

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**RETİNA HASTALIKLARININ OCT GÖRÜNTÜLERİNDEN
HİBRİT TABANLI CNN YÖNTEMİ İLE TESPİT EDİLMESİ**

Mümtaz KORKMAZ

Yüksek Lisans Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

TEMMUZ 2022

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

RETİNA HASTALIKLARININ OCT GÖRÜNTÜLERİNDEN HİBRİT TABANLI CNN YÖNTEMİ İLE TESPİT EDİLMESİ

Tez Yazarı

Mümtaz KORKMAZ

Danışman

Doç. Dr. Taner TUNCER

TEMMUZ 2022

ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Retina Hastalıklarının Oct Görüntülerinden Hibrit Tabanlı Cnn Yöntemi İle Tespit Edilmesi
Yazarı:	Mümtaz KORKMAZ
İlk Teslim Tarihi:	31.05.2022
Savunma Tarihi:	01.07.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Taner TUNCER Fırat Üniversitesi Bilgisayar Mühendisliği	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. Mehmet KAYA Fırat Üniversitesi Bilgisayar Mühendisliği	Onayladım
Üye:	Dr. Öğr. Üyesi Turab SELÇUK Sütçü İmam Üniversitesi Bilgisayar Mühendisliği	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Retina Hastalıklarının Oct Görüntülerinden Hibrit Tabanlı Cnn Yöntemi İle Tespit Edilmesi” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

01.07.2022

Mümtaz KORKMAZ



ÖNSÖZ

Yapay Zekânın bir alt alanı olan makine öğrenimi farklı disiplinleri içine alarak ve günlük hayatta karşılaşılan gerçek problemler için ürettiği zekice çözümler sebebiyle önemini her geçen gün ziyadeleştiren en önemli bilim dallarından biridir. Bu alanın gelişmesi sonucu ortaya çıkan ve makine öğreniminin bir alt dalı olan derin öğrenme de bu çalışmaya en büyük katkıyı sağlamış olmakla beraber ilerlemeye ve katkıyı arttırmaya devam etmektedir. Bu çalışmada derin öğrenme mimarileri kullanılarak retina hastalıklarının sınıflandırılması yapılmıştır.

Bu çalışma sürecinde bana her türlü sabır, destek ve bilgisiyle katkı sunan değerli danışmanım Doç. Dr. Taner TUNCER hocama, uygulama geliştirme sürecinde bana yardım eden değerli hoca ve arkadaşlarıma, her zaman bana destek veren ve yanımda olan çok kıymetli aileme ve eşime teşekkür ediyorum.

Mümtaz KORKMAZ

ELAZIĞ, 2022

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vi
ABSTRACT	vii
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	x
KISALTMALAR LİSTESİ	xi
1. GİRİŞ	1
2. GÖZÜN YAPISI VE RETİNA HASTALIKLARI.....	4
2.1. Yaşa Bağlı Makula Dejenerasyonu (AMD).....	5
2.2. Diyabetik Retinopati (DR).....	5
2.3. Santral Seröz Retinopati (SSR)	5
2.4. Makula Deliği (MH).....	6
2.5. Drusen	6
3. LİTERATÜR TARAMASI	7
4. YAPAY ZEKÂ, MAKİNE ÖĞRENİMİ, YAPAY SİNİR AĞLARI VE DERİN ÖĞRENME	18
4.1. Yapay Zekâ ve Tarihçe.....	18
4.2. Makine Öğrenimi.....	21
4.2.1. Gözetimsiz Makine Öğrenimi	24
4.2.2. Pekiştirmeli Makine Öğrenimi	24
4.3. Yapay Sinir Ağları.....	24
4.4. Derin Öğrenme	25
4.4.1. Derin Öğrenme Mimarileri.....	26
4.4.2. CNN Tabanlı Derin Öğrenme Algoritmaları.....	39
5. MATERYAL VE METOD	44
5.1. Veri Seti.....	45
5.2. Önerilen Yöntem	45
5.2.1. Veri Çoğullama	46
5.2.2. Önerilen Modelde Kullanılan CNN Mimarileri	47
5.2.3. Özellik Seçici Algoritmalar	47
5.2.4. Sınıflandırıcılar	48
6. DEĞERLENDİRME	49
6.1. Performans Matrikleri.....	49
6.2. Uygulama	50
7. SONUÇ.....	59
KAYNAKLAR.....	60
ÖZGEÇMİŞ	

ÖZET

Retina Hastalıklarının Oct Görüntülerinden Hibrit Tabanlı Cnn Yöntemi İle Tespit Edilmesi

Mümtaz KORKMAZ

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Temmuz 2022, Sayfa: xi + 66

İnsan hayatı için en önemli organlardan biri de hiç şüphesiz gözdür. Göz insanoğlunun dış dünyayı görmek için kullandığı bir araçtır. Hayatı olumsuz etkileyen mühim sebeplerden biri de gözde bulunan retinada meydana gelen hastalıklardır. Retinada oluşan hastalıklar görme fonksiyonunu etkilediğinden ve retinada oluşan hasar geri döndürülemez olduğundan hassas bir şekilde ele alınması gereken bir durumdur. Zamanında yapılmayan bir müdahale veya geciktirilmiş bir durum söz konusu olduğunda gözde kalıcı hasarlara sebep olabilmektedir. Söz konusu hastalıkların takip edilmesi için ihtiyaç duyulan doktor sayısı ve her geçen gün artan hasta sayısı arasında dengesizlikler oluşmakla birlikte bu hastaları takip etmek oldukça güç duruma gelmiştir. Bu sebeple hastalar için hem zaman hem ekonomik anlamda yardımcı olunması, diğer taraftan doktorların işini kolaylaştırması noktasında erken teşhis ve bunun neticesinde başlayacak hayat kurtarıcı tedaviler için yapay zekâ yöntemleri kullanılarak Optik Koherens Tomografi(OCT) görüntülerinden retina hastalıkları tespitinin yapılması mümkün hale gelmiştir.

Bu çalışmada yapay zekânın bir alt alanı olan makine öğrenimi, makine öğreniminin bir alt dalı olan ve günümüzde popüler hale gelen derin öğrenme mimarileri kullanılarak Yaşa Bağlı Makula Dejenerasyonu (AMD), Koroid Neovaskülarizasyonu (CNV), Diyabetik Makula Ödem (DME), Diyabetik Retinopati (DR), Santral Seröz Retinopati (SSR), Makula Deliği (MH) gibi retina hastalıkları ve Drusen retina hastalıkları OCT görüntülerinde hibrit tabanlı Convolutional neural networks(CNN) yöntemi kullanılarak hastalığın tespit edilmesi ve bu görüntülerin sınıflandırılması gerçekleştirilmesi amaçlanmıştır.

Anahtar Kelimeler: Yapay Zekâ, Makine Öğrenimi, Derin Öğrenme, Convolutional neural networks Retina hastalıkları, Optik Koherens Tomografi

ABSTRACT

Detection of Retinal Diseases From Oct Images By Hybrid-Based Cnn Method

Mümtaz KORKMAZ

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

July 2022, Pages: xi + 66

One of the most important organs for human life is undoubtedly the eye. The eye is a window that human beings use to see the outside world. One of the important causes that negatively affect life is the diseases that occur in the retina of the eye. Since diseases in the retina affect visual function and the damage to the retina is irreversible, it is a situation that should be seriously considered. In the case of a timely intervention or a delayed situation, it can cause permanent damage to the eye. Although there are imbalances between the number of doctors needed for the follow-up of these diseases and the number of patients increasing day by day, it has become very difficult to follow these patients. For this reason, it has become possible to detect retinal diseases from Optical Coherence Tomography (OCT) images by using artificial intelligence methods for early diagnosis and life-saving treatments that will begin as a result of helping patients both in terms of time and economy, and on the other hand, facilitating the work of doctors

In this study, machine learning, which is a sub-field of artificial intelligence, is a sub-branch of machine learning and using deep learning architectures that have become popular today, Age-Related Macular Degeneration (AMD), Choroid Neovascularization (CNV), Diabetic Macular Edema (DME), Diabetic Retinopathy (DR), Central Serous Retinopathy (CSR), Macular Hole (MH) and Drusen retinal diseases are aimed to detect the disease and classify these images by using the hybrid-based Convolutional neural networks(CNN) method in OCT images.

Keywords: Artificial Intelligence, Machine Learning, Deep Learning, Convolutional neural networks, Retinal diseases, Optical Coherence Tomography

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Gözün Anatomik Yapısı	4
Şekil 4.1. Yayap Zeka ve Alt Dalları(Makine Öğrenimi ve Derin Öğrenme).....	21
Şekil 4.2. Makine Öğrenimi Grupları	21
Şekil 4.3. İki sınıflı bir problemde en uygun hiper düzlem, sınır ve destek vektörleri	22
Şekil 4.4. Karar ağacı örneği.....	23
Şekil 4.5. K-En yakın komşu algoritması örneği	23
Şekil 4.6. Tek ve çok gizli katmanlı sinir ağı yapısı	25
Şekil 4.7. RNN'nin şematik yapısı.....	26
Şekil 4.8. LSTM'nin şematik yapısı.	27
Şekil 4.9. RBM'nin yapısı.....	28
Şekil 4.10. Yığılmış kısıtlı Boltzmann makineleri (RBM) tarafından oluşturulan derin inanç ağı (DBN) mimarisi	29
Şekil 4.11. AE(Autoencoders) yapısı	29
Şekil 4.12. DAE(Deep/Stacked Autoencoder) yapısı.....	30
Şekil 4.13. Örnek CNN yapısı	30
Şekil 4.14. Evrişim İşlemi Örneği	34
Şekil 4.15. Padding Örneği.....	34
Şekil 4.16. Pooling Örneği	35
Şekil 4.17. Tam Bağlı Katman yapısı.....	36
Şekil 4.18. ReLU fonksiyon grafiği.....	37
Şekil 4.19. Sigmoid fonksiyon grafiği.....	37
Şekil 4.20 Tanh fonksiyon grafiği	38
Şekil 4.21. Softmax fonksiyon grafiği.....	38
Şekil 4.22. Dropout Yapısı	39
Şekil 4.23. Alexnet mimarisi	40
Şekil 4.24. Resnet-18 mimarisi	40
Şekil 4.25. Resnet50 blok şeması	41
Şekil 4.26. Resnet101 blok şeması	41
Şekil 4.27. Googlenet mimarisi	42
Şekil 4.28. Squeezenet mimarisi.....	42
Şekil 4.29. Mobilenetv2 mimarisi	43

Şekil 4.30.	Densenet201 blok şeması	43
Şekil 5.1	Önerilen Modelin çalışma şeması	44
Şekil 5.2.	Her bir hastalığa ait OCT görüntüsü	45
Şekil 5.3.	Önerilen hibrit model	46
Şekil 5.4.	Veri arttırmaya örnek bazı görüntüler	46
Şekil 6.1	Karışıklık matrisi.....	49
Şekil 6.2.	Resnet50_Densenet201 + laplacian+SVM karışıklık matrisi ve doğruluk varyansı	52
Şekil 6.3.	Resnet50_Densenet201 + laplacian+K-NN karışıklık matrisi ve doğruluk varyansı	53
Şekil 6.4.	Resnet50_Densenet201 + laplacian+DT karışıklık matrisi ve doğruluk varyansı.....	53
Şekil 6.5.	Resnet50_Densenet201 + fscrm+SVM karışıklık matrisi ve doğruluk varyansı.....	53
Şekil 6.6.	Resnet50_Densenet201 + fscrm+K-NN karışıklık matrisi ve doğruluk varyansı	54
Şekil 6.7.	Resnet50_Densenet201 + fscrm+DT karışıklık matrisi ve doğruluk varyansı.....	54
Şekil 6.8.	Resnet50_Densenet201 + relief+SVM karışıklık matrisi ve doğruluk varyansı	54
Şekil 6.9.	Resnet50_Densenet201 + relief+K-NN karışıklık matrisi ve doğruluk varyansı	55
Şekil 6.10.	Resnet50_Densenet201 + relief+DT karışıklık matrisi ve doğruluk varyansı.....	55

TABLÖLER LİSTESİ

	Sayfa
Tablo 5.1. Veri seti özeti.....	45
Tablo 5.2. CNN Mimarileri Katman, Parametre Sayısı ve Model Derinliği.....	47
Tablo 6.1. Performans metrikleri	50
Tablo 6.2. CNN modelleri performans metrik değerleri	50
Tablo 6.3. Seçilen CNN modellerinden elde edilen özelliklerin sınıflandırıcılara verilerek elde edilen performans metrik değerleri.....	51
Tablo 6.4. Seçilen CNN modellerinden elde edilen özelliklerin birleştirilip sınıflandırıcılara verilerek elde edilen performans metrik değerleri	52
Tablo 6.5. Önerilen modelin performans metrik değerleri.....	55
Tablo 6.6. Önerilen yöntem ve literatür karşılaştırması.....	58

KISALTMALAR LİSTESİ

AE	:Autoencoders
AMD	: Age-related macular degeneration
CNN	: Convolutional neural networks
CNV	: Choroidal neo vascularization
CSC	: Central Seröz koryoretinopati
SSR	: Santral seröz retinopati
DBM	: Deep boltzman machine
DBN	: Deep belief network
DL	: Deep learning
DME	: Diabetic macular edema
DR	: Diyabetik retinopati
DT	: Desicion tree
FN	: False negatif
FP	: False pozitif
K-NN	: K-nearest neighbor
LSTM	: Long short term memory
MH	: Macular hole
OCT	: Optical coherence tomography
ReLU	: Rectified lineer unit
RNN	: Recurrent neural network
RPE	: Retina pigment epiteli
RSLT	: Retina sinir lifi tabakası
TN	: True negatif
TP	: True pozitif
YSA	: Yapay sinir ağıları

1. GİRİŞ

Göz, insanoğlu için en kıymetli duyu organlarından biridir. İnsanın dış dünya ile irtibatını kuran, tabiatı müşahade etmeye yarayan hassas bir organdır. Göz ancak ışığın varlığında görme vazifesini yapabilmektedir. Bu vazifenin gerçekleşebilmesi için birçok yapı beraber çalışmaktadır. Bu yapıların her hangi birinde meydana gelen hasar veya bozulmalar gözde çeşitli rahatsızlıklara sebep olmaktadır. Meydana gelen bu rahatsızlıklar, görme kalitesinde bozulmalara neden olmakta veya körlükle neticelenmektedir. Bu amaçla, gözde oluşabilecek rahatsızlıklar insanın hayatında ciddi olumsuzluklara sebep olabilmektedir.

Gözün görme vazifesinde en etkili ve hassas olan kısımlarından biri retinadır. Retina insan gözünün arka duvarını kaplayan ve yapısında görme hücrelerinden oluşan ağ tabakasıdır. Bu tabaka, gözün sahip olduğu en karmaşık ve hassas noktasıdır. Retinada merkezi görmeyi sağlayan ışığın odaklandığı ve ışığa duyarlı reseptörleri(fotoreseptör) içeren bir bölge mevcut olup bu bölgeye makula denilmektedir. Makula denilen bu bölgede oluşan bozulmalar, görme fonksiyonunu etkilemektedir. Makula bölgesinde yaştan ilerlemesi ile bağlantılı başlayan pigment bozuklukları, Bruch membranının kalınlaşması ve bazal laminar birikinti oluşumu ile görme kayıpları başlamaktadır [1]. Yaşa bağlı makula bölgesinde başlayan bu oluşumlar, yaşa bağlı makula dejenerasyonunun meydana geldiğinin habercisidir. Yaşa bağlı makula dejenerasyonu kısa adıyla AMD olarak bilinen bu hastalık, körlüğün başlıca nedeni olarak bilinmektedir. Ülkelerin bir çoğunda yaşlanan nüfusla birlikte %20'den fazlası bu rahatsızlığa sahip olabilmektedir [2]. Diyabet hastalığı bulunan insanlarda ekseriyetle nörovasküler yapının bozulması sonucu makula ödemi oluşur. Diyabetik makula ödemi (DME) olarak bilinen bu hastalık, diyabet hastalığı olan insanların yaklaşık olarak %25'i civarında görülebilmektedir [3]. Retinayı etkileyen sistematik hastalıkların en önemlisi diyabettir. Bu nedenle toplumda rastladığımız görme kayıplarının nedeni ilk sırada diyabettir. Diyabet damarlara etki eden bir hastalık olduğundan, gözdeki retinaya zarar vermekte ve bunun neticesinde bazen kalıcı hasarlara yol açmaktadır. Bahsettiğimiz retina hastalıklarının yanı sıra Santral Seröz Retinopati(SSR), Makula Deliği(MH) ve Drusen hastalıkları retina ile ilgili diğer çeşit hastalıklardır. Söz konusu bu hastalıkların zamanında teşhis edilmesi hayati önem taşımaktadır. Tıp ilminin oftalmoloji kısmında bu hastalıkları teşhis ve tespit etmenin birkaç yöntemi mevcuttur. Bu yöntemlerden biri optik coherans tomografi(OCT) yöntemidir. Optik koherans tomografi, gelişmiş dünyamızda oftalmoloji kliniklerinde en yaygın kullanılan tıbbi görüntüleme tekniklerinden birisidir [4]. Bu görüntüleme tekniği, retinanın çapraz kesitli olarak 3D ve çözünürlüğü yüksek görüntüler elde ederek yapısı hakkında bilgi vermektedir. OCT, retinayı ve optik sinir başını etkileyen makula dejenerasyonu ve makula ödemi gibi çeşitli patolojilerin erken teşhisi için çok önemli olan retina yapılarının kesitsel olarak görüntülenmesinde kullanılmaktadır

[5]. Optik coherens tomografi (OCT), klinik oftalmolojide büyük önem taşıyan non-invaziv bir görüntüleme yöntemidir. Uzmanlar retinanın her ayrıntısını detaylı bir şekilde OCT görüntülerinden bakarak incelerler. Çünkü muhtelif yerlerde bahsedildiği üzere retina yapısında oluşan ufak bir hasar gözde görme fonksiyonlarına zarar verebilir. Bu nedenle söz konusu uzmanların bu görüntüleri kapsamlı bir tarzda incelemesi manuel ve uzun bir süreç olması itibari ile zaman alıcıdır. Ancak retina hastalıklarında tanı ve teşhis öncelik olmalıdır. Erken teşhis edilebilen bir retina rahatsızlığı tedavisi ile beraber gözün görme fonksiyonlarına zarar gelmeden kurtarılabilir. Retina hastalıklarına yakalanan insan sayısı çeşitli faktörlere binaen günden güne artmakla beraber doktorlara binen yük de buna paralel olarak artmaktadır. Bu sebeple hem söz konusu hastalıkların erken teşhis edilmesi hem de doktorlara yüklenmiş olan iş yükünün azaltılması noktasında uzmanlara yardımcı karar destek sistemlerini geliştirmek mühim bir vazifedir.

Günümüz dünyasında teknolojinin gelişmesi ile yapay zekanın kullanımı ziyadeleşmiştir. Yapay zeka hayatımızın ayrılmaz bir parçası haline gelmiş durumdadır. Yapay zekanın amacı, insan benzeri öğrenme ve akıl yürütme yeteneğine sahip sistemleri veya makinaları oluşturmaktır. Makine öğrenmesi dallarından biri olan derin öğrenme ve bunların içinde hususan evrimsel sinir ağının(CNN) görüntü sınıflandırma üstündeki yüksek performansı, görüntü tabanlı birçok uygulama alanında çığır açmıştır[6]. CNN'ler, yüksek boyutta kapasiteye sahip görüntü ve özellik vektörleri içeren datalarda, özellikle görüntü ve konuşma tanımda yüksek seviyede başarılar elde etmiştir[7]. Evrimsel sinir ağlar, birçok alanda olduğu gibi tıbbi görüntü analizi amacıyla aktif olarak kullanılmaktadır. Derin öğrenmenin kullanıldığı tıbbi alanlardan biri de oftalmolojidir. Oftalmolojide derin öğrenmeye dayanan yöntemler fundus görsellerine ve optik koherans tomografisine uygulanmıştır. Bu yöntemler diyabetik retinopati, prematüre retinopatisi, glaukom benzeri disk, makula ödemi ve yaşa bağlı makula dejenerasyonun saptanmasında önemli sınıflandırma performansı göstermişlerdir[8]. Diğer tıbbi alanlarda olduğu gibi oftalmolojide de kullanılan bu metotlar ve neticesinde elde edilen başarılar karar destek sistemlerine olan ihtiyacı arttırmıştır. Birçok retina hastalığının tespit edilebileceği OCT görüntülerinde, bu vazifede çalışan uzmanların iş yükünü hafifletmek, tanıya yardımcı olmak ve zamandan tasarruf etmek noktasında yardımcı olacak karar destek sistemleri vazgeçilmez duruma gelmiştir.


Bu tez çalışmasında, Yaşa Bağlı Makula Dejenerasyonu (AMD), Diyabetik Retinopati (DR), Santral Seröz Retinopati (SSR), Makula Deliği (MH) ve Drusen gibi retina hastalıkları OCT görüntüleri kullanılarak hibrit tabanlı derin öğrenme mimarilerinden biri olan evrimsel sinir ağları(CNN) algoritmaları ile tespit edilmesi gerçekleştirilmiştir.

Bu tezin ikinci bölümünde gözün yapısı ve retina hastalıkları ile ilgili bilgi verilmektedir. Üçüncü bölümünde literatür taraması, dördüncü bölümünde yapay zekâ, makine öğrenimi ve derin öğrenme hakkında bilgi verilmektedir. Beşinci bölümde materyal ve metod, altıncı bölümde uygulamanın yapılması ve değerlendirilmesi hakkında bilgi verilmiştir. Yedinci bölümde yapılan uygulamanın sonuçları tartışılmıştır.



2. GÖZÜN YAPISI VE RETİNA HASTALIKLARI

Göz, kendisine gelen ışık enerjisini elektro-kimyasal enerjiye çeviren bir organdır [9]. İnsanın dış dünya ile irtibatını kuran en önemli duyu organlarından biridir.



