



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



Glakom ve katarakt hastalığının derin öğrenme modelleri ile teşhisi

Diagnosis of glaucoma and cataract disease with deep learning models

Yazar(lar) (Author(s)): Mustafa TEKE ¹, Zafer CİVELEK ², Mehmet TÜMAY ³

ORCID¹: 0000-0002-7262-4918

ORCID²: 0000-0001-6838-3149

ORCID³: 0000-0003-2938-8005

To cite to this article: Teke M., Civelek Z. ve Tümay M., “Glakom ve Katarakt Hastalığının Derin Öğrenme Modelleri ile Teşhisi”, *Journal of Polytechnic*, 27(5): 1813-1821, (2024).

Bu makaleye şu şekilde atıfta bulunabilirsiniz: Teke M., Civelek Z. ve Tümay M., “Glakom ve Katarakt Hastalığının Derin Öğrenme Modelleri ile Teşhisi”, *Politeknik Dergisi*, 27(5): 1813-1821, (2024).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.1348143

Glakom ve Katarakt Hastalığının Derin Öğrenme Modelleri ile Teşhisi


Diagnosis of Glaucoma and Cataract Disease with Deep Learning Models

Önemli noktalar (Highlights)

- ❖ Katarakt ve glakom hastalıkları için erken tanı ve teşhisinin belirlenebilmesi sağlanmıştır. / Early detection and diagnosis of cataract and glaucoma diseases are provided.
- ❖ Eğitilmiş ağların göz data setiyle yeniden eğitilip karşılaştırılması yapılmıştır. / The trained networks were retrained and compared with the eye data set.
- ❖ En başarılı sonucu veren ağ mimarisi ve eniyileme yöntemi simülasyonlar sonucunda tesbit edilmiştir. / The network architecture and optimization method that gives the most successful results were determined as a result of simulations.

Grafik Özet (Graphical Abstract)

Göz dibi resimleriyle katarakt ve glakom hastalıklarının derin öğrenme modelleriyle erken teşhisi analiz edilmiştir. / Early diagnosis of cataract and glaucoma diseases with deep learning models was analyzed using fundus images.



Şekil A. Sistemin çalışması / Figure A. Operation of the system

Amaç (Aim)

Bu çalışmanın amacı katarakt ve glakom olarak bilinen göz hastalıklarının Evrişimli Sinir Ağları (ESA) kullanılarak erken tanı ve teşhisinin analiz edilebilirliğini belirlemektir. / The aim of this study is to determine the analysability of the early detection and diagnosis of eye diseases known as cataracts and glaucoma using Convolutional Neural Networks (CNN).

Tasarım ve Yöntem (Design & Methodology)

Araştırma, bir süreç yöntemi önermektedir. Optimizasyon yöntemleri uygulanarak eğitilmiş ağların performansları karşılaştırılmıştır. / The research proposes a process method. The performances of the trained networks were compared by applying optimization methods.

Özgünlük (Originality)

Bu çalışmada kullanılan ağlar, bu modele ve veri kümesine ilk kez uygulanmıştır. / The networks used in this study have been applied to this model and dataset for the first time.

Bulgular (Findings)

Bu çalışma, datasetteki göz dibi görüntüleri kullanılarak gerçekleştirilmiştir. Diğer ağlara kıyasla rmsprop optimizator ve Xception ağ mimarisi ile elde edilenlerin daha iyi sonuçlar verdiği tespit edilmiştir. / This study was conducted using fundus images in the dataset. Compared to other networks, it has been determined that the ones obtained with the rmsprop optimizator and the Xception network architecture have better results.

Sonuç (Conclusion)

Tespit edilen sürecin, bu hastalıkların erken tanısı ve uzman teşhisine yardımcı olmak için kullanılabilir bir araç olacağını göstermektedir. / It demonstrates that the identified process will be a usable tool to aid in early and expert diagnosis of these diseases.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Glakom ve Katarakt Hastalığının Derin Öğrenme Modelleri ile Teşhisi

Araştırma Makalesi / Research Article

Mustafa TEKE¹, Zafer CİVELEK¹, Mehmet TÜMAY^{2*}

¹ Çankırı Karatekin Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Türkiye

² Çankırı Karatekin Üniversitesi, Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümü, Türkiye

(Geliş/Received : 22.08.2023 ; Kabul/Accepted : 18.09.2023 ; Erken Görünüm/Early View : 15.11.2023)

ÖZ

Göz, insanoğlunun en önemli organlarından biri olmasına rağmen birçok hastalığa da maruz kalabilmektedir. Bu hastalıklardan bazılarında toplumda sıklıkla rastlanmaktadır. Bunlardan ikisi katarakt ve glakom olarak bilinen çok önemli göz hastalıklarıdır. Evrişimli Sinir Ağları (ESA), bu hastalıkların erken tanı ve uzman teşhisine yardımcı olmak için kullanılabilir. Bu çalışmada derin öğrenme yöntemlerinden biri olan Evrişimli Sinir Ağları kullanılarak katarakt, glakom ve normal göz dibi görüntüleri sınıflandırılmıştır. Eğitilmiş Ağlar kullanılarak Googlenet, Densenet-201, Xception ve Inception-V3 ağlarının performansları karşılaştırılmıştır. Her ağ için adam, rmsprop ve sgdm optimizasyon yöntemleri uygulanmıştır. Bu çalışma, datasetteki 262 Katarakt, 200 Glakom ve 2816 normal göz dibi görüntüsü kullanılarak yapılmıştır. Görüntüler, yeniden boyutlandırma, arka planı kaldırma, rastgele döndürme ve yeniden boyutlandırma ile önceden işlenmiştir. Matlab ortamında yapılan simülasyonlar sonucunda, diğer ağlara göre en iyi sonuçlar rmsprop optimizasyonlu Xception ağ mimarisi ile elde edilmiştir.

