

X-RAY GÖĞÜS GÖRÜNTÜLERİNİN GÖRÜNTÜ DÖNÜŞTÜRÜCÜLER İLE SINIFLANDIRILMASI VE COVID-19 TESPİTİ

Dilek CIVİL *^{ID}
Özge ÖZTİMUR KARADAĞ*^{ID}

Alınma: 23.09.2022 ; düzeltme: 14.04.2023 ; kabul: 27.05.2023

Öz: 2019 yılında dünya çapında pandemi ilan edilmesine sebep olan COVID-19 virüsü, bulaştığı bazı kişilerde hastalığın çok hızlı ilerlemesi sebebi ile çok ciddi sağlık problemlerine, hatta ölümlere neden olmuştur. Hastalığın hızlı teşhisi bu olumsuz durumların ortaya çıkmasını engellemek için büyük önem arz etmiştir. X-Ray göğüs görüntüleri, Bilgisayarlı Tomografi (BT) vb. gibi tıbbi görüntüleme yöntemleri covid-19 un tespit edilmesinde önemli rol oynamıştır. Derin öğrenme yöntemleri, insan faktörünü ve insandan kaynaklı hata payını minimuma indirerek üstün görüntü analizi yeteneğini kanıtlamıştır. Bu çalışmada, son dönemlerde bilgisayarlı görü uygulamalarında öne çıkan görüntü dönüştürücülerin (Vision Transformers, VIT) X-ray göğüs görüntüleri üzerinde Covid-19 tespiti için kullanılması önerilmiştir. Önerilen sistemin eğitim ve test performansı literatürde yaygın kullanılan bir Konvolüsyonel Sinir Ağı, Resnet50, ile ayrıntılı olarak karşılaştırılarak analiz edilmiştir. Ayrıca VIT mimarisinin etkinliği doğruluk, kesinlik, hassasiyet ve F1 skoru kriterleri aracılığı ile Resnet50'nin yanı sıra COVID-19'un çok sınıflı veri kümelerinde başarı gösterdiği kaydedilen VGG16 ve InceptionV3 mimarileri ile de karşılaştırılmıştır. Deneyler sonucunda VIT mimarisinin öğrenme aktarımı yöntemi ile eğitilen Resnet50 ve VGG16 mimarilerinden daha iyi performans gösterdiği ve InceptionV3 ile başa baş sonuçlar elde ettiği gözlemlenmiş ve COVID-19 tespitinde alternatif bir karar destek sistemi olarak kullanılabilirliği tespit edilmiştir.

Anahtar Kelimeler: Covid-19, Görüntü Dönüştürücü, Derin Öğrenme, CNN, Aktarım Öğrenme

Classification of X-Ray chest images by vision transformers and covid-19 detection

Abstract: The COVID-19 virus, which caused the declaration of a worldwide pandemic in 2019, caused serious health problems and even death due to the rapid progression of the disease. Hence, early diagnosis of the disease has been of great importance to prevent the emergence of these adverse conditions. Medical imaging methods, such as X-Ray chest images, Computed Tomography (CT), etc. have played an important role in the detection. Deep learning methods have proven their superior image analysis ability. In this study, it is proposed to use the Vision Transformer (VIT), which has recently been popular in computer vision applications, for Covid-19 detection using X-ray chest images. The effectiveness of the VIT architecture is compared with a popular Convolutional Neural Network architecture, Resnet50 through various criteria, as well as VGG16 and InceptionV3 architectures, which were recorded to be successful in multi-class datasets of COVID-19. As a result of the experiments, it has been observed that the VIT architecture outperforms the Resnet50 and VGG16 architectures trained with the transfer learning method, and it has been observed that it achieves head-to-head results with InceptionV3, and it has been concluded that it can be used as an alternative decision support system for COVID-19 detection.

Keywords: COVID-19, Vision Transformers, Deep Learning, CNN, Transfer Learning

* Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü, Kestel Mahallesi, Üniversite Caddesi, No:80 PK:07425

Alanya/ANTALYA

İletişim Yazarı: Özge Öztimur Karadağ (ozge.karadag@alanya.edu.tr)

1. GİRİŞ

2019 yılından itibaren dünya çapında, Şiddetli Akut Solunum Sendromu Coronavirüs 2'nin (SARS-CoV-2) neden olduğu COVID-19 adlı bir salgın hızla yayılmaya başlamıştır. Bu salgını global düzeyde kontrol altına almak için birçok yöntem ele alınmasına rağmen, salgın dünya genelinde insan kayıplarından ekonomik durgunluklara kadar birçok alanda ağır kayıpların yaşanmasına sebep olmuştur.