Şekil 2.1. Gözün Anatomik Yapısı

Şekilde 2.1 de gözün anatomik yapısı gösterilmiştir. Görüldüğü üzere gözün dış duvarı iç kısma doğru üç katmandan oluşmaktadır. Bunlar aşağıdaki gibidir:

- Kornea(Saydam Tabaka): Kornea gözümüzün en ön kısmındaki saydam tabakadır. Göze gelen ışığın kırılmaya uğradığı ilk tabaka korneadır [9].
- Damar Tabaka(Koroid): Damarsal ağ tabaka skleranın iç kısmında bulunur. Adından da anlaşılacağı gibi tamamen damarlardan oluşmuş bir tabakadır. Damarsal ağ tabaka iç kısımda bulunan retinanın kanlanması ve beslenmesinden sorumludur. Bu tabaka insan vücudunda birim alan başına en fazla kanlanması olan tabakadır. Bu kadar fazla kanlanma iç tabakadaki retinanın gün boyu süren faaliyetleri için gerekmektedir [9].
- Retina(Ağ Tabaka): Retina göz duvarının en iç kısmında bulunan ve ışığa duyarlı sinir hücrelerinin bulunduğu tabakadır. Önce korneadan daha sonra ise lensten kırılarak retina üzerine odaklanan ışık retinadaki sinir hücreleri tarafından elektro-kimyasal enerjiye dönüştürülür ve optik sinir (görme siniri) aracılığıyla beyne iletilir [9].

Retinada çeşitli sebeplerden dolayı bazı hastalıklar veya rahatsızlıklar meydana gelmektedir. Bunların bir kısmı zamanında müdahale edilmezse geri döndürülemez bozukluklara sebep olmaktadır. Retinada meydana gelen bazı hastalıklar; yaşa bağlı makula dejenerasyonu(AMD), diyabetik retinopati(DR), santral seröz retinopati(SSR), makula deliği(MH) ve drusen olarak sıralanabilir.

2.1. Yaşa Bağlı Makula Dejenerasyonu (AMD)

Yaşa bağlı makula dejenerasyonu ilk olarak 1885 yılında Otto Haab tarafından 50 yaş üstü hastalarda ilerleyici retina pigment epitelyal ve makula atrofik dejenerasyonları ile merkezi görme keskinliğini azaltan bir hastalık olarak tanımlanmıştır [10]. AMD nörodejeneratif bir hastalık olmakla beraber şu anda batı dünyasında en sık görülen körlük nedenlerinden biridir. Hastalığın prevalansı 65-75 yaş grubunda %10, 75 yaşından sonra %25 olarak verilmektedir. AMD çok yönlü ve karmaşık bir durumdur. AMD'nin farklı formları bazı ortak patolojik özellikleri ve nedenleri paylaşırsa da, her form için benzersiz mekanizmalar vardır [10].

2.2. Diyabetik Retinopati (DR)

Diyabet, pankreasın yeterli miktarda insülin hormonu üretememesi veya insülin hormonunu etkili bir şekilde kullanamamasından dolayı vücuttaki kan şekerinin artmasıyla ortaya çıkan ve yaşam boyu süren metabolik bir hastalıktır [11]. Dünya’ da 2019 yılında diyabetli olan kişi sayısı 463 milyon olarak tahmin edilmekte ve bu sayının 2030 yılında 578 milyona ulaşması beklenmektedir [12]. En yaygın körlük nedenlerinden biri olan diyabetik retinopati, diyabete bağlı olarak retina ağ tabakasında yer alan kan damarlarında meydana gelen hasardır. Diyabetik retinopatinin toplum içerisinde görülme sıklığı, diyabet süresine paralel olarak artmakta ve genel olarak diyabet hastalarının %30’unda görülmektedir [13]. Bu durum diyabet hastalarının görme yetileri için risk oluşturmaktadır.

2.3. Santral Seröz Retinopati (SSR)

Santral Seröz Retinopati, retina tabakasının altında sıvı birikimini ifade eder. Hastalık genelde görme noktasını(fovea) etkileyip merkezi görmeyi bozduğu için santral seröz retinopati olarak isimlendirilmiştir. Retina altındaki sıvının kaynağı koroid dokusu olduğu için hastalığın bir diğer ismi santral seröz koryoretinopatidir [14]. Santral seröz retinopatinin kesin nedeni bilinmemektedir. Hastalığın retinanın dış kısmını besleyen damarları içeren koroid tabakasındaki basınç artışına ikincil retina pigment epitelinde bozulmaya bağlı olduğu düşünülmektedir. Retina pigment epitelindeki bozulma retina altında sıvı birikimine yol açar. Santral seröz retinopati, 20 ile 80 yaş

arası tüm bireylerde görülme ihtimali mevcuttur. Genelde de 30-35 yaş arası erkek bireylerde görülmektedir [14].

2.4. Makula Deliği (MH)

Makula deliği, merkezi görme kaybı ile sonuçlanan fovea merkezindeki tam kat retina doku defektidir [15]. Toplumda görülme sıklığı 100,000 de 8,7 olup kadın erkek oranı 3.3:1 dir [16]. Başka bir şekilde ifade edilecek olursa; makula deliği, yaşlanmanın doğal bir süreci olarak vitreus yapısının bozularak makuladan ayrılması sırasında oluşur. Retina yüzeyinde kalan vitreus kalıntısı kasılıp büzüşerek makula ve foveayı dışa doğru çeker. Bunun sonucunda delik tarzı doku kaybı oluşur. Makula deliği daha seyrek olarak göz travması, yüksek miyopi, göz içi iltihaplanması, retina dekolmanı ve diğer göz hastalıklarına da bağlı gelişebilir [14].

2.5. Drusen

Klasik olarak retina pigment epiteli (RPE) altında anormal ekstraselüler madde birikimlerine drusen adı verilmektedir [17]. Drusen gelişimi normal yaşlanma sürecinin doğal bir sonucu olabileceği gibi, önemli bir retina hastalığının bulgusu da olabilir [18]. Bu ayrımın yapılabilmesi ise drusen özelliklerinin dikkatli bir şekilde değerlendirilmesine bağlıdır. Yaşın ilerlemesine bağlı olarak biyokimyasal süreçler, değişikliğe uğramış genetik veya çevresel faktörler drusen oluşumuna ve hastalık gelişimine neden olmaktadır.

3. LİTERATÜR TARAMASI

Günümüzde yaklaşık her alanda olduğu gibi tıp alanında da yapay zekâ ve bunun alt dalı olan makine öğrenimi kullanımı her geçen gün artmaktadır. Teknolojinin hızlı bir şekilde yayıldığı bu asırda tıp ilmi ve teknolojiden sıkça istifade eden ve tıbbın bir alt alanı olan Oftalmoloji, makine öğrenimi alt dallarından biri olan derin öğrenmenin çokça istimal edildiği ve gittikçe kullanımının arttığı bir alan haline gelmiştir. Derin öğrenme yöntemleri ile tıbbi görüntüler sınıflandırılabilir, segmantasyon vb. yapılabilir. Optik koherens tomografi görüntüleri kullanılarak derin öğrenme mimarileri ile çeşitli retinal hastalıkları sınıflandırma işlemleri yapılmış olup yüksek doğruluk oranlarına ulaşılmıştır.

Bilgisayar teknolojisi ve OCT görüntülemedeki ilerlemelerin kombinasyonu, bu hastalıkları teşhis edebilen ve doktora yardımcı olabilecek tanı destek sistemleri birçok araştırmacı tarafından gerçekleştirilmiştir [17, 18, 19].

García-Floriano Andrés ve ark. Dijital Görüntü İşleme, Matematiksel Morfoloji ve SVM modelini kullanan bir yöntem kullanmışlardır. Kapalı maküler bölge, bir kontrast geliştirme yöntemine tabi tutulur, ardından temel morfolojik işlemler uygulanır. İşlenen görüntünün özellikleri olarak uzamsal moment kullanmışlardır. Elde edilen vektör, bir SVM tarafından drusen için pozitif veya negatif olarak sınıflandırılmıştır. Drusen hastalığını %92.15 doğrulukla tespit etmişler [20].

Sugmk Jathurong ve ark. Retina pigment epiteli (RPE) katmanını bulmak ve RPE katmanında bir drusen şeklini saptamak, optik koherens tomografiyi (OCT) bölmek için bir görüntü bölütleme adımı önermişlerdir. Daha sonra, RPE tabakası, retina sinir lifi tabakasını (RSLT) bulmak ve RSLT kompleksinde bir kan baloncuğu tespit etmek için kullanılır. Son olarak, bu yöntem, AMD ve DME arasındaki karakteristik iki hastalığı sınıflandırmak için ikili bir sınıflandırma kullanır. İki hastalığı bölümlere ayırmak ve sınıflandırmak için 16 OCT görüntüsü kullanmışlardır. Deneysel sonuçlarda, AMD'nin 10 görüntüsü ve DME'nin 6 görüntüsü tespit edilebilir ve %87.5 doğrulukla sınıflandırılabilir olduğunu tespit etmişler [21].

Acharya U. Rajendra ve ark. DME'nin otomatik tespiti için 4 alt sistemli bir hibrit model önerdi. Bu sistemler Radon dönüşümü, ayırık dalgacık dönüşümü, ayırık kosinüs dönüşümü ve sınıflandırıcıdır. MESSIDOR veritabanları için iki ve yedi önemli özellik kullanılarak %97'nin üzerinde sınıflandırma performansı elde edilmiştir [22].

Thomas Anju ve ark. Retinal Pigment Epitel (RPE) katmanını ve retinal spektral alan OCT (SD-OCT) görüntülerinden taban çizgisini çıkarmak ve RPE katmanındaki drusen yüksekliğini bulmak için bir yöntem önerdi. Drusen yüksekliği elde edildi ve OCT görüntüsü AMD veya normal olarak sınıflandırıldı. Sınıflandırma doğruluğu %96.66 olarak belirlenmiştir [23].

Das Vineeta ve ark. Maküler patolojileri sınıflandırmak ve güvenilir bir tanı koymak için bir CNN kullanan çok ölçekli derin özellik füzyonu tabanlı bir yaklaşım önerdi. Görüntülerdeki ölçekler arası varyasyonları yakalamak ve sınıflandırıcıya ayırt edici ve tamamlayıcı bilgiler sağlamak için kullanıldı. Önerilen yöntem, farklı sınıf dağılımlarına sahip 84.484 görüntü içeren bir OCT veri seti üzerinde değerlendirilmiştir. Sınıflandırıcının öğrenmesi sırasında maliyete duyarlı kayıp fonksiyonu eklenerek veri setindeki dengesizlik giderilmiştir. Sınıflandırma sonucunda test setinde sırasıyla ortalama %99.6, %99.87 ve %99.6 duyarlılık, özgüllük ve doğruluk elde edilmiştir [24].

Feng Shuanglang ve ark. VceptionC3D olarak adlandırılan 3B retinal OCT görüntülerini sınıflandıran verimli ve çok sınıflı bir ağ modeli önerdi. VceptionC3D, gelişmiş 3D başlangıç modülleri eklenerek temel C3D'den geliştirilmiş bir 3D CNN'dir. Önerilen yöntem 6 sınıflı 873 3B OCT görüntüsü üzerinde eğitilmiş ve test edilmiştir. Rastgele başlangıç ağırlıklarıyla C3D'nin, önceden eğitilmiş ağırlıklarla C3D'nin ve önceden eğitilmiş ağırlıklarla önerilen VceptionC3D'nin ortalama doğruluğu sırasıyla %89.35, %92.09 ve %94.04'tür [25].

Perdomo Oscar ve ark. Retina hastalıklarını sınıflandırmak için yeni bir derin öğrenme modeli olan OCT-NET'i sundu. Bu model ile SERI-CUHK ve A2A SD-OCT veri setlerinde belirtilen sağlıklı, diyabetik retinopati, diyabetik makula ödemi ve yaşa bağlı makula dejenerasyonu OCT görüntüleri %93 doğrulukla sınıflandırılmıştır [26].

Lee Cecilia S. ve ark. Maküler OCT görüntülerine göre normal ve AMD arasında ayırım yapmak için derin öğrenme tabanlı bir model önerdi. VGG16 CNN modeli modifiye edilerek geliştirilen model 21 katmana sahiptir. Hastalık ayırımı %87.63 doğruluk ve 92.77 AUC değeri ile yapılmıştır [27].

Peng Yifan ve ark. Yaşa bağlı göz hastalıklarının seviyesini tespit etmek için renkli fundus görüntülerini kullanan derin öğrenme tabanlı bir CNN mimarisi geliştirdi. Drusen, pigment anormallikleri ve AMD gibi hastalıklarda 0'dan 5'e kadar şiddet derecesine göre sınıflandırıldı. DeepSeeNet 58402 üzerinde veri ile eğitildi ve AREDS'den 4549 katılımcının boylamsal takibinden elde edilen 900 görüntü üzerinde test edildi. drusen, pigment anormallikleri ve AMD için doğruluk sırasıyla 0.742, 0.890 ve 0.967 olarak elde edilmiştir [28].

Perdomo Oscar ve ark. Diyabetik makula ödem hastalığını tespit etmek noktasında OCT hacimlerinin otomatik olarak sınıflandırılması için CNN'ye dayanan bir OCT-NET modeli sunmuşlardır. Model ile %93,75 doğruluk değeri elde edilmiştir [29].

Fang Leyuan ve ark. Retina OCT görüntülerinin otomatik sınıflandırılması için yinelemeli bir füzyon evrişimli sinir ağı yöntemi önerdiler. Evrişimli sinir ağında, farklı evrişim katmanları farklı ölçeklerden özellik bilgilerini içerir. Bu nedenle, önerilen ağ, mevcut evrişim katmanındaki özellikleri CNN ağında önceki tüm katmanların özellikleriyle yinelemeli olarak birleştiren ve böylece OCT görüntülerinin doğru bir şekilde sınıflandırılmasını sağlamak için farklı evrişimli katmanların özelliklerini ortaklaşa kullanabilen yinelemeli bir füzyon stratejisini benimser. Gerçek bir retinal OCT veri seti ve bir kas-iskelet radyografisi veri seti üzerindeki deneysel sonuçlar, önerilen yöntemin geleneksel CNN ve birkaç iyi bilinen OCT sınıflandırma yöntemine göre üstünlüğünü göstermiştir. Model %87,3 doğruluk sağlamıştır [30].

Motozawa Naohiro ve ark. Yaptıkları çalışmada, AMD'yi sağlıklı OCT taramalarından ayırt edebilecek derin öğrenme modelleri oluşturmayı ve bir segmentasyon algoritması kullanmadan AMD'yi eksüdatif değişikliklerle ve eksüdatif değişiklikler olmadan ayırt etmeyi amaçladı. AMD'li hastaların ve sağlıklı bir kontrol grubunun toplam 1621 spektral alan (SD)-OCT görüntüsü incelenmiştir. İlk CNN modeli, 1382 AMD görüntüsü ve 239 normal görüntü kullanılarak eğitildi ve doğrulandı. İkinci transfer-öğrenme modeli, eksüda değişiklikleri içeren 721 AMD görüntüsü ve herhangi bir eksüda içermeyen 661 AMD görüntüsü ile eğitildi ve doğrulandı. CNN'nin ilgi alanı, sınıf aktivasyon haritasına göre bir ısı haritası olarak tanımlandı. Görüntüleri eksüdatif değişiklikler olan veya olmayan AMD olarak sınıflandıran ikinci modelde, transfer öğrenmeyi kullanan ve kullanmayan modellerin öğrenme stabilizasyonu karşılaştırıldı. Elde edilen veriler; İlk CNN modeli kullanılarak, AMD ve normal OCT görüntülerini %100 duyarlılık, %91.8 özgüllük ve %99.0 doğrulukla sınıflandırabilmişler. İkinci transfer-öğrenme modelinde, AMD'yi %98,4 duyarlılık, %88,3 özgüllük ve %93.9 doğrulukla eksüdatif değişikliklere sahip veya yok olarak sınıflandırmışlar. Bunun neticesinde ikinci modele transfer-öğrenme modelinin dahil edilmesi, transfer-öğrenme modelinin dahil edilmediği zamana göre daha hızlı stabilizasyon sağlamıştır [31].

Li Feng ve ark. Optik koherens tomografi görüntülerinde koroid neovaskülarizasyonu (CNV), diyabetik maküler ödem (DME), DRUSEN ve NORMAL'i otomatik olarak tespit etmek için 4 sınıflı bir sınıflandırma problemine odaklanmıştır. Önerilen sınıflandırma algoritması, her biri geliştirilmiş artık sinir ağına (ResNet50) dayanan retinal OCT görüntülerini tanımlamak için dört sınıflandırma modeli örneğinden oluşan bir topluluk benimsemiştir. Deney, retina OCT görüntü veri setinin geliştirilmesinde hasta düzeyinde 10 kat çapraz doğrulama sürecini izledi. Önerilen

yaklaşım, B-taramada 0.973 (%95 güven aralığı [CI], 0.971-0.975) sınıflandırma doğruluğu, 0.963 (%95 GA, 0.960-0.966) duyarlılık ve 0.985 (%95 GA, 0.983-0.987) özgüllük elde ettiler [32].

Zhang Quan ve ark. Kendini geliştirme yeteneği ve klinik triyaj hastalarının yeteneği ile daha sezgisel ve sağlam bir teşhis modeli önermişlerdir. Modeli oluşturmak ve değerlendirmek için 38.057 OCT görüntüsü (Drusen, DME, CNV ve Normal) kullanılmıştır. Tüm veriler fundus retinanın OCT görüntüleridir. Eğitim veri setinde 37.457 örnek ve doğrulama veri setinde 600 örnek bulunmaktadır. Bu görüntüleri doğru bir şekilde teşhis etmek için çok ölçekli bir transfer öğrenme algoritması önerdiler. İlk olarak, numune, kenar algılama ve iyileştirme için otomatik kendini geliştirme modülüne gönderilir. Daha sonra işlenen veriler görüntü tanı modülüne gönderilerek hastalık tipi belirlenir. Bu süreç, daha fazla veriyi daha etkili hale getirir ve doğru bir şekilde sınıflandırabilir. Model, bağımsız test veri setinde %94,5 doğruluk, %97,2 kesinlik, %97,7 duyarlılık ve %97 özgüllüğe ulaştı [33].

Kim Jongwoo ve ark. Hastaların OCT görüntülerini koroidal neovaskülarizasyon (CNV), diyabetik maküler ödem (DME), drusen ve normal gibi dört sınıfta kategorize eden derin öğrenme modelleri önermektedir. İki farklı model önerilmiştir. Biri üç ikili evrişimli sinir ağı (CNN) sınıflandırıcısı, diğeri dört ikili CNN sınıflandırıcısı kullanıyor. VGG16, VGG19, ResNet50, ResNet152 gibi çeşitli CNN'ler, DenseNet121 ve InceptionV3, ikili sınıflandırıcıları geliştirmek için özellik çıkarıcılar olarak uyarlanmıştır. Bunlar arasında, CNV vs. Diğer sınıflar için VGG16, DME vs. diğer sınıflar için VGG16, Drusen vs. Diğer sınıflar için VGG19 ve Normal vs. diğer sınıflar için InceptionV3 kullanarak önerilen model, 0.987 doğruluk, 0.987 hassasiyet 0.996 özgüllük ile en iyi performansı göstermektedir. Normal sınıf için ikili sınıflandırıcı 0,999 doğruluğa sahip olduğunu göstermişler [34].

Sharma Abhinav ve ark. Diyabetik makula ödemi(DME), koroid neovaskülarizasyonu(CNV) ve drusen olmak üzere üç bozukluğun her birinin varlığını belirleme ve aksi takdirde bunları normal makula olarak sınıflandırma amacıyla bir model geliştirmişler. Erken teşhis edildiğinde tedavi edilebilecek kör edici retina hastalıkları olan hastaları taramak amacıyla derin öğrenmeye dayalı bir tespit sistemi önerildi. Bunu başarmak için evrişimli sinir ağı (CNN) kullanılmaktadır. 0.9938'e varan bir hassasiyetle %99.38'lik bir doğruluk elde edildi. Eğri Altındaki Alan ortalama 1.00 olarak değerlendirildi [35].

You Tae Keun ve ark. Üretken bir çekişmeli ağ kullanan birkaç adımlı öğrenmenin, ender hastalıkların optik koherens tomografi(OCT) teşhisinde derin öğrenmenin uygulanabilirliğinin iyileştirebileceğini gösterdiler. Bu çalışmaya çok sayıda veri içeren dört ana sınıflı bir veri seti ve

az sayıda veri içeren beş ender hastalık sınıfı bir veri seti dahil edilmiştir. Sınıflandırıcıyı eğitmeden önce, normal OCT görüntülerinden her nadir hastalığın patolojik OCT görüntülerini oluşturmak için Üretken çekişmeli ağ modelleri oluşturuldu. Inception-v3 mimarisi, artırılmış bir eğitim veri kümesi kullanılarak eğitildi ve nihai model, bağımsız bir test veri kümesi kullanılarak doğrulandı. Sentetik görüntüler, her söz konusu hastalığın karakteristik özelliklerinin çıkarılmasına yardımcı oldu. Önerilen derin öğrenme modeli, az görülen retina hastalıklarının OCT teşhisinin doğruluğunda önemli bir gelişme gösterdi ve geleneksel derin öğrenme modelleri, Siyam ağı ve prototip ağdan daha iyi performans göstermiş oldu. Oftalmologun santral seröz korioretinopati, maküler delik, maküler telenjiyektazi, retinitis pigmentosa ve Stargardt hastalığı teşhisi için sınıf başına gerçek pozitif oranları sırasıyla 1.00, 1.00, 0.50, 0.25 ve 0.50 iken, önerilen modelde oranlar sırasıyla 1.00, 1.00, 1.00, 0.75 ve 0.75. olarak hesaplanmıştır [36].