Anahtar Kelimeler: Derin öğrenme, Evrişimli sinir ağları, Katarakt, Glakom.

Diagnosis of Glaucoma and Cataract Disease with Deep Learning Models

ABSTRACT

Although the eye is one of the most important organs of human beings, it can also be exposed to many diseases. Some of these diseases are frequently encountered in society. Two of these are very important eye diseases known as cataracts and glaucoma. Convolutional Neural Networks (CNN) can be used to aid in the early detection and expert diagnosis of these diseases. In this study, cataract, glaucoma and normal eye fundus images have been classified using Convolutional Neural Networks, which is one of the deep learning methods. The performances of Googlenet, Densenet-201, Xception and Inception-V3 networks have been compared using Transfer Learning. Adam, rmsprop and sgdm optimization methods have been applied for each network. This study has been performed using 262 Cataracts, 200 Glaucoma and 2816 normal fundus image data in the Dataset. Images have pre-processed with resizing, background removal, random rotation and resizing. As a result of the simulations made in the Matlab environment, the best results have obtained with the Xception network architecture with rmsprop optimizer compared to other network ones.

Keywords: Deep learning, Convolutional neural networks, Cataract, Glaucoma.

1. GİRİŞ (INTRODUCTION)

İnsanoğlu için her duyu organının yetisi çok önemlidir, bunların başında görme duyusu gelmektedir. Görme kayıplarının önüne geçmek ve riskli duruma düşmemek için her hastalıkta olduğu gibi göz hastalıklarında da hastalığın erken teşhisi, tedavi süreci için çok önemli bir yere sahiptir. Katarakt ve glakom en çok görülen göz hastalıklarının başında gelmektedir ayrıca glakom göz hastalıklarının en tehlikelilerinden biridir ve hastanın bu durumu anlaması pek de mümkün olmamaktadır bu da teşhislerin gecikmesine sebep olabilmektedir. Bazı bölgelerdeki doktor veya uzman yetersizliği de teşhisin geç konmasında bir etkidir. Aynı zamanda uzmanın gözünden kaçan durumlar da olabilmektedir. Bütün bu durumlara çözüm olabilecek, çok fazla çalışma yapılmış ve yapılmaya devam etmektedir. Günümüzün en popüler

konularından biri olan ve hayatımızın her alanına girmeye başlayan yapay zeka en iyi çözümlerden biri haline almıştır. Bu çalışmada yapay zeka metodları kullanılarak glakom ve katarakt hastalığının teşhisini gerçekleştirecek makinenin en iyi performansı elde etmesi için farklı mimarilerin değerlendirilmesi amaçlanmıştır.

Katarakt ve glakom dahil olmak üzere toplam 6 çeşit hastalığın teşhisini derin öğrenme yöntemlerinden CNN kullanarak yapmış bir çalışma vardır. Basic CNN, Deep CNN, AlexNet 2, Xception, Inception V3, ResNet 50, and DenseNet121 ağ yapılarını transfer öğrenimi yöntemi ile kullanmıştır [1, 2]. Bu çalışmada, geniş alanlı, kaynak taramalı optik koherens tomografi (wide-field swept-source optical coherence tomography (SS-OCT) images) görüntülerinden, derin öğrenme

*Sorumlu Yazar (Corresponding Author)
e-posta : mtumay@karatekin.edu.tr


sınıflandırıcısı kullanarak glakom hastalığının teşhisi sağlanmıştır. Geniş alanlı SS-OCT görüntüleri kullanarak DL tabanlı yöntemlerin performansı ile geleneksel parametre tabanlı (conventional parameter based methods) yöntemlerin performansını karşılaştırılmıştır. Derin öğrenme ağı olarak VGG-19 kullanılmıştır. 258'i sağlıklı, 417'si glakom hastası olmak üzere 675 resim üzerinde çalışılmıştır [3]. Bu çalışmada, ultra geniş alan taramalı lazer oftalmoskop ile alınmış görüntülerin derin öğrenme (DL) sınıflandırıcı ağı kullanarak glakom görme kusuru teşhisi yapılmıştır. Glakom görme hasarı bölgesine göre hastalar 3 sınıfa ayrılmıştır. Bu sınıflar, erken, orta ve şiddetlidir. Çalışmada, erken sınıfına ait 558 resim, orta sınıfına ait 203 resim, şiddetli sınıfına ait 221 resim ve sağlıklı gözlerle ait 417 resim kullanılmıştır. Bu çalışmada kendi geliştirdikleri evrişimli sinir ağını kullanmışlardır [4]. Spektral alanlı optik koherens tomografi (SD-OCT) görüntüleri ve derin öğrenme ağları ile glakom hastalığının teşhisi yapılmıştır. Bu çalışmada 350 görüntü kullanılmıştır. 196 görüntü sağlıklı, 197 görüntü hastalara aittir. NASNet ağ yapısı kullanılmıştır [5]. Bu çalışmada hibrit derin öğrenme metodu ile optik koherens tomografi görüntüleri kullanılarak daha önce sağlıklı ama glakom şüpheli ve hafif glakom olarak etiketlenilmiş verilerin sınıflandırılması yapılmıştır. 102 görüntüden, 57 si hafif glakomlu, 45'i glakom şüpheli olarak uzmanlarca etiketlenmiştir. Evrişimli sinir ağı olarak AlexNet özellik çıkarmak için kullanılmıştır. Çıkarılan özellikler Random forest classifier kullanılarak glakom hastalığı sınıflandırması yapılmıştır [6]. Bu makale, katarakt tespiti için normal, hafif, orta ve şiddetli gibi fundus retina görüntülerinden kataraktın ciddiyetini derecelendiren bir bilgisayar destekli tanı yöntemi önermiştir. Önerilen yöntem, özellikleri çıkarmak için transfer öğrenmeli çeşitli önceden eğitilmiş evrişimli sinir ağlarının (AlexNet, VGGNet, ResNet) kullanıldığı hibrit bir yaklaşım kullanır. Her bir ağı ayrı ayrı ve birleştirilmiş haldeki bu öznelik vektörleri, 4 aşamalı katarakt sınıflandırması için destek vektör makine sınıflandırıcılarına uygulanır. Fundus katarakt görüntüleri, birkaç açık erişim veri setinden elde edilir ve bir göz uzmanının yardımıyla 4 sınıf halinde düzenlenir [7]. Bu çalışmada, yarık lamba (slit-lamp) görüntülerinden nükleer kataraktların ciddiyetini derecelendirmek için özellikleri otomatik olarak öğrenecek bir sistem önerilmektedir. Katarakt derecesini belirlemek için destek vektör regresyonu uygulanmaktadır. Tüm deneyler, 0,1 ile 5,0 arasında değişen ondalık derecelendirme puanlarına sahip 5378 görüntüden oluşan ACHIKO-NC veri kümesi üzerinde gerçekleştirilmiştir [8]. Bu çalışma, dört tür dijital retina görüntüsü (DRI) için derin öğrenme tabanlı bir kategorizasyon yaklaşımını açıklamaktadır. 300 resmin normal, geri kalanının hastalıklı olduğu toplam 601 resim mevcuttur. 100 resim katarakt, 101 resim glakom ve 100 resim retina hastalıklarına aittir.

