



Transfer Öğrenme Mimarileri Kullanılarak Bilgisayarlı Tomografi Görüntülerinden Covid-19'un Yüksek Doğrulukla Sınıflandırılması

High Accuracy Classification of Covid-19 from CT Images Using Transfer Learning Architectures

Farid Al-Areqi¹, Mehmet Zeki Konyar^{2*}

¹ Kocaeli Üniversitesi, Biyomedikal Mühendisliği Bölümü, ffuad95@gmail.com
ORCID: <https://orcid.org/0000-0001-7607-993X>

² Kocaeli Üniversitesi, Yazılım Mühendisliği Bölümü, mzeki.konyar@kocaeli.edu.tr
ORCID: <https://orcid.org/0000-0001-8914-5553>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 23 Nisan 2022
Revizyon 13 Haziran 2022
Kabul 13 Temmuz 2022
Online 30 Eylül 2022

Anahtar Kelimeler:

Covid-19,
DenseNet201,
Derin öğrenme,
Transfer Öğrenme,
VGG19.

ÖZ

Covid-19 virüsü 2019 yılından beri milyonlarca kişinin ölümüne neden olmuştur. Enfekte vaka oranını mümkün oldukça düşük tutmak amacıyla, virüsü tespit etmek ve hasta kişileri teşhis etmek için, çeşitli testler kullanılmıştır. Yapay zekâ, PCR testi gibi geleneksel yöntemlerden daha iyi performans göstererek, tıbbi görüntülerde virüsü tespit etmede kullanılan yöntemlerden biri olarak etkinliğini kanıtlamıştır. Bu çalışmada, halka açık iki farklı veri seti üzerinde derin öğrenme yaklaşımı ile Covid-19 sınıflandırması yapmak üzere VGG19, ResNet50, EfficientNetB0, DenseNet201 ve Xception transfer öğrenme mimarileri kullanılmıştır. Önerilen çalışmada daha yüksek doğruluklar elde etmek için modellerin hiper parametreleri üzerinde ince ayarlar yapılmıştır. Önerilen modellerin kullanılmasıyla en iyi sınıflandırma doğrulukları, birinci veri setinde VGG19 ile %98,04 ve ikinci veri setinde ResNet50 ile %99,62 olarak elde edilmiştir. Her iki veri setinin test kümelerinde VGG19 ve DenseNet201 modelleri güncel literatür yöntemleriyle kıyaslanabilir doğruluklara erişmiştir. İkinci veri setinin sınıflandırma sonuçları, bu makalede kullanılan modellerin ortalama %99,51 ile diğer literatür yöntemlerinden daha yüksek doğruluklara ulaştığını göstermiştir.

ARTICLE INFO

Article history:

Received 23 April 2022
Received in revised form 13 June 2022
Accepted 13 July 2022
Available online 30 September 2022

Keywords:

Covid-19,
DenseNet201,
Deep Learning,
Transfer Learning,
VGG19.

ABSTRACT

The Covid-19 virus has caused the deaths of millions of people since 2019. To keep the infected cases rate as low as possible, several types of tests have been used to detect the virus and diagnose the patients. Artificial intelligence has proven its effectiveness as one of the methods used in detecting the virus in medical images, outperforming traditional methods such as PCR testing. In this study, VGG19, ResNet50, EfficientNetB0, DenseNet201 and Xception transfer learning architectures were used to classify Covid-19 with a deep learning approach on two different publicly available datasets. In the proposed study, the hyperparameters of the models were fine-tuned to obtain higher accuracies. With the use of the proposed models, the best classification accuracies were obtained with VGG19 as 98.04% in the first dataset and 99.62% with ResNet50 in the second dataset. In the test sets of both datasets, the VGG19 and DenseNet201 models achieved comparable accuracies with the state-of-the-art literature methods. The classification results of the second data set showed that the models proposed in this article achieved higher accuracy than other literature methods with an average of 99.51%.

Doi: 10.24012/dumf.1129870

* Sorumlu Yazar

Giriş

Covid-19, çok tehlikeli olan ve Dünya Sağlık Örgütü (WHO) tarafından 2020 yılında küresel pandemi ilan edilen Corona ailesi virüslerinden biridir [1]. İlk olarak Aralık 2019'da Çin'in Wuhan kentinde keşfedilmiştir. Bu hastalığın yayılması doğrudan enfekte insanlardan veya dolaylı olarak kontamine nesnelere veya yüzeylere aracılığıyla ortaya çıkabilmektedir [2]. Ateş, yorgunluk, kuru öksürük, göğüs ağrısı, nefes darlığı bu hastalığın belirtilerinden bazılarıdır. Vakaların çoğunda semptomlar enfeksiyondan birkaç gün sonra ortaya çıkmaktadır. Covid-19, diğer virüslere kıyasla alt ve üst solunum yollarını daha yüksek oranda enfekte edebilmektedir. Sosyal mesafeyi korumak, maske ve dezenfektan kullanmak insanların bu hastalıktan korunmak için izledikleri önlemlerden olmuştur [3]-[6].

Bu hastalığın toplumda yayılımını durdurmak için en önemli yol, hastalığın erken tespiti olmuştur. Bu ani salgın nedeniyle, çeşitli araştırma merkezleri onu tedavi etmek için farklı teşhis teknikleri ve aşılarda belirlemeye çalışmaktadır. RT-PCR, Trakeal aspirat, balgam testi ve Kan testinin ile Covid-19'u tespit etmek için birkaç saat veya gün gerekmektedir [7]. Ayrıca bu testler için burun salgısı örnekleri, akciğerlerden mukus, kan örnekleri gerekmektedir. Oysaki yapay zekâ yöntemleriyle bu hastaların tespiti daha hızlı ve daha kolay olmaktadır. Literatürde makine öğrenmesi ve derin öğrenme yöntemleriyle yapılan çalışmalar mevcuttur [1].

