



Derin Öğrenme Kullanılarak Fundus Görüntülerinden Katarakt ve Diyabetik Retinopati Tespiti

Detection of Cataract and Diabetic Retinopathy from Fundus Images Using Deep Learning

¹Şükrü AYKAT , ²Sibel SENAN 

¹Mardin Artuklu Üniversitesi, Midyat Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Mardin, Türkiye

²İstanbul Üniversitesi-Cerrahpaşa, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye

¹sukruaykat@gmail.com, ²ssenan@iuc.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 25 July 2023

Accepted : 13 October 2023

Keywords:

Retinal Diseases, Deep Learning, Convolutional Neural Networks, Cataract, Diabetic Retinopathy

ABSTRACT

The aim of this study is to use deep learning-based methods for the detection of retinal diseases. In the study, Kaggle dataset, which was created by taking fundus images from IDRID (The Indian diabetic retinopathy image), ODIR (Ocular Disease Intelligent Recognition) and HRF (High-Resolution Fundus) datasets, was used to detect retinal diseases. This data set consists of fundus images of healthy individuals and diabetic retinopathy and cataract patients. In the study, first a pre-processed data set was created by applying the histogram equalization method on the Kaggle data set. Then, trainings were carried out on the data sets by adjusting the hyperparameters of the traditional deep learning models of RestNet50, InceptionV3, MobileNet, Xception and EffcientNetV2S. Finally, a MobileNet-based hybrid model with the highest success on datasets has been developed. The proposed hybrid model achieved 99% accuracy on the preprocessed dataset. It has been observed that the classification success of the hybrid model is higher than the success of the deep learning models considered.

© 2023 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 25 Temmuz 2023

Kabul : 13 Ekim 2023

Anahtar Kelimeler:

Retina Hastalıkları, Derin Öğrenme, Evrişimli Sinir Ağları, Katarakt, Diyabetik Retinopati

ÖZET

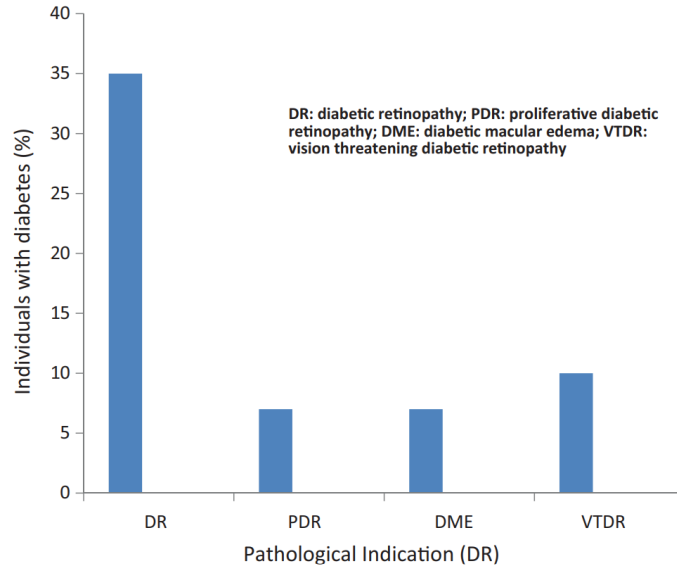
Bu çalışmanın amacı, retina hastalıklarının tespiti için derin öğrenme tabanlı yöntemlerin kullanılmasıdır. Çalışmada retina hastalıklarının tespit etmek için IDRID (The Indian diabetic retinopathy image), ODIR (Ocular Disease Intelligent Recognition) ve HRF (High-Resolution Fundus) veri setlerinden fundus görüntüleri alınarak oluşturulmuş olan Kaggle veri seti kullanılmıştır. Bu veri seti sağlıklı bireyler ile diyabetik retinopati ve katarakt hastalarının fundus görüntülerinden oluşmaktadır. Çalışmada ilk önce Kaggle veri seti üzerinde histogram eşitleme yöntemi uygulanarak ön işlenmiş bir veri seti oluşturulmuştur. Ardından RestNet50, InceptionV3, MobileNet, Xception ve EffcientNetV2S geleneksel derin öğrenme modellerinin hiperparametre ayarı yapılarak veri setleri üzerinde eğitimler gerçekleştirilmiştir. Son olarak veri setleri üzerinde en yüksek başarıya sahip MobileNet tabanlı bir hibrit model geliştirilmiştir. Önerilen hibrit model, ön işlenmiş veri seti üzerinde %99 doğruluk oranı elde etmiştir. Hibrit modelin sınıflandırma başarısının ele alınan derin öğrenme modellerinin başarısından daha yüksek olduğu görülmüştür.

© 2023 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayımlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Diyabetik retinopati (DR) daha çok uzun süreli diyabetli hastalarda yaygın olarak görülen bir retina hastalığıdır [1]. Diyabet hastası olan yaklaşık 285 milyon kişinin üçte birinde DR belirtileri olup, bunların da üçte birinde görmeyi tehdit eden DR hastalığı bulunmaktadır [2]. Şekil 1, H. Ahsan [3] tarafından 2015 yılında yapılan çalışmaya göre diyabetli insanlar içinde DR, PDR (proliferatif diyabetik retinopati), DME (diyabetik maküler ödem), VTDR (görmeyi tehdit eden diyabetik retinopati), retina hastalarının oranlarını göstermektedir. Şekil 1 incelendiğinde retina hastalıkları içinde DR hasta oranının oldukça fazla olduğu görülmektedir. Yine 2015 senesinde R.Varma ve ark. [4] tarafından yapılmış çalışmaya göre DR hastalarının sayısının 2050'ye kadar üç katına çıkacağı tahmin edilmektedir.

Diyabetik hastalarda herhangi bir klinik retinopati semptomunun ortaya çıkması birkaç yıl almaktadır [5]. İstatistiksel verilere dayanarak 5 yıl diyabet hastası olan bireylerde DR gelişme riski yaklaşık %17 iken, 15 yıl veya daha uzun süre diyabet tanısı olan hastalarda ise DR gelişme riski yaklaşık %97,5 olmaktadır [6]. Uzun süreli tedavi edilmeyen diyabetin sonuçları çok ağır olduğundan ve şiddetli DR yaygınlaşmasına yol açabileceğinden, diyabet hastalığının uygun ve erken tedavisi çok önemlidir [7, 8]. Önlenebilir görme bozukluğunun ortadan kaldırılması, uzman doktor sayısına ve gözün tedavisi için gerekli olan temel sağlık hizmetleri altyapısına bağlı olmaktadır [9, 10]. Hindistan'da, göz sağlığı uzmanlarının nüfusa oranı 1:107.000 iken bazı bölgelerde 608.000 nüfus için sadece bir göz sağlığı uzmanı bulunmaktadır [11, 12]. Sürekli takip gerektiren çok sayıda insan ve göz doktoru eksikliği nedeniyle, DR tespiti için bilgisayar destekli tanı aracı geliştirme ihtiyacı ortaya çıkmaktadır [13, 14].



Şekil 1. Diyabet hastası olan kişilerde retina hastalıkları oranı [3].

Katarakt, merceği bulanıklaştıran proteinin birikmesiyle ortaya çıkmaktadır [15]. Katarakt hastalığı gelişimsel anormallikler, travma, metabolik bozukluklar, genetik, ilaca bağlı değişiklikler, yaş vb. gibi birçok faktörle ilişkili olmaktadır [16]. Ayrıca diyabetik hastalarında da katarakt görme bozukluğunun başlıca nedenlerinden biridir [17]. Katarakt nedenlerine göre yaşa bağlı katarakt, doğumsal katarakt ve ikincil katarakt olarak sınıflandırılmaktadır [16, 18]. Kristal lens opaklığının konumuna bağlı olarak nükleer katarakt, kortikal katarakt ve posterior subkapsüler katarakt olarak gruplandırılmaktadır [19, 20]. Nükleer katarakt, nükleer bölgede kademeli bulutlanmayı ve kademeli sertleşmeyi ifade etmektedir. Kortikal katarakt, beyaz kama şeklinde ve radyal olarak yönlendirilmiş opasitelerin şeklidir ve merceğin dış kenarından merkeze doğru kol benzeri bir tarzda gelişmektedir [16, 21]. Posterior subkapsüler katarakt, granüler opasitelerdir ve semptomu, lens kapsülünün altına serpilmiş küçük kırıntılar veya kum parçacıklarını içermektedir [19]. Katarakt, çoğunlukla gelişmekte olan ülkelerde, küresel körlüğün önemli bir nedeni olmaya devam etmektedir [22]. Genel yaygınlık azalıyor olsa da, dünya çapında 10 milyondan fazla insanın katarakta ikincil olarak kör olduğu ve 35 milyondan fazla insanın orta veya ciddi görme bozukluğu olduğu tahmin edilmektedir [23]. Teknolojideki son gelişmelere ve artan küresel farkındalık ve erişime rağmen, katarakt büyük bir küresel sağlık yükü olmaya devam etmektedir [15, 24].

