücünü tek bir grafik üzerinden değerlendirmektedir. Benzer bir şekilde Cheng ve ark. (2021), CNV, DME, DRUSEN ve NORMAL sınıflarını içeren çok sınıflı sınıflandırma problemlerinde geliştirdikleri derin öğrenme modelinin performansını, her sınıfa ait ROC eğrilerini tek bir grafikte sunarak görsel olarak karşılaştırmayı ve modelin ayırt edicilik gücünü bütüncül biçimde değerlendirmeyi amaçlamışlardır. Bu yaklaşım, modelin hangi sınıflarda daha başarılı veya zayıf olduğunu görsel olarak anlamayı kolaylaştırmakta, çok sınıflı problemler için genel performans analizine bütüncül bir bakış açısı sağlamaktadır. Ayrıca, sınıflar arası dengesizlik veya benzerlik durumlarında modelin ayırt edici gücündeki farklılıkları

açıkça ortaya koymak için de etkili bir yöntemdir. Rajagopalan ve ark. (2021), ROC eğrilerinin tek bir grafikte sunulma nedeni, modelin dört farklı sınıf (CNV, DME, DMD ve NORMAL) üzerindeki sınıflandırma performansını tek ve bütüncül bir bakışla karşılaştırmalı olarak değerlendirmek ve görselleştirmektir. Böylece, modelin her bir sınıf için ayırt edicilik başarımı (True Positive Rate vs. False Positive Rate) aynı ölçek üzerinde gözlemlenebilmekte ve klinik olarak öncelikli sınıflarda (örneğin CNV, DME gibi acil sevk gerektiren durumlar) modelin duyarlılığı hakkında yorum yapmak kolaylaşmaktadır. Ayrıca bu grafik, modelin hangi sınıflarda daha güçlü veya zayıf performans gösterdiğini doğrudan karşılaştırmalı biçimde ortaya koyarak, sınıf bazlı optimizasyonlar için de yol gösterici olmaktadır.

Bu bağlamda, Şekil 4.6.da sunulan çoklu ROC eğrisi yaklaşımı, modelin tüm sınıflardaki tanı gücünü bütüncül ve karşılaştırmalı biçimde sergilemekte, modelin klinik güvenilirliğini değerlendirmek açısından önemli bir görsel araç olarak işlev görmektedir. Öte yandan ROC eğrilerinin her sınıf için ayrı ayrı grafiklerde sunulması, görsel karmaşayı azaltmak gibi bazı avantajlar sunsa da çok sınıflı sınıflandırma problemlerinde bazı önemli dezavantajlara da sahiptir. Öncelikle, her eğri farklı grafiklerde yer aldığına sınıflar arası ayırt edicilik performansının doğrudan ve bütüncül biçimde karşılaştırılması zorlaşır; bu da modelin güçlü ya da zayıf yönlerinin topluca değerlendirilmesini engelleyebilir. Ayrıca, farklı eksen aralıkları ya da ölçekler kullanıldığında görsel karşılaştırmaların yanıltıcı hale gelmesi mümkündür. Klinik önemi farklı olan sınıfların duyarlılık ve özgüllük açısından bir arada değerlendirilmesi, özellikle öncelikli hastalıkların ayırt edilmesinde kritik rol oynar. Bu nedenle, çok sınıflı sınıflandırmalarda ROC eğrilerinin tek bir grafikte sunulması, ölçek birliğini koruyarak doğrudan karşılaştırma yapılmasını ve modelin genel tanısal başarımının bütüncül olarak analiz edilmesini sağlar.

4.2. Tartışma

Elde edilen sonuçlar, modelin retina hastalıklarının tespiti konusunda güvenilir bir araç olduğunu göstermektedir. Yüksek doğruluk ve hassasiyet oranları, modelin doğru pozitifleri başarılı bir şekilde tespit edebildiğini ve retina hastalıklarının erken teşhisinde etkili olduğunu kanıtlamaktadır. Bununla birlikte, modelin özgüllük oranının yüksek olması, yanlış pozitif oranının düşük olduğunu ve modelin sağlıklı görüntüleri doğru bir şekilde ayırt edebildiğini göstermektedir.

Modelin başarısının altında yatan ana nedenler arasında DenseNet201 yapısının kullanılması ve eğitim verisinin dengeli bir şekilde dağıtılması bulunmaktadır. DenseNet201 modeli, katmanlar arasında yoğun bağlantılar oluşturarak bilgi akışını iyileştirmiş ve modelin daha verimli çalışmasını sağlamıştır. Ayrıca, eğitim verisinin dengeli dağılımı, modelin her bir hastalık kategorisinde yüksek performans göstermesine katkıda bulunmuştur.

