

**RETİNAL HASTALIKLARIN OFTALMOLOJİK
GÖRÜNTÜLER ÜZERİNDEN DERİN ÖĞRENME
TEKNİKLERİ İLE TESPİT EDİLMESİ**

YÜKSEK LİSANS TEZİ

Safiye Pelin TAŞ

Danışman

Dr. Öğr. Üyesi Gür Emre GÜRAKSIN

BİYOMEDİKAL MÜHENDİSLİĞİ

ANABİLİM DALI

Temmuz 2021

**AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**RETİNAL HASTALIKLARIN OFTALMOLOJİK GÖRÜNTÜLER
ÜZERİNDEN DERİN ÖĞRENME TEKNİKLERİ İLE TESPİT
EDİLMESİ**

Safiye Pelin TAŞ

Danışman

Dr. Öğretim Üyesi Gür Emre GÜRAKSIN

**BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI**

Temmuz 2021

TEZ ONAY SAYFASI

Safiye Pelin TAŞ tarafından hazırlanan “Retinal Hastalıkların Oftalmolojik Görüntüler Üzerinden Derin Öğrenme Teknikleri ile Tespit Edilmesi” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 14 / 07 / 2021 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Biyomedikal Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Gür Emre GÜRAKSIN

Başkan : Dr. Öğr. Üyesi Asım Sinan YÜKSEL
Süleyman Demirel Üniversitesi,
Mühendislik Fakültesi



Üye : Dr. Öğr. Üyesi Gür Emre GÜRAKSIN
Afyon Kocatepe Üniversitesi,
Mühendislik Fakültesi



Üye : Dr. Öğr. Üyesi Ahmet Haşim YURTTAKAL
Afyon Kocatepe Üniversitesi,
Mühendislik Fakültesi



Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. İbrahim EROL
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

24 / 06 / 2021



Safiye Pelin TAŞ

ÖZET

Yüksek Lisans Tezi

RETİNAL HASTALIKLARIN OFTALMOLOJİK GÖRÜNTÜLER ÜZERİNDEN DERİN ÖĞRENME TEKNİKLERİ İLE TESPİT EDİLMESİ

Safiye Pelin TAŞ

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Dr. Öğretim Üyesi Gür Emre GÜRAKSIN

Retina, görmeyi sağlayan ışığa ve renge duyarlı hücreleri ve sinir liflerini içeren göz tabakasıdır. Retinada oluşan bozukluklar görme kayıplarına ve körlüğe neden olabilecek hastalıklara yol açar. Bu yüzden bu hastalıkların teşhisi ve tedavisi oldukça önemlidir. Günümüzde, retinada oluşan bozuklukların tanısına yardımcı olmak amacıyla optik koherans tomografi ve fundus floresein anjiyografi görüntüleme teknikleri kullanılmaktadır. Bu tekniklere ek olarak gelişen teknolojiyle birlikte bu görüntüleri analiz etmeye yardımcı olabilecek derin öğrenme tabanlı uygulamalarının geliştirilmesi de literatürde önemli bir yer edinmiştir. Yapılan literatür taraması da göze alınarak bu çalışmada, retinada oluşan hastalıkların optik koherans tomografi görüntülerinden teşhisi için görüntü ön işleme ve bir derin öğrenme yöntemi olan evrişimsel sinir ağları (ESA)'na dayalı hibrit bir yöntem önerilmiştir. Hastalık teşhisi ve sınıflandırma için 5 katmanlı ESA mimarisi oluşturulmuştur. Önerilen yöntemin retinal hastalıkların teşhisinde %99,45 oranında başarı sağladığı görülmüştür. Elde edilen başarı dikkate alındığında önerilen yöntemin retinal hastalıkların teşhisinde klinik ortamda hekimlere yardımcı olabilecek bir karar destek sistemi olabileceği görülmektedir.

2021, viii + 69 sayfa

Anahtar Kelimeler: Derin öğrenme, Evrişimsel sinir ağları, Yapay zeka, Oftalmoloji, Optik koherans tomografi

ABSTRACT

M.Sc. Thesis

DETECTION OF RETINAL DISEASES ON OPHTHALMOLOGICAL IMAGES BY DEEP LEARNING TECHNIQUES

Safiye Pelin TAŞ

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Biomedical Engineering

Supervisor: Asst. Prof. Gür Emre GÜRAKSIN

The retina is the layer of the eye that contains the light and color sensitive cells and nerve fibers that provide vision. Defects in the retina lead to diseases that can cause vision loss and blindness. Therefore, diagnosis and treatment of these diseases is very important. Today, optical coherence tomography (OCT) and fundus fluorescein angiography (FFA) imaging techniques are used to help diagnose retinal disorders. In addition to these techniques, the development of deep learning-based applications that can help analyze these images with the developing technology has also gained an important place in the literature. Considering the literature review, in this study, a hybrid method based on image preprocessing and a deep learning method, convolutional neural networks (ESA), is proposed for the diagnosis of retinal diseases from OCT images. An 5-layer ESA architecture has been created for disease diagnosis and classification. It has been observed that the proposed method has a success rate of 99.45% in the diagnosis of retinal diseases. Considering the success achieved, it is seen that the proposed method can be a decision support system that can help physicians in the clinical setting in the diagnosis of retinal diseases.

2021, viii + 69 pages

Keywords: Deep learning, Convolutional neural networks, Artificial intelligence, Ophthalmology, Optical coherence tomography

TEŐEKKÜR

Bu arařtırmanın konusu, deneysel alıřmaların ynlendirilmesi, sonuların deęerlendirilmesi ve yazımı ařamasında yapmıř olduęu byk katkılarında dolay tezdaniřmanım Sayın Dr. đretim yesi Gr Emre GRAKSIN, arařtırma ve yazım sresince yardımlarını esirgemeyen Sayın Arř. Gr. Sezin BARIN'a her konuda neri ve eleřtirileriyle yardımlarını grdđm hocalarıma teőekkr ederim.

Manevi desteklerinden dolay Emine YAŐAR, Břra DALKILIN ve zlem KARAMAN'a teőekkr ederim.

Bu arařtırma boyunca maddi ve manevi desteklerinden dolay aileme teőekkr ederim.

Safiye Pelin TAŐ
Afyonkarahisar 2021

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
KISALTMALAR DİZİNİ	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ.....	viii
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	7
3. MATERYAL ve METOT	15
3.1 Yapay Sinir Ağları (YSA).....	15
3.2 Derin Öğrenme	20
3.2.1 Evrişimli Sinir Ağları.....	25
3.2.1.1 Evrişimli Katman.....	27
3.2.1.2 Aktivasyon Fonksiyonları.....	29
3.2.1.3 Havuzlama Katmanı	31
3.2.1.4 Düzleştirme Katmanı	33
3.2.1.5 Tamamen Bağlı Katman	33
3.2.1.6 Kayıp Fonksiyonları	34
3.2.1.7 ESA'ları Düzenleme	35
3.2.1.8 ESA'ların Öğrenme Süreci	36
3.3 Önerilen Sistem.....	38
3.3.1 Veri Seti	39
3.3.2 Veri Ön İşleme	41
3.3.3 Önerilen ESA Modeli.....	47
3.3.3.1 Modelin Eğitilmesi	48
4. BULGULAR	50
5. TARTIŞMA ve SONUÇ	58
6. KAYNAKLAR.....	61
ÖZGEÇMİŞ.....	69

KISALTMALAR DİZİNİ

Kısaltmalar

AMD	Age related macular degeneration – Yaşa bađlı maküla denjenarasyonu
DME	Diabetic Macular Edema- Diyabetik maküla ödemi
DR	Diabetic retinopathy – Diyabetik retinopati
ESA	Evrişimli sinir ađları
FFA	Fundus fluorescein angiography – Fundus floresein anjiyografi
GAP	Global average pooling – Küresel ortalama havuzlama
OCT	Optical coherence tomography – Optik koherans tomografi
RELU	Rectified linear unit – Doğrultulmuş lineer birim

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1 FFA retinal hastalıkların görüntüleri.....	3
Şekil 1.2 OCT görüntüleri ve hastalıklar	4
Şekil 1.3 Yapay zekânın gelişimi.	6
Şekil 2.1 Son 8 yıldır yayınlanan ESA ve OCT tabanlı yayın sayısı	7
Şekil 3.1 Nöronun biyolojik gösterimi	16
Şekil 3.2 Yapay sinir ağının genel yapısı	17
Şekil 3.3 Yapay sinir ağının matematiksel gösterimi.....	18
Şekil 3.4 İleri besleme sinir ağının şematik gösterimi	19
Şekil 3.5 Geri besleme sinir ağının şematik gösterimi.....	19
Şekil 3.6 Derin Denetimli Öğrenme Gösterimi.....	21
Şekil 3.7 Yarı Denetimli Derin Gösterme Akış Şeması.....	22
Şekil 3.8 Denetimsiz Derin Öğrenme Akış Şeması	23
Şekil 3.9 Pekiştirmeli Derin Öğrenme Akış Şeması	24
Şekil 3.10 ESA Konfigürasyonu	26
Şekil 3.11 Örnek bir ESA mimarisi.	27
Şekil 3.12 Evrişimli katmanın her adımında gerçekleştirilen birincil hesaplamalar.....	29
Şekil 3.13 Aktivasyon fonksiyonları a) ReLU, b) Sigmoid ve c) Tanh	31
Şekil 3.14 Havuzlama teknik ve yöntemleri	32
Şekil 3.15 Düzleştirme tekniği.	33
Şekil 3.16 Tam bağlı katman şematik gösterimi	34
Şekil 3.17 Çalışma Diyagramı.....	39
Şekil 3.18 Veri setinden bazı örnekler	41
Şekil 3.19 Arka fon doldurma işlemi	42
Şekil 3.20 Orijinal görüntü ve kontrast sınırlı uyarlamalı histogram eşitleme uygulanmış görüntünün histogram dağılımı.....	44
Şekil 3.21 Maskeleyme işlem süreci	45
Şekil 3.22 Gürültü giderme teknikleri uygulanan görüntüler	46
Şekil 3.23 ESA modeli genel şeması	47
Şekil 4.1 Eğitim sonucunda elde edilen doğruluk ve kayıp grafiği.....	51
Şekil 4.2 Hata matrisi	53
Şekil 4.3 Görüntü işleme teknikleri uygulanmayan görüntüler ile eğitilen ESA mimarisinden elde edilen doğruluk ve kayıp grafikleri	55

Şekil 4.4 Ön işleme teknikleri uygulanmayan görüntüler ile eğitilen ESA mimarisinin hata matrisi.....	56
--	----

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1 Veri kümesinin açıklanması.....	40
Çizelge 3.2 ESA mimarisindeki katmanların çıktı değerleri.....	48
Çizelge 3.3 Modelde kullanılan eğitim parametreleri	49
Çizelge 4.1 Modelin performans değerleri.....	54
Çizelge 4.2 Modelin değerlendirme parametreleri.....	54
Çizelge 4.3 Ön işleme teknikleri uygulanmayan görüntüler ile eğitilen ESA mimarisinin performans değerleri.	56
Çizelge 4.4 Ön işleme teknikleri uygulanmayan görüntüler ile eğitilen ESA mimarisinin değerlendirme parametreleri	57
Çizelge 5.1 Literatürde Kermany vd. (2018) tarafından kullanılan halka açık kaynaklı optik koherens tomografi görüntüleri veri seti ile yapılan çalışmalar.....	59

1. GİRİŞ

Retina, doğrudan beyinle bağlantılı görmeyi sağlayan ışığa ve renge duyarlı hücreleri ve sinir liflerini içeren göz tabakasıdır. Algılanan görsel sinyallerin yorumlanabilmesi için beyne aktarır ve bu şekilde görme eyleminin tamamlanmasına yardımcı olur (Kermany vd. 2018). Bu sebeple retinada oluşabilecek bozukluklar görme kayıplarına ve körlüğe neden olabilecek hastalıklara yol açar. Aynı zamanda retinal hastalıkların görme duyusu üzerindeki etkisinin yanı sıra, kalp hastalıkları ve hipertansiyon gibi hastalıklara da yol açtığı bilinmektedir (Miranda vd. 2019). Bu tür olumsuzlukların engellenmesi veya en aza indirgenmesi için erken teşhis ve tedavi oldukça önemlidir.


Önemli retina hastalıklarına yaşa bağlı maküla dejenerasyonu (Age Related Macular Degeneration, AMD), drusen, diyabetik retinopati (Diabetic Retinopathy, DR), diyabetik maküler ödem (Diabetic Macular Edema, DME), miyopik koroidal neovaskülarizasyon (Myopic Choroidal Neovascularization CNV) örnek olarak verilebilir. Bu hastalıklardan AMD retinanın merkezinde yer alan maküla isimli görüş netliği ve keskinliği sağlayan tabakanın hasar görmesi sonucu ortaya çıkan bir retina hastalığıdır. 50 yaş ve üzeri kişilerde sıkça karşılaşılan bu hastalık görme kayıplarına sebep olabilmektedir. (Mishra vd. 2019). Yapılan araştırmalarda maküla dejenerasyonu ile yaşayan insan sayısının 2040 yılına kadar dünya çapında 288 milyona ulaşması beklenmektedir (Berrimi vd. 2020). Maküla dejenerasyonu kuru ve ıslak olarak ikiye ayrılır. Kuru AMD en sık görülen tiptir. Kuru AMD maküla dokularının yaşlanması ve incelmeye, drusen isimli protein kümelerini biriktirmesi veya her iki sebepten dolayı zarar görmesi sonucu ortaya çıkar. Granül veya amorf materyal birikintisi olan yumuşak drusen, AMD'nin öncüsü olarak kabul edilmektedir. (Sunija vd. 2021). Kuru AMD'de hastalığın şiddeti, drusen lezyon sayısı, boyutu ve yoğunluğuna bağlıdır. Islak AMD ise kuru AMD'nin daha ilerlemiş bir halidir. Retina altında yeni, anormal kan damarları oluşur ve büyür. Bu damarlar kan veya sıvı sızdırarak makülada iz kalmasına sebep olur (Wang vd. 2019). Diğer bir retinal hastalık türü olan DR ise retinadaki kan damarlarının, şeker hastalığına veya yüksek tansiyona bağlı olarak hasar görmesidir. Çalışma çağındaki yetişkinlerin büyük bir bölümünü etkileyen ilerleyici bir göz hastalığıdır (Abidalkareem vd. 2020). DR' de kan damarları büyür ve sızıntı

yapabilirler. Hatta kanın geçmesine engel olarak ödem oluşmasına sebep olabilirler. İleri safhada retinada yeni kan damarları oluşabilmekte ani göz içi kanamaları meydana gelebilmektedir. Bu semptomlar iki gözde de görülebilir. Ayrıca DR insan gözünde farklı rahatsızlıklara da sebep olabilir (Ishtiaq vd. 2019). Örneğin DME diyabetik retinopati kaynaklı bir retinal hastalıktır. DR' de görülen kan damarlarındaki sızıntı birikip retinada ödem oluşturabilir ve bunun sonucunda DME hastalığı ortaya çıkabilir (Varma vd. 2014). Son olarak bahsi geçen CNV ise göz arkasında bulunan kan damarlarının düzgün büyümemesi sonucu oluşur. Görme kaybına yol açan, görmeyi tehdit eden çok yaygın bir hastalıktır. Bruch membranındaki bir kırılma yoluyla koroidden çıkan yeni kan damarları retina altı pigment epiteline veya subretinal boşluğa doğru büyür (Berrimi vd. 2020). Zamanla bu damarlar patlayarak retina içerisine kan ve sıvı sızıntısına neden olabilir (Wang vd. 2020). Sızıntının sonucunda görüş bozulması ve görüntünün bulanıklaşması gibi belirtiler meydana gelebilir.

Günümüzde, bu hastalıkların tanısına yardımcı olmak amacıyla fundus florescin anjiyografi (fundus fluorescein angiography, FFA) ve optik koherans tomografi (optical coherence tomography, OCT) görüntüleme teknikleri kullanılmaktadır.

Fundus florescin anjiyografi, kana el veya kol damarları üzerinden florescin isimli boyanın verilmesi ile retinadaki damarlarda bu maddenin hareketinin izlenmesi mantığına dayanır (Gupta 2011). İlk olarak florescin boya damardan verilir ve vücutta yayılması beklenir. Boya retinaya ulaştıktan sonra özel uyarma ve bariyer filtrelerine sahip fundus kamera ile anlık görüntüler çekilir. Kameradan görüntü alınabilmesi için öncelikle retinada yayılan florescin boyanın bu görüntüleme sistemi tarafından uyarılması gerekir. Sistem içindeki kamera flaşından çıkan beyaz ışık mavi filtreden geçirilerek göze gönderilir. Burada mavi ışık florescin tarafından emilir ve sarı-yeşil dalga boyuna sahip ışınlar dönüşür. Bu şekilde uyarılma işlemi tamamlanmış olur. Daha sonra hem sarı-yeşil florescin ışınları hem de florescin içermeyen göz dokularından gelen mavi ışınlar sisteme geri döner. Bu aşamada devreye sarı-yeşil bariyer filtre girer ve mavi ışının geçmesine engel olarak sadece florescin boyanın görüntülenmesini sağlar. Görüntü siyah ve beyaz piksellerden oluşur. Boyanın olduğu kısımlar beyaz diğer yerler ise siyahtır (Khohtali vd. 2016). Görüntü bir uzman


tarafından floreseinin retina damarlarındaki hareketine göre incelenir ve hastalık teşhisi yapılır. Şekil 1.1’de FFA ile çekilen retina görüntüleri gösterilmiştir.



Şekil 1.1 FFA retinal hastalıkların görüntüleri (Kermany vd. 2018).

Optik koherans tomografi ise göze kızıl ötesi ışınlar gönderilerek mikron düzeyde yüksek çözünürlüklü, invazif olmayan bir görüntü elde etme tekniğidir (Rawat vd. 2014). Tomografik kesitler alarak gözün tüm katmanlarının 3 boyutlu görüntülenmesini sağlar. Bu katmanlar bir uzman tarafından boyut, kalınlık, şekil vb. gibi özelliklerine göre incelenerek retinal hastalıklar tespit edilebilir (Zhang vd. 2019). OCT gözün kızıl ötesi bir ışıkla taranması ve geri dönen ışığın özel bir sistem yardımıyla toplanıp matematiksel ifadelerle yorumlanıp görüntü oluşturulması mantığına dayanır. Düşük yoğunluklu bir ışık kaynağından çıkan ışınlar bir ışın bölücü yardımıyla hem göze hem de referans sisteme gönderilir (Hassan vd. 2015). Gözden geri yansıyan ışınlar ile referans sistemden geri yansıyan ışınlar karşılaştırılıp yorumlanır ve görüntüye dönüştürülür. OCT’de daha detaylı görüntülerin elde edilmesi OCT-A taraması sayesinde olur. Sonuç olarak görüntülenmesi istenilen alan, bahsi geçen sistem tarafından taranır. Enine görüntüler ise elde edilen OCT-A görüntülerinin yan yana sırasıyla birleştirilmesiyle oluşturulur (Rawat vd. 2014). Şekil 2.2 de OCT ile çekilmiş

retina görüntüleri verilmektedir.



Şekil 2.2 OCT görüntüleri ve hastalıklar (Kermany vd. 2018).

Bahsedilen bu iki görüntüleme tekniği retinal hastalıkların teşhisinde sıkça kullanılmaktadır. Ancak bu iki sistemin birbirine göre artı ve eksi yönleri bulunmaktadır. FFA şuan için eski, sınırlı kullanıma sahip, yavaş ve invazif bir görüntüleme tekniğidir. OCT ise yeni gelişen, hızlı ve invazif olmayan bir sistemdir. FFA'ya göre daha geniş bir kılcal yapıyı değerlendirebilmesinin yanı sıra anatomik olarak kesin bir bölge ve gözün tüm katmanlarıyla ilgili daha detaylı bilgileri verir (Taş vd. 2021). Ayrıca son zamanlarda akademik çalışmalarda daha çok yer edinmeye başlamıştır. Bu akademik çalışmalar sayesinde OCT veri setlerine ulaşım daha kolay hale gelmiştir. Yapılan bu araştırmalar göz önünde bulundurularak retinal hastalıkların teşhisi için önerilen sistemde OCT ile elde edilen oftalmolojik görüntülerin kullanımına karar verilmiştir.