Bu çalışmada, göz hastalıklarının tespiti ve sınıflandırılması için ImageNet veri seti (1000 sınıf) üzerinde önceden eğitilmiş ağırlıkları ile Inception V4 derin öğrenme modeli olarak adlandırılan bir CNN varyantı kullanılmıştır [9]. Dijital kamera görüntülerinden oluşturulan bir veri seti kullanılarak evrişimli konvolüsyon ağları (CNN) ile katarakt teşhisi gerçekleştirilmiştir. CNN'in zaman ve maliyetini azaltmak amacıyla ADAM optimizasyonu kullanılmıştır. Evrişimli konvolüsyon ağı; 3 konvolüsyon katmanı, 3 ortaklama (pooling) katmanı, 1 düzleştirme (flatten) katmanı ve 2 sıkışık (dense) katmanından oluşmaktadır [10]. Retinal fundus kamera görüntülerinde optik disk üzerinden katarakt ve sağlıklı olma durumlarının sınıflandırılması gerçekleştirilmiştir. Çin'deki Shang Gong Medical Technology tarafından toplanan 512x512 pikseli 613 renkli görüntüden oluşmaktadır. Bu görüntüler ön işleme sırasında 0 ile 1 arasında ölçeklendirilmiştir ve her bir renk kanalı için normalizasyon gerçekleştirilmiştir. Jupyter Notebook'ta VGG-19, ResNet-50 ve ResNet-100 mimarileri kullanarak görüntülerin sınıflandırması yapılmıştır [11]. Bu çalışmada, bir oküler B-ultrason görüntü veri seti toplanmaktadır ve kataraktı saptamak için İşbirlikçi İzleme Derin Öğrenme (CMDL) yöntemi önerilmiştir. Önerilen CMDL yönteminde, gürültü girişimini azaltmak, kataraktı algılamak ve doğruluğunu iyileştirmek ve odak alanlarını algılamak için YOLO-v3'e dayalı bir nesne algılamaya ağı sunulmuştur. Bu çalışmada kullanılan veri seti 5595 görüntü içermektedir. Ayrıca, önerilen CMDL modelini değerlendirmek için eğitim setindeki 5045 görüntü 9:1 oranına göre iç eğitim alt kümesine ve doğrulama alt kümesine rastgele bölünmüştür [12]. Fundus görüntülerinden kataraktın normal, hafif, orta ve şiddetli gibi çeşitli aşamalarını tespit etmek için bilgisayar destekli otomatik katarakt tespit yöntemi önerilmiştir. Özellik çıkarımı için önceden eğitilmiş CNN modeli kullanılır ve çıkarılan özellikler daha sonra bir destek vektör makinesi (SVM) sınıflandırıcısına uygulanır. Fundus katarakt görüntüleri, çeşitli açık erişim veri setlerinden toplanır ve oftalmoloji uzmanlarının yardımıyla dört aşamada etiketlenir [13]. Hastaların fundus görüntüleriyle otomatik olarak teşhis ve derecelendirme yapan bir algoritma geliştirilmiştir. İki göz doktorunun etiketlediği ve 3 deneyimli kişinin kontrolünden geçen 1352 görüntüye sahip bir veri seti oluşturulmuştur. Bu veri setindeki görüntüler; 487 görüntü sağlıklı, 317 görüntü çok hafif katarakt, 124 görüntü hafif katarakt, 154 görüntü orta katarakt, 135 görüntü hafif şiddetli katarakt ve 135 şiddetli katarakt olmak üzere altı dereceden oluşmaktadır. Katarakt derecelerinin ResNet18 ağı kullanılarak üst düzey özellikler, gri düzey eş oluşum matrisleri (GLCM) kullanılarak ise doku özellikleri çıkarılmıştır. Fundus görüntülerinin sınıflandırılmasında destek vektör makineleri (SVM) ve tam evrişimli sinir ağı (FCNN) kullanılmıştır [14]. Derin öğrenme kullanılarak yapılmış bir çok çalışma literatürde mevcuttur [15-20].