COVID-19'un en yaygın kullanılan tıbbi tanı yöntemleri arasında antikor testi ve kantitatif ters transkripsiyon-polimeraz zincir reaksiyonu (RT-PCR) bulunur(Jacofsky ve diğ., 2020)(Tahamtan ve Ardebili, 2020). Antikor testi tekniği tipik olarak hızlı sonuç vermektedir. Fakat erken ve aktif enfeksiyonlar için yanlış sonuçlar verebileceğinden dolayı doğruluğu biraz şüphelidir. RT-PCR ise nispeten daha doğrudur. Fakat uzun süreli süreci, gerçek zamanlı kullanım için uygun değildir. Ayrıca, hastada herhangi bir belirti yoksa virüsün varlığını ayırt etmede o kadar etkili olmayabilir.

Genel olarak, tanı yöntemleri sonuçlandırmak için bir uzman bilgisine ihtiyaç duyulmaktadır. Ayrıca birçok ülkede hastaneler ve diğer sağlık kuruluşları, test kitlerinin varlığını ve virüsün yayılmasına engel olacak test taleplerine yanıt verme süreleri açısından yetersiz kalmıştır. Bu nedenle, iyileştirilmiş tıbbi görüntü analizinin, eğer doğru şekilde ele alınır ve uygulanırsa, bu alanda görev yapan tıp uzmanlarına yardımcı olabilecek bir araç olabileceği düşünülmektedir.

Geniş bir çalışma alanına sahip olan tıbbi görüntü analizi, hızlı, basit ve doğru sonuçlar vermesi ile alanında son on yılda büyük bir ivme kazanmıştır(Bercovich ve Javitt, 2018). Bu konu bağlamında ele alınacak tıbbi veriler ise en önemli bileşenler içerisinde yer almaktadır. COVID-19'un tespiti için, X-ray göğüs görüntüleri, ultrason görüntüleri ve Bilgisayarlı Tomografi (BT) görüntüleri en yaygın kullanılan tıbbi görüntü kaynakları arasında yer almaktadır. X-Ray göğüs görüntüleri, COVID-19 ve diğer akciğer enfeksiyonlarının bilgisayarlı tespiti için yararlı ve diğer yöntemlere göre daha uygun maliyetli bir kaynak sunmaktadır.

Teknoloji, uzman kişilere duyulan ihtiyacı azaltması ve insanın yapabileceği hataları minimuma indirmesi ile birçok hastalığın erken teşhisine imkân sağlamaktadır. Güçlü bilgi işleme donanımının ortaya çıkışı sayesinde, derin öğrenme tıbbi uygulamalarda son teknoloji bir çözüm olarak ortaya çıkmıştır.

Bu makale, X-ray Göğüs Röntgeni görüntü verileri kullanarak COVID-19'un otomatik analizi için yeni bir derin öğrenme hattı sunmaktadır. Bu çalışmanın ana katkıları aşağıdaki gibidir:

-Yalnızca COVID-19 tespiti için değil aynı zamanda COVID-19 dışında akciğerlerde oluşabilen pnömoni hastalığının tespitinde de kullanılmaktadır.

-COVID-19'un otomatik tespiti ve sınıflandırılması için Görüntü Dönüştürücüye (Vision Transformer, VİT) dayalı bir yaklaşım önerilmektedir.

-Orijinal görüntüleri sınıflandırmak için mimari içerisinde veri çoğaltma tekniği kullanılmıştır.

Bu makalenin geri kalanı aşağıdaki gibi organize edilmiştir. Bölüm 2, COVID-19 teşhisi için literatürde yer alan ilgili çalışmaları kapsamaktadır. Bölüm 3, kullanılan yöntemlerin ve verilerin ayrıntılarını açıklamaktadır. Bölüm 4, modeller için performans değerlendirme ölçütlerini ve sonuçları açıklamaktadır. Bölüm 5, sonuç kısmını içermektedir.

2. İLGİLİ ÇALIŞMALAR

Güngör ve diğ. (2021), DeOldify kütüphanesini ele alarak veri kümesindeki BT görüntülerini renklendirerek derin öğrenme yöntemlerinden DenseNet121 üzerinde çalışarak COVID-19 hastalarını, sağlıklı bireylerden ayırt etmeye çalışmışlardır. Sonucunda %98'lik doğruluk elde etmişlerdir.