Her iki görüntüleme tekniği ile elde edilen oftalmolojik görüntülerin analizinin zaman alıcı, maliyetli ve insan hatasına açık olması kaçınılmazdır. Retinada oluşan hastalıklar görüntüleme teknikleri sayesinde bir uzmanın bilgi, tecrübe ve deneyimlerine dayanarak taranır ve tespit edilebilir. Bu aşamada uzmanların gözden kaçırıp değerlendiremediği bulgular yanlış teşhise yol açabilir. Ayrıca uzmanlar tarafından görüntülerde rastlanan


hastalık belirtileri bir başka retinal hastalığın bulguları ile karıştırılabilir. Örneğin diyabetik retinopati hastalığının belirtileri, damar yırtılması veya miyopik koroidal neovaskülarizasyon hastalığının belirtileri ile birbirine çok yakındır. Uzman, DR hastalığına sahip bir kişinin retinal görüntülerini incelerken bu benzerliklerden dolayı yanlış kararlar verebilir ve hastanın yanlış bir tedavi görmesine sebep olabilir. Bahsi geçen temel problemler göz önüne alındığında, dezavantajları en aza indirgeyecek ve klinik ortamda hekimlere destek olabilecek yapay zekâ tabanlı çalışmalara oldukça ihtiyaç duyulmaktadır.

Yapay zekâ (YZ) genellikle düşünce, derin öğrenme, adaptasyon, kalıtım ve duyuşsal anlayış gibi insan zekâsı tarafından desteklenen mekanizmaları taklit eden hesaplama teknolojilerinde kullanılan bir tekniktir. Ulusal güvenlik, sağlık hizmetleri, eğitim, ulaşım gibi birçok sektörde farklı uygulamalarda kullanılmaktadır. Fakat son zamanlarda özellikle sağlık alanında oldukça dikkat çekmeyi başarmıştır. Hatta bu anlamda YZ, sağlık hizmetleri, halk sağlığı ve küresel sağlık da dâhil olmak üzere dönüştürücü ve küresel etkileri olan "dördüncü sanayi devrimi" olarak da tanımlanmıştır (Murphy vd. 2021). Yapay zekânın sağlık alanında bu şekilde adını duyurmasında modern bilgisayarların yüksek derece geliştirilmiş hesaplama gücü ve sahip olunan büyük miktarda dijital veri havuzu gibi faktörlerinde önemli etkileri vardır. Tıpta yapay zekâ modelleri, biyomedikal araştırma ve klinik uygulamalarda potansiyel risk modelleme ve tabakalandırma, kişiselleştirilmiş tarama, teşhis (moleküler hastalık alt tiplerinin de sınıflandırılması dâhil olmak üzere), tedaviye yanıt tahmini gibi çeşitli alanlarda kullanılmaktadır (Castiglioni vd. 2021). YZ hastalığı tespit etmek ve klinik kararlara rehberlik etmek için farklı modalitelerde büyük hacimli verileri alabilir, analiz edebilir ve raporlayabilir (Secinaro vd. 2021). Tıpta yapay zekânın potansiyeli sınırsızdır ve klinik uygulamada sağlık hizmeti sunumunu iyileştirmek için büyük bir potansiyel mevcuttur.

Yapay zekânın algoritmik gelişimine bakıldığında ise karşımıza makine öğrenimi ve derin öğrenme kavramları çıkmaktadır.

Makine öğrenimi en temel anlamıyla verileri ayrıştıran, bu verilerden öğrenen ve

ardından öğrendiklerini bilinçli kararlar vermek için uygulayan algoritmaları içeren bir yapay zekâ alt uygulamasıdır. Makinelerin deneyimlerine (verilerine) dayalı olarak öğrenmesine ve tahminlerde bulunmasına olanak tanır. Derin öğrenme ise, kendi başına akıllı kararlar alabilen ve öğrenebilen bir "yapay sinir ağı" oluşturmak için katmanlardaki algoritmaları yapılandıran bir makine öğrenimi alt alanıdır. Derin öğrenme modelleri bir roket motoru olarak düşünülürse onun yakıtı, bu algoritmalara beslediğimiz muazzam miktarda veri kaynağıdır. Şekil 3.3’de yapay zekanın gelişime ait bir görsel verilmiştir.

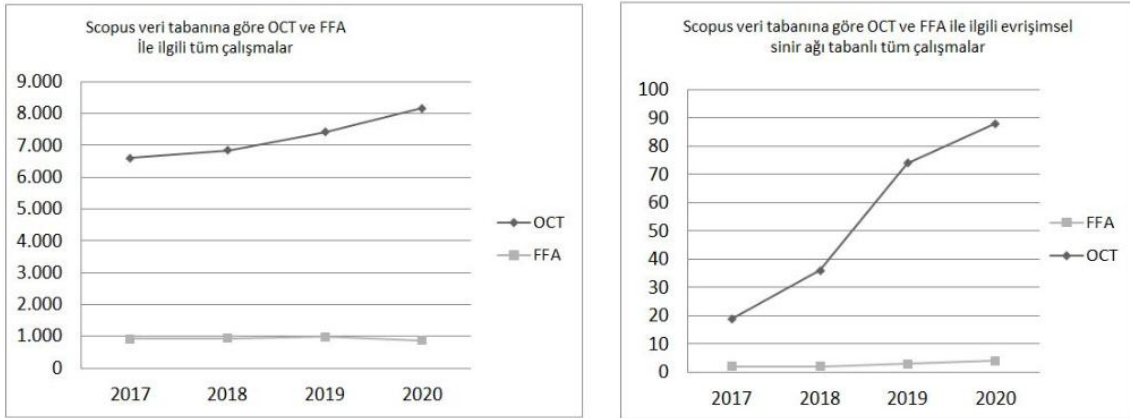


Şekil 3.3 Yapay zekânın gelişimi (İnt.Kyn. 3).

Bu çalışmada yukarıda anlatılan ön araştırmalar dikkate alınarak retinal hastalıkların (CNV, DME, DRUSEN, NORMAL) sınıflandırılması ve tanımlanması için görüntü ön işleme ve 5 katmanlı derin sinir ağı mimarisine dayanan bilgisayar destekli bir yöntem önerilmiştir. Önerilen yöntemin eğitimi ve testi için 83.484 görüntü ve 4 kategoriden oluşan bir veri seti kullanılmıştır.

2. LİTERATÜR BİLGİLERİ

Bir önceki bölümde retina yapısını görüntülemek için altın standart konumunda olan iki görüntüleme tekniğinden ve son zamanlarda görüntüler üzerinde en çok çalışılan alan olan derin öğrenme yönteminden bahsedilmiştir. Yapılan literatür araştırması sonucunda OCT görüntüleme tekniğinin güncel ve gelişen bir yöntem olduğuna karar verilmiştir. Literatürde OCT ve FFA ile ilgili yayımlanan tüm çalışmaların oranlarına da bakıldığında 2020 yılında 2019 yılına göre fundus görüntüleri ile yapılan çalışmalar %25 oranında azalırken OCT yayınlarında %20 oranında arttığı gözlenmiştir (İnt.Kyn. 6). Ayrıca OCT görüntüleri ve evrişimsel sinir ağları üzerine yayımlanan yayınların sayısının FFA görüntüleri kullanılarak çalışılan yayınlara göre çok daha fazla olduğu da Şekil 2.1'de görülmektedir. Yapılan çalışma istatistiklerine bakıldığında OCT görüntüleme tekniğinin oldukça hızlı gelişen, popüler bir alan olduğu görülebilmektedir.



Şekil 2.1 Son 4 yıldır OCT ve FFA görüntüleri kullanılarak yayımlanan tüm çalışmaların ve bu görüntüler ile birlikte ESA kullanılarak yapılan çalışmaların grafik üzerinde gösterilmesi.

Yukarıda da önemi belirtildiği üzere OCT görüntüleri ile yapılan derin öğrenme çalışmaları literatürde oldukça geniş bir yer kaplamaktadır. Aşağıda 2018-2020 yılları arasında optik koherans tomografi görüntüleme tekniğine ait oftalmolojik görüntüler ve ESA mimarileri kullanılarak yapılan çalışmalara örnekler verilmiştir.

Li vd. (2019) retinadaki CNV, DME ve kuru tip AMD hastalıklarını tespit etmek için evrişimli sinir ağları (ESA) tabanlı bir uygulama geliştirmişlerdir. Bu çalışma için 2013-

2017 yılları arasında California San Diego Üniversitesi Shiley Eye Enstitüsü, California Retina Araştırma Vakfı, Tıp Merkezi Oftalmoloji Associates, Pekin Tongren Göz Merkezi ve Şanghay İlk Halk Hastanesi'nde tedavi gören 5.319 yetişkin hastanın OCT görüntüleri kullanılmıştır. Deney için 109.312 görüntü seçilmiştir ve bu görüntüler 4 kategoriye (CNV, DME, DRUSEN, NORMAL) ayrılmıştır. Bu görüntülerin 37.546'sı CNV 11.599 'u DME, 11.599'u drusen hastalarına, 51.390'nı ise sağlıklı bireylere aittir. Alınan görüntüler ön işlemlere tabi tutulduktan sonra 633 hastadan 1000 görüntü (her kategoriden 250 görüntü) doğrulama veri seti olarak, geriye kalan 4.689 hastanın görüntüleri ise eğitim veri seti olarak ayrılmıştır. Çalışma için ImageNet veri tabanında önceden eğitilmiş VGG-16 ESA mimarisi kullanılmıştır. Transfer öğrenme yöntemi ile VGG-16 ağıнын ağırlıkları hastalardan alınan görüntüler ile yeniden eğitilmiştir. Yapılan bu çalışma sonucunda OCT görüntülerinden retina hastalıklarının teşhisinde %98,6'lık bir tahmin doğruluğu elde edilmiştir, ayrıca %97,8'lik bir duyarlılık, %99,4'lük özgüllük ve ROC eğrisi altında %100'lük bir alan saptanmıştır.

Mishra vd. (2019) retinadaki AMD ve DME hastalıklarını teşhis edebilmek için OCT görüntülerini ve ESA'nın ResNet50 mimarisini kullanmışlardır. Bu mimari ilk olarak ImageNet veri tabanındaki verilerle eğitilmiş. Daha sonra transfer öğrenim yöntemi kullanılarak ResNet'in eğitilmiş ağırlıkları OCT veri tabanı görüntüleriyle hassas bir şekilde ayarlanmıştır. Deneyler için Duke [40] ve Neh [41] veri tabanları kullanılmıştır. Bu çalışma çok seviyeli çift dikkat mekanizması (DAM) adlı bir yaklaşımı ESA katmanlarına uygulamayı hedeflemiştir. Bu yaklaşım sayesinde OCT girdi görüntülerinin hem göze çarpan kaba özelliklerinin hem de daha ince özelliklerinin öğrenilmesi sağlanmıştır. Bu deneyin sonucunda Duke veri tabanından %99,97 doğruluk , %99,97 duyarlılık Neh veri tabanından %99,62 doğruluk, %99,62 duyarlılık elde edilmiştir.

Alqudah (2020) OCT görüntüleri kullanarak retinal hastalıkların teşhisi için AOCT-NET isimli yeni bir ESA mimarisi üzerinde çalışmıştır. Çalışma Zhang (Farsiu vd. 2014) ve Farsiu (Srinivasan vd. 2014) veri tabanlarından elde edilmiş ve 5 ana kategoriden (AMD, CNV, DME, DRUSEN ve NORMAL) oluşan toplam 136.187 OCT görüntüsü kullanılarak gerçekleştirilmiştir. Bu görüntülerden 1250 tanesi (her

kategoriye ait 250 görüntü) test için kullanılmıştır. Geriye kalan görüntülerden ise %70'i eğitim için %30 'u doğruluk için kullanılarak ESA beslenmiştir. AOCT-NET toplam 19 katmandan oluşmuştur ve uygulanabilir moment oranı yöntemi kullanılarak zenginleştirilmiştir. Bu yöntem sayesinde daha yüksek doğruluk ve daha düşük maliyet elde edilmiştir. Sonuçlar öğrenilen sistemin %97,78 doğruluk , %97,78 hassasiyet ve %97,778 özgüllük oranlarına ulaşabileceğini göstermiştir.

Das vd. (2019) ise AMD, CNV ve DME hastalıklarının teşhisi için ESA ile birlikte çok ölçekli derin özellikli bir füzyon tabanlı sınıflandırma yaklaşımı üzerinde çalışmışlardır. Bu yöntem 3 ana adımdan (ön işleme, çok ölçekli uzamsal piramit ayrışması ve çok ölçekli derin özellikli bir füzyon tabanlı ESA beslenmesi) oluşmaktadır. Retinanın OCT görüntüleri hastalar arasında değişen bir doğal eğriliğe sahiptir ve bu durum sınıflandırma sırasında olumsuz etkiler yaratabilir. İlk olarak bu durumu önlemek için grafik tabanlı bir eğrilik çıkarma yöntemi uygulanarak retina düzleştirilmesi yapılmıştır ve ardından görüntü üzerindeki ilgilenen kısımlar kırılmıştır. Daha sonra görüntü tekrardan boyutlandırılarak ön işleme adımına son verilmiştir. İkinci aşamada ise işlenmiş görüntü çok ölçekli görüntüler elde etmek için ayrıştırılmıştır. Bu ayrıştırılan görüntüler daha sonra çok ölçekli derin özellikli bir füzyon tabanlı sınıflandırıcıya giriş verisi olarak uygulanmıştır. Sistem 4 kategoriye göre (CNV, DME, DRUSEN ve NORMAL) sınıflama yapmaktadır. Veri seti olarak California San Diego veri tabanı kullanılmıştır. Bu veri tabanı toplam 83.484 OCT görüntüsünü içerir. Bu görüntüler sistemin eğitimi ve testi için iki gruba ayrılmıştır. 633 hastadan 1000 görüntü (her kategoriye ait 250 görüntü) test için kullanılmıştır. Geriye kalan eğitim setindeki görüntülerin ise %80'i eğitim %20'si doğruluma için kullanılmıştır. ESA mimarisini olarak VGG-16 'dan esinlenilmiştir. Önerilen sistem test setinde sırasıyla %99,60, %99,87, %99,60 hassasiyet, özgüllük ve doğruluk sağlamıştır.

Vaghefi vd. (2020) AMD hastalığının teşhisinde, ESA mimarisinin farklı retinal görüntüler ile eğitilmesi üzerine çalışmışlardır. İlk olarak ESA'ya OCT, OCT-A ve renkli fundus görüntüleri sırayla verilmiştir. Daha sonra ise tüm görüntüler bir arada verilerek sonuçlar incelenmiştir. Bu deney sonucunda yalnızca OCT verileri kullanılarak eğitilen ESA %94 doğruluk gösterirken OCT-A eğitilmiş ESA %91 tanı

doğruluğu göstermiştir. Birden çok yöntem (OCT, OCT-A ve renkli fundus fotoğrafçılığı) birleştirildiğinde ise %96 ya yükselen doğruluk değeri tespit edilmiştir.

ESA mimarisinin tasarımı için Inception-ResNet-V2 ağı örnek alınmıştır ve bu ağa göre bazı değişiklikler yapılmıştır. Çalışmaya 75 katılımcı dâhil edilmiştir. Katılımcılar genç sağlıklı, yaşlı sağlıklı ve yüksek riskli AMD' li olarak 3 kategoriye ayrılmıştır. Her katılımcı için kapsamlı bir göz muayenesi yapılmıştır. AMD grubuna kayıtlı olan hastaların maküler durumu deneyimli bir uzman tarafından incelenmiştir.

Görüntüleri elde etmek için OCT cihazı (Topcon DRI OCT Triton, Topcon Corporation, Tokyo, Japonya) kullanılmıştır. Ham OCT, OCT-A ve renkli fundus görüntüleri Topcon ImageNet 6.0 yazılımı kullanılarak dışa aktarılmıştır.

Motozawa vd. (2019) iki hesaplamalı derin öğrenme modeli kullanarak AMD hastalığının teşhisi üzerinde çalışmışlardır. Bu çalışmada iki ESA modeli oluşturulmuştur. İlk model verilen OCT görüntülerini AMD'li ve sağlıklı olmak üzere iki kategoride incelemiştir. İkinci transfer öğrenme modelinde ise AMD teşhisli görüntüler eksüdatif olanlar ve olmayanlar olarak sınıflandırılmıştır. Ayrıca ikinci sistemde transfer öğrenim yönteminin kullanılmasının modelin öğrenim hızına etkisi de incelenmiştir. Deney sonucunda ilk ESA mimarisi AMD hastalığının teşhisi için %100 hassasiyet, %91,8 özgüllük ve %99,0 doğruluk değerlerini vermiştir. İkinci ESA modeli ise eksüdatif bulguların tespitinde %98,4 hassasiyet, %88,3 özgüllük ve %93,8 doğruluk değerleriyle başarı göstermiştir. Ayrıca ikinci modele transfer öğrenim yönteminin dâhil edilmesinin öğrenim hızını arttırdığı da gözlemlenmiştir. İlk ESA modeli toplamda 1.621 OCT görüntüsü ile (1382 AMD ve 239 normal) eğitilip onaylanmıştır. İkinci transfer öğrenme modeli ise eksüdatif değişikliklere sahip 721 AMD görüntüsü ve eksüdatif değişikliklere sahip olmayan 661 AMD görüntüsü ile eğitilmiştir. Çalışmaya Kobe Şehri Tıp Merkezi Genel Hastanesi'ne ait hasta kayıtları da dâhil edilmiştir.

Saha vd. (2019) AMD hastalığına yol açabilecek bio-belirteçlerin otomatik sınıflandırılması üzerinde çalışmışlardır. AMD hastalığına yol açabilecek 3 ana durum hiper-replektif odaklar, drusen içindeki hiper-replektif odaklar ve subretinal drusenoid birikimler) ele alınmıştır. 153 hastadan alınan ve 19584 OCT-B taraması içeren görüntü veri seti ESA modellerinin eğitimi ve testi için kullanılmıştır. Bu görüntüler 2010-2014 yılları arasında Doheny Göz merkezinde AMD tanısı konulmuş hastalardan elde

edilmiştir. Deney için 3 farklı ESA mimarisi ayrı ayrı (Inception-V3, ResNet50 ve InceptionResNet50) eğitilip test edilmiştir. Yapılan deneylerin sonucunda verilen 3 patoloji için de doğruluk değerleri %86 ~ %89 arasında değişmiştir. En iyi sonuçlar InceptionResNet50 mimarisinde gözlemlenmiştir. Bu ESA ağı subretinal drusenoid birikimleri sırasıyla %79, %92 ve %86 hassasiyet, özgüllük ve doğruluk değerleriyle tespit edebilmiştir. Drusen içindeki hiper-replektif odaklarda ise %78 hassasiyet ve %100 özgüllük değerlerini verirken hiper-replektif odakları sırasıyla %79 ile % 95 duyarlılık ve özgüllük oranlarıyla tespit ederek başarısını göstermiştir.

Najeeb vd. (2019) OCT görüntüleri üzerinden retinal hastalıkların saptanması ve sınıflandırılması olasılığı üzerinde durmuşlardır. Çalışmaya CNV, DME ve drusen hastalıkları dâhil edilmiştir. Önerilen yöntemde ESA ağının eğitimi için Kermany vd. (2018) açık kaynaklı OCT görüntülerinden oluşan veri seti kullanılmıştır. Veri seti 83.484 görüntü içeren (37.205 CNV görüntüsü, 11.348 DME görüntüsü ve 26.315 sağlıklı göz durumu görüntüsü) eğitim setinden oluşmaktadır. Ağın test edilebilmesi için her kategoriden 242 görüntü toplamda 968 görüntü ayrılmıştır. ESA mimarisi olarak temel konvolüsyon sinir ağı kullanılmıştır. Sonuçlar incelendiğinde ise önerilen sistemin retinal hastalıkları %95,66 hassasiyetle tespit edebileceği gözlemlenmiştir.