2. MATERYAL VE METOD (MATERIAL AND METHOD)

Bu çalışmada Kaggle sitesinden indirilmiş bir data seti kullanılmıştır. Data setinde, Ocular Disease Intelligent Recognition (ODIR) 262 katarakt, 200 glakom, 2816 normal retinal fundus resimleri kullanılmıştır. Bu veri seti Shangong Medical Technology Co., Ltd. tarafından Çin'deki farklı hastanelerden toplanmıştır. Bu kurumlarda, Canon, Zeiss ve Kowa gibi piyasadaki çeşitli kameralar tarafından çekilmiş fundus görüntüleri vardır. Ek açıklamalar, kalite kontrol yönetimi ile eğitilmiş insan okuyucular tarafından etiketlenmiştir. <https://www.kaggle.com/datasets/andrewmvd/ocular-disease-recognition-odir5k> adresinden Bu data setine ulaşılabilir..


Data setine ait resimlerin örnekleri Şekil 1'de gösterilmiştir.



Şekil 1. Data setine ait örnek resimler (a) katarakt (b) glakom (c) normal (Sample images of the data set (a)-cataract (b)-glaucoma (c)-normal)

2.1. Ön işleme (Preprocessing)

Şekil 2'de görüldüğü gibi değişik boyutta bulunan göz fundus resimleri tekrar boyutlandırma ile 224x224x3 boyutuna getirilmiştir. Daha sonra resimlerin arka planlarında bulunan kısımlardan resimler ayrılmıştır. Daha sonra -45 derece ile 45 derece arasında rastgele döndürme işlemine tabi tutulmuştur. Daha sonra bazı resimler 0,5 ile 1 arasında rastgele boyutlandırmaya tabi tutulmuştur.



Şekil 2. Ön işleme bölümleri (Preprocessing sections)

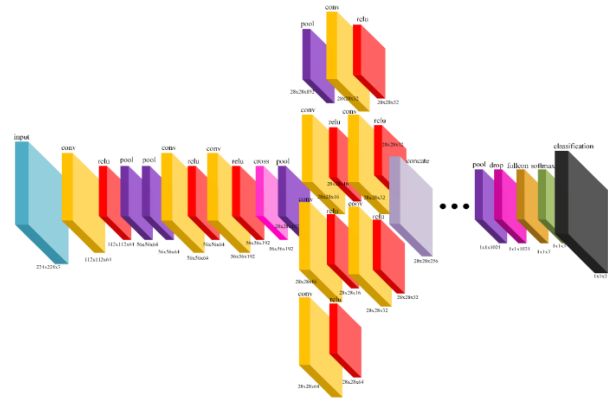
2.2. Transfer Öğrenimi (Transfer Learning)

Transfer learning'de daha önceden eğitilmiş bazı ağlar kullanılmıştır. Bu ağların eğitilmiş ağırlıkları aynen kullanılmıştır. Ağların konvolüsyon tabakalarında bir değişiklik yapılmamıştır. Yalnızca tam bağlantı tabakalarında data setine ve sınıf sayısına uygun değişiklikler yapılmıştır. Matlab ortamında yapılan simülasyonda mini batch size=10, max epoch=8, learning rate=0.0001, validation frequency=5 olarak alınmıştır.

2.2.1. GoogleNet

Yapı, ağ derinliği ve genişliğindeki bazı değişikliklerle birlikte LeNet ve AlexNet'ten bazı çerçeve yapılarını devralır. Yapı 22 ağ katmanına sahiptir ancak VGG parametrelerinin yalnızca 1/36'sı kadardır. Eğitim döngüsünü büyük ölçüde kısaltan paralel yapıyı yenilikçi bir şekilde kullanır. GoogLeNet, kaynakları daha verimli


kullanarak, başka bir deyişle aynı miktarda hesaplama için daha fazla özellik çıkararak eğitim sonuçlarını iyileştirir [21]. Ağın mimari yapısı Şekil 3'te gösterilmiştir.



Şekil 3. GoogleNet mimarisi (GoogleNet architecture)

2.2.2. DenseNet

DenseNet mimarisi, tüm katmanları ileri beslemeli bir şekilde doğrudan birbirine bağlayan bir bağlantı modeli kullanır. Geleneksel evrişimli H katmanlı bir ağ, katmanlar arasında H adet bağlantıya sahip iken, DenseNet mimarisinde $\frac{H(H+1)}{2}$ bağlantıya sahiptir. Her katman, önceki tüm katmanlardan girdiler alır ve sonraki tüm katmanlara kendi özellik çıkarımını aktarır. Böylece ağdaki bilgi akışını en üst düzeye çıkarmaya çalışır. Bu mimari, kaybolan gradyan problemini azaltır, özellik yayılımını artırır, ayrıca parametre sayısında önemli miktarda azalma sağlar [22]. Ağın mimari yapısı Şekil 4'de gösterilmiştir.




Şekil 4. DenseNet mimarisi (DenseNet architecture)

2.2.3. Xception

Xception mimarisi özellikleri çıkarmak için 36 evrişim katmanı dahil olmak üzere 126 katmana sahiptir. Parametre sayısını azaltmak için tam bağlı katmanın yerini almak üzere bir genel ortalama havuzlama katmanı kullanılır ve tahminin çıktısını almak için softmax işlevi kullanılır. 36 evrişimli katman, ilk ve son modüller hariç tümü etrafında doğrusal atlama bağlantılarına sahip 14 modül halinde yapılandırılmıştır. 36 evrişimli katman 3 bileşene ayrılmıştır: giriş akışı; orta akış ve çıkış akışı. Veriler önce giriş akışından, ardından sekiz kez tekrarlanan orta akıştan ve son olarak çıkış akışından geçer. Giriş akışı 8 evrişim katmanından, orta akış $8 \times 3 = 24$ evrişim katmanından ve çıkış akışı 4 evrişim katmanından oluşur. Xception modeli, derinlemesine


ayrılabilir evrişim işlemi uygulamıştır ve bu da evrişim işlem maliyetini önemli ölçüde azaltmıştır [23]. Ağın mimari yapısı Şekil 5’de gösterilmiştir.