İlgili Çalışmalar

JavadiMoghaddam ve diğerleri [8], dalgacık ve dört evrişim katmanı ve ortaklama katmanında Sıkma Uyarma Bloğu (Squeeze Excitation Block) katmanından oluşan Dalgacık CNN-4 adlı bir derin öğrenme modeli önermişlerdir. Önerilen modeli VGG11, ResNet18, ResNet50 ve Inception-v3 gibi önceden eğitilmiş modellerle karşılaştırmışlardır. Önerilen model %99,03 doğruluk elde etmiştir. Balaha ve arkadaşları [9], Covid-19'u tespit etmek için önceden eğitilmiş modellere dayalı hibrit öğrenme ve optimizasyon yaklaşımı önermişlerdir. Hiperparametreleri optimize etmek için Harris Hawks Optimizasyon (HHO) algoritması kullanılmıştır. Halka açık üç veri setini birleştirerek veri artırmayı gerçekleştirmişlerdir. Modellerin kombinasyonları arasında karşılaştırma yapmak için bir değerlendirme metriği olarak Ağırlıklı Toplam Yöntemi (WSM) kullanılmış olup en iyi doğruluk VGG19 ile %99,33 olarak elde edilmiştir.

Ahamed ve arkadaşları [10], önerilen modellerini eğitmek için çalışmalarında göğüs röntgeni ve CT görüntülerinden oluşan veri setlerini kullanmışlardır. Görüntüler, önerilen ResNet50V2 modeline girmeden önce ön işleme tabi tutulmuş ve büyütülmüşlerdir. Düzenleştirme ve ince ayar süreçleriyle temel modele ekstra katmanlar eklenmiştir. Görüntüleri ön-işlemeli ve ön-işlemesiz olmak üzere iki sınıflı, üç sınıflı ve dört sınıflı kategorilere göre sınıflandırmışlardır. Model, ön-işlemeli ve ön-

işlemesiz 3 sınıf kategorisi için sırasıyla %99,01 ve %83,6 doğruluk elde etmiştir.

Bağdadi ve diğerleri [11], önceden eğitilmiş SeresNext50, SeresNext101, SeNet154, MobileNet, MobileNetV2, MobileNetV3Small ve MobileNetV3Large modellerini kullanmışlardır. En iyi konfigürasyonu bulmak için önceden eğitilmiş CNN (Convolutional Neural Network, Evrişimsel Sinir Ağı) modellerinin hiper parametrelerini bir Serçe arama algoritması ile optimize etmişlerdir. Yazarlar, ikisi iki sınıflı ve diğeri üç sınıflı olmak üzere halka açık üç veri seti kullanmışlardır. Veri setlerini ikili sınıflarda birleştirip onu ikili bir veri seti olarak kullandılar. Hem birleştirilmiş hem de üç sınıflı veri setleri, artırma teknikleri kullanılarak dengelenmiştir. Elde edilen en iyi doğruluk, MobileNetV3Large ve SeNet154 modellerinde sırasıyla iki sınıf için %99,74 ve üç sınıf için %98 olmuştur.

Zheng ve arkadaşları [12], CT görüntülerinden Covid-19 tespiti için 3-boyutlu derin evrişimli sinir ağı (DeCoVNet) kullanmayı önermişlerdir. Çalışmaya 540 hasta dahil edilmiş olup, bunların 313'ü Covid-19'lu ve 229 hasta Covid-19 değildir. Ağ, birleşik bir şekilde, basit bir 2D UNet ile önceden eğitilmiştir. Eşikleri değiştirilerek Covid-19'u tespit edilmiş ve %90,8 sınıflandırma doğruluğuna erişmişlerdir.

Xu ve arkadaşları [13], 219 Covid-19, 175 sağlıklı insan ve 224 influenza-A viral pnömonisi (IAVP) içeren 618 CT görüntüsü içeren üç sınıfın derin öğrenmeye dayalı sınıflandırılmasını önermişlerdir. Transfer öğrenme modeli ile 3-boyutlu CNN bölütleme yöntemi kullanılmışlardır. Transfer öğrenme modelleri, ResNet-18 tabanlı geleneksel sınıflandırma ve konum-dikkat temelinde yapılandırılmıştır. Bu çalışmada, Covid-19, IAVP ve sağlıklı vakaları %86,7 doğruluk oranıyla üç sınıf olarak sınıflandırılmıştır. Üç sınıfın bir başka derin öğrenme tabanlı sınıflandırmasında Song ve arkadaşlarının çalışmasında [14], Covid-19'lu 88 hastayı, bakteri pnömonisi ile enfekte 100 hastayı ve sağlıklı 86 kişiyi vardır. Ayrıntılı ilişki çıkarma sinir ağı adlı önceden eğitilmiş ResNet50 modeli tabanlı bir derin öğrenme modeli kullandılar ve üç sınıflı sınıflandırma için %93 doğruluk oranı elde ettiler.

Wang ve arkadaşları [15], Covid-19 hastalarını sınıflandırmak için GoogleNet başlangıç ağı modeli adlı önceden eğitilmiş bir modelle kullanılmış transfer öğrenme içeren bir CNN modeli kullanmışlardır. 325 Covid-19 pozitif ve 740 Covid-19 negatif hasta için sınıflandırma doğrulukları %89,5'tir. Alsharman ve diğerleri [16], GoogleNet tabanlı CNN sınıflandırıcı adlı önceden eğitilmiş bir model kullanmış ve %82,14 doğruluk oranı elde etmişlerdir. Çalışmaları 463 Covid-19 olmayan görüntü ve 349 Covid-19 CT görüntüsü içermektedir. Neha ve diğerleri [17], CNN tabanlı bir model ve lojistik regresyon tabanlı bir model önermişlerdir. İki farklı veri seti kullandıkları CNN modeliyle, %99,10 doğruluğa erişmişlerdir.

Bu makalede önerilen çalışmamızda transfer öğrenme temelli derin öğrenme yöntemleri olan VGG19,

ResNet50, EfficientNetB0, DenseNet201 ve Xception ile Covid-19 tespiti yapılması amaçlanmıştır. Önerilen çalışmada iki farklı veri seti üzerinde sınıflandırma etkileri incelenmiş olup, çalışmanın ana katkıları; önceden eğitilmiş transfer öğrenmesi modellerine yeni katmanlar eklenerek iki ortak CT Covid-19 veri setinin değerlendirilmesi, en güncel yöntemlerle kıyaslanabilir bir performans elde edilmesi, önerilen modelin katmanlarının ve parametrelerinin iki farklı veri seti ile iyileştirilmesiyle yüksek doğruluklara erişilmesi olarak özetlenebilir.


Bu makalenin geriye kalan kısmı şu şekilde düzenlenmiştir: Malzeme ve Yöntem kısmında, veri setleri, derin öğrenme, transfer öğrenmesi, sınıflandırma için önerilen yöntemin mimarisi verilmiştir. Bulgular ve Tartışma kısmında, önerilen yaklaşımların veri setleri üzerindeki başarımları değerlendirilmiştir.

