



Derin Öğrenme Modellerini Kullanarak İnsan Retinasının Optik Koherans Tomografi Görüntülerinden Hastalık Tespiti

Batuhan METİN^{1*}, Bahadır KARASULU²

¹Çanakkale Onsekiz Mart Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Çanakkale, Türkiye

²Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Çanakkale, Türkiye

Özet

Bireylerin yaşamını olumsuz etkileyen aynı zamanda bireylerin yaşlarının ilerlemesi ile yaşamın kaçınılmazlarından olan en önemli sorunlardan birisi de retina hastalıkları sebebi ile meydana gelen görme bozukluklarıdır. Bu hastalıkların oluşmasının önüne geçmek için erken dönemlerde teşhis etme sayesinde yaşamın olumsuz etkilenmesinde ve sonraki evresi olan görme kaybı riskini en aza indirmek için çok önemlidir. Gelişen teknolojik yöntemler ile doğru orantılı olarak kullanımı yaygınlaşan makine öğrenmesi ve derin öğrenme yöntemleri Optik Koherans Tomografisi (OKT) görüntüleme yöntemi üzerinde çalışmayı yaygınlaştırmıştır. Bu çalışmada halkın kullanımına açık OKT veri kümesi üzerinden deneyler gerçekleştirilmiştir. Yüksek sınıflandırma performansları göz önüne alınarak Evrişimli Sinir Ağı (ESA) tabanlı ResNet50 ve MobileNetV2 modelleri çalışmamızda kullanılmıştır. Oluşturulan derin öğrenme tabanlı yapılar çalışmamızda gerçekleştirilen deneylerde çeşitli retina hastalıklarının sınıflandırılmasında test edilmiştir. Deneylerde farklı parametreler oluşturulan modeller üzerinde girdi olarak verilerek sınıflandırma başarımlarındaki doğruluk ölçümleri gerçekleştirilmiştir. Yapılan testlerin sonucunda, her iki model de dikkate alınarak makro ortalama doğruluk değerleri olarak yaklaşık %81 ile %94 aralığında bir başarımlar elde edilmiştir. Bu test sonuçlarına göre; deneylerde kullanılan ResNet50 ve MobileNetV2 modelleri birlikte dikkate alındığında ortalama F1 skoru; CNV için 0,75, Drusen için 0,86, DME için 0,90 ve normal yapıdaki retinalar için ise 0,96 olarak elde edilmiştir. Elde edilen sonuçlar ile literatürdeki çalışmalar karşılaştırıldığında yüksek doğrulukta başarımlar elde edildiği görülmüştür. Çalışmada sonuçlara ilişkin tartışma ve bilimsel bulgulara da yer verilmiştir.

Anahtar Kelimeler: Derin Öğrenme, Optik Koherans Tomografi, Evrişimli sinir ağı

Diseases Detection from Human Retina's Optical Coherence Tomography Images using Deep Learning Models

Abstract

One of the most important problems that has affected the lives of individuals is the progression of the age of individuals and the inevitable of life is the visual disorders caused by retinal diseases. To avoid these diseases, diagnosis in early periods is essential to

Makale Bilgisi

Başvuru:
03/10/2022
Kabul:
04/11/2022

* İletişim e-posta: batuhanmetin@gmail.com

minimize the risk of life being adverse and subsequent loss of vision. Machine learning and deep learning methods that have become more prevalent with evolving technological methods have made it more common to study the method of Optical Coherence Tomography (OCT) imaging. In this study, experiments were carried out on the publicly available OCT dataset. By considering their high classification performance, the Convolutional Neural Network (CNN)-based ResNet50 and MobileNetV2 models are used in our study. Deep learning-based structures were tested in the classification of various retinal diseases in the experiments carried out in our study. In experiments, accuracy measurements of classification performance were performed by giving input on models with different parameters created. By considering both models, the result of the tests was performed that the macro average accuracy values as resulting in a performance of approximately 81% to 94%. According to these test results, when the ResNet50 and MobileNetV2 models used in the experiments are considered together that the average $F1$ score is obtained as 0.75 for CNV, 0.86 for Drusen, 0.90 for DME and 0.96 for normal retinas. With the comparison of the results obtained in this study and other studies in the literature, it is showed that this study has high accuracy performance. The study also includes discussions and scientific findings on the results.

Keywords: Deep learning, Optical Coherence Tomography, Convolutional neural network

1 Giriş

Günümüzde doktorlar tarafından hastalığın detaylı bir şekilde teşhis edilmesi gelişen görüntüleme cihazları sayesinde. Hastalığa ait birçok görüntü, hastalığın teşhis edilmesi ve sonraki aşamalarda için takibinde kolaylıklar sağlamaktadır. Hastalık ile elde edilen çok sayıdaki görüntülerin takibi uzmanların performansı düşündüğünde sınırlı kalmaktadır. Bu durumda görüntü analizine dayalı teşhis ve takip sistemlerine ihtiyaç duyulmaktadır. Görüntü analizine dayalı karar destek sistemlerinin sağlık alanındaki önemi büyüktür [1]. Görüntülerin analiz edilip hastalıkların teşhis edilmesi çalışmaları sürekli gelişmekte ve kullanımı artmaktadır. Wilhelm Roentgen'in tıbbi görüntülemeye katkısı büyüktür. Roentgen tarafından X ışınları ve röntgen cihazı keşfedilmiştir [2]. Daha sonrasında vücut içerisinde yer alan alanların detaylı resimlerini kesitler halinde bilgisayar ortamına aktaran bilgisayarlı tomografi cihazları kullanılmaya başlanmıştır. Hastalardan anlık görüntülerin elde edilmesinde ultrason cihazları kullanılırken, vücut hakkında detaylı bilgi edinebilmek için diğer görüntüleme teknikleriyle genellikle elde edilemeyen sintigrafi görüntüleri kullanılır [3, 4]. Retina gibi göz dibine ait yapıların fundus cihazları ile incelendiği fundus görüntüleri diğer bir görüntüleme tekniğidir.

Sağlık alanındaki hastalıkların erken yaşlarda teşhis edilmesi modern sağlık sisteminin ve insan yaşamının önemli bir parçasıdır [5]. Göz, görme olayını gerçekleştiren, yaşamın kalitesini belirleyen bir duyu organımızdır. Bireylerin

yaşlarının ilerlemesi ve retina hastalıkları sebebi ile meydana gelen görme bozuklukları insanların yaşamlarına olumsuz etkilerde bulunmaktadır. Görme kayıplarını en aza indirebilmek için retina hastalıklarının erken dönemlerde teşhis edilmesi yaşamın kalitesine etki etmektedir [6]. Günümüzde insan uzman dışında en etkili çözüm yöntemlerinden biri makine öğrenmesi ve derin öğrenme kullanılarak görüntü sınıflandırılması ile teşhis edilmesidir. Gelişen teknolojide Optik Koherans Tomografi (Optical Coherence Tomography, OKT-OCT), lazer vasıtası ile retinanın her bir tabakası görülür ve bu tabakaların kalınlıkları haritalanıp ölçülür. Ölçüm sonucunda tanı konulan retina hastalıkları için tedavi rehberliği sağlamaktadır [7].

