

**(Araştırma Makalesi)****Retinal Hastalıkların Teşhisi için Optik Koherans Tomografi Görüntülerinin Derin Öğrenme Metotları ile Sınıflandırılması****Hafiza Esra URMAMEN<sup>\*1</sup>, Sabri KOÇER<sup>2</sup>**<sup>1</sup>Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, ORCID No: 0000-0002-4933-1586<sup>2</sup>Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, ORCID No: 0000-0002-4849-747X**Anahtar Kelimeler:**Optik Koherans Tomografi,  
Derin Öğrenme,  
Evrişimli Sinir Ağı,  
Transfer Öğrenme,  
Retina OCT

**Özet** Retina, görmeyi sağlayan ışığa ve renklere duyarlı ağ tabakasıdır. Retinadaki bozulmalar insanların yaşam kalitesini düşürmektedir. Retinada meydana gelen hasarlar körlüğe varan ciddi sorunlara sebep olabilmekte ve retinada kalıcı hasarlar meydana gelebilmektedir. Retinal hastalıkların tedavisinde gelişen teknoloji ile birlikte bilgisayarlı tanı sistemlerinin kullanımı oldukça yaygınlaşmıştır. Erken teşhis ve tedavi edilmesi retina da oluşabilecek kalıcı hasarları ve hastaların görme yetisini kaybetmesini önlemektedir. Teknolojinin ilerlemesiyle birlikte fotoğraf makineleri ve bilgisayarlı tanı sistemleri oldukça yaygın kullanılmaya başlanmıştır. OCT cihazları kullanılarak elde edilen retinal görüntüler uzmanların daha doğru ve erken teşhis koymalarını sağlamaktadır. Bu çalışmada, retinal hastalıkların sınıflandırılması için transfer öğrenme yöntemlerinden InceptionV3, Xception ve önerilen Evrişimsel Sinir Ağı (ESA) modeli karşılaştırılmıştır. Xception ağında %95.36 oranında doğruluk değerine, Inception ağında ise %98.2 oranında doğruluk oranı elde edilmiştir. Önerilen ESA mimarisinde %97.51 oranında doğruluk oranı elde edilmiştir. Önerilen mimari hastalık bazında diyabet ve normal hastalıkların sınıflandırılmasında diğer yöntemlerden daha başarılı sonuçlar elde etmiştir.

**(Research Article)****Classification of Optical Coherence Tomography Images for the Diagnosis of Retinal Diseases using Deep Learning Methods****Keywords:**Optical Coherence Tomography,  
Deep Learning,  
Convolutional Neural Network,  
Transfer Learning,  
Retinal OCT

**Abstract:** The retina is light-sensitive neural layer that enables vision and perception of colors. Distortions in the retina can negatively impact people's quality of life. Such distortions can lead to serious problems, including blindness and permanent damage to the retina. With the advancement of technology in the treatment of retinal diseases, the use of computer-aided diagnosis systems has become increasing common. Early diagnosis and treatment can prevent permanent damage to the retina and help patients retain their vision. As technology has progressed, cameras and computer-aided diagnosis systems have been widely adopted. Retinal images obtained using OCT devices enable experts to make more accurate and early diagnoses. In this study, transfer learning methods, specifically InceptionV3, Xception, and the proposed Convolutional Neural Network(CNN) model, were compared for classifying retinal diseases. The Xception network achieved an accuracy of 95.36%, while the Inception network achieved an accuracy of 98.2%. The proposed CNN architecture achieved an accuracy of 97.51%. The proposed architecture has obtained more successful results in the classification of diabetes and normal diseases based on diseases architecture compared to other methods.

\*Sorumlu Yazar/Corresponding Author: heurmamen@ktun.edu.tr

## 1. GİRİŞ

Retina, göz küresinin arka tabakasında bulunan yaklaşık 0.5 mm genişliğe sahip ışığı algılayan hassas yapıdaki ağ dokudur[1]. Yapısında bulunan foto reseptör hücreleri sayesinde algıladığı bilgileri beyne iletir ve görme eyleminin gerçekleşmesine yardımcı olmaktadır.

Retina hücreleri kendini yenileyemeyen yapıya sahip olması sebebiyle yapısında meydana gelen bozulmalar, değişiklikler kalıcı olabilmektedir. Retinanın yapısında meydana gelen bu değişiklikler ciddi görme kayıplarına neden olabilmektedir. Retina, görme eyleminde önemli rol alması sebebiyle yapısında meydana gelebilecek rahatsızlıklar görme yetisinin kaybedilmesi gibi geri dönüş olmayan, oldukça ciddi sorunlara sebep olabilmektedir. Retinada aniden oluşan perdeli görüntü, görme kayıpları, gözün önünde ışık çakması, eğik veya kırık görüntü gibi ciddi sorunlarla karşılaştığında uzman kişilere başvurusu gerekmektedir.