Şekil 5. Xception mimarisi (Xception architecture)

2.2.4. Inception-V3

Inception-v3 modeli üç bölümden oluşur: temel evrişim bloğu, geliştirilmiş Inception modülü ve sınıflandırıcı. Özellik çıkarımı için evrişimli ve maksimum havuzlama katmanlarını değiştiren temel evrişimli blok kullanılır. Geliştirilmiş Başlangıç modülü, çok ölçekli evrişimlerin paralel olarak yürütüldüğü ve her dalın evrişimsel sonuçlarının daha da birleştirildiği Ağ İçinde Ağ temelinde tasarlanmıştır. Yardımcı sınıflandırıcıların kullanımı sayesinde, daha kararlı eğitim sonuçları ve daha iyi gradyan yakınsaması elde edilir ve aynı anda kaybolan gradyanlar ve fazla uydurma sorunları da hafifletilir. Inception-v3’te, özellik kanallarının sayısını azaltmak ve eğitim hızını artırmak için yaygın olarak 1×1 evrişimli çekirdek kullanılır. Ek olarak, büyük evrişim, parametre sayısını ve hesaplama masrafını azaltan küçük evrişimlere ayrıştırılır [24]. Ağın mimari yapısı Şekil 6’da gösterilmiştir.



Şekil 6. Inception-v3 mimarisi (Inception-v3 architecture)

2.3. Eniyileme Yöntemleri (Optimization Methods)

Stokastik gradyan inişi, uygun pürüzsüzlük özellikleriyle bir amaç fonksiyonunu optimize etmek için yinelemeli bir yöntemdir. Gerçek gradyanı bunun bir tahminiyle değiştirdiğinden, gradyan iniş optimizasyonunun stokastik bir yaklaşımı olarak kabul edilebilir. Özellikle yüksek boyutlu optimizasyon problemlerinde bu, çok yüksek hesaplama yükünü azaltır ve daha düşük bir yakınsama oranı karşılığında daha hızlı yinelemeler sağlar [25].

RMSprop iyileştirici, momentumlu gradyan iniş algoritmasına benzer. RMSprop optimizör, salınımları dikey yönde kısıtlar. Bu nedenle, öğrenme oranı arttırılabilir ve algoritma yatay yönde daha hızlı yakınsayarak daha büyük adımlar atabilir [26].

Adam optimizör, derin öğrenme uygulamalarında uygulanabilecek olan stokastik gradyan inişinin genişletilmiş versiyonudur. Yöntemin uygulanması kolaydır, hesaplama açısından verimlidir, az bellek gereksinimi vardır ve parametreler açısından büyük problemler için çok uygundur [27].

2.4. Değerlendirme Ölçütleri (Evaluation Criteria)

Doğruluk (Accuracy), bir modelde doğru tahmin edilen alanların toplam veri kümesine oranı olarak hesaplanmaktadır ve Eşitlik 1’de ifade edilmiştir. Özellikle eşit dağılmayan veri kümelerinde model doğruluğu tek başına yeterli değildir. Eşitlik (1), (2), (3), (4) de, DP: Doğru Pozitif, DN: Doğru Negatif, YP: Yanlış Pozitif, YN: Yanlış Negatif kısaltmaları kullanılmıştır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (1)$$

Kesinlik (Precision), pozitif olarak tahmin edilen değerlerin gerçekte kaç adedinin pozitif olduğunu göstermektedir ve eşitlik (2)’de gösterilmiştir. Kesinlik değeri özellikle Yanlış Pozitif tahminlerin önemli olduğu durumlarda dikkat edilmesi gereken bir kriterdir.

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (2)$$

Duyarlılık (Sensitivity) ise pozitif olarak tahmin etmemiz gereken işlemlerin ne kadarını pozitif olarak tahmin ettiğimizi gösteren bir metriktir ve eşitlik (3)’ verilmiştir. Yanlış Negatif tahminlerin önemli olduğu durumlarda dikkate alınması gereken bir metriktir.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3)$$

F1_Score, kesinlik ve duyarlılık değerlerinin harmonik ortalamasını göstermektedir ve eşitlik (4)’te gösterilmiştir. Harmonik ortalama olmasının sebebi uç durumların göz ardı edilmemesidir. Doğruluk yanında F1_Score’un da dikkate alınmasının sebebi eşit dağılmayan veri kümelerinde hatalı bir model seçimi yapmamaktır.

$$F1_{score} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

3. BULGULAR VE YORUMLAR (FINDINGS AND COMMENTS)

Bu makalede katarakt, glakom ve normal göz resimlerinin sınıflandırılması yapılmıştır. Çalışma Matlab ortamında gerçekleştirilmiştir. GoogLeNet, Xception, Inception-V3 ve DenseNet-201 ağ mimarileri

Çizelge 1. Simülasyon sonuçları (Simulation results)