Malzeme ve Yöntem

Bu bölüm, bu makalede kullanılan veri setleri, derin CNN modelinin ayrıntıları, önceden eğitilmiş CNN modelleri olan VGG19, ResNet50, EfficientNetB0, DenseNet201 ve Xception ve önerilen sınıflandırma yaklaşımının detayları anlatılacaktır.

Veri seti

Bu çalışmada için halka açık iki veri seti kullanılmıştır. İlk veri setinin (Large COVID-19 CT scan slice dataset) [18] 466 hastadan 7.593 Covid-19 görüntüsü, 604 hastadan 6.893 normal görüntü ve 60 hastadan 2.618 Toplum kökenli pnömoni (CAP) görüntüsü içermektedir. İkinci veri seti (CT Scans for COVID-19 Classification) [19] üç sınıftan oluşmaktadır.



Şekil 1. Veri setlerinden görüntü örnekleri. (a) [18]'deki Veri seti, Normal (üstte), CAP (ortada) Covid-19 (altta) (b) [19]'deki Veri seti, Negatif (üstte), NiCT (ortada) Pozitif (altta)

Bu veri setinin, iki versiyonu vardır, orijinal versiyon ve ön işlemden geçirilmiş versiyon. Ön-ışlemeli versiyon, CT görüntülerinden akciğer parankiminin çıkarılmasıyla oluşturulmuştur. Birinci sınıf 9979 negatif CT (nCT) görüntüsü, ikinci sınıf, 4001 pozitif CT (pCT) görüntüsü, üçüncü sınıf, akciğer parankimi olmayan 5705 bilgilendirici olmayan CT (NiCT) görüntüsü içermektedir. Her iki veri setindeki üç sınıf için bazı görüntü örnekleri Şekil 1'de gösterilmektedir. Bu veri setleri hakkında daha fazla ayrıntı [18] ve [19]'daki kaynaklardan incelenebilir. Önerilen model

metodolojisi, derin transfer öğrenme mimarisine dayanmaktadır. Araştırmacılar son zamanlarda çeşitli bilgisayar görme problemlerini ele almak için transfer öğrenme tabanlı CNN modellerini kullanmakla ilgilenmeye başlamışlardır. Son yıllarda, bu modeller tıbbi hastalık teşhisinde [20], endüstride ve tarımda [21],[22] yaygın olarak kullanılmışlardır.

Evrişimsel sinir ağı

Evrişimsel Sinir Ağı (Convolutional Neural Network, CNN) [23], tıbbi araştırmalarda kullanılan en verimli ve başarılı derin öğrenme modellerinden biridir. Görüntülerdeki kalıpları analiz etmek için kullanılır. CNN modelinde girdi, evrişimsel katmanlar adı verilen bazı gizli katmanlardan geçirilen görüntülerdir. CNN katmanlarının sonucunda, eğitim verilerine dayanarak verilen girdi görüntüsünü sınıflandıran veya etiketleyen çıktılar alınmaktadır. CNN'nin dört temel katmanı vardır: Evrişim katmanı, aktivasyon katmanı, ortaklama katmanı ve tam bağlı katman.

Evrişim katmanı

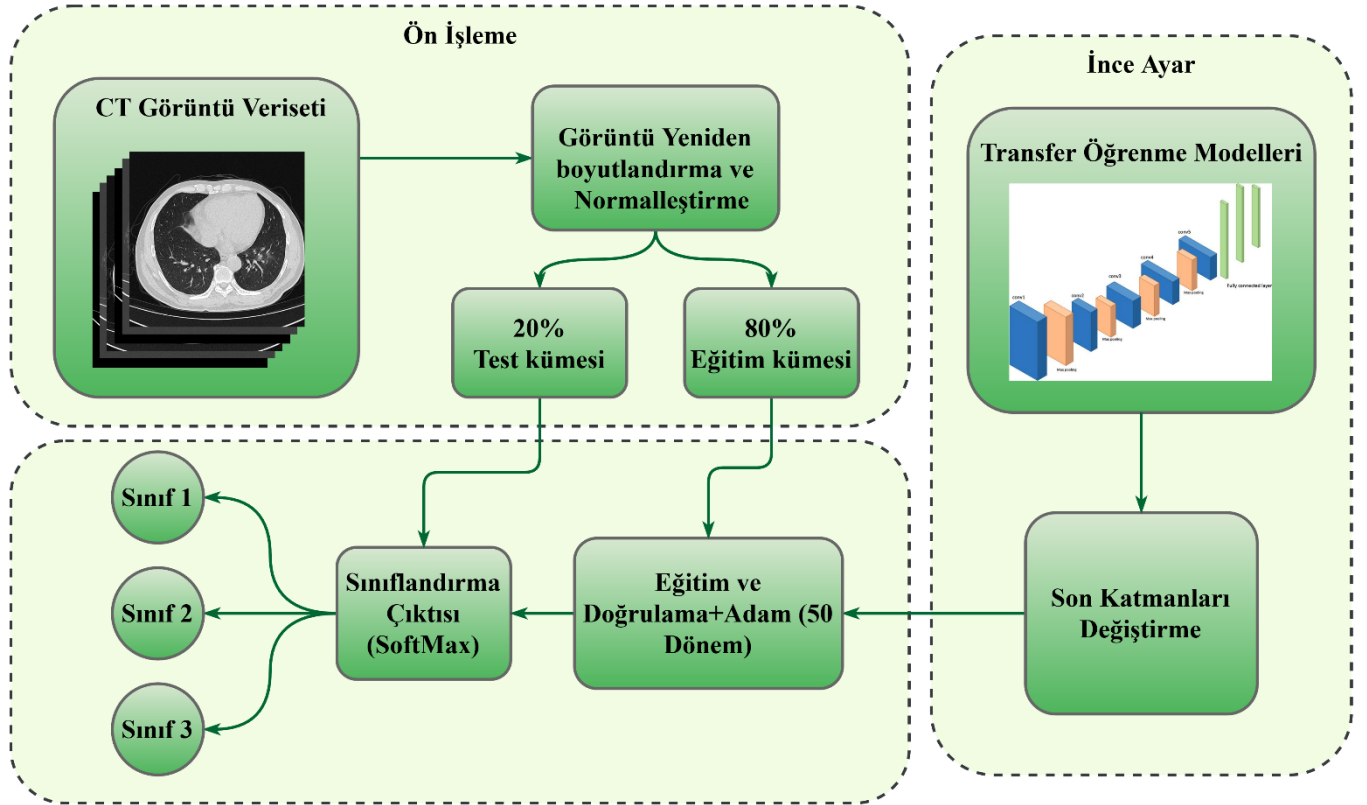
Evrişim katmanı, bir CNN'nin ana yapı taşıdır. Temel matris çarpması yerine, a^* ile gösterilen bir evrişim işlemi gerçekleştirir. Parametreleri, genellikle çekirdekler olarak bilinen bir dizi öğrenilebilir filtre kullanılarak oluşturulur. Bu katmanın amacı, girdi görüntülerinin yerel bölgelerindeki öznitelikleri bulmak ve girdi verilerinde gözlenen özniteliklerin varlığını azaltan bir öznitelik haritası üretmektir. Temel evrişim işlemi Denklem (1)'e göre yazılabilir:

$$F(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n)K(m, n) \quad (1)$$

Burada I bir girdi görüntü matrisini ifade eder, m ve n görüntünün satır sütun boyutlarını temsil eder ve K bir 2-boyutlu filtre/çekirdeği temsil eder. 2-boyutlu karakteristik haritasının sonucu F 'dir. F , I girişinin K ile evrilmesiyle üretilir. Bu nedenle, $I * K$ evrişim eylemini belirtir. $*$ ayrı bir evrişim sürecini gösterir. Matris K , adım parametresini hesaba katarak giriş matrisini tarar. Ayrıca, doğrusal olmayanlığın oluşturulması için, evrişimin her katmanının sonuçları, aktivasyon işlevi adı verilen bir işlev kullanılarak derlenir [24].

Aktivasyon katmanı

Derin öğrenme alanında en iyi bilinen aktivasyon katmanlarından biri olan ReLU (rectified linear unit, düzeltilmiş doğrusal birim) ile, çeşitli türlerde aktivasyon işlevleri yaygın olarak kullanılmaktadır. ReLU aktivasyon işlevi genellikle girişin sıfıra normalleştirilmesiyle hesaplanır.



Şekil 2. Önerilen sınıflandırma yaklaşımının blok diyagramı

ReLU ayrıca giriş 0'dan küçükse 0 çıkışı ve giriş 0'dan büyükse ham çıkış üretir. Denklem (2), matematiksel olarak temsil etmek için kullanılabilir.

$$f(x) = \max(0, x) \quad (2)$$

Dolayısıyla, x 'in giriş değeri sıfırdan küçükse, $f(x)$ işlevi 0 döndürür; x 'in giriş değeri sıfırdan büyük veya sıfıra eşitse, $f(x)$ işlevi 1 döndürür.

Ortaklama katmanı

Ortaklama katmanları, bir CNN'deki evrişim katmanı dizilerinin önemli bir parçasıdır. Bu katmanlar, bir katmandaki nöron demetlerinin çıktılarını toplayarak ve sonraki katmanda bunları tek bir nörona dönüştürerek girdi verilerinin uzamsal boyutlarını azaltır. Ortaklama katmanları, öznitelik haritasının her kanalı üzerinde 2 boyutlu bir filtrenin kaydırılmasını ve filtre kapsama alanı içindeki özelliklerin

özetlenmesini gerektirir. Maksimum ortaklama, L2-norm ortaklama, küresel ortaklama katmanları ve ortalama ortaklama, evrişimsel sinir ağlarında kullanılan ortaklama katmanlarından bazılarıdır. Diğer ortaklama teknikleri ile karşılaştırıldığında, maksimum ortaklama, giriş bölgesinde kullanılırken maksimum değeri sağlar.

Tam bağlı katman

Tam bağlı katman, önceki katmandaki tüm nöronun bir sonraki katmandaki tüm nörona bağlandığı ve ardından her bir değer her bir sınıfla yaklaşık ne kadar eşleştiğinin tahminini ilettiği CNN'nin temel bir parçasıdır. Tam bağlı katman çıktısı daha sonra çıktı sınıfı puanları sağlayan bir etkinleştirme işleviyle birleştirilir. CNN, Sigmoid, SoftMax gibi çeşitli fonksiyonları kullanır. SoftMax Denklem (3) ile, K sayıda çıktı kategorisinin olasılık dağılımını hesaplayabilir.

$$S(x_i) = \frac{e^{x_i}}{\sum_{j=1}^K e^{x_j}} \quad (3)$$

Burada girdi vektörü x_i olarak işaretlenmiştir, K sınıflandırma sınıflarının sayısını belirtirken, çıktı vektörü S olarak etiketlenmiştir, burada $i = 1, \dots, n$. Tüm çıktıların toplamı, S bire eşittir [24].

Önceden eğitilmiş CNN'ler: Transfer Öğrenme Modelleri

Son zamanlarda Covid-19 hastalığının tespit edilmesi için makine öğrenmesi ve derin öğrenme yöntemleri kullanılmaya başlanmıştır [25]. Bu çalışmada CT görüntülerindeki Covid-19'u, Covid-19 olmayanlardan ayırt etmek için önceden eğitilmiş VGG19, ResNet50, EfficientNetB0, DenseNet201 ve Xception mimarilerine dayanan modellerin kullanılması önerilmiştir. Önceden eğitilmiş ağlar, ImageNet veri tabanındaki bir milyondan fazla görüntü üzerinde eğitilmişlerdir. Önceden eğitilmiş ağlar, görüntüleri klavye, fare, kurşun kalem ve birçok hayvan gibi 1000 nesne kategorisine ayırabilmektedirler. Sonuç olarak, bu ağlar çok çeşitli görüntüleri temsil eden zengin özellikler öğrenmişlerdir. Bu çalışmada kullanılan VGG19, ResNet50, EfficientNetB0, DenseNet201 ve Xception modellerinin ana özellikleri aşağıda verilmiştir. Bu transfer öğrenme mimarileri genellikle RGB görüntülerini (224,224,3) şeklinde girdi olarak kabul ederler.

VGG19, Oxford Üniversitesi Görsel Geometri Grubu tarafından 2014 yılında önerilen evrişimli sinir ağı tabanlı bir modeldir. 16 evrişim katmanı, 5 MaxPool katmanı, 3 Tam bağlı katman ve 1 SoftMax katmanından oluşan 19 derin katmana sahiptir [26].

ResNet50, Kaiming He tarafından 2015 yılında önerilen evrişimli sinir ağı tabanlı bir modeldir. 48 evrişim katmanı, 1 MaxPool katmanı ve 1 Ortalama havuz katmanından oluşan 50 derin katmana sahiptir [27].