Retina hastalıklarının ilerlemesi ve saptanması, gözün retinasının optik disk, kan damarları ve fovea gibi farklı retinal kısımlarında veya yakınındaki bozukluklar aracılığıyla gözlemlenmektedir [25]. Bu gözlemleri yapmak için retina görüntülerine ihtiyaç bulunmaktadır. Retina görüntülerinin doğru analiz edilebilmesi için retinanın doğal yapısında bulunan optik disk ve makula gibi yapıların doğru tanınması ve dejenerasyonlardan ayırt edilmesi gerekmektedir [26]. Göz doktorları bu görüntüleri analiz ederek retina hastalığını teşhis etmektedir. Ancak bazı çalışmalara göre gelecekte sınırlı sayıda göz doktorunun retina hastalarına bakamayacak durumda olacağı öngörülmektedir [27]. Retina hastaları ile göz hekimi sayısı arasındaki bu büyük orantısız durum hizmetlerde

gecikmelere yol açacaktır. Böyle bir senaryoda göz doktorlarının iş yükünü hafifletmek için göz hastalıklarını otomatik olarak tespit eden sistemlere büyük ihtiyaç olacaktır.

Geçmişten günümüze araştırmacılar, matematiksel morfoloji görüntü işleme [28], şablon eşleştirme [29], piksel sınıflandırma [30], dalgacık analizi [31], bulanık C-ortalama kümeleme [32] yöntemlerini kullanarak görüntülerden farklı özellikleri tanımlamışlardır. Bu yöntemler ile mikroanevrizma, eksuda, kırmızı lezyon ve anormal damar özellikleri saptamak için kullanılmışlardır. Son yıllarda tıp alanında yapay zekaya dayalı yöntemler kullanılarak yapılan analiz çalışmalarında önemli sonuçlar elde edilmiştir [33].

Bu çalışmanın amacı, derin öğrenme yaklaşımları kullanılarak DR ve katarakt retina hastalıkları tespitini yüksek başarı oranı ile gerçekleştirmektir. Bu amaçla, hastalık tespit başarı sonuçlarını analiz etmek için beş farklı hiperparametre ayarlı derin öğrenme modeli ve derin öğrenme tabanlı hibrit bir model önerilmiştir. Kullanılan derin modellerin doğruluk yüzdeleri sunularak performans değerlendirmeleri yapılmıştır.

Çalışma 5 adımda değerlendirilebilir:

1. IDRID (Indian Diabetic Retinopathy Image Dataset), ODIR (Ocular Disease Intelligent Recognition) ve HRF (High-Resolution Fundus) veri setlerinden fundus görüntüleri alınarak oluşturulmuş Kaggle veri seti içerisinde sağlıklı bireyler ile DR ve katarakt hasta görüntülerinden yaklaşık 1000'er adet örnek alınarak bir veri seti oluşturulmuştur.
2. Oluşturulan yeni veri seti görüntülerine histogram eşitleme işlemi uygulanarak yeni bir ön işlenmiş veri seti elde edilmiştir.
3. Evrişimli sinir ağı (ESA) modellerinin (ResNet50, InceptionV3, MobileNet, Xception, EfficientNetV2S) sınıflandırma performanslarını artırmak için hiperparametre ayarlı sürümleri elde edilmiş ve veri setleri üzerinde orijinal ve hiperparametre ayarlı versiyonları eğitilmiştir.
4. Eğitilen modellerden en başarılı sonucu veren hiperparametre ayarlı MobileNet tabanlı bir hibrit model geliştirilmiştir. Geliştirilen hibrit model ham veri seti ve ön işlenmiş veri seti üzerinde eğitilerek model performansı bu çalışmada kullanılan diğer modellerin performansı ile karşılaştırılmıştır.
5. Hiperparametre ayarlı ESA modellerinin ve önerilen hibrit yöntemin performans sonuçları literatürdeki benzer çalışmaların performansı ile karşılaştırılmıştır. Hibrit yöntemin literatürdeki bu çalışmalara göre daha başarılı sonuçlar elde ettiği görülmüştür.

Makalenin ikinci bölümünde literatür araştırması; üçüncü bölümünde kullanılan yöntemler, önerilen model ve veri kümesi hakkında detaylı bilgiler verilmiştir. Deneysel bulgulara ve tartışmaya dördüncü bölümde yer verilmiştir. Makalenin son bölümünde nihai sonuçlara değinilmiştir.

2. LİTERATÜR ARAŞTIRMASI

Günümüzde derin öğrenme modelleri kullanılarak retina görüntülerinin analizi için birçok çalışma yapılmıştır. Bu bölümde derin öğrenme yöntemleri kullanılarak DR ve katarakt sınıflandırılması ile ilgili çalışmalar ele alınmıştır. DR hastalık seviyelerini tespit etmek için literatürde birçok çalışma bulunmaktadır. Tariq ve ark. [34] makalede derin transfer öğrenmesi kullanmışlardır. Beş evrişimsel sinir ağı tabanlı tasarım kullanmışlardır (AlexNet, GoogleNet, Inception V4, Inception ResNetV2 ve ResNeXt-50). Veri setini DR hastalığın şiddetine göre farklı kategorilerde sınıflandırmışlardır. Deneysel sonuçlara göre önceden eğitilmiş model ResNeXt-50'nin, çalışmada kullandıkları önceden eğitilmiş modeller arasında %97,53 ile en iyi sınıflandırma doğruluğunu elde etmişlerdir. Pava Rodriguez [35], çalışmalarında fundus görüntüleri kullanarak DR'nin otomatik olarak sınıflandırılması için iki yaklaşım sunmuşlardır. İlki, DR ile ilgili ana oküler lezyonları tanımlamak ve hastalığı teşhis etmek için ESA'yı, transfer öğrenmeyi, sığ makine öğrenimi sınıflandırıcılarını kullanmışlardır. İkincisi ise aynı anda oküler lezyonları ve DR'yi teşhis eden çok görevli bir modeldir. Kaggle EyePACS ve Messidor-2 veri kümelerinden bir göz doktoru tarafından oküler lezyonlar etiketlenerek alt kümeler oluşturmuşlardır. Kaggle EyePACS alt kümesini eğitim seti olarak, Messidor-2 alt kümesini ise hem lezyonlar hem de DR sınıflandırma modelleri için test seti olarak kullanmışlardır. Sonuçlar, her iki yöntemin de son teknoloji performanslarla karşılaştırılabilir sonuçlar elde ettiğini göstermişlerdir. Vinayaki ve Kalaiselvi [36], çalışmalarında DR tespiti ve sınıflandırması için yeni bir çerçeve önermişlerdir. Ön işleme, bölütleme, özellik çıkarma ve sınıflandırma olmak üzere dört aşamadan oluşan bir çalışma önermişlerdir. İlk olarak görüntü ön işlemesi yapılmış ve ardından çoklu eşik tabanlı remora optimizasyon algoritması ile damar bölütlemesi gerçekleştirmişlerdir. Özellik çıkarma ve sınıflandırma için Wild Geese algoritması ile Region-based Convolution Neural Network (R-CNN) kullanmışlardır. Sonuç olarak, R-CNN modeli ile DR olmayan, proliferatif DR, şiddetli DR, orta dereceli DR, hafif DR dahil olmak üzere DR'nin farklı seviyelerini etkili bir şekilde sınıflandırmışlardır. Chilukoti ve ark. [37], çalışmada önceden eğitilmiş ResNet, VGG ve EfficientNet modelleri kullanmışlardır. Diyabetik retinopatinin farklı evrelerini şiddetine göre sınıflandırmak için doğruluk, f1 puanı, kesinlik ve hatırlama gibi en yaygın kullanılan metriklerin yanında kuadratik ağırlıklı kappayı kullanmışlardır. EfficientNet-B3 ağını kullanarak ikinci dereceden ağırlıklı kappa skorunu 0,85 elde ederek performans olarak destek vektör makineleri, karar ağaçları, ESA ve önceden eğitilmiş DenseNet modeli gibi mevcut modelleri geride bırakmışlardır. Nhut Huynh ve ark. [38], DR'nin beş aşamalı durumunu (sağlıklı, hafif, orta, şiddetli ve çoğalan) derin öğrenme tekniği kullanılarak sınıflandırmışlardır. Veri kümesinde 5.590 görüntü üzerinde çapraz doğrulama eğitimi ve testinden sonra, diyabetik retinopatinin aşamalarının sınıflandırılmasında önceden eğitilmiş MobileNetV2 modelini kullanmışlardır. Modelin ortalama doğruluğunu %94,00 olarak bulmuşlardır.