Derin öğrenme, gelişmiş bir temsili öğrenmeye (representation learning) dayanan makine öğrenmesinin alt sınıfıdır. Gizli katmanlar içerisinde öznelik elde etme işlemi yapabilen yapıya sahiptir. Seçilmiş özneliklerden veriyi öğrenmeye dayalı sisteme sahiptir [8]. 2017 yılında Google tarafından önerilen MobileNet mimarisi [9] mobil ve gömülü cihazlarda kullanılan derinlemesine ayrılabilir, bellek isterleri az olan bir derin sinir ağıdır. Önceden eğitilmiş evrimsel ve tam bağlantılı katmanlara sahip olan derin öğrenme modeli olan ResNet öznelik elde etmek için kullanılır [10].

Literatürde yapılan çalışmalar incelendiği zaman; Güldemir vd., 2021 yılındaki çalışmasında OKT görüntülerini kullanarak Evrimsel Sinir

Ağı (Convolutional Neural Network, ESA-CNN) mimarisi ile eğitilen Xception, VGG16, InceptionV3 ve ResNet50 derin sinir ağı modelleriyle Yaşa Bağlı Makula Dejenerasyonu (Age Related Macular Degeneration (YBMD-AMD)) hastalığının tespit edilmesi gerçekleştirilmiştir [11]. Bir diğer çalışmada Tasmin vd., 2019 yılındaki çalışmasında OKT görüntülerini kullanarak ESA mimarisi tabanlı retinanın normal, Drusen, YBMD, Diyabetik Makula Ödemi (Diabetic Macular Edema (DMÖ-DME)) sınıflandırmasında MobileNetV2, ResNet50 ve Xception derin sinir ağı modellerinin kullanımını önermişlerdir [12]. Yenikaya, 2022 yılındaki çalışmasında YBMD hastalığının teşhisi için derin sinir ağı modellerinden ResNet50, AlexNet, GoogLeNet, Xception kullanmıştır [13].

Çalışmamızda farklı yaş gruplarına ait OKT görüntüleri kullanılarak elde ettiğimiz sonuçlar ile retina hastalıklarının ESA tabanlı derin sinir ağı mimarisindeki ResNet50 ve MobileNetV2 modelleri kullanılarak sınıflandırılmasına dair deneysel çalışmalar yapılmıştır. Makalenin organizasyonu şu şekilde düzenlenmiştir. Bölüm 2'de OKT kullanılarak retina hastalıkları hakkında bilgi verilmektedir. Bölüm 3'de retina hastalıklarının sınıflandırılması ve kullanılan ESA ve çalışmada kullanılan modeller açıklanmıştır. Bölüm 4'de deney sonuçlarına yer verilirken, Bölüm 5'de bulgulara dayanan tartışmaya yer almaktadır.

2 Optik Koherans Tomografi ve retina hastalıkları

2.1 Optik Koherans Tomografi

OKT, yüksek çözünürlükte biyolojik dokularda ışığın evrilik özelliğini kullanarak kesitsel görüntüleme sağlayan bir yöntemdir [14]. OKT'nın tıp alanında yaygın olarak kullanılmasının sebebi gözlemlenen yapıya zarar vermemesidir. Huang vd. [15] çalışmasında OKT teknolojisinin altyapısı detaylarıyla ilk kez literatürde yayınlanmıştır. OKT yoluyla retinaya gelen kızılötesi ışığın farklı optik özelliklere sahip dokularındaki yansımalarının değerlendirilmesidir. Bu değerlendirmelerin sonucunda ilgili retina hastalıkları için tedavi rehberliği sağlamaktadır [16]. Kermany vd. [17] çalışmasında kullanılan örnek bir OKT görüntüsü Şekil 1'de görülmektedir.



Şekil 1. Örnek OKT görüntüsü [17]

2.2 Retina hastalıkları

Retina, göz küresinin arka iç duvarında bulunan, ışığa duyarlı sinirlerden oluşan, sinirler aracılığıyla beyne görüntünün iletilmesini sağlayan duysal zardır. Retina renkli ve renksiz görüntülerin algılandığı bölgedir [18]. Retina hastalıkları çalışmamızda üç farklı sınıf için değerlendirilmiştir. Bunlar; Drusen, Yaşa Bağlı Makula Dejenerasyonu (Age Related Macular Degeneration (YBMD-AMD)), Diyabetik Makula Ödemi (Diabetic Macular Edema (DMÖ-DME)) ve Miyopik Koroidal Neovaskülarizasyon (Myopic Choroidal Neovascularization (MKV-CNV)) olarak bilinmektedir [18-23]. Bu bölümde bu hastalık tipleri incelenmektedir.

2.2.1 Drusen

Drusen, retina pigment epiteli altında biriken ve merkezi görme bozukluğuna yol açabilen sarımsı birikintilerdir [19]. Drusen çeşitleri yaşın ilerlemesi ile normal bir sonuç olarak kabul edilmektedir. Bazı Drusen çeşitleri erken yaşlarda da görülebilmektedir. Retina Drusen'inin iki çeşidi vardır. Sert (Hard) ve Yumuşak (Soft) Drusen [19]. Sert Drusen'de birikimler küçük ve birbirinden uzak haldeyken, Yumuşak Drusen'de büyük ve küme oluşturma eğilimindedir.

2.2.2 Yaşa bağlı Makula Dejenerasyonu

Sarı nokta hastalığı olarak da bilinen YBMD, retinanın üzerinde yer alan görme işlemi yerine getiren merkezde makula (sarı nokta) bölgesinde, lutein ve zeoksantin sarı renkli pigmentlerinden kaynaklanmaktadır [18, 20, 23]. Bu hastalığın belirtileri arasında, renkleri tam net görememe, karanlıktan aydınlığa geçtikten sonraki görme zorlukları, okurken harflerin kaybolması ve ışık ihtiyacının artması bazı örneklerdir. Wong vd. yaptığı çalışmada [20] tüm dünyada 2040 yılında YBMD sahip hastaların sayısının 288 milyona ulaşacağı tahmin edilmektedir.