Bhowmik vd. (2019) göz hastalıklarının tespiti için OCT görüntüleri üzerinde çalışmışlar ve ESA mimarisinde transfer öğrenme yöntemini kullanmışlardır. Göz hastalıkları DRUSEN, DME ve CNV olmak üzere 3 gruba ayrılmıştır. Kaggle açık erişimli veri seti sitesinde bulunan, 84.495 gri tonlamalı OCT görüntüsü içeren veri seti kullanılmıştır. Bu veri seti California San Diego Üniversitesi, Shiley Eye Enstitüsü, California Retinal Araştırma Vakfı, Tıp Merkezi Oftalmoloji Ortakları, Şanghay İlk Halk Hastanesi ve Pekin Tongren Göz Merkezi tarafından oluşturulmuştur. ESA mimarisi olarak önceden eğitilmiş VGG16 ve Inception-V3 sinir ağları kullanılmıştır. Sistemin eğitimi için veri setinden her kategoriye (DRUSEN, AMD, CNV ve NORMAL) ait 1000 görüntü alınarak oluşturulmuş toplamda 4.000 görüntü içeren veri seti kullanılmıştır. Bu şekilde modelin öğrenme sürecinin kısaltılması amaçlanmıştır. Geriye kalan görüntüler modelin testi için kullanılmıştır. Önerilen yaklaşım test verilerinde %94, eğitim verilerinde ise %99,94 doğruluk değerleri sağlamıştır. Yapılan

deneylerin sonucunda iyi performansı gösteren VGG16 mimarisinin ölçüm değerleri esas alınmıştır.

Kamble vd. (2018) DME hastalığını OCT görüntülerinden tespit edebilmek için Inception-ResNet-V2 ESA mimarisini kullanmışlardır. Bu mimari üzerinde çalışmaya uygun olarak bazı ince ayarlar yapılmıştır. Inception-ResNet-V2, Singapur Göz Araştırma Enstitüsü'nün halka açık veri setleri kullanılarak eğitilmiştir. Daha sonra eğitilen bu model Hong Kong Çin Üniversitesi (CHUCK) tarafından yayınlanan başka biri veri setiyle de test edilmiştir. Önerilen yöntem DME hastalığının teşhisinde %100 doğruluk değeri sağlamıştır. Ayrıca Inception-ResNet-V2 ağından elde edilen sonuçlar InceptionV3 ve Resnet50 ESA mimarilerinin sonuçlarıyla da karşılaştırılmıştır. Bu karşılaştırma sonucunda ise Inception-ResNet-V2 mimarisinin sonuçlarının diğer iki ağa göre üstünlüğü tespit edilmiştir.

Wang vd. (2019) ıslak AMD ve kuru AMD'nin tespiti için çift eğitilmiş iki akışlı ESA modeli üzerinde çalışmışlardır. Bu yaklaşımda ESA OCT ve fundus görüntüleriyle ayrı ayrı eğitilmek için hazırlanan iki akışlı ağ tasarımdan oluşmaktadır. İki model içinde ESA mimarisi olarak önceden eğitilmiş ResNet-18 ağı kullanılmıştır. Ağ eğitimi için gevşek eşleştirme yöntemi kullanılmıştır. Bu yöntem ile bir OCT görüntüsünün aynı etkiye sahip başka bir fundus görüntüsüyle eşleştirilmesi amaçlanmıştır. Deneyler için Peking Union Tıp Koleji Hastanesi'nden OCT ve fundus görüntüleri toplanmıştır. Bu çalışma sonucunda iki tek modlu model %94,2 doğruluk değeri ile tek modlu modellere göre üstünlük sağlanmıştır.

Wang vd. (2020) CNV membranının varlığına göre görüntüleri ayıran ve membranın olması durumunda damar sistemini bölümlerine ayıran 2 farklı ESA mimarisi eğitmişlerdir. Çalışmada Helsinki Bildirgesi'ne uygun olarak Oregon Eye & Science Üniversitesi, Portland, OR, ABD ve Shanxi Göz Hastanesi, Taiyuan, Shanxi, PR China'daki retina kliniklerinden alınan verilerin bulunduğu çok çeşitli sinyal gücü endeksine (SSI) sahip OCT-A veri setleri kullanılmıştır. Çalışmada uygulanan yöntemde iki ESA mimarisi birleştirilmiştir. İlki CNV membran tanımlama ve segmentasyonu için diğeri piksel bazlı damar segmentasyonu için eğitilmiştir. Membran

segmentasyonu için tasarlanan ESA'da oto-encoder mimarisi temel alınmıştır. Özellik çözünürlüğünü azalttığı düşünülen birçok havuzlama katmanı yerine sıfır eklenerek 3x3 boyutuna genişletilmiş atrous çekirdek kullanılmıştır. 2 boyutlu olarak tasarlanmış ESA'yı beslemek için 3 boyutlu yapıya sahip dış retinal hacim görüntülerinin derinliğinin her bir katmanı ayrı bir kanal olarak girilmiştir. Yapısal ve anjiyografik özellikler birleştirildikten sonra özellik çıkarmak için kodlayıcı katmanları beslenmiştir. Özellik birleştirmeden sonra tek bir havuzlama katmanı eklenmiş, kod çözücü bölümüne ise U-Net benzeri bir mimari uygulanmıştır. CNV membran segmentasyon mimarisinin son kısmında softmax katmanı kullanılarak, CNV membranlarının olasılık haritası çıkarılmıştır. Damar segmentasyon kısmında, CNV membran segmentasyonundan elde edilen olasılık haritası giriş olarak kullanılmıştır. Ayrıca damar segmentasyon mimarisi, CNV membran segmentasyon mimarisinde bulunan havuzlama katmanı çıkartılarak ve atrous çekirdeğinin genişleme oranı azaltılarak daha basit yapıda kullanılmıştır. Çalışma sonunda %100 hassasiyete, %95 özgüllük sahip teşhis ve 0,88 oranında kesişmeye sahip segmentasyon sonuçları elde edilmiştir.

Xi vd. (2019) önsel öğrenimli çok ölçekli ESA (MS-ESA-SP) kullanarak CNV segmentasyonu yapan bir yöntem önermişlerdir. Sistemde 2 aşama mevcuttur. İlk kısımda önsel/öncelikli öğrenim yapılmış ikinci kısımda ise CNV segmentasyonu için önceden öğrenilen yapının dahil edildiği çok ölçekli ESA modeli oluşturulmuştur. Eğitim ve test aşamalarından oluşan yöntemde ilk olarak görüntüler süper piksele ayrılmış ve daha sonra her süper piksel için yoğunluk, doku ve yerel bilgi özellikleri çıkartılmıştır. Küresel yapısı ise süper piksellere göre öğrenilmiştir. Önceden öğrenilen küresel yapıdan CNV'nin mekânsal konumu tespit edilmiş ve potansiyel matrisin hesaplanması için yerel potansiyel fonksiyon geliştirilmiştir. Daha sonra, orijinal görüntüler, önsel/öncelikli matris kullanılarak belirginliği artırılmış görüntülere dönüştürülmüştür. Belirginleştirilmiş görüntülerden farklı boyutlarda eğitim parçaları çıkartılmış ve önsel öğrenimli çok ölçekli ESA modelini eğitmek için kullanılmıştır. Test aşamasında eğitim aşamasında yapılan tüm aşamalar test görüntüleri içinde yapılarak son olarak segmentasyon sonucu, MS-CNN-SP modellerinin segmentasyon sonuçlarının füzyonu yoluyla elde edilmiştir. Çalışmada CNV teşhisi konulmuş 15 spektral domain OCT görüntüsü kullanılmıştır. Sonuçlara bakıldığında MS-ESA-SP

yöntemi ile zar benzerlik katsayısı 0,7806, doğru pozitif hacim oranı 0,8024 ve yanlış pozitif hacim oranı 0,0036 olarak hesaplanmıştır. Sonuçlar önsel öğrenim kullanılmayan çok ölçekli ESA modeli ile karşılaştırılmış ve önsel öğrenimli yöntemde yaklaşık %28 daha başarılı sonuç alındığı gözlemlenmiştir.

Yapılan literatür taramasında, derin sinir ağı tabanlı çalışmalarda, hesaplama maliyeti yüksek ve genellikle önceden eğitilmiş ağların kullandığı görülebilir. Bu nedenle, ağ boyutunu olabildiğince küçük tutarken doğruluğu artırabilecek yenilikçi yöntemler geliştirmek gerekir. Ağın karar verme sürecini açıklamak da önemlidir. Çalışmada yapılan literatür araştırması göz önünde bulundurularak literatürde yer edinebilmek için:


- Sınıflandırma doğruluğu yükseltilerek başarı sıralamalarında önemli bir yer edinilmesi hedeflenmiştir;
- Yapılan araştırmalara göre çoğu çalışmada ön işleme tekniklerinin yeterli düzeyde kullanılmadığı fark edilmiştir. Bu yüzden önerilen modelde literatürde daha önce kullanılmamış ön işleme tekniklerine yer verilmiştir.
- Literatürde transfer öğrenme ile yapılan çalışmalara daha sık rastlanmıştır. OCT görüntülerine özel model oluşturularak, yapılan çalışma sayısının artırılması için önerilen sistemde özel bir ESA modeli oluşturulmuştur.
- Tasarlanan modelde katman sayısı kısıtlı tutulmuştur ve model 5 evrişim katmanından oluşturulmuştur. Bu sayede matematiksel hesaplama maliyetinden olabildiğince düşük tutulmuştur.

3. MATERYAL ve METOT

Bu tez çalışmasında görüntü ön işleme yöntemlerine tabi tutulan OCT görüntüleri ve 5 katmanlı ESA mimarisi kullanılarak retinal hastalıkların otomatik sınıflandırılmasına yönelik bir sistem önerilmiştir. Önerilen sistem görüntü ön işleme ve sınıflandırma olarak iki aşamadan oluşmaktadır. Ön işleme basamağının ilk adımında, veri setindeki tüm görüntüler gri seviyeye dönüştürülmüştür. Daha sonra veri setindeki görüntülerin arka fonunda bulunan beyaz boşluklara bağlı şekil bozuklukları tespit edilmiştir. Bu bozuklukların giderilmesi için iki görüntüyü birleştirme yöntemine (piksellerinin çarpılması işlemi) başvurulmuştur. Arka plandaki beyaz boşluklar doldurulduktan sonra tüm görüntülerin aynı boyutta olabilmesi için 128x128 ölçülerinde yeniden boyutlandırma işlemi yapılmıştır. Veriler üzerinde gri seviyeye dönüştürme, boşluk doldurma ve boyutlandırma işlemi yapıldıktan sonra görüntü üzerindeki gürültülerin giderilmesi ve hastalıkların teşhis edilmesindeki önemli noktaların belirginleştirilmesi için görüntüler üzerinde sırasıyla histogram eşitleme, medyan filtre, gaussian filtre ve yerel olmayan ortalama filtresi kullanılmıştır. Ön işleme tekniklerinden sonra retinal hastalıkların teşhisi için 5 katmanlı evrişimsel sinir ağı mimarisi tasarlanmıştır. Tasarlanan 5 katmanlı evrişimsel sinir ağı mimarisinin eğitim ve test aşamalarında yukarıda belirtilen ön işleme teknikleri uygulanan görüntüler kullanılmıştır.

3.1 Yapay Sinir Ağları (YSA)

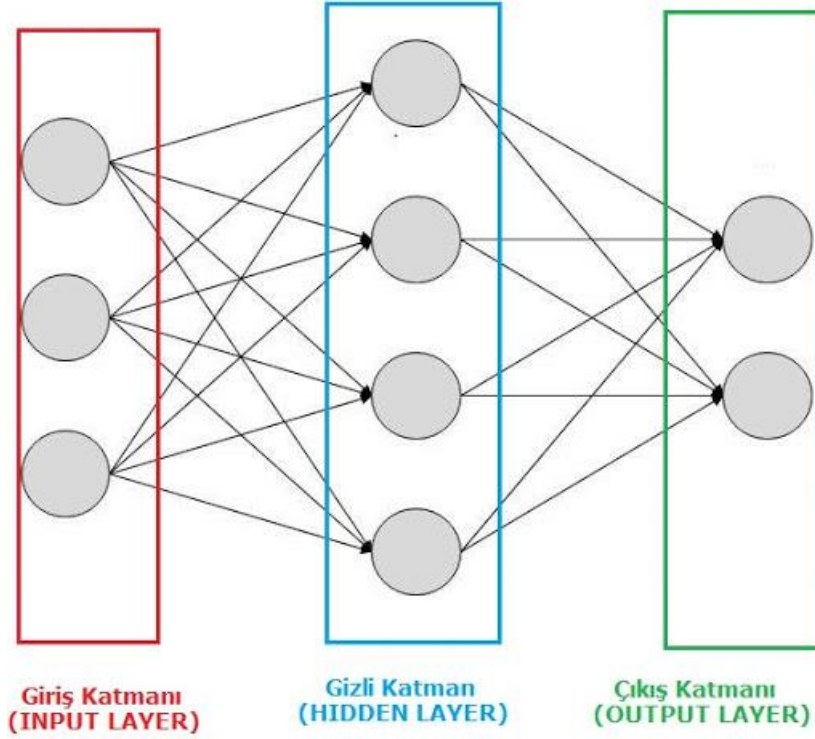
Yapay sinir ağları, fiziksel bir olayı veya bir karar sürecini tanımlayan temsili verilerden örnek olarak öğrenmeye izin veren bir modelleme tekniğidir. Bağımsız ve bağımlı değişkenler arasında deneysel ilişkiler kurabilirler ve veri setlerinden ince bilgileri ve karmaşık bilgileri çıkartabilmektedirler (Sadiq vd. 2019). Sinir ağları, örüntü tanıma, sınıflandırma, kümeleme, boyut azaltma, bilgisayarla görme, doğal dil işleme, regresyon, tahmine dayalı analiz vb. dâhil olmak üzere çeşitli problemlerde kullanılabilir. YSA' lar insan sinir sistemlerindeki yapılar ve sinirsel aktarımlar örnek alınarak oluşturulan algoritmalar bütünüdür. Bu yüzden yapay sinir ağlarının işleyişini anlayabilmek için biyolojik sinir ağlarının temelleri bilinmelidir. Biyolojik sinir sisteminin temel birimi bir sinir hücresi olan nöronlardır (Umut vd. 2019).



Şekil 3.1 Nöronun biyolojik gösterimi (İnt.Kyn. 5).

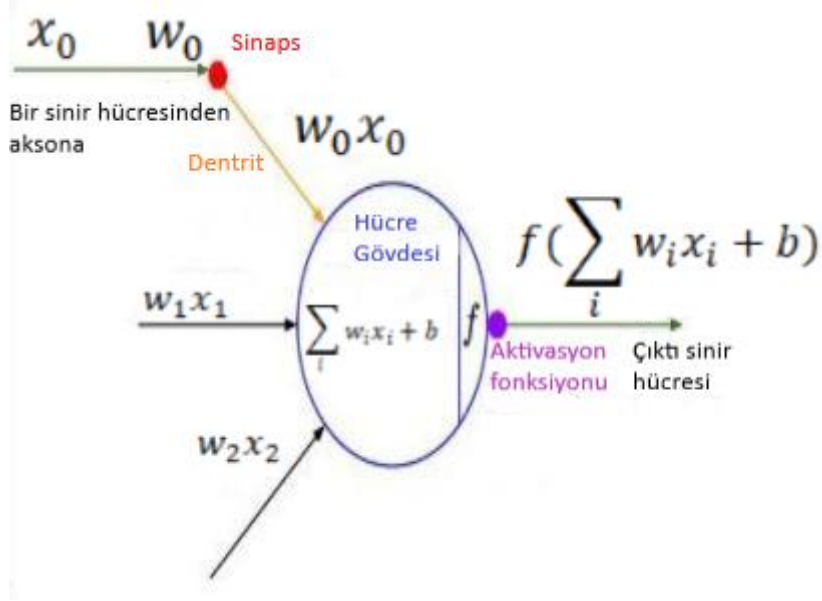
Şekil 3.1’de canlı sinir sisteminin bir parçası gösterilmektedir. İnsan beyni yaklaşık 100 milyar nöron içerir. Nöronlar hücre gövdesi, aksonlar ve dendritler olmak üzere 3 ana kısımdan oluşur. Dış çevreden gelen uyarılar veya duyu organlarından gelen girdiler dendritler tarafından kabul edilir. Bu girdiler, aksonlar boyunca iletilir. Nöronlar birbirlerine akson terminalleri ve dendritler aracılığıyla bağlıdır, aksonlar tarafından iletilen sinyaller akson terminalleriyle diğer bir nöronun dendritine geçiş yapar (Cantile ve Youssef 2016).

Yapay sinir ağları ise girdi, çıktı ve gizli olmak üzere üç katmandan oluşur. Giriş katmanı genellikle veri girişi için kullanılırken, çıktı katmanı operatöre bilgi sağlamakta ve gizli katman ise makinenin alması gereken kararı veya eylemi belirlemeye yardımcı olan matematiksel hesaplamaları gerçekleştirmektedir.



Şekil 3.2 Yapay sinir ağının genel yapısı (İnt.Kyn. 9).

Şekil 3.2’de gösterilen bu üç katman, insan beyninin biyolojik nöronlarını taklit eden ve her biri bir dizi gerçek değerli aktivasyon üretebilen ağırlıklı düğümler ile birbirine bağlıdır (Choudhury vd. 2018). Her katman birden çok nörondan oluşmaktadır. Her nöron, girişlerini doğrusal olarak birleştirir ve ardından bunu doğrusal veya doğrusal olmayan bir aktivasyon fonksiyonundan geçirerek sonraki katmana aktarır. Bir nörona yapılan her girdi, ara bağlantının gücünü ve dolayısıyla bu ara bağlantının sonraki nöronlara katkısını belirleyen bir ağırlık faktörüne sahiptir. Girdilerin doğrusal kombinasyonu (aktivasyonu), ağırlıkların ve girdilerin çarpımlarının toplanmasıyla gerçekleştirilir (Pujol vd. 2011).




Şekil 3.3 Yapay sinir ağının matematiksel gösterimi (İnt.Kyn. 2).

Şekil 3.3' de yapay sinir ağının matematiksel gösterimi verilmiştir. Şekle göre x değeri girişi, w değeri ağırlıkları temsil etmektedir.

Her katmandaki düğümler veya birimler, bitişik katmanlardaki düğümlere bağlanır. Her bağlantının bir ağırlık değeri vardır. Girişler, ilgili ağırlıklarla çarpılır ve her birimde toplanır. Toplam daha sonra, çoğu durumda bir sigmoid fonksiyonunu veya düzeltilmiş doğrusal birim (rectified linear unit, ReLU) olan aktivasyon fonksiyonuna dayalı bir dönüşüme uğrar. Bu fonksiyonlar hata deltanın kısmi türevlerinin bireysel ağırlıklara göre hesaplanmasını kolaylaştırır (Misra vd. 2019).


Yapay sinir ağları, hücrelerin bağlantı şekillerine göre ileri beslemeli ağ ve geri beslemeli ağ olarak iki şekilde sınıflandırılmaktadır.

İleri beslemeli sinir ağında bilgi akışı tek yönlüdür. Bir nöron aldığı bir bilgiyi sadece önündeki nörona aktarabilir. Geri bildirim döngüsü yoktur. Sabit giriş ve çıkış değerlerine sahiptirler. Şekil 3.4' de ileri beslemeli sinir ağı yapısı gösterilmektedir.



Şekil 3.4 İleri besleme sinir ağının şematik gösterimi (İnt.Kyn. 8).

Geri beslemeli ağlar ise geri bildirim döngülerine sahiptirler. Giriş verilerinden elde edilen değerler, adreslenebilir ve hafızalarda kullanılabilir. Nöronlar arası aktarım hem ileri yönde hem de geri yöndedir. Şekil 3.5’de geri beslemeli sinir ağı gösterilmektedir.



Şekil 3.5 Geri besleme sinir ağının şematik gösterimi (İnt.Kyn. 8).