Ancak, bazı sınırlamalar da göz önünde bulundurulmalıdır. Modelin performansı, kullanılan veri setinin kalitesine ve miktarına bağlıdır. Eğitim ve test verilerinin çeşitliliği artırılarak modelin genelleme yeteneği geliştirilebilir. Ayrıca, modelin gerçek dünya koşullarında da test edilmesi, performansını daha iyi değerlendirmek için önemlidir. Modelin sadece belirli bir veri seti üzerinde test edilmesi, genelleme yeteneği konusunda sınırlamalar yaratabilir. Bu nedenle, farklı veri setleri ve gerçek klinik veriler üzerinde test edilmesi gereklidir.

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuç

Bu çalışmada geliştirilen yapay zekâ destekli model, Optik Koherens Tomografi (OCT) görüntülerini kullanarak retina hastalıklarını yüksek doğrulukla tespit etmeyi başarmıştır. Test çalışmaları sırasında, modelin doğruluk, hassasiyet, özgüllük ve kesinlik gibi performans metriklerinde oldukça yüksek sonuçlar elde edilmiştir. Modelin doğruluk oranı %94,42, hassasiyet oranı %94,42, özgüllük oranı %98,14, kesinlik oranı %94,42 ve F1 skoru %94,42 olarak belirlenmiştir. Ayrıca, ROC eğrisi altında kalan alan (AUC) değeri 1.00 olup, modelin mükemmel bir sınıflandırma performansı sergilediğini göstermektedir.

Modelin doğruluk ve hassasiyet oranlarının yüksek olması, özellikle erken teşhis gerektiren retina hastalıklarının tespiti açısından büyük bir avantaj sağlamaktadır. Hastalıkların erken evrelerinde doğru teşhis konulabilmesi, tedavi sürecini hızlandırmakta ve hastaların görme yetisini korumasına yardımcı olmaktadır. Ayrıca, modelin hızlı ve doğru tahmin yapabilme yeteneği, klinik ortamlarda doktorların iş yükünü azaltarak daha fazla hastaya hizmet verebilmelerini sağlayabilir.

5.2. Öneriler

Literatür araştırması çalışmalarında da görüldüğü üzere retina hastalıkları üzerinde birçok çalışma mevcuttur. Bu alışımayı diğer çalışmalardan ayıran en önemli özelliklerinden başında kullanılan yapay zekâ modeli dışında diğerlerinden daha kapsamlı bir şekilde birçok yönüyle düşünülüp dizayn edilmiş arayüzüdür. Fakat kabul edilmelidir ki bu çalışma en üst düzey bir çalışma olmamakla beraber geliştirilmeye son derece müsait bir çalışmadır.

Tez çalışması hazırlık aşamasında çeşitli hastane yönetimi bireyleri, sağlık personelleri ve yazılım geliştiriciler ile görüşülmüş olup hem fikir alışverişi sağlanmaya çalışılmış hem de çalışmayı daha da ileriye taşımak için, daha doğrusu daha da geliştirmek için ne gibi çalışmaların yapılabileceği konusunda destekleri talep edilmiştir. Ama ne yazık ki bu araştırmalar esnasında bazı pürüzler meydana

gelmesinden, çeşitli izinlerin gerekmesinden ve çalışmanın tahmine edilenden çok daha maliyetli ve uzun sürecektir olmasından dolayı çalışmanın ileri seviye geliştirilmesi fikir olarak kalmıştır ve bu bölüm başlığı altında dile getirilecektir.

Çalışma esnasında meydana gelen en büyük pürüz, çalışmanın düşük donanımlı bilgisayarda istenilen performansa ulaşamaması ve gereğinden fazla zaman harcamasıdır. Günlük hayatta sağlık sektörü özelinde düşünülecek olunursa hastane ortamındaki her bilgisayarın donanımsal olarak yeterli olmadığından yola çıkarak bu çalışmadan istenilen performansın elde edilemeyeceği fikri açıkça göze çarpmaktadır. Bu da çalışmayı kullanışlı olmaktan biraz uzaklaştırmaktadır.

Çalışma esnasında meydana gelen bir diğer problem görüşülen hastanelerde OCT cihazının olmaması ve olanlarında da sağlık bakanlığı iznidir. Modeli gerçek verilerle test etmek için çeşitli hastane yönetimleri ve sağlık personelleriyle görüşülmüş, fakat çoğunda OCT cihazı mevcut değildi. OCT cihazı mevcut olanları da hasta mahremiyeti ve sağlık bakanlığı izni gerekçesiyle talebi geri çevirmişlerdir.

Çalışma esnasında hastanelere yazılım desteği sağlayan yazılım şirketleriyle de görüşülmüş olup teknik detaylar ve diğer problemler hakkında bilgi alışverişi sağlanmıştır. Bu çalışmayı hastane yazılımlarına veya OCT cihazına entegre etmek için yazılım şirketleriyle görüşülmüş olup zaman, maliyet ve izin gibi çeşitli problemlerle karşılaşmıştır. Entegrasyon yöntemi öneriler bölümünde irdelenmiştir.