2.2.3 Diyabetik Makula Ödemi

DMÖ, diyabet hastalarında en sık görülen göz rahatsızlığı olup görme azlığına neden olan ödemdir [21]. Bulanık görme ve merkezi görmeye azalma DMÖ'nun belirtileridir.

2.2.4 Miyopik Koroidal Neovaskülarizasyon

Görme kaybına sebep olan MKV, gözün arkasında bulunan kan damarlarının düzgün büyümemesi sonucu oluşan hastalıktır. Düzgün büyüemeyen yeni kan damarları zamanla patlayarak retina içerisine kan veya sıvı sızdırırlar. Bu olay sonucunda hastada görmeye bozulmalar meydana gelmektedir [22].

3 Materyal ve metod

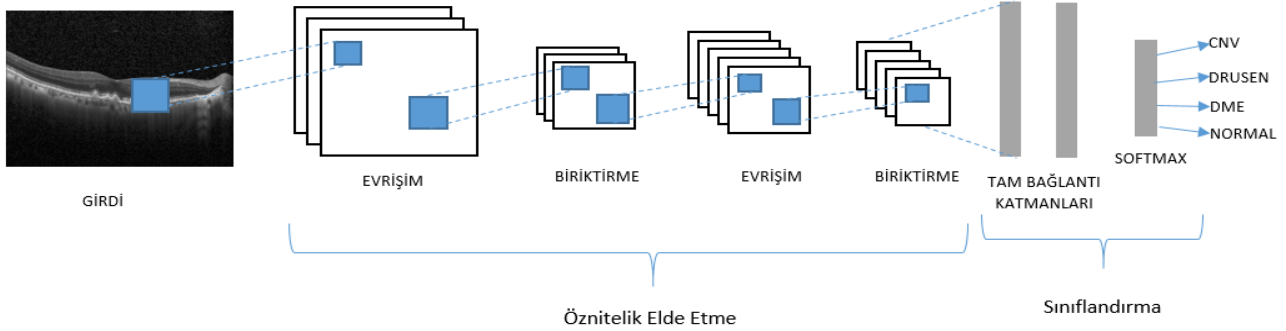
Literatürde gerçekleşen çalışmaların incelenmesi sonucu anlaşıldığı üzere retina hastalıklarının sınıflandırılması için derin öğrenme tekniklerinin kullanıldığı gözlemlenmektedir. Bu yöntemlerden ESA mimarileri, görüntüleri sınıflandırma, nesne tanıma ve tanıma işleminden sonra nesne tespit etme yöntemleri için sıklıkla kullanılmaktadır [24, 25]. Sınıflamada yüksek doğruluk oranları ile dikkat çeken yöntemlerdir [26]. Çalışmalarda tercih edilen görüntü sınıflandırma yöntemleri, genellikle veri kümesindeki bir girdi görüntüsünün alınmasıyla işleme başlanılan ve bu yolla çeşitli görünüm veya görüntüdeki nesnelerin birbirinden

ayırarak bir sınıflandırıcı altyapısının oluşturulmasına imkan sunan derin öğrenme yöntemine dayanmaktadır.

3.1 Evrışimsel sinir ağı

Bilgisayarlı görü ve görüntü işleme alanlarında daha çok görüntü içeren verilerin sınıflandırması başta olmak üzere birçok alanda kullanılan ESA, Yapay Sinir Ağı (Artificial Neural Network, YSA-ANN) tabanlı bir yöntemdir. ESA klasik sinir ağlarından farkı evrışim işlemleri, otomatik öznitelik elde etme ve çeşitli soyutlama işlemleri yapan katmanlardan öznitelik elde etme ve katmanlarından oluşmaktadır [27].

ESA temel olarak, verilen ham görüntünün hangi sınıfa ait olabileceğini yüksek doğruluk oranında tespit edilebilmesini sağlamaktadır [28]. Örnek olarak insanın soyutlama yeteneği sayesinde, bir görüntüye baktığımız zaman o görüntüye ait temel özellikleri (öznitelik) ortaya çıkarıp ve hangi nesneye ait olduğunu sınıflandırırız [29]. Şekil 2'de görüldüğü gibi ESA girdi olarak verilen ham görüntüyü parçalara ayırıp, ayrılan her parçaya filtre uygulama işlemi yaparak bu parçalar arasında ilişki kurup tanıma işlemi yapmaktadır [27].



Şekil 2. ESA mimarisi

Evrışimsel katmanın amacı girdi olarak verilen bir görüntüden öznitelik elde etmedir. Evrışim katmanının dört temel katmanı vardır. Bunlar sırasıyla; Evrışim katmanı (Convolution layer), Biriktirme katmanı (Pooling Layer), İletim sönümü katmanı (Dropout Layer) ve Düzleştirme katmanı (Flatten Layer) olarak verilmektedir.

3.1.1 Evrışim

Evrışim (Convolution), girdi ve filtre matrisleri arasındaki matematiksel bir işlemidir. Aynı

zamanda çıktısı da bir matristir [30]. Örneğin girdi matrisinin boyutu 5×5 , filtre matrisinin boyutu 3×3 olsun. 3×3 boyutlu filtre matrisinin 5×5 boyutlu girdi matrisinde oluşturabileceği çıktı matrisi biçiminde maksimum pozisyon sayısı 3×3 'tür. Evrışim işlemi uygulanan $n \times n$ boyutlarındaki görüntü ile $f \times f$ boyutlarındaki filtrenin, çıktı matrisinin boyutu Denklem (1) ile hesaplanır.

$$\text{Çıktı matrisi} = (n-f+1) \times (n-f+1) \quad (1)$$

Denklem (1)' de sırasıyla n girdi matrisinin boyutu, f ise filtre matrisinin boyutunu ifade etmektedir.

3.1.2 Piksel ekleme

Girdi matrisine eklenen piksel miktarı olan piksel ekleme (padding), evrişim işleminden sonra girdi ve çıktı matrisleri arasındaki boyut farkının kontrol edilmesini sağlar. Piksel eklenmesi görüntünün daha doğru analiz edilmesine olanak tanır [31, 32]. Verilen 6×6 boyutlu girdi matrisine 3×3 lük filtre matrisi uygulanmak isteniyor olsun. Uygulanan filtreleme işleminde kenarlarda veya köşelerde bulunan piksellerin çıktı matrisi üzerinde ki etkisi orta alanlarda bulunan piksellere göre azdır. Kenar ve köşede bulunan piksellerin bilgileri çıktı matrisinde az kullanılmaktadır. Bu durumda piksel ekleme uygulanarak çıktı matrisinin boyutu değiştirilir [31, 32].