EfficientNet, ilk olarak 2019 yılında Tan ve Le tarafından tanıtılmıştır. Imagenet ve yaygın görüntü sınıflandırma transferi öğrenme işlerinde yüksek doğruluğa ulaşan en verimli evrişimli sinir ağı tabanlı modelleri arasında yer almaktadır [28].

DenseNet-201, ResNet modelinden etkilenen Huang ve ark. tarafından 2017'de önerilmiştir. DenseNet-201 de 7x7 evrişim filtresi ve ardından ilk katman olarak 3x3 MaxPool,

arada 3 ortalama havuz katmanı olan 196 evrişimsel katman ve 1 çıkıştan oluşan toplam 201 katmana sahiptir [29].

Xception, derinlemesine ayrılabilir kıvrımlar içermesi dışında Inception mimarisine dayanmaktadır. Bu model 36 katman derinliğindedir ve 2017'de Google, Inc.'den Francois Chollet tarafından önerilmiştir. Model, varsayılan şekliyle (299,299,3) RGB görüntüleri girdi olarak kabul eder. Ayrıca (224,224,3) şeklindeki görüntüleri de kabul edebilir. Derinlemesine ayrılabilir evrişimler, her filtre kanalını her bir giriş kanalıyla saran derinlemesine bir evrişimi ve üretilen çıkış kanallarını 1x1 filtre ile sararak birleştiren noktasal bir evrişimi birleştiren evrişimlerdir [30].

Önerilen modellerin, gradyan inişinin optimizasyonu için bir algoritma olan Uyarlamalı Moment Tahminini (Adaptive Moment Estimation, ADAM) kullanmıştır. Bu yöntem, çok sayıda veri örneği veya parametre içeren problemlerle uğraşırken oldukça etkilidir. ADAM, geleneksel stokastik gradyan inişi ile aynı değildir. Esasen ADAM, stokastik amaç fonksiyonlarının gradyan tabanlı optimizasyonu için bir algoritmadır. Kök Ortalama Kare Yayılımı (RMSProp) ve Uyarlanabilir Gradyan Algoritması (AdaGrad) olmak üzere iki gradyan inişi uzantısının avantajlarını birleştirir ve farklı parametreler için bireysel uyarlanabilir öğrenme oranlarını hesaplar. ADAM, sinir ağının her ağırlığı için öğrenme oranını uyarlamak için birinci ve ikinci gradyan anlarının tahminlerini kullanır. Anları tahmin etmek için ADAM, mevcut bir mini grupta değerlendirilen gradyan üzerinde hesaplanan üstel olarak hareketli ortalamaları kullanır:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (4)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (5)$$

m_t ve v_t gradyanların sırasıyla birinci momentinin (ortalama) ve ikinci momentinin (merkezlenmemiş varyans) tahminleri olduğunda, g mevcut mini gruptaki gradyandır ve betalar algoritmanın yeni hiper parametreleridir. m_t ve v_t , 0'ların vektörleri olarak başlatıldığından, ADAM ile, özellikle ilk zaman adımlarında ve özellikle bozunma oranları küçük olduğunda (yani, β_1 ve β_2 , 1'e yakın olduğunda) sıfıra doğru eğilimli olduklarını gözlemlenmektedir. Bu eğilimin düzeltilmesi için birinci ve ikinci an tahminleri hesaplanmaktadır:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (6)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (7)$$

ADAM son olarak, öğrenme oranı (η) ve bir ϵ sabiti kullanarak parametreleri iyileştirmek için Denklem (8)'deki ağırlık (θ) güncelleme işlemini yapmaktadır.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (8)$$

Bu makalede β_1 için 0,9, β_2 için 0,999 ve ϵ için 10^{-8} değerleri kullanılmıştır [24].

Önerilen modelin mimarisi

Bu makalede önerilen modellerin daha uygulanabilir, etkili ve sağlam hale getirilmesi için kullanılan modellerin katmanlarına ekstra katmanlar eklenerek önceden eğitilmiş transfer öğrenme temel mimarileri daha da geliştirmiştir. Şekil 2’de, önerilen modelin diyagramı gösterilmektedir. Düzleştirilmiş katman, önceki CNN katmanlarından çıkarılan özellikler alır ve bunları 1 boyutlu (tek boyutlu) bir diziye dönüştürür ve daha sonra girdi olarak sonraki yoğun katmana beslenir. Yoğun katmandaki her nöron, önceki katmanlardaki diğer tüm nöronlardan girdiler alarak onları yoğun bir şekilde birbirine bağlı hale getirir. Son olarak, önerilen modelin performansını iyileştirmek için ek katmanlarda hiper parametrelerin düzenlenmesi ve etkili ince ayarı yapılmıştır. Önerilen modelde kullanılan hiper parametreler Tablo 1’de listelenmiştir. Ayrıca model, görüntüleri üç sınıflı bir kategoride sınıflandırmak için aktivasyon için SoftMax fonksiyonunu kullanmaktadır. Önerilen modelde 1,656,195 eğitilebilir ve 20,074,688 eğitilemez olmak üzere toplam 21,730,883 parametre vardır.

Tablo 1. Önerilen modelde kullanılan hiper parametreler.

Hiper parametreler	Değer/türü
Giriş boyutu	224x224
Ağırlıklar	ImageNet ağırlıkları
Optimize Edici	ADAM
Batch boyutu	64
Öğrenme oranı	0.001 (varsayılan)
Epochs (Eğitim turu)	50

Bulgular ve Tartışma

Bu çalışmada, CT görüntülerinden Covid-19’u sınıflandırmak için transfer öğrenme temelli mimarilerin kullanımı önerilmiştir. Önerilen yöntem iki farklı veri seti üzerinde incelenmiştir. Her iki veri setinin de üç sınıfı vardır. [18]’deki veri seti toplam 17104, [19]’daki veri seti ise toplam 19685 görüntüden oluşmaktadır. Her iki veri seti de %80 eğitim kümesi (eğitim ve doğrulama) ve %20 test kümesi olarak ayrılmıştır. Eğitim kümesindeki verilerin %80’i eğitim, %20’si ise doğrulama için ayrılmıştır.

Önerilen model, Windows 10 işletim sistemi üzerinde Intel Core i7-3820 3,60GHz CPU, Nvidia GTX 1080 Ti 11GB GPU ve 32 GB RAM içeren bir iş istasyonunda uygulanmıştır. Modelin uygulaması, TensorFlow [31] üzerinde Keras kütüphanesi [32] kullanılarak Python 3.7’de gerçekleştirilmiştir.