Son zamanlarda yapay sinir ağı ve derin öğrenme kavramları aynı anlamda görülüp bir birleri yerine kullanılmaktadır. Bu çok da doğru bir yaklaşım değildir. Yapay sinir ağları, bir bilgisayarın gözlemsel verilerden öğrenmesini sağlayan, biyolojik olarak ilham alan güzel bir programlama paradigmasıdır (Natrayan ve Kumar 2021). Derin sinir ağları ise sinir ağlarından oluşan öğrenmeye yönelik güçlü bir teknikler dizisidir. Derin sinir ağları YSA katmanlarının derinlik getirilmiş halidir. YSA’larda tek bir gizli

katman bulunurken derin öğrenme mimarilerinde sonsuz sayıda gizli katman olabilir. Derin öğrenme sahip olduğu bu gizli katmanlar sayesinde bilgiyi filtreleyerek kendi kendine öğrenim yapabilir (Bersimis ve Varlamis 2019).

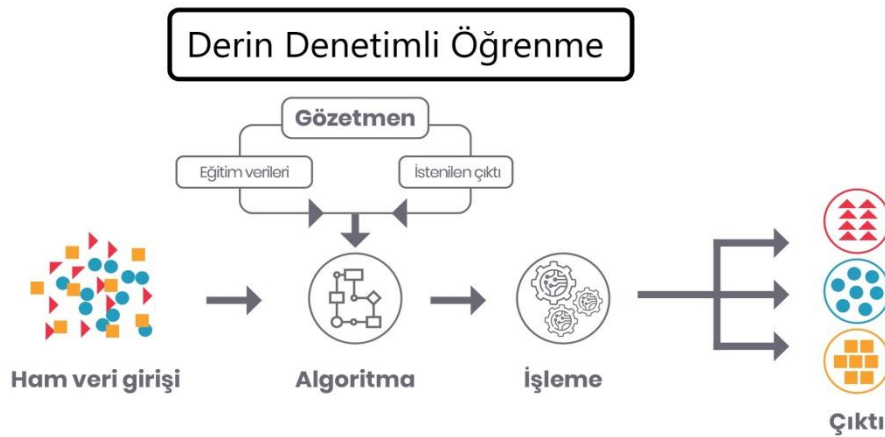
3.2 Derin Öğrenme

Son yıllarda fazlasıyla ses getiren derin öğrenme kavramı, makine öğrenmesinin bir alt dalı olarak karşımıza çıkmaktadır. Günümüzde askeri, endüstri, ekonomi, biyomedikal gibi hemen hemen her alanda ses tanıma, video işleme, görüntü analiz etme, dil işleme vb. gibi farklı uygulamalar ile iş birliği içinde gelişim göstermektedir. Derin öğrenme çoklu katmanlardan oluşur ve büyük veri setleri ile birlikte çalışır (Boulemtafes vd. 2019). Bu katmanlar sayesinde veriyi temsil edebilecek her türlü özelliği öğrenimine katabilir ve eğitim sürekli kendini yenileyerek devam edebilir (Şeker vd. 2017). Bu katmanlar insan beynindeki sinir ağ yapısına çok benzer olup yapay nöronlar ile birbirine bağlıdır. Aynı bir insan sinir sistemindeki gibi çok aşamalı işlemler sayesinde girdi verilerini ayrıştırarak ve soyutlayarak verinin öz niteliklerini öğrenmeyi ve daha sonra elde ettiği öz nitelikler sayesinde yeni çıkarımlar yaparak süreklilik sağlamayı amaçlar (Arel vd. 2010). Her bir katmandan çıkan nitelikler diğer katmanın girdi verisi olarak kullanılır ve bu aktarım yapay nöronlar sayesinde yapılır (Deng vd. 2014).

Kısacası derin öğrenme bir girdi, bir çıktı ve aralarında tamamen bağlı çok katmanlı sinir ağlarından oluşan derin yapay sinir ağı mimarileridir ve birçok karmaşık algoritmalar serisinden meydana gelen bir makine öğrenim alt dalıdır. Derin öğrenmenin kendine özgü mimari yapıları bulunur. Bu yapılara evrişimli sinir ağları (ESA), tekrarlayan sinir ağları, uzun kısa vadeli hafıza ağları, kısıtlı boltzmann makineleri, öz yinelemeli sinir ağları, derin oto-kodlayıcılar örnek olarak verilebilir (Boulemtafes vd. 2019). Bahsi geçen sinir ağlarından özellikle ESA görüntü ve ses işleme uygulamalarında kayda değer başarılar elde etmiştir. Bu yüzden literatürde ESA kullanılarak biyomedikal alanda görüntü işleme ile yapılan çalışmalara oldukça sık rastlanmaktadır.


Derin öğrenme teknikleri denetimsiz, kısmen denetimli (yarı denetimli) ve denetimli olmak üzere 3 kategoride incelenmektedir. Bu üç kategoriye ek olarak derin pekiştirmeli öğrenme çoğunlukla kısmen denetimli (ve bazen denetimsiz) öğrenme teknikleri kategorisine girdiği düşünülen başka bir öğrenme tekniğidir (Schmidhuber 2015).

- **Denetimli Öğrenme:** Bu teknik, etiketli verilerle ilgilenir. Denetimli öğrenmeyle, bir dizi örnek olan eğitim seti, eğitim aşamasında sisteme girdi olarak sunulur. Her giriş istenen bir çıkış değeri ile etiketlenir, bu şekilde sistem girdi geldiğinde çıktının nasıl olduğunu bilir. Daha sonra, ağ parametreleri, tercih edilen çıktılar için geliştirilmiş bir tahmin elde etmek için sistem tarafından tekrar tekrar güncellenir. Olumlu bir eğitim sonucunun ardından sistem çevreden gelen sorulara doğru çözümleri elde etme becerisi kazanır. Derin öğrenme için, tekrarlayan sinir ağları, evrişimli sinir ağları ve derin sinir ağları gibi çeşitli denetimli öğrenme teknikleri vardır. Bu tekniğin temel avantajı, önceki bilgilerden veri toplama veya bir veri çıktısı üretme yeteneğidir. Bununla birlikte, bu tekniğin dezavantajı, eğitim seti bir sınıfta olması gereken örneklerle sahip olmadığında karar mekanizmasının aşırı derece zorlanabilmesidir (Castiglioni 2021). Şekil 3.6’da derin denetimli öğrenmenin çalışma mekanizması gösterilmektedir.



Şekil 3.6 Derin Denetimli Öğrenme Gösterimi (İnt.Kyn. 1).


- Yarı Denetimli Öğrenme: Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenmenin ortasında yer alır. Bu teknikte, öğrenme süreci yarı etiketli veri setlerine dayanmaktadır. Etiketsiz verilere ek olarak, algoritmaya bazı denetim bilgileri sağlanabilir ancak tüm örnekler için zorunlu değildir. Çoğu zaman, bilgiler bazı örneklerle ilişkili hedefler olabilir. Bu tekniğin avantajlarından biri, ihtiyaç duyulan etiketli veri miktarını en aza indirmektir. Öte yandan, bu tekniğin dezavantajlarından biri ise yetersiz girdi özelliğidir ve bu yüzden oluşturulan sistem yanlış kararlar verebilir. Metin belgesi sınıflandırıcı, yarı denetimli öğrenme uygulamasının en popüler örneklerinden biridir. Büyük miktarda etiketli metin belgesi elde etmenin zorluğu nedeniyle, yarı denetimli öğrenme, metin belgesi sınıflandırma görevi için idealdir (Zhai vd. 2019). Şekil 3.7’de yarı denetimli derin öğrenmenin çalışma mekanizması gösterilmektedir.



Şekil 3.7 Yarı Denetimli Derin Gösterme Akış Şeması (İnt.Kyn. 1).

- Denetimsiz Öğrenme: Bu teknik, mevcut etiketli verilerin yokluğunda öğrenme sürecini uygulamayı mümkün kılmak için kullanılır (yani etiket gerekmez). Burada sistem, giriş verilerindeki tanımlanamayan yapıyı veya ilişkileri keşfetmek için gereken önemli özellikleri veya iç gösterimi öğrenir. Üretken ağların teknikleri olan boyutsallığı azaltma ve kümeleme sıklıkla denetimsiz öğrenme kategorisi içinde yer alır. Derin öğrenme ailesinin birkaç üyesi, doğrusal olmayan boyutsallık azaltma ve kümeleme görevlerinde iyi performans göstermiştir; bunlar arasında en son geliştirilen teknikler olan kısıtlı Boltzmann

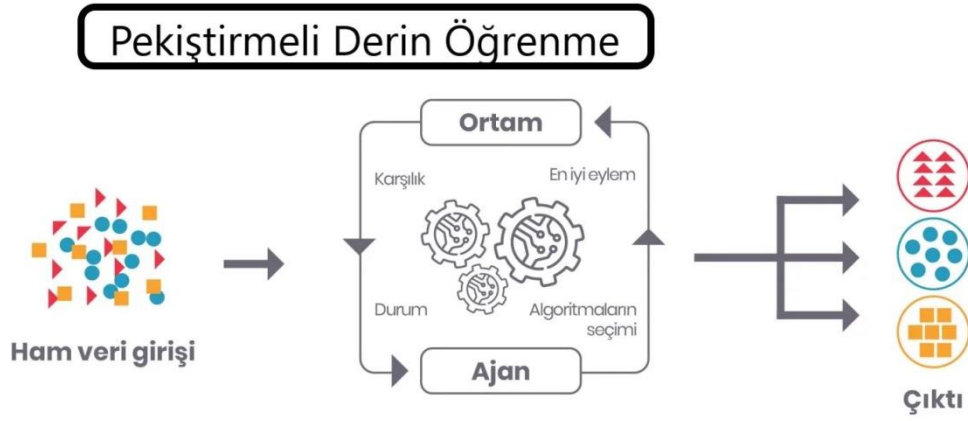
makineleri, otomatik kodlayıcılar ve çekişmeli üretici ağlar bulunmaktadır. Denetimsiz öğrenmenin temel dezavantajları, veri sıralama ve hesaplama karmaşıklığı ile ilgili doğru bilgi sağlayamamaktır. En popüler denetimsiz öğrenme yaklaşımlarından biri kümelemedir (Shrestha ve Mahmood 2019). Şekil 3.8’de denetimsiz derin öğrenmenin çalışma mekanizması gösterilmektedir.



Şekil 3.8 Denetimsiz Derin Öğrenme Akış Şeması (İnt.Kyn. 1).

- **Pekiştirmeli Öğrenme:** Takviyeli derin öğrenme, çevre ile etkileşim üzerinde çalışırken, denetimli öğrenme, sağlanan örnek veriler üzerinde çalışır. Sistem çevre ile etkileşime girer ve sonuçları gözlemler ardından bir sonraki adımda bu sonuçları dikkate alarak eylemler gerçekleştirir. Bu teknik, 2013 yılında Google Deep Mind ile geliştirilmiştir. Daha sonra, pekiştirmeli öğrenmeye bağlı birçok gelişmiş teknik oluşturulmuştur. Bu yöntem bazen yarı denetimli öğrenme olarak da adlandırılabilir. Bu konseptte dayanarak, çeşitli denetimli ve denetimsiz teknikler de geliştirilmiştir. Geleneksel denetimli tekniklerle karşılaştırıldığında, bu öğrenmeyi gerçekleştirmek çok daha zordur, çünkü pekiştirmeli öğrenme tekniğinde doğrudan kayıp işlevi yoktur. Ek olarak, denetimli öğrenme ile pekiştirmeli öğrenme arasında iki temel fark vardır: birincisi, optimizasyon gerektiren işleve tam erişim yoktur, yani etkileşim yoluyla sorgulanması gerekir; ikincisi, etkileşimde bulunulan durum, girdinin önceki eylemlerine dayanmaktadır.

Bir görevi çözmek için, gerçekleştirilmesi gereken pekiştirmeli öğrenme türünün seçimi, problemin alanına veya kapsamına bağlıdır. Örneğin, DRL, birçok parametre içeren sorunların optimize edilmesinin en iyi yoludur. Buna karşılık, türev içermeyen pekiştirmeli öğrenme, sınırlı parametrelere sahip problemler için iyi performans gösteren bir tekniktir. Takviye öğrenme uygulamalarının bazıları, endüstriyel otomasyon için iş stratejisi planlaması ve robotiktir. Takviyeli öğrenmenin temel dezavantajı, parametrelerin öğrenme hızını etkileyebilmesidir (Schmidhuber 2015). Şekil 3.9'da pekiştirmeli derin öğrenmenin çalışma mekanizması gösterilmektedir.



Şekil 3.9 Pekiştirmeli Derin Öğrenme Akış Şeması (İnt.Kyn. 1).

Derin öğrenmenin kendine özgü mimari yapıları bulunur. Bu yapılara evrimsel sinir ağları (ESA), tekrarlayan sinir ağları, uzun kısa vadeli hafıza ağları, kısıtlı boltzmann makineleri, öz yinelemeli sinir ağları, derin oto-kodlayıcılar örnek verilebilir (Şeker vd. 2017). Bahsi geçen sinir ağlarından özellikle ESA görüntü ve ses işleme uygulamalarında kayda değer başarılar elde etmiştir bu yüzden literatürde ESA kullanılarak biyomedikal alanda görüntü işleme ile yapılan çalışmalara oldukça sık rastlanmaktadır.

3.2.1 Evrişimli Sinir Ağları


Evrişimli sinir ağları (ESA) derin sinir ağlarının en güçlü sınıflarından biridir. Hayvanların görsel korteksinden esinlenen ve yaygın olarak kullanılan derin öğrenme çerçevesidir. İlk zamanlar nesne tanıma görevleri için yaygın olarak kullanılsa da, günümüzde görüntü işleme, bilgisayarla görme, ses işleme, yüz tanıma, metin işleme, görüntü tanıma ve sınıflandırma gibi birçok farklı alanda kapsamlı bir şekilde kullanılmaktadır (Ajit vd. 2020). ESA'ların diğer derin öğrenme mimarilerine kıyasla ana yararı, ilgili özellikleri herhangi bir insan gözetimi olmaksızın otomatik olarak tanımlamasıdır.

Başlangıçta donanımsal yetersizliklerden dolayı ESA mimarileri dezavantajlı konumda iken merkezi işlem birimlerinden (Central Process Unit, CPU'lar) çok daha kuvvetli hesaplama yeteneklerine sahip grafiksel işlem birimlerinin (graphical processing units, GPU'lar) ortaya çıkışı ile literatürde oldukça geniş ve popüler bir çalışma alanı kazanmıştır (Grewal vd. 2018).

Bilgisayarla görme ortamında ESA'ları diğer geleneksel sinir ağlarına göre kullanmanın faydaları şu şekilde sıralanmıştır:

- ESA dikkate alınmanın ana nedeni, eğitilebilir ağ parametrelerinin sayısını azaltan ve dolayısıyla ağın genellemeyi geliştirmesine ve aşırı uyumu önlemesine yardımcı olan ağırlık paylaşım özelliğidir.
- Özellik çıkarma katmanlarını ve sınıflandırma katmanını eşzamanlı olarak öğrenmek, model çıktısının hem yüksek düzeyde organize olmasına hem de çıkarılan özelliklere oldukça bağımlı olmasına neden olur.
- Büyük ölçekli ağ uygulamasının, ESA ile diğer sinir ağlarına göre çok daha kolay olmasıdır.

ESA'lar 3 boyutlu (genişlik, yükseklik ve derinlik) nöronlardan oluşmaktadır. (Li vd. 2019). Şekil 3.10'da bir ESA'nın genel yapısı gösterilmiştir.




Şekil 3.10 ESA Konfigürasyonu (Li vd. 2019).

ESA mimarisi, bir iskelet içinde bir dizi evrişim, aktivasyon, havuzlama ve diğer katmanlardan oluşan bir organizasyondur. Tüm ESA'ların genel modeli kaç katmandan oluştuğuna, her katmanda kaç nöron olduğuna ve nöronların birbirine nasıl bağlı olduğuna cevap verebilmelidir.

Evrişimli sinir ağı, her bir aşamanın popüler olarak özellik haritaları olarak bilinen dizilerin koleksiyonundan oluştuğu, çok aşamalı çeşitli katmanlardan oluşan bir çerçeve çalışmasıdır. Öncelikle, bu diziler her aşamanın girdi ve çıktılarıdır. Genel olarak bir ESA mimari 6 temel katman ve fonksiyonlardan oluşmaktadır.

- Evrişimli katman
- Aktivasyon Fonksiyonları (Doğrusal olmayan işlem)
- Havuzlama veya alt örnekleme katmanı
- Düzleştirme katmanı
- Tamamen bağlı katman
- Kayıp fonksiyonları

ESA'larda, gerekli ön işleme işlemleri diğer sınıflandırma tekniklerinden çok daha azdır. Geleneksel tekniklerde, sistemi eğitecek filtreleri oluşturmak için oldukça fazla ön işlem gerekmektedir. Aksine, ESA'lar, farklı özellikleri elde etme ve bu özellikler için kendini otomatik olarak eğitime yeteneğine sahiptir. Şekil 3.11, çeşitli ESA katmanlarının işleyişini göstermektedir (Dhillon, ve Verma 2020).




Şekil 3.11 Örnek bir ESA mimarisi (İnt.Kyn. 7).

3.2.1.1 Evrişimli Katman

Evrişim Katmanı, ESA'daki en önemli katmandır. Temel olarak, belirli görüntü veya nesne için oluşturulan piksel matrisini, verilen görüntü için bir özellik haritası oluşturmak üzere dönüştürür veya çoğaltır. Evrişimli katmanların birincil amacı, özellikleri girdiden çıkarmaktır. Tipik olarak, kenarları, çizgileri ve köşeleri algılama gibi özellikler ilk katmanlarla rapor edilir. Ayrıca, sonraki yoğun katmanların ilk katmanlarla birleştirilmesi, nesnelerin görünüşleri ve oluşumları gibi daha belirgin özelliklerin çıkarılmasına neden olur.

Bir katmanın çerçeve çalışması, filtreler olarak da bilinen birden çok öğrenme çekirdeğinden oluşur. Evrişim operatörü kullanılarak, matris çarpım ilkeleri, girişe ve filtreye maksimum ölçüde uygulanır ve bir özellik haritası oluşturulur. Birkaç filtre tarafından oluşturulan bu haritaların kombinasyonu ve yığılması, ağırlıklın toplamı ile hesaplanır ve evrişim katmanının performansını oluşturur (Sunija vd. 2021).

- Çekirdek: Farklı sayı değerlerinden oluşan bir filtre çerçevesi olarak tanımlanmaktadır. Her bir değer çekirdek ağırlığını temsil etmektedir. ESA eğitim sürecinin başlangıcında çekirdeğin ağırlıklarına rastgele sayılar atanır. Daha sonra, bu ağırlıklar her eğitim döneminde ayarlanır; böylece çekirdek önemli özellikleri çıkarmayı öğrenir.
- Evrişimli İşlem: Başlangıçta, ESA giriş formatı açıklanır. Vektör biçimi, geleneksel sinir ağının girdisi, çok kanallı görüntü ise ESA'nın girdisidir. Örneğin, gri tonlamalı görüntünün formatı tek kanal iken, RGB görüntü formatı üç kanallıdır. Evrişimli işlemi anlamak için, 4×4 ile gri tonlamalı görüntüyü ve 2×2 rastgele ağırlıklı başlatılmış çekirdeği örnek alalım. İlk olarak, çekirdek yatay ve dikey olarak tüm görüntünün üzerinde kaydırılır. Giriş görüntüsü ile çekirdek arasındaki iç çarpım belirlenir. Burada karşılık gelen değerler çarpılır ve ardından eş zamanlı olarak hesaplanan tek bir skaler değer oluşturmak için toplanır. Daha sonra tüm işlem, daha fazla kayma mümkün olmayana kadar tekrarlanır. Hesaplanan iç çarpım değerleri çıktının özellik haritasını temsil etmektedir. Şekil 3.12, her adımda gerçekleştirilen birincil hesaplamaları grafiksel olarak gösterir. Bu şekilde, açık yeşil renk, 2×2 çekirdeği; açık mavi renk ise giriş görüntüsünün benzer büyüklükteki alanını temsil eder ve her ikisi çarpılır; Ortaya çıkan değerler (açık turuncu renkle işaretlenmiş) toplandıktan sonraki sonuç, çıktı özelliği haritasına bir giriş değerini temsil eder (Alzubaidi vd. 2021).



Şekil 3.12 Evrişimli katmanın her adımında gerçekleştirilen birincil hesaplamalar (Alzubaidi vd. 2021).