3.1.3 Kaydırma adımı

Literatürde çekirdek (kernel) matrisinin kaç adımda taşınacağını belirten kaydırma adımı (stride) girdi matrisi üzerine uygulanır [31]. Örneğin kaydırma adımı sayısının 1 olması durumunda filtreler 1 piksel ile taşınmaktadır. Kaydırma adım sayısını ne kadar az ise çıktı o kadar büyük olur.

3.1.4 Biriktirme

Biriktirme (Pooling), görüntüler çok büyük olduğu zaman parametre sayısını azaltarak görüntüyü küçültme işlemi yapan ESA'nın yapı taşlarından biridir. Maksimum ve ortalama biriktirme olmak üzere iki yöntemi bulunmaktadır [31, 33].

3.1.5 İletim sönümü

Eğitimi uzun süren karmaşık yapıdaki ağlarda aşırı öğrenmenin önüne geçebilmek için sınıflandırma katmanlarından önce iletim sönümü (dropout) katmanı kullanılır. Bu katman aşırı öğrenmeyi engellemek için bazı sinir düğümlerinin eğitiminin ilgili adımları esnasında unutulmasını sağlamaktadır [33].

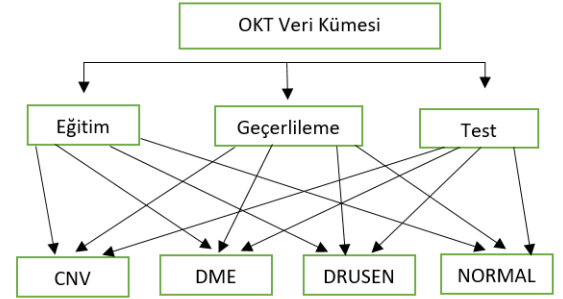
3.1.6 Düzleştirme

Düzleştirme (Flattening) katmanı, evrişimli veya havuzlama katmanlarındaki işlemlerden sonra elde edilen verinin tam bağlantı katmanında kullanılabilmesi için veriyi düzenleme işlemini yerine getirmesidir [34].

4 Bulgular ve sonuçlar

4.1 Veri kümesi

Makalemizde gerçekleştirilen çalışmada kullanılan OKT verileri, halkın kullanımına açık, California San Diego üniversitesi, California Retinal Araştırma Vakfı, Shanghai First People's Hastanesi ve Beijing Tongren Göz Merkezi'nde 1 Temmuz 2013 ve 1 Mart 2017 tarihleri arasında yetişkin hastalardan alınan verileridir (Kermany vd. [17, 35]). Veri kümesi eğitim, test ve geçerlileme olmak üzere 3 klasöre ayrılmıştır. 84.495 görüntüden oluşan veri kümesi her klasörün altında Normal, DME, DRUSEN, CNV olmak üzere dört kategoriye ayrılmıştır [35, 36]. Şekil 3'te veri kümesinin dizin yapısı gösterilmiştir.



Şekil 3. Veri Kümesi Dizin Yapısı

4.2 Önceden Eğitilmiş Derin Sinir Ağı Modelleri

4.2.1 ResNet50

ResNet50, 2015 yılında He vd. tarafından önerilmiştir. ResNet50, Artık değerli sinirsel ağların (Residual Neural Network) kanlamına gelen ESA modelidir [37]. Çalışmamızda kullanılan model olarak 50 katmandan oluşan mimarinin giriş katmanı $224 \times 224 \times 3$ boyutundadır.

4.2.2 MobileNetV2


MobileNetV1, 2017 yılında Google tarafından önerilmiştir. Bellek isterleri az olan model mobil veya gömülü cihazlarda kullanılmak için geliştirilen derinlemesine ayrılabilir verimli sinir ağıdır [38]. MobileNetV2, MobileNetV1'e tersine çevrilmiş artık yapılar ve darboğazlar getirilerek geliştirilmesi sonucu oluşan versiyondur. Daha fazla öznetelik elde etmede bu kanalı 1×1 biçimindeki evrişim işlemi sayesinde genişleten tersine çevrilmiş artıklar, öznetelik elde etme için ise 3×3 derinlemesine evrişim kullanırlar. Kanal numarasını geri sıkıştırmak için ise 1×1 noktadan noktaya evrişim kullanırlar. Aktivasyon fonksiyonu tersine çevrilmiş artık yapılarda, öğrenmeyi

hızlandırdığı gibi modelin kararlılığını da artırmaktadır [39, 40]. Çalışmamızda kullanılan model olarak 53 katmandan oluşan mimarinin giriş katmanı $224 \times 224 \times 3$ boyutundadır.

4.3 Deneysel sonuçlar

Uygulamada, derin sinir ağı modellerinin kullanımıyla transfer öğrenme [17] ve ince ayarlamaların yapılması önceliklendirilmiştir. Bu nedenle, derin öğrenme altyapısının oluşturulabilmesi için Python [41] programlama dili ile kodlama yapılmıştır. Uygulamadaki işlemleri destekleyen veri bilimi platformu olan Anaconda [42] kullanılmıştır. Deneylerde kullanılan kaynak kodların yazılması PyCharm [43] ve Jupyter [44] geliştirme ortamında gerçekleştirilmiştir. Çalışmamızda derin öğrenme tabanlı model geliştirmede Tensorflow [45] derin öğrenme kütüphanesi arka uç (backend) olarak kullanılırken, Uygulama Programlama Arayüzü (Application Programming Interface, API) Keras [46] ön uç (front end) olarak kullanılmıştır.

Çalışmamızda ResNet50 ve MobileNetV2 modellerini eğitmek için veri kümemizin %75'i eğitim, %10'nu geçerleme ve %15'i test olmak üzere ayrıştırılmıştır. Şekil 4'te kullanmış olduğumuz veriler, halkın kullanımına açık, Kermany vd. [35] tarafından yetişkin hastalardan 2013 ilâ 2017 yılları arasında alınan verilerle oluşturulan ayrıştırılmış eğitim, test ve geçerleme altında yer alan OKT tomografi etiketli sınıfların görüntüleridir. OKT görüntüleri farklı boyutlar da olduğundan dolayı ResNet50 ve MobileNetV2 için 224×224 piksel çözünürlüğünde olarak yeniden boyutlandırılmıştır.