Uzmanlar tarafından teşhis için kullanılan retinal tomografi görüntüleri elde edildikten sonra alanında uzman ve deneyim sahibi hekimler tarafından teşhis edilmelidir. Ancak zaman ve uzman hekim sayısının yetersiz kalması gibi sorunlar sebebiyle hastalıkların teşhisi zorlaşabilmektedir. Bu sorunun üstesinden gelebilmek için son teknoloji ile birlikte oldukça sık kullanılan bilgisayarlı tanı sistemleri geliştirilerek hekimlerin zamandan ve işgücünden tasarruf etmeleri amaçlanmıştır.

Diyabetik Retinopati(DR), Miyop, Hipertansiyon, Glokom, Yaşa Bağlı Maküler Ödem (YBMÖ), Katarakt ve Drusen gibi retinada oluşabilen birçok göz rahatsızlığı mevcuttur. Retinal hastalıklar birçok sebepten dolayı meydana gelebilmektedir. Kalıtsal ve çevresel birçok neden retinanın zarar görmesine sebep olabilmektedir. Son zamanlarda oldukça sık kullanılan evrişimli sinir ağları (ESA), retinal patolojilerin erken tespit ve tedavisinde kayda değer sonuçlar elde edilmesini sağlamaktadır.

2014 yılında Srinivasan ve ark. yönlendirilmiş gradyan (HOG) ve destek vektör makinesine (SVM) dayalı bir sistem önermişlerdir. Yönlendirilmiş gradyan, Yaşa Bağlı Maküler Dejenerasyon (AMD) ve Diyabetik Maküler Ödem (DME) gibi retinal hastalıkların tespit edilmesi için kullanılmıştır. Açık kaynak olarak sunulan Optik Koherans Tomografi (OCT) veri setinde bulunan görüntüler yetişkin hastaların retinalarından seçilmiş görüntülerden oluşmaktadır. OCT setinde veriler Normal, CNV, Drusen ve DME olmak üzere dört sınıfa ayrılmıştır. DME için %100, AMD için %100 ve normal olarak sınıflandırılmış sağlıklı retina da %86.76 gibi yüksek bir doğruluk oranı elde etmiştir [2].

2016 yılında Gulshan ve ark. tarafından Diyabetik Retinopati ve Diyabetik Maküler Ödem belirlenebilmesi için Inception mimarisi kullanarak önerdikleri modeli EyePACS-1 veri seti ve Messidor-2 veri setleri üzerinde eğitmişlerdir. EyePACS-1 için duyarlılık %90.3 ve özgüllük %98.1 değerleri elde edilmiştir. Messidor-2 veri seti için duyarlılık %87.0 ve özgüllük %98.5 olarak bulunmuştur[3].

2018 yılında Najeeb ve ark. tarafından retinal anormalliklerin otomatik olarak tespit edilebilmesi için Optik Koherans Tomografi (OCT) tarama görüntülerinden oluşturulan içerisinde çeşitli hastalıklardan oluşan 83.484 veri içeren OCT veri setini kullanarak retinal rahatsızlıkların sınıflandırması için tek katmanlı nötr ağ yapısı kullandıkları modeli önermişlerdir. Önerilen model %95.66 oranında doğruluk oranına sahip ve açık kaynak olarak kullanıma sunulmuştur [4].

Sunja ve ark. tarafından Optik Koherans Tomografi görüntülerinin sınıflandırılması için 6 evrişim bloğundan oluşan derin evrişimli sinir ağı önerilmiştir. Modelin eğitim ve doğrulanması için halka açık bulunan OCT veri seti kullanılmıştır. Kullanılan veri seti Diyabetik Maküler Ödem (DME), Drusen, Koroidal NeoVaskülarizasyon (CNV) ciddi retinal patolojileri içermektedir. Önerilen yöntem ile %99.69 doğruluk, %99.69 özgüllük ve %99.69 duyarlılık değerleri elde edilmiştir. Elde edilen sonuçlar ResNet-50 modeline kıyaslandığında öğrenebilir parametrelerin sadece %6.9 unu kullandığını ve sınıflandırma performansında ResNet-50 modelini geride bıraktığı görülmektedir [5].