3.2.1.2 Aktivasyon Fonksiyonları

Girdiyi çıktıya eşlemek, her tür sinir ağındaki aktivasyon fonksiyonunun temel amacıdır. Girdi değeri, nöron girdisinin ağırlıklı toplamı ve sapması (varsa) hesaplanarak belirlenir. Bu şekilde aktivasyon fonksiyonunun, karşılık gelen çıktıyı oluşturarak belirli bir girdiye referansla bir nöronu ateşleyip ateşlemeyeceğine karar verdiği anlamına gelir.

Lineer olmayan aktivasyon katmanları, ESA mimarisinde ağırlıklara sahip tüm katmanlardan sonra (Tam bağlı katmanlar, evrişimli katmanlar vs.) kullanılır. Bu aktivasyon katmanları ESA'ya ekstra karmaşık şeyleri öğrenme yeteneği verir. Ayrıca aktivasyon fonksiyonu, ağı eğitmek için hata geri yayılmasının kullanılmasına izin verdiği için mimariye son derece önemli bir özellik olan ayırt etme yeteneğini kazandırır. Aşağıda ESA ve diğer derin yapay sinir ağlarında kullanılan aktivasyon

fonksiyonları verilmiştir (Glorot vd. 2011).

- Sigmoid: Bu aktivasyon fonksiyonunun girişi gerçek sayılar, çıkışı ise sıfır ile bir arasında sınırlıdır. Sinir ağı çalışmalarında yaygın olarak kullanılmaktadırlar, ancak ESA ile birlikte kullanımlarında iki ana dezavantaja sahip olurlar. Bu dezavantajlardan birincisi doyunluk ve yok olan gradyan değerleri, ikincisi ise sigmoid çıktılarının sıfır merkezli olmaması ve gradyan değerlerinin pozitif ve negatif değerler arasında salınmasına neden olmasıdır. Sigmoid fonksiyonu eğrisi S şeklindedir. Matematiksel olarak Denklem 3.1 ile gösterilebilir.

$$f(x)_{sigm} = \frac{1}{1+e^{-x}} \quad (3.1)$$

- Tanh: Tanh fonksiyonu sigmoid fonksiyonunun büyütülmüş bir versiyonu olarak düşünülebilir. Ancak çıktı değerleri -1 ile 1 arasında sınırlıdır. Doğrusal değildir. Sigmoid fonksiyonundan farklı olarak çıktısı sıfır merkezlidir. Bu nedenle, pratikte tanh doğrusal olmama durumu sigmoid doğrusal olmama durumuna tercih edilir. Matematiksel olarak Denklem 3.2 ile gösterilebilir.

$$f(x)_{tanh} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.2)$$

- ReLU: ESA bağlamında en çok kullanılan işlevdir. Girdinin tüm değerlerini pozitif sayılara dönüştürür. Daha düşük hesaplama yükü, ReLU'nun diğer aktivasyon fonksiyonlarına göre temel avantajıdır. Matematiksel olarak Denklem 3.3 ile gösterilebilir.

$$f(x)_{ReLU} = \max(0, x) \quad (3.3)$$

Zaman zaman ReLU kullanımı sırasında birkaç önemli sorun ortaya çıkabilir. Örneğin, içinden daha büyük bir gradyan akan bir hata geri yayılma algoritması düşünün. Bu gradyanı ReLU işlevinden geçirmek, ağırlıkları, nöronun bir kez daha etkinleştirilmemesini sağlayacak şekilde güncelleyecektir. Bu sorun,


"Dying ReLU" olarak adlandırılır. Bu tür sorunları çözmek için bazı ReLU alternatifleri mevcuttur.

- Leaky ReLU: ReLU aktivasyon fonksiyonunda uygulanan negatif girişleri küçültme işlemi yerine, bu negatif girişlerin göz ardı edilmemesini sağlamaktadır. Leaky ReLU aktivasyon fonksiyonu özellikle dying ReLU problemini çözmek için tercih edilmektedir. ReLU'nun negatif girişleri küçültmek yerine, bu aktivasyon fonksiyonu bu girişlerin asla göz ardı edilmemesini sağlar. Dying ReLU problemini çözmek için kullanılır. Leaky ReLU, Denklem 3.4'deki gibi matematiksel olarak temsil edilebilir (Nair vd. 2010).

$$f(x)_{LeakyReLU} = f(x) = \begin{cases} x, & x > 0 \\ mx, & x \leq 0 \end{cases} \quad (3.4)$$

m sızıntı faktörünü ifade etmektedir ve negatif değerlerin tamamen göz ardı edilmesini önler. Genellikle 0,001 gibi çok küçük bir değer tercih edilmektedir.

Yukarıda anlatılan aktivasyon fonksiyonlarının grafikleri Şekil 3.13'de verilmiştir.



Şekil 3.13 Aktivasyon fonksiyonları a) ReLU, b) Sigmoid ve c) Tanh (Singh vd. 2021).

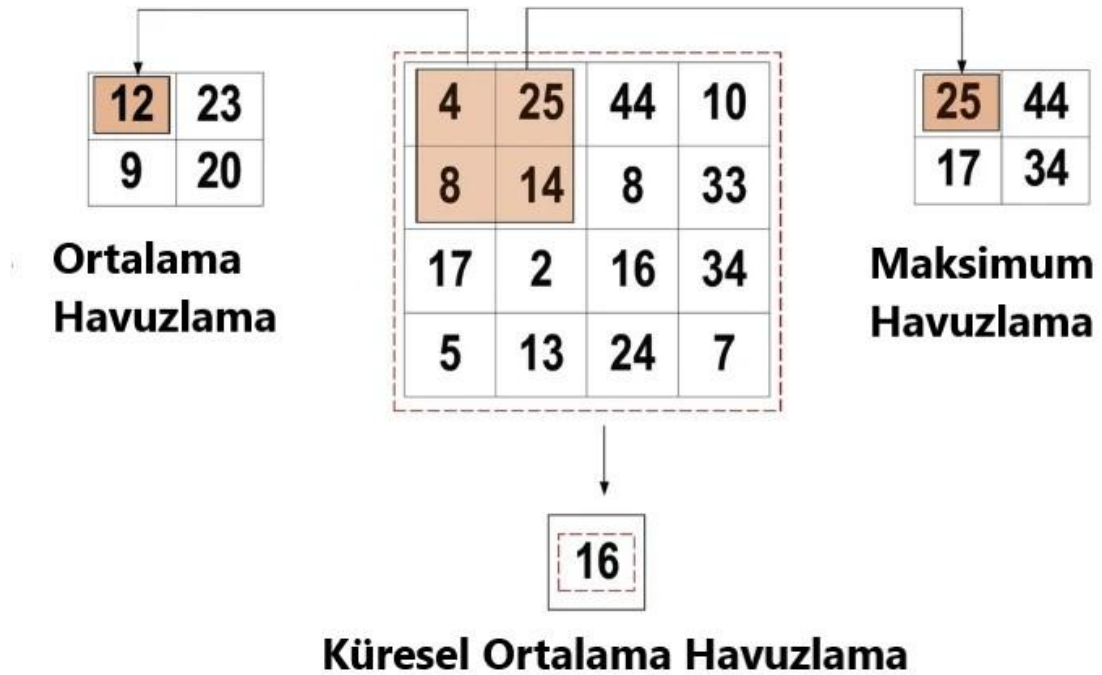
3.2.1.3 Havuzlama Katmanı

ESA'nın bir parçası ve hiyerarşideki evrişimden sonraki ikinci katmandır. Bu katman normalde iki evrişim katmanının ortasında bulunur. Havuzlama görüntünün belirli bir

bölümündeki komşu pikseller üzerinde işlemler yaparak, görüntünün boyutunu azaltır. Evrişimsel konvolüsyon katmanından bir grup uzamsal veriyi girdi olarak alır, verinin boyutunu küçültür ve çıktı olarak bir sonraki katmana iletir.

Havuzlama, aktivasyon haritasının boyutlarını azaltmak için önemli bir adımdır, yalnızca önemli özellikleri korurken aynı zamanda uzay değişmezliğini de (bilgi kaybını) azaltır. Bu şekilde model için öğrenilebilir özelliklerin sayısını azaltır ve öğrenim yavaşlığı, aşırı öğrenme gibi sorunların önüne geçilmiş olunur.

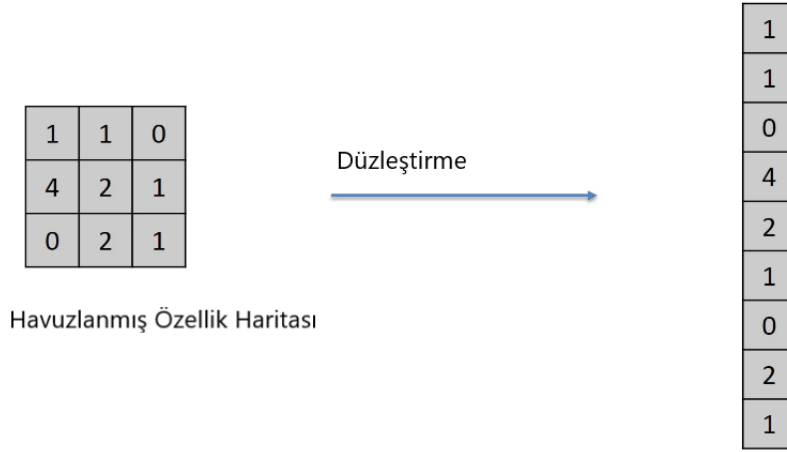
Çeşitli havuzlama katmanlarında kullanım için çeşitli havuzlama yöntemleri mevcuttur. Bu yöntemler arasında ağaç havuzlama, kapılı havuzlama, ortalama havuzlama, minimum havuzlama, maksimum havuzlama, küresel ortalama havuzlama (global average pooling, GAP) ve global maksimum havuz oluşturma gibi teknikler yer alır. Bu teknikler en bilinen ve en sık kullanılan havuzlama yöntemleridir. Şekil 3.14, ilk üç havuzlama işlemini göstermektedir (Ajit vd. 2020).



Şekil 3.14 Havuzlama teknik ve yöntemleri (Alzubaidi vd. 2021).

3.2.1.4 Düzleştirme Katmanı


Havuzlama katmanından sonra birleştirilmiş özellikli harita elde edildiğinde, sonraki adım onu düzleştirmektir. Düzleştirme, havuzlanmış özellik haritası matrisinin tamamının tek bir sütuna dönüştürülmesini ve daha sonra işlenmek için tam bağımlı katmana iletilmesini sağlamaktadır. Şekil 3.15'te düzleştirme işlemi gösterilmektedir.



Şekil 3.15 Düzleştirme tekniği (İnt.Kyn. 4).

3.2.1.5 Tamamen Bağlı Katman

Tam bağımlı katmanlar ESA'ların sınıflandırma veya regresyon için kullanılmak üzere aktivasyonlardan tahminler oluşturmaya çalışan ve bir çok katmanın birleşiminden oluşabilen son an katmanlar bütünüdür. Bu katmandaki nöronlar, normal bir yapay sinir ağında olduğu gibi bir önceki katmandaki tüm nöronlara tamamen bağlıdır. Burada üst düzey akıl yürütme yapılıır. Nöronlar uzamsal olarak düzenlenmemiştir (tek boyutlu). Veriler üzerindeki tüm muhakeme ve hesaplamalar burada yapılır. Şekil 3.16'da tam bağımlı katman tekniği gösterilmiştir (Singh vd. 2021).



Şekil 3.16 Tam bağlı katman şematik gösterimi (Alzubaidi vd. 2021).

3.2.1.6 Kayıp Fonksiyonları

ESA mimarisinin son katmanını temsil eden tam bağlı katmandan nihai sınıflandırma elde edilir. ESA modelindeki eğitim örneklerinde oluşturulan tahmin edilen hatayı hesaplamak için ise çıktı katmanında bazı kayıp fonksiyonları kullanılır. Bu şekilde istenen ve gerçek çıktı arasındaki tutarsızlık için bir ceza olan kayıp veya hata değerleri hesaplanır. Hesaplanan bu hata değerleri, gerçek çıktı ile tahmin edilen çıktı arasındaki farkı ortaya çıkarır. Çeşitli problem türlerinde çeşitli kayıp fonksiyonu türleri kullanılır. Aşağıda bazı kayıp fonksiyon türleri kısaca açıklanmaktadır (Aloysius ve Geetha 2017).

- Çapraz Entropi veya Softmax Kaybı İşlevi: Bu işlev, ESA model performansını ölçmek için yaygın olarak kullanılmaktadır. Günlük kayıp işlevi olarak da adlandırılır. Çıktısı bir olasılıktır $o \in \{ 0, 1 \}$. Çıktı katmanında, çıktıyı bir olasılık dağılımı içinde üretmek için softmax aktivasyonlarını kullanır. Çıktı sınıfı olasılığının matematiksel temsili Denklem 3.5'de verilmiştir.

$$p_i = \frac{e^{a_i}}{\sum_{k=1}^N e_k^a} \quad (3.5)$$

Burada e^{a_i} , önceki katmandan normalleştirilmemiş çıktıyı temsil ederken, N çıktı katmanındaki nöronların sayısını temsil eder. Son olarak, çapraz entropi

kayı fonksiyonunun matematiksel temsili Denklem 3.6'da gösterilmiştir.

$$H(p, y) = - \sum_i y_i \log(p_i) \quad \text{where } i \in [1, N] \quad (3.6)$$

- b. Öklid Kaybı Fonksiyonu: Bu fonksiyon regresyon problemlerinde yaygın olarak kullanılmaktadır. Tahmini Öklid kaybının matematiksel ifadesi Denklem 3.7'de verilmiştir.

$$H(p, y) = \frac{1}{2N} \sum_{i=1}^N (p_i - y_i)^2 \quad (3.7)$$

- c. Mentşe Kaybı Fonksiyonu: Bu fonksiyon genellikle ikili sınıflandırma ile ilgili problemlerde kullanılır. Bu sorun, maksimum marj tabanlı sınıflandırma ile ilgilidir. Matematiksel formülü Denklem 3.8'de verilmiştir.

$$H(p, y) = - \sum_{i=1}^N \max(0, m - (2y_i - 1) p_i) \quad (3.8)$$

Bu denklemde m marjı genellikle 1'e ayarlanır. Tahmin edilen çıktı p_i ve istenen çıktı y_i ile gösterilir.

3.2.1.7 ESA'ları Düzenleme

Evrişimsel sinir ağları gibi karmaşık modeller, görünmeyen verilere genelleme yapmak yerine eğitim setindeki kendine özgü kalıpları ezberlemedeki esneklikleri nedeniyle fazla uyum sağlamaya meyillidir. Genelleme hatasını azaltmayı amaçlayarak (eğitim hatası kastedilmemektedir) bir öğrenme algoritmasında yaptığımız herhangi bir değişikliğe düzenleme denir. Modeli düzenleme tekniklerini kullanarak yeterince basit tutmak, ağı daha önce görmediği veri noktaları üzerinde iyi bir şekilde genelleme yapmasına olanak tanır. Başlıca önemli düzenleme tekniklerine bırakma, veri büyütme ve erken durdurma örnek olarak verilebilir (Hou ve Wang 2019).

- Bırakma: Düzenleme teknikleri içinde yaygın olarak kullanılan bir tekniktir.

Her eğitim döneminde, nöronlar rastgele düşürülür. Bunu yaparken, özellik seçme gücü tüm nöron grubuna eşit olarak dağıtılır ve aynı zamanda modeli farklı bağımsız özellikleri öğrenilmeye zorlanır. Eğitim sürecinde, bırakılan nöronlar geri yayılımın veya ileri yayılımın bir parçası olmayacaktır. Buna karşılık, test işlemi sırasında tahmin gerçekleştirmek için tam ölçekli ağ kullanılmaktadır (Poernomo ve Kang, 2018).

- **Veri Büyütme:** Veri kümesi büyütme, döndürme, orijinal görüntüdeki bazı piksellere bulanıklık ekleme veya kırpma gibi küçük değişiklikler yaparak mevcut eğitim verilerinden yapay olarak veri üretme işlemidir. Modeli büyük miktarda veri üzerinde eğitmek, fazla uydurmayı önlemenin en kolay yoludur.
- **Erken Durdurma:** Erken durdurma yöntemindeki asıl amaç, eğitim verilerine ve modele bir sinir ağı yerleştirirken, ağın her yinelemeden sonra görünmeyen veriler üzerinde değerlendirilmesidir. Modelin doğrulama verileri üzerindeki performansı iyileşmiyorsa, doğrulama hatası belirli yinelemeler için artıyor veya aynı kalıyorsa, modeli daha fazla eğitmenin bir anlamı yoktur. Model eğitimini en düşük eğitim hatasına ulaşmadan durdurma işlemi, erken durdurma olarak bilinir.

3.2.1.8 ESA'ların Öğrenme Süreci

ESA'ların öğrenme sürecinde iki ana durum vardır: bunlardan birincisi öğrenme algoritmasının seçilmesi (optimizer), ikincisi ise çıktıyı geliştirmek için öğrenme algoritması ile birlikte geliştiricilerin (AdaDelta, Adagrad ve momentum gibi) kullanılmasıdır.

Çok sayıda öğrenilebilir parametreye (örneğin önyargılar, ağırlıklar, vb.) veya hatayı en aza indirmeye (gerçek ve tahmin edilen çıktı arasındaki varyasyon) dayanan kayıp fonksiyonları, tüm denetimli öğrenme algoritmalarının temel amacıdır. Bir ESA ağı için gradyan tabanlı öğrenme teknikleri sık olarak kullanılmaktadır. Ağ parametreleri her zaman tüm eğitim dönemlerinde güncellenmeli ve ağ hatayı en aza indirmek için tüm

eđitim d6nemlerinde yerel olarak optimize edilmiř yanıtı aramalıdır.

6đrenme oranı, parametre g6ncellemesinin adım boyutu olarak tanımlanır. Eđitim d6nemi, bir seferde eksiksiz eđitim veri k6mesini ieren parametre g6ncellemesinin tam bir tekrarını temsil eder. 6đrenme oranının bir hiper-parametre olmasına rađmen, 6đrenme s6recini 6nemli bir řekilde etkileyebilir. Bu y6zden 6đrenme oranının akıllıca ve ađa uygun bir řekilde seilmesi gerekmektedir.

Gradyan iniři veya gradyan tabanlı 6đrenme algoritması: Bu algoritma eđitim hatasını en aza indirmek iin her eđitim d6neminde ađ parametrelerini tekrar tekrar g6nceller. Daha spesifik olarak, parametreleri dođru bir řekilde g6ncellemek iin, parametrelerine g6re birinci dereceden t6rev fonksiyonları uygulayarak ađın gradyanını (eđimini) hesaplamayı amalar. Ardından, hata deđeri azaltılmak iin parametreler gradyanın ters y6n6nde g6ncellenir. Parametre g6ncelleme iřlemi, her n6rondaki gradyanın 6nceki katmandaki t6m n6ronlara geri yayıldıđı ađ geri yayılım yoluyla gerekleřtirilir.

Gradyan tabanlı 6đrenme algoritmasının farklı varyantları mevcuttur ve ařađıda yaygın olarak kullanılan algoritmalardan kısaca bahsedilmiřtir.