Şekil 4. OKT Görüntüleri [35]

4.3.1 Veri artırma

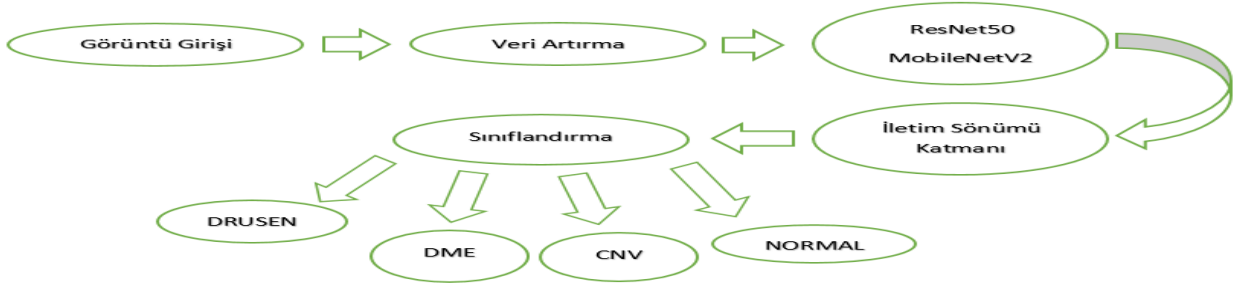
Büyük veri kümeleri ile ESA mimarileri daha iyi performans gösterirler. Bu nedenle derin sinir ağı modellerinde performansı artırmak için yeni verilerin eklenmesi yerine eldeki mevcut

verilerden artırma işlemleri gerçekleştirilir [26]. Veri artırma işlemleri veri kümesinin örneklerini artıran olumlu sonuçlar veren işlemlerdir. Aynı zamanda veri artırma, veri dağılımını dengeler ve aşırı öğrenmeyi (overfitting) azaltır [47]. Veri artırmadaki amaç, eldeki verilere belirli deformasyon işlemleri uygulayarak ek eğitim verilerinin oluşturulmasıdır [48]. Temel olarak alınan görüntüye, gürültü ekleme, farklı açılar ile döndürme işlemi uygulama, görüntüyü eğme, bükme gibi birçok veri artırma işlemi vardır. Şekil 5'te görüleceği gibi veri kümesinden Kermany vd. [35] çalışmasından alınan CNV retina hastalığına ait veri artırma işlemi yer almaktadır.



Şekil 5. Veri Artırma İşlemi [35]

Özellikle çalışmamızda, deneylerin tümünün donanım açısından güçlü bir sistem üzerinde yapılması açısından, Intel (R) Core(TM) i7- 6700 modeliyle belirtilen 2,6 GHz hızında işlemcili, Intel (R) HD Graphics 530 modelinde ekran kartı içeren, 16 GB RAM bellekli donanım mimarisine sahip bilgisayarda gerçekleştirilmiştir. Şekil 6'da yapılan çalışmamızda oluşturulan sistemin blok diyagramı görülmektedir. Bu çalışmada ResNet50, MobileNetV2 olmak üzere iki ESA modeli kullanılmıştır. ESA mimarisi ile oluşturulan ResNet50, MobileNetV2 derin sinir ağı modellerinin katmanları Tablo 1 de gösterilmiştir. Modelin eğitiminde kullanılan fonksiyonlara ve üstün parametrelerine (hyperparameters) Tablo 2 de yer verilmiştir. Burada ADAM (Adaptive Moments Estimation) eniyileme yöntemine dair fonksiyon kullanılarak uyarlanırlar bir öğrenme oranının elde edilmesi sayesinde eğitimin başarımlı iyileştirilmektedir [46]. Eğitim işlemlerinde ise doğrultulmuş biçimli doğrusal birim (Rectified Linear Unit, ReLU) yanı sıra softmax aktivasyon fonksiyonu kullanılarak sınıflandırma çıktı sonucu oluşturulmuştur [46].



Şekil 6. Çalışmamızdaki Sistemin Blok Diyagramı

Tablo 1. ResNet50 ve MobileNetV2 modellerinin katmanları.

Model	Katmanlar	Çıktı Boyutu	Parametre
MobileNetV2 ve ResNet50	-	-	-
	Evrişim	(224,224,32)	896
	Biriktirme	(112,112,32)	-
	Evrişim	(112,112,32)	9248
	Biriktirme	(56,56,32)	-
	Evrişim	(56,56,64)	18496
	Biriktirme	(28,28,64)	-
	İletim Sönümü	(28,28,64)	-
	Düzleştirme	(50176)	-
	Tam Bağlantı	(128)	-
	Çıktı	(4)	-

Tablo 2. Modelin üstün parametreleri.

Model	Öğrenme Oranı	Eniyileme Fonksiyonu	Aktivasyon Fonksiyonu
ResNet50	0,001	ADAM	ReLU - Softmax
MobileNetV2	0,001	ADAM	ReLU - Softmax

Çalışmamızda kullandığımız modelleri değerlendirmek için nesnel performans ölçütleri kullanılmaktadır. Doğruluk, toplam doğru yaptığımız tahmin sayısının, doğru yaptığımız tahminlerin sayısına oranıdır. Doğruluk, bir durumun sonucunu doğru bir şekilde tahmin etmedir [49]. Doğruluk ölçütü Denklem (2) ile hesaplanmaktadır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+FN+TN} * 100 \quad (2)$$

Denklem (2)'de bulunan, TP doğru pozitif, TN doğru negatif, FP yanlış pozitif ve FN yanlış negatif ifade etmektedir. Doğruluk ölçütü literatürdeki bazı çalışmalarda 100 ile genişletilerek yüzdelik oran olarak da verilmektedir. Çalışmamızda buna

uygun olması adına hem ondalık sayı hem de yüzdelik oran olarak deneysel sonuçlarda ifade edilmiştir. Duyarlılık ölçütü, bir sınıflandırma deneyinde, etiketleri pozitif olarak tahmin etmemiz gerekirken ne kadarını pozitif olarak tahminleyebildiğimizi göstermektedir [49]. Duyarlılık ölçütü Denklem (3) ile formüle edilmiştir.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3)$$

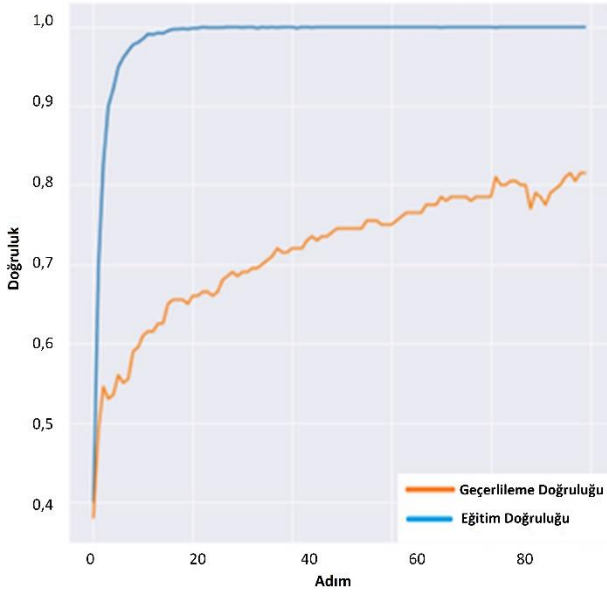
Kesinlik, pozitif olarak değerlendirdiğimiz tahminlerin gerçekten pozitif olduğunu gösteren olasılıktır [49]. Kesinlik ölçütü Denklem (4) ile hesaplanmaktadır.