Çalışma çok yönlü tasarlanmış olmasına rağmen yukarıda zikredilen problemlerden ötürü kısıtlı kalmıştır. Çalışmaya dahil edilemeyen fikirler ve gelecek çalışmalar için aşağıdaki öneriler sunulabilir:

5.2.1. Veri çeşitliliği ve miktarının artırılması

Modelin genelleme yeteneğini artırmak için daha geniş ve çeşitli veri setleri kullanılması önerilir. Farklı coğrafi bölgelerden ve çeşitli demografik özelliklere sahip bireylerden elde edilen OCT görüntüleri, modelin performansını iyileştirebilir. Ayrıca, veri setlerine yeni hastalık kategorilerinin eklenmesi, modelin daha kapsamlı bir şekilde eğitilmesini sağlayabilir.

5.2.2. Modelin gerek dnya kořullarında test edilmesi

Modelin klinik ortamlarda ve gerek hasta verileriyle test edilmesi, performansının daha doęru bir řekilde deęerlendirilmesini saęlayabilir. Bu, modelin pratik kullanımda ne kadar bařarılı olduęunu grmek iin nemlidir. Gerek dnya verilerinde elde edilecek sonular, modelin iyileřtirilmesi gereken noktaları belirlemek iin de faydalı olacaktır.

5.2.3. Hibrit yntemlerin kullanılması

Modelin performansını daha da artırmak iin hibrit yntemler kullanılması nerilir. rneęin, derin ęrenme modelleri ile geleneksel makine ęrenimi algoritmalarının birleřtirilmesi, modelin doęruluęunu ve hassasiyetini artırabilir. Ayrıca, farklı derin ęrenme modellerinin entegrasyonu ile daha karmařık ve gl modeller oluřturulabilir.

5.2.4. Kullanıcı Ara yznn Geliřtirilmesi

Kullanıcı dostu ve etkileřimli bir ara yz geliřtirilmesi, saęlık profesyonellerinin modeli daha etkin bir řekilde kullanmalarını saęlayabilir. Kullanıcı geri bildirimlerine dayalı iyileřtirmeler yapılabilir. Ara yzn kullanım kolaylıęı, modelin benimsenmesini ve yaygın olarak kullanılmasını artıracaktır.

5.2.5. Gerek zamanlı tahmin ve grselleřtirme

Modelin gerek zamanlı tahmin ve grselleřtirme yetenekleri geliřtirilerek, OCT grntleri anında iřlenip sonular kullanıcıya sunulabilir. Bu, klinik karar verme srelerini hızlandırabilir ve doktorların daha hızlı ve doęru kararlar almasını saęlayabilir. Ayrıca, gerek zamanlı grselleřtirme ile hastalık blgelerinin daha iyi analiz edilmesi mmkn olabilir.

5.2.6. Modelin sürekli eğitimi ve güncellenmesi

Modelin performansını artırmak ve güncel kalmasını sağlamak için sürekli eğitim ve güncelleme yapılmalıdır. Yeni veriler ve hastalık örnekleri modelin eğitimine dâhil edilerek, modelin adaptasyonu sağlanabilir. Bu, modelin zamanla değişen hastalık trendlerine ve yeni ortaya çıkan hastalık türlerine karşı da etkili olmasını sağlar.

5.2.7. Multimodal veri entegrasyonu

Retina hastalıklarının tespitinde sadece OCT görüntüleri değil, diğer medikal görüntüler ve hasta verileri de kullanılabilir. Multimodal veri entegrasyonu ile daha kapsamlı ve doğru teşhisler yapılabilir. Bu yaklaşım, hastalığın farklı yönlerini daha iyi analiz etmeyi ve daha kesin teşhisler koymayı mümkün kılar.

Bu öneriler, gelecekte yapılacak çalışmalarda modelin performansını artırmak ve daha geniş bir kullanım alanına yayılmasını sağlamak için önemli adımlar olarak değerlendirilebilir.

5.2.8. OCT cihazına entegrasyonu

Daha etkin ve yerinde sonuç almak ve sağlık personelinin zamanından tasarruf sağlamak için model gömülü sistem olarak güncelleme yoluyla veya başka bir yolla OCT cihazına entegre edilebilir. Böylece kullanıcı arayüzüne grafiksel ve istatistiksel olarak sonuç anında yansır. Hatta öyle ki hastanın önceki görüntüleri varsa onlarla karşılaştırarak hastalığın ilerleyişi hakkında bilgi vermek mümkün olur.