Katarakt hastalığını tespit etmek için literatürde çalışmalar bulunmaktadır. Zhang ve ark. [39] çalışmada, kataraktı otomatik olarak tespit etmek ve derecelendirmek için derin ESA'yı kullanarak performans ve verimliliği araştırmayı amaçlamışlardır. Çalışmalarında ESA sınıflandırmasına önemli bir katkı sağlayan G-filtresinden sonra retina fundus görüntüleri kullanılarak gözlerin yansımaları kaldırılmışlardır. Ayrıca mevcut örnek miktarının artırılmasıyla ESA sınıflandırma doğruluğunun %93'e ulaşmasını sağlamışlardır. Pratap ve Kokil [40] önerdikleri yöntemde, otomatik katarakt sınıflandırmasını gerçekleştirmek için transfer öğrenimi için önceden eğitilmiş ESA kullanmışlardır. Fundus katarakt görüntülerini, çeşitli açık erişim veri setlerinden toplamışlar ve oftalmoloji uzmanlarının yardımıyla dört gruba ayırmışlardır. ESA modeli kullanarak çıkarılan özellikler destek vektör makinesi ile sınıflandırmışlardır. Dört sınıf için model doğruluğunu %92,91 olarak elde etmişlerdir. Hossain ve ark. [41], doğruluğu %95,77 olan ResNet'e dayalı bir sınıflandırıcı modeli kullanan otomatik bir katarakt tespit sistemi önermişlerdir. Imran ve ark. [42] çalışmalarında fundus görüntü tabanlı katarakt sınıflandırması için yeni bir hibrit evrişimli ve tekrarlayan sinir ağı (CRNN) sağlamayı amaçlamışlardır. Önerilen yöntemin dört sınıflı katarakt sınıflandırması için ortalama %97,39 doğrulukla en yeni yöntemlerden daha iyi performans göstermişlerdir. Kant ve ark. [43], fundus görüntülerinin özellik çıkarımı için transfer öğrenme yaklaşımıyla birlikte hibrit bir yöntem kullanan bir sistem önerdiler. Özellik çıkarımı için, AlexNet, VGGNet ve ResNet gibi önceden eğitilmiş birkaç CNN modeli uyguladılar ve kataraktları hafif, orta, hayır ve şiddetli olmak üzere dört sınıfa sınıflandırmak için bir destek vektör makinesi (DVM) sınıflandırıcısı kullanmışlardır.

3. MATERYAL VE METOT

Bu çalışmada katarakt ve DR hastalarını saptamak için oluşturduğumuz fundus retina görüntü veri setleri üzerinde hiperparametre ayarlı ESA modelleri ve hibrit model eğitilmiş ve bu modellerin performans sonuçları analiz edilmiştir. Çalışmada ele alınan ESA modelleri; RestNet50, InceptionV3, MobileNet, Xception, EffcientNetV2S'dir.

3.1. Evrişimli Sinir Ağı

ESA mimarisi, görüntüler gibi birçok veri içeren uygulamalarda sınıflandırma için sıklıkla kullanılan bir derin öğrenme modelidir. ESA, geleneksel sinir ağlarına benzer bir şekilde eğitilmesi gereken ağırlıklara sahip nöronlardan oluşmaktadır. Her nöronda girdilerin ve ağırlıkların çarpımı uygulanmaktadır [44]. ESA mimarisi, birbirini izleyen bir dizi katmanın birleşiminden oluşmaktadır. Şekil 2'de gösterildiği gibi genişlik ve yüksekliğe sahip bir görüntünün kullanıldığı giriş katmanından sonra üç ana katman vardır: tam bağlantılı, havuzlama ve evrişim. Bu katmanlar birbiri ardına eklenerek bir ESA mimarisi oluşturulmuştur [45].



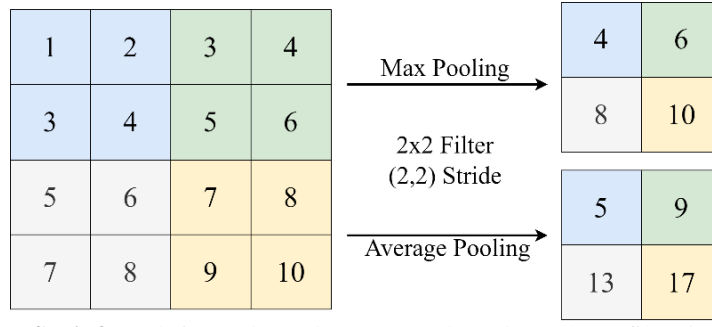
Şekil 2. Evrişimli sinir ağı katmanları.

3.1.1. Evrişim Katmanı

Evrişimli katmanda görüntülerin çizgiler, kenarlar, renk damlaları gibi özellikleri algılanmaktadır. Evrişimli katmanda, her döngüde görüntünün tüm piksellerine bir filtre uygulayan ve görüntü özelliklerine dayalı olarak sınıf olasılıklarını tahmin eden bir özellik haritası oluşturulur. Filtre, istenen özelliğin mevcut olup olmadığını kontrol etmek için görüntüyü oluşturan parçalara etki etmektedir [46–48].

3.1.2. Havuzlama Katmanı

Havuzlama veya alt örnekleme katmanı, Şekil 3'te gösterildiği gibi aktivasyon haritasının genişliğini ve yüksekliğini azaltmak için kullanılmaktadır. Genel olarak, evrişimli katmanların sayısı arttıkça, ağıdaki parametre ve hesaplama sayısını azaltmaktadırlar [49–51]. Havuzlama işlemi, bir filtrenin özellik haritasının üzerinde kaydırılarak özet bir özellik haritası oluşturmaktadır. Ortalama ve maksimum değerlerin alındığı özel havuzlama türleridir. Maksimum ve ortalama havuzlama türleri, bilgisayarlı görme dünyasında en yaygın kullanılan ve uygulanan havuzlama katmanlarıdır [52]. Şekil 3'te görüldüğü gibi maksimum havuzlamada, özellik haritası üzerindeki filtrenin kapsadığı alan içindeki maksimum değer seçilmektedir. Bu sayede özellik haritasının en belirgin özellikleri korunmaktadır. Ortalama havuzlamada ise özellik haritası üzerindeki filtrenin kapsadığı alan içindeki özelliklerin ortalaması alınmaktadır.



Şekil 3. Maksimum havuzlama ve ortalama havuzlama filtresi.

3.1.3. Tam Bağlantılı Katman

Havuzlama katmanlarını tamamen bağlı katman takip etmektedir. Nitelikler, giriş görüntülerinden havuzlama ve evrişim katmanlarının çıktılarında elde edilmektedir. Tamamen bağlı katman, görüntüyü önceden belirlenmiş bir sınıfa sınıflandırmak için bu özellikleri kullanmaktadır.

3.2. Evrişimli Sinir Ağı Modelleri

3.2.1. ResNET50 Modeli

He ve diğ. [53] ImageNet Büyük Ölçekli Görsel Tanıma Mücadelesinde (ILSVRC 2015) birinci olan, artık sinir ağı adlı bir ağ yapısı kullanmışlardır. ResNet ile bilgi kazanımını korumaya, kaybı azaltmaya ve eğitim sırasında performansı artırmaya yardımcı olan katmanlar arasında artık bağlantıları önermişlerdir. Artık ağlar çok derin sinir ağlarında kaybolan gradyan problemini çözmek için geliştirilen mimaridir. Bu ağda atlama bağlantısı adı verilen bir teknik kullanılmıştır. Atlama bağlantısı, bir katmanın aradaki bazı katmanları atlayarak diğer katmanlara bağlanmaktadır. Bu atlama bağlantısının avantajı, herhangi bir katmanın mimarinin performansını düşürmesi durumlarında bu katmanın atlanmasını sağlamaktadır. Dolayısıyla kaybolan gradyan probleminin neden olduğu sorunlar ortadan kaldırılarak çok derin sinir ağlarının eğitilmesi sağlanmaktadır. ResNet50, 48 evrişim katmanı, 1 Ortalama Havuzlama katmanı ve 1 Max Havuzlama katmanı olmak üzere 50 katmandan oluşmaktadır.

3.2.2. InceptionV3 Modeli

Inception ağı, Google tarafından 2014 yılında kullanıma sunulan önceden eğitilmiş bir modeldir [54]. Bu ağ, maksimum havuzlama ve çeşitli ölçeklerde öznelikleri çıkarmak için kullanılan farklı boyutlarda filtreler içeren 22 katmandan oluşmaktadır. Hesaplamalarda zaman kazanmak için küçük filtreler kullanılmaktadır. 2015 yılında Google, Inception modelindeki parametreleri azaltmak için evrişim katmanlarının hesaba katıldığı 48 katmanlı InceptionV3'ü [55] piyasaya sürmüştür. Ağların performansını etkilemeden hesaplamayı azaltmak için 5×5 evrişimli filtreler yerine iki adet 3×3 filtre kullanmışlardır. Ağ parametrelerinin miktarını azaltmakla kalmayıp aynı zamanda ağ derinliğini de artıran Inception ağ yapısını benimsemektedir. Bu nedenle görüntü sınıflandırmada yaygın olarak kullanılmaktadır [56].

3.2.3. MobileNet Modeli

MobileNet günümüz uygulamalarına uygun bir ESA mimarisidir [57]. MobileNet, derinlemesine ayrılabilir kıvrımlar kullanan hafif, derin evrişimli sinir ağlarından oluşmaktadır. MobileNet'in derinlemesine ayrılabilir evrişim modülü, nokta evrişim filtrelerinden ve derin evrişim filtrelerinden oluşmaktadır. MobileNet, derin ve nokta evrişimler hariç 28 katmana sahiptir [58]. Derinlemesine ayrılabilir evrişim modülü, hem hesaplama karmaşıklığını hem de parametreleri sıkıştırılmaktadır. Gömülü ve mobil cihazların GPU ve CPU'nun işlem gücünden tam olarak yararlanmasını sağladığından, doğruluk kaybı olmadan görüntü tanımayı hızlandırmaktadır [59]. MobileNet ağında bir görüntünün her pikseli, filtre kanalı sayısı ile çarpılır ve görüntünün tüm giriş kanalları boyunca kayan filtre tarafından işlenen giriş piksellerinin toplamını alır. Görüntü özellikleri yalnızca giriş kanalları kullanılarak öğrenilir ve dolayısıyla çıkış katmanı, giriş kanallarıyla eşit sayıda kanala sahiptir. Derinlemesine ayrılabilir evrişiminde standart evrişim işlemine göre parametrelerinin hesaplanma maliyetinin 8-9 kat azaldığı gösterilmiştir [60].