$$Kesinlik = \frac{TP}{TP+FP} \quad (4)$$

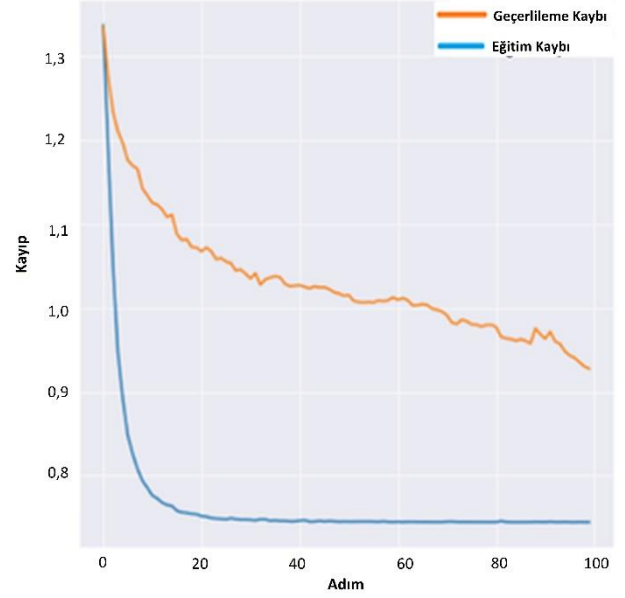
F1 Skoru, kesinlik (precision) ve duyarlılığın (recall) harmonik ortalamasıdır. Yanlış pozitifler ve yanlış negatifler sürecin bir parçasıdır [49]. F1 skoru Denklem (5) ile hesaplanmaktadır.

$$F1 = 2 * \frac{kesinlik * duyarlılık}{kesinlik + duyarlılık} \quad (5)$$

Şekil 7 ila Şekil 10'a kadar olan şekiller ESA mimarisi ile oluşturulan iki farklı modelin kayıp fonksiyonu ve doğruluk grafiklerine yer verilmiştir. Modellerin, model kayıp grafiği dikkate alındığında ilk eğitimlerde yüksek oranda çıkan kayıp fonksiyonu değerinin modellerin öğrenme adımlarında sona yaklaşırken 0,8 değerine yaklaştığı görülmektedir. Model doğruluk ölçütü değerlerine dair grafikler incelendiğinde en iyi yöntemin ResNet50 olduğu görülmektedir.

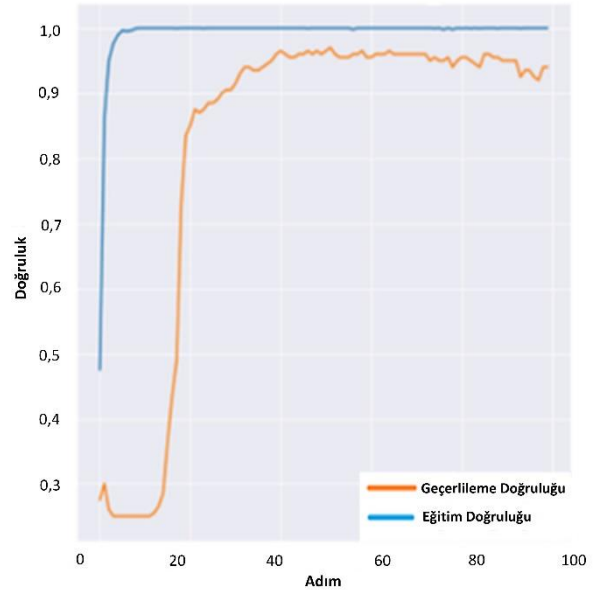


Şekil 7. MobileNetV2 eğitim ve geçerleme doğruluk grafiği

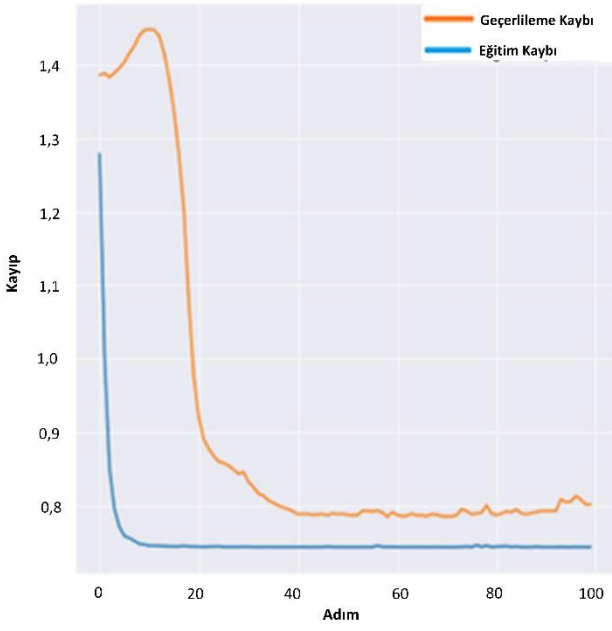


Şekil 8. MobileNetV2 Kayıp Fonksiyonu Grafiği

İlk eğitimlerinde düşük olan doğruluk oranının son eğitimlerde 0,94 ile yüksek doğruluk oranına yaklaştığı görülmektedir. ResNet50, MobileNetV2 modellerinin testler sonucunda performanslarının karşılaştırılması Tablo 3'te gösterilmiştir. Bu tabloda doğruluk değerleri makro ortalaması yüzdelik oran olarak verilmiştir.



Şekil 9. ResNet50 eğitim ve geçerleme doğruluk grafiği



Şekil 10. ResNet50 kayıp fonksiyonu grafiği

Literatürdeki benzer çalışmalara bakıldığında (deneysel sonuçlar yüzdelik oran olarak verilecek olursa), Güldemir vd. tarafından 2021 yılındaki yapılan çalışmada OKT veri kümesi üzerinden derin sinir ağı modellerinin test edilmesi sonucunda ResNet50 modeliyle %95, VGG16 modeli ile %95, InceptionV3 modeliyle %97 ve Xception modeliyle %98 doğruluk ölçütü oranıyla sınıflandırma yapılmıştır [11]. Tasmin vd. tarafından 2019 yılında yapılan çalışmada OKT görüntüleri kullanılarak MobileNetV2 modeliyle %99,17, ResNet50 modeliyle %97 ve Xception modeliyle de %99,07 doğruluk ölçütü oranları elde edilmiştir [12]. Yenikaya'nın 2022 yılındaki çalışmasında deneylerde kullanılan veri kümesindeki OKT görüntülerini ResNet50 modeli %93,80, AlexNet modeli %92,17, GoogLeNet modeli %91,67 ve Xception modeli %91,53 doğruluk ölçütü oranında başarıyla sınıflandırabilmiştir [13]. Bu sonuçlar dikkate alındığında çalışmamızın yeterince başarılı sonuçlar ürettiği anlaşılmaktadır.