2023 yılında Lu ve ark. Oftalmologların hastaların tedavilerini geliştirmek için DR ve DME hastalıklarını otomatik olarak derecelendirmek için transfer öğrenmeye dayalı beş katmanlı evrişimli sinir ağı modeli geliştirmişlerdir. Geliştirdikleri beş katmanlı çapraz doğrulama modeli Messidor veri setinin kullanarak DR ve DME hastalıklarında sırasıyla 0.96, 0.97, 0.96 ve 0.96'lük ortalama doğruluk, kesinlik, özgüllük ve F1 skorunu MobileNetV2'den daha iyi sonuçlar elde etmiştir. Bu sonuçlar geliştirdikleri modelin klinik deneylerde retina hastalıklarının teşhisinde umut verici sonuçlar elde ettiği görülmektedir [6].

## 2. MATERYAL VE METOT

Bu bölümde retinal hastalıkların erken teşhisi ve sınıflandırılması için kullanılan yöntemlerde, retinanın yapısından ve kullanılan ODIR-5K veri setinden bahsedilmiştir. Veri seti üzerinde çeşitli ön işleme teknikleri, ölçeklendirme ve veri çoğaltma işlemleri uygulanmıştır. Elde edilen veriler öncelikle gri filtre sonrasında CLAHE ön işlem aşamasından geçirilmiştir. Veri ön işlemleri ardından önerilen ESA modelinde eğitilmiştir. Elde edilen sonuçlar önceden eğitilmiş transfer öğrenme metotlarından InceptionV3 ve XceptionV3 ağlarının eğitiminden elde edilen sonuçlar ile karşılaştırılmıştır.

### 2.1. Retinanın Yapısı

Retina, gözün en temel ve hassas yapıya sahip alanıdır. Işık kaynağından gelen ışığı alarak ve bunu beyne iletirip görme eyleminin gerçekleşmesini sağlayan sinir hücrelerinden oluşan ağ tabakasıdır. Yapısında bulunan konik ve basil hücreler sayesinde keskin ve net görüş sağlamaktadır.



Şekil 2.1. Retinanın Anatomik Yapısı[7].

Retina Şekil 2.1 incelendiğinde temelde fovea, makula, optik disk, retinal damarlar ve retinal atardamarları içeren birçok hassas bölümden oluşmaktadır. Makula, retina tabakasında bulunan yaklaşık 4-5 mm çapındaki yapıdır. Göz yapısında dıştan içe doğru destekleyici (sert) tabaka, vasküler (damar) tabaka ve ağ tabaka olmak üzere birbirini saran üç temel segmentten oluşmaktadır [8]. Renkli ve keskin görmenin merkez bölgesidir. Makula bölgesinin ortasında “fovea” adı verilen “sarı nokta” olarak da bilinen merkezi ve ayrıntılı, keskin görmeden sorumlu bölge bulunmaktadır.

## 2.2. Veri Seti


Bu çalışmada, retinal hastalıkların tespit edilmesi için ODIR-5K veri seti kullanılmıştır. ODIR-5K halka açık şekilde bulunan veri seti Kaggle web sayfası üzerinden alınmıştır.

Çin ‘de bulunan Shangong Medikal Teknoloji tarafından çeşitli sağlık kuruluşlarından alınan verilerle oluşturulan retinal hastalara ve sağlıklı bireylere ait tomografi görüntülerini içermektedir. Kullanılan veri setinde toplamda 5000 hastadan alınan 6.392 retinal fundus görüntüsü bulunmaktadır[9].

ODIR-5K veri setinde sekiz farklı sınıfa ait patolojik veri içeren tomografi görüntüsü bulunmaktadır. Veri setinde bulunan patolojiler sırasıyla Yaşa Bağlı Maküler Ödem (AMD), Glukom, Miyop, Hipertansiyon, Diyabet, Katarakt, normal ve diğer hastalıklar ve anormallikleri içeren verilerden oluşmaktadır.

ODIR-5K veri setinde bulunan hastalıkların veri dağılımları arasında farklılıklar ve dengesizlikler bulunmaktadır. Veri setinde bulunan sınıfların dağılımları arasındaki dengelenmenin sağlanması için çeşitli veri çoğaltma işlemleri görüntü yaklaştırma, döndürme, parlaklık ayarı, yeniden ölçeklendirme işlemleri uygulanarak veri dengelenme işlemi yapılmıştır. Veri seti dengeleme işleminin ardından gri filtre ve CLAHE (Contrast Limited Adaptive Histogram Equalization) ön işleme uygulaması yapılarak veri ön işleme tamamlanmış ve eğitim için hazır hale getirilmiştir.