Performans metriklerinin değerlendirilmesi

Bu çalışmada önerilen mimarinin performansını değerlendirmek için dört metrik kullanılmıştır. Değerlendirmeler doğruluk (accuracy, Acc), duyarlılık (sensitivity, Sen), kesinlik (precision, Pre), F1-skoru olup bu metrikler için matematiksel formüller sırasıyla (9), (10), (11) ve (12)’deki denklemlerde sunulmuştur.

$$Acc = \frac{(TP + TN)}{(TP + TN + FN + FP)} \quad (9)$$

$$Pre = \frac{TP}{(TP + FP)} \quad (10)$$


$$Sen = \frac{TP}{(TP + FN)} \quad (11)$$

$$F1 - score = \frac{(2 * Pre * Sen)}{(Pre + Sen)} \quad (12)$$


Modelin veri kümeleri üzerindeki performansı

Bu bölümde, önerilen modellerimizin performans sonuçları veri setleri üzerinden değerlendirilmektedir. Şekil 3, Şekil 4 ve Şekil 5, her bir veri kümesi için 50 tur (epoch) üzerinden eğitim ve doğrulama işlemlerinin doğruluğunu ve kaybını göstermektedir. Gösterilen grafikler en yüksek doğruluğa erişen iki yöntem için olup, diğer yöntemler de benzer grafiklere sahiptir. Eğitim sürecinde kullanılan modellerin ilk 10 turda daha yüksek doğruluğa yakınsadığı ve 50 tura ulaşana kadar geliştiği grafiklerden görülmektedir.

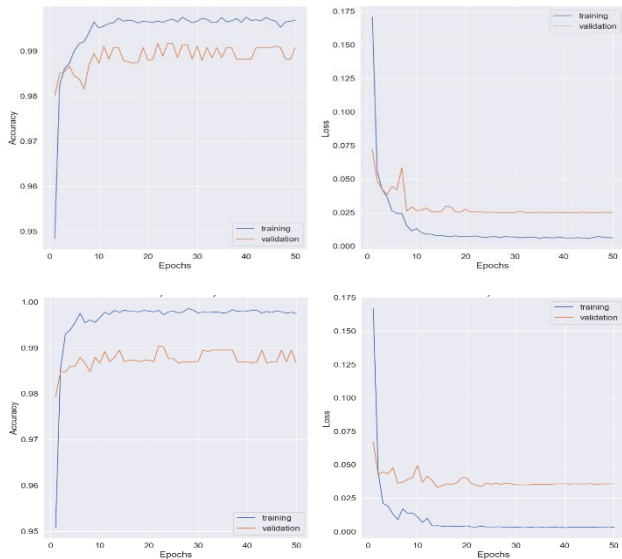
Bilgisayarlı tomografi görüntüleri içerisinde Covid-19 hastalığı olanların tespit edilip, sınıflandırılması için ilk olarak [18]’deki veri seti kullanılmıştır. Öncelikle her bir transfer öğrenme modeli bu veri seti üzerinde test edilmiş olup, elde edilen sonuçlar Tablo 2’de verilmiştir. Önerilen 5 farklı modelin ortalama doğruluğu %97,42 olmuştur. En yüksek sınıflandırma doğruluğuna %98.04 ile VGG19 erişirken, DenseNet201 modeli %98.01 ile ikinci en iyi sonuca ulaşmıştır. Xception modeli, %95,35 ile nispeten en düşük doğruluğa erişen model olmuştur. Tablo 2’deki başarımların ölçütlerinin elde edildiği karışıklık matrisleri Şekil 6’da sunulmuştur.



Şekil 3. Önerilen modelin [18]’deki veri seti için tur sayısına karşı eğitim doğruluğu ve hata grafiği VGG19 (üstte), DenseNet201 (altta).



Şekil 4. Önerilen modelin [19]'daki veri setinin orijinal versiyonu için tur sayısına karşı eğitim doğruluğu ve hata grafiği ResNet50 (üstte), EfficientNetB0 (altta).



Şekil 5. Önerilen modelin [19]'daki veri setinin ön-işlemeli versiyonu için tur sayısına karşı eğitim doğruluğu ve hata grafiği VGG19 (üstte), DenseNet201 (altta).

Tablo 2. Önerilen modellerin [18]'deki veri seti üzerindeki sonuçları (%).

Model	Acc	Pre	Sen	F1 score
VGG19	98.04	98.06	98.04	98.04
ResNet50	97.84	97.86	97.84	97.84
EfficientNetB0	97.84	97.86	97.84	97.84
DenseNet201	98.01	98.04	98.01	98.01
Xception	95.35	95.40	95.35	95.35

Normal	1363	15	1
Covid-19	45	1469	5
CAP	0	1	522
	Normal	Covid-19	CAP

VGG19

Normal	1357	22	0
Covid-19	76	1442	1
CAP	0	1	522
	Normal	Covid-19	CAP

ResNet50

Normal	1358	20	1
Covid-19	49	1469	1
CAP	2	1	520
	Normal	Covid-19	CAP

EfficientNetB0

DenseNet201

Normal	1325	52	2
Covid-19	99	1417	3
CAP	2	1	520
	Normal	Covid-19	CAP

Xception


Şekil 6. [18]'deki veri seti üzerinde yapılan testlerde elde edilen karışıklık matrisleri

Tablo 3. Önerilen modellerin [19]'daki veri setinin orijinal versiyonu üzerindeki test sonuçları.

Model	Acc	Pre	Sen	F1 score
VGG19	99.54	99.54	99.54	99.54
ResNet50	99.62	99.62	99.62	99.62
EfficientNetB0	99.57	99.57	99.57	99.57
DenseNet201	99.42	99.42	99.42	99.42
Xception	99.39	99.39	99.39	99.39

Önerilen modeller ikinci olarak, [19]'daki veri setinin orijinal versiyonu üzerindeki test edilmiş ve test sonuçları Tablo 3'te verilmiştir. Tablo 3'teki sonuçlar incelendiğinde 5 farklı transfer öğrenme modelinin ortalama %99,51 doğruluk değeriyle çok iyi bir sınıflandırma işlemi yaptığı görülmektedir. ResNet50 ve EfficientNetB0 modelleri sırasıyla %99,62 ve %99,57 ile en yüksek doğruluklara ulaşmışlardır. VGG19 modeli %99,54 ile önemli bir başarıya

ulaşırken, bir önceki veri setinde olduğu gibi bu veri setinde de en düşük doğruluk Xception modeli ile elde edilmiştir. Tablo 3'teki başarımlar ölçütlerinin elde edildiği karışıklık matrisleri Şekil 7'de sunulmuştur.