5.2.9. Sağlık sistemi yazılımlarına ve e-nabız'a entegrasyonu

Her hastanenin çalıştığı yazılım ve dolayısıyla yazılım desteği sağlayan şirketler farklı olmaktadır. Bu yazılım şirketleriyle görüşülüp kendi yazılımlarına entegre edilebilir. Böylece doktorun bilgisayarına görüntü ile beraber görüntü sonuçları da grafiksel ve istatistiksel olarak yansır. Aynı durum E-nabız için de gereklidir. Tabi özellikle sunulan son iki öneri çalışmanın başlıca hedefleriydi fakat yine yukarıda zikredilen problemlerden dolayı şimdilik fikir aşamasında öteye gidememiştir. Yeterli

altyapı sađlandıktan, mali destek ve gerekli izinler sađlandıktan sonra bu fikirler gerekleřtirilebilir.



KAYNAKLAR

- Abid, A., Abdalla, A., Abid, A., Khan, D., Alfozan, A., & Zou, J. (2019). Gradio: Hassle-Free Sharing and Testing of ML Models in the Wild. arXiv preprint arXiv:1906.02569
- Acar, E., Türk, Ö., Ertuğrul, Ö. F. ve Aldemir, E. (2021). Employing deep learning architectures for image-based automatic cataract diagnosis. *Turkish Journal of Electrical Engineering & Computer Sciences*, 29(5), 2649–2662. <https://doi.org/10.3906/elk-2103-77>
- Ait Hammou, B., Antaki F., Boucher M. C., & Duval R. (2023). MBT: Model-Based Transformer for retinal optical coherence tomography image and video multi-classification. *International Journal of Medical Informatics*, 178, 105178.
- Alsaih, K., Lemaitre, G., Rastgoo, M., Massich, J., Sidibé, D., & Hafiane, A. (2017). Machine learning techniques for diabetic macular edema (DME) classification on SD-OCT images. *Biomedical Engineering/Biomedizinische Technik*, 62(6), 593–602
- Apaydın, K. C., & Bilgin, A. B. (2010). Diabetic Retinopathy: Early Diagnosis and Medical Treatment. *Journal of Retina-Vitreous*, 18 (Özel Sayı), 61-65.
- Arica, E. ve Kaya, Y. (2023). ResNet-18 transfer derin öğrenme ile anlamsal bölütleme. *Uluslararası Bilişim Kongresi Bildiriler Kitabı*, Batman, s.953(1), 91–103.
- Aydın, A., & Bilge, A. H. (2007). Optik koherens tomografinin glokomda yeri. *Glokom-Katarakt Oftalmoloji Dergisi*, 2(2), 77–82. <https://search.trdizin.gov.tr/en/yayin/detay/69314>
- Aykat, Ş., & Şenan, S. (2023). Advanced detection of retinal diseases via novel hybrid deep learning approach. *Traitement du Signal*, 40(6), 2367–2382. <https://doi.org/10.18280/ts.400604>
- Baharlouei, Z., Rabbani, H., & Plonka, G. (2023). Wavelet scattering transform application in classification of retinal abnormalities using OCT images. *Scientific Reports*, 13, 19013. <https://doi.org/10.1038/s41598-023-46200-1>
- Bar-David, D., Bar-David, L., Shapira, Y., Leibu, R., Dori, D., Gebara, A., Schneur, R., Fischer, A., & Soudry, S. (2023). Elastic Deformation of Optical Coherence Tomography Images of Diabetic Macular Edema for Deep-Learning Models Training: How Far to Go? *IEEE Journal of Translational Engineering in Health and Medicine*, 11, 487–494.
- Bayram, F. (2020). Derin öğrenme tabanlı otomatik plaka tanıma. *Politeknik Dergisi*, 23(4), 955–960.
- Berger, J. (2018). *Görme Biçimleri* (24. B.). İstanbul: Metis Yayınları.