Veri setine ait sınıflandırılmış hastalıkların dağılımına ait histogram grafiği Şekil 2.2’de verilmiştir.



Şekil 2.2. ODIR-5K Veri Seti Hastalıkların Dağılımı


Tablo 1. Veri Setinde Bulunan Hastalıkların Sayısal Dağılımı

Hastalıklar	Sayısal dağılımı
AMD	266
Katarakt	293
Diyabet	1608
Glukom	284
Hipertansiyon	128
Normal	2873
Patolojik Miyop	232
Diğer Hastalıklar ve Anormallikler	708

Tablo 1’de ODIR-5K veri setine ait hastalıkların sayısal değerlerinin dağılımına yer verilmektedir. Tablo 2’de veri dengeleme işlemleri sonrasında elde edilen hastalıklara ait sayısal değerlere yer verilmektedir.

Tablo 2. Veri Seti Dengeleme İşlemi Sonrası Sayısal Dağılımı

Hastalıklar	Sayısal dağılımı
AMD	2888
Katarakt	2769
Diyabet	3048
Glukom	2901
Hipertansiyon	2856
Normal	2816
Patolojik Miyop	2928
Diğer Hastalıklar ve Anormallikler	2592




Şekil 2.3. ODIR-5K Veri seti[9].


## 2.3. Xception Mimarisi

Xception, Chollet tarafından geliştirilen temel yapı olarak InceptionV3 ağ mimarisinden ilham alınarak inşa edilmiştir. “Aşırı Başlangıç (Extreme Inception)” olarak da bilinen Derin Sinir Ağı (DNN) mimarisidir[10]. Inception mimarisi yeniden yapılandırılmış, derinlemesine ayrılabilir evrişim katmanları ile değiştirilerek formüle edilmiştir [10].

Inception mimarisine göre daha verimli sonuçlar elde etmiştir. Şekil 2.4’de Xception mimarisinde uygulanan derinlemesine evrişim yapısı gösterilmiştir. Xception mimarisi, toplamda 14 tane modülden oluşan evrişim katmanlarının her biri artık bağlar ile birbirine bağlantılıdır. Özellik çıkarımı işlemi için 36 evrişim katmanı, tam bağlı ve çıkışında bulunan sınıflandırma katmanlarından oluşmaktadır.



Şekil 2.4. Xception Mimarisi Derinleştirilmiş Evrişim Modeli [10].

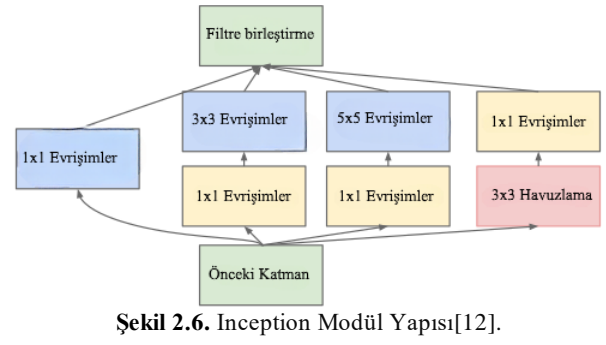


Şekil 2.5. Xception Ağ Mimarisi [10].

Veriler öncelikle giriş akışından, sonrasında 8 kez yinelenen orta akıştan son olarak çıkış akışından geçirilmektedir ve ağı eğitimi tamamlanmaktadır.