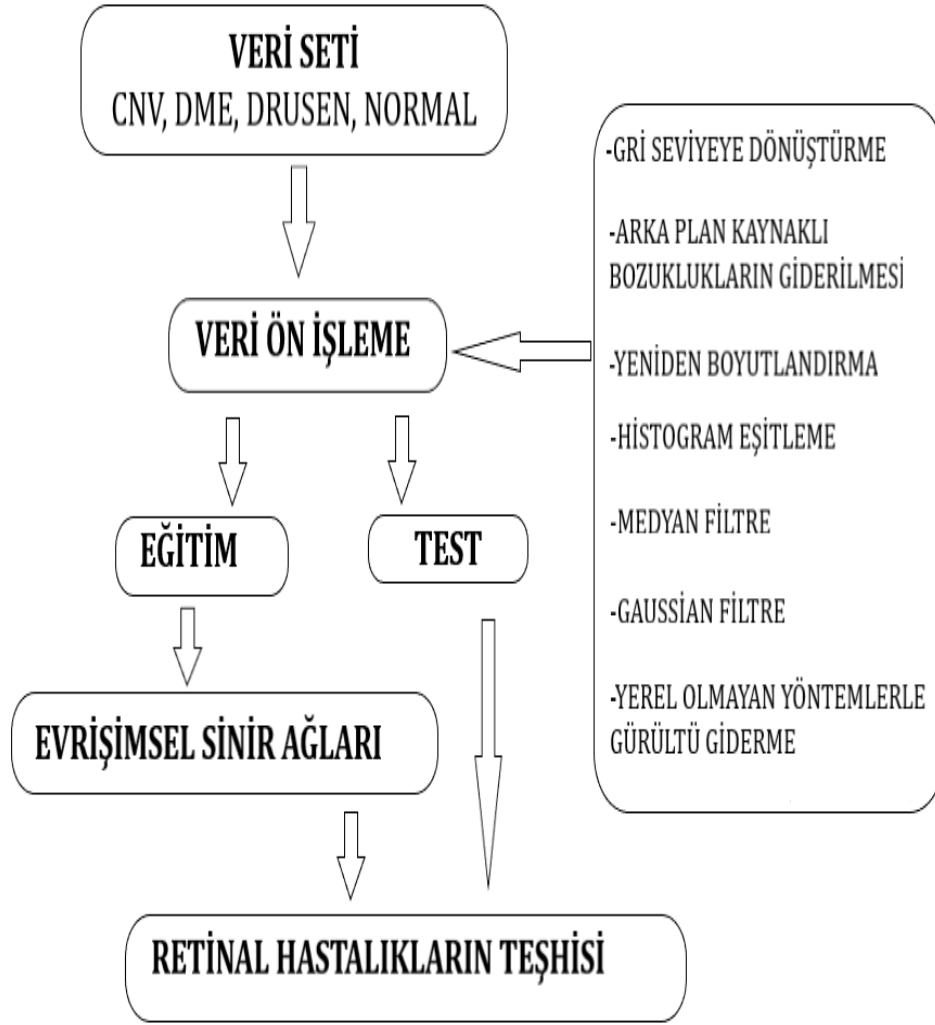
- Toplu Gradyan Iniři: Bu teknikte ađ parametreleri, ađ 6zerinden t6m eđitim veri k6meleri dikkate alınarak yalnızca bir kez g6ncellenir. T6m eđitim setinin gradyanını hesaplar ve ardından parametreleri g6ncellemek iin bu gradyanı kullanır. K66k boyutlu bir veri k6mesi iin, ESA modeli daha hızlı yakınsar ve toplu gradyan iniřini kullanarak ekstra kararlı bir gradyan oluřturur. Parametreler her eđitim d6nemi iin yalnızca bir kez deđiřtirildiđinden, 6nemli miktarda kaynak gerekir. Buna karřılık, b6y6k bir eđitim veri k6mesine yakınsama iin ek s6re gerekir ve yerel bir optimuma yakınsanabilir (Hinton vd. 2012).
- Stokastik Gradyan Iniři: Bu teknikte her eđitim 6rneđi iin bir parametre g6ncellemesi gerekleřtirir. Toplu gradyan iniři, her parametre g6ncellemesinden 6nce benzer 6rnekler iin gradyanları yeniden hesapladıđı iin

büyük veri kümeleri için gereksiz hesaplamalar gerçekleştirir. Skolastik gradyan ise, her seferinde bir güncelleme gerçekleştirerek bu fazlalığı ortadan kaldırır. Bu nedenle genellikle çok daha hızlıdır ve çevrimiçi öğrenmek için de kullanılabilir. Ancak, sıklıkla güncelleme yaptığı için, cevap yönünde son derece gürültülü adımlar atmakta ve bu da yakınsama davranışının oldukça kararsız hale gelmesine neden olmaktadır (Shrestha ve Mahmood 2019).

- Mini Toplu Gradyan İnişi: Bu yaklaşımda, eğitim örnekleri, aralarında hiçbir örtüşme olmaksızın, küçük boyutlu mini gruplara ayrılır. Ardından, her mini grupta gradyan hesaplamasının ardından parametre güncellemesi gerçekleştirilir. Bu yöntemin avantajı, hem toplu gradyan inişi hem de stokastik tekniklerinin avantajlarını birleştirmesinden kaynaklanmaktadır. Böylece, sabit bir yakınsama, daha fazla hesaplama verimliliği ve ekstra bellek etkinliğine sahiptir (Khairat vd. 2017).
- Adaptive Moment Estimation (Adam): Yaygın olarak kullanılan bir diğer optimizasyon tekniği veya öğrenme algoritmasıdır. Derin öğrenme optimizasyonundaki en son trendleri temsil etmektedir. Bu algoritma, ikinci dereceden bir türev kullanan Hessian matrisi ile temsil edilebilir. Adam, derin sinir ağlarını eğitmek için özel olarak tasarlanmış bir öğrenme stratejisidir. Bu optimizasyon tekniğinin iki önemli avantajı daha verimli bellek kullanımı ve daha az hesaplama gücü gerektirmesidir. Adam'ın mekanizması, modeldeki her parametre için uyarlanabilir öğrenme oranını hesaplamaktır (Zhang 2018).

3.3 Önerilen Sistem

Şekil 3.17'de OCT görüntülerinden retinal hastalıkların tespiti için önerilen sistemin akış şeması verilmiştir. Önerilen sistem görüntü işleme teknikleri ve derin öğrenme tabanlı evrimsel sinir ağlarından oluşmaktadır. Uygulanan her adım aşağıdaki bölümlerde daha detaylı bir şekilde anlatılmıştır.



Şekil 3.17 Çalışma Diyagramı.

3.3.1 Veri Seti


Oluşturulan ESA modelinin eğitim ve testi için Kermany vd. (2018) tarafından kullanılan halka açık kaynaklı optik koherens tomografi görüntüleri veri seti kullanılmıştır. Görüntüler, California San Diego Üniversitesi Shiley Göz Enstitüsü, California Retinal Araştırma Vakfı, Tıp Merkezi Oftalmoloji Associates, Şanghay Birinci Halk Hastanesi ve Pekin Tongren Göz Merkezi'nden 2013 ve 2017 yılları arasında yetişkin hastaların retrospektif kohortlarından seçilmiştir.

Veri seti, Çizelge 3.1’de gösterildiği gibi, orijinal olarak 83.484 eğitim görüntüsü ve 1.000 test görüntüsü içeren dört sınıftan oluşmaktadır. Eğitim veri setinde CNV sınıfı 37.205, DME sınıfı 11.348, drusen sınıfı 8.616 ve Normal sınıfı 26.315 görüntü içermektedir. Test veri seti her sınıf için 250 görüntüye sahiptir.

Çizelge 3.1 Veri kümesinin açıklanması.

Veri Seti	Sınıf	Görüntü Sayısı
EĞİTİM	CNV	37.205
	DME	11.348
	DRUSEN	8.616
	NORMAL	26.315
TEST	CNV	250
	DME	250
	DRUSEN	250
	NORMAL	250

Veri setindeki görüntüler tek tip boyut ve kaliteye sahip değildir. Her sınıftaki görseller farklı görsel boyutlarına ve görsel kalitelerine sahiptir. Tüm görüntülerin tek biçimli şekilleri yoktur. Her görüntünün yakınlaştırma oranı birbirinden farklıdır. Çoğu görüntüde tuz ve biber gürültüsü vardır ve bazı görüntüler normal OCT görüntülerinden daha ciddi gürültüye sahiptir. Orijinal OCT görüntülerini kullanarak ESA'ları eğitebiliriz. Ancak daha fazla yakınsama süresi gerektirebilir ve distorsiyon nedeniyle daha fazla hata oluşturabilir. Şekil 3. 18’de bu görüntülere örnekler verilmiştir.



Şekil 3.18 Veri setinden bazı örnekler.

3.3.2 Veri Ön İşleme

Ön işleme için ilk adımda, tüm görüntüler gri seviyeye dönüştürülmüştür. Daha sonra görüntülerin arkasındaki beyaz fondan kaynaklanan görüntü şekil bozuklukları giderilmeye çalışılmıştır. Arka fondan kaynaklanan bozuklukların giderilmesi için iki görüntüyü birleştirme yöntemine (piksellerinin çarpılması işlemi) başvurulmuştur. Bu aşama iki ana adımdan oluşmaktadır.


Birinci adımda görüntüler üzerinde eşikleme işlemi uygulanmıştır. Eşikleme giriş olarak verilen görüntüyü ikili görüntüye çevirmek için kullanılan bir yöntemdir. İkili görüntü (binary), görüntünün siyah ve beyaz olarak tanımlanmasıdır. Görüntü üzerindeki gürültüleri azaltmak veya nesne belirlemek gibi farklı amaçlar için kullanılabilir. Giriş olarak verilen görüntü üzerinde uygulanan eşikleme tipine bağlı olarak, pikselleri verilen eşik değerine göre siyah ya da beyaz olarak günceller (Bradley ve Roth 2007).

Yapılan çalışmada OCT görüntüleri üzerinde ikili eşikleme (binary treshold) işlemi uygulanmıştır.

Eşik sınırları için de 240 ve 255 piksel değerleri belirlenmiştir. Bu sayede görüntü üzerindeki piksellerin en küçük değeri 240'a ve en büyük değeri ise 255'e eşitlenmiştir.

Daha sonra bu görüntüler üzerinde birleştirmeden kaynaklanacak problemlerin giderilmesi için morfolojik dönüşümler uygulanarak ayarlamalar yapılmıştır. Son olarak da beyaz arka plan piksel değerleri (RGB = (0, 0, 0)) siyah piksel değerleriyle (RGB = (255, 255, 255)), siyah arka plan piksel değerleri (RGB = (255, 255, 255)) beyaz piksel değerleriyle (RGB = (0, 0, 0)) değiştirilmiştir.

İkinci adımda ise ilk adımda uygulanan görüntü işleme tekniklerine sahip görüntü ile orijinal görüntünün piksel değerleri çarpılarak istenilen görüntüye ulaşılmıştır. İkinci adımın son basamağı olarak ise tüm görüntülerin aynı boyutta olabilmesi için 128x128 ölçülerinde yeniden boyutlandırma işlemi yapılmıştır. Şekil 3.19'da bu adımlar sonucu elde edilen görüntüler gösterilmiştir.

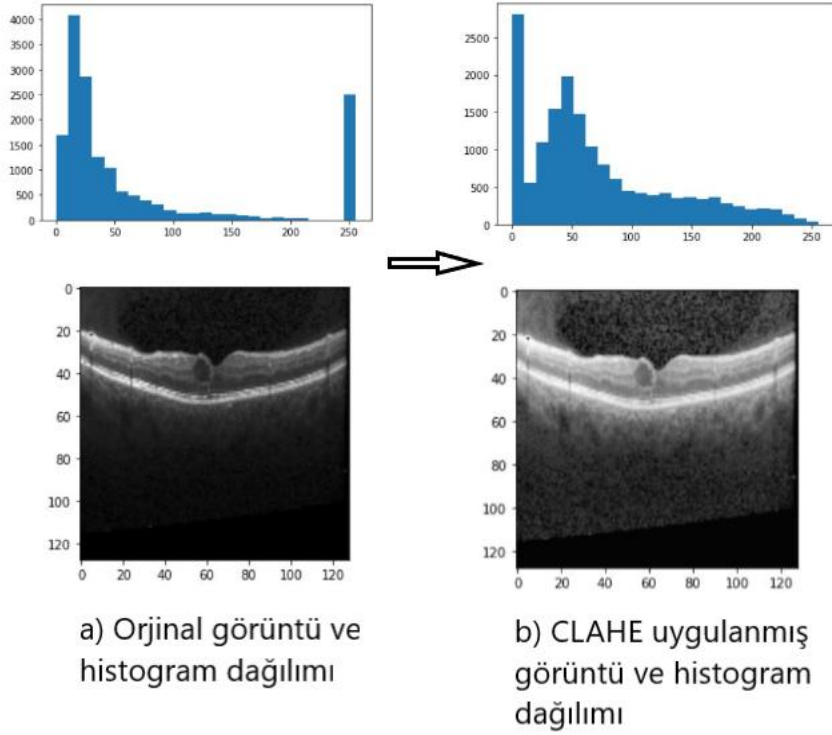


Şekil 3.19 Arka fon doldurma işlemi.

Veriler üzerinde boşluk doldurma ve boyutlandırma işlemi yapıldıktan sonra görüntü üzerindeki gürültülerin giderilmesi ve hastalıkların teşhis edilmesindeki önemli noktaların belirginleştirilmesi için diğer ön işleme tekniklerine geçilmiştir. Bu aşama 3 ana adımdan oluşmaktadır.

1. Kontrast Sınırlı Uyarlamalı Histogram Eşitleme: Dijital görüntülerde kontrastı iyileştirmek için çoğunlukla kullanılan yöntemlerden birisi histogram eşitleme yöntemidir. Görüntünün genel kontrastını iyileştirmeye çalışır. Yani görüntünün tamamını içeren histogram dağılımı üzerinde işlemler yapar. Histogram eşitleme, basit ve etkili bir yöntemdir. Histogram dağılımı dengeli olmayan bir görüntünün kontrastının düzeltilmesinde başarılı sonuçlar vermektedir. Bu yöntem ile görüntünün histogramı dengeli bir hale gelmektedir. Bu şekilde kontrastın iyileşmesini sağlar.

Kontrast sınırlı uyarlamalı histogram eşitleme (contrast limited adaptive histogram equalization - CLAHE) yöntemi ise bir çeşit uyarlamalı kontrast geliştirme yöntemidir. Ancak arasında farklar bulunmaktadır. CLAHE yönteminde her görüntü parçalara ayrılır. Her bir parçanın histogramı bulunur (Tayal 2021). Ardından histogram kırpma limiti kullanılarak kırpılır ve histogram buna göre düzenlenir. Her bir parçanın kontrastı geliştirilir. Bunun için histogram eşitleme yönteminden faydalanılır. Ardından bu parçalar birleştirilerek kontrastı iyileştirilmiş görüntü elde edilir. Bu algoritma, tıbbi görüntülerde ve oftalmolojide yaygın olarak kullanılmaktadır. Gri seviye görüntülerin gizli özelliklerinin görünürlüğünü artırmaya yardımcı olur. Ancak arka plan ve gürültünün etkisini de ortaya çıkarabilir ve bir sonraki görüntü işleme adımlarında istenmeyen sonuçlara da neden olabilir (Yadav 2014). Şekil 3.20'de orijinal görüntü ve CLAHE uygulanmış görüntü arasındaki fark gösterilmiştir.




Şekil 3.20 Orijinal görüntü ve kontrast sınırlı uyarlamalı histogram eşitleme uygulanmış görüntünün histogram dağılımı.

Şekil 3.20’de de görüldüğü üzere histogram eşitlemeye uğramış görüntülerde istenmeyen gürültü oluşumlarına maruz kalınmıştır. Bu durumun etkilerini en aza indirmek için ileriki adımlarda gürültü giderme teknikleri kullanılmıştır. Ama öncelikle diğer adımda görüntülerin teşhis edilmesinde önemli olan noktaların vurgulanması için maskeleme yöntemine geçilmiştir.

2. Maskeleme Yöntemi: Bu yöntem iki görüntünün piksellerinin birleştirilmesi mantığına dayanmaktadır (Polesel vd. 2000). Yapılan çalışmada maskeleme yöntemi için aynı görüntünün iki kopyası kullanılmış ve üzerlerinde parlaklık, saydamlık gibi ayarlar yapılarak kullanıma hazırlanmıştır. İlk görüntü arka planda kullanılmak üzere medyan filtre uygulanarak bulanıklaştırılmış ve gürültülerden arındırılmıştır. Medyan yumuşatıcılar, gürültü nedeniyle bozulmuş görüntüleri temizlemek için görüntü işlemede yaygın olarak kullanılır. Medyan filtreleri özellikle aykırı değerlerin kaldırılmasında etkilidir. Genellikle "tuz ve

biber" gürültüsü olarak anılan aykırı değerler, iletimdeki bit hataları nedeniyle sıklıkla mevcuttur veya sinyal toplama aşamasında ortaya çıkar.

Temel fikri, her pikseli komşu piksellerin (penceredeki pikseller) medyanı ile değiştirmektir. Bu çalışmada görüntüler üzerine medyan filtre uygulandıktan sonra saydamlık ve parlaklık ayarları yapılarak arka plan için kullanıma hazır hale getirilmiştir. Ön plan için ise orijinal görüntüler kullanıldı. Bu iki görüntünün piksel değerleri toplanarak yeni görüntü oluşturuldu. Şekil 3.21'de maskeleme yöntemine ait süreç akışı gösterilmiştir.



Şekil 3.21 Maskeleme işlem süreci.

Uygulanan histogram eşitleme ve maskeleme yönteminden sonra görüntüler üzerindeki tuz-biber gürültüsünde ciddi bir artış olduğu gözlemlenmiştir. Bu yüzden son aşamada görüntü üzerinde gauss filtresi ve yerel olmayan araçlarla gürültü giderme teknikleri uygulanmıştır.


3. Gauss Filtre ve Yerel Olmayan Ortalama Filtre: Gauss yumuşatma operatörü, görüntüleri 'bulanıklaştırmak' ve ayrıntı ile paraziti ortadan kaldırmak için

kullanılan 2 boyutlu bir evrişim operatörüdür. Bu anlamda, medyan filtreye benzer, ancak Gauss ('çan şekilli') tümseğinin şeklini temsil eden farklı bir çekirdek kullanmaktadır (Wuethrich vd. 2016).

Yerel olmayan ortalama filtresi, ilk olarak Buades vd. (2011) tarafından önerilen bir gürültü giderme algoritmasıdır. Yöntem, görüntü üzerindeki bir pikselin değerini benzer piksel değerlerinin ortalaması alınarak, yeni bir piksel değeri oluşturma prensibine dayanmaktadır (Buades vd. 2011).

Görüntü üzerindeki benzer piksel değerleri her zaman komşu veya yakın mesafede olmayabilir. Bu yöntemde benzer piksel değerleri aranırken matris üzerinde geniş bir bölüm taramaktadır. Bu yöntemin diğer gürültü giderme tekniklerine göre avantajı daha geniş bir tarama alanında çalışma imkânı sağlamasıdır.

Şekil 3.22'de anlatılan gürültü giderme tekniklerinin uygulandığı görüntüler gösterilmektedir.




Şekil 3.22 Gürültü giderme teknikleri uygulanan görüntüler.

Bu tez çalışmasında kullanılan tüm görüntü işleme teknikleri Python'nın OPEN CV

kütüphanesi kullanılarak uygulanmıştır.

3.3.3 Önerilen ESA Modeli

Şekil 3.23’de çalışmada tasarlanan ESA modeli gösterilmiştir.



Şekil 3.23 ESA modeli genel şeması.

Şekil 3.23’de gösterildiği üzere ESA modelimizin özellik çıkarım kısmı 5 evrişim katmanından oluşmaktadır ve her evrişimden sonra 2*2 maksimum havuzlama katmanı bulunmaktadır. Evrişim katmanlarının tamamında ReLU aktivasyon fonksiyonu kullanılmıştır. Modelimizin sınıflandırma kısmı ise 1 düzeltme katmanı ve 5 tam bağı katmandan oluşmaktadır. Son tam bağı katman haricinde diğer 4 tam bağı katmanda ReLU aktivasyon fonksiyonları kullanılmıştır. Son katmanda ise softmax aktivasyon fonksiyonu kullanılmıştır. Modelimize girdi olarak üzerinde ön işleme teknikleri uygulanmış 128*128 ölçülerinde tek kanallı OCT görüntüleri verilmiştir. İlk evrişim katmanımızda 32 filtre, 3*3 çekirdek ve ReLU aktivasyon fonksiyonu kullanılmıştır. Ardından 2*2 maksimum havuzlama işlemi uygulanarak 64*64*32

boyutunda veriler elde edilmiştir.

Diğer katmanlardaki çıktı değerleri ise Çizelge 3.2’de ayrıntılı bir şekilde gösterilmiştir.

Çizelge 3.2 ESA mimarisindeki katmanların çıktı değerleri.