- Berrimi, M., & Moussaoui, A. (2020). Deep learning for identifying and classifying retinal diseases. In 2020, the 2nd International Conference on Computer and Information Sciences (ICCIS) (pp. 1–6). IEEE. <https://doi.org/10.1109/ICCIS49240.2020.9257674>
- Bhende, M., Shetty, S., Parthasarathy, M. K., & Ramya, S. (2018). Optical coherence tomography: A guide to interpretation of common macular diseases. *Indian Journal of Ophthalmology*, 66 (1), 20.
- Borno, M. N. A., Shovon, M. S. H., Sikder, M. H., Rimi, I. F., Alahmadi, T. J., & Moni, M. A. (2025). Federated Learning with LoRA Optimized DeiT and Multiscale Patch Embedding for Secure Eye Disease Recognition. *arXiv*. <https://doi.org/10.48550/arXiv.2505.06982>
- Bos, B., Çelik, T., Hickson, I., Lie, H. W. (2011). Cascading Style Sheets Level 2 Revision 1 (CSS 2.1) Specification. World Wide Web Consortium (W3C).
- Caelen, O. (2017). A Bayesian interpretation of the confusion matrix. *Annals of Mathematics and Artificial Intelligence*, 81 (3), 429-450
- Chandra Joshi, R., Kumar Sharma, A., & Kishore Dutta, M. (2024). VisionDeep-AI: Deep learning-based retinal blood-vessels segmentation and multi-class classification framework for eye diagnosis. *Biomedical Signal Processing and Control*, 94, 106273.
- Curcio, C. A., Sloan, K. R., Kalina, R. E., & Hendrickson, A. E. (1990). Human photoreceptor topography. *Journal of Comparative Neurology*, 292 (4), 497-523.
- Çimeliler, A. & Çelik, N. (2008). Bilgi ve erişim amaçlı bir tekstil web sitesinin tasarımı ve uygulaması. *Çukurova Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 19(4), 102–111.
- Dai, H., Yang, Y., Yue, X., & Chen, S. (2024). Improving retinal OCT image classification accuracy using medical pre-training and sample replication methods. *Biomedical Signal Processing and Control*, 91, 106019.
- Dandekar, S. S., Jenkins, S. A., Peto, T., et al. (2005). Autofluorescence imaging of choroidal neovascularization due to age-related macular degeneration. *Archives of Ophthalmology*, 123, 1507-1513.
- Demir, F.B., Yılmaz, E. (2021). X-Ray Görüntülerinden COVID-19 Tespiti için Derin Öğrenme Temelli Bir Yaklaşım. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 627-632.
- Demirezen, Y. (2008). Retina hastalıklarının teşhisinde yapay zekâ destekli bir sistem önerisi (Yüksek lisans tezi). Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- Deutman, A. F., & Hansen, L. M. A. A. (1970). Dominantly inherited drusen of Bruch's membrane. *British Journal of Ophthalmology*, 34, 373-382.

- Diao, S., Su, J., Yang, C., Zhu, W., Xiang, D., Chen, X., Peng, Q., & Shi, F. (2023). Classification and segmentation of OCT images for age-related macular degeneration based on dual guidance networks. *Biomedical Signal Processing and Control*, 84, 104810.
- Doğanay, E. (2010). Hipertansiyon için retina görüntülerinden atardamar daralmasını kullanarak otomatik tanı algoritmasının geliştirilmesi (Yüksek lisans tezi, Fatih Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı).
- Elsharif, A. A. E. F., & Abu-Naser, S. S. (2022). Retina diseases diagnosis using deep learning. *International Journal of Academic Engineering Research (IJAER)*, 6(2), 11–37.
- Elsharkawy, M., Sharafeldeen, A., Soliman, A., Khalifa, F., Ghazal, M., El-Daydamony, E., Atwan, A., Sandhu, H. S., & El-Baz, A. (2022). A novel computer-aided diagnostic system for early detection of diabetic retinopathy using 3D-OCT higher-order spatial appearance model. *Diagnostics*, 12(2), 532. <https://doi.org/10.3390/diagnostics12020532>.
- Erdoğan, A. Epiretinal Membran Cerrahisinde Prognozu Etkileyen Faktörler. *Uzmanlık Tezi*, s. 8.
- Fan, Y., Gao, E., Liu, S., Guo, R., Dong, G., Tang, X., Liao, H., & Gao, T. (2024). RMAP-ResNet: Segmentation of brain tumor OCT images using residual multicore attention pooling networks for intelligent minimally invasive theranostics. *Biomedical Signal Processing and Control*, 90, 105805.
- Fawcett, T. (2006). ROC analizine giriş. *Pattern Recognition Letters*, 27(8), 861–874. doi:10.1016/j.patrec.2005.10.010
- Fernández, D. C. (2005). Delineating fluid-filled region boundaries in optical coherence tomography images of the retina. *IEEE Transactions on Medical Imaging*, 24 (8), 929-945.
- Fu, M.-Y., Wang, Y., Wei, W., Chen, Z., & Li, Z. (2023). The progress of optical coherence tomography in industry applications. *Advanced Devices & Instrumentation*, 2 (5), 53. <https://doi.org/10.34133/adi.0053>
- Gargeya, R., & Leng, T. (2017). Automated identification of diabetic retinopathy using deep learning. *Ophthalmology*, 124(7), 962–969.
- Gencer, G., & Gencer, K. (2024). Advanced retinal disease detection from OCT images using a hybrid squeeze and excitation enhanced model. *PLOS ONE*, 19(6), e0318657. <https://doi.org/10.1371/journal.pone.0318657>