Şekil 7. [19]'daki veri setinin orijinal versiyonu üzerinde yapılan testlerde elde edilen karışıklık matrisleri


Bu makale kapsamında son olarak [19]'daki veri setinin ön işlem yapılmış görüntülerinin olduğu versiyon üzerindeki sınıflandırma başarımları değerlendirilmiştir. Deneysel çalışmalardan elde edilen test sonuçları Tablo 4'te verilmiştir.

Tablo 4. Önerilen modellerin [19]'daki veri setinin ön-ışlenmiş versiyonu üzerindeki test sonuçları.

Model	Acc	Pre	Sen	F1 score
VGG19	99.21	99.21	99.21	99.21
ResNet50	98.55	98.55	98.55	98.55
EfficientNetB0	98.93	98.94	98.93	98.93
DenseNet201	99.16	99.16	99.16	99.16
Xception	97.71	97.71	97.71	97.71

Ortalama %98,71 doğruluk değerine ulaşan modeller içerisinde en yüksek doğruluk başarımları %99,21 ve %99,16 ile sırasıyla VGG19 ve DenseNet201 modellerine aittir. Xception modeli %97,71 doğruluk değeri ile en düşük başarıma erişen model olmuştur. Tablo 4'teki başarımlar ölçütlerinin elde edildiği karışıklık matrisleri Şekil 8'de sunulmuştur.

Önerilen yöntemin sonuçları Tablo 5'te benzer çalışmalarla kıyaslanmıştır. Literatürdeki güncel çalışmalarla kıyaslandığında, önerilen yöntemin çok yüksek sonuçlara ulaştığı görülmektedir. [18]'deki veri seti için VGG19 ile elde edilen sonuçlar kabul edilebilir düzeyde iyidir. [19]'deki ön-ışlenmiş veri seti ile elde sınıflandırma sonuçları kullanılan VGG19, ResNet50, EfficientNetB0, DenseNet201 ve Xception modellerinin hepsi kıyaslanan literatür yöntemlerin tamamından daha yüksektir. [19]'deki veri setinin ön-ışlemeli görüntüleri için elde edilen sonuç [9] dışındaki bütün çalışmalardan iyidir.



Şekil 8. [19]'daki veri setinin ön-ışlemeli versiyonu üzerinde yapılan testlerde elde edilen karışıklık matrisleri

Tablo 5. Önerilen modelin güncel literatür çalışmalarıyla karşılaştırma sonuçları.

Yöntem	Model	Veri seti	Ön-işlem	Acc (%)
Javadi ve ark. [8]	WCNN4	[19]	Var	99.03
Balaha ve ark. [9]	VGG19	[19] ve iki farklı veri setinin birleşimi	Var	99.33
Ahamed ve ark. [10]	ResNet50V2	[18]	-	83.60
Ahamed ve ark. [10]	ResNet50V2	[18]	Var	99.01
Baghdadi ve ark. [11]	SeNet154	[18]	Var	98.00
Zheng ve ark. [12]	3D DeCoVNet	Özel veri seti	Var	90.80
Xu ve ark. [13]	ResNet-18	Özel veri seti	Var	86.70
Song ve ark. [14]	ResNet50	Özel veri seti	Var	93.00
Wang ve ark. [15]	GoogleNet	Özel veri seti	Var	89.50
Alsharman ve ark. [16]	GoogleNet	Covid-CT [33]	Var	82.14
Neha ve ark. [17]	CNN	[19]	Var	99.10
Önerilen Yöntem	VGG19	[18]	-	98.04
	VGG19	[19]	-	99.54
	ResNet50	[19]	-	99.62
	EfficientNetB0	[19]	-	99.57
	DenseNet201	[19]	-	99.42
	Xception	[19]	-	99.39
	VGG19	[19]	Var	99.21

Sonuç

Covid-19, ortaya çıkışından bu yana çok sayıda ölüme neden olmuş ve hızlı ve doğru bir şekilde tespit edilmesi gerekmektedir. Bu çalışmada, görüntülerden Covid-19'u tespit etmek ve sınıflandırmak amacıyla CNN tabanlı önceden eğitilmiş transfer öğrenme mimarilerine sahip VGG19, ResNet50, EfficientNetB0, DenseNet201 ve Xception modelleri iki farklı CT Covid-19 veri seti üzerinde incelenmiştir. Sonuçlar, önerilen yöntemlerin [18] ve [19]'daki veri setleri için sırasıyla %97,42 ve %99,54 ortalama doğruluk, %98,04 ve %99,62 en iyi bireysel doğruluk değerleriyle mükemmel bir performanslar elde ettiğini göstermiştir. Elde edilen sonuçlar güncel literatür çalışmalarıyla kıyaslandığında daha iyi başarımlar elde edilmiştir.

VGG19 ve DenseNet201 modelleri iki veri setine ait iki test kümesi için en iyi sonuçları vermiştir. Bu iki model, [19]'daki veri setinin orijinal test kümesi için ise literatürdeki sonuçlardan daha iyi sonuçlara erişirken, bu makaledeki diğer yöntemlere yakın sonuçlar vermiştir. Xception modeli tüm test kümeleri için en düşük sınıflandırma doğruluğuna erişen yöntemdir. Buna rağmen Xception modeli [19]'daki veri setinin orijinal test kümesi için ise literatürdeki yöntemlerde daha yüksek doğruluğa sahiptir.

Etik kurul onayı ve çıkar çatışması beyanı

“Hazırlanan makalede etik kurul izni alınmasına gerek yoktur”. “Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır”

Yazar katkıları

‘**Al-Areqi**’: Çalışma konsepti ve tasarım, Veri toplama, Verilerin analizi, Taslağın oluşturulması. ‘**Konyar**’: Çalışma konsepti ve tasarım, Verilerin analizi ve yorumlanması, Taslağın oluşturulması, Revizyon

Teşekkür

Bu çalışma Kocaeli Üniversitesi Yazılım Mühendisliği Bölümü Yazılım Teknolojileri Araştırma Laboratuvarı'nda (STAR Lab) gerçekleştirilmiş olup Kocaeli Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimince Desteklenmiştir. **Proje Numarası: 2021-2751.**

Kaynaklar

- [1] F. Al-Areqi, M. Z. Konyar, “Effectiveness evaluation of different feature extraction methods for classification of covid-19 from computed tomography images: A high accuracy classification study”, *Biomedical Signal Processing and Control*, vol 76, 103662, 2022.