Haq Arinal ve ark. Yaptıkları çalışmada toplu normalleştirme ile evrimsel sinir ağı kullanarak OCT görüntülerini dört koşulda (koroid neovaskülarizasyonu, diyabetik maküler ödem, drusen ve normal durum) tespit etmek için otomatik algılama sistemi önerdiler. Sınıflandırma katmanı için önerilen CNN modeli, ResNet, Inception ve ResNeXt dahil olmak üzere ImageNet veri kümesi kullanılarak görüntü sınıflandırma ve nesne algılamada en son teknolojiye sahip birkaç CNN mimarisinde transfer öğrenimi kullanılarak geliştirilmiştir. Model geliştirme, sınıflandırma katmanında değişiklik gibi çeşitli yaklaşımlar kullanılarak gerçekleştirilir. Her modelin performansı, en iyi performansa sahip en iyi modeli elde etmek için değerlendirilir. Model değerlendirmesinden en iyi model, InceptionV3 mimarisine sahip sınıflandırma katmanında toplu normalleştirme kullanan ve %99.793 doğruluk, %99.794 duyarlılık ve %99.931 özgüllük elde edebilen değiştirilmiş bir model olan inceptionv3_bn'dir. Elde edilen iyi performans, geliştirilen CNN modelinin OCT görüntülerini dört koşulda tespit etmek için kullanılabileceğini göstermektedir [37].

Luo Yuemei ve ark. Optik koherens tomografi görüntüleri ile retinopatinin tespiti için önceden eğitilmiş VGG-16 ve sanal çekişmeli eğitim üzerine kurulmuş yarı denetimli bir derin öğrenme yöntemi önermişler. Model eğitimi için yalnızca çok az etiketli ve çok sayıda etiketlenmemiş OCT görüntüsü kullanılmıştır. Deneylerde önerilen yöntemi iki popüler veri kümesi üzerinde değerlendirdiler. Önerilen yöntem, yalnızca 80 etiketli OCT görüntüsü ile sınıflandırma doğruluklarına 0,942 ve 0,936, duyarlılıkları 0,942 ve 0,936 olarak ölçülmekle beraber iki veri setinde sırasıyla özgüllükleri 0,971 ve 0,979 ve AUC'leri de (ROC Eğrileri altındaki Alan) 0,997 ve 0,993 olarak hesaplamışlar. Ayrıca, tahminlerde bulunurken önerilen yöntemin odaklandığı kilit bölgeleri görselleştirmek için gradient class activation map (Grad-CAM) yöntemini de

kullanmışlar. Önerilen yöntemin, retinopatiyi tahmin ederken giriş OCT görüntülerinin temel modellerini doğru bir şekilde tanıyabildiğini göstermektedir [38].

Arefin Raisul ve ark. Retinal optik koherens tomografi görüntülerini kullanarak dört maküler hastalık tipini sınıflandırmak için yapılandırılabilir bir derin evrişimli sinir ağı (CNN) geliştirdiler. Önerilen aktarımsız derin CNN modeli (acc: %97,9), ResNet-50 (acc: %89,0), ResNet-101 (acc: %96,7), VGG-19 (acc: %93,3) gibi mevcut transfer öğrenme modellerinden daha iyi performans gösterir. Inception-V3 aynı retinal OCT görüntü sınıflandırma görevinde (acc: %95.8)'lik bir oran vermektedir. Modelden çıkarılan görüntü özelliklerinin post-hoc analizleri, son evrişim katmanında 256 CNN filtre çekirdeğinden sadece sekizinin aktif olduğunu ortaya koymaktadır. Bu sekiz seçici filtrenin kıvrımlı yanıtları, iki boyutlu ana bileşen alanına yansıtıldığında bile dört maküler hastalık sınıfını verimli bir şekilde ayıran görüntü özelliklerini vermektedir [39].

Han J ve ark. Spektral alan optik koherens tomografi (SD-OCT) görüntülerini kullanarak nAMD'nin alt türlerini ayırt etmek için bir derin öğrenme modeli önerdiler. nAMD'nin (polipoidal koroidal vaskülopati, retinal anjiyomatöz proliferasyon ve tipik nAMD) SD-OCT görüntülerinden ve normal sağlıklı hastalardan elde edilen veriler, bir konvolüsyonel sinir ağı kullanılarak analiz edildi. Model, 347 hasta ve 50 sağlıklı kontrolden alınan 4749 SD-OCT görüntüsüne dayalı olarak eğitilmiş ve doğrulanmıştır. Doğru ve sağlam bir görüntü sınıflandırma mimarisini benimsemek için, iyi bilinen üç CNN yapısını (VGG-16, VGG-19 ve ResNet) ve iki özelleştirilmiş sınıflandırma katmanını (düşüklü tam bağlantılı katmana karşı küresel ortalama havuzlama) kullandılar. Test seti performansının ardından, sınıflandırma doğruluğu en yüksek olan model kullanılmıştır. Modelin sağlamlığını ve doğruluğunu artırmak için transfer öğrenme ve veri büyütme uygulandı. Önerilen model, aynı veriler için on oftalmologdan daha yüksek puan alarak test verilerinde (920 görüntü) %87.4 doğruluk gösterdi. Ayrıca model, sınıflandırmada önemli bulduğu kısmı Grad-CAM görüntüleri ile doğrulamış ve sonuç olarak göz doktorları ile benzer değerlendirme kriterlerine sahiptir [40].

Yoon Jeewoo ve ark. Bir konvolüsyonel sinir ağı (CNN) kullanarak CSC alt tiplerini ayırt etmek için bir derin öğrenme sistemi modeli oluşturmayı amaçlamıştır. Ocak 2015 ile Ocak 2020 arasında tek bir üçüncü basamak merkezden CSC'li 435 hastayı kaydettiler. Hastaların spektral alan OCT (SD-OCT) görüntülerinden elde edilen veriler, derin bir CNN kullanılarak analiz edildi. Modelin akut, çözülme, aktif olmayan ve kronik atrofik CSC'yi ayırt etme yeteneğini değerlendirmek için beş katlı çapraz doğrulama kullanıldı. Önerilen model Resnet-50, Inception-V3 ve sekiz oftalmologun performansları karşılaştırıldı. Genel olarak, 3209 SD-OCT görüntüsü dahil

edildi. Önerilen model, %70.0'lık bir ortalama çapraz doğrulama doğruluğu gösterdi (%95 güven aralığı [CI], 0.676-0.718) ve en yüksek test doğruluğu %73.5 idi. 104 hastadan oluşan bağımsız bir grupta ek değerlendirme, önerilen modelin güvenilir performansını gösterdi (doğruluk: %76.8) [41].

Upadhyay Pawan Kumar ve ark. Retina hastalıklarının dört sınıflı sınıflandırması için OCT görüntülerinde neovaskülarizasyon (CNV), diyabetik makula ödemi (DME), DRUSEN ve NORMAL sınıf etiketini tespit edebilen tutarlı bir konvolüsyonel sinir ağı önermişler. Çalışmalarında üç zorluğun üstesinden gelmektedirler. Bunlar; her bir retina hastalığı sınıfının düzensiz kalıplarını daha derinden tespit etmek, ağın girdi ve çıktısı arasındaki tutarlılığı yönetmek ve görüntü özelliklerinin kolay akışı için ağı katmanlarını uyumlu bir şekilde bağladı. Önerilen evrişim sinir ağı modeli beş katmana sahiptir. Tutarlı davranışı benimsemek için, her aktivite katmanı ile birlikte toplu normalleştirme katmanını aşıl原因an önerilen model, retina hastalığı tespiti için %97.19'luk bir doğruluk elde etti [42].

Ko Junseo ve ark. Santral seröz korioretinopati(CSC)'yi teşhis etmek için çoklu spektral alan optik koherens tomografi (SD-OCT) görüntülerini birlikte kullanarak derin öğrenme tabanlı bir sınıflandırma modeli oluşturmayı amaçladı. Önerilen sistem iki modül içerir: tek görüntü tahmini (SIP) ve bir nihai karar (FD) sınıflandırıcı. 297 katılımcıdan (109 akut CSC, 106 kronik CSC, 82 normal) toplam 7425 SD-OCT görüntü dahil edildi. Beş katlı çapraz doğrulama testinde model ortalama %94,2 doğruluk gösterdi. Diğer uçtan uca modellerle, örneğin bir 3D evrişimli sinir ağı (CNN) modeli ve bir CNN-uzun kısa süreli bellek (CNN-LSTM) modeli ile karşılaştırıldığında, önerilen sistem %10'dan fazla daha yüksek doğruluk gösterdi. Önerilen model ve oftalmologları karşılaştıran deneylerde, model akut, kronik ve normal vakaları ayırt etmede uzmanlardan daha yüksek doğruluk gösterdiğini ispatladılar [43].

Abdullahi Muhammed Muhammed ve ark. Kuru ve ıslak AMD arasında sınıflandıracak bir evrişimsel sinir ağı modeli geliştirmiştir. Kuru ve ıslak AMD'nin 32.931 OCT görüntüsünden oluşan KERMANY veri setini kullanarak modeli eğitmek için 50 katmanlı önceden eğitilmiş ResNet50 kullanıldı. Model değerlendirilmiş ve sırasıyla %96.56 doğruluk, %98.20 Özgüllük ve %89.45 duyarlılıkla gerçekleştirilmiştir [44].

Chen Yiwei ve ark. RepVGG yapay sinir ağına dayalı optik koherens tomografi hacimlerinin otomatik sınıflandırılması için bir algoritma önermişler. Algoritma, optik koherens tomografi hacimlerinden yaşa bağlı kuru maküler dejenerasyon ve diyabetik maküler ödemin tespiti için tasarlanmıştır. RepVGG, optik koherens tomografi hacimlerini sınıflandırmak için kullandıkları

basit ama güçlü bir evrimsel sinir ağıdır. Kuru yaşa bağlı makula dejenerasyonu, diyabetik makula ödemi ve normal numunelerden elde edilen optik koherens tomografi hacimleri sınıflandırılabilir. Önerilen algoritmanın etkinliğini 45 denekten (15 sağlıklı denek, kuru yaşa bağlı makula dejenerasyonu olan 15 hasta ve diyabetik makula ödemi olan 15 hastadan) toplanan bir optik koherens tomografi veri seti üzerinde deneysel olarak değerlendirildi. Önerilen algoritma, kuru yaşa bağlı makula dejenerasyonu olan hastaların %73,3'ünü, diyabetik makula ödemi olan hastaların %93,3'ünü ve normal kişilerin %86,7'sini doğru bir şekilde sınıflandırmıştır [45].

Alqudah Amin ve ark. Yaptıkları çalışmada OCT görüntülerinden, özellikle spektral alan (SD-OCT) görüntülerinden advanced OCT network (AOCTNet) CNN mimarisi kullanılarak çıkarılan otomatik derin öznetelikler kullanılarak göz retina hastalıklarının çok sınıflı sınıflandırması için hibrit bir yapay zekâ sistemi önerilmiştir. Önerilen metodoloji esas olarak retina hastalıklarını normal ve dört anormal sınıfa (AMD, CNV, DME ve Drusen) retina hastalığı olarak sınıflandırmak için kullanılmıştır. Önerilen sistem, sekiz tür makine öğrenme algoritması (linear çekirdekli destek vektör makinesi, radyal temel fonksiyonlu çekirdekli destek vektör makinesi, yapay sinir ağı, k en yakın komşu, random forest, lineer discriminant analysis, quadratic discriminant analysis ve naive bayes). Sınıflandırıcılar yüksek performans elde ettiler. Örneğin, KNN ve random forest sınıflandırıcıları sırasıyla 99.44 ve 99.12 doğruluk elde etmiştir [46].

Saleh Neven ve ark. Yaptıkları çalışmada, optik coherens tomografi (OCT) görüntüleri kullanılarak hastaları koroid neovaskülarizasyonu, diyabetik makula ödemi, drusen ve normal olarak sınıflandırmayı amaçlamaktadır. İlk kez, retina bozukluğu sınıflandırması için iki yeni transfer öğrenme tabanlı teknik kullanıldı: SqueezeNet ve InceptionV3Net. Orijinal SqueezeNet ile geliştirilmiş olanın performansını karşılaştırmak için iki SqueezeNet senaryosu kullanıldı. SqueezeNet'in veri bölümlenmesi için 11200 OCT görüntüsünden oluşan bir veri seti ve bu arada InceptionV3Net için 18000 görüntü kullanıldı. Değiştirilmiş SqueezeNet, orijinaline göre %1.2'lik bir iyileştirme ile %98 doğruluk elde etti. InceptionV3Net sınıflandırıcı, sınıflandırma doğruluğunu %98,4'e yükseltti [47].

Luo Yuemei ve ark. etiketli bir veri kümesinde bir modeli eğitmek ve onu etiketlenmemiş bir veri kümesine (farklı koşullar altında toplanan) uyarlamak için yeni bir derin alan uyarlaması yöntemi önerdiler. Etki alanı hizalaması için iki modülden oluşur, yani çekişmeli öğrenme ve entropi minimizasyonu. Önerilen yöntemin performansını değerlendirmek için üç genel veri kümesi üzerinde kapsamlı deneyler yapıldı. Sonuçlar, veri kümeleri arasında büyük alan kaymaları olduğunu ve bunun geleneksel derin öğrenme yöntemleri için düşük bir performansla sonuçlandığını gösterdiler. Önerilen derin alan yöntemi, OCT görüntüleri ile retinopati

sınıflandırması için mevcut yöntemlerden önemli ölçüde daha iyi performans gösterdiler. Üç etki alanı arası (veri kümeleri arası) senaryolar altında 0,915, 0,959 ve 0,990 retinopati sınıflandırma doğruluğuna ulaşıldı. Ayrıca, önerilen yöntemi eğitmek için bu veri kümesindeki hiçbir etiketli verinin kullanılmadığı bir veri kümesinde insan uzmanlarla karşılaştırılabilir bir performans elde etti. Ayrıca öğrenilen özellikleri t-dağıtılmış stokastik komşu gömme tekniğini kullanarak görselleştirdiler. Sonuçlar, önerilen yöntemin retinopati sınıflandırması için ayırt edici özellikleri öğrenebileceğini göstermiş oldular [48].

Cheung Carol Yim-lui ve ark. DME'yi sınıflandırmak ve DME dışındaki retina anormallikleri için aynı anda piyasada bulunan üç yaygın optik koherens tomografi (OCT) cihazından görüntüleri kullanarak bir derin öğrenme sistemi geliştirmekle beraber test edilip doğrulandı. Çok fonksiyonlu bir ağı, biri üç boyutlu(3B) ResNet-34'ü temel alan ve diğeri iki boyutlu(2B) ResNet-18'i temel alan iki sürümünü, DME'yi (merkezle ilgili DME [CI - DME] CI-DME olmayan veya DME'nin yokluğu) ve diğer retina anormallikleri (varlığı veya yokluğu) sırasıyla 3B hacim taramaları ve 2B taramaları kullanılarak sınıflandırmak için eğitildi ve doğrulandı. DME'li 1.238 denekten 2.444 gözü temsil eden toplam 73.746 OCT görüntüsü, eğitim ve birincil doğrulama için kullanıldı. Bu görüntüler, Cirrus OCT'den 3.788 3D hacim taramasını, Spectralis OCT'den 30.515 2D B-taramasını ve Triton OCT'den 39.443 2B-taramasını içerir. Cirrus OCT'den 3.218 hacim taraması, Spectralis OCT'den 18.295 B taraması ve Triton OCT'den 5.468 B taraması kullanılarak farklı klinik ayarlar altında yedi bağımsız veri kümesinde harici testler yapıldı. DME'nin varlığını veya yokluğunu sınıflandırırken, derin öğrenme sistemi 0.937 (%95 CI 0.920-0.954), 0.958 (0.930-0.977), ve harici veri kümeleri için 0.906'dan büyük AUROC'lere ek olarak sırasıyla Cirrus, Spectralis ve Triton OCT'lerinden elde edilen birincil veri kümeleri için 0.965 (0.948-0.977) olarak elde edildi. CI-DME ve CI-DME olmayan alt grupların daha ileri sınıflandırması için, AUROC'ler birincil veri kümeleri için 0.968 (0.940-0.995), 0.951 (0.898-0.982) ve 0.975 (0.947-0.991) idi ve harici veri kümeleri için 0.894'ten büyüktü. Diğer retinal anormalliklerin varlığının veya yokluğunun sınıflandırılmasında, AUROC'ler sırasıyla Cirrus, Spectralis ve Triton OCT'lerinden elde edilen görüntüler arasında 0.948 (0.930-0.963) 0.949 (0.901-0.996) ve 0.938 (0.915-0.960) idi. AUROC aralıkları 0.901-0.969 olmak üzere harici veri kümelerindeki performans mükemmel kaldı [49].

Kim Kyoung Min ve ark. Retina hastalıklarının ayırıcı tanısı için fundus görüntüsüne dayalı bir yapay zeka (derin öğrenme) modeli tasarlamışlar. Retina görüntülerini üç evrişimli sinir ağı modeliyle sınıflandırma işlemi yapılmıştır: ResNet50, VGG19 ve Inceptionv3. Ayrıca, birkaç yoğun (tamamen bağlı) katmanın performansı karşılaştırıldı. 128 düğümlü yoğun bir katman ekleyen ResNet50 modelinde sekiz retina hastalığının (dAMD, nAMD, DR, ERM, RRD, RP, MH

ve RVO) dokuz sınıfının teşhisi ve normal kontrol için tahmin doğruluğu %87,42 idi. Ayrıca, bu yöntemin, göz doktorlarının retina hastalığının teşhisindeki performansını arttıracaklarını düşündüler. Bu sonuçlar, fundus görüntüsüne dayalı derin öğrenme yöntemine retina hastalıklarının tıbbi teşhis süreci için uygulanabilir olduğunu göstermiştir [50].

Mohammed Asif ve ark. Yaptıkları çalışmada, CNN algoritması, OCT retina görüntülerinin veri kümesini dört türde etiketledi: CNV, DME, DRUSEN ve Doğal Retina. Bunları sinir ağına aktarmadan önce görüntüler üzerinde birkaç ön işleme de gerçekleştirmişler. Bireysel modellerin farklı gizli katmanlara sahip olduğu algoritma için farklı modeller uygulandı. Yapılan araştırma neticesinde söz konusu CNN algoritmasının %93 doğruluk ürettiğini buldular [51].

Yan Yan ve ark. AMD'yi otomatik olarak teşhis etmek için bir dikkat mekanizmasının yardımıyla OCT görüntülerine dayalı bir derin öğrenme sistemi geliştirdiler. Derin öğrenme modelini geliştirmek için bir eğitim veri seti ve bir klinik doğrulama veri seti olarak bir genel veri seti (toplam 51.140 OCT görüntüsü) ve bir özel veri seti (toplam 4951 OCT görüntüsü) kullanıldı. Her birime entegre edilmiş evrişimli blok dikkat modülü(CBAM) bloğuna sahip bir ResNet-34 DL modeli, önce genel veri setinde önceden eğitildi ve ardından AMD'yi otomatik olarak teşhis etmek ve klinik karar vermeye yardımcı olmak için özel veri setinde ince ayar yapıldı. Modelin yorumlanabilirliğini geliştirmek için bir görselleştirme tekniği olan GradCam kullanıldı. Modelin kesinliği ve geri çağırılması sırasıyla drusen için %84.3 ve %87.3, aktif olmayan CNV için %81.2 ve %80.0, aktif CNV için %97.7 ve %90.2 ve normal için %93.7 ve %96.5 idi. Model için drusen, aktif olmayan CNV, aktif CNV ve normale karşılık gelen eğrinin altındaki alan (AUC) sırasıyla 0.9395, 0.9476, 0.9880 ve 0.9925 olarak tespit edildi [52].

Xu Lianghai ve ark. Yaptıkları çalışmada drusen(DRUSEN), koroid neovaskülarizasyonu(CNV) ve diyabetik makula ödemi(DME) olmak üzere üç çeşit retina hastalığının etiyolojisi ve semptomları anlatılmaktadır. Ayrıca, farklı retinopati görüntülerini sınıflandırmak ve tanımak için hibrit bir dikkat mekanizması da oluşturmuşlar. Özellikle, bu yazıda önerilen hibrit dikkat mekanizması, paralel uzamsal dikkat mekanizması ve kanal dikkat mekanizmasını içermektedir. Retinopati görüntülerinin kanal boyutundaki ve uzamsal boyutundaki temel özellikleri çıkarılabilir ve arka plan bilgisinin sınıflandırma sonuçları üzerindeki olumsuz etkisini azaltabilir. Deneysel sonuçlar, bu yazıda önerilen hibrit dikkat mekanizmasının, ağır retinopati alanının özelliklerini çıkarmaya odaklanmasına daha iyi yardımcı olabileceğini ve farklı veri kümelerinin farklılıklarına uyarlanabilirliği artırabileceğini göstermektedir. Son olarak, hibrit dikkat mekanizması, retinopatinin iki genel OCT veri setinde sırasıyla %96,5 ve %99,76 sınıflandırma doğruluğu elde edilmiştir [53].

Thakoor Kaveri ve ark. Yaptıkları çalışmada AMD olmayan gözlerin, neovasküler olmayan AMD'li gözlerin ve neovasküler AMD'li gözlerin çok sınıflı kategorik sınıflandırmasında %77,8'e varan doğruluk sağlayan hibrit 3D-2D CNN'leri tanımlanmış ve AMD'de ilerlemeyi ayırt etmek için türünün ilk örneği olan bir derin öğrenme yaklaşımı sunulmuştur [54].



4. YAPAY ZEKÂ, MAKİNE ÖĞRENİMİ, YAPAY SİNİR AĞLARI VE DERİN ÖĞRENME

Yapay Zekâ, görevleri yerine getirmek yöntemleri noktasında insan zekâsını taklit eden ve topladığı bilgilerle kendisini peyderpey geliştiren sistemler veya makineler olarak ifade edilebilir. Yapay zekâ, makine öğrenmesini ve derin öğrenme terimlerini içine alan geniş bir teknolojidir.