Korkmaz ve diğ. (2021) çalışmalarında, derin öğrenme yöntemlerini kullanarak COVID-19'u ve çeşitli nedenlerle akciğerde oluşan pnömoni hastalığını tespit etmeye çalışmışlardır. Veri kümesi olarak 3 farklı sınıfa ait göğüs röntgen görüntülerini ele almışlardır. Modelinin eğitiminde

ve değerlendirilmesinde 5-katlamalı çapraz doğrulama yöntemi kullanmışlardır. Önerilen yöntemin doğruluğunu karşılaştırmak için, mevcut veri kümesi üzerinde literatürde başarılı görülen beş farklı mimari üzerinde aynı 5-katlamalı çapraz doğrulama yöntemini uygulamışlardır. Eğitimin sonunda elde edilen model ortalama %97 doğrulukla sınıflandırma yapabilmektedir.

Yılmaz (2021) X-Ray göğüs görüntülerinden COVID-19 teşhisi için, çok kanallı Konvolüsyonel Sinir Ağı (CNN) yöntemini önermiştir. Literatürdeki çalışmalardan farklı olarak, önerilen çok kanallı CNN mimarisinin özgünlüğü beş evrişim kanalına sahip olması ve bu kanal arasından en etkili özellik filtrelerini seçmesidir. Kullanılan mimarinin verimliliğini değerlendirmek için, aynı veri kümesi üzerine Tekrarlayan Sinir Ağları (Simple Recurrent Networks, SRN) uygulamışlar ve önerdikleri mimarinin daha iyi sonuçlar verdiğini göstermişlerdir.

Bozkurt ve Yağanoğlu (2021) bir Evrişimsel Sinir Ağı (ESA) modeli sunmuş; COVID-19, Normal ve Viral Pnömoni sınıflarından veriler üzerinde yaptıkları deneylerde önerdikleri ESA modelinin etkinliğini VGG19, InceptionV3 ve ResNet50 gibi ESA tabanlı diğer popüler modeller ile karşılaştırmışlar ve önerdikleri model için %96 doğruluk elde etmişlerdir.

Karaman (2021) ResNet18, ResNet50, VGG16, AlexNet ve SqueezeNet1_1 mimarilerini ele alarak, transfer öğrenim yöntemini kullanarak COVID-19'u tespit etmek için modelleri yeniden eğitmiştir. En yüksek sınıflandırma performans parametreleri ResNet50 mimarisi için elde edilmiş ve %99,80 doğruluk, %99,61 kesinlik ve %100,00 hassasiyet olarak hesaplanmıştır.

Özbay ve Özbay (2021) COVID-19 hastalığının teşhisi için tahmin modelinde güncel teknolojik gelişmelere uygun birçok sınıflandırma algoritmaları ile ESA modelleri için çıktılarının performansları üzerine bir karşılaştırma yapmıştır. Çalışmada kullanılan veri kümesi, 1252 adet COVID-19, 1230 adet COVID-19 negatif olmak üzere toplam 2482 görüntüden oluşmaktadır. Bu çalışmada Evrişimli Sinir Ağı (ESA) sınıflandırma performansı makine öğrenmesinde öne çıkan diğer yöntemlerle; Rastgele Orman, Destek Vektör Makinesi, Rastgele Ağaç ve Naive Bayes ile karşılaştırılmış ve ESA modelinin, diğer gelişmiş sınıflandırma algoritmalarından daha iyi performans gösterdiği görülmüştür.

Li ve diğ. (2021) X-ışını veri kümelerini ele alarak COVID-19'u tespit etmek için yumuşak mesafe düzenlemeli, çok ölçekli, dikkat yönlendirmeli bir derin ağ modeli oluşturmuşlardır. Önerilen ağ, çok ölçekli özellik haritalarından bir tahmin vektörü oluşturmaktadır. Ayrıca, modeli daha sağlam hale getirmek ve eğitim verilerini doldurmak için yumuşak mesafe düzenlemesi ile dikkat yönlendirmeli büyütme benimsenmiştir.

Ardakani ve diğ. (2020) BT görüntülerinden COVID-19'u tespit etmek VGG-16, VGG-19, AlexNet, GoogleNet, SqueezeNet, ResNet-18, ResNet-50, ResNet-101, MobileNet-V2 ve Xception mimarilerinin performansını karşılaştırmışlardır. Elde ettikleri sonuçlar doğrultusunda, ResNet-101'in öne çıktığını gözlemlemişler ve ResNet-101'i kullanmayı önermişlerdir.

Heidari ve diğ. (2020) X-ışını görüntülerini üç sınıfa ayırmak için önceden eğitilmiş bir VGG16 modeline ince ayar yaparak çalışmalarına devam etmişlerdir. 2544 vakadan oluşan bir alt küme üzerinde test edilen CNN modeli, üç vaka alt kümesini sınıflandırmada %94,5 doğruluk ve COVID-19 ile enfekte olmuş pnömoni vakalarını tespit etmede %98,1 doğruluk sonucu elde etmiştir.