Tablo 3. ResNet50 ve MobileNetV2 modellerinin yapılan test sonucunda Kesinlik, Duyarlılık ve F1 skorlarının karşılaştırılması.

Model	Kategori	Kesinlik	Duyarlılık	F1 Skoru	Makro Ortalama Doğruluk (%)
ResNet50	CNV	0,88	0,90	0,89	%94
	DRUSEN	0,92	0,94	0,93	
	DME	0,96	0,92	0,94	
	NORMAL	1,00	1,00	1,00	
MobileNetV2	CNV	0,96	0,46	0,62	%81
	DRUSEN	0,67	0,96	0,79	
	DME	0,91	0,84	0,87	
	NORMAL	0,86	1,00	0,93	

5 Sonuç

Bu çalışmada ESA ağlarıyla oluşturulan ResNet50 ve MobileNetV2 modelleri kullanılarak retina hastalıklarının sınıflandırılması yapılmıştır. Modellerin performansları doğruluk, duyarlılık, kesinlik ve F1 skoru ölçütleri ile nesnel olarak değerlendirilmiştir. Ortalama F1 skoru; CNV için 0,75, Drusen için 0,86, DME için 0,90 ve normal yapıdaki retinalar için ise 0,96 olarak elde edilmiştir. Çalışmamızda, iki farklı derin sinir ağı modeli ile yapılan deneylerde, çeşitli hastalıkların doğru sınıflandırılmasında derin öğrenmenin sunduğu temsili öğrenme ile öznetelikleri öğrenme ve içerikten elde edilen anlamsal zenginliği artıran

temel altyapısı sayesinde, oldukça yüksek bir başarı oranında sonuç elde edilmesini sağlamıştır.

İleriki çalışmalarımızda, farklı derin sinir ağı modelleri ile çeşitli büyüklüklerdeki veri kümeleri üzerinden farklı kombinasyonlardaki model yapılarının denenmesi yoluyla hastalık çeşidi artırılarak tanılama başarımının daha da iyileştirilmesi hedeflenmektedir.

Teşekkür

Çalışmamızda kullanılan halka açık veri kümelerinin sahiplerine teşekkür ederiz.

Kaynaklar

- [1] Vatansever B., Aydın H., Çetinkaya A. "Heart Disease Prediction with Machine Learning Algorithm Using Feature Selection by Genetic Algorithm". *Bilim, Teknoloji ve Mühendislik Araştırmaları Dergisi*, 2(2): 67-80. 2021.
- [2] Röntgen, W., *Sitzungsberichte der Würzburger Physik-medice*, (1895).
- [3] NEOSON web sitesi. <https://neoson.com.tr/dijital-ultrasonografi-renkli-doppler>. (15.08.2022).
- [4] Grup Florence Nightingale Hastaneleri web sitesi. <https://www.florence.com.tr/sintigrafisi>. (15.08.2022).
- [5] Kayadibi İ. "Optik Koherens Tomografisi Görüntüleri Kullanarak Evrişimsel Sinir Ağları Tabanlı Retinal Hastalık Tespiti". Yüksek Lisans Tezi. Temmuz 2021.
- [6] Ağalday M.F., Çınar A. "Derin Öğrenme Mimarilerini Kullanarak Katarakt Tespiti". *Avrupa Bilim ve Teknoloji Dergisi Özel Sayı 28*: 1428-1433, 2021.
- [7] Ziya Kapran web sitesi. <https://ziyakapran.com/optik-koherens-tomografi> (15.08.2022).
- [8] Kutlu Ö. "İnsansız Hava Aracı İle Elde Edilen Görüntülerin Derin Öğrenme Yöntemleri İle Analizi". Yüksek Lisans Tezi 2019.
- [9] Howard A.G., Zhu M., Chen B., Kalenichenko D., Wang W., Weyand T., Andreetto M., Adam H., "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv Prepr. arXiv1704.04861*, 2017.
- [10] Er M.B. "Önceden Eğitilmiş Derin Ağlar İle Göğüs Röntgeni Görüntüleri Kullanarak Pnömoni Sınıflandırılması". *Konya Mühendislik Bilimleri Dergisi*, c. 9, s. 1, 193-204, 2021 *Konya Journal of Engineering Sciences*, v. 9, n. 1, 193-204, 2021 ISSN: 2667-8055 (Elektronik). DOI: 10.36306/konjes.794505.
- [11] Güldemir N.H., Alkan A., "Derin Öğrenme ile Optik Koherens Tomografi Görüntülerinin Sınıflandırılması". *Fırat Üniversitesi Müh. Bil. Dergisi Araştırma Makalesi* 33(2), 607-615, 2021.
- [12] Tasnim N, Hasan M, Islam I, 2019, "Comparisional study of Deep Learning approaches on Retinal OCT Image", *arXiv preprint arXiv:1912.07783*.
- [13] Yenikaya M.A., "Optik Koherens Tomografi Görüntülerinden Yaşa Bağlı Makular Dejenerasyon Tiplerinin Yapay Zekâ Kullanılarak Tespiti", Doktora Tezi, İstanbul T.C. Maltepe Üniversitesi Lisansüstü Eğitim Enstitüsü Haziran, 2022.
- [14] Mumcuoğlu T., Erdurman C., Durukan A.H. "Optik Koherens Tomografi Prensipleri ve Uygulamadaki Yenilikler". *T. Oft. Gaz.* 38, 168-175, 2008.
- [15] Huang D, Swanson EA, Lin CP, Schuman JS, Stinson WG, Chang W, Hee MR, Flotte T, Gregory K, Puliafito CA, et al.: Optical coherence tomography. *Science* 1991;254:1178-1181.
- [16] Şengül Özdek web sitesi. <https://www.sengulozdek.com/hastalar-icin/tanisa-testler/optik-koherens-tomografi-oct/>. (15.08.2022).
- [17] Kermany DS, Goldbaum M, Cai W, Valentim CCS, Liang H, Baxter SL, McKeown A, Yang G, Wu X, Yan F, Dong J, Prasadha MK, Pei J, Ting MYL, Zhu J, Li C, Hewett S, Dong J, Ziyar I, Shi A, Zhang R, Zheng L, Hou R, Shi W, Fu X, Duan Y, Huu VAN, Wen C, Zhang ED, Zhang CL, Li O, Wang X, Singer MA, Sun X, Xu J, Tafreshi A, Lewis MA, Xia H, Zhang K. "Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning". *Cell*. 2018 Feb 22;172(5):1122-1131.e9. doi: 10.1016/j.cell.2018.02.010. PMID: 29474911.
- [18] Venividigöz web sitesi. <https://venividigoz.com/retina-hastaliklari/>. (15.08.2022).
- [19] İstanbul Retina Enstitüsü web sitesi. <https://www.istanbulretina.com/makaleler-goz-hastaliklari-drusen-cesitleri-ve-goruntulenme-yontemleri.php#:~:text=Retina%20pigment%20epiteli%20alt%C4%B1nda%20ekstrasel%C3%BCleris e%20daha%20gen%C3%A7%20ya%C5%9Flarda%20g%C3%B6r%C3%BClebilmektedir>. (15.08.2022).
- [20] Wong WL, Su X, Li X, Cheung CM, Klein R, Cheng CY, et al. Global prevalence of age-related macular degeneration and disease burden projection for 2020 and 2040: a systematic review and meta-analysis. *Lancet Glob Health*. 2014; 2(2):e106-16.
- [21] Alim S, Demir AK. "Diyabetik Maküla Ödemi Tedavisinde Serum HbA1c Düzeyinin İntravitreal Anti-VEGF Tedavisine Etkisi". *Türk Diyabet Obez* 2019(2): 79-83.
- [22] Taş S.P. "Retinal Hastalıkların Oftalmolojik Görüntüler Üzerinden Derin Öğrenme Teknikleri İle Tespit Edilmesi". Yüksek Lisans Tezi. Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü, 2021
- [23] Güven web sitesi. <https://www.guven.com.tr/saglik-rehberi/sari-nokta-goz-hastaligi-nedir>. (15.08.2022).
- [24] Gao, X., Li, W., Loomes, M., Wang, L., "A fused deep learning architecture for viewpoint classification of echocardiography", *Information Fusion*, 36: 103-113, 2017.
- [25] Ari A., Hanbay D. "Tumor detection in MR images of regional convolutional neural networks". *Journal of the Faculty of Engineering and Architecture of Gazi University* 34(3): 1395-1408, 2019.
- [26] Gao, X. W., Hui, R., Tian, Z., "Classification of CT brain images based on deep learning networks", *Computer Methods and Programs in Biomedicine*, 138, 49-56, 2017.
- [27] Fırıldak K., Talu M.F., "Evrişimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının

- İncelenmesi". Anatolian Journal of Computer Science. Anatolian Science, 4(2): 88-95, 2019.
- [28] Ayata F., Çavuş H. "Evrimsel Sinir Ağı Temelli Yüz Tanıma Yöntemleri ile Robot Resim Oluşturma Uygulaması". Fırat Üniversitesi Müh. Bil. Dergisi Araştırma Makalesi 34(1): 215-228, 2022.
- [29] Akpınar B., "Görüntü sınıflandırma için derin öğrenme ile bayesçi derin öğrenme yöntemlerinin karşılaştırılması," Yüksek lisans tezi, İstatistik, Fen Bilimleri Enstitüsü, Afyonkarahisar Üniversitesi, Afyon, Türkiye, 2019.
- [30] Datasience-enthusiast web sitesi. https://datasience-enthusiast.com/DL/Convolution_model_Step_by_Stepv2.html. (15.08.2022).
- [31] Miul web sitesi. <https://www.miul.com/not-defteri/evrimsimli-sinir-aglarina-giris>. (15.08.2022).
- [32] Towardsdatasience web sitesi. <https://towardsdatasience.com/the-most-intuitive-and-easiest-guide-for-convolutional-neural-network-3607be47480>. (15.08.2022).
- [33] Zephyrnet web sitesi. <https://zephyrnet.com/basics-of-cnn-in-deep-learning/>. (15.08.2022).
- [34] Bozkurt F., Yağanoğlu M. "Derin Evrimsel Sinir Ağları Kullanarak Akciğer X-Ray Görüntülerinden COVID19 Tespiti", Veri Bilim Dergisi, 4(2):1-8, 2021.
- [35] Kermany D., Zhang K., Goldbaum M. 2018. Large Dataset of Labeled Optical Coherence Tomography(OCT) and Chest X-Ray Images, Mendeley Data.
- [36] Kaggle web sitesi. <https://www.kaggle.com/datasets/paultimothymooney/kermany2018>. (15.08.2022).
- [37] He K, Zhang X, Ren S, Sun J. "Deep residual learning for image recognition", IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 27-30 June 2016, Las Vegas, Nevada, USA. pp. 770-778.
- [38] Sandler M., Howard A., Zhu M., Zhmoginov A., and Chen L.-C., "MobileNetV2: Inverted Residuals and Linear Bottlenecks," in proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City, UT, USA, pp. 4510-4520, 2018.
- [39] Demir F. "Derin Öğrenme Tabanlı Yaklaşımla Kötü Huylu Deri Kanserinin Dermatoskopik Görüntülerden Saptanması". Fırat Üniversitesi Mühendislik Bilimleri Dergisi 2021;33: 617-624.
- [40] Aslan M., "Derin Öğrenme Tabanlı Otomatik Beyin Tümör Tespiti". Fırat Üniversitesi Müh. Bil. Dergisi Araştırma Makalesi 34(1), 399-407, 2022.
- [41] Python programlama dili web sitesi. <https://www.python.org/>. (15.08.2022)
- [42] Anaconda web sitesi. <https://www.anaconda.com/>. (15.08.2022)
- [43] Jetbrains web sitesi. <https://www.jetbrains.com/pycharm/>(15.08.2022)
- [44] Jupyter web sitesi. <https://jupyter.org/>. (15.08.2022).
- [45] Tensorflow web sitesi. <https://www.tensorflow.org/>. (15.08.2022).
- [46] Keras web sitesi. <https://keras.io/>. (15.08.2022).
- [47] Alimovski E., Erdemir G. "Veri Artırma Tekniklerinin Derin Öğrenmeye Dayalı Yüz Tanıma Sisteminde Etkisi". İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi (2021) 3(1): 76-80.
- [48] Salamon, J., & Bello, J. P. (2017). "Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification", IEEE Signal Processing Letters, 24(3), 279-283.
- [49] Singh V, Asari VK, Rajasekaran R. A Deep Neural Network for Early Detection and Prediction of Chronic Kidney Disease. Diagnostics (Basel). 2022 ;12(1):116. doi: 10.3390/diagnostics12010116.