- [2] A. Widders, A. Broom, and J. Broom, "SARS-CoV-2: The viral shedding vs infectivity dilemma" *Infection, disease & health*, vol. 25, no 3, pp. 210–215, 2020.
- [3] A Ozyigit, "Understanding Covid-19 transmission: The effect of temperature and health behavior on transmission rates", *Infection, disease & health*, vol. 25, no 4, pp. 233–238, 2020.
- [4] M. A. Shereen et. al. "COVID-19 infection: Origin, transmission, and characteristics of human coronaviruses", *Journal of advanced research*, vol. 24, pp. 91–98, 2020.
- [5] J. Cui, F. Li and Z. L. Shi, "Origin and evolution of pathogenic coronaviruses", *Nature reviews. Microbiology*, vol. 17, no. 3, pp. 181–192. 2019.
- [6] S. J. Dancer, "Covid-19 exposes the gaps in infection prevention and control", *Infection, disease & health*, vol. 25, no. 4, pp. 223–226, 2020.
- [7] W. Wang, et al., "Detection of SARS-CoV-2 in Different Types of Clinical Specimens" *JAMA*, vol. 323, no. 18, pp. 1843–1844, 2020.
- [8] S. JavadiMoghaddam and H. Gholamalinejad, "A novel deep learning based method for COVID-19 detection from CT image" *Biomedical signal processing and control*, vol. 70, 102987, 2021.
- [9] H. M. Balaha, E. M. El-Gendy and M. M Saafan, "CovH2SD: A COVID-19 detection approach based on Harris Hawks Optimization and stacked deep learning", *Expert systems with applications*, vol. 186, 115805, 2021.
- [10] K. U. Ahamed, et al., "A deep learning approach using effective preprocessing techniques to detect COVID-19 from chest CT-scan and X-ray images", *Computers in biology and medicine*, vol. 139, 105014, 2021.
- [11] N. A. Baghdadi, et al., "An automated diagnosis and classification of COVID-19 from chest CT images using a transfer learning-based convolutional neural network", *Computers in biology and medicine*, 144, 105383. 2022.
- [12] C. Zheng, et al., "Deep learning-based detection for COVID-19 from chest CT using weak label", *MedRxiv*, 2020.
- [13] X. Xu, et al., "A deep learning system to screen novel coronavirus disease 2019 pneumonia", *Engineering*, vol. 6, no 10, pp. 1122–1129, 2020.
- [14] Y. Song, et al., "Deep learning enables accurate diagnosis of novel coronavirus (COVID-19) with CT images", *IEEE/ACM Trans. Comput. Biol.Bioinform.* vol. 18, no. 6, pp. 2775–2780, 2021.
- [15] S. Wang, et al., "A deep learning algorithm using CT images to screen for Corona Virus Disease (COVID-19)", *European radiology*, vol. 31, no. 8, pp. 6096–6104, 2021.
- [16] N. Alsharman and I. Jawarneh, "GoogleNet CNN neural network towards chest CT coronavirus medical image classification", *J. Comput. Sci.* vol. 16, no. 5, pp. 620–625, 2020.
- [17] Neha, K., Joshi, K. P., Jyothi, N. A., & Kumar, J. V. (2021). Preliminary Detection of COVID-19 Using Deep Learning and Machine Learning Techniques on Radiological Data. *Indian Journal of Computer Science and Engineering*, 79-88.
- [18] M. Maftouni, "Large COVID-19 CT scan slice dataset", Available: <https://www.kaggle.com/datasets/maedemaftouni/large-covid19-ct-slice-dataset> (Accessed on: March. 28, 2022).
- [19] A. Z. Bin-Aziz, 'CT Scans for COVID-19 Classification', Available: <https://www.kaggle.com/datasets/azaemon/preprocesse-d-ct-scans-for-covid19> (Accessed on: March. 28, 2022).
- [20] O. S. Lih, et al., "Comprehensive electrocardiographic diagnosis based on deep learning", *Artificial intelligence in medicine*, vol. 103, 101789, 2020.
- [21] J. Dekhtiar, et al., "Deep learning for big data applications in CAD and PLM – Research review, opportunities and case study", *Computers in Industry*, vol. 100, 227–243, 2018.
- [22] M. Rahimzadeh and A. Attar, "Detecting and counting pistachios based on deep learning", *Iran J Comput Sci*, vol. 5, pp. 69–81, 2022
- [23] R. Yamashita, et al. "Convolutional neural networks: an overview and application in radiology", *Insights Imaging*, vol. 9, pp. 611–629, 2018.
- [24] I. Goodfellow, Y. Bengio, and A. Courville, "Deep learning", *MIT press*, 2016.
- [25] F. Al-Areqi and M. Z. Konyar, "Comparative Analysis of Machine Learning and Deep Learning Based Covid-19 Classification Methods", *International Marmara Sciences Congress (Imascon 2022 Spring)*, İzmit, Türkiye, 13-14 May 2022.
- [26] K. Simonyan, A. Zisserman, "Very deep convolutional networks for large-scale image recognition", *3rd International Conference on Learning Representations, ICLR 2015*, San Diego, CA, USA, May 2015.
- [27] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Dec. 2016.
- [28] M. Tan, Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks", *36th International Conference on Machine Learning, ICML 2019*, June 2019.
- [29] G. Huang, Z. Liu, L. Van Der Maaten, K. Q. Weinberger, "Densely connected convolutional networks", *30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, Jan. 2017.
- [30] F. Chollet, "Xception: Deep learning with depthwise separable convolutions", *30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, Jan. 2017.
- [31] M. Abadi et al., "{TensorFlow}: A System for {Large-Scale} Machine Learning", *In 12th USENIX symposium on operating systems design and implementation (OSDI 16)*, pp. 265-283, 2016.
- [32] F. Chollet, et al., "Keras: Deep Learning for humans". Available: <https://github.com/fchollet/keras>. (Accessed on: March. 28, 2022).
- [33] Yang, X., He, X., Zhao, J., Zhang, Y., Zhang, S., & Xie, P. (2020). COVID-CT-dataset: a CT scan dataset about COVID-19. arXiv preprint arXiv:2003.13865.