4.1. Yapay Zekâ ve Tarihçe

Yapay zekâ, öncelikle zekâ ve düşüncenin insanlara birçok yönden yardımcı olabilecek makinelere aktarılmasına yönelik bir bilgi işlem alanı haline gelmişti. Yapay Zekâ, insan zekâsı iktiza eden farklı görevleri yerine getirmek için insan zekâsını taklit ederek akıllı makineler ve bilgisayar programları oluşturan bir bilim ve teknoloji dalıdır. Bir başka ifadeye göre; Yapay zekâ insan tarafından yapıldığında zeki olarak adlandırılan davranışların makine tarafından yapılmasıdır.

Yapay zekâ, 1950 yılında Alan Turing'in, düşünen makineler oluşturma ihtimali hakkında düşüncelerini yazdığı makale, bu konuyla alakalı bir dönüm noktası olduğu aşîkârdır. Fakat yapay zeka kavramı olarak 1956 tarihli Dartmouth olarak, Marvin Minsky, John McCarthy ve iki kıdemli bilim adamı Claude Shannon ve Nathan Rochester tarafından düzenlenen konferansta dile getirildi. Bu konferanstan sonraki yıllarda geliştirilen programlar çoğu insan için basit bir ifadeyle şaşırtıcıydı [55]. Bilgisayarlar cebirsel kelime problemlerini çözüm bulmuş, geometrideki teoremlerine kanıt sunmakla beraber İngilizce konuşmayı öğreniyorlardı. O zamanlar bunun mümkün olduğuna pek az insan inanmaktaydı. Tıpta yapay zeka makine öğrenimi ve derin öğrenmenin popülerleşmesi ile hayatımıza büyük bir giriş yapmış olmakla beraber yaklaşık on yıldır ciddi bir çalışma potansiyeli mevcuttur. Tahmine dayalı modeller, hastalıkların teşhisi, terapötik yanıtın öngörülmesi ve gelecekte potansiyel olarak önleyici tıp için kullanılabilir durumda görünmektedir. Yapay zekânın teknolojisinin kademeli olarak büyümesi ve gelişmesi aşamalı bir şekilde özetlenmiştir.

Yapay zekâ evveliyatında, daha önce yalnızca bir insanın yapabileceği çıkarımlar veya kararlar verme yeteneğine sahip makinelerin geliştirilmesine yönelik çalışmalara odaklandı. İlk endüstriyel robot kolu (Unimate; Unimation, Danbury, Conn, ABD) 1961'de General Motors'daki montaj hattına katıldı ve otomatik kalıp dökümü gerçekleştirdi [56]. Unimate, adım adım komutları takip edebildi. Tarih 1964'ü gösterdiğinde Eliza, Joseph Weizenbaum tarafından tanıtıldı. Doğal dil işlemeyi kullanan Eliza, insan konuşmasını (yüzeysel iletişim) taklit etmek için kalıp eşleştirme ve

ikame metodolojisi kullanarak iletişim kurabilen bir makineydi ve gelecekteki sohbet robotları için çerçeve görevi gördü [57].

İlk elektronik kişi diye vasıflandırılan Shakey 1966'lara gelindiğinde geliştirildi. Stanford Araştırma Enstitüsü'nde oluşturulan bu mobil robot, talimatları yorumlayabilen ilk robottu. Shakey, tek adımlı komutları takip etmek yerine, bundan daha karmaşık komutları işleyebiliyordu ve uygun eylemleri gerçekleştirebiliyordu [58]. Bu durum, robotik alanında ve yapay zekada önemli bir adım oldu.

Mühendislikte alanında yaşanan bu yeni durumlara rağmen, yapay zekâyı tıp alanında gerektiği gibi kullanmanın zamanı henüz gelmemişti. Ancak bu erken dönem, daha sonra yapay zekânın tıp alanında gelecekteki şekillenmesi ve kullanımı için temel görevi görecektir olan verilerin dijitalleştirilmesi için önemli bir dönem olduğu söylenebilir. Tarih 1960'lara geldiğinde Ulusal Tıp Kütüphanesi tarafından Tıbbi Literatür Analizi ve Erişim Sisteminin ve web tabanlı arama motoru PubMed'in geliştirilmesi, biyotıbbın daha sonra hızlanması için önemli bir dijital kaynak haline geldi. Klinik bilişim veri tabanları ve tıbbi kayıt sistemleri de ilk olarak bu süre içinde oluşturuldu ve yapay zekânın tıpta gelecekteki gelişmeleri için temel oluşturulmasına yardımcı oldu [59].

Yapay zekânın iki büyük kışı diye nitelendirilen ve 1970 ile 2000 arasını kapsayan dönemde olumlu ve olumsuz durumların yaşandığı bir süreç olmuştur. Yaşanan olumsuzlukların biri yapay zekânın ilk kışı olarak bilinen ve 1970'lerin sonuna tekabül eden dönemdir. Bu dönem yapay zekânın algılanan sınırlamalarından kaynaklanan ve ikincisi, 1980'lerin sonunda, uzman dijital bilgi veri tabanlarını geliştirme ve sürdürmenin aşırı maliyetinden kaynaklanan 1990'ların başına kadar uzanmaktadır.

Bu süreçte genel olarak ilgili olunmadığı halde, yapay zekâ alanındaki öncüler arasındaki işbirliği devam etti. Bu da, 1971'de Rutgers Üniversitesi'nde Saul Amarel tarafından biyotıpta bilgisayarlar üzerine araştırma kaynağının geliştirilmesi noktasında teşvik oldu. 1973'te Zaman paylaşımlı bir bilgisayar sistemi olan Stanford Üniversitesi Tıbbi Deneysel-Tıpta yapay zekâ, oluşturuldu ve çeşitli kurumlardan klinik ve biyomedikal araştırmacılar arasında ağ oluşturma yeteneklerini geliştirildi [60]. Büyük ölçüde bu işbirliklerinin bir sonucu olarak, 1975'te Rutgers Üniversitesi'nde Ulusal Sağlık Enstitüleri sponsorluğundaki ilk tıpta yapay zekâ çalışmayı düzenlendi. Bunla böylece tıpta yapay zekâ öncüleri arasında ilk yerlerini almış oldular.

Yapay zekânın ilaca uygulanmasının başarılabilirliğini gösteren öncü uygulamalardan biri, CASNET modelidir. Bu model kullanarak glokom için bir konsültasyon programı geliştirilmiştir. Bu model üç ayrı programdan oluşan nedensel-ilişkisel bir ağıdır: model oluşturma, danışma ve

ortak çalışanlar tarafından oluşturulan ve sürdürülen bir veritabanı. Söz konusu model, belirli bir hastalık hakkındaki bilgileri bireysel hastalara uygulayabilir ve doktorlara hasta yönetimi konusunda tavsiyelerde bulunabilir [61]. Rutgers Üniversitesi'nde geliştirildi ve 1976'da Nevada, Las Vegas'taki Oftalmoloji Akademisi toplantısında resmi olarak ilan edildi.


Bu dönemin başında(1970'lerin başı) geri zincirleme yapay zeka sistemi olan MYCIN oluşturuldu. Hekimler tarafından yapılan hasta bilgilerine ve yaklaşık 600 kuralın bilgi tabanına dayanarak, MYCIN, potansiyel bakteriyel patojenlerin bir listesini meydana getirebilir ve ardından hastanın vücut ağırlığına göre uygun şekilde ayarlanmış antibiyotik tedavi seçenekleri önerebiliyordu. MYCIN, daha sonraki kural tabanlı sistem olan EMYCIN'in çerçevesi oldu. INTERNIST-1 daha sonra EMYCIN ile aynı çerçeve ve birinci basamak hekime teşhiste yardımcı olmak için daha geniş bir tıbbi veri tabanı kullanılarak geliştirildi [59].

Massachusetts Üniversitesi 1986 yılında DXplain diye bir karar destek sistemi geliştirdi. Söz konusu program girilen semptomlardan tanıyı oluşturmaktaydı. Bu uygulama hastalıkların ayrıntılı açıklamalarını ve ek referansları sağlayan elektronik bir tıp ders kitabı işlevi de görmekteydi. DXplain piyasaya ilk sürüldüğünde yaklaşık olarak 500 hastalık hakkında bilgi içermekteydi. O dönemden beridir sayısı 2400'ü aşan hastalık mevcuttur [62]. Artık 1990'ların sonuna gelindiğinde yaşanan teknolojik gelişmelerle birlikte tıpta yapay zekanın popüler dönemi olan makine öğrenimine ilginin artması yapay zeka kışını geride bırakarak ümitleri tekrar yeşertti.

Makine öğrenimi başlayan bu süreçte 2007 yılında Watson adlı açık alanlı bir soru-cevap sistemi geliştirildi. Bu sistem manuel eğer-öyleyse kuralları kullanan geleneksel sistemlerin aksine, DeepQA ağı kullanılmıştır. Verileri analiz etmek için doğal dil işleme ve çeşitli aramalar kullandı. Olası yanıtları oluşturmak için yapılandırılmamış içeriğin üzerine çıktı [63]. Bu sistem kullanıma uygun, bakımı daha kolay ve daha ekonomiktir. DeepQA teknolojisi hastanın elektronik tıbbi kayıtlarından ve diğer elektronik kaynaklardan bilgi alarak, kanıta dayalı tıp yanıtları oluşturabiliyordu. Bu nedenle, kanıta dayalı klinik karar vermede yeni olanaklara yol açıldı. Bu hız nazara alındığında, gelişmiş bilgisayar donanımı ve yazılım programları ile birlikte dijitalleştirilmiş tıp daha kolay erişilebilir hale geldi ve tıpta yapay zekâ hızla büyümeye başladı.

Yapay zekâ medikal alanda daha önce 1990 yıllarında kullanılmış fakat bazı başarısız sonuçlar elde edilmiştir. Bunun nedenleri arasında yeterince gelişmiş olmayan donanımsal cihazlar yetersiz bilgi işlem kapasitesi, veri eksikliği neticesinde veri kümelerinin doğru bir şekilde işlenememesi ve bunun aşırı uyuma sebep olması bu olumsuzluklara sebep olmuştur. Yaşanan bu olumsuzluklar neticesinde de bazı hekimler sağlık alanında yapay zekâ kullanılmasına karşı bir önyargıya sahip olmuşlardır. Ancak günümüzde derin öğrenmenin başarısı sayesinde, hekimlerin ve mühendislerin

iş birliği yapmasıyla pek çok çalışma gerçekleştirilmiş ve son derece başarılı sonuçlar elde edilmiştir. Şekil 4.1’de yapay zekâ ve alt dalları arasındaki ilişki ve tarihsel gelişim süreçleri gösterilmiştir.



Şekil 4.1. Yapay Zeka ve Alt Dalları(Makine Öğrenimi ve Derin Öğrenme)

4.2. Makine Öğrenimi

Makine öğrenimi, çevredeki ortamlardan öğrenecek insan zekâsını taklit edecek şekilde tasarlanmış olup gelişen bir hesaplama algoritmaları dalıdır. Makine öğrenimine dayalı teknikler, örüntü tanıma, bilgisayarla görme, uzay aracı mühendisliği, finans, eğlence ve hesaplamalı biyolojiden biyomedikal ve tıbbi uygulamalara kadar çeşitli alanlarda başarıyla uygulanmıştır. Diğer bir ifade ile, Makine Öğrenimi: Sistemlere programlanmadan deneyimden otomatik olarak öğrenme ve geliştirme yeteneği sağlayan yapay zekanın bir uygulamasıdır veya bir alt dalıdır denilebilir. Makine öğrenimi, verilere erişebilen ve öğrenmeyi kendileri için kullanabilen bilgisayar programlarının geliştirilmesine odaklanır. Modellerin eğitim sırasında girdi verilerini nasıl kullandıklarına kategorize edilen birkaç tür makine öğrenimi vardır. Makine öğrenimi çalışma algoritmalarına ve sınıflandırıcılara göre supervised(gözetimli), unsupervised(gözetimsiz) ve reinforcement(takviyeli) olarak kategorize edilmektedir. Şekil 4.2’de makine öğrenimi ve çeşitleri gösterilmektedir.



Şekil 4.2. Makine Öğrenimi Grupları

Gözetimli Makine Öğrenimi


Gözetimli öğrenme , etiketli veri kümelerinin kullanımıyla tanımlanan bir makine öğrenimi yaklaşımıdır. Başka bir ifadeyle önceden gözlenerek sonuçları bilinen verilerden yararlanarak bu verilerin ve sonuçların tümünü kapsayan bir fonksiyon elde etmeyi yöntemidir [64]. Bu veri kümeleri, verileri sınıflandırmak veya sonuçları doğru bir şekilde tahmin etmek için algoritmaları eğitmek veya denetlemek için tasarlanmıştır. Model, etiketlenmiş girdi ve çıktıları kullanarak doğruluğunu ölçebilir ve zamanla öğrenebilir. Denetimli makine öğreniminin iki türü mevcuttur: sınıflandırma, regresyon.

Sınıflandırma

Test verilerini belirli kategorilere doğru bir şekilde atamak için bir algoritma kullanır. Veri kümesi içindeki belirli varlıkları tanır ve bu varlıkların nasıl etiketlenmesi veya tanımlanması gerektiği konusunda bazı sonuçlar çıkarmaya çalışır. Yaygın sınıflandırma algoritmaları: destek vektör makineleri (SVM), karar ağaçları, k-en yakın komşu en çok bilinen türleridir.

Destek Vektör Makineleri


Destek vektör makinesi, Vladimir Vapnik tarafından geliştirilen ve hem veri sınıflandırması hem de regresyon için kullanılan popüler bir denetimli öğrenme algoritmasıdır. Bununla birlikte, tipik olarak, iki veri noktası sınıfı arasındaki mesafenin maksimum olduğu bir hiperdüzlem oluşturarak, sınıflandırma problemlerinde kullanılır. Bu hiperdüzlem, düzlemin her iki tarafındaki veri noktalarının sınıflarını (örneğin kedi ve köpek) ayıran karar sınırı olarak bilinir. Başka bir ifadeyle, iki sınıfı birbirinden ayırabilen en uygun hiper düzlemin elde edilmesidir. Hiper düzlemin sınır genişliğini sonlandıran noktalara destek vektörleri adı verilmektedir. Elde edilen hiper düzlem sayesinde destek vektörleri arasındaki uzaklık maksimize edilmekte ve en uygun karar fonksiyonu oluşturulmaktadır. Şekil 4.3'te ikili sınıflandırma için destek vektör makineleri yapısı gösterilmektedir.



Şekil 4.3. İki sınıflı bir problemde en uygun hiper düzlem, sınır ve destek vektörleri

Karar Ağaçları


Karar Ağaçları, belirli bir parametreye göre verilerin sürekli olarak bölündüğü bir Denetimli Makine Öğrenmesi türüdür. Ağaç, karar düğümleri ve yapraklar olmak üzere iki varlık tarafından açıklanabilir. Yapraklar kararlar veya nihai sonuçlardır. Karar düğümleri verilerin nereye bölündüğünü gösterir. Şekil 4.4'te karar ağacı yapısı(düğümler, yapraklar ve dallar) gösterilmektedir.



Şekil 4.4. Karar ağacı örneği

K-En Yakın Komşu

K-nn algoritması olarak da bilinen k-en yakın komşu, veri noktalarını yakınlıklarına ve diğer mevcut verilerle ilişkilerine göre sınıflandıran parametrik olmayan bir algoritmadır. Bu algoritma, benzer veri noktalarının birbirine yakın bulunabileceğini varsayar. Sonuç olarak, genellikle Öklid mesafesi aracılığıyla veri noktaları arasındaki mesafeyi hesaplamaya çalışır ve ardından en sık görülen kategoriye veya ortalamaya göre bir kategori atar. Kullanım kolaylığı ve düşük hesaplama süresi, bu yöntemi tercih edilen bir algoritma haline getirir, ancak test veri seti büyüdükçe işlem süresi uzar ve sınıflandırma görevleri için daha az çekici hale gelir. Bu algoritma genelde öneri motorları ve görüntü tanıma için kullanılmaktadır. Şekil 4.5'te k-nn(k=3 için) için bir örnek gösterilmektedir.



Şekil 4.5. K-En yakın komşu algoritması örneği

4.2.1. Gözetimsiz Makine Öğrenimi


Gözetimsiz makine öğrenimi, etiketlenmemiş ham veri kümesindeki veriler arasında var olan ancak net olarak görülmeyen bağıntının açığa çıkarılması işlemidir[64]. Gözetimsiz öğrenme (Unsupervised Learning) gözlemlere bağlı bir makine öğrenmesi yöntemidir. Yani çıktı verilerini kullanmadan girdiler üzerinde öğrenme işlemini gerçekleştirmeye çalışma durumudur [65]. Gözetimsiz öğrenme tekniğinin kullanışlı olduğu alanlardan bir de veri sıkıştırma işlemleridir.

4.2.2. Pekiştirmeli Makine Öğrenimi

Pekiştirmeli öğrenme, davranışsal bir öğrenme modelidir. Algoritma, veri analizinden geribildirimleri alarak kullanıcıyı en iyi sonuca yönlendirir. Sistem örnek veri kümesiyle eğitilmediğinden pekiştirmeli öğrenme, diğer gözetimli öğrenme türlerinden farklıdır. Burada sistem, deneme ve yanılma yöntemiyle öğrenir. Böylece başarılı kararlar sonunda süreç sağlamlaştırılır.

4.3. Yapay Sinir Ağları

Yapay sinir Ağları (YSA), insan beyninin öğrenme yolunu taklit ederek, hatırlama, genelleme yapma yolu ile topladığı verilerden yeni veri üretebilme gibi temel işlevlerin gerçekleştirildiği bilgisayar yazılımları olarak ifade edilebilir. Bu ağlar insan beyninden esinlenerek, öğrenmenin matematiksel olarak modellenmesi uğraşı sonucu oluşturulmuştur. Yapay sinir ağları paralel olarak çalışan, birbiriyle bağlantılı olan düğümlerden oluşmaktadır. Bu düğümler canlı sinir sistemleri örnek alınarak oluşturulmuştur. YSA’da bir düğümün alt grubuna katman denilmektedir. İlk grup giriş katmanı, son grup çıktı katmanı olarak isimlendirilir. Bu katmanlar arasında kalan katmanlara da gizli katman denilir. Gizli katman sayısı bir den fazla ise çok katmanlı yapı olarak bilinirken gizli katman sayısı bir olan ağlar tek katmanlı olarak adlandırılmaktadır. Şekil 4.6’ da tek katman ve çok katmanlı yapay sinir ağ yapısı gösterilmektedir.



Şekil 4.6. Tek ve çok gizli katmanlı sinir ağı yapısı

4.4. Derin Öğrenme

Geleneksel olarak, makine öğrenme modelleri, ham verilerden çıkarılan manuel olarak tasarlanmış özelliklere veya diğer basit makine öğrenme modelleri tarafından öğrenilen özelliklere dayanarak faydalı görevleri yerine getirmek üzere eğitilir. Derin öğrenmede, bilgisayarlar yararlı temsilleri ve özellikleri otomatik olarak, doğrudan ham verilerden otomatik olarak öğrenir. Derin öğrenmenin teorik temelleri, klasik yapay sinir ağı literatüründe yer edinmiştir. Ancak, sinir ağlarının daha geleneksel kullanımından farklı olarak, derin öğrenme, yeni eğitim paradigmalarıyla birleştirilmiş mimari bir avantaj olarak birçok gizli nöron ve katmanın (genelde ikiden fazla) kullanımından oluşmaktadır. Birçok nörona başvurmak eldeki ham verilerin kapsamlı bir şekilde kapsanmasına izin verirken, çıktıların doğrusal olmayan kombinasyonlarının katman katman boru hattı, girdi alanının daha düşük boyutlu bir projeksiyonunu oluşturur. Her düşük boyutlu projeksiyon, daha yüksek bir algısal seviyeye karşılık gelmektedir. Ağın optimal olarak ağırlıklandırılması koşuluyla, ham veri veya görüntülerin etkili bir yüksek düzeyde soyutlanmasıyla sonuçlanır [66]. Derin öğrenme yöntemlerinin temel ortak özelliği, özellik öğrenmeye odaklanmasıdır: verilerin otomatik olarak temsil edilmesini öğrenme gibi.

Tıp gibi alanlarda, bu otomatik özellik setinin insan müdahalesi olmadan üretilmesinin birçok avantajından söz etmek mümkündür. Örneğin, tıbbi görüntülemede, daha karmaşık ve tanımlayıcı yollarla detaylandırılması zor olan özellikler bu vesileyle üretebilir. Örtük özellikler, fibroidleri ve polipleri belirleyebilir ve tümörler gibi doku morfolojisindeki düzensizlikleri karakterize edebilir [67-68].


Derin öğrenmenin çeşitli metodolojik varyantları mevcuttur. Bu mimarilerin bir kısmı kullanılabilirlik ve üstün performansı bakımından öne çıkmaktadır. Bunların içinde özellikle, Evrişimli Sinir Ağları (CNN) sağlık alanında en büyük etkiyi uyandırmıştır. Mimarisi, indirgeme, düzeltme veya havuzlama katmanları tarafından takip edilen evrişimsel filtreler uygulayan serpiştirilmiş ileri beslemeli katmanlar kümesi olarak tanımlanır. Ağdaki her katman, üst düzey bir soyut özellik oluşturur. Biyolojiden özellikle de insan beyninden ilham alan bu mimari, görsel korteksin görsel bilgiyi alıcı alanlar şeklinde özümlediği prosedürü andırmaktadır [66]. CNN ile beraber farklı olaylara uygulanmak üzere çeşitli derin öğrenme mimarileri mevcuttur.

4.4.1. Derin Öğrenme Mimarileri

Söz konusu derin öğrenme mimarileri şunlardır: tekrarlayan sinir ağları(RNN), uzun kısa süreli bellek ağları(UKSBA), derin Boltzmann makinesi(DBM) ve derin inanç ağları(DİA), evrişimli sinir Ağları(CNN).