3.2.4. Xception Modeli

Francois Chollet tarafından tanıtılan Xception mimarisi [61], InceptionV3'ün geliştirilmiş bir sürümüdür [55]. Xception modeli [61], sıradan evrişimi uzamsal evrişime ve nokta evrişimine bölen derinden ayrılabilir evrişime dayanmaktadır. Uzamsal evrişim, her giriş kanalında bağımsız olarak gerçekleşmektedir. Noktadan noktaya evrişim, noktadan noktaya gelişmek için 1x1 çekirdek kullanılmaktadır. Parametre sayısı azaldıkça hesaplama sayısı da azalmaktadır. Xception, 36 evrişim katmanına sahip 14 modülden oluşmaktadır. İlk ve son modüller dışında diğer modüller doğrusal artık bağlantılar içermektedir. Nesne tanıma veya görüntü sınıflandırmada tespit edilecek

nesne bazı görüntülerde büyük, bazı görüntülerde ise küçük olabilir. Farklı nesne boyutları, evrişim işlemi için filtre boyutunun belirlenmesini zorlaştırabilir. Görsellerde büyük görünen objeler için büyük filtre boyutu tercih edilmeli, küçük objeler için ise küçük filtre boyutu tercih edilmelidir. Inception mimarisi, girişte birden fazla farklı büyüklükteki filtre kullanılmasını önererek, farklı büyüklükteki nesnelerin neden olduğu sorunlara çözüm sunmaktadır [62].

3.2.5. EfficientNet Modeli

Tan ve Le [63] CNN'lerden daha yüksek hassasiyet gösteren ve daha esnek olan EfficientNet modelini önermişlerdir. Yazarlar, EfficientNet modellerinin derinlik, genişlik ve çözünürlük boyutlarını eşit şekilde ölçeklendirmek için verimli ve basit bileşik katsayılar kullanmışlardır. Bu, ağına daha yüksek performans elde etmek için sabit bir kaynak bütçesi kullanmasını sağlamışlardır. EfficientNet ailesi, EfficientNetB0'dan EfficientNetB7'ye kadar adlandırılan sekiz CNN modelinden oluşmaktadır. EfficientNetB0'dan EfficientNetB7'ye çözünürlük, genişlik, derinlik, model boyutu ve doğruluk artmaktadır.

Tan ve Le [64], tarafından önerilen EfficientNetV2, daha yüksek performansa ve daha kısa eğitim süresine sahiptir. Eğitimi ve verimliliği artırmak için EfficientNet'te kullanılan bazı MBConv katmanları yerine Fused MBConv katmanını kullanılmış ve mevcut modellerden 6,8 kata kadar daha hızlıdır. EfficientNetV2 mimarisi, EfficientNetV2S, EfficientNetV2M ve EfficientNetV2L olmak üzere üç versiyonda mevcuttur.

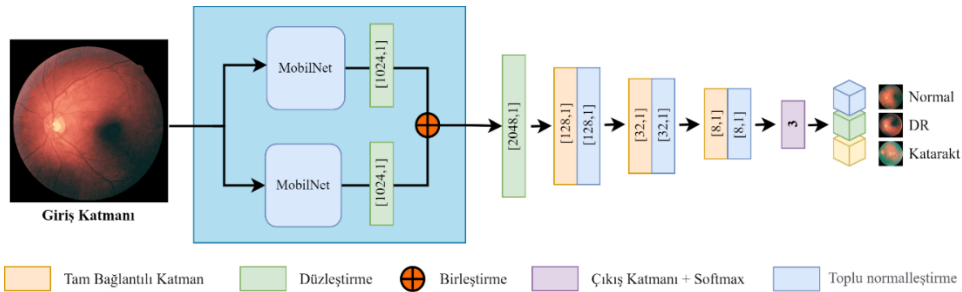
3.3. Önerilen Model

Bu çalışmada ilk önce ResNet50, InceptionV3, MobileNet, Xception ve EfficientNetV2S ESA öğrenme modellerinin orijinal ve hiperparametre ayarlı sürümleri kullanılmıştır. Beş ESA öğrenme modeli hem ham veri seti hem de ön işlenmiş veri seti üzerinde eğitilmiştir. Tablo 1'de derin öğrenme modellerinin ve önerilen hibrit modelin parametre değerleri verilmiştir.

Tablo 1. Kullanılan derin öğrenme modellerinin ve önerilen hibrit modelin parametre değerleri.

Parametre	Değeri
Giriş katmanı görüntü boyutu	224px * 224px
Aktivasyon fonksiyonu	ReLU, Softmax (Çıkış katmanı)
Optimizasyon algoritması	Adam
Eğitim sayısı	200
Küme boyutu (batch size)	4
Eğitimi erken durdurma kuralı	Eğitim doğruluk oranı > %99
Öğrenme oranı	0.001 (Her eğitimde yarıya indirilmiştir.)

Önerdiğimiz hibrit modelin yapısı Şekil 4'te gösterilmiştir. Önerilen hibrit model iki MobileNet modeli, üç düzleştirme katmanı, üç tam bağlantılı katman ve softmax fonksiyonunun kullanıldığı bir çıkış katmanından oluşmaktadır. Hibrit model eğitimi daha hızlı ve daha kararlı hale getirmek için tam bağlantılı katmanlardan sonra toplu normalleştirme kullanılmıştır. İlk bölümde veri setleri üzerinde eğitilen hiperparametre ayarlı modeller arasında en yüksek performansı gösteren MobileNet olduğu için hibrit modelde kullanılması tercih edilmiştir. Veri setlerinin eğitimi sırasında MobileNet modellerinden elde edilen özellikler birleştirilmiştir. Özelliklerin birleştirilmesi sonucunda sınıflandırma performansında yüksek başarı elde edilmiştir. Geliştirilen hibrit model ile hem orijinal veri seti hem de ön işlenmiş veri seti eğitilmiştir. En sonda test veri seti ile modellerin performansları değerlendirilmiştir.



Şekil 4. Önerilen model mimarisi.

3.3.1. Hiperparametre Ayarı

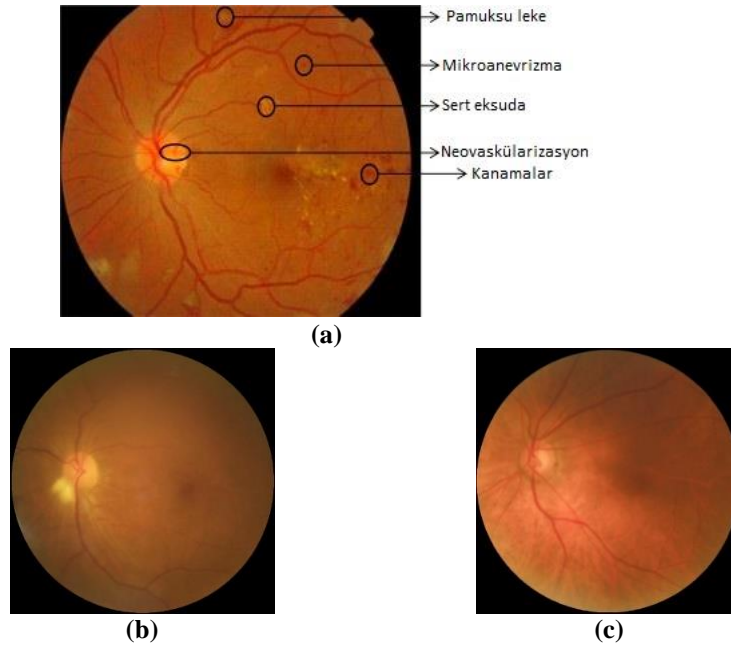
Ağın eğitiminden önce ayarlanan hiperparametreler, ağın yapısını ve ağın nasıl eğitileceğini belirleyen değişkenlerdir. Gizli katman sayısı, dropout, toplu normalleştirme, aktivasyon fonksiyonu, öğrenme oranı, eğitim sayısı ve parti boyutu hiperparametrelerden bazılarıdır. Uygun hiperparametre seçimi ile ESA eğitiminin yüksek başarıyla ve daha az maliyetle gerçekleşmesini sağlamaktadır. Bengio [65] öğrenme oranının, genellikle en

önemli hiperparametre olduğunu ve her zaman ayarlanması gerektiğini belirtmiştir. Hem önerilen hibrit modelde hem de bu çalışmada kullanılan derin öğrenme modellerinde öğrenme oranı eğitim boyunca değiştirilerek hiperparametre ayarlaması yapılmıştır. Öğrenme oranı, çok büyük olduğunda global optimuma ulaşamayabilir hatta çok uzaklaşabilir. Çok küçük seçildiğinde ise model her döngüde çok küçük adımlarla ilerleyeceği için yerel optimuma takılabilir ve yakınsama çok uzun sürecektir [66].

Adam optimizasyon her dönemde azalan öğrenme oranıyla kullanılmıştır. Eğitim başlangıcında öğrenme oranı 0.001 iken, devir sayısı arttıkça öğrenme oranı yarıya düşürülmüştür. Bunu yapmamızın nedeni başlangıçta öğrenme oranının çok düşük olması yerel optimum değere takılıp optimum global optimum değere hiç ulaşamamasına neden olabilmektedir.