- Glorot, X., Bordes, A., & Bengio, Y. (2011). Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics. PMLR, 15, 315-323.
- Gökmen, F. G. (2003). Sistematik Anatomi. İzmir: Güven Kitabevi, 794-796, 869-892.
- Gueddena, Y., Aboudi, N., Zgolli, H., Mabrouk, S., Sidibe, D., Tabia, H., & Khelifa, N. (2024). A new intelligent system based deep learning to detect DME and AMD in OCT images. International Ophthalmology, 44, Article 191. <https://link.springer.com/article/10.1007/s10792-024-03115-8>
- Gülsüm, A. R. (2023). Derin Öğrenme ile Optik Koherens Tomografi Görüntülerinden Retinal Bozukluk Tanısı. Yüksek Lisans Tezi, İstanbul.
- Güzel, F., Sarp, G. ve Temürçin, K. (2025). ResNet-34 derin öğrenme algoritması ile deprem sonrası yıkılan yapıların tespiti: 6 Şubat 2023 depremi, Antakya örneği. Mühendislik Bilimleri ve Tasarım Dergisi, 13(1), 57.
- He, T., Zhou, Q. ve Zou, Y. (2022). Automatic detection of age-related macular degeneration based on deep learning and local outlier factor algorithm. Diagnostics, 12(2), 532. <https://doi.org/10.3390/diagnostics12020532>
- Hipwell, J., Strachan, F., Olson, J., McHardy, K., Sharp, P., & Forrester, J. (2000). Automated detection of microaneurysms in digital red-free photographs: A diabetic retinopathy screening tool. Diabetic Medicine, 17(8), 588–594.
- Hussain, M. A., Bhuiyan, A., Luu, C. D., Smith, R. T., Guymer, R. H., Ishikawa, H., Schuman, J. S., & Ramamohanarao, K. (2018). Classification of healthy and diseased retina using SD-OCT imaging and Random Forest algorithm. PLOS ONE, 13(6), e0198281. <https://doi.org/10.1371/journal.pone.0198281>
- İnik, Ö. & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3), 85–104.
- İsmail Malkoç (2005). İnsan ve Görme Duyusu Gelişmiş Hayvanların Görme Yollarının Karşılaştırmalı Anatomisi. Doktora Tezi, Erzurum.
- Kamble, R. M., Chan, G. C., Perdomo, O., Kokare, M., Gonzalez, F. A., Müller, H., & Mériaudeau, F. (2018, December). Automated diabetic macular edema analysis using fine-tuning with Inception-ResNet-v2 on OCT images. In 2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES) (pp. 442-446). IEEE.
- Kamran, S. A., Saha, S., Sabbir, A. S., & Tavakkoli, A. (2019, December). Optic-Net: A novel convolutional neural network for diagnosis of retinal diseases from optical tomography images. In 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA) (pp. 964-971). IEEE.

- Kanagasingam, Y., Bhuiyan, A., Abramoff, M. D., Smith, R. T., Goldschmidt, L., & Wong, T. Y. (2014). Progress on retinal image analysis for age-related macular degeneration. *Progress in Retinal and Eye Research*, 38, 20–42.
- Karri, K., & Mahadevappa, M. (2023). Convolution neural networks for optical coherence tomography (OCT) image classification. *Biomedical Signal Processing and Control*, 79(Part 2), 104176. <https://doi.org/10.1016/j.bspc.2022.104176>
- Karthik, K., & Mahadevappa, M. (2023). Convolution neural networks for optical coherence tomography (OCT) image classification. *Biomedical Signal Processing and Control*, 79, 104176.
- Kavitha, S., & Shenbaga, D. V. (2005). An efficient approach for optic disc and exudates detection in diabetic retinopathy images. *International Journal of Computer Science and Network Security*, 5(12), 285–289.
- Khan, A., Pin, K., Aziz, A., Han, J. W., & Nam, Y. (2023). Optical coherence tomography image classification using hybrid deep learning and ant colony optimization. *Sensors*, 23(15), 6706. <https://doi.org/10.3390/s23156706>
- Kılınç, M. (2024). EfficientNet ve CNN ile Görme Engelliler için Yüz Tanıma ve Duygu Analizi Yaklaşımı. *Engelsiz Bilişim 2024- Teknolojide Eşit Fırsatlar Uluslararası Kongresi*, 9. <https://www.researchgate.net/publication/387663810>
- Kılınççeker, O. (2011). Diyabetik retinopati hastalığında lezyon bölgelerinin tespitine yönelik benzerlik ölçüm teknikleri (Yüksek lisans tezi, Ege Üniversitesi, Fen Bilimleri Enstitüsü, Uluslararası Bilgisayar Anabilim Dalı).
- Kırık, F., Demirkıran, B., Ekinci Aslanoglu, C., Koytak, A., & Özdemir, H. (2023). Detection and Classification of Diabetic Macular Edema with a Desktop-Based Code-Free Machine Learning Tool. *Turkish Journal of Ophthalmology*, 53(5), 301–306. <https://doi.org/10.4274/tjo.galenos.2023.92635>
- Kızrak, M. A. ve Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Gazi Üniversitesi Bilimsel Teknik ve Düşünce Dergisi*, (25), 1–13. <https://doi.org/10.17671/gazibtd.419205>
- Kim, J., & Tran, L. (2021). Retinal disease classification from OCT images using deep learning algorithms. *2021 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB 2021)*.
- Kingma, D. P. ve Ba, J. L. (2015). Adam: A method for stochastic optimization. *Uluslararası Temsili Öğrenme Konferansı (International Conference on Learning Representations - ICLR 2015)*. <https://arxiv.org/abs/1412.6980>
- Kulyabin, M., Zhdanov, A., Nikiforova, A., Stepichev, A., Kuznetsova, A., Ronkin, M., Borisov, V., Bogachev, A., Korotkich, S., Constable, P. A., & Maier, A. (2024). OCTDL: Optical coherence tomography dataset for image-based deep learning methods. *Scientific Data*, 11(365). <https://doi.org/10.1038/s41597-024-03182-7>