### 2.3. Inception Mimarisi

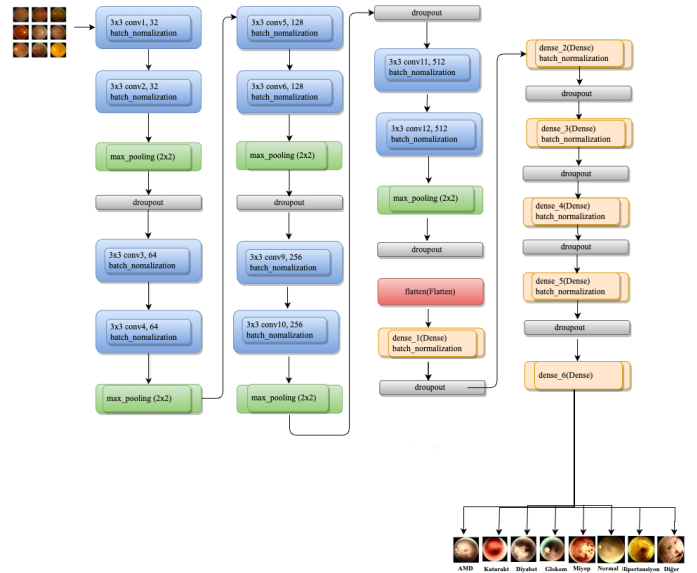
2015 yılında Christian Szegedy ve arkadaşları tarafından "Bilgisayarlı Görü için Inception Mimarisini Yeniden Düşünmek (Rethinking the Inception Architecture for Computer Vision)" makalesinde geliştirilen InceptionNet, GoogleNet için geliştirilmiş evrişimli sinir ağıdır [11]. Evrişim katmanlarının sayısının fazla olması işlem karmaşıklığına, eğitim maliyetini artırmaya, hafıza ihtiyacının, çıkış veri miktarının artması gibi dezavantajlara neden olmuştur. Ayrıca kaybolan gradyan problemi gibi bazı sorunları da beraberinde getirmektedir. Bu sorunlara çözüm olarak geliştirilen mimariyi katman olarak derinleşmektense, ağı genişletmek mantığıyla modelleme yapılmıştır. Inception mimarisinde toplam 22 katmandan oluşmakta olan ağ ImageNet veri yarışmasında %6,67'lik top-5 hata oranına ulaşarak birincilik almıştır. [12].



Şekil 2.6. Inception Modül Yapısı [12].

### 2.4. Önerilen ESA Mimarisi

Önerilen ESA mimarisinde önceden eğitilmiş transfer öğrenme mimarilerinin aksine katman sayısı minimal seviyede tutulmaya çalışılmıştır. Veri seti ön işlemlerden geçirilerek eğitim için hazır hale getirilmiştir. Veriler evrişim katmanlarından ardından 2x2 boyutlarında maksimum havuzlama uygulanarak sonrasında batch-normalization katmanı ile veri normalizasyonu ve veri dağılımının dengesi sağlanmıştır. Ardından dropout katmanı uygulanarak tekrar evrişim katmanları eklenmiştir. Önerilen ESA mimarisi detaylı şekilde 2.7' de gösterilmektedir.




Şekil 2.7. Önerilen ESA Mimarisi

### 3. BULGULAR

Veri setinde artırma işlemleri bulunan 6.392 retina tomografi fotoğrafına veri uygulanarak veri dağılımında bulunan dengesizliklerin giderilmesi amaçlanmıştır ve veri sayısı 22.798 olarak artırılıp dengelenmiştir. Veri seti %64 eğitim, %16 doğrulama ve %20 test olmak üzere ayrılmıştır.

ODIR-5K veri seti önceden eğitilmiş transfer öğrenme metotlarından XceptionV3, InceptionV3 ağlarında ve önerilen ESA modeli üzerinde eğitilmiştir. Optimizasyon fonksiyonu olarak 'Adam' tercih edilmiştir. Öğrenme oranı 0.0001, batch size değeri 32 olarak belirlenmiştir ve 50 adım sayısında eğitim işlemi tamamlanmıştır. Eğitim ve test verileri üzerinde elde edilen doğruluk, kesinlik, duyarlılık ve F1-puanı değerleri Tablo 3'de verilmiştir.

Eğitilen ağlara ait doğruluk ve kayıp grafikleri 2.8, 2.10, 2.12’de gösterilmiştir. Eğitilen mimarilere ait karmaşıklık matrisleri Şekil 2.9, Şekil 2.11 ve Şekil 2.13’de verilmiştir. Karmaşıklık matrisi veri setinde sınıflandırılmak istenen yedi farklı hastalığa ait ve normal retinaya sahip bireyler olmak üzere sekiz farklı sınıf için doğru sınıflandırmaları ve yanlış sınıflandırma sonuçlarını göstermektedir.