Ağ	Çözücü	Eğitim Doğruluğu	Eğitim Kaybı	Doğrulama Oranı	Doğrulama Kaybı	Test Doğruluğu	Test Kesinliği	Test Duyarlılığı	Test F1_Skoru
Googlenet	adam	100	0,0521	91,4839	0,2535	0,9596	0,8754	0,7576	0,8028
Xception	adam	100	0,0103	90,9677	0,3801	0,9688	0,9327	0,7995	0,8534
Inception-V3	adam	100	0,0428	91,4839	0,3071	0,9619	0,9272	0,7483	0,7911
DenseNet-201	adam	90	0,1585	91,6129	0,2837	0,9566	0,9241	0,7102	0,7565
Googlenet	rmsprop	100	0,0654	90,5806	0,3718	0,9430	0,9450	0,5926	0,6391
Xception	rmsprop	100	0,0534	89,9355	0,4965	0,9736	0,9331	0,8475	0,8855
Inception-V3	rmsprop	90	0,1664	91,6129	0,3459	0,9641	0,9193	0,7715	0,8229
DenseNet-201	rmsprop	90	0,2302	91,0968	0,2690	0,9596	0,8293	0,8654	0,8461
Googlenet	sgdm	100	0,0401	89,8065	0,2817	0,9469	0,8382	0,6538	0,7065
Xception	sgdm	100	0,0659	90,9677	0,2766	0,9439	0,8473	0,6185	0,6294
Inception-V3	sgdm	90	0,0928	90,8387	0,2887	0,9546	0,8627	0,7113	0,7506
DenseNet-201	sgdm	90	0,1479	91,6129	0,2736	0,9594	0,8380	0,8184	0,8261

kullanılmıştır. Bu ağların ön eğitilmiş ağırlıkları kullanılmakla birlikte, ağ mimarilerinde probleme uygun şekilde düzenlemeler yapılmıştır. Yapılan çalışma 3'lü bir sınıflandırma problemi olduğundan Googlenet, Xception, Inception-V3 ve DenseNet-201 ağ mimarileri bu üçlü sınıflandırmaya göre yeniden düzenlenmiştir.

Simülasyon esnasında kullanılan ağ mimarilerinde üç çeşit eniyileme algoritmaları kullanılmıştır. Bu eniyileme algoritmaları; adam, rmsprop ve sgdm dir.

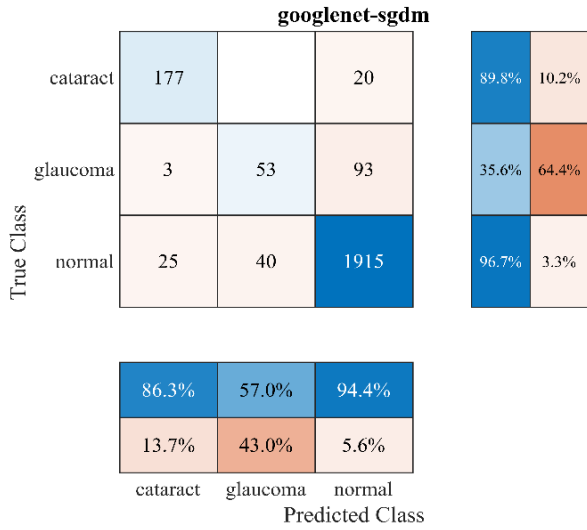
Böylece her ağ yapısı üç eniyileme algoritması için denenmiştir. Bulunan sonuçlar Çizelge 1'de gösterilmiştir.

		googlenet-adam				
True Class	cataract	174		23	88.3%	11.7%
	glaucoma		98	51	65.8%	34.2%
	normal	2	41	1937	97.8%	2.2%
		98.9%	70.5%	96.3%		
		1.1%	29.5%	3.7%		
		cataract	glaucoma	normal	Predicted Class	


(a) Karışıklık Matrisi GoogleNet adam (Confusion Matrix GoogleNet adam)

		googlenet-rmsprop				
True Class	cataract	149	10	38	75.6%	24.4%
	glaucoma		127	22	85.2%	14.8%
	normal		292	1688	85.3%	14.7%
		100.0%	29.6%	96.6%		
			70.4%	3.4%		
		cataract	glaucoma	normal	Predicted Class	


(b) Karışıklık Matrisi GoogleNet rmsprop (Confusion Matrix GoogleNet rmsprop)




(c) Karışıklık Matrisi GoogleNet sgdm (Confusion Matrix GoogleNet sgdm)



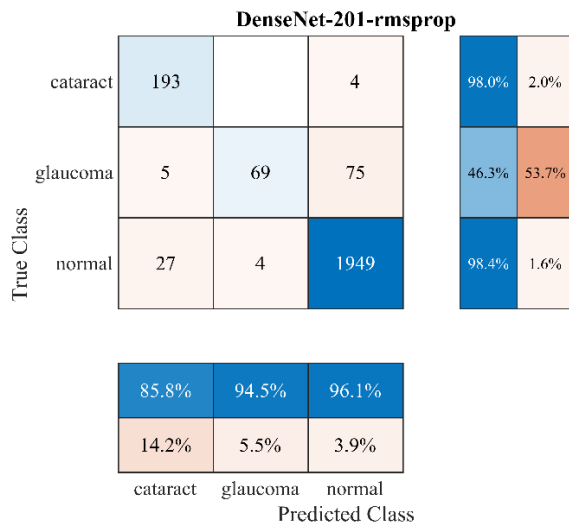
(f) Karışıklık Matrisi DenseNet-201 sgdm (Confusion Matrix DenseNet-201 sgdm)