4.4.1.1 Tekrarlayan Sinir Ağları(Recurrent Neural Network - RNN)

Bu mimari Jeff Elman tarafından geliştirilmiştir. Elman'ın cümle yapısı simülasyonunda kullanılan her bir kelime için gizli kalıpların üzerinde ortalama örüntü kümeleme sonucunda isim ve fiil kategorileri temiz şekilde ayrılmıştır. Buna ilave olarak isimler arasında canlı-cansız ayırımı, daha da ilerisi insan-hayvan, hayvanlar arasında avcı-yırtıcı gibi ayrımlar da yapılmıştır [69]. Bu mimarideki temel düşünce sıralı bilgileri kullanmaktır. Geleneksel bir sinir ağında tüm girdiler ile çıktıların birbirinden bağımsız olduğu varsayılmaktadır. Örneğin, bir cümle içinde bir sonraki kelimeyi tahmin etmek için, hangi sözcüklerin o anki kelimeden önce geldiğini bilmek gerekmektedir. RNN mimarisinin yinelenen olarak adlandırılmasının sebebi, bir dizinin her ögesi için aynı görevi önceki çıktılarına bağlı olarak yerine getirmesidir.




Şekil 4.7. RNN'nin şematik yapısı

RNN'ler şekil 4.7' de görüldüğü üzere bir giriş katmanına, iki gizli katmana ve bir çıkış katmanına sahiptir. Bu katmanların hepsi bağımsız şekilde çalışmaktadır. Dolayısıyla her katmanın kendine has ve farklı bir işlevi vardır. Daha da detaylandırılması gerekirse her katmandaki yapıların ağırlıkları vardır ve katmana özgü şekilde eşik değerleri belirlenir. Bu sayede sistemin daha olası sonuçlar vermesi amaçlanır. Tekrarlanan bu aşamalar sonucunda bir önceki giriş durumu depolanır

ve yeni elde edilen giriş değeriyle birleştirilir. Bu sayede yeni elde edilen girişin bir önceki girişle olan ilişkisi sağlanır.

4.4.1.2 Uzun Kısa Süreli Bellek Ağları(Long Short Term Memory - LSTM)


RNN mimarilerinde önceki bilgi kullanımına dayalı bir yöntem söz konusuydu. Örneğin “Güneş doğudan doğar” tümcesinde bulunan Güneş kelimesini tahmin etmek zor değildir. Fakat bağlamlar arası boşluk arttığında RNN modelinin geçmişten gelen bir bilgiyi kullanması oldukça güçtür. Mesela, “Türkiye’de doğdum ve orda büyüdüm... Türkçe dilini iyi konuşurum.” gibi bir metinde Türkçe kelimesini tahmin ederken, söz konusu cümleden yola çıkarak bunun bir dil olduğunu tahmin edebilir, ancak doğru kelimenin Türkçe olduğunu tahmin etmek için, metnin başında bulunan cümledeki yer bilgisini hafızada tutması gerekmektedir. Teorik olarak mümkün görünen “uzun-vadeli bağımlılıklar”, uygulamada büyük sorunlara yol açtığı görülmüştür [70]. Bu sorunları çözmek için, uzun vadeli bağımlılıkları öğrenebilen özel bir RNN türü olan Uzun Kısa Vadeli Bellek ağları Hochreiter ve Schmidhuber tarafından 1997 yılında tasarlanmıştır [71]. Söz konusu mimari giriş, unut ve çıkış olmak üzere 3 kapısı mevcuttur. Bu kapılar hücrenin yazılmasını, okunmasını ve sıfırlanmasını gerçekleştirir. Uzun ve kısa bellek hücre durumu, uzun ve kısa süreli belleğin her bloğu arasında bilgi aktarımı için anahtar bir bileşendir. Bütün hücreler bu üç kapı tarafından kontrol edilir [72]. Giriş kapısı açık hücreye giriş bilgileri kontrol eder, geçmiş geçidi kullanarak yeni verilere ne kadar bilgi aktarılacağını belirler ve çıkış geçidini kullanarak çıktıyı hesaplarken ne kadar bilgi kullanılacağını kontrol eder [73]. Şekil 4.8’ de LSTM’nin şematik yapısı gösterilmiştir.



Şekil 4.8. LSTM'nin şematik yapısı

4.4.1.3 Sınırlı Boltzmann Makinesi(Restricted Boltzmann Machines - RBM)

Sınırlı Boltzmann makineleri (Restricted Boltzmann Machines-RBM), Harmonium adıyla 1986'da ortaya çıkmışsa da, çok uzun zaman sonra (2006) Geoffrey Hinton ve arkadaşları tarafından hızlı bir öğrenme algoritması olarak ön plana çıkarılmıştır [74]. RBM'lerin temeli Hinton, Sejnowski ve Ackley tarafından yayınlanan "A Learning Algorithm for Boltzmann Machines" makale ile öğrenme algoritmalarının prensiplerine dayandırılmaktadır. RBM girdi seti üzerinde olasılık dağılımını öğrenebilen üretken bir rastgele yapay sinir ağıdır. Görünür ve gizli olmak üzere aralarında simetrik bağlantı bulunan iki parçalı graflardan oluşurlar. Aynı katmanda bulunan düğümler arasında bağlantı bulunmaz. Bu vesileyle katman içi iletişim söz konusu değildir. Ancak, Kısıtlamasız Boltzmann makineleri gizli birimler arasında da bağlantı vardır. Bu kısıtlama, Boltzmann makinelerinin genel sınıfı için mevcut olanlardan daha etkili eğitim algoritmalarına imkân tanır [75]. RBM'ler, boyut indirgeme, sınıflandırma, işbirlikçi filtreleme, özellik öğrenimi ve konu modelleme gibi farklı konular için kullanışlı bir algoritmalar olduğu tespit edilmiştir. Kısıtlı Boltzmann makinası şematik yapısı şekil 4.9' de gösterilmiştir.




Şekil 4.9. RBM'nin yapısı

4.4.1.4 Derin İnanç Ağları(Deep Belief Networks - DBN)

Derin inanç ağları, Sınırlı Boltzmann Makinelerinin (RBM) yığılmış modüllerinden oluşan olasılıklı bir üretken modeldir. Bir RBM, sırasıyla sadece katmanlar arasındaki bağlantıları olan görünür(v) ve gizli(h) birimlerden oluşan iki katmana sahip, yönlendirilmemiş enerji tabanlı bir modeldir. Ancak herhangi bir katmanın düğümleri birbirleriyle yatayda iletişimi bulunmamaktadır. En son katman olarak bir softmax katmanı ile sınıflandırma veya denetimsiz bir öğrenme için kümeleme yeteneğine sahiptir [76]. Her aşamanın çıktısı (öğrenilen özellikler) sonraki RBM aşamasının girişi olarak kullanılır. Daha sonra, tüm ağ genellikle sınıflandırma performansını

iyileştirmek için denetimli öğrenme ile eğitilir. Derin inanç ağı yapısı şekil 4.10’ da gösterildiği gibidir.



Şekil 4.10. Yığılmış kısıtlı Boltzmann makineleri (RBM) tarafından oluşturulan derin inanç ağı (DBN) mimarisi


4.4.1.5 Derin Oto – Kodlayıcılar

Diabolo ağı olarak da bilinen oto-kodlayıcılar (Autoencoders-AE) denetimsiz öğrenme için kullanılan bir özel yapay sinir ağıdır [77]. Oto-kodlayıcılar bir veri kümesi için boyut indirgeme amacıyla bir temsil (kodlama) öğrenmeyi hedeflemektedir. AE genel olarak ifade edilecek olursa; girdi verisinin sıkıştırılmış gösteriminden en iyi özelliklerin öğrenilmesini hedefleyen bir ileri beslemeli sinir ağıdır [78]. Bu mimarinin mantığında, girdi verisi şifreleme-şifre çözme işleminden sonra çıktı olarak yine aynı girdiyi görene kadar ağırlıklar değiştirilir. Amaca gidildiğinde gizli katmandaki düğüm sayısı ile girdi verisi temsil edilmiş bulunmaktadır. Şekil 4.11’ autoencoder şematik yapısı gösterilmektedir.



Şekil 4.11. AE(Autoencoders) yapısı

Derin veya yığınlı oto-kodlayıcılar ise (Deep/Stacked Autoencoder-DAE), her bir katmandaki çıktıların ardışık katmanın girişlerine bağlandığı oto-kodlayıcıların çok katmanlarından oluşan sinir ağıdır [79].




Şekil 4.12. DAE(Deep/Stacked Autoencoder) yapısı

Şekil 4.12’ de ardışık olarak yerleştirilmiş iki AE ağı bulunmaktadır. Girdi dizisi ilk gizli katmanda şifrelenerek Features I dizisi elde edilmiştir. Sonraki gizli katmana elde edilen özellik dizisi girdi olarak verilmiş ve bu şifreleme sonucunda features II dizisi elde edilmiştir. Özellik II dizisi ise özellik vektörü olarak son katmanda softmax sınıflandırıcıya girdi olarak verilmiş, sınıflandırma işlemi bu vektörle gerçekleşmektedir.

4.4.1.6 Evrişimsel Sinir Ağları(Convolution Neural Network - CNN)

CNN’ler 2012 yılı itibari ile derin öğrenme alanında bir devrim olması vesilesiyle sınıflandırmanın kesinliğinde muazzam iyileştirmeler yaşandıktan sonra popüler olmaya başladı. Söz konusu tarih itibari ile bir kısım ileri teknoloji şirketleri çeşitli hizmetler için bu ağları kullanmaktadırlar.

CNN’ler canlıların görsel bakış açısından faydalanılarak oluşturulan çoklu katman yapısı kullanan gelişmiş ağlardır. Bu ağlar bilgisayarlı görme işlemlerinde girdi görüntülerinden denetimsiz derin özellik çıkartımı sağlar. CNN’ler dizi olarak sıralanan birden fazla verileri işlemek için tasarlanmıştır[80]. Görüntüler 2B diziler olarak ifade edilmektedir. Çoklu katman yapısından oluşan CNN şekil 4.13’ te gösterilmiştir.



Şekil 4.13. Örnek CNN yapısı[81]

Evrişimli sinir katmanları, görüntülerde iyi özellikleri tespit etme ve ağda daha derine giderken karmaşıklıklarının büyüdüğü doğrusal olmayan özelliklerin hiyerarşilerini oluşturma konusunda güvenilir olduğundan dolayı özellik öğrenme algoritması olarak kullanılmaktadırlar. Bu ağların temel amacı, doğrusal olmayan özellikleri bu denli derin katmanlara yığmaktır. Çünkü karmaşık özelliklerin birkaç katmandan öğrenilmesi oldukça zordur. CNN'lerin görüntüleri öğrenmesinde, kenarların ve lekelerin önceki katmanlarda ayıklanabilecek en iyi özellikler olduğu matematiksel olarak gösterilmektedirler. CNN'ler girdi, evrişim, havuzlama, tam bağlı ve sınıflandırma katmanlarından oluşmaktadır.

Girdi Katmanı:

CNN'nin şekil 4.13' te görüldüğü üzere giriş katmanında ham veriler ağa verilerek ağın eğitimi başlatılmaktadır. Girdi boyutu ağın başarımları ve performansını etkilemektedir. Girdi boyutunun artmasına bağlı olarak başarı oranı da artar. Ancak boyutun artmasına bağlı olarak daha fazla bellek ihtiyacı doğmakta ve buna paralel olarak işlem süresi de uzamaktadır. Söz konusu parametreler göz önünde bulundurularak ortalama bir boyut tercih edilmelidir.

Evrişim(Konvolüsyon) Katmanı:

CNN'nin temelini oluşturan bu katman dönüşüm katmanı olarak da bilinmektedir. Bu dönüşüm işlemi belirli bir filtrenin görüntü üzerinde dolaştırılması işlemidir. Bu sebeple filtreler katmanlı mimarinin vazgeçilmez bir bileşenidir. Filtreler 2x2, 3x3, 5x5 gibi farklı boyutlarda olabilir. Filtreler, bir önceki katmandan gelen görüntülere konvolüsyon işlemi uygulanarak çıkış verisini oluştururlar. Bu konvolüsyon işlemi sonucu aktivasyon haritası (Özellik haritası) meydana gelmektedir. Aktivasyon haritası, her bir filtreye özgü özelliklerin keşfedildiği bölgelerdir. CNN'lerin eğitimi esnasında bu filtrelerin katsayıları, eğitim kümesindeki her öğrenme yinemesiyle değişir. Bu sebeple ağ, özelliklerin belirlenmesi için, verinin hangi bölgelerinin önem taşıdığını belirler. Bir filtrenin görüntü üzerine uygulanması Şekil 4.14' te gösterilmiştir. Söz konusu şekilde görüldüğü gibi giriş görüntüsü 5x5 tek kanallı bir matris olduğu düşünülürse giriş veri boyutu 5x5x1 olacaktır. Konvolüsyon işlemi için 3x3'lük bir filtre ile giriş görüntüsü üzerinde sağa veya sola doğru belirli Adım(Stride) kaydırılarak dolaşma yapılır. Bu dolaşma esnasında matris sınırına gelindiğinde ise bir basamak aşağı kayıp tekrar devam edilir. Bu dolaşma işlemi görüntü matrisinin tümü üzerinde yapılır. Aşağıda f görüntü ve h kernel(filter) olmak üzere bu işlemin formülü 4.1' de gösterildiği gibidir.

$$f * h = \sum_k \sum_l f(k, l) h(i - k, j - l) \quad (4.1)$$

$$\mathbf{f} = \begin{bmatrix} f_1 & f_2 & f_3 \\ f_4 & f_5 & f_6 \\ f_7 & f_8 & f_9 \end{bmatrix}$$

$$\mathbf{h} = \begin{bmatrix} h_1 & h_2 & h_3 \\ h_4 & h_5 & h_6 \\ h_7 & h_8 & h_9 \end{bmatrix}$$

$$f * h = f_1 * h_9 + f_2 * h_8 + f_3 * h_7 + f_4 * h_6 + f_5 * h_5 + f_6 * h_4 + f_7 * h_3 + f_8 * h_2 + f_9 * h_1$$



1	1	1	1	0
1	1	0	1	0
0	1	1	0	1
1	1	1	1	0
0	1	2	0	0

*

1	0	1
1	1	0
0	1	1

Kernel(Filtre)(3x3)

Giriş Görüntüsü

1 _{x1}	1 _{x1}	1 _{x0}	1	0
1 _{x0}	1 _{x1}	0 _{x1}	1	0
0 _{x1}	1 _{x0}	1 _{x1}	0	1
1	1	1	1	0
0	1	2	0	0

4		

1	1 _{x1}	1 _{x1}	1 _{x0}	0
1	1 _{x0}	0 _{x1}	1 _{x1}	0
0	1 _{x1}	1 _{x0}	0 _{x1}	1
1	1	1	1	0
0	1	2	0	0

4	4	

1	1	1 _{x1}	1 _{x1}	0 _{x0}
1	1	0 _{x0}	1 _{x1}	0 _{x1}
0	1	1 _{x1}	0 _{x0}	1 _{x1}
1	1	1	1	0
0	1	2	0	0

4	4	5

1	1	1	1	0
1 _{x1}	1 _{x1}	0 _{x0}	1	0
0 _{x0}	1 _{x1}	1 _{x1}	0	1
1 _{x1}	1 _{x0}	1 _{x1}	1	0
0	1	2	0	0

5	4	5
6		

1	1	1	1	0
1	1 _{x1}	0 _{x1}	1 _{x0}	0
0	1 _{x0}	1 _{x1}	0 _{x1}	1
1	1 _{x1}	1 _{x0}	1 _{x1}	0
0	1	2	0	0

4	4	5
6	4	

1	1	1	1	0
1	1	0 _{x1}	1 _{x1}	0 _{x0}
0	1	1 _{x0}	0 _{x1}	1 _{x1}
1	1	1 _{x1}	1 _{x0}	0 _{x1}
0	1	2	0	0


4	4	5
6	4	3

1	1	1	1	0
1	1	0	1	0
0 _{x1}	1 _{x1}	1 _{x0}	0	1
1 _{x0}	1 _{x1}	1 _{x1}	1	0
0 _{x1}	1 _{x0}	2 _{x0}	0	0

4	4	5
6	4	3
3		

1	1	1	1	0
1	1	0	1	0
0	1 _{x1}	1 _{x1}	0 _{x0}	1
1	1 _{x0}	1 _{x1}	1 _{x1}	0
0	1 _{x1}	2 _{x0}	0 _{x1}	0

4	4	5
6	4	3
3	5	



Şekil 4.14’ter bir konvolüsyon işlemi gösterilmiştir. CNN’lerde söz konusu bu konvolüsyon işlemine bakıldığında üç hiperparemetre dikkat çekmektedir: adım(stride), dolgu(padding), derinlik. Bu hiperparemetreler çıktı boyutu üzerinde etkilidir. Çıkış hacminin derinliği bir hiperparemetre olarak ifade edilir ve kullanılan kernel sayısına denk gelmektedir ve her biri girdide farklı bir şey öğrenir. Adım kernelin giriş hacminin etrafında nasıl evrildiğini kontrol eden bir parametredir. Filtre bir, iki vb. adım kaydırılarak giriş hacminin üzerinde gezdirilir. Örneğin adım 1 olarak belirlendiğinde kernel görüntü üzerinde bir piksel hareket ettirilirken adım 2 olarak belirlendiğinde ise kernel görüntü üzerinde gezdirilirken iki piksel hareket ettirilir. Bu durumda adım sayısı arttıkça da elde edilen özellik haritasının boyutu düşer. Padding hiperparemetresi ise, evrişim işleminde, çıktı tensörlerinin büyüklüğünü giriş hacmi ile aynı tutmak için giriş tensörüne eklenebilir. Padding büyüklüğü genel olarak filtre boyutuna göre belirlenir. Örneğin; 3x3 boyutunda bir kernel kullanılacak olursa paddingin 1, 5x5 boyutlarında kernel kullanılırsa padding 2 olur. Padding işlemi iki şekilde yapılır: padding işlemi ya sıfır olarak eklenir ya da kenar pikseliyle aynı olacak şekilde eklenir.

Şekil 4.15. Padding Örneği


Şekil 4.15'te bir padding örneği gösterilmektedir. Her hangi bir evrişim katmanı için çıktı büyüklüğü 4.2'deki gibi hesaplanabilir.

$$O = \frac{(W - K + 2P)}{S} + 1 \quad (4.2)$$

Genel olarak genişlik ve yükseklik eşit olmaktadır. Denklemden 4.2'de görüldüğü üzere O çıktı boyutu, W giriş görüntüsü boyutu, K kernel boyutu, P padding(dolgu), S stride(adım) olarak ifade edilmektedir.

Havuzlama Katmanı(Pooling Layer)


CNN'de ardışık gelen konvolüsyon katmanları arasına veya tam bağlı katmanları arasında havuzlama(pooling) katmanı kullanılmaktadır. Subsampling(alt örnekleme) olarak da isimlendirilir. Bu katman ağıdaki parametrelerin ve hesaplamaların sayısını azaltmak için konvolüsyon katmanı çıktısının mekânsal boyutunu küçültür. İlave olarak aşırı uyumun da önüne geçmektedir. Söz konusu katman genel olarak maximum havuzlama(Max Pooling) ve ortalama havuzlama(Average Pooling) olmak üzere iki yöntem kullanılmaktadır. Bir giriş çerçevesinde, max pooling çerçeve içindeki maximum değerleri alırken average pooling çerçeve içindeki ortalama değerleri almaktadır. Havuzlama işleminde havuzlama boyutu ve stride olmak üzere iki önemli parametre vardır. Şekil 4.16' da max pooling ve average pooling örneği mevcuttur.



Şekil 4.16. Pooling Örneği

Tam Bağlı Katman(Fully Connected Layer):

CNN'lerin son katmanı olmakla beraber en önemli katmanı da denilebilir. Bu katmanın içinde, her nöron, Tam Bağlantılı yaklaşımı olarak adlandırılan bir önceki katmanın tüm nöronlarına bağlanır. Tam Bağlı katmanın amacı, üst düzey özelliklerin, girdi görüntüsünü farklı sınıflara sınıflandırmak için kullanılır. Bir tür ileri beslemeli YSA olduğu için geleneksel çok katmanlı algılayıcı sinir ağının temel yöntemini izler. Tam bağlı katmanın girişi, son havuzlama veya evrişim katmanından gelir. Bu girdi, düzleştirmeden sonra özellik haritalarından oluşturulan bir vektör biçimindedir [82]. Örnek bir tam bağlı katman şekil 4.17' de verilmiştir.




Şekil 4.17. Tam Bağlı Katman yapısı[83]

Aktivasyon(Activation) Katmanı:

Aktivasoyon fonksiyonlarının kullanıldığı katmandır. Bu fonksiyonlar, nöronun ağırlıklar toplamını hesaplayarak ve bias(b) değerini ekleyerek aktive edilip edilmeyeceği durumuna bakmaktadır. Aktivasyon fonksiyonları, çok katmanlı ağlarda modele non-linearite katar. Bir sinir ağında, nöronların ağırlıkları ve bias değerleri çıktıdaki hataya göre güncellenir. Bu işleme geri yayılım denmektedir. Aktivasyon fonksiyonları bu geri dönüşleri olası yapmakta olup gradyanlar, ağırlıkları ve bias değerlerini güncelleme hatasıyla birlikte verir. Bazı yaygın olarak kullanılan aktivasyon fonksiyonları: ReLU, Sigmoid, Tanh ve Softmax'tır.

- **ReLU Aktivasyon Fonksiyonu:**


Sinir ağları bağlamında doğrultucu(Rectified Linear Unit-ReLU) doğrusal olmayan bir aktivasyon işlevidir. Bu fonksiyon x negatif giriş parametreleri için 0 değerini almakta olup x pozitif giriş parametreleri için ise x değerini almaktadır. Fonksiyon grafiği ve denklemi şekil 4.18' deki gibidir.