Şekil 2.8. Xception Ağ Doğruluk ve Kayıp Grafikleri

Gerçek değer	Tahmin edilen değer							
	YBMÖ	Katarakt	Diyabet	Glokom	Hipertansiyon	Miyop	Normal	Diğer
YBMÖ	534	0	7	1	1	1	11	9
Katarakt	0	529	0	1	0	1	5	1
Diyabet	0	4	360	15	33	3	132	58
Glokom	2	1	3	552	2	0	20	1
Hipertansiyon	0	0	6	1	595	0	1	2
Miyop	1	1	0	1	0	577	0	2
Normal	16	9	106	37	20	3	300	64
Diğer	28	14	43	11	5	15	88	313

Şekil 2.9. Xception Ağ Karmaşıklık Matrisi

Şekil 2.9’da verilen XceptionV3 mimarisine ait karmaşıklık matrisi incelendiğinde Yaşa Bağlı Maküler Ödem (YBMÖ) için 564 görüntü içerisinde 534 tanesini doğru olarak sınıflandırmıştır ve %94.68 oranında doğruluk değerine ulaşmıştır. Katarakt hastalığı için 537 adet veriden 529 tanesini doğru, 8 veriyi yanlış sınıflandırarak %98.51’lik başarı oranına elde edilmiştir. Diyabet hastalığı için bulunan 608 veri içerisinde sadece 360 tanesini doğru sınıflandırmıştır ve %59.21 oranında doğruluk değerine ulaşmıştır. Glokom hastalığı için 581 veri içerisinde 552 veriyi doğru sınıflandırmıştır, 29 adet veriyi yanlış tahminde bulunarak %95 oranında doğruluk değeri elde etmiştir. Hipertansiyon hastalığı için bulunan 605 veriden 595 tanesini doğru olarak sınıflandırarak %98.34 oranında doğruluk değeri elde etmiştir. Miyop hastalığı için 582 veriden 577 tanesini doğru, 5 veriyi yanlış sınıflandırarak %99.14 oranında doğruluk elde etmiştir. Diğer hastalık sınıfında bulunan 517 veriden 313 tanesini doğru sınıflandırmıştır ve %60.54 oranında doğruluk değeri elde edilmiştir. Son olarak normal retinaya sahip verilerin bulunduğu sınıf incelendiğinde 555 verinin 300 tanesini doğru sınıflandırarak %54.05 oranında doğruluk değeri elde edilmiştir.




Şekil 2.10. Inception Mimarisi Doğruluk ve Kayıp Grafikleri

Gerçek değer	Tahmin edilen değer							
	YBMÖ	Katarakt	Diyabet	Glokom	Hipertansiyon	Miyop	Normal	Diğer
YBMÖ	555	0	0	1	0	0	7	1
Katarakt	0	537	0	0	0	0	0	0
Diyabet	8	0	393	12	26	2	122	50
Glokom	0	1	3	566	0	0	10	1
Hipertansiyon	1	0	1	0	601	0	1	1
Miyop	0	0	0	0	0	582	0	0
Normal	14	10	119	32	13	4	323	40
Diğer	15	4	23	5	5	8	60	401

Şekil 2.11. Inception Ağ Karmaşıklık Matrisi

Şekil 2.11’de verilen karmaşıklık matrisi incelendiğinde Yaşa Bağlı Maküler Ödem (YBMÖ) için 564 görüntü içerisinde 555 tanesini doğru olarak sınıflandırmıştır ve %98.40 oranında doğruluk değerine ulaşmıştır. Katarakt hastalığı için 537 adet veriden tamamını doğru sınıflandırarak %100 başarı oranı elde edilmiştir. Diyabet hastalığı için bulunan 608 veri içerisinde sadece 393 tanesini doğru sınıflandırmıştır ve %64.63 oranında doğruluk değerine ulaşmıştır. Glokom hastalığı için 581 veri içerisinde 566 veriyi doğru sınıflandırmıştır, 15 adet veriyi yanlış tahminde bulunarak %97.41 oranında doğruluk değeri elde etmiştir. Hipertansiyon hastalığı için bulunan 605 veriden 601 tanesini doğru olarak sınıflandırarak %99.33 oranında doğruluk değeri elde etmiştir. Miyop hastalığı için 582 veriden tamamını doğru sınıflandırarak %100 oranında doğruluk elde etmiştir. Diğer hastalık sınıfında bulunan 517 veriden 401 tanesini doğru sınıflandırmıştır ve %77.56 oranında doğruluk değeri elde edilmiştir. Son olarak normal retinaya sahip verilerin bulunduğu sınıf incelendiğinde 555 verinin 323 tanesini doğru sınıflandırarak %58.19 oranında doğruluk değeri elde edilmiştir.