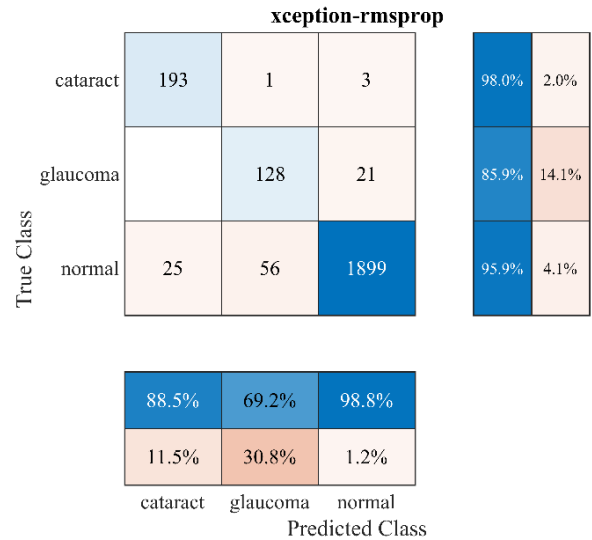
(d) Karışıklık Matrisi DenseNet-201 adam (Confusion Matrix DenseNet-201 adam)



(g) Karışıklık Matrisi Xception adam (Confusion Matrix Xception adam)



(e) Karışıklık Matrisi DenseNet-201 rmsprop (Confusion Matrix DenseNet-201 rmsprop)



(h) Karışıklık Matrisi Xception rmsprop (Confusion Matrix Xception rmsprop)

		xception-sgdm					Inception-V3-sgdm				
True Class	cataract	171		26	86.8%	13.2%	186		11	94.4%	5.6%
	glaucoma	3	4	142	2.7%	97.3%	6	46	97	30.9%	69.1%
	normal	23	2	1955	98.7%	1.3%	21	22	1937	97.8%	2.2%
		86.8%	66.7%	92.1%			87.3%	67.6%	94.7%		
		13.2%	33.3%	7.9%			12.7%	32.4%	5.3%		
		cataract	glaucoma	normal			cataract	glaucoma	normal		
		Predicted Class					Predicted Class				

(i) Karışıklık Matrisi Xception sgdm (Confusion Matrix Xception sgdm)

(l) Karışıklık Matrisi Inception-V3 sgdm (Confusion Matrix Inception-V3 sgdm)

Şekil 7. Karışıklık Matrisleri (Confusion Matrices)

		Inception-V3-adam				
True Class	cataract	188		9	95.4%	4.6%
	glaucoma	1	114	34	76.5%	23.5%
	normal	17	37	1926	97.3%	2.7%
		91.3%	75.5%	97.8%		
		8.7%	24.5%	2.2%		
		cataract	glaucoma	normal		
		Predicted Class				

(j) Karışıklık Matrisi Inception-V3 adam (Confusion Matrix Inception-V3 adam)

		Inception-V3-rmsprop				
True Class	cataract	183	1	13	92.9%	7.1%
	glaucoma		113	36	75.8%	24.2%
	normal	14	70	1896	95.8%	4.2%
		92.9%	61.4%	97.5%		
		7.1%	38.6%	2.5%		
		cataract	glaucoma	normal		
		Predicted Class				

(k) Karışıklık Matrisi Inception-V3 rmsprop (Confusion Matrix Inception-V3 rmsprop)

4. SONUÇLAR (RESULTS)

Bu çalışmada, Katarakt, Glakom ve Normal göz resimlerinin sınıflandırılması için transfer learning metodu kullanılmıştır. Deep neural network modeli olarak GoogleNet, DenseNet-201, Xception ve Inception-V3 modelleri kullanılmıştır. Ağların eğitilmiş ağırlıkları ile eğitime başlandığından, eğitim süresi kısaltılmıştır. Çizelge 1 incelendiğinde, test doğruluk bakımından en iyi performansı %97,36 ile rmsprop optimizasyon yöntemli Xception ağı göstermiştir. Bununla birlikte %96,88 ile Xception-adam, %96,41 ile Inception-V3-rmsprop ve %96,19 ile Inception-V3-adam doğruluk bakımından yüksek ağırlardır. Test precision olarak en iyi performansı %94,50 ile GooleNet-rmsprop göstermiştir. GoogleNet'den sonra %93,31 ve %93,27 ile Xception-rmsprop ve Xception-adam gelmektedir. Test sensitivity açısından %86,54 ile DenseNet-201-rmsprop en iyi performansı göstermiştir. Daha sonra %84,75 ile Xception-rmsprop gelmektedir. Test F1_Score açısından %88,55 ile Xception-rmsprop en iyi performansı göstermiştir.

Şekil 7'deki Karışıklık matrisleri incelendiğinde Xception rmsprop ağının üç sınıfı da %85 üzerinde bir sınıflandırma ile en iyi olduğu görülmektedir. Ondan sonra üç sınıfı da dengeli bir şekilde %75 üzerinde bir doğrulukla sınıflandıran Googlenet rmsprop gelmektedir. Diğer ağların glakom sınıflandırma başarıları bu iki ağa yetişmemektedir.

Sonuç olarak, Çizelge 1 simülasyon sonuçları ve Şekil 7 Karışıklık matris sonuçlarına göre katarakt, glakom ve normal göz fundus görüntülerinden hastalık tespitinde en başarılı ağ modelinin Xception rms, ondan sonra Googlenet rmsprop olduğu söylenebilir.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Mustafa TEKE: Simülasyonları yapmış ve sonuçlarını analiz etmiştir.

Zafer CİVELEK: Simülasyonları yapmış ve sonuçlarını analiz etmiştir.