Şekil 4.18. ReLU fonksiyon grafiği

- **Sigmoid Aktivasyon Fonksiyonu:**


Sık kullanılan ve doğrusal olmayan(non-linear) aktivasyon fonksiyonudur. Bu fonksiyonun değeri [0-1] aralığında olmakla beraber karar vermeye yönelik olasılıksal bir yaklaşımdır. Yani çıktının ne olduğuna dair olasılıksal bir tahmin vermektedir. Doğrusal fonksiyonlardan farklı olarak sigmoid fonksiyonu türevlenebilir olduğu için öğrenme işlemi gerçekleşmektedir. Bu fonksiyon çoğunlukla son katmanda bulunmaktadır. Fonksiyon grafiği ve denklemi şekil 4.19’ da gösterildiği gibidir.



Şekil 4.19. Sigmoid fonksiyon grafiği

- **Tanh Aktivasyon Fonksiyonu:**

Bu fonksiyon sigmoid fonksiyonu ile aynıdır. Ancak aralarındaki fark tanh fonksiyonu değerleri $[-1,1]$ aralığında ortalanmasıdır. Söz konusu fonksiyonun grafiği ve denklemi şekil 4.20’ deki gibidir.




Şekil 4.20. Tanh fonksiyon grafiği

- **Softmax Aktivasyon Fonksiyonu:**

Çoklu sınıflandırma problemlerinde kullanılmaktadır. Bu fonksiyon $[0,1]$ aralığında değer üretmekte olup verilen her bir girdinin bir sınıfa ait olma olasılığını göstermektedir. Sınıflayıcı olarak kullanılması itibari ile sigmoide benzediği ya da başka bir deyişle çoklu sigmoid olarak bilinir. Bu fonksiyonun grafiği ve denklemi şekil 4.21’ deki gibidir.


$$f(x) = \frac{e_i^x}{\sum_i^k e_i^x}, i = 0,1,2, \dots, k$$



Şekil 4.21. Softmax fonksiyon grafiği

Dropout Katmanı:


Dropout bir model ortalamasıdır [84]. Farklı modellerden tahmin edilen sonuçların ağırlıklı ortalamasıdır. Dropout'daki rastgele seçim, eğitim sürecindeki gizli katman düğümlerini görmezden gelebilir, sonuç olarak her eğitim ağı farklıdır ve her eğitim yeni bir model olarak kabul edilebilir. Özellikle gizli düğümler belirli olasılıklara göre rastgele ortaya çıkar. Herhangi iki gizli düğümün modelde aynı anda birden çok kez görünmesi garanti edilmez; bu nedenle, ağırlıkların güncellenmesi, sabit ilişkinin örtük düğümlerinin etkileşimine bağlı değildir ve birkaç özelliğin başka bir belirli özelliğe olası bağımlılığını önleyebilir. Şekil 4.22' de dropout katmanları olan ve olmayan sinir ağı birimleri karşılaştırılmıştır. Söz konusu şeklin (1) durumu ortasındaki her katmandaki düğümler diğer katmandaki herhangi bir düğümlle ilişkilendirilebilir yani dropout uygulanmamış ve (2) durumunda ise düğümlerin bazıları rastgele göz ardı edilmiştir yani dropout uygulanmıştır. Bu göz ardı edilen gizli katman düğümleri, hesaplama maliyetini azaltır. Ayrıca, bu düğümler, ağı ezber yapmasını engel olmak için düğümler arasındaki bağlantıyı koparır ve böylece verilerin en temel özelliklerini keşfetmeye yardımcı olur [85].



Şekil 4.22. Dropout Yapısı


4.4.2. CNN Tabanlı Derin Öğrenme Algoritmaları

Alexnet: Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından ortaya atılan bir derin ağ Modelidir [86]. 25 katmandan oluşmaktadır. Girdi katmanında olan görüntü 227x227x3 boyutlarındadır. ImageNet veritabanında doğruluk oranını %80 olarak yakalamış bir derin öğrenme modelidir. Şekil 4.23'te AlexNet'e ait mimari yapı gösterilmektedir.




Şekil 4.23. Alexnet mimarisi [86]

Resnet-18: Resnet-18, ImageNet veritabanında bir milyondan fazla görüntü üzerinde eğitilmiş bir CNN ağıdır. Bu mimari 18 katman derinliğe sahiptir. Görüntü sınıflandırmada kullanışlı ve verimli olması ile beraber 1000 nesne sınıfına ayırabilir. Ağ 224x224x3 giriş görüntü boyutuna sahiptir. Söz konusu ağın mimarisi şekil 4.24’ de gösterildiği gibidir.




Şekil 4.24. Resnet18 mimarisi [87]

Resnet-50: Bu model CNN’nin geliştirilmiş bir mimarisidir. Aynı zamanda CNN ağlarının performans düşümü sorununu çözmeyi hedeflemekte olan bir modeldir. Söz konusu problemi çözmek için katmanlar arasına ağ derinleştikçe oluşan bozulmayı önlemek için kısa yollar eklemekte ve daha hızlı eğitim yapabilmek için darboğaz(bottleneck) blokları kullanmaktadır. Resnet50 ImageNet veri kümesi üzerinde eğitilmiş 177 katmanlı 50 derinlikli bir yapıdır. Bu model (1x1, 3x3, 1x1) şeklinde evrişim katmanları kullanır. Resnet50 ağının şeması şekil 4.25’de gösterilmiştir.




Şekil 4.25. Resnet50 blok şeması [88]

Resnet-101: Resnet-101, ImageNet veritabanında bir milyondan fazla görüntü üzerinde eğitilmiş bir CNN ağıdır. Bu mimari 101 katman derinliğe sahiptir. Görüntü sınıflandırmada kullanışlı ve verimli olması ile beraber 1000 nesne sınıfına ayırabilir. Ağ 224x224x3 giriş görüntü boyutuna sahiptir. Söz konusu ağın mimarisi şekil 4.26’ da gösterildiği gibidir.




Şekil 4.26. Resnet101 blok şeması [89]

Googlenet: Inception mimarisine dayalı ve 22 katman derinliğe sahip bir CNN ağıdır. Imagenet üzerinde eğitilmiştir. Bu ağ, çok çeşitli görüntüler için farklı özellik temsillerini öğrenmiştir. Giriş görüntüsü 224 x 224 piksel boyutundadır. Googlenet mimari yapısı şekil 4.27’de gösterilmektedir.



Şekil 4.27. Googlenet mimarisi [90]


Squeezenet: 224×224 piksel giriş boyutunda, derinlemesine bir öğrenme modeli olan SqueezeNet, evrişimli katmanlar, havuz katmanları, ReLU ve Fire katmanlarından oluşur. SqueezeNet'te tamamen bağlı katmanlar ve yoğun katmanlar yoktur. Fakat, Fire katmanları bu benzer katmanların işlevlerini yerine getirmektedir. Bu modelin en büyük yararı, parametre sayısını düşürüp böylece model boyutu kapasitesini de azaltarak analizleri başarıyla gerçekleştirmesidir. Şekil 4.28' de modelin mimarisi gösterilmektedir.



Şekil 4.28. Squeezenet mimarisi [91]


Mobilenet: düşük donanım maliyetli cihazlarda kullanılmak üzere tasarlanmış bir derin öğrenme modelidir. Söz konusu ağ 154 katmandan oluşmakta ve 53 katman derinliğindedir. Giriş boyutu

224 × 224 pikseldir ve mimarisi derinlemesine (DW) ayrılabilir filtrelerden ve adımların birleşiminden oluşur. Şekil 4.29’da mobilenetv2 mimarisi gösterilmektedir.



Şekil 4.29. Mobilenetv2 mimarisi[92]

Densenet-201: Densenet, gereksiz özellik haritalarını öğrenmediği için geleneksel bir CNN'den daha az sayıda parametreye ihtiyaç duyar. DenseNet'teki her katman orijinal girdi görüntüsüne ve kayıp işlevinden gradyanlara doğrudan erişime sahiptir. Bu nedenle, hesaplama maliyeti önemli ölçüde azalır. Bunun böyle olması da Densenet'i görüntü sınıflandırması için daha iyi bir seçim haline getirir. Densenet-201 derinliği 201 olup 708 katmandan oluşmaktadır. Şekil 4.30'da densenet201 blok şeması gösterilmektedir.




Şekil 4.30. Densenet201 blok şeması[93]

5. MATERYAL VE METOD

Yapay zekânın bir alt dalı olan derin öğrenme teknolojileri, tıbbın çeşitli alanlarında kullanıldığı gibi neredeyse tüm retina hastalıklarının patolojik özelliklerinin tespiti ve hastalık tiplerinin lezyon derecelerini gruplandırarak bu hastalıkların teşhis ve tedavisine yardımcı olması için de kullanılmaktadır. Derin öğrenme teknikleri, mimari esnekliği nedeniyle büyük verimlilik sağlamaktadır. Geniş veri modeline sahip olmak, daha karmaşık fonksiyonlardan istifade etmeyi mümkün kılan daha fazla temsil gücüne sahiptir. Ayrıca, bu alandaki hızlı gelişme, tasarım için araç kutusunu genişleten yeni teknikleri ve mimarileri sürekli olarak tanıtmaktadır. Ek olarak, basitlik her zaman benimsenmeli ve ağır mümkün olduğunca basit tutulması mantıklı olmaktadır. CNN tekniğini kullanan bir çalışma, veri madenciliğinde havuzlama ve karmaşık aktivasyon işlevlerini kullanmanın yaygın olmasına dahi sebep oldu. Bunun yerine, doğru seçilmiş adım ve filtre boyutu parametreleriyle yalnızca yinelenen katmanların kullanılması büyük kolaylık sağlamakla birlikte zaman tasarrufu, maddi ve manevi zahmetin azalması noktasında yardımcı olmaktadır.

Çalışmanın bu bölümünde, kullanılan veriler tanıtılmış, bunlar üzerinde uygulanan metod ve uygulama adımları aktarılmıştır. Söz konusu adımlar Şekil 5.1’de gösterilmiştir. Mevcut hastalıkların sınıflandırma metodu, OCT görüntü veriseti üzerinde veri artırma işlemleri uygulandıktan sonra önerilen CNN hibrit modeli üzerinde eğitim / test işlemleri yapılması ve bunun sonucunda görüntülerin sınıflandırılmasından oluşmaktadır.




Şekil 5.1 Önerilen Modelin çalışma şeması

5.1. Veri Seti

Bu çalışmada, erişime açık OCT2017[97] ve OCTID[98] genel veri setlerinden elde edilen OCT görüntüleri kullanıldı. OCTID veri setinde toplam 572, OCTID2017 veri 3399 OCT görüntüsü mevcuttur. Tablo 5.1 her bir hastalık için kullanılan OCT görüntü sayılarını, şekil 5.2’ de her bir hastalık için örnek bir OCT görüntüsünü göstermektedir.

Veri Seti	AMD	SSR	DR	MH	Drusen	Normal	Toplam
OCTID	55	102	107	102	-	206	572
OCT2017	406	461	450	430	947	705	3399
Oluşturulan Veri Seti	461	563	557	532	947	911	3971
Arttırılmış Veri Seti	2812	3033	3179	3032	2976	3388	18420


Tablo 5.1. Veri seti özeti



Şekil 5.2. Her bir hastalığa ait OCT görüntüsü

5.2. Önerilen Yöntem


Bu bölümde Yaşa Bağlı Makula Dejenerasyonu(AMD), Santral Seröz Retinopati(SSR), Diyabetik Retinopati(DR), Makula Deliği(MH), Drusen ve Normal OCT görüntülerinin sınıflandırılması için önerilen yöntem sunulmaktadır. İlk olarak, OCT görüntülerine veri artırma yöntemleri uygulanmıştır. İkinci olarak önerilen yöntem ile OCT görüntülerinin özellikleri elde edilmiş ve çıkartılan özellik vektörleri birleştirilmiştir. Üçüncü olarak sınıflandırma başarımını maksimum yapan özelliklerin belirlenmesi için özellik çıkartım algoritmaları kullanılmıştır. Son olarak elde edilen özellik vektörü SVM, DT ve K-NN ile sınıflandırılmıştır. Şekil 5.3’ te önerilen yöntemin yapısı verilmektedir.



Şekil 5.3. Önerilen hibrit model

5.2.1. Veri Çoğullama

Elde bulunan verilere çeşitli teknikler uygulayarak yeni ve sentetik veri oluşturma işlemine veri çoğullama(data augmentation) denmektedir. Bir başka ifadeyle elimizdeki orijinal veriler değiştirilerek yeni veriler elde etmektir. Oluşturulan bir modelin veriyi öğrenebilmesi için büyük bir veri setinin mevcut olması gerekmektedir. Fakat mevcut veriler modelin iyi bir öğrenme yapabilmesi için yeterli olmayabilir. Böyle bir durumda veriler tekrar nereden temin edildiyse yine öyle bir yöntem ile elde etme yoluna girilir. Ancak meşakkatli bir süreç olabilmektedir. Bunun önüne geçmek için veri çoğullama yöntemleri kullanılarak veri seti genişletilebilir ve modelin öğrenmesine uygun hale getirilebilir. Bu yöntemlerle oluşturulan veriye sentetik veri denmektedir. Söz konusu teknikler: rotation(döndürme), shear(kırpma), zoom(yakınlaştırma), flip(çevirme) ve brightness(parlaklık) olarak gösterilmektedir. Söz konusu tekniklere örnek bir adet AMD görüntüsü şekil 5.4' te gösterilmektedir.



Şekil 5.4. Veri arttırmaya örnek bazı görüntüler

5.2.2. Önerilen Modelde Kullanılan CNN Mimarileri

Bu tez çalışmasında kullanılan hibrit modelin oluşturulması için kullanılan CNN modelleri özellik çıkarıcı olarak kullanılmaktadır. Bölüm 4’ te bahsedilen CNN modellerinin performansları karşılaştırılmış olup performansı diğer modellere göre daha yüksek olan resnet50 ve densenet201 modelleri seçilmiştir. Söz konusu ağlara ait performans metrik değerleri bölüm 6 da verilecektir.

CNN mimarileri katman, parametre sayısı ve katman derinliği tablo 5.2’de verilmiştir.

CNN MODEL	KATMAN SAYISI	PARAMETRE SAYISI	DERİNLİK
AlexNet	25	61.0M	8
ResNet18	71	11.7M	18
ResNet50	177	25.6M	50
ResNet-101	347	44.6M	101
GoogleNet	144	7.00M	22
SqueezeNet	68	1.24M	18
MobileNet-v2	154	3.50M	53
DenseNet-201	708	20.0M	201

Tablo 5.2. CNN Mimarileri Katman, Parametre Sayısı ve Model Derinliği

Sınıfları daha baskın bir şekilde birbirinden ayıran özellikler üst düzey özneliteler olarak ifade edilmekte ve özellikle sınıflandırıcı performansı açısından çok önemli olmaktadır. Tüm özellikleri kullanmak yerine seçilen üst düzey özellikleri kullanmak işlem süresini azaltır ve performansı artırır. Özellik seçici olarak kullanılan Resnet-50’nin 175. katmanı olan fullyconnectedlayer(fc1000) ve Densenet-201’in 706. katmanı olan fullyconnectedlayer(fc1000) katmanından alınan özellikler birleştirilerek yeni bir vektör oluşturulmuştur. Oluşturulan bu yeni özellik vektörü özellik seçisi algoritmalar ile sınıflandırma başarımı yüksek olan özellikler elde edilmek üzere seçilir.

5.2.3. Özellik Seçici Algoritmalar

Önerilen modelde mimarilerden elde edilen özellikler birleştirildikten sonra gelecek aşama olan özellik seçici algoritmalar kullanılarak sınıflandırma başarımını maksimum yapan özelliklerin belirlenmesi için özellik çıkartım algoritmaları kullanılmaktadır. Bu çalışmada kullanılan özellik seçici algoritmalar relief, laplacian ve mRMR’dir. Bu algoritmalar filtreleme yöntemine dayanmaktadır. Söz konusu algoritmalar en iyi performansı relief ile elde edildiği tespit edilmiştir.

Laplacian: Bir özelliğin Laplacian skoru, o özelliğin yerelliği korumayla ilgisini gösterir. Laplacian skoru, birbirine yakın olan iki örneğin genellikle aynı sınıfa ait olduğu gözlemine

dayanır. Laplacian skoru, verilerin yerel yapısını elde etmek için en yakın komşu grafiğini kullanır ve her bir özelliğin laplacian skor değerini elde eder. Daha yüksek laplacian skor değerlerine sahip özellikler seçilmiş olur [96].

mRMR: mRMR, temel olarak, sınıf etiketlerine yakın özellikleri seçmeye ve kalanını filtrelemeye çalışan bir algoritmadır. Algoritma, en ilgili özellikleri belirlerken, ilgili özellikler arasındaki fazlalığı da en aza indirmeye çalışır [97]. Özel olarak, mRMR algoritması, her bir özelliği ve sınıf vektörünü ayrı bir random değişken olarak ele alır. Ölçmek için iki özellik arasındaki veya bir öznelik ile sınıf vektörü arasındaki benzerlik, karşılıklı bilgi ölçüsünü kullanır.

Relief: Kira ve Rendell tarafından 1992'de geliştirilen ve özellik seçimine özellikle özellik etkileşimlerine duyarlı olan filtre yöntemi yaklaşımını benimseyen bir algoritmadır[98]. Relief, benzer örnekler arasındaki farkla tutarlı özelliklerin ağırlıklarını değerlendirir. Bu algoritma random bir X örneğini seçer. Random bir örnekleme örneğine göre, Relief en yakın isabetini H'yi aynı sınıftan ve en yakın ıskasını M'yi diğer farklı sınıftan bulur. Ardından, relief niteliklerin ağırlıklarını etkilemek için iki benzer örnek arasındaki farkı hesaplar ve tüm özellikler A için X, M ve H değerlerine bağlı olarak kalite tahminini yani “W[Ai]”yi günceller. Aynı sınıfta, iki benzer örnek arasındaki fark özellikten kaynaklanıyorsa, özelliğin olumsuz bir etkisi vardır. Farklı bir sınıfta, iki benzer örnek arasındaki fark özellikten kaynaklanıyorsa, özelliğin olumlu bir etkisi vardır[99]. Ai özelliğinin ağırlığını hesaplama formülü (5.1)’de verilmiştir.

$$W[A_i] = W[A_i] - \text{diff}(A_i, X_m, H) / T + \text{diff}(A_i, X_m, M) / T \quad (5.1)$$

diff(A_i, X₁, X₂) fonksiyonu, A_i özelliği için X₁ ve X₂ örneği arasındaki farkı hesaplar. W [A_i], A_i özelliğinin ağırlığıdır. T, maksimum yinelemeli sürelerin sayısıdır.

5.2.4. Sınıflandırıcılar

Sınıflandırma başarımını maksimum yapan özelliklerin belirlenmesi için özellik çıkartım algoritmalarından elde edilen özellik vektörü bölüm 4’te bahsedilen sınıflandırıcılara(K-NN, SVM ve DT) verilmekte ve elde edilen performans değerleri sonuç ve bulgular kısmında gösterilmektedir.

6. DEĞERLENDİRME

6.1. Performans Matrikleri

Bu çalışmada önerilen yöntemlerin değerlendirilmesi için performans metrikleri, Karışıklık (confusion) Matrisi üzerinden hesaplanmıştır. Karışıklık matrisi, sınıflandırma modelinin performansını tanımlayan bir tablodur. Sınıflandırıcı tarafından yapılan gerçek değerler ve tahmin sınıflandırmaları hakkında bilgi içerir ve bu bilgi sınıflandırıcının performansını değerlendirmek için kullanılmaktadır. Karışıklık matrisi, nesnenin gerçek sınıfını indekslediği ekseni ve sınıflandırıcının tahmin ettiği sınıfı indekslediği başka bir ekseni olmak üzere iki eksenli bir yapıdadır. Başka bir şekilde ifade edilecek olursa; nesnenin gerçek sınıfının satır olduğu düşünülürse, tahmin sınıfı da sütunlardan oluşan yapıdır.

Karışıklık matrisi, performans açısından sınıflandırma modellerini iyileştirmesi ve problemlerin çözümünde önerilen yöntemlerin geliştirilmesi için sıkça kullanılmaktadır. Genel olarak karışıklık matrisinden hesaplanıp yaygın bir şekilde kullanılan performans metrikleri bunlardır: doğruluk (accuracy), duyarlılık (sensitivity), özgüllük (specificity), kesinlik (precision) ve F1-skor (F1-score). Karışıklık matrisi ve performans metrikleri hesaplamaları için iki sınıflı örnek matrisi şekil 6.1’de gösterilmiştir.

		Predicted	
		Positive	Negative
Actual	Positive	TP	FN
	Negative	FP	TN

Şekil 6.1 Karışıklık matrisi

Doğru pozitif (TP): Pozitif olarak tanımlanan sınıftaki örneklerin sınıflandırma çıktısında doğru olarak tahmin edilmesidir.

Yanlış pozitif (FP): Negatif sınıfın yanlışlıkla pozitif olarak tahmin edilmesidir. Örneğin pozitif olduğuna dair yanlış yapılan tahmin sayısıdır.

Doğru negatif (TN): Negatif sınıfın doğru şekilde negatif olarak tanımlandığı doğru tahmin olarak ifade edilmektedir.

Yanlış negatif (FN): Pozitif sınıfındaki örneğin negatif sınıf olarak tahmin edilmesi durumudur. Yanlış tahminlerin sayısı olarak da ifade edilmektedir.

Yukarıda tanımlanan bu parametreler performans değerlendirmelerinde kullanılan metriklerdir. Bu metrikler tablo 6.1’ de gösterildiği gibidir.