- Latha, V., Ashok, L. R., & Sreeni, K. G. (2021). Automated macular disease detection using retinal optical coherence tomography images by fusion of deep learning networks. 2021 National Conference on Communications (NCC 2021).
- Liu, M. ve Grana, D. (2019). Accelerating geostatistical seismic inversion using TensorFlow: A heterogeneous distributed deep learning framework. *Computers & Geosciences*, 124, 37–45.
- Liu, T., Fang, S., Zhao, Y., Wang, P., & Zhang, J. (2015). Implementation of training convolutional neural networks. arXiv:1506.01195.
- Lu, W., Tong, Y., Yu, Y., Xing, Y., Chen, C., Shen, Y., & Shen, Y. (2018). Deep learning-based automatic classification of multi-categorical abnormalities from optical coherence tomography images. *Translational Vision Science & Technology*, 7(6), 41. <https://doi.org/10.1167/tvst.7.6.41>
- Ma, W., & Lu, J. (2017). An equivalence of fully connected layer and convolutional layer. arXiv:1712.01252.
- Matallah, H., Belalem, G., & Bouamrane, K. (2021). Comparative Study Between the MySQL Relational Database and the MongoDB NoSQL Database. *International Journal of Software Science and Computational Intelligence (IJSSCI)*, 13(3), 38-63.
- Motozawa, N., Mizuashi, M., Ueda, T., Kato, Y., Shibuya, E., Miyake, M., ... & Yoshikawa, T. (2019). Evaluation of deep learning models for the classification of normal and age-related macular degeneration in optical coherence tomography images. *Journal of Clinical Medicine*, 8(9), 1420. <https://pubmed.ncbi.nlm.nih.gov/31407214/>
- Motozawa, N., An, G., Takagi, S., Kitahata, S., Mandai, M., Hiram, Y., ... & Kurimoto, Y. (2019). Optical coherence tomography-based deep-learning models for classifying normal and age-related macular degeneration and exudative and non-exudative changes. *Ophthalmology and Therapy*, 8 (4), 527-539.
- Mooney, P. T. (2018). Kermany 2018: Labeled optical coherence tomography (OCT) and chest X-ray images [Dataset]. Kaggle. <https://www.kaggle.com/datasets/paultimothymooney/kermany2018>
- Muni Nagamani, G., & Rayachoti, E. (2024). Deep learning network (DL-Net) based classification and segmentation of multi-class retinal diseases using OCT scans. *Biomedical Signal Processing and Control*, 88, 105619.
- Özdemir, E., & Türkoğlu, İ. (2022). Yazılım Güvenlik Açıklarının Evrimsel Sınır Ağları (CNN) ile Sınıflandırılması.
- Özküçük, M., Alçın, Ö. F. ve Gençoğlu, M. (2022). EMG sinyalleri kullanılarak GoogLeNet ve çok seviyeli DPD ile el tutma hareketlerinin sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 33–43. <https://doi.org/10.35234/fumbd.932585>