3.4. Veri Seti

Retinanın dijital fundus görüntüleri, DR'nin şiddetini teşhis etmesi ve derecelendirmesi için göz doktorlarına önemli bir tarama platformu olarak hizmet etmektedir. Fundus görüntüsünde, küçük ve yuvarlak koyu kırmızı noktalar olarak görünen mikroanevrizma, kanama ve salgı gibi anormal DR özellikleri, DR'yi saptamak için kullanılan yaygın özelliklerdir [28]. Retina bölgesindeki anormalliklerin sayısı, hastalığın evresi ile birlikte artmaktadır [67]. Fundus görüntüsü katarakt tanısında yaygın olarak kullanılır ve retina hakkında yeterli bilgi sağlayabilir [68]. Şekil 5'te normal gözler ve DR ile katarakt hastalarının fundus görüntüleri gösterilmektedir.



Şekil 5. (a) Diyabetik retinopati, (b) katarakt ve (c) normal birey fundus görüntü özellikleri.


Bu çalışmada, retina hastalıkları teşhisinde Python programlama dili kullanılarak tensorflow ve opencv kütüphanelerinden yararlanılmıştır. Deneyler Windows 11 işletim sistemli, 16 GB RAM ve Intel (R) Core(TM) i7-11800H @ 2.30GHz işlemcili bir bilgisayarda Python'un 3.9.7 sürümü kullanılarak gerçekleştirilmiştir.

Bu çalışmada retina hastalıklarını tespit etmek için fundus görüntüleri içeren Kaggle [69] veri seti kullanılmıştır. Bu veri seti IDRID (The Indian diabetic retinopathy image), ODIR (Ocular Disease Intelligent Recognition) ve HRF (High-Resolution Fundus) veri setlerinden görüntüler alınarak oluşmaktadır. Görüntüler 512*512 piksel boyutlarında ve .jpg dosya formatındadır. Her sınıftan yaklaşık 1000 fundus görüntüsü alınarak sağlıklı bireyler ile DR ve katarakt hastalarının retina görüntülerinden oluşan bir veri seti oluşturulmuştur. Ayrıca daha iyi bir sınıflandırma başarısı elde etmek için ham veri seti üzerinde histogram eşitleme işlemi uygulanarak ön işlenmiş yeni bir veri seti oluşturulmuştur. Bu veri setlerindeki görüntüler eğitim, doğrulama ve test verilerine ayrılmıştır. Tablo 2'de veri setlerinin dağılımı gösterilmiştir.

Tablo 2. Ham ve önışlenmiş veri setlerinin dağılımı.

Sınıf	Toplam	Eğitim	Doğrulama	Test
Normal	1074	674	200	200
DR	1098	698	200	200
Katarakt	1038	638	200	200

Çalışmada kullanılan veri setlerinin bazı örnekleri Şekil 6'da gösterilmiştir.



Şekil 6. Fundus veri setlerinin örnek görüntüleri. a) Katarakt, b) DR, c) Normal.

3.5. İstatistiksel Analiz

Çalışmamızda modellerin başarısını değerlendirmek için karışıklık matrisi kullanılmıştır. Doğruluk, hatırlama, kesinlik ve F1-skor metrikleri performans ölçütleri olarak kullanılmıştır. Performans metriklerinin hesaplanmasında Yanlış Negatif (FN), Yanlış Pozitif (FP), Gerçek Negatif (TN) ve Gerçek Pozitif (TP) endeksleri kullanılmıştır. TP, aslında pozitif bir durumu ifade eden ve sınıflandırıcı tarafından pozitif olarak tahmin edilen numuneleri ifade etmektedir. FP, aslında negatif bir durumu ifade eden ve sınıflandırıcı tarafından pozitif olarak tahmin edilen numuneleri ifade etmektedir. FN, aslında negatif bir durumu ifade eden ve sınıflandırıcı tarafından pozitif olarak tahmin edilen numuneleri ifade etmektedir. TN, gerçekte negatif bir durumu temsil eden ve sınıflandırıcı tarafından negatif olarak tahmin edilen numuneleri belirtmektedir.

Doğruluk, sınıflandırıcının doğru olarak tahmin ettiği doğru ve yanlış veri sayısının toplam veri sayısına oranıdır.

$$\text{Doğruluk} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (1)$$

Hatırlama, gerçek sınıftaki örneklerin doğru tahmin edilme oranıdır.

$$\text{Hatırlama} = \frac{TP}{(TP + FN)} \quad (2)$$

Kesinlik, sınıflandırıcının doğru tahmin ettiği veri sayısının gerçek veri sayısına oranıdır.

$$\text{Kesinlik} = \frac{TP}{(TP + FP)} \quad (3)$$

F1-skor değeri bize kesinlik ve hatırlama değerlerinin harmonik ortalamasını göstermektedir.

$$F1 - \text{Skor} = 2 * \frac{\text{Hatırlama} * \text{Kesinlik}}{\text{Hatırlama} + \text{Kesinlik}} \quad (4)$$

4. BULGULAR

Bu bölümde, fundus veri setleri üzerinde ESA modellerinin performansları karşılaştırılarak analizler yapılmıştır. Fundus veri setleri üzerinde beş ESA modelinin hem orijinal hem de hiperparametre ayarlı sürümleri ile eğitimler gerçekleştirilmiştir. Hiperparametre ayarlı modellerde her eğitimde öğrenme oranı yarıya indirilmiştir. Öğrenme oranının çok büyük olması hata değerinin artmasına sebep olabilmektedir. Aynı zamanda model eğitime başladığında öğrenme oranının çok düşük olması global minimuma ulaşamamasına neden olabilmektedir. Veri setinin ham hali üzerinde eğitilen beş ESA modelinin orijinal ve hiperparametre ayarlı sürümlerinin performansları Tablo 3'te gösterilmiştir. Veri setinin ön işlenmiş hali üzerinde eğitilen beş ESA modelinin orijinal ve hiperparametre ayarlı sürümlerinin performansları Tablo 4'te gösterilmiştir.

Tablo 3. Ham veri seti için ESA modellerinin orijinal ve hiperparametre ayarlı sürümlerinin performansları.

Model	Orijinal Model				Hiperparametre Ayarlı Model			
	D (%)	K (%)	H (%)	S (Sn)	D (%)	K (%)	H (%)	S (Sn)
RestNet50	63,83	63,83	63,83	30	79,83	79,83	79,83	31
InceptionV3	55,17	55,11	54,83	28	91,00	91,00	91,00	32
MobileNet	74,00	74,20	73,83	18	97,50	97,50	97,50	18
Xception	77,00	77,05	76,67	40	96,17	96,48	96,00	40
EfficientNetV2S	63,83	64,46	63,17	45	95,17	95,31	94,83	52

*D:Doğruluk, K:Kesinlik, H:Hatırlama; S: Eğitim aşaması dönem başına çalışma süresi, sn:Saniye, %:Yüzde

Tablo 3 incelendiğinde ham veri seti üzerinde hiperparametre ayarlı modellerin daha yüksek performansa sahip olduğu görülmektedir. Orijinal derin öğrenme modelleri arasında Xception modelinin, hiperparametre ayarlı modeller arasında MobileNet modelinin en yüksek başarıya ulaştığı görülmektedir. Ham veri seti üzerinde Xception modeli ile %77,00 doğruluk oranı, hiperparametre ayarlı MobileNet modeli ile %97,50 doğruluk oranı elde edilmiştir. Orijinal derin öğrenme modelleri arasında InceptionV3 modeli, hiperparametre ayarlı modeller arasında RestNet50 modeli en düşük performansa sahip olmuştur. Dönem başına çalışma süresi açısından değerlendirildiğinde, ham veri seti üzerinde hem orijinal hem de hiperparametre ayarlı MobileNet modeli 18 saniye ile en iyi performansı göstermiştir.

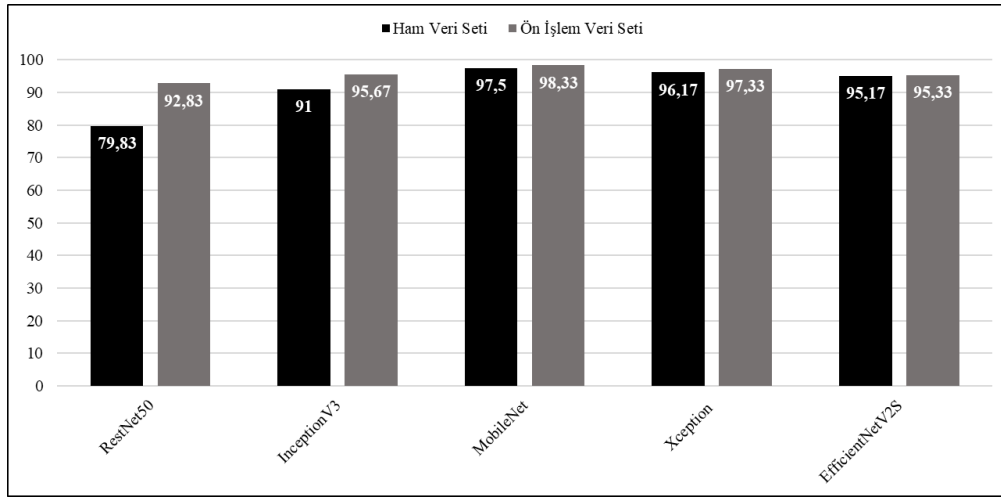
Tablo 4. Ön işlenmiş veri seti için ESA modellerinin orijinal ve hiperparametre ayarlı sürümlerinin performansları.