Doğruluk	Doğruluk, tüm doğru tahminlerin sayısının veri kümesinin toplam sayısına bölünmesiyle hesaplanır.	$A = \frac{TP + TN}{TP + TN + FP + FN}$
Duyarlılık	Pozitif olarak tahmin edilmesi gereken verilerin ne kadarını pozitif olarak tahmin edildiğini gösterir.	$S = \frac{TP}{TP + FN}$
Kesinlik	Kesinlik, toplam pozitif tahmin sayısına bölünen doğru pozitif tahminlerin sayısı olarak hesaplanır. Pozitif Tahmin değer olarak da adlandırılır.	$P = \frac{TP}{TP + FP}$
F ₁ -Skor	F1 puanı, kesinlik ve duyarlılığın harmonik ortalamasıdır.	$F_1 = \frac{2TP}{2TP + FN + FP}$
Özgüllük	Özgüllük, doğru negatif tahminlerin sayısının toplam negatif sayısına bölünmesiyle hesaplanır. Gerçek negatif oran olarak da adlandırılır.	$Spec = \frac{TN}{TN + FP}$

Tablo 6.1. Performans metrikleri

6.2. Uygulama

Uygulama için intel core i7-4510 işlemcili ve 8 GB RAM'li bir bilgisayar kullanıldı. Uygulama kodları Matlab R2021a ortamında yazıldı. Her bir uygulama için 5 kez test yapıldı ve modellerin değerlendirilmesi ortalama değerlere göre yapıldı. Önerilen yaklaşımın performansını test etmek için, Accuracy, Sensitivity, Specificity, Precision, F1-Score parametreleri kullanılmıştır. Tablo 6.1 kullanılan parametre tanımları verilmektedir.

Önerilen modelin üstünlüğünü göstermek için ilk olarak OCT görüntüleri ön eğitilmiş AlexNet, ResNet18, ResNet50, ResNet101, GoogleNet, DenseNet201, SqueezeNet ve MobileNetv2 ile performansları test edildi. Elde edilen performans değerleri karşılaştırıldı. Daha sonra söz konusu CNN mimarileri SVM, K-NN ve DT sınıflandırıcıları ile hibrit yapılar oluşturularak elde edilen performans değerleri karşılaştırıldı. Tablo 6.2' de performans değerleri gösterilmektedir. Karşılaştırılan bu değerlerden tespit edildiği üzere resnet50 ve densenet201 önerilen model için uygun olduğu görülmüştür.

Kullanılan Mimari	Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Score
AlexNET	0.9652	0.9610	0.9623	0.9930	0.9623
ResNET18	0.9675	0.9580	0.9606	0.9937	0.9591
ResNET50	0.9793	0.9723	0.9761	0.9959	0.9741
ResNET101	0.9746	0.9684	0.9695	0.9951	0.9680
GoogleNET	0.9697	0.9612	0.9620	0.9941	0.9620
DenseNET201	0.9799	0.9736	0.9712	0.9782	0.9707
SqueezeNET	0.9544	0.9592	0.9581	0.9920	0.9577
MobileNET	0.9687	0.9588	0.9610	0.9940	0.9597

Tablo 6.2. CNN modelleri performans metrik değerleri

Daha sonra seçilen CNN mimarilerinden elde edilen özellikler tekrar SVM, K-NN ve DT algoritmaları ile sınıflandırmaya tabi tutulmuştur. Elde edilen yeni performans metrikleri Tablo 6.3.' te gösterilmektedir.

Kullanılan Mimari	Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Score
Alexnet+SVM	0.9223	0.9186	0.9178	0.9845	0.9180
Alexnet+Knn	0.8782	0.8692	0.8741	0.9755	0.8710
Alexnet+DTree	0.6798	0.6605	0.6733	0.9366	0.6641
DenseNET201+SVM	0.9655	0.9562	0.9589	0.9932	0.9573
DenseNET201+Knn	0.9399	0.9233	0.9379	0.9878	0.9295
DenseNET201+DTree	0.7438	0.7054	0.7082	0.9500	0.7046
ResNET18+SVM	0.9369	0.9204	0.9225	0.9879	0.9203
ResNET18+Knn	0.9330	0.9152	0.9239	0.9867	0.9187
ResNET18+DTree	0.7379	0.6880	0.6939	0.9484	0.6887
ResNET50+SVM	0.9645	0.9555	0.9571	0.9931	0.9560
ResNET50+Knn	0.9290	0.9147	0.9161	0.9862	0.9141
ResNET50+DTree	0.7678	0.7191	0.7161	0.9551	0.7163
ResNET101+SVM	0.9645	0.9553	0.9564	0.9931	0.9554
ResNET101+Knn	0.9275	0.9097	0.9198	0.9854	0.9140
ResNET101+DTree	0.7263	0.6816	0.6864	0.9465	0.6815
GoogleNET+SVM	0.9216	0.9078	0.9111	0.9846	0.9079
GoogleNET +Knn	0.9246	0.9093	0.9220	0.9847	0.9146
GoogleNET +DTree	0.7145	0.6718	0.6708	0.9437	0.6709
SqueezeNET+SVM	0.9466	0.9408	0.9431	0.9894	0.9417
SqueezeNET+Knn	0.8817	0.8714	0.8824	0.9760	0.8754
SqueezeNET+Dtree	0.6868	0.6695	0.6798	0.9382	0.6717
MobileNET +SVM	0.9568	0.9557	0.9561	0.9914	0.9559
MobileNET +Knn	0.9763	0.9719	0.9763	0.9952	0.9736
MobileNET +Dtree	0.7145	0.6746	0.6759	0.9442	0.6717

Tablo 6.3. Seçilen CNN modellerinden elde edilen özelliklerin sınıflandırıcılara verilerek elde edilen performans metrik değerleri

Görüldüğü üzere densenet201 ve resnet50 SVM sınıflandırıcısı ile en yüksek performans elde edilmiştir. Daha sonra bu modellerden elde edilen özellik vektörleri birleştirilerek oluşturulan yeni


vektör tekrar sınıflandırıcılara verilmiş olup performanslarına bakılmıştır. Söz konusu performans metrikleri tablo 6.4’ te gösterilmektedir.

Kullanılan Mimari	Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Score
Resnet+Densenet201+SVM	0.9893	0.9891	0.9896	0.9979	0.9892
Resnet+Densenet201+KNN	0.9099	0.9095	0.9127	0.9820	0.9095
Resnet+Densenet201+DT	0.6760	0.6727	0.6744	0.9353	0.6733


Tablo 6.4. Seçilen CNN modellerinden elde edilen özelliklerin birleştirilip sınıflandırıcılara verilerek elde edilen performans metrik değerleri

Son olarak önerilen modelde arttırılan veri seti seçilen ön eğitilmiş CNN mimarilerine verilmektedir. Veri seti 18420 OCT görüntüsünden oluşmaktadır. Bu görüntülerin 12893 adedi eğitim, 5527 adedi de test için kullanılmıştır. Daha sonra tüm özellikleri kullanmak yerine seçilen üst düzey özellikleri kullanmak işlem süresini azaltır ve performansı artırır. Özellik seçici olarak kullanılan Resnet-50’nin 175. katmanı olan fullyconnectedlayer(fc1000) ve Densenet-201’in 706. katmanı olan fullyconnectedlayer(fc1000) katmanından alınan özellikler birleştirilerek yeni bir vektör oluşturulmuştur. Oluşturulan bu yeni özellik vektörü özellik seçisi algoritmalar(relief, laplacian, mRMR) ile sınıflandırma başarımı maximum olan özellikler elde edilmek üzere seçildi. Daha sonra seçilen bu üst düzey özellikler tekrar sınıflandırıcılara verilmiş olup performansları karşılaştırılmıştır. Önerilen modelin performansı karışıklık matrisleri ve doğruluk varyans grafikleri ile gösterilmektedir.

Birleştirilmiş özellik vektörü ilk olarak laplacian özellik seçici algoritması ile işleme tabi tutularak sınıflandırıcılara giriş olarak verilmektedir. Karışıklık matrisi ve doğruluk varyans grafiği şekil 6.2 şekil 6.3 ve şekil 6.4’ te verilmiştir.



Şekil 6.2. Resnet50_Densenet201 + laplacian+SVM karışıklık matrisi ve doğruluk varyansı




Şekil 6.3. Resnet50_Densenet201 + laplacian+K-NN karışıklık matrisi ve doğruluk varyansı




Şekil 6.4. Resnet50_Densenet201 + laplacian+DT karışıklık matrisi ve doğruluk varyansı


Elde edilen özellik vektörü bu defa fscrmr özellik seçicisine verilmekte ve elde edilen yeni özellik vektörü sınıflandırıcılara verilmektedir. Karışıklık matrisi ve doğruluk varyansı şekil 6.5, şekil 6.6 ve şekil 6.7’de gösterildiği gibidir.



Şekil 6.5. Resnet50_Densenet201 + fscrmr+SVM karışıklık matrisi ve doğruluk varyansı




Şekil 6.6. Resnet50_Densenet201 + fscmr+K-NN karışıklık matrisi ve doğruluk varyansı




Şekil 6.7. Resnet50_Densenet201 + fscmr+DT karışıklık matrisi ve doğruluk varyansı


Özellik vektörü son olarak relief özellik seçicisine verilmekte ve elde edilen yeni özellik vektörü sınıflandırıcılara verilmektedir. Karışıklık matrisi ve doğruluk varyansı şekil 6.8, şekil 6.9 ve şekil 6.10'da gösterildiği gibidir.



Şekil 6.8. Resnet50_Densenet201 + relief+SVM karışıklık matrisi ve doğruluk varyansı



Şekil 6.9. Resnet50_Densenet201 + relief+K-NN karışıklık matrisi ve doğruluk varyansı



Şekil 6.10. Resnet50_Densenet201 + relief+DT karışıklık matrisi ve doğruluk varyansı

Önerilen modele ait performans metrik değerleri karşılaştırılmış olup sonuçlar tablo 6.5' te verilmiştir.

Kullanılan Mimari	Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Score
Resnet+Densenet201+Relife+SVM	0.9862	0.9860	0.9860	0.9973	0.9860
Resnet+Densenet201+Relief+KNN	0.9378	0.9389	0.9377	0.9876	0.9377
Resnet+Densenet201+Relief+DT	0.6745	0.6728	0.6707	0.9350	0.6714
Resnet+Densenet201+Laplacian+SVM	0.9741	0.9737	0.9739	0.9948	0.9738
Resnet+Densenet201+Laplacian +KNN	0.9484	0.9496	0.9482	0.9897	0.9485
Resnet+Densenet201+Laplacian +DT	0.6760	0.6753	0.6729	0.9352	0.6738
Resnet+Densenet201+Fscmm+SVM	0.9846	0.9842	0.9844	0.9969	0.9843
Resnet+Densenet201+Fscmm +KNN	0.9240	0.9250	0.9234	0.9849	0.9236
Resnet+Densenet201+ Fscmm +DT	0.6732	0.6707	0.6700	0.9347	0.6701

Tablo 6.5. Önerilen modelin performans metrik değerleri

Karışıklık matrisinden ve doğruluk varyansından elde edilen sonuçlara göre en iyi performansın önerilen modelde relief ve SVM ile elde edildiği tablo 6.5' te gösterildiği üzere tespit edilmiştir. Tablo 6.6.' da önerilen model ve literatürde bazı çalışmalar karşılaştırılmıştır.

YAZARLAR	YIL	DATASET	GÖRÜNTÜ SAYISI	SINIF SAYISI	DL TEKNİĞİ	PERFORMANS
Chan GCY ve ark. [100]	2018	OCT	14720	2	AlexNet, VGG, GoogleNet	Doğruluk: 93.75%
Kermany D ve ark.[94]	2018	OCT2017	207130	4	Inception V3	Doğruluk : %96,6
Perdomo Oscar ve ark.[26]	2019	SERI-CUHK, A2A SD-OCT	(75+384) 459	2	OCT-NET+SVM	AUC: %99 Duyarlılık: %99 Özgüllük: %99 Kesinlik: %99
Feng Shuanglang ve ark.[25]	2019	OCT	873	6	Vinception C3D	Doğruluk : %94.04
Hassan Bilal ve ark.[101]	2019	OCT(zhang, rabbani)	76891	2	CNN	Doğruluk : %94,33
Dos Santos VA ve ark. [102]	2019	OCT	20160	2	CNN	Doğruluk : %99.56
Asaoka R ve ark. [103]	2019	OCT	4316	2	CNN	AUC: %93.7
Zhang Quan ve ark.[33]	2020	OCT	38057	4	CNN	Doğruluk : %94.5
Tsuji Takumasa ve ark.[104]	2020	kaggle	84484	4	CNN	Doğruluk : %99.6
Alqudah Amin ve ark.[46]	2021	UCSD, DUKE	136187	5	AOCTNet, KNN	Doğruluk: %99.44 Duyarlılık: %99.44 Özgüllük: %99.86

						Kesinlik: %99.45
Sharma Abhinav ve ark.[35]	2021	Mendeley	207130	4	CNN	Doğruluk : %99.38 Hassasiyet: %99.38
Kim Jongwoo ve ark.[34]	2021	OCT	109309	4	VGG16, VGG-19, Inception-V3	Doğruluk : %99.90
Thomas Anju ve ark.[105]	2021	Mendeley	97711	2	CNN	Doğruluk : %99.60
Yoo Tae Keun ve ark.[36]	2021	Mendeley	84126	9	Inception-v3, CycleGAN	Doğruluk : %93.9
Haq Arinal ve ark.[37]	2021	Mendeley	207130	4	Inception-V3	Doğruluk : %99.79 Duyarlılık: %99.79 Özgüllük: %99.93
Luo Yuemei ve ark.[38]	2021	BOE,CELL	84484	3	VGG-16,VAT	Doğruluk : %94.02 Duyarlılık: %94.20
Arefin Raisul ve ark.[39]	2021	OCT	84458	4	CNN	Doğruluk : %97.9
Yoon Jeewoo ve ark.[41]	2022	OCT	3209	4	VGG-16	Doğruluk : %76.8
Upadhyay,Pa wan Kumar ve ark.[42]	2022	Mendeley	84495	4	CNN	Doğruluk : %97.19

Ko Junseo ve ark.[106]	2022	SD-OCT	7425	3	Resnet-50	Doğruluk : %98,33
Önerilen Model	2022	OCTID, OCT2017	18420	6	Resnet-50, Densenet-201	Doğruluk : %98.62 Duyarlılık: %98.60 Kesinlik: %98.60 Özgüllük: %99.73 F1-Score: %98.60

Tablo 6.6. Önerilen yöntem ve ilteratür karşılaştırması

7. SONUÇ

Makine öğrenimi veya bunu bir alt dalı olan derin öğrenme günümüzde, donanım performansının artmasına ve buna paralel olarak önceki senelere nazaran maliyetlerin azalmasından dolayı sıkça kullanılmaya başlanmış, kullanım alanı çokça genişlemiştir. Yaygın kullanım alanlarından biri de tıp alanıdır. Tıpta teşhis süresini kısaltmak, zamandan tasarruf sağlamak ve en önemlisi insan kaynaklı hataları minimize etmek sebebiyle önemi artmıştır.

Dünya genelinde yüksek sayıda retina hastalıklarına bağlı körlüklerin meydana gelmesi ve giderek artması kaçınılmaz bir gerçektir. Retinal hastalıkların görme duyusu üzerindeki etkisinin yanında kalp rahatsızlıklarına, hipertansiyon vb. hastalıklara da sebep olduğu bilinmektedir. Bu olumsuzlukların önüne geçilmesi veya engellenmesi erken teşhis ve tedaviye bağlıdır. Teknolojinin gelişmesine bağlı olarak tıpta kullanılan görüntüleme teknikleri ve bunun neticesinde elde edilen görüntüler artmıştır. Bu görüntüleme tekniklerinden biri de oftalmolojide kullanılan OCT'dir. OCT retina hastalıklarının tanısında en çok istimal edilen tekniklerden biridir. OCT görüntülerinin analizinin zaman alıcı, maliyetli ve beşer hatasına açık olması kaçınılmazdır. Retinal hastalıklar OCT vb. görüntüleme teknikleri vesilesiyle uzmanların bilgi, beceri ve tecrübelerine dayanarak taranır ve tespit edilir. Bu süreçte gözden kaçabilecek durumlar olabileceği gibi hastalık belirtileri başka retinal hastalığın bulguları ile karıştırmak da mümkündür. Bu nedenle gerek OCT gerek diğer tıbbi görüntüleme yöntemleri için uzmanlara destek olabilecek yapay zeka tabanlı çalışmalara ihtiyaç duyulmaktadır. Son yıllarda derin öğrenme alanında olağanüstü performans elde eden çalışmalara imza atılmıştır. Buna paralel olarak önerilen yöntem literatür çalışmaları da göz önünde bulundurularak oluşturulmuştur.

Bu çalışmada OCT2017 ve OCTID veri setlerinden elde edilen OCT görüntülerinden 6 sınıflı retina hastalıklarını tespit etmek için CNN tabanlı bir hibrit yöntem önerilmiştir. Yöntemin daha sağlıklı çalışabilmesi için görüntülere veri arttırma yöntemleri uygulanmıştır. Önerilen modelin performans metrikleri incelendiğinde %98.62 doğruluk, %98.60 duyarlılık, %98.60 kesinlik, %99.73 özgüllük ve %98.60 f1-score elde edildiği tablo 6.5'te gösterilmektedir.

Bu alanda literatürde yapılan çalışmalar ile karşılaştırıldığında tablo 6.6'da görüldüğü üzere sınıf sayısı ve performans metrikleri göz önünde bulundurulduğunda diğer çalışmalara kıyasla başarılı sonuçlar elde edildiği açıktır. Önerilen modelin hem uzmanlara hem de hastaları yardımcı olması noktasında hastalık teşhisinde oftalmologlar tarafından kullanılabileceği elde edilen performans metrikleri ile ortaya konulmuştur.

KAYNAKLAR

- [1] Young R W, 1987, Pathophysiology of age-related macular degeneration, Survey of Ophthalmology, 31, 291-306.
- [2] Lim L S, Mitchell P, Seddon J M, Holz F G, Wong T Y, 2012, Age-related macular degeneration, The Lancet, 379, 1728-1738.
- [3] Cohen S R, Gardner T W, 2016, Diabetic retinopathy and diabetic macular edema, Retinal Pharmacotherapeutics, 55, 137-146.
- [4] Balyen L, Peto T, 2019, Promising artificial intelligence-machine learning-deep learning algorithms in ophthalmology, The Asia-Pacific Journal of Ophthalmology, 8, 264- 272.
- [5] M. R. Hee, J. A. Izatt, E. A. Swanson, D. Huang, J. S. Schuman, C. P. Lin, C. A. Puliafito, and J. G. Fujimoto, "Optical Coherence Tomography of the Human Retina," Arch. Ophthalmol., vol. 113, pp. 325-332, 1995
- [6] Krizhevsky A, Sutskever I, Hinton G E, 2012, Imagenet classification with deep convolutional neural networks, Advances in Neural Information Processing Systems, 25, 1097-1105.
- [7] LeCun Y, Bengio Y, Hinton G, 2015, Deep learning, Nature, 521, 436-444.
- [8] Ting D S W, Pasquale L R, Peng L, Campbell J P, Lee A Y, Raman R, vd., 2019, Artificial intelligence and deep learning in ophthalmology, British Journal of Ophthalmology, 103, 167-175.
- [9] Çakır Gündoğan, F. (2020). gozdoktor.net: <https://gozdoktor.net/gozun-yapisi/> adresinden alındı
- [10] Akkoyun, İmren. "Yaşa bağlı makula dejenerasyonu: sınıflandırma ve patogenezi/Yasa bağlı makula dejenerasyonu sınıflandırma ve patogenezi." *Türk Oftalmoloji Dergisi* , cilt. 44, sayı. 6, Kasım-Aralık 2014, s. 476+. Gale Academic OneFile, link.gale.com/apps/doc/A414824436/AONE?u=anon~86866540&sid=googleScholar&xid=51e01254 . Erişim tarihi: 8 Mart 2022.
- [11] Akademi, M.(2010). Diyabetik Maküler Ödem. Medikal akademi: <https://www.medikalakademi.com.tr/diyabetik-makuler-odem-dmoe-nedir/> adresinden alındı
- [12] Saeedi, P., Petersohn, I., Salpea, P., Malanda, B., Karuranga, S., Unwin, N., Colagiuri, S., Guariguata, L., Motala, A. A., Ogurtsova, K., Shaw, J. E., Bright, D., Williams, R., & IDF Diabetes Atlas Committee. (2019). Global and regional diabetes prevalence estimates for 2019 and projections for 2030 and 2045: results from the international diabetes federation diabetes atlas. Diabetes Research and Clinical Practice, 157, 107843, 1-10.
- [13] Klein Kobrin, B. E. (2007). Overview of epidemiologic studies of diabetic retinopathy. Ophthalmic Epidemiology, 14(4), 179- 183.
- [14] İstanbul Retina Enstitüsü. (2018). <https://www.istanbulretina.com>
- [15] Özcan, E., Türkçüoğlu, P., & Yeşilırmak, N. (2018). Nüks Maküla Delği: Nedenleri, Risk Faktörleri ve Tedavisi. Güncel Retina Dergisi, 2(3), 293-295.
- [16] Mc Cannel CA, Ensminger JL, Diehl NN, Hodge DN. Population based incidence of macular holes. Ophthalmology 2009;116(7): 1366-1369
- [17] T. Hassan, M.U. Akram, M. F. Masood, U. Yasin, "Deep structure tensor graph search framework for automated extraction and characterization of retinal layers and fluid pathology in retinal SD-OCT scans", Computers in Biology and Medicine, Vol.105, pp.112-124, 2019.