Şekil 2.12. ESA Mimarisi Doğruluk ve Kayıp Grafikleri

Gerçek değer	Tahmin edilen değer							
	YBMÖ	Katarakt	Diyabet	Glokom	Hipertansiyon	Miyop	Normal	Diğer
YBMÖ	559	0	0	0	0	0	3	2
Katarakt	0	537	0	0	0	0	0	0
Diyabet	2	3	429	5	9	0	138	27
Glokom	0	0	0	566	0	0	15	0
Hipertansiyon	0	1	1	0	602	0	1	0
Miyop	0	0	0	0	0	581	0	1
Normal	8	5	107	23	4	3	358	47
Diğer	7	4	23	3	2	7	40	435

Şekil 2.13. Önerilen ESA Mimarisi Karmaşıklık Matrisi

Şekil 2.13’de verilen karmaşıklık matrisi incelendiğinde Yaşa Bağlı Maküler Ödem (YBMÖ) için 564 görüntü içerisinde 559 tanesini doğru olarak sınıflandırmıştır ve 5 veriyi yanlış sınıflandırarak %99.11 oranında doğruluk değerine ulaşmıştır. Katarakt hastalığı için 537 adet veriden tamamını doğru sınıflandırarak %100 başarı oranı elde etmiştir. Diyabet hastalığı için bulunan 608 veri içerisinde sadece 429 tanesini doğru sınıflandırmıştır ve %70.55 oranında doğruluk değerine ulaşmıştır. Glokom hastalığı için 581 veri içerisinde 566 veriyi doğru sınıflandırmıştır, 15 adet veriyi normal sınıfta tahmin etmiştir ve %97.41 oranında doğruluk değeri elde etmiştir. Hipertansiyon hastalığı için bulunan 605 veriden 602 tanesini doğru olarak sınıflandırarak %99.50 oranında doğruluk değeri elde etmiştir. Miyop hastalığı için 582 veriden 581 tanesini doğru 1 tanesini diğer hastalık sınıfına dahil ederek %99.82 oranında doğruluk değeri elde etmiştir. Diğer hastalık sınıfında bulunan 517 veriden 435 tanesini doğru sınıflandırmıştır ve %84.13 oranında doğruluk değeri elde edilmiştir. Son olarak normal retinaya sahip verilerin bulunduğu sınıf incelendiğinde 555 verinin 358 tanesini doğru sınıflandırarak %64.5 oranında doğruluk değeri elde edilmiştir.

Tablo 3. Modellerin Performans Metrikleri

Model	Eğitim doğruluğu	Doğrulama Doğruluğu	Test Doğruluğu
InceptionV3	%98.2	%86.83	%86.29
Xception	%95.36	%82.49	%88.60
Önerilen ESA	%97.51	%89.22	%89.26

#### 4. TARTIŞMA VE SONUÇ

Retinal hastalıkların teşhis edilebilmesi için kullanılan Optik Koherans Tomografi (OCT) retinanın enine kesit görüntülerinin detaylı şekilde analizi için kullanılan bir tekniktir. OCT, diğer tomografi cihazlarının aksine radyasyona maruz bırakmadan retinal görüntünün elde edilmesini sağlamaktadır. Elde edilen fundus fotoğrafları alanında uzman oftalmologlar tarafından teşhis edilmekte ve erken tedavi uygulanması sağlanmaktadır. Ancak OCT cihazlarının sayısının az olması ve uzman sayısının yetersiz kalması gibi sorunlar ortaya çıkmaktadır. Teknolojinin gelişmesiyle birlikte bilgisayarlı tanı sistemleri oldukça sık kullanılmaya başlanmıştır. Derin

öğrenmede Evrişimli Sınır Ağları (ESA) sınıflandırma problemlerinde oldukça iyi sonuçlar vermektedir. Bu makalede, OCT cihazından elde edilen tomografi görüntülerinden Yaşa Bağlı Maküler Ödem (YBMÖ), Katarakt, Diyabet, Glokom, Hipertansiyon, Miyop, Normal ve Diğer anormallikleri içeren sekiz farklı sınıf için ESA modeli önerilmiştir. Önerilen model önceden eğitilmiş InceptionV3 ve XceptionV3 ağları ile karşılaştırılmıştır. InceptionV3 mimarisinde %98.2, XceptionV3 mimarisinde %95.36 ve önerilen ESA mimarisinde ortalama %97.51 doğruluk oranı elde edilmiştir. Önerilen ESA mimarisi diyabet hastalığı için %70.55, normal sınıf için %64.5 ve diğer hastalıklarda %84.13 doğruluk oranına ulaşmış olup InceptionV3 ve XceptionV3 mimarileri ile kıyaslandığında sınıf bazında kıyaslandığında normal, diğer hastalıklar, katarakt ve diyabet hastalığında önceden eğitilmiş transfer öğrenme metotlarından daha yüksek doğruluk değerlerine ulaşmıştır. Modellerin test doğruluk değerleri karşılaştırıldığında Inception mimarisinin %86.29, Xception mimarisinin %88.60 ve önerilen ESA mimarisinin %89.26 oranında test başarısına ulaşarak önceden eğitilmiş transfer öğrenme metotlarına kıyasla yüksek test başarısına ulaştığı görülmektedir.