Model	Orijinal Model				Hiperparametre Ayarlı Model			
	D (%)	K (%)	H (%)	S (Sn)	D (%)	K (%)	H (%)	S (Sn)
RestNet50	74,67	75,47	73,83	28	92,83	93,14	92,83	28
InceptionV3	72,83	76,25	71,17	28	95,67	95,83	95,67	26
MobileNet	74,50	74,50	74,50	15	98,33	98,33	98,33	15
Xception	69,50	69,50	69,50	38	97,33	97,33	97,33	37
EfficientNetV2S	79,50	78,50	79,50	45	95,33	95,33	95,33	45

*D:Doğruluk, K:Kesinlik, H:Hatırlama; S: Eğitim aşaması dönem başına çalışma süresi, sn:Saniye, %:Yüzde

Tablo 4 incelendiğinde ön işlenmiş veri seti üzerinde hiperparametre ayarlı modellerin daha yüksek performansa sahip olduğu görülmektedir. Orijinal derin öğrenme modelleri arasında EfficientNetV2S modelinin, hiperparametre ayarlı modeller arasında MobileNet modelinin en yüksek başarıya ulaştığı görülmektedir. Ön işlenmiş veri seti üzerinde EfficientNetV2S modeli ile %79,50 doğruluk oranı, hiperparametre ayarlı MobileNet modeli ile %98,33 doğruluk oranı elde edilmiştir. Orijinal derin öğrenme modelleri arasında Xception modeli, hiperparametreli ayarlı modeller arasında RestNet50 modeli en düşük performansa sahip olmuştur. Dönem başına çalışma süresi açısından değerlendirildiğinde, ön işlenmiş veri seti üzerinde hem orijinal hem de hiperparametre ayarlı MobileNet modeli 15 saniye ile en iyi performansı göstermiştir.


Şekil 7'de ön işlenmiş veri seti üzerinde yapılan eğitimlerde ham veri setine göre daha iyi sonuçlar elde edildiği görülmektedir. Hiperparametreli ayarlı MobileNet modeli hem ham veri seti hem de ön işlenmiş veri seti üzerinde en yüksek başarıyı elde edildiği görülmektedir.



Şekil 7. Hiperparametre ayarlı modellerin veri setleri üzerindeki doğruluk performansları.

Çalışmanın son analizinde geliştirilmiş olan hibrit modelin performans değerlendirmesi yapılmıştır. Hibrit model için hem ham veri seti üzerinde hem de ön işlenmiş veri seti üzerinde yüksek performans gösteren hiperparametre ayarlı MobileNet model paralel bir şekilde eğitilerek çıkış özellikleri birleştirilmiştir. Şekil 4'te önerilen model incelendiğinde her bir MobileNet modelinden elde edilen 1.024 özellik birleştirilerek 2.048 özellik elde edilmiştir. Hibrit model ham veri seti ve ön işlenmiş veri seti üzerinde eğitilmiştir. Önerilen hibrit modele ait karışıklık matrisleri ise Şekil 8'de gösterilmiştir. Şekil 8 incelendiğinde hibrit modelin ön işlem uygulanmış veri seti üzerinde retina hastalıklarını daha iyi tahmin ettiği görülmektedir.

Ham veri setinde katarakt görüntülerinin tümü (200), DR görüntülerinin 199'u ve Normal görüntülerin 192 tanesi doğru tahmin edilmiştir. Bir DR görüntüsü ve 8 normal görüntü katarakt olarak tahmin edilmiştir. Ön işlenmiş veri setinde katarakt görüntülerinin 199'u, DR görüntülerinin tümü (200) ve Normal görüntülerin 195 tanesi doğru tahmin edilmiştir. Bir katarakt görüntüsü normal olarak ve 5 normal görüntü katarakt olarak tahmin edilmiştir. Hibrit modelin performans sonuçları ise Tablo 5'te verilmiştir. Tablo 5 incelendiğinde önerilen hibrit modelin hem



Şekil 8. Hibrit modelin karışıklık matrisi; a) ham veri seti, b) ön işlenmiş veri seti.

ham veri seti hem de ön işlenmiş veri seti üzerinde hiperparametre ayarlı derin öğrenme modellerine göre daha iyi performans gösterdiği görülmektedir. En yüksek başarımlı, ön işlenmiş veri seti üzerinde %99 doğruluk oranı ile önerilen hibrit model tarafından elde edilmiştir. Ayrıca önerilen model F1-skorlarına göre her iki veri setinde DR hastalarını tahmin etmede büyük başarı elde etmiştir.

Tablo 5. Hibrit modelin performans sonuçları.

Sınıf	Ham Veri Seti			Genel Doğ.	Ön İşlenmiş Veri Seti			Genel Doğ.
	Kesinlik	Hatırlama	F1-Skor		Kesinlik	Hatırlama	F1-Skor	
Katarakt	0,96	1,00	0,98	%98,50	0,98	0,99	0,99	%99,00
DR	1,00	0,99	1,00		1,00	1,00	1,00	
Normal	1,00	0,96	0,98		0,99	0,97	0,98	

Tablo 6'da önerilen model ve literatürdeki çalışmalarda kullanılan modellerin doğruluk ölçümlerinin karşılaştırılması gösterilmektedir. Literatürde fundus görüntüleri üzerinden katarakt ve DR hastalarının sınıflandırıldığı sınırlı sayıda çalışma bulunmakta ve bu çalışmalarda üç sınıflı (sağlıklı-DR-katarakt) tespit sunulmamaktadır. Çalışmalar iki sınıf üzerinden (sağlıklı-DR/sağlıklı-katarakt) hastalıkların seviyeleri sınıflandırmaya dahil edilerek sunulmaktadır. Bu nedenle, sunduğumuz çalışma literatüre katarakt, DR ve sağlıklı birey sınıflarını tespit eden derin öğrenme modelinin öne sürülmesi ile de katkı sağlamaktadır.

Tablo 6. Önerilen modelin literatürdeki diğer çalışmalar ile karşılaştırılması.

Çalışma	Sınıflar	ESA Modeli	Doğruluk
Pava Rodriguez [35]	Sağlıklı ve DR	MLP	%94,82
Tariq vd. [34]	Sağlıklı ve dört DR seviyesi	ResNeXt-50	%97,53
Vinayaki ve Kalaiselvi [36]	Sağlıklı ve dört DR seviyesi	R-CNN	%91,70
Chilukoti ve diğ. [37]	Sağlıklı ve dört DR seviyesi	EfficientNet-B3	%87,00
Nhut Huynh ve diğ. [38]	Sağlıklı ve dört DR seviyesi	MobileNetV2	%94,00
L. Zhang ve diğ. [39]	Sağlıklı ve üç katarakt seviyesi	DCNN	%93,52
Pratap ve Kokil [40]	Sağlıklı ve üç katarakt seviyesi	CNN + SVM	%92,91
Imran vd. [42]	Sağlıklı ve üç katarakt seviyesi	CRNN	%97,39
Hossain ve diğ. [41]	Sağlıklı ve katarakt	DCNN	%95,77
Önerilen Model	Sağlıklı, katarakt ve DR	Hibrit Model	%99,00

Tablo 6'da yer alan çalışmalardaki modeller fundus veri kümeleri ile eğitilmiştir. Önerilen modelin ele alınan diğer çalışmalara göre en iyi performansı gösterdiği görülmektedir.

5. SONUÇ

- Bu makale, fundus görüntülerini kullanarak sağlıklı birey (normal), DR ve katarakt hastalarını ayırmak için derin öğrenme tabanlı yeni sonuçlar ortaya koymaktadır. DR, katarakt ve sağlıklı bireyleri sınıflandırmak için öncelikle hiperparametre ayarlı beş ESA modeli kullanılmıştır. Bu ESA modellerinin hiperparametre ayarlı sürümlerinin fundus veri setleri üzerinde daha iyi performanslar sergilediği görülmüştür.

Hiperparametre ayarlı modeller arasında sınıflandırma başarısı en yüksek olan model MobileNet modeli olmuştur.

- Daha sonra, MobileNet tabanlı bir hibrit model geliştirilerek çalışmada ele alınan modellere göre ~~çok~~ daha başarılı sonuçlar elde edilmiştir. Ayrıca, literatürdeki derin öğrenme tabanlı katarakt, DR hastalıkları tespiti çalışmaları ile kıyaslandığında da önerilen modelin daha geniş kapsamda, daha etkin performans sergilediği görülmüştür. Bununla birlikte, literatürde katarakt, DR ve normal bireylerin sınıflandırıldığı çalışmaların seyrekliği göz önüne alındığında, bu konuda da literatüre katkı sağlanmıştır.
- Sunulan çalışma, ele alınan retina hastalıklarını hızlı ve yüksek bir doğrulukla tespit ettiği için, retina hastaları ve göz hekimi sayısı arasındaki orantısız durumun oluşturduğu hizmet gecikmelerini ortadan kaldırmaya yardımcı sistemlerin geliştirilmesine ışık tutması beklenmektedir. Gelecekte tıp bölümlerindeki uzmanların kullanabileceği ve uzmanlara fikir verebilecek yazılımlara dönüştürülebilir. Ayrıca pratisyen hekimlerin retina hastalıkları konusunda hızlı karar vermelerine yardımcı olacak mobil uygulamalar geliştirilebilir.
- Bundan sonraki çalışmalarda daha büyük bir veri seti ve farklı retina hastalıkları ile derin öğrenme temelli çalışmaların yapılması planlanmaktadır.