KATMAN	ÇIKTI DEĞERİ	ÖĞRENEBİLİR PARAMETRE SAYISI
Evrişim 1	128*128*32	320
Max Havuzlama	64*64*32	0
Evrişim 2	64*64*64	18.496
Max Havuzlama	32*32*64	0
Evrişim 3	32*32*128	73.856
Max Havuzlama	16*16*128	0
Evrişim 4	16*16*256	295.168
Max Havuzlama	8*8*256	0
Evrişim 5	8*8*512	786.944
Max Havuzlama	4*4*512	0
Düzleştirme	8.192	0
Tam Bağlı	256 Nöron	2.097.408
Tam Bağlı	128 Nöron	32.896
Tam Bağlı	64 Nöron	8.256
Tam Bağlı	32 Nöron	2.080
Tam Bağlı	4 Nöron	132

Toplam öğrenilebilir parametre sayısı 3.315.556

Çizelge 3.2’de de görüldüğü üzere 5. havuzlama katmanından sonra elde edilen tüm özelliklerin çıkışlarını tam bağlı katmana bağlamak ve 8.192 elemanlı tek boyutlu bir vektör oluşturmak için bir düzleştirme işlemi gerçekleştirilmiştir. Daha sonra sırasıyla 256, 128, 64, 32 ve 4 nöronlu tam bağlı katmanlar sayesinde sınıflandırma işlemi gerçekleştirilmiştir. Son 4 nöronlu katman, çıkışları (CNV, DME, DRUSEN, NORMAL) temsil etmektedir.

3.3.3.1 Modelin Eğitilmesi

ESA mimarisi, eğitim setinin 83.484 görüntüsü kullanılarak eğitilmiştir. Modelin

doğrulanması için de 32 görüntüden oluşan doğrulama veri seti kullanılmıştır. Eğitim sırasında birinci dereceden gradyan tabanlı stokastik optimizasyon prosedürü olan 'Adam' optimizasyon yöntemi kullanılmıştır. Bu optimizasyon yöntemi için öğrenme oranı 0.0001 olarak verilmiştir. Eğitim sürecinde mini parti boyutu (batch-size) 64, dönem sayısı (epoch) ise 48 olarak ayarlanmıştır. Kayıp fonksiyonu olarak çapraz entropi ve softmax fonksiyonu kullanılmıştır. Çizelge 3.3'de kullanılan eğitim parametreleri gösterilmiştir.

Çizelge 3.3 Modelde kullanılan eğitim parametreleri.

Eğitim Parametreleri	Değerleri
Öğrenme Optimizasyonu	ADAM
Öğrenme Oranı	0.0001
Mini Parti Boyutu (Batch Size)	64
Dönem Sayısı (Epoch)	48

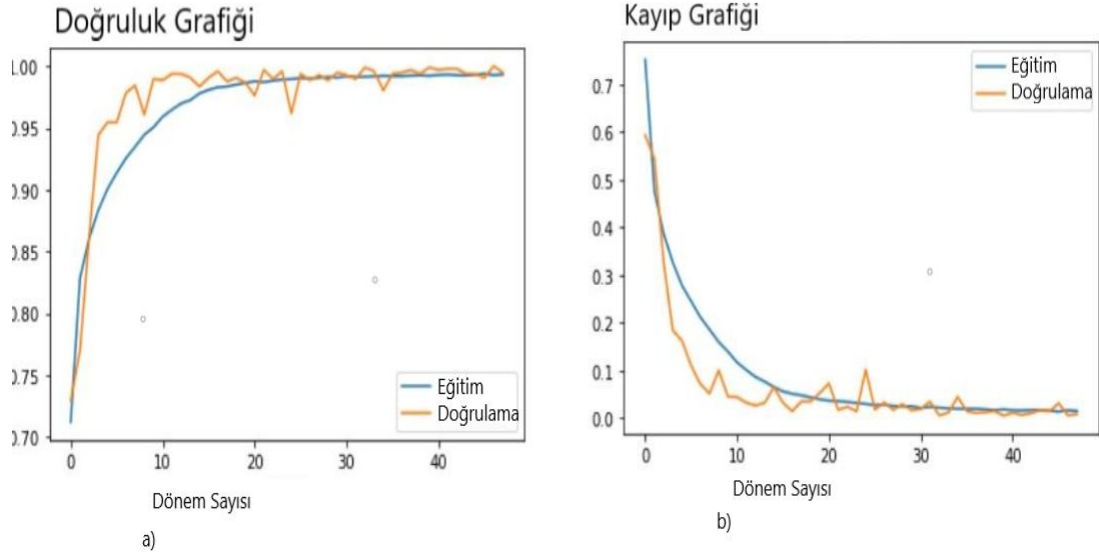
4. BULGULAR

Önerilen sistemde materyal ve metot bölümünde anlatılan görüntüleme teknikleri ve evrişimsel sinir ağları kullanılmıştır.

Ön işleme için ilk adımda, veri setindeki tüm görüntüler gri seviyeye dönüştürülmüştür. Veri setindeki görüntüler üzerinde arka fondaki beyaz boşluklara bağlı şekil bozuklukları tespit edilmiştir. Bu bozuklukların giderilmesi için iki görüntüyü birleştirme yöntemine (piksellerinin çarpılması işlemi) başvurulmuştur. Arka plandaki beyaz boşluklar doldurulduktan sonra tüm görüntülerin aynı boyutta olabilmesi için 128x128 ölçülerinde yeniden boyutlandırma işlemi yapılmıştır.

Veriler üzerinde gri seviyeye dönüştürme, boşluk doldurma ve boyutlandırma işlemi yapıldıktan sonra görüntü üzerindeki gürültülerin giderilmesi ve hastalıkların teşhis edilmesindeki önemli noktaların belirginleştirilmesi için görüntüler üzerinde sırasıyla histogram eşitleme, medyan filtre gauss filtre ve yerel olmayan ortalama filtresi kullanılmıştır. Ön işleme tekniklerinden sonra retinal hastalıkların teşhisi için 5 katmanlı evrişimsel sinir ağı mimarisi tasarlanmıştır. Tasarlanan 5 katmanlı evrişimsel sinir ağı mimarisinin eğitimi ve testi için ön işleme teknikleri sonucunda elde edilen görüntüler kullanılmıştır.

Oluşturulan model ile eğitim veri setinde 0,9940 doğruluk ve 0,0134 kayıp değerlerini elde edilmiştir. Doğrulama testin de ise 0,9948 doğruluk ve 0,0084 kayıp değerlerinde sonuçlar elde edilmiştir. Şekil 4.1'de eğitim sonucu elde edilen değerlerin grafikleri gösterilmiştir.



Şekil 4.1 Eğitim sonucunda elde edilen doğruluk ve kayıp grafiği.

Model eğitimini tamamladıktan sonra test veri setindeki görüntüler ile tekrar beslenmiştir. Bu işlem sonucundan ise 0,9948 doğruluk ve 0,0084 kayıp test sonuçları elde edilmiştir.

Modelin performansının daha detaylı analiz edilmesi için hata matrisi oluşturulup incelenmiştir. Hata matrisi, bir sınıflandırma problemindeki tahmin sonuçlarının bir özetidir. Doğru ve yanlış tahminlerin sayısı, sayı değerleriyle özetlenir ve her sınıfa göre ayrılır. Hata matrisi, sınıflandırma sırasında modelin nasıl tahminlerde bulunduğunu karşılaştırmalı olarak gösterir. Bu mekanizma, yalnızca sınıflandırıcı tarafından yapılan hataları değil, aynı zamanda model tarafından yapılan hataların türlerini de anlamamızı sağlar. Hata matrisinden, modelin performansını değerlendirirken göz önünde bulundurulacak kesinlik, geri çağırma (hassasiyet), f1-skoru, özgüllük ve doğruluk gibi değerleri ölçmek için de yararlanılmıştır.

Gerçek pozitif (True Positive, TP), gerçek negatif (True Negative, TN), yanlış pozitif (False Positive, FP) ve yanlış negatif ((False Negative, FN) değerleri, hata matrisinden türetilen değerlerdir.

Diğer önemli kriterlerin hesaplamaları için kullanılmışlardır (Tayal vd. 2021).

TP: doğru tahmin edilen pozitif sınıf;

FP: yanlış tahmin edilen pozitif sınıf;

FN: yanlış tahmin edilen negatif sınıf;

TN: doğru tahmin edilen negatif sınıf.

- Toplam Doğruluk: Sistemde doğru olarak yapılan tahminlerin tüm tahminlere oranıdır. Denklem 4.1'deki gibi hesaplanabilir.

$$DOĞRULUK (0 - 1 aralığı) = \frac{TP+TN}{FP+FN+TP+TN} \quad (4.1)$$

- Hassasiyet (Geri Çağırma): Doğru sınıflandırılmış pozitif kalıpların kesirini hesaplamak için kullanılır. Mümkün olduğu kadar yüksek olmalıdır. Denklem 4.2'deki gibi hesaplanabilir.

$$HASSASİYET (0 - 1 aralığı) = \frac{TP}{TP+FN} \quad (4.2)$$

- Kesinlik: Pozitif olarak tahmin edilen bir durumdaki başarıyı gösteren değerdir. Denklem 4.3'deki gibi hesaplanabilir.

$$KESİNLİK (0 - 1 aralığı) = \frac{TP}{TP+FP} \quad (4.3)$$

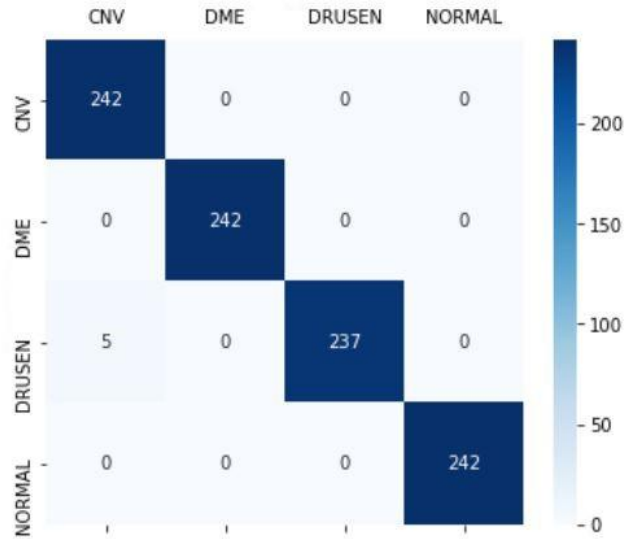
- Özgüllük: Doğru sınıflandırılan negatif kalıpların kesirini hesaplamak için kullanılır. Denklem 4.4'deki gibi hesaplanabilir.

$$\text{ÖZGÜLLÜK (0 - 1 aralığı)} = \frac{TN}{FP+TN} \quad (4.4)$$

- F1 puanı: Ağırlıklı ortalamayı hesaplamak için kesinlik ve geri çağırma değerlerini dikkate alır. Denklem 4.5'deki gibi hesaplanabilir.

$$F1 - SKORU (0 - 1 aralığı) = \frac{2*TP}{FP+FN+(2*TP)} \quad (4.5)$$

Şekil 4.2'de oluşturulan ESA modelinin hata matrisi verilmiştir.



Şekil 4.2 Hata matrisi.

Şekil 4.2'deki hata matrisine göre x eksini tahmin etiketlerini ve y eksenini gerçek etiketleri temsil etmektedir. Modelin testi için 968 görüntü kullanılmıştır ve her kategori için 242 veri bulunmaktadır. Koyu mavi hücreler doğru tahmin edilen görüntüleri

gösterir, yani tahmin edilen etiketler resimlerin gerçek etiketleriyle eşleşmektedir. Matris incelenecek olunursa model, drusen kategorisi hariç diğer 3 kategoride %100 doğru tahmin başarısı göstermektedir. Drusen kategorisinde ise 242 görüntü içinde 5 görüntüyü yanlış değerlendirerek CNV kategorisine etiketlemiştir. Toplam görüntü sayısı baz alınarak bakılırsa oluşturulan sistem 968 görüntüde 963 görüntüyü doğru sınıflandırarak %99'un üstünde başarı elde etmiştir.

Çizelge 4.1'de ise modelin kesinlik, geri çağırma ve f1-puan değerlerine yer verilmiştir.

Çizelge 4.1 Modelin performans değerleri.

	Kesinlik	Hassasiyet	F1-Puanı	Veri Sayısı
CNV	0,98	1,00	0,99	242
DME	1,00	1,00	1,00	242
DRUSEN	1,00	0,98	0,99	242
NORMAL	1,00	1,00	1,00	242

Son olarak ise modelin kategorilere göre doğruluk, özgüllük ve hassasiyet değerleri Çizelge 4.2'de verilmiştir.

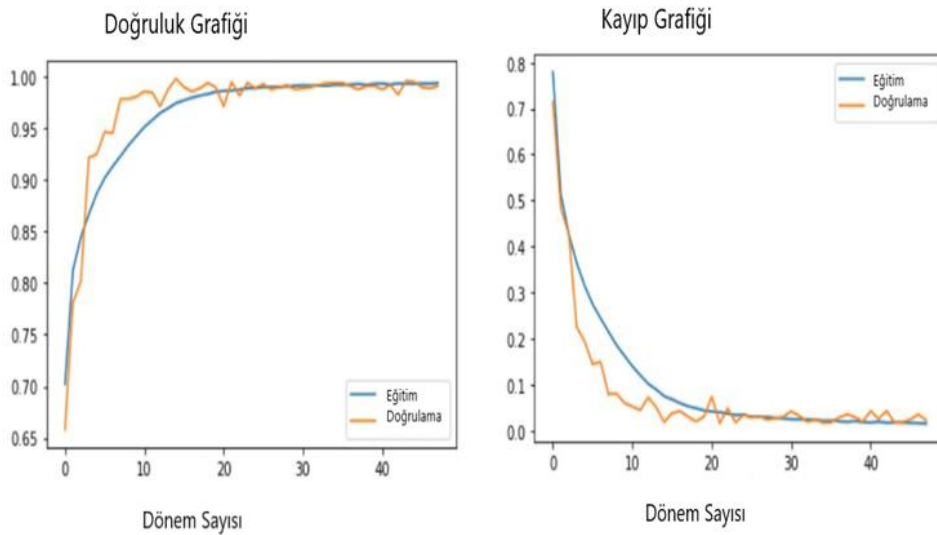
Çizelge 4.2 Modelin değerlendirme parametreleri.

	Hassasiyet	Özgüllük	Doğruluk
CNV	1	0,9931	0,9948
DME	1	1	1
DRUSEN	0,98	1	0,9948
NORMAL	1	1	1

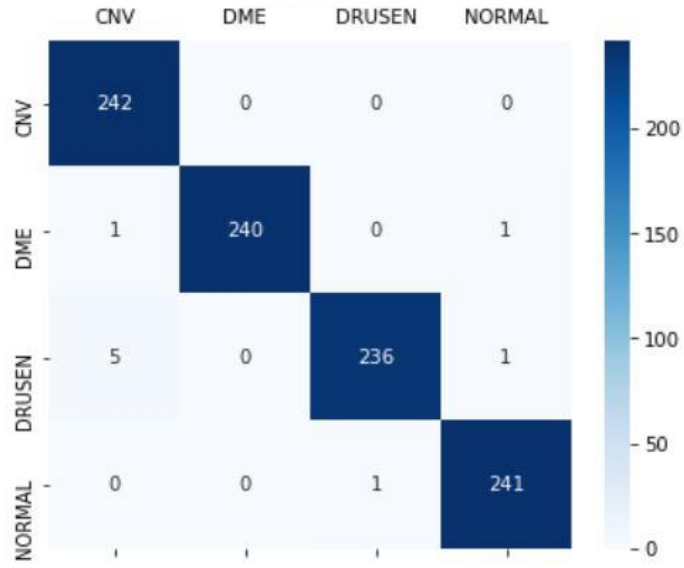
Alınan sonuçlar özetlenecek olunursa önerilen yöntem eğitim veri setinden 0,9940 doğruluk elde ederken test veri setinden 0,9948 doğruluk, 0,9948 hassasiyet ve 0,9983 özgüllük değerleri elde edilmiştir.

Çalışmada kullanılan ön işleme tekniklerinin ağ performansı üzerindeki etkilerinin tespit edilebilmesi için oluşturulan ESA mimarisi eğitim parametreleri değiştirilmeden, ön işleme teknikleri uygulanmayan görüntüler ile tekrar eğitilip, test edilmiştir. Bu aşamada Şekil 4.3'te gösterildiği üzere ESA mimarisine uygulanan eğitim veri setinden 0,9950 doğruluk ve 0,015 kayıp değeri elde edilmiştir. Test veri setinden ise 0,9907 doğruluk ve 0,0215 kayıp değeri elde edilmiştir.

Ön işlemsiz uygulanan görüntüler ile eğitilen ESA mimarisinden elde edilen hata matrisi Şekil 4.4'te verilmiştir. Sonuçlara bakıldığında ön işleme tekniği uygulanan ESA mimarisinde sadece drusen görüntülerinin sınıflandırılmasında hata gözlemlenirken, ön işlem uygulanmayan ESA mimarisinde diğer hastalıkların sınıflandırılmasında da hatalar gözlenmiştir.



Şekil 4.3 Görüntü işleme teknikleri uygulanmayan görüntüler ile eğitilen ESA mimarisinden elde edilen doğruluk ve kayıp grafikleri.



Şekil 4.4 Ön işleme teknikleri uygulanmayan görüntüler ile eğitilen ESA mimarisinin hata matrisi.

Çizelge 4.3'te ise modelin kesinlik, geri çağırma ve f1-puan değerlerine yer verilmiştir.

Çizelge 4.3 Ön işleme teknikleri uygulanmayan görüntüler ile eğitilen ESA mimarisinin performans değerleri.

	Kesinlik	Hassasiyet	F1-Puanı	Veri Sayısı
CNV	0,98	1,00	0,99	242
DME	1,00	0,99	1,00	242
DRUSEN	1,00	0,98	0,99	242
NORMAL	1,00	1,00	0,99	242

Son olarak ise modelin kategorilere göre doğruluk, özgüllük ve hassasiyet değerleri Çizelge 4.4'te verilmiştir.

Çizelge 4.4 Ön işleme teknikleri uygulanmayan görüntüler ile eğitilen ESA mimarisinin değerlendirme parametreleri.

	Hassasiyet	Özgüllük	Doğruluk
CNV	1	0,9917	0,9758
DME	0,9917	1	1
DRUSEN	0,9752	0,9986	0,9958
NORMAL	0,9959	0,9972	0,9918

Ön işleme teknikleri uygulanmayan görüntüler ile eğitilen ESA mimarisinden alınan sonuçlar özetlenecek olunursa eğitim sonucunda 0,9950 doğruluk elde edilirken test sonucunda 0,9907 doğruluk, 0,9907 hassasiyet ve 0,9969 özgüllük değerleri elde edilmiştir.

Sonuç olarak görüntü işleme teknikleri ile oluşturulan önerilen sistemin ön işlemsiz görüntülerle eğitilen ESA mimarisine göre daha başarılı olduğu tespit edilmiştir. Ön işleme teknikleri ile oluşturulan sistemin doğruluk performansında 0,0041 oranında bir artış gözlemlenirken, hassasiyet ve özgüllük değerlerinde de sırasıyla 0,0041 ve 0,0014 oranlarında bir artış gözlemlenmektedir.

5. TARTIŞMA ve SONUÇ

Dünya çapında yüksek sayıda kayıtlı retina hastalıklarına bağlı körlükler gözlemlenmektedir. Aynı zamanda retinal hastalıkların görme duyusu üzerindeki etkisinin yanı sıra, kalp hastalıkları ve hipertansiyon gibi hastalıklara da yol açtığı bilinmektedir. Bu tür olumsuzlukların engellenmesi veya en aza indirgenmesi için erken teşhis ve tedavi oldukça önemlidir. OCT ve FFA görüntüleme teknikleri retina hastalıklarının tanısında en çok tercih edilen iki yöntemdir. Bu görüntüleme teknikleri sayesinde elde edilen oftalmolojik görüntülerin analizinin zaman alıcı, maliyetli ve insan hatasına açık olması kaçınılmazdır. Retinada oluşan hastalıklar görüntüleme teknikleri sayesinde bir uzmanın bilgi, tecrübe ve deneyimlerine dayanarak taranır ve tespit edilebilir. Bu aşamada uzmanların gözden kaçırıp değerlendiremediği bulgular yanlış teşhise yol açabilir. Ayrıca uzmanlar tarafından görüntülerde rastlanan hastalık belirtileri bir başka retinal hastalığın bulguları ile karıştırılabilir. Bu nedenle, hem OCT hem de FFA görüntüleri için uzmanlara destek olabilecek yapay zekâ tabanlı çalışmalara oldukça ihtiyaç duyulmaktadır. Son yıllarda ise bu alanda yaşanan teknolojik gelişmeler ile yapay zekânın alt dalı olan derin öğrenme modellerinde olağanüstü performanslar elde edilmiştir ve önceki bilgisayar destekli tanılama yöntemlerinden daha iyi performans elde edilmiştir. Önerilen sistem yapılan literatür çalışmaları incelenerek ve literatürdeki eksik kalınan durumlar göz önüne alınarak oluşturulmuştur.