- Pekala, M., Joshi, N., Liu, T. A., Bressler, N. M., DeBuc, D. C., & Burlina, P. (2019). Deep learning based retinal OCT segmentation. *Computers in Biology and Medicine*, 114, 103445.
- Perdomo, O., Rios, H., Rodríguez, F. J., Otálora, S., Meriaudeau, F., Müller, H., & González, F. A. (2019). Classification of diabetes-related retinal diseases using a deep learning approach in optical coherence tomography. *Computer Methods and Programs in Biomedicine*, 183, 105047. <https://doi.org/10.1016/j.cmpb.2019.06.016>
- Pin, K., Chang, J. H., & Nam, Y. (2022). Comparative study of transfer learning models for retinal disease diagnosis from fundus images.
- Rajagopalan, N., Venkateswaran, N., Josephraj, A. N., and Srithaladevi, E. (2021). Diagnosis of retinal disorders from Optical Coherence Tomography images using CNN. *PLoS ONE*, 16(7), e0254180. <https://doi.org/10.1371/journal.pone.0254180>
- Resnikoff, S., Lansingh, V. C., Washburn, L., Felch, W. C., & Gauthier, T. M. (2020). Vision loss and its impact on quality of life. *Ophthalmic Epidemiology*, 27 (2), 85-90.
- Salaheldin, A. M., Wahed, M. A., & Saleh, N. (2022). Machine learning-based platform for classification of retinal disorders using optical coherence tomography images. In *Artificial Intelligence and Sustainable Computing* (pp. 269–283). Springer. https://link.springer.com/chapter/10.1007/978-981-19-1653-3_21
- Salati, M., Askerzade, İ. & Bostancı, G. E. (2025). Saldırı tespiti için metasezgisel tabanlı özellik seçim yöntemi kullanan evrişimli sinir ağı modelleri. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 40(1), 179–188. <https://doi.org/10.17341/gazimmfd.1287186>
- Sharma, A., & Sharma, A. (2018). Introduction to HTML (Hyper Text Markup Language) – A Review Paper. *International Journal of Science and Research*, 7(5), 1337–1339
- Sertkaya, M. E., Ergen, B., & Togacar, M. (2019). Diagnosis of eye retinal diseases based on convolutional neural networks using optical coherence images. In *2019 23rd International Conference Electronics* (pp. 1–4). IEEE. <https://doi.org/10.1109/ELECTRONICS.2019.8765579>
- Shi, X., Keenan, T. D. L., Chen, Q., De Silva, T., Thavikulwat, A. T., Broadhead, G., Bhandari, S., Cukras, C., Chew, E. Y., and Lu, Z. (2021). Improving interpretability in machine diagnosis: Detection of geographic atrophy in OCT scans. *Ophthalmology Science*, 1(3), 100038. <https://doi.org/10.1016/j.xops.2021.100038>
- Sinthanayothin, C., Boyce, J. F., Cook, H. L., Williamson, T. H., & Usher, D. (1999). Automated localisation of the optic disc, fovea, and retinal blood vessels from digital colour fundus images. *British Journal of Ophthalmology*, 83(8), 902-910.

- Srinivasan, P. P., Kim, L. A., Mettu, P. S., Cousins, S. W., Comer, G. M., Izatt, J. A., & Farsiu, S. (2014). Fully automated detection of diabetic macular edema and age-related macular degeneration from optical coherence tomography images. *Biomedical Optics Express*, 5(10), 3568–3577.
- Stanojević, M., Drašković, D., & Nikolic, B. (2022). Retinal disease classification based on optical coherence tomography images using convolutional neural networks. *Journal of Electronic Imaging*, 32(3), 032004. <https://doi.org/10.1117/1.JEI.32.3.032004>
- Suciu, C. I., Marginean, A., Suciu, V. I., Muntean, G. A., & Nicoară, S. D. (2023). Diabetic Macular Edema Optical Coherence Tomography Biomarkers Detected with EfficientNetV2B1 and ConvNeXt. *Diagnostics*, 14 (1), 76.
- Sun, Y., Zhang, H., & Yao, X. (2020). Automatic diagnosis of macular diseases from OCT volume based on its two-dimensional feature map and convolutional neural network with attention mechanism. *Journal of Biomedical Optics*, 25(9), 096004. <https://doi.org/10.1117/1.JBO.25.9.096004>
- Türkoğlu, M., Hanbay, K., Saraç Sivrikaya, I., & Hanbay, D. (2020). Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *BEÜ Fen Bilimleri Dergisi*, 9(1), 334-345.
- Urmamen, H. E. (2023). Optik koherens tomografi görüntüleri ile retinal hastalıkların evrişimsel sinir ağı kullanılarak teşhis edilmesi (Yüksek lisans tezi, Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı).
- Wang, X., Tang, F., Chen, H., Cheung, C. Y., & Heng, P. A. (2023). Deep semi-supervised multiple instance learning with self-correction for DME classification from OCT images. *Medical Image Analysis*, 83, 102673.
- Yıldız, A., Shams, P., & Güney, Z. (2021). MongoDB'nin ilişkisel veri tabanları gibi kullanılabilmesi. *ABMYO Dergisi*, 16(63), 151-172. https://doi.org/10.17932/IAU.ABMYOD.2006.005/abmyod_v16i63002
- Yoo, T. K., Choi, J. Y., & Kim, H. K. (2021). Feasibility study to improve deep learning in OCT diagnosis of rare retinal diseases with few-shot classification. *Medical & Biological Engineering & Computing*, 59, 401–415. <https://doi.org/10.1007/s11517-021-02321-1>
- Zhou, Q., Wang, J., Guo, J., Huang, Z., Ding, M., Yuchi, M., & Zhang, X. (2021). Anterior chamber angle classification in anterior segment optical coherence tomography images using hybrid attention-based pyramidal convolutional network. *Biomedical Signal Processing and Control*, 68, 102686.

EKLER

EK-1 Çalışma Web Site Kodları ve Model Eğitim Kodları Github Adresi

[1] <https://github.com/hasanmemis21/OCT-Classification-Doctor-Interface.git>