Yazar Katkıları

Şükrü AYKAT: Deneyleri yapmış ve sonuçlarını analiz etmiştir. Literatür taraması çalışmasını gerçekleştirmiştir. Makalenin yazım işlemine katkı sağlamıştır.

Sibel SENAN: Model performans sonuçlarını analiz etmiştir. Çalışmanın sunumu konusunda makalenin yazım sürecine katkı sağlamıştır.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler

KAYNAKÇA

- [1] P.H. Scanlon, S.J. Aldington, and I.M. Stratton "Epidemiological Issues in Diabetic Retinopathy," Middle East Afr. J. Ophthalmol, vol. 20, no. 4, pp. 293, 2013.
- [2] R. Lee, T.Y. Wong, and C. Sabanayagam "Epidemiology of diabetic retinopathy, diabetic macular edema and related vision loss," Eye Vis. (London, England), vol. 2, no. 1, 2015.
- [3] H. Ahsan "Diabetic retinopathy--biomolecules and multiple pathophysiology," Diabetes Metab. Syndr. vol. 9, no. 1, pp. 51–54, 2015.
- [4] R. Varma, N.M. Bressler, Q.V. Doan, M. Danese, C.M. Dolan, A. Lee, and A. Turpcu "Visual Impairment and Blindness Avoided with Ranibizumab in Hispanic and Non-Hispanic Whites with Diabetic Macular Edema in the United States," Ophthalmology, vol. 122, no. 5, pp. 982–989, 2015.
- [5] M.S. Ola, M.I. Nawaz, M.M. Siddiquei, S. Al-Amro, and A.M. Abu El-Asrar "Recent advances in understanding the biochemical and molecular mechanism of diabetic retinopathy," J. Diabetes Complications, vol. 26, no. 1, pp. 56–64, 2012.
- [6] T. Behl, I. Kaur, H. Goel, and R. Pandey "Diabetic nephropathy and diabetic retinopathy as major health burdens in modern era," World J. Pharm, vol. 3, no. 7, pp. 370–387, 2014.
- [7] T. Kauppi, V. Kalesnykiene, J.K. Kamarainen, L. Lensu, I. Sorri, A. Raninen, R. Voutilainen, J. Pietilä, H. Kälviäinen, and H. Uusitalo "The DIARETDB1 diabetic retinopathy database and evaluation protocol." Proc. Br. Mach. Vis. Conf. vol. 1, pp. 15.1-15.10, 2007.
- [8] N.B.A. Mustafa, W.M.D.W. Zaki, and A. Hussain "A review on the diabetic retinopathy assessment based on retinal vascular tortuosity," Proc. - 2015 IEEE 11th Int. Colloq. Signal Process. Its Appl. CSPA, pp. 127–130, 2015.
- [9] S. Jones and R.T. Edwards "Diabetic retinopathy screening: a systematic review of the economic evidence," Diabet. Med. vol. 27, no. 3, pp. 249–256, 2010.
- [10] S. Lin, P. Ramulu, E.L. Lamoureux, and C. Sabanayagam "Addressing risk factors, screening, and preventative treatment for diabetic retinopathy in developing countries: a review," Clin. Experiment. Ophthalmol, vol. 44, no. 4, pp. 300–320, 2016.
- [11] R. Raman, L. Gella, S. Srinivasan, and T. Sharma "Diabetic retinopathy: An epidemic at home and around the world." Indian J. Ophthalmol, vol. 64, no. 1, pp. 69, 2016.
- [12] P. Porwal, S. Pachade, M. Kokare, G. Deshmukh, and V. Sahasrabudhe "Automatic Retinal Image Analysis for the Detection of Diabetic Retinopathy." Biomedical Signal and Image Processing in Patient Care, pp. 146–161, 2018.
- [13] D.S.W. Ting, G.C.M. Cheung, and T.Y. Wong "Diabetic retinopathy: global prevalence, major risk factors, screening practices and public health challenges: a review." Clin. Experiment. Ophthalmol, vol. 44, no. 4, pp. 260–277, 2016.
- [14] T. Walter, J.C. Klein, P. Massin, and A. Erginay "A contribution of image processing to the diagnosis of diabetic retinopathy--detection of exudates in color fundus images of the human retina," IEEE Trans. Med. Imaging, vol. 21, no. 10, pp. 1236–1243, 2002.
- [15] D. Allen and A. Vasavada "Cataract and surgery for cataract." BMJ, vol. 333, no. 7559, pp. 128–132, 2006.

- [16] Y.C. Liu, M. Wilkins, T. Kim, B. Malyugin, and J.S. Mehta “Cataracts.” *Lancet*, vol. 390, no. 10094, pp. 600–612, 2017.
- [17] J.J. Drinkwater, W.A. Davis, and T.M.E. Davis “A systematic review of risk factors for cataract in type 2 diabetes.” *Diabetes. Metab. Res. Rev.* vol. 35, no. 1, pp. e3073, 2019.
- [18] P.A. Asbell, I. Dualan, J. Mindel, D. Brocks, M. Ahmad, and S. Epstein “Age-related cataract.” *Lancet (London, England)*, vol. 365, no. 9459, pp. 599–609, 2005.
- [19] H. Li, J.H. Lim, J. Liu, D.W.K. Wong, Y. Foo, Y. Sun, and T.Y. Wong “Automatic detection of posterior subcapsular cataract opacity for cataract screening.” *2010 Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBC’10*, pp. 5359–5362, 2010.
- [20] H. Li, J.H. Lim, J. Liu, D.W.K. Wong, N.M. Tan, S. Lu, Z. Zhang, and T.Y. Wong “An automatic diagnosis system of nuclear cataract using slit-lamp images.” *Proc. 31st Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. Eng. Futur. Biomed*, pp. 3693–3696, 2009.
- [21] M. Chew, P.P.C. Chiang, Y. Zheng, R. Lavanya, R. Wu, S.M. Saw, T.Y. Wong, and E.L. Lamoureux “The impact of cataract, cataract types, and cataract grades on vision-specific functioning using rasch analysis.” *Am. J. Ophthalmol.*, vol. 154, no. 1, pp. 29–38.e2, 2012.
- [22] C.M. Lee and N.A. Afshari “The global state of cataract blindness.” *Curr. Opin. Ophthalmol.*, vol. 28, no. 1, pp. 98–103, 2017.
- [23] M. Khairallah, R. Kahloun, R. Bourne, H. Limburg, S.R. Flaxman, J.B. Jonas, J. Keeffe, J. Leasher, K. Naidoo, K. Pesudovs, H. Price, R.A. White, T.Y. Wong, S. Resnikoff, and H.R. Taylor “Number of People Blind or Visually Impaired by Cataract Worldwide and in World Regions, 1990 to 2010” *Invest. Ophthalmol. Vis. Sci.* vol. 56, no. 11, pp. 6762–6769, 2015.
- [24] D. Pascolini and S.P. Mariotti: “Global estimates of visual impairment: 2010.” *Br. J. Ophthalmol.*, vol. 96, no. 5, pp. 614–618, 2012.
- [25] S. Farsiu, S.J. Chiu, R. V. O’Connell, F.A. Folgar, E. Yuan, J.A. Izatt, and C.A. Toth “Quantitative Classification of Eyes with and without Intermediate Age-related Macular Degeneration Using Optical Coherence Tomography.” *Ophthalmology*, vol. 121, no. 1, pp. 162, 2014.
- [26] Z. Yavuz, C. İkibaş, U. Şevik, and C. Köse: “Retinal Görüntülerde Optik Diskin Otomatik Olarak Çıkarılması için Bir yöntem.” *5. Uluslararası İleri Teknolojiler Sempozyumu, IATS’09*, 2009.
- [27] Y. Peng, S. Dharssi, Q. Chen, T.D. Keenan, E. Agrón, W.T. Wong, E.Y. Chew, and Z. Lu “DeepSeeNet: A deep learning model for automated classification of patient-based age-related macular degeneration severity from color fundus photographs.” *Ophthalmology*, vol. 126, no. 4, pp. 565, 2019.
- [28] M. Patil “An Approach for the Detection of Vascular Abnormalities in Diabetic Retinopathy.” *Int. J. Data Min. Tech. Appl.* vol. 2, no. 2, pp. 55–58, 2013.
- [29] M.D. Abramoff, J.M. Reinhardt, S.R. Russell, J.C. Folk, V.B. Mahajan, M. Niemeijer, and G. Quellec “Automated early detection of diabetic retinopathy.” *Ophthalmology*, vol. 117, no. 6, pp. 1147–1154, 2010.
- [30] M. Niemeijer, M.D. Abramoff, and B. Van Ginneken “Information fusion for diabetic retinopathy CAD in digital color fundus photographs.” *IEEE Trans. Med. Imaging*, vol. 28, no. 5, pp. 775–785, 2009.
- [31] G. Quellec, M. Lamard, P.M. Josselin, G. Cazuguel, B. Cochener, and C. Roux “Optimal wavelet transform for the detection of microaneurysms in retina photographs.” *IEEE Trans. Med. Imaging*, vol. 27, no. 9, pp. 1230–1241, 2008.
- [32] A. Osareh, M. Mirmehdi, B. Thomas, and R. Markham “Automated identification of diabetic retinal exudates in digital colour images.” *Br. J. Ophthalmol.*, vol. 87, no. 10, pp. 1220, 2003.
- [33] N. Ghaffar Nia, E. Kaplanoglu, and A. Nasab “Evaluation of artificial intelligence techniques in disease diagnosis and prediction.” *Discov. Artif. Intell.* 2023 31. vol. 3, no. 1, pp. 1–14, 2023.
- [34] H. Tariq, M. Rashid, A. Javed, E. Zafar, S.S. Alotaibi, and M.Y.I. Zia “Performance Analysis of Deep-Neural-Network-Based Automatic Diagnosis of Diabetic Retinopathy.” *Sensors* 2022, vol. 22, no. 1, pp. 205, 2021.
- [35] M.D. La Pava Rodriguez: “Automatic retinopathy detection using deep learning and medical findings.” 2021.
- [36] V.D. Vinayaki and R. Kalaiselvi “Multithreshold Image Segmentation Technique Using Remora Optimization Algorithm for Diabetic Retinopathy Detection from Fundus Images.” *Neural Process. Lett.* vol. 54, no. 3, pp. 2363–2384, 2022.
- [37] S. Venkatesh Chilukoti, A.S. Maida, and X. Hei “Diabetic Retinopathy Detection using Transfer Learning from Pre-trained Convolutional Neural Network Models.” 2022.
- [38] H. Nhut Huynh, M. Thanh Do, G. Thinh Huynh, A. Tu Tran, T. Nghia Tran, M. City, H. Chi Minh City, L. Trung Ward, T. Duc District, T. Truong, T. Tran, T. Nguyen, and Q. Le “Classification of Stages Diabetic Retinopathy Using MobileNetV2 Model.” *Kalpa Publ. Eng.* vol. 4, pp. 147–157, 2022.
- [39] L. Zhang, J. Li, I. Zhang, H. Han, B. Liu, J. Yang, and Q. Wang: “Automatic cataract detection and grading using Deep Convolutional Neural Network.” *Proc. 2017 IEEE 14th Int. Conf. Networking, Sens. Control*, pp. 60–65, 2017.
- [40] T. Pratap and P. Kokil: “Computer-aided diagnosis of cataract using deep transfer learning.” *Biomed. Signal Process. Control.* vol. 53, pp. 101533, 2019.
- [41] M.R. Hossain, S. Afroze, N. Siddique, and M.M. Hoque: “Automatic Detection of Eye Cataract using Deep Convolution Neural Networks (DCNNs).” *2020 IEEE Reg. 10 Symp. TENSYP*, pp. 1333–1338, 2020.
- [42] A. Imran, J. Li, Y. Pei, F. Akhtar, T. Mahmood, and L. Zhang “Fundus image-based cataract classification using a hybrid convolutional and recurrent neural