Sonuç olarak önerilen ESA modeli transfer öğrenme metotlarından en sık kullanılan iki tanesi ile karşılaştırılarak doğruluk ve test değerleri elde edilmiştir. 8 sınıfın olduğu veri seti genişletilerek farklı hastalıklar içinde çeşitlendirilebilir ve önerilen ESA mimarisi sayesinde retinal hastalıkların erken teşhis edilmesi ve tedavi yöntemlerinin uygulanmasında uzmanlar tarafından kullanılabilir. Böylelikle uzman sayısının yetersiz kaldığı durumlarda önerilen ESA mimarisi sayesinde retinada meydana gelebilecek kalıcı hasarlar erken tespit yapıldığı takdirde önlenmiş olacaktır.

#### Etik Hususlar

#### Etik kurallara uyum

Bu çalışmada, insan gönüllüleri ve deneysel hayvan içeren çalışmalarda gerçekleştirilen tüm prosedürleri, kurumsal ve / veya ulusal araştırma komitesinin etik standartlarına ve 1964 Helsinki deklarasyonuna ve daha sonraki değişikliklerine veya karşılaştırılabilir etik standartlara uygun olarak çalışıldığını beyan ederiz.

#### Finansman

Bu çalışmada, araştırmalarının kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe kullanılmadığını beyan ederiz.

#### Çıkar çatışması

Bu çalışmada herhangi bir çıkar çatışması olmadığını beyan ederiz.

#### KAYNAKÇA

- [1] Kolb, H. Simple anatomy of the retina. 2012.
- [2] Srinivasan, P. P., Kim, L. A., Mettu, P. S., Cousins, S. W., Comer, G. M., Izatt, J. A., Farsiu, S. 2014. Fully automated detection of diabetic macular edema and dry age-related macular degeneration

from optical coherence tomography images. *Biomed Opt Express*, 2014. 5(10): p. 3568-77. <https://doi.org/10.1364/BOE.5.003568>

*Computer Vision and Pattern Recognition (CVPR)*. <https://doi.org/doi:10.1109/CVPR.2015.7298594>.

- [3] Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., Venugopalan, S., Widner, K., Madams, T., Cuadros, J., Kim, R., Raman, R., Nelson, P. C., Mega, J. L., Webster, D. R. 2016. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*, 2016. 316(22): p. 2402-2410. <https://doi.org/10.1001/jama.2016.17216>
- [4] S. Najeeb, N. Sharmile, M. S. Khan, I. Sahin, M. T. Islam, M. I. Hassan Bhuiyan, 2018. Classification of Retinal Diseases from OCT scans using Convolutional Neural Networks. 10th International Conference on Electrical and Computer Engineering (ICECE). 2018.
- [5] A P, S., Kar, S., S, G., 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*, 2021. 200: p. 105877. <https://doi.org/10.1016/j.cmpb.2020.105877>
- [6] Lu, Z., Miao, J., Dong, J., Zhu, S., Wang, X., Feng, J. 2023. Automatic classification of retinal diseases with transfer learning-based lightweight convolutional neural network. *Biomedical Signal Processing and Control*, 2023. 81: p. 104365. <https://doi.org/10.1016/j.bspc.2022.104365>
- [7] S.C., E.P.A. 2023. Retina. [cited 2023 16.4.2023]; Available from: <https://www.epawi.com/comprehensive-eye-care-milwaukee/retina/>.
- [8] Karalezli, A., Kaderli, A. 2021. Tıp Fakültesi Öğrencileri için Göz Hastalıkları. 2021: p. 1-3.
- [9] Kaggle, 2019.
- [10] Chollet, F. 2017. Xception: Deep Learning with Depthwise Separable Convolutions, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017, pp. 1800-1807, <https://doi.org/10.1109/CVPR.2017.195>.
- [11] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. 2016. Rethinking the Inception Architecture for Computer Vision, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 2818-2826, <https://doi.org/10.1109/CVPR.2016.308>.
- [12] Szegedy, C., et al. 2015. *Going deeper with convolutions*. in *2015 IEEE Conference on*