Bu çalışmada OCT görüntülerinden göz rahatsızlıklarının tespiti için derin öğrenme tabanlı bir yöntem önerilmiştir. Bu amaçla 5 evrişim katmanından oluşan bir ESA mimarisi tasarlanmıştır. Bu şekilde katman sayısının fazlalığından doğabilecek kayıpların önüne geçilmiştir ve yakınsama süresi azaltılmıştır. Çalışmada daha etkin bir sistem oluşturulabilmesi için öncelikle görüntüler üzerinde ön işleme teknikleri uygulanmıştır. Önerilen sistemden ön işleme teknikleri uygulanan test setinde 0,9948 doğruluk, 0,9948 hassasiyet ve 0,9983 özgüllük değerleri elde edilmiştir. Bu ön işleme teknikleri sayesinde oluşturulan ESA mimarisinin doğruluk değerlerinde 0,0041 oranında artış gözlemlenmiştir. Ayrıca önerilen sistemin hata matrisine bakıldığında sadece drusen hastalığı kategorisinde 5 görüntü üzerinde yanlış teşhis yapıldığı tespit

edilmiştir. Veri setinde hem eğitim hem de test kategorisinde en az veriye sahip olan hastalık grubu drusendir. Sistemin sadece bu hastalık üzerinde yanlış teşhiste bulunmasının veri sayısının yetersiz olmasından kaynaklanan bir durum olduğu düşünülmektedir.

Çizelge 5.1’de literatürde Kermany vd. (2018) tarafından kullanılan halka açık kaynaklı optik koherens tomografi görüntüleri veri seti ile yapılan çalışmalarının doğruluk değerlerine ait veriler gösterilmektedir. Bu sayede yapılan projenin alanında yer edinip edinemeyeceği tespit edilmeye çalışılmıştır.

Çizelge 5.1 Literatürde Kermany vd. (2018) tarafından kullanılan halka açık kaynaklı optik koherens tomografi görüntüleri veri seti ile yapılan çalışmalar.

YÖNTEM	HASSA SİYET	ÖZGÜLLÜK	DOĞRULUK
Önerilen Yöntem	% 99,48	% 99,83	%99,48
Kermany vd. 2018	%97,8	%97,4	%96,6
Najeeb vd. 2018	%95,66	-	%95,19
Li vd. 2019	% 97,8	% 99,4	%98,6
Das vd. 2019	% 99,60	% 99,87	%99,60
Saha vd. 2019	-	-	%87
Bhowmik vd. 2019	%94	-	%94
Berrimi vd. 2020	%98,50	-	%98,65
Bhadra ve Kar 2020	%99,1	%97,9	%96,5
Amaladevi ve Jacob 2020	%96	%99	%96

Literatürde yapılan çalışmaların karşılaştırılmasının verildiği Çizelge 5.1 incelendiğinde önerilen sistemin diğer çalışmalara kıyasla daha başarılı sonuçlar elde ettiği görülmektedir. Yapılan çalışmalar doğruluk sonuçlarına göre sıralandığında ise tasarlanan sistemin ikinci sırada yer aldığı gözlemlenmiştir. Önerilen sisteme çok yakın değerlerle doğruluk sıralamasında birinci olan Das vd. (2019)'nin yaptığı çalışma incelendiğinde hastalık sınıflandırılması için çok ölçekli derin özellikli bir füzyon tabanlı evrişimsel sinir ağları kullandıkları tespit edilmiştir. Oluşturdukların bu ağın hesaplama maliyetinin yüksek olacağı unutulmamalıdır. Tasarlanan modelde katman sayısı kısıtlı tutulmuştur ve model 5 evrişim katmanından oluşturulmuştur. Bu sayede matematiksel hesaplama maliyetinden olabildiğince düşük tutulmuştur.

6. KAYNAKLAR

- Abidalkareem A J, Abd M A, Ibrahim A K, Zhuang H, Altaher A S, Ali, A, M, 2020, Diabetic Retinopathy (DR) Severity Level Classification Using Multimodel Convolutional Neural Networks, Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), July 20-24, Canada, 1404-1407.
- Ahmad Z, Rahim S, Zubair M, Abdul-Ghafar J, 2021, Artificial Intelligence (AI) in Medicine, Current Applications and Future Role with Special Emphasis on Its Potential and Promise in Pathology: Present and Future Impact, Obstacles Including Costs and Acceptance Among Pathologists, Practical and Philosophical Considerations, A Comprehensive Review, Diagnostic Pathology, 16,1-16.
- Ajit A, Acharya K, Samanta A, 2020, A Review of Convolutional Neural Networks, International Conference on Emerging Trends in Information Technology and Engineering, IEEE, February 24-25, India, 1-5.
- Aloysius N, Geetha M, 2017, A Review on Deep Convolutional Neural Networks, International Conference on Communication and Signal Processing (ICCSP), IEEE, April 6-8, India, 0588-0592.
- Alqudah A M, 2020, AOCT-NET: A Convolutional Network Automated Classification of Multiclass Retinal Diseases Using Spectral-Domain Optical Coherence Tomography Images, Medical & Biological Engineering & Computing, 58, 41-53.
- Alzubaidi L, Zhang J, Humaidi A J, Al-Dujaili A, Duan Y, Al-Shamma O, Farhan L, 2021, Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions, Journal of Big Data, 8, 1-74.
- Amaladevi S, Jacob G, 2020, Classification of Retinal Pathologies Using Convolutional Neural Network, International Journal.

- Arel I, Rose D C, Karnowski T P, 2010, Research Frontier: Deep Machine Learning A New Frontier in Artificial Intelligence Research, IEEE Computational Intelligence Magazine, 5, 13-18.
- Berrimi M, Moussaoui A, 2020, Deep Learning for Identifying and Classifying Retinal Diseases, International Conference on Computer and Information Sciences (ICCIS), October 13-15, Saudi Arabia, 1-6.
- Bersimis F G, Varlamis I, 2019, Use of Health-Related Indices and Classification Methods in Medical Data, in Classification Techniques for Medical Image Analysis and Computer Aided Diagnosis, Academic Press, 31-66.
- Bhadra R, & Kar S, 2020, Retinal Disease Classification from Optical Coherence Tomographical Scans Using Multilayered Convolution Neural Network, in 2020 IEEE Applied Signal Processing Conference (ASPCON), IEEE, October 7-9, India.
- Bhowmik A, Kumar S, Bhat N, 2019, Eye Disease Prediction from Optical Coherence Tomography Images with Transfer Learning, in International Conference on Engineering Applications of Neural Networks, Springer, Cham.
- Boulemtafes A, Derhab A, Challal Y, 2019, A Review of Privacy-Preserving Techniques for Deep Learning, Neurocomputing,
- Bradley D, Roth G, 2007, Adaptive Thresholding Using the Integral Image, Journal of Graphics Tools, 12, 13-21.
- Buades A, Coll B, Morel J M, 2011, Non-Local Means Denoising, Image Processing On Line, 1, 208-212.
- Cantile C, Youssef S, 2016, Nervous System, Jubb, Kennedy, Palmer's Pathology of Domestic Animals, 1, 250.
- Castiglioni I, Rundo L, Codari M, Di Leo G, Salvatore C, Interlenghi M, Sardanelli F, 2021, AI Applications To Medical Images: from Machine Learning to Deep Learning, Physica Medica, 83, 9-24.

- Choudhury M D, Atteya W A, Dahal K, Chetia P, Choudhury K D, Paradkar A, 2018, Virtual Screening of Phytochemicals, in Computational Phytochemistry, 301-334.
- Das V, Dandapat S, Bora P K, 2019, Multi-Scale Deep Feature Fusion for Automated Classification of Macular Pathologies from OCT Images, Biomedical Signal Processing and Control, 54-101605.
- Deng L, Yu D, 2014, Deep Learning: Methods and Applications, Foundations and Trends in Signal Processing, 7, 197-387.
- Dhillon A, Verma G K, 2020, Convolutional Neural Network: A Review Of Models, Methodologies and Applications to Object Detection, Progress in Artificial Intelligence, 9, 85-112.
- Glorot X, Bordes A, Bengio Y, 2011, Deep Sparse Rectifier Neural Networks, in Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, 315-323, JMLR Workshop and Conference Proceedings.
- Grewal P S, Oloumi F, Rubin, U, Tennant M T, 2018, Deep Learning in Ophthalmology: A Review, Canadian Journal of Ophthalmology, 53, 309-313.
- Gupta D, 2011, Fundus Fluorescein Angiography and OCT, Graefes Archive for Clinical and Experimental Ophthalmology, 249, 463-463.
- Hassan T, Akram M U, Hassan B, Nasim A, Bazaz, S A, 2015, Review Of OCT and Fundus Images for Detection of Macular Edema, in 2015 IEEE International Conference on Imaging Systems and Techniques, September 16-18, China, 1-4.
- Hou S, Wang Z, 2019, Weighted Channel Dropout for Regularization of Deep Convolutional Neural Network, in Proceedings of the AAAI Conference on Artificial Intelligence.
- Hinton G, Srivastava N, Swersky K, 2012, Neural Networks for Machine Learning Lecture 6a Overview of Mini-Batch Gradient Descent, Cited on, 14.
- Ishtiaq U, Kareem S A, Abdullah E R M F, Mujtaba G, Jahangir R, Ghafoor H Y, 2019, Diabetic Retinopathy Detection Through Artificial Intelligent Techniques: A Review and Open Issues, Multimedia Tools and Applications, 1-44.

- Kamble R M, Chan G C, Perdomo O, Kokare M, González F A, Müller H, Mériaudeau, F, 2018, Automated Diabetic Macular Edema (DME) Analysis Using Fine Tuning with Inception-Resnet-V2 on OCT Images, in 2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES), IEEE, December 3-6, Malaysia, 442-446.
- Kermany D, Zhang K, Goldbaum M, 2018, Large Dataset of Labeled Optical Coherence Tomography (Oct) and Chest X-Ray Images, Mendeley Data.
- Khiritat S, Feyzmahdavian H R, Johansson M, 2017, Mini-Batch Gradient Descent: Faster Convergence Under Data Sparsity, IEEE 56th Annual Conference on Decision and Control (CDC), IEEE, December 12-16, Australia.
- Khochtali S, Khairallah-Ksiaa I, Ben Yahia S, 2016, Normal Fundus Fluorescein Angiography, in: Gupta V, Nguyen Q, Lehoang P, Herbort Jr, C, (Eds) The Uveitis Atlas, Springer, New Delhi.
- Li F, Chen H, Liu Z, Zhang X, Wu Z, 2019, Fully Automated Detection of Retinal Disorders By Image-Based Deep Learning, Graefe's Archive for Clinical and Experimental Ophthalmology, 257, 495-505.
- Miranda S M, Romero G, Francisco J, 2019, Antioxidants and Retinal Diseases, Antioxidants, Vol. 8, N. 12.
- Misra S, Li H, He J, 2019, Machine Learning for Subsurface Characterization, Gulf Professional Publishing.
- Mishra S S, Mandal, B, Puhan N B, 2019, Multi-Level Dual-Attention Based CNN for Macular Optical Coherence Tomography Classification, IEEE Signal Processing Letters, 26, 1793-1797.
- Motozawa N, An G, Takagi S, Kitahata S, Mandai M, Hiramami Y, Kurimoto Y, 2019, 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, 8, 527-539.

- Murphy K, Di Ruggiero E, Upshur R, Willison D J, Malhotra N, Cai J C, Gibson, J, 2021, Artificial Intelligence for Good Health: A Scoping Review of The Ethics Literature, BMC Medical Ethics, 22, 1-17.
- Nair V, Hinton G E, 2010, Rectified Linear Units Improve Restricted Boltzmann Machines, in Icml.
- Najeeb S, Sharmile N, Khan M S, Sahin I, Islam M T, Bhuiyan M I H, 2018, Classification of Retinal Diseases From OCT Scans Using Convolutional Neural Networks, in 2018 10th International Conference on Electrical and Computer Engineering (ICECE), December 20-22, Bangladesh, 465-468.
- Natrayan L, Kumar M S, 2021, Optimization of Wear Parameters of Aluminium Hybrid Metal Matrix Composites by Squeeze Casting Using Taguchi and Artificial Neural Network, in Sustainable Manufacturing And Design, 223-234.
- Poernomo A, Kang D K, 2018, Biased Dropout and Crossmap Dropout: Learning Towards Effective Dropout Regularization in Convolutional Neural Network, Neural Networks, 104, 60-67.
- Polesel A, Ramponi G, Mathews V J, 2000, Image Enhancement Via Adaptive Unsharp Masking, IEEE Transactions on Image Processing, 9, 505-510.
- Pujol J C F, Pinto J M A, 2011, A Neural Network Approach to Fatigue Life Prediction, International Journal of Fatigue, 33, 313-322.
- Rawat C S, Gaikwad V S, 2014, Signal Analysis and Image Simulation for Optical Coherence Tomography (OCT) Systems, in 2014 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT), July 10-11, India 626-631.
- Sadiq R, Rodriguez M J, Mian H R, 2019, Empirical Models to Predict Disinfection By-Products (Dbps) in Drinking Water: An Updated Review.
- Saha S, Nassisi M, Wang M, Lindenberg S, Sadda S, Hu Z J, 2019, Automated Detection And Classification of Early AMD Biomarkers Using Deep Learning, Scientific Reports, 9, 1-9.

- Schmidhuber J, 2015, Deep Learning in Neural Networks, an Overview, Neural Networks, 61, 85-117.
- Secinaro S, Calandra D, Secinaro A, Muthurangu V, Biancone P, 2021, The Role of Artificial Intelligence in Healthcare: A Structured Literature Review, BMC Medical Informatics and Decision Making, 21, 1-23.
- Shrestha A, Mahmood A, 2019, Review of Deep Learning Algorithms and Architectures, IEEE Access, 7, 53040-53065.
- Singh N, Sabrol H, 2021, Convolutional Neural Networks-An Extensive Arena of Deep Learning, A Comprehensive Study, Archives of Computational Methods in Engineering, 1-26.
- Sunija A P, Kar S, Gayathri S, Gopi V P, Palanisamy P, 2021, Octnet: A Lightweight CNN for Retinal Disease Classification from Optical Coherence Tomography Images, Computer Methods and Programs in Biomedicine, 200, 105877.
- Şeker A, Diri B, Balık H H, 2017, Derin Öğrenme Yöntemleri Ve Uygulamaları Hakkında Bir İnceleme, Gazi Mühendislik Bilimleri Dergisi (GMBD), 3, 47-64.
- Taş S P, Barin S, Güraksin G E, 2021, Deep Learning For Ophthalmological Images, in Deep Learning for Biomedical Applications, CRC Press, 110-119.
- Tayal A, Gupta J, Solanki A, Bisht K, Nayyar A, Masud M, 2021, DL-CNN-Based Approach with Image Processing Techniques for Diagnosis of Retinal Diseases, Multimedia Systems, 1-22.
- Kaya U, Yılmaz A, Dikmen Y, 2019, Sağlık Alanında Kullanılan Derin Öğrenme Yöntemleri, Avrupa Bilim ve Teknoloji Dergisi, 792-808.
- Vaghefi E, Hill S, Kersten H M, Squirrell D, 2020, Multimodal Retinal Image Analysis Via Deep Learning for The Diagnosis of Intermediate Dry Age-Related Macular Degeneration: A Feasibility Study, Journal Of Ophthalmology.
- Varma R, Bressler N M, Doan Q V, Gleeson M, Danese M, Bower J K, Turpcu A, 2014, Prevalence of and Risk Factors for Diabetic Macular Edema in The United States, JAMA Ophthalmology, 132, 1334-1340.

- Wang J, Hormel T T, Gao L, Zang P, Guo Y, Wang X, Jia Y, 2020, Automated Diagnosis and Segmentation of Choroidal Neovascularization in OCT Angiography Using Deep Learning, *Biomedical Optics Express*, 11, 927-944.
- Wang W, Xu Z, Yu W, Zhao J, Yang J, He F, Li X, 2019, Two-Stream CNN With Loose Pair Training for Multi-Modal AMD Categorization, in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 156-164.
- Wuethrich M, Trimpe S, Garcia Cifuentes C, Kappler D, Schaal S, 2016, A New Perspective and Extension of The Gaussian Filter, *The International Journal of Robotics Research*, 35, 1731-1749.
- Xi X, Meng X, Yang L, Nie X, Yang G, Chen H, Chen X, 2019, Automated Segmentation of Choroidal Neovascularization in Optical Coherence Tomography Images Using Multi-Scale Convolutional Neural Networks with Structure Prior, *Multimedia Systems*, 25, 95-102.
- Yadav G, Maheshwari S, Agarwal A, 2014, Contrast Limited Adaptive Histogram Equalization Based Enhancement for Real Time Video System, in *2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 2392-2397.
- Zhai X, Oliver A, Kolesnikov A, Beyer L, 2019, S4I: Self-Supervised Semi-Supervised Learning, in *Proceedings of The IEEE/CVF International Conference on Computer Vision*, 1476-1485.
- Zhang Y, Zhang B, Fan M, Gao X, Wen X, Li Z, Lan Y, 2019, The Vascular Densities of The Macula and Optic Disc in Normal Eyes From Children by Optical Coherence Tomography Angiography, *Graefe's Archive for Clinical and Experimental Ophthalmology*, 1-8.Spaide.
- Zhang Z, 2018, Improved Adam Optimizer for Deep Neural Networks, *International Symposium on Quality of Service (Iwqos)*, June 4-6, Canada, 1-2.

İnternet Kaynakları

- 1- <https://blog.turhost.com/makine-ogrenmesi-machine-learning-nedir/>, 15/03/2021
- 2- <https://cs231n.github.io/neural-networks-1/>, 19/05/2021
- 3- <https://www.endustri40.com/yapay-zeka-makine-ogrenimi-ve-derin-ogrenme-arasindaki-farklar/> (yapay zeka), 05/01/2021
- 4- <https://nickmccullum.com/python-deep-learning/flattening-full-connection/>, 21/05/2021
- 5- <http://www.sanalbiyoloji.com/tr/index.php/ygs/ders-notlari/sinir-sistemi>, 03/11/2020
- 6- <https://www.scopus.com/results>, 17/06/2021
- 7- <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>, 20/06/2021
- 8- https://www.tutorialspoint.com/artificial_intelligence/artificial_intelligence_neural_networks.htm, 13/02/2021
- 9- <https://www.veribilimiokulu.com/yapay-sinir-agiartificial-neural-network-nedir/> 11/03/2021

ÖZGEÇMİŞ

Adı Soyadı : Safiye Pelin TAŞ
Doğum Yeri ve Tarihi : Akşehir – 20.06.1996
Yabancı Dili : İngilizce
İletişim (Telefon / e-posta) : 05413481198

Eğitim Durumu (Kurum ve Yıl)

Lise : Akşehir Şehit Selçuk Özer Anadolu Lisesi, (2010–2014)
Lisans : Afyon Kocatepe Üniversitesi, Biyomedikal Mühendisliği
Bölümü, (2015–2019)
Yüksek Lisans : Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü,
Biyomedikal Mühendisliği Anabilim Dalı, (2019–2021)

Yayımları (SCI ve diğer) :

Taş S P, Barin S, Güraksin G E, 2021, Deep Learning for Ophthalmological Images.
In Deep Learning for Biomedical Applications, CRC Press, 101-119.