- [18] E. Garcia-Martin, M. Ortiz, L. Boquete, E.M. Sánchez-Morla, R. Barea, C. Cavaliere, E. Vilades, E. Orduna, M.J. Rodrigo, “Early diagnosis of multiple sclerosis by OCT analysis using Cohen's d method and a neural network as classifier”, *Computers in Biology and Medicine*, Vol.129, 104165, 2021.
- [19] M. Pekala, N. Joshi, T. Y. A. Liu, N.M. Bressler, D. C. DeBuc, P. Burlina, “Deep learning based retinal OCT segmentation”, *Computers in Biology and Medicine*, Vol.114, 103445, 2019.
- [20] A. García-Floriano, Á. Ferreira-Santiago, O. Camacho-Nieto, C. Yáñez-Márquez, “A machine learning approach to medical image classification: Detecting age-related macular degeneration in fundus images”, *Computers & Electrical Engineering*, Vol.75, pp.218-229, 2019.
- [21] J. Sugmk, S. Kiattisin and A. Leelasantitham, "Automated classification between age-related macular degeneration and Diabetic macular edema in OCT image using image segmentation" *The 7th 2014 Biomedical Engineering International Conference*, Fukuoka, Japan, pp.1-4, 2014.
- [22] U. R. Acharya, M. R. K. Mookiah, J. E.W. Koh, J. H. Tan, S. V. Bhandary, A. K. Rao, Y. Hagiwara, C. K. Chua, A. Laude, “Automated diabetic macular edema (DME) grading system using DWT, DCT Features and maculopathy index”, *Computers in Biology and Medicine*, Vol.84, p.59-68, 2017.
- [23] A. Thomas, A. P. Sunija, R. Manoj, R. Ramachandran, S. Ramachandran, P. G. Varun, P. Palanisamy, “RPE layer detection and baseline estimation using statistical methods and randomization for classification of AMD from retinal OCT”, *Computer Methods and Programs in Biomedicine*, Vol.200, 105822, 2021.
- [24] V. Das, S. Dandapat, P. K. Bora, “Multi-scale deep feature fusion for automated classification of macular pathologies from OCT images”, *Biomedical Signal Processing and Control*, Vol.54, 101605, 2019.
- [25] S. Feng, W. Zhu, H. Zhao, F. Shi, D. Xiang, X. Chen, “VinceptionC3D: a 3D convolutional neural network for retinal OCT image classification”, *SPIE Medical Imaging (SPIE, 2019)*, Vol.10949, 2019.
- [26] O. Perdomo, H. Rios, F. J. Rodríguez, S. Otálora, F. Meriaudeau, H. Müller, F. A. González, “Classification of diabetes-related retinal diseases using a deep learning approach in optical coherence tomography”, *Computer Methods and Programs in Biomedicine*, Vol.178, pp.181-189, 2019.
- [27] C. S. Lee, D. M. Baughman, A. Y. Lee, “Deep Learning Is Effective for Classifying Normal versus Age-Related Macular Degeneration OCT Images”, *Ophthalmology Retina*, Vol.1(4), pp.322-327, 2017.
- [28] Peng, Y., Dharssi, S., Chen, Q., Keenan, T. D., Agrón, E., Wong, W. T., ... & Lu, Z. (2019). DeepSeeNet: a deep learning model for automated classification of patient-based age-related macular degeneration severity from color fundus photographs. *Ophthalmology*, 126(4), 565-575.
- [29] O. Perdomo, S. Otálora, F. A. González, F. Meriaudeau, H. Müller, "OCT-NET: A convolutional network for automatic classification of normal and diabetic macular edema using sd-oct volumes", 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), Washington, DC, USA, pp. 1423-1426, 2018.
- [30] L. Fang, Y. Jin, L. Huang, S. Guo, G. Zhao, X. Chen, “Iterative fusion convolutional neural networks for classification of optical coherence tomography images”, *Journal of Visual Communication and Image Representation*, Vol.59, pp.327-333, 2019.
- [31] N. Motozawa, G. An, S. Takagi, et al., “Optical Coherence Tomography-Based Deep-Learning Models for Classifying Normal and Age-Related Macular Degeneration and Exudative and Non-

- Exudative Age-Related Macular Degeneration Changes”, *Ophthalmology and Therapy*, Vol.8, pp.527–539, 2019.
- [32] Feng Li, Hua Chen, Zheng Liu, Xue-dian Zhang, Min-shan Jiang, Zhi-zheng Wu, and Kai-qian Zhou, "Deep learning-based automated detection of retinal diseases using optical coherence tomography images," *Biomed. Opt. Express* 10, 6204-6226 (2019)
- [33] Zhang, Q., Liu, Z., Li, J., & Liu, G. (2020). Identifying Diabetic Macular Edema and Other Retinal Diseases by Optical Coherence Tomography Image and Multiscale Deep Learning. *Diabetes, metabolic syndrome and obesity: targets and therapy*, 13, 4787–4800. <https://doi.org/10.2147/DMSO.S288419>
- [34] Kim, J., & Tran, L. (2021, October). Retinal Disease Classification from OCT Images Using Deep Learning Algorithms. In *2021 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB)* (pp. 1-6). IEEE.
- [35] A. Sharma, A. V. Khanna and M. Bhargava, "Multi-label classification of Retinal Disorders in Optical Coherence Tomography using Deep Learning," 2021 Second International Conference on Electronics and Sustainable Communication Systems (ICESC), 2021, pp. 1750-1757, doi: 10.1109/ICESC51422.2021.9532711.
- [36] 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(2), 401-415.
- [37] A. Haq, A. Fariza and N. Ramadijanti, "Automatic Detection of Retinal Diseases in Optical Coherence Tomography Images using Convolutional Neural Network," 2021 International Electronics Symposium (IES), 2021, pp. 343-348, doi: 10.1109/IES53407.2021.9594003.
- [38] Luo, Y., Xu, Q., Jin, R., Wu, M., & Liu, L. (2021). Automatic detection of retinopathy with optical coherence tomography images via a semi-supervised deep learning method. *Biomedical Optics Express*, 12(5), 2684-2702.
- [39] Arefin, R., Samad, M. D., Akyelken, F. A., & Davanian, A. (2021, August). Non-transfer Deep Learning of Optical Coherence Tomography for Post-hoc Explanation of Macular Disease Classification. In *2021 IEEE 9th International Conference on Healthcare Informatics (ICHI)* (pp. 48-52). IEEE..
- [40] Han, J., Choi, S., Park, J.I. *et al.* Classifying neovascular age-related macular degeneration with a deep convolutional neural network based on optical coherence tomography images. *Sci Rep* 12, 2232 (2022). <https://doi.org/10.1038/s41598-022-05903-7>
- [41] Yoon, J., Han, J., Ko, J. *et al.* Classifying central serous chorioretinopathy subtypes with a deep neural network using optical coherence tomography images: a cross-sectional study. *Sci Rep* 12, 422 (2022). <https://doi.org/10.1038/s41598-021-04424-z>
- [42] Upadhyay, P. K., Rastogi, S., & Kumar, K. V. (2022). Coherent convolution neural network based retinal disease detection using optical coherence tomographic images. *Journal of King Saud University-Computer and Information Sciences*
- [43] Ko, J., Han, J., Yoon, J. *et al.* Assessing central serous chorioretinopathy with deep learning and multiple optical coherence tomography images. *Sci Rep* 12, 1831 (2022). <https://doi.org/10.1038/s41598-022-05051-y>
- [44] Abdullahi, M. M., Chakraborty, S., Kaushik, P., & Sami, B. S. (2022, February). Detection of Dry and Wet Age-Related Macular Degeneration Using Deep Learning. In *2nd International Conference on Industry 4.0 and Artificial Intelligence (ICIAI 2021)* (pp. 211-214). Atlantis Press.

- [45] Chen, Y., He, Y., Wang, J., Xing, L., & Shi, G. (2021, November). Automated classification of retinal optical coherence tomography volumes based on RepVGG: Experimental validation for detection of dry age-related macular degeneration and diabetic macular edema. In *2021 2nd International Conference on Intelligent Computing and Human-Computer Interaction (ICHCI)* (pp. 299-302). IEEE.
- [46] Alqudah, A., Alqudah, A. M., & AlTantawi, M. (2021). Artificial Intelligence Hybrid System for Enhancing Retinal Diseases Classification Using Automated Deep Features Extracted from OCT Images. *International Journal of Intelligent Systems and Applications in Engineering*, 9(3), 91–100. <https://doi.org/10.18201/ijisae.2021.236>
- [47] Saleh, N., Abdel Wahed, M., & Salaheldin, A. M. (2021). Transfer learning-based platform for detecting multi-classification retinal disorders using optical coherence tomography images. *International Journal of Imaging Systems and Technology*.
- [48] Luo, Y., Xu, Q., Hou, Y., Liu, L., Wu, M., J. *Biophotonics* 2021, 14 (8), e202100096. <https://doi.org/10.1002/jbio.202100096>
- [49] Cheung, C. Y. L., Tang, F., Ran, A., Tan, G. S. W., Ting, D. S., Chen, H., ... & Wang, X. (2021). A Multi-Task Deep-Learning System to Classify Diabetic Macular Edema for Different Optical Coherence Tomography Devices: A Multi-Center Analysis. *Investigative Ophthalmology & Visual Science*, 62(8), 1033-1033.
- [50] Kim, K. M., Heo, T.-Y., Kim, A., Kim, J., Han, K. J., Yun, J., & Min, J. K. (2021). Development of a Fundus Image-Based Deep Learning Diagnostic Tool for Various Retinal Diseases. *Journal of Personalized Medicine*, 11(5), 321. <https://doi.org/10.3390/jpm11050321>
- [51] Mohammad, A., Utso, M. Z., Habib, S. B., & Das, A. K. (2021). Predicting Retinal Diseases using Efficient Image Processing and Convolutional Neural Network (CNN). *Journal of Engineering Advancements*, 2(04), 221–227. <https://doi.org/10.38032/jea.2021.04.008>
- [52] Yan, Y., Jin, K., Gao, Z., Huang, X., Wang, F., Wang, Y. and Ye, J. (2021), Attention-based deep learning system for automated diagnoses of age-related macular degeneration in optical coherence tomography images. *Med. Phys.*, 48: 4926-4934. <https://doi.org/10.1002/mp.15002>
- [53] Xu L, Wang L, Cheng S, Li Y (2021) MHANet: A hybrid attention mechanism for retinal diseases classification. *PLoS ONE* 16(12): e0261285. <https://doi.org/10.1371/journal.pone.0261285>
- [54] K. Thakoor, D. Bordbar, J. Yao, O. Moussa, R. Chen and P. Sajda, "Hybrid 3d-2d Deep Learning For Detection Of Neovascularage-Related Macular Degeneration Using Optical Coherence Tomography B-Scans And Angiography Volumes," *2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI)*, 2021, pp. 1600-1604, doi: 10.1109/ISBI48211.2021.9434111.
- [55] Russell, Stuart J.; Norvig, Peter (2003), *Artificial Intelligence: A Modern Approach* (2nd ed.), Upper Saddle River, New Jersey: Prentice Hall, ISBN 0-13-790395-2
- [56] M.E. Moran Evolution of robotic arms *J Robot Surg*, 1 (2007), pp. 103-111
- [57] J. Weizenbaum ELIZA—a computer program for the study of natural language communication between man and machine *Commun ACM*, 9 (1966), pp. 36-45
- [58] B.F. Kuipers, P.E. Hart, N.J. Nilsson Shakey: from conception to history *AI Magazine*, 38 (2017), pp. 88-103
- [59] C.A. Kulikowski Beginnings of artificial intelligence in medicine (AIM): computational artifice assisting scientific inquiry and clinical art—with reflections on present AIM challenges *Yearb Med Inform*, 28 (2019), pp. 249-256

- [60] C.A. Kulikowski An opening chapter of the first generation of artificial intelligence in medicine: the first Rutgers AIM workshop, June 1975 Yearb Med Inform, 10 (2015), pp. 227-233
- [61] S. Weiss, C.A. Kulikowski, A. Safir Glaucoma consultation by computer Comput Biol Med, 8 (1978), pp. 25-40
- [62] The Massachusetts General Hospital Laboratory of Computer Science. Using decision support to help explain clinical manifestations of disease Available at: <http://www.mghlcs.org/projects/dxplain>, Accessed 30th Apr 2020
- [63] D.L. Ferrucci, S. Bagchi, D. Gondek, *et al.* Watson: beyond *Jeopardy!* Artif Intell, 199-200 (2013), pp. 93-105
- [64] Nizam, H. ve ark. (2014). Sosyal Medyada Makine Öğrenmesi ile Duygu Analizinde Dengeli ve Dengesiz Veri Setlerinin Performanslarının Karşılaştırılması. XIX. Türkiye'de İnternet Konferansı.
- [65] Hinton G. ve Sejnowski T.J. (1999). Hinton G. ve Sejnowski T.J. (editorler), 1999, "Unsupervised Learning and Map Formation: Foundations of Neural Computation", MIT Press, ISBN 0-262-58168-X. MIT Press, ISBN 0-262- 58168-X.
- [66] D. Ravi *et al.*, "Deep Learning for Health Informatics," in *IEEE Journal of Biomedical and Health Informatics*, vol. 21, no. 1, pp. 4-21, Jan. 2017, doi: 10.1109/JBHI.2016.2636665.
- [67] H. R. Roth et al., "Improving computer-aided detection using convolutional neural networks and random view aggregation", *IEEE Trans. Med. Imag.*, vol. 35, no. 5, pp. 1170-1181, May 201
- [68] R. Fakoor, F. Ladhak, A. Nazi and M. Huber, "Using deep learning to enhance cancer diagnosis and classification", *Proc. Int. Conf. Mach. Learn.*, pp. 1-7, 2013.
- [69] J. L. Elman, "Finding Structure in Time," *Cogn. Sci.*, vol. 14, no. 2, pp. 179–211, Mar. 1990.
- [70] Y. Bengio, P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," *IEEE Trans. Neural Networks*, vol. 5, no. 2, pp. 157–166, Mar. 1994.
- [71] S. Hochreiter and J. Schmidhuber, "Long ShortTerm Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997.
- [72] Singh, D., Merdivan, E., Psychoula, I., Kropf, J., Hanke, S., Geist, M., Holzinger, A. (2017). Human Activity Recognition Using Recurrent Neural Networks. Paper presented at the International Cross-Domain Conference for Machine Learning and Knowledge Extraction.
- [73] Tokgöz, A. ve Ünal, G. (2018). Türkiye elektrik yükünü tahmin etmek için RNN tabanlı bir zaman serisi yaklaşımı. In 2018 26 Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU) (s. 1-4). IEEE.
- [74] R. R. Salakhutdinov, «Reducing the Dimensionality of Data with Neural Networks,» *Science*, cilt vol. 313, no. no. 5786, p. 504–507, Jul. 2006.
- [75] M. A. Carreira-Perpiñán and G. E. Hinton, "On Contrastive Divergence Learning," *Artif. Intell. Stat.*, vol. 10, 2005.
- [76] G. E. Hinton and R. R. Salakhutdinov, "Reducing the Dimensionality of Data with Neural Networks," *Science* (80-.), vol. 313, no. 5786, pp. 504–507, Jul. 2006
- [77] Y. Bengio, "Learning Deep Architectures for AI," *Found. Trends® Mach. Learn.*, vol. 2, no. 1, pp. 1–127, 2009.
- [78] A. Krizhevsky and G. E. Hinton, "Using Very Deep Autoencoders for Content Based Image Retrieval," in *European Symposium on Artificial Neural Networks*, 2011, pp. 489–494.
- [79] A. Seker and A. Gürkan YUKSEK, "Stacked Autoencoder Method for Fabric Defect Detection," *Sci. Sci. J.*, vol. 38, no. 2, 2017.
- [80] LeCun Y, Bengio Y, Hinton G, 2015, Deep learning, *Nature*, 521, 436-444.

- [81] Jan B, Farman H, Khan M, Imran M, Islam I U, Ahmad A, vd., 2019, Deep learning in big data analytics: a comparative study, *Computers and Electrical Engineering*, 75, 275-287.
- [82] Alzubaidi, L., Zhang, J., Humaidi, A.J. *et al.* Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data* 8, 53 (2021). <https://doi.org/10.1186/s40537-021-00444-8>
- [83] Tammina, S. (2019). Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images. *International Journal of Scientific and Research Publications (IJSRP)*, 9(10), p9420. <https://doi.org/10.29322/ijsrp.9.10.2019.p9420>
- [84] Hou, Z.H.; Fang, H.J. Robust fault-tolerant control for networked control system with packet dropout. *J. Syst. Eng. Electron.* **2007**, 18, 76–82.
- [85] Yang, J., & Yang, G. (2018). Modified Convolutional Neural Network Based on Dropout and the Stochastic Gradient Descent Optimizer. *Algorithms*, 11(3), 28. <https://doi.org/10.3390/a11030028>
- [86] A. Krizhevsky I. Sutskever and G.E. Hinton "ImageNet Classification with Deep Convolutional Neural Networks" *Adv. Neural Inf. Process. Syst.* pp. 1-9 2012
- [87] Ramzan, Farheen & Khan, Muhammad Usman & Rehmat, Asim & Iqbal, Sajid & Saba, Tanzila & Rehman, Amjad & Mehmood, Zahid. (2019). A Deep Learning Approach for Automated Diagnosis and Multi-Class Classification of Alzheimer's Disease Stages Using Resting-State fMRI and Residual Neural Networks. *Journal of Medical Systems*. 44. 10.1007/s10916-019-1475-2.
- [88] Ali, L., Alnajjar, F., Jassmi, H. A., Gochoo, M., Khan, W., & Serhani, M. A. (2021). Performance evaluation of deep CNN-based crack detection and localization techniques for concrete structures. *Sensors*, 21(5), 1688.
- [89] Chen, Jiayao & Zhou, Mingliang & Zhang, Dongming & Huang, H. & Zhang, Fengshou. (2021). Quantification of water inflow in rock tunnel faces via convolutional neural network approach. *Automation in Construction*. 123. 103526. 10.1016/j.autcon.2020.103526.
- [90] Kasim, Nur & Rahman, Nur & Ibrahim, Zaidah & Abu Mangshor, Nur Nabilah. (2018). Celebrity Face Recognition using Deep Learning. *Indonesian Journal of Electrical Engineering and Computer Science*. 12. 476-481. 10.11591/ijeeecs.v12.i2.pp476-481.
- [91] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size", *arXiv Prepr. arXiv1602.07360*, pp. 1–13, 2016.
- [92] Seidaliyeva, Ulzhalgas & Akhmetov, Daryn & Ilipbayeva, Lyazzat & Matson, Eric. (2020). Real-Time and Accurate Drone Detection in a Video with a Static Background. *Sensors*. 20. 3856. 10.3390/s20143856.
- [93] DenseNet: Better CNN model than ResNet. Available: <http://www.programmersought.com/article/7780717554/>
- [94] Kermany D, Goldbaum M, Cai W et al. Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. *Cell*. 2018; 172(5):1122-1131. doi:10.1016/j.cell.2018.02.010.
- [95] Peyman Gholami, Priyanka Roy, Mohana Kuppaswamy Parthasarathy, Vasudevan Lakshminarayanan, "OCTID: Optical Coherence Tomography Image Database", *arXiv preprint arXiv:1812.07056*, (2018). For more information and details about the database see: <https://arxiv.org/abs/1812.07056>
- [96] B. Chandra, Chapter 3 - Gene Selection Methods for Microarray Data, Editor(s): Dhiya Al-Jumeily, Abir Hussain, Conor Mallucci, Carol Oliver, In *Emerging Topics in Computer Science and Applied*

- Computing, Applied Computing in Medicine and Health, Morgan Kaufmann, 2016, Pages 45-78, ISBN 9780128034682, <https://doi.org/10.1016/B978-0-12-803468-2.00003-5>.
- [97] Daliri MR. Feature selection using binary particle swarm optimization and support vector machines for medical diagnosis. *Biomedizinische Technik/Biomedical Engineering*, 2012, 57(5):395–402.
 - [98] K. Kira, L.A. Rendell, A practical approach to feature selection, in: *Proceedings of the Ninth International Workshop on Machine Learning*, 1992b, pp. 249–256.
 - [99] Cui, X., Li, Y., Fan, J. *et al.* Rölyefe dayalı yeni bir filtre özelliği seçim algoritması. *Appl Intell* **52**, 5063–5081 (2022). <https://doi.org/10.1007/s10489-021-02659-x>
 - [100] Chan GCY, Kamble R, Muller H, Shah SAA, Tang TB, Meriaudeau F. Fusing results of several deep learning architectures for automatic classification of Tong et al. *Eye and Vision* (2020) 7:22 Page 14 of 1566 normal and diabetic macular edema in optical coherence tomography. *Conf Proc IEEE Eng Med Biol Soc.* 2018;2018:670–3
 - [101] Hassan, B., Hassan, T., Li, B., Ahmed, R., & Hassan, O. (2019). Deep ensemble learning based objective grading of macular edema by extracting clinically significant findings from fused retinal imaging modalities. *Sensors*, 19(13), 2970.
 - [102] Dos Santos VA, Schmetterer L, Stegmann H, Pfister M, Messner A, Schmidinger G, et al. CorneaNet: fast segmentation of cornea OCT scans of healthy and keratoconic eyes using deep learning. *Biomed Opt Express*. 2019;10(2):622–41.
 - [103] Asaoka R, Murata H, Hirasawa K, Fujino Y, Matsuura M, Miki A, et al. Using deep learning and transfer learning to accurately diagnose early-onset glaucoma from macular optical coherence tomography images. *Am J Ophthalmol*. 2019;198:136–45.
 - [104] Tsuji, T., Hirose, Y., Fujimori, K., Hirose, T., Oyama, A., Saikawa, Y., ... & Kotoku, J. I. (2020). Classification of optical coherence tomography images using a capsule network. *BMC ophthalmology*, 20(1), 1-9.
 - [105] Thomas, A., Harikrishnan, P., Krishna, A. K., Palanisamy, P., & Gopi, V. P. (2021). Automated Detection of Age-Related Macular Degeneration from OCT Images Using Multipath CNN. *Journal of Computing Science and Engineering*, 15(1), 34-46.
 - [106] Ko, J., Han, J., Yoon, J., Park, J. I., Hwang, J. S., Han, J. M., ... & Hwang, D. D. J. (2022). Assessing central serous chorioretinopathy with deep learning and multiple optical coherence tomography images. *Scientific Reports*, 12(1), 1-8.

ÖZGEÇMİŞ

Mümtaz KORKMAZ

[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]

ARAŞTIRMA DENEYİMİ

- ✓ Kullandığınız laboratuvar cihazları, bildiğiniz deney sistemleri gibi bilgiler veriniz
- ✓ Bildiğiniz bilgisayar programlama dillerini yazınız (C-C++, MATLAB, PYHTON, vb.)
- ✓ Kullanabildiğiniz bilgisayar programlarını yazınız (CAT/CAM, PROTEUS, CALCULUS, vb.)