Mehmet TÜMAY: Sonuçları analiz etmiş ve makalenin yazım işlemini gerçekleştirmiştir.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

KAYNAKLAR (REFERENCES)

- [1] Kumar, Y., and Gupta, S., "Deep transfer learning approaches to predict glaucoma, cataract, choroidal neovascularization, diabetic macular edema, drusen and healthy eyes: an experimental review", *Archives of Computational Methods in Engineering*, 30(1):521-541, (2023).
- [2] Kubilay, A. T. A. Ş., Atakan, K. A. Y. A., & Myderrizi, I., "Yapay sinir ağı tabanlı model ile x-ray görüntülerinden Covid-19 teşhisi", *Politeknik Dergisi*, 26(2): 541-551, (2023).
- [3] Shin, Y., Cho, H., Jeong, H. C., Seong, M., Choi, J. W., & Lee, W. J., "Deep learning-based diagnosis of glaucoma using wide-field optical coherence tomography images", *Journal of Glaucoma*, 30(9): 803-812, (2021).
- [4] Masumoto, H., Tabuchi, H., Nakakura, S., Ishitobi, N., Miki, M., & Enno, H., "Deep-learning classifier with an ultrawide-field scanning laser ophthalmoscope detects glaucoma visual field severity", *Journal of Glaucoma*, 27(7): 647-652, (2018).
- [5] Lee, J., Kim, Y. K., Park, K. H., & Jeoung, J. W., "Diagnosing glaucoma with spectral-domain optical coherence tomography using deep learning classifier", *Journal of Glaucoma*, 29(4): 287-294, (2020).
- [6] Muhammad, H., Fuchs, T. J., De Cuir, N., De Moraes, C. G., Blumberg, D. M., Liebmann, J. M., ... & Hood, D. C., "Hybrid deep learning on single wide-field optical coherence tomography scans accurately classifies glaucoma suspects", *Journal of Glaucoma*, 26(12):1086, (2017).
- [7] Yadav, J. K. P. S., & Yadav, S., "Computer-aided diagnosis of cataract severity using retinal fundus images and deep learning", *Computational Intelligence*, 38(4): 1450-1473, (2022).
- [8] Gao, X., Lin, S., & Wong, T. Y., "Automatic feature learning to grade nuclear cataracts based on deep learning", *IEEE Transactions on Biomedical Engineering*, 62(11): 2693-2701, (2015).
- [9] Raza, A., Khan, M. U., Saeed, Z., Samer, S., Mobeen, A., & Samer, A., "Classification of eye diseases and detection of cataract using digital fundus imaging (DFI) and inception-V4 deep learning model", *IEEE International Conference on Frontiers of Information Technology (FIT)*, Pakistan, 137-142, (2021).
- [10] Chaudhary, R., & Kumar, A., "Cataract Detection using Deep Learning Model on Digital Camera Images", *IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom)*, Indonesia, 489-493, (2022).
- [11] Triyadi, A. B., Bustamam, A., & Anki, P., "Deep Learning in Image Classification Using VGG-19 and Residual Networks for Cataract Detection", *2nd International Conference on Information Technology and Education (ICIT&E)*, Indonesia, 293-297, (2022).
- [12] Wang, Y., Tang, C., Wang, J., Sang, Y., & Lv, J., "Cataract detection based on ocular B-ultrasound images by collaborative monitoring deep learning", *Knowledge-based systems*, 231, 107442, (2021).
- [13] Pratap, T., & Kokil, P., "Computer-aided diagnosis of cataract using deep transfer learning", *Biomedical Signal Processing and Control*, 53, 101533, (2019).
- [14] Zhang, H., Niu, K., Xiong, Y., Yang, W., He, Z., & Song, H., "Automatic cataract grading methods based on deep learning", *Computer methods and programs in biomedicine*, 182, 104978, (2019).
- [15] Mutlu, M., Özdem, K., & Akcayol, M. A., "Derin öğrenme ile kuş türü sınıflandırma: Karşılaştırmalı bir çalışma", *Politeknik Dergisi*, 25(3): 1251-1260, (2022).
- [16] Altun, S., & Alkan, A., "MR Spektroskopi kullanılarak beyin tümörü tespitinde LSTM tabanlı derin öğrenme uygulaması", *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(2), 1193-1202, (2022).
- [17] Gürkahraman, K., & Karakiş, R., "Veri çoğaltma kullanılarak derin öğrenme ile beyin tümörlerinin sınıflandırılması", *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36(2), 997-1012, (2021).
- [18] Yıldız, O., "Derin öğrenme yöntemleriyle dermoskopi görüntülerinden melanom tespiti: Kapsamlı bir çalışma", *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 34(4), 2241-2260, (2019).
- [19] Korkmaz Ş., Alkan M., "Derin öğrenme algoritmalarını kullanarak deepfake video tespiti", *Politeknik Dergisi*, 26(2): 855-862, (2023).
- [20] Şenalp F. M., Ceylan M., "Termal yüz görüntülerinden oluşan yeni bir veri seti için derin öğrenme tabanlı süper çözünürlük uygulaması", *Politeknik Dergisi*, 26(2): 711-720, (2023).
- [21] Szegegy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A., "Going deeper with convolutions", *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9, (2015).
- [22] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q., "Densely connected convolutional networks", *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4700-4708, (2017).
- [23] Chollet, F., "Xception: Deep learning with depthwise separable convolutions", *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251-1258, (2017).
- [24] Szegegy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z., "Rethinking the inception architecture for computer vision", *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826, (2016).
- [25] Hardt, M., Recht, B., & Singer, Y., "Train faster, generalize better: Stability of stochastic gradient descent", *33rd International Conference on Machine Learning*, New York, NY, USA, 48:1225-1234, (2016).

- [26] Kumar, A., Sarkar, S., & Pradhan, C., "Malaria disease detection using cnn technique with sgd, rmsprop and adam optimizers", *Deep learning techniques for biomedical and health informatics*, 211-230, (2020).
- [27] Salimans, T., & Kingma, D. P., "Weight normalization: A simple reparameterization to accelerate training of deep neural networks", *Advances in neural information processing systems*, 901-909, (2016).