- network.” *Vis. Comput.*, vol. 37, no. 8, pp. 2407–2417, 2021.
- [43] J. Kant, P. Singh, Y.S. Yadav, A.P.J. Abdul, and A.P.J.A. Kalam “Computer-aided diagnosis of cataract severity using retinal fundus images and deep learning.” *Comput. Intell.* vol. 38, no. 4, pp. 1450–1473, 2022.
- [44] Y.-H. Chen, T. Krishna, J.S. Emer, and V. Sze: “Eyeriss: An Energy-Efficient Reconfigurable Accelerator for Deep Convolutional Neural Networks.” *IEEE J. Solid-State Circuits*, vol. 52, no. 1, pp. 127–138, 2017.
- [45] J. Salamon and J.P. Bello “Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification.” *IEEE Signal Process. Lett.* vol. 24, no. 3, pp. 279–283, 2017.
- [46] M.A.H.A. Bakr, H.M. Al-Attar, N.K. Mahra, and S.S. Abu-Naser “Breast Cancer Prediction using JNN.” *Int. J. Acad. Inf. Syst. Res.* vol. 4, pp. 1–8, 2020.
- [47] A.M. Barhoom, A.J. Khalil, B.S. Abu-Nasser, M.M. Musleh, and S.S. Abu-Naser “Predicting Titanic Survivors using Artificial Neural Network.” *Int. J. Acad. Eng. Res.* vol. 3, no. 9, pp. 8–12, 2019.
- [48] H.Z. Belbeisi, Y.S. Al-Awadi, M.M. Abbas, and S.S. Abu-Naser “Effect of Oxygen Consumption of Thylakoid Membranes (Chloroplasts) From Spinach after Inhibition Using JNN.” *Int. J. Acad. Heal. Med. Res.* vol. 4, no. 11, pp. 1–7, 2020.
- [49] M.A. Dalffa, B.S. Abu-Nasser, and S.S. Abu-Naser “International Journal of Engineering and Information Systems (IJEAIS) Tic-Tac-Toe Learning Using Artificial Neural Networks.” *Int. J. Eng. Inf. Syst.* vol. 3, no. 2, pp. 9–19, 2019.
- [50] I.M. Dheir, Alaa Soliman Abu Mettleq, Abeer A. Elsharif, and Samy S. Abu-Naser “Classifying Nuts Types Using Convolutional Neural Network.” *Int. J. Acad. Inf. Syst. Res.*, vol. 3, no. 12, pp. 12–18, 2019.
- [51] K. Jamal Dawood, M. Hussam Zaqout, R. Mohammed Salem, and S.S. Abu-Naser “Artificial Neural Network for Mushroom Prediction.” *Int. J. Acad. Inf. Syst. Res.* vol. 4, pp. 9–17, 2020.
- [52] E.N. Arrofiqoh and H. Harintaka “IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI TANAMAN PADA CITRA RESOLUSI TINGGI.” *GEOMATIKA.* vol. 24, no. 2, pp. 61, 2018.
- [53] K. He, X. Zhang, S. Ren, and J. Sun “Deep Residual Learning for Image Recognition.” *IEEE Conf. Comput. Vis. Pattern Recognit.* pp. 770–778, 2016.
- [54] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich “Going deeper with convolutions; Going deeper with convolutions”, 2015.
- [55] C. Szegedy, V. Vanhoucke, S. Ioffe, and J. Shlens: “Rethinking the Inception Architecture for Computer Vision; Rethinking the Inception Architecture for Computer Vision.” 2016 *IEEE Conf. Comput. Vis. Pattern Recognit.* pp. 2818–2826, 2016.
- [56] N. Dong, L. Zhao, C.H. Wu, and J.F. Chang “Inception v3 based cervical cell classification combined with artificially extracted features.” *Appl. Soft Comput.* vol. 93, pp. 106311, 2020.
- [57] G. Hinton, L. Deng, D. Yu, G. Dahl, A. Mohamed, N. Jaitly, A. Senior, V. Vanhoucke, P. Nguyen, T. Sainath, and B. Kingsbury: “Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups.” *IEEE Signal Process. Mag.* vol. 29, no. 6, pp. 82–97, 2012.
- [58] S. Ghoury, C. Sungur, and A. Durdu “Real-Time Diseases Detection of Grape and Grape Leaves using Faster R-CNN and SSD MobileNet Architectures.” *Int. Conf. Adv. Technol. Comput. Eng. Sci.*, 2019.
- [59] X. Liu, Z. Jia, X. Hou, M. Fu, and L. Ma “Real-time Marine Animal Images Classification by Embedded System Based on Mobilenet and Transfer Learning; Real-time Marine Animal Images Classification by Embedded System Based on Mobilenet and Transfer Learning.” *OCEANS 2019 - Marseille* (2019).
- [60] K.D. Kadam, S. Ahirrao, and K. Kotecha “Efficient Approach towards Detection and Identification of Copy Move and Image Splicing Forgeries Using Mask R-CNN with MobileNet V1.” *Comput. Intell. Neurosci.* vol. 2022, 2022.
- [61] F. Chollet “Xception: Deep Learning with Depthwise Separable Convolutions.” 2017.
- [62] Ö. Polat “Detection of Covid-19 from Chest CT Images using Xception Architecture: A Deep Transfer Learning based Approach.” *Sak. Univ. J. Sci.* vol. 25, no. 3, pp. 800–810, 2021.
- [63] M. Tan and Q. V. Le “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks.” 36th *Int. Conf. Mach. Learn.* pp. 10691–10700, 2019.
- [64] M. Tan and Q. V. Le “EfficientNetV2: Smaller Models and Faster Training.” 2021.
- [65] Y. Bengio “Practical recommendations for gradient-based training of deep architectures.” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 7700, pp. 437–478, 2012.
- [66] S. Haykin “Neural networks and learning machines, 3/E.” Pearson Education India, 2009.
- [67] R.J. Fante, V.D. Durairaj, and S.C.N. Oliver “Diabetic retinopathy: An update on treatment.” *Am. J. Med.* vol. 123, no. 3, pp. 213–216, 2010.
- [68] M.D. Abramoff, M.K. Garvin, and M. Sonka “Retinal imaging and image analysis.” *IEEE Rev. Biomed. Eng.* vol. 3, pp. 169–208, 2010.
- [69] G.V. DODDI “eye_diseases_classification | Kaggle,” <https://www.kaggle.com/datasets/gunavenk/atdoddi/eye-diseases-classification>.