Narin ve diğ. (2021) göğüs röntgeni görüntülerini kullanılarak koronavirüs ve pnömoni ile enfekte hastanın tespiti için beş önceden eğitilmiş ESA tabanlı modeli (ResNet50, ResNet101, ResNet152, InceptionV3 ve Inception-ResNetV2) karşılaştırmışlardır. COVID-19, normal (sağlıklı), viral pnömoni ve bakteriyel pnömoni sınıflarından oluşan veri kümesi ile elde edilen performans sonuçlarına bakıldığında, en iyi performansı önceden eğitilmiş ResNet50 modelinin sağladığı görülmüştür.

Calderon-Ramirez ve diğ. (2021) X-ışınlarından COVID-19 tespiti için Softmax puanları, Monte-Carlo bırakma ve deterministik belirsizlik niceleme gibi çeşitli belirsizlik tahmin yöntemlerini uygulamayı önermiştir.

Amyar ve diğ. (2020) BT görüntüleri üzerinden covid-19 hastalığını tespit etmek için üç temel görevden oluşan çok görevli bir öğrenme yaklaşımı önermişlerdir. Temel görevler sırası ile sınıflandırma işlemi, bölütlere ayırma ve yeniden yapılandırma on evrişim katmanlı kodlayıcı aşamasından, yeniden yapılandırma için 9-evrişimsel-katmanlı bir kod çözücü parçasından ve bölütlere ayırmak için 9-evrişimli-katmanlı bir kod çözücü bölümünden oluşan derin bir ağ kurmuşlardır. Deneyler neticesinde AUC = 0.97 ve %94'ün üzerinde bir doğrulukla sınıflandırma sonuçları için kurulan modelin , %56 ile %90 arasında değişen sonuçlar elde etmişlerdir.

Ko ve diğ. (2020) önceden eğitilmiş dört derin evrişimli ağı karşılaştırmak için transfer öğrenmeyi kullandı ve ResNet-50 kullanarak en iyi sonuçları elde etti.

Kumar ve diğ. (2021) çalışmalarında, COVID-19 vakalarının sınıflandırılması için derin transfer öğrenme tabanlı bir model önermişlerdir. Önerdikleri model, DeQueueNet olarak adlandırılmıştır. Model DenseNet121 ve SqueezeNet1.0 birleşimine dayanmaktadır. DeQueueNet, COVID-19 vakalarını sınıflandırmak için etkin bir şekilde kullanılan röntgen görüntülerinden çeşitli etkili özelliklerin önemini çıkartabilmektedir. Önerilen modelin performans sonuçları; %94,52 doğruluk, %90,48 kesinlik ve %96,15 hassasiyet olarak hesaplanmıştır.

Literatürde yer alan benzer çalışmaların karşılaştırılması Tablo 1 'de sunulmuştur. Bu tabloda yer alan çalışmaların tümü X-ray görüntüleri üzerinde çalışmaktadır. Ele aldıkları veri kümesi, sınıf sayısı (C: Corona, N: normal, P: , V:viral pnömoni, B:bakteriyal pnömoni, Ö:ödem, E:effüzyon, A:amfizem, Fibrozis) , kullanılan mimari ve elde edilen doğruluk oranı tabloda verilmiştir.

Tablo 1. Literatür tablosu (Demir ve Yılmaz, 2021)

| ÇALIŞMA | VERİ SETİ | MİMARİ | SINIF SAYISI | SONUÇLAR |
|------------------------|--|---|--------------------------|--------------------------------------|
| Ozturk ve diğ. | Covid-19 image data collection ChestX-Ray8 | DarkCovidNet | C*N C*N*P | 0,98 0,87 |
| Narin ve diğ. | Covid-19 image data collection ChestX-Ray8 Chest-X-ray Images(Pneumonia) | InceptionV3 ResNet50 ResNet101 ResNet152 Inception-ResNetV2 | C*N C*V C*B | 0,96 0,99 0,99 |
| Apostolopoulos ve diğ. | Covid-19 image data collection | Mobile Net v2 | C*N C*P*N*Ö*E*A *F | 0,99 0,87 |
| Condaragin ve diğ. | Covid-19 Radiography Database | VGG-16 ResNet50 DenseNet-201 InceptionV3 NasNetMobile | C*O*P*N | 0,96 0,95 0,96 0,96 0,95 |
| Hussain ve diğ. | Covid-19 Radiography Database | 1 katman CNN 3 katman CNN 4 katman CNN | C*N | 0,95 0,96 0,94 |

Tablo 1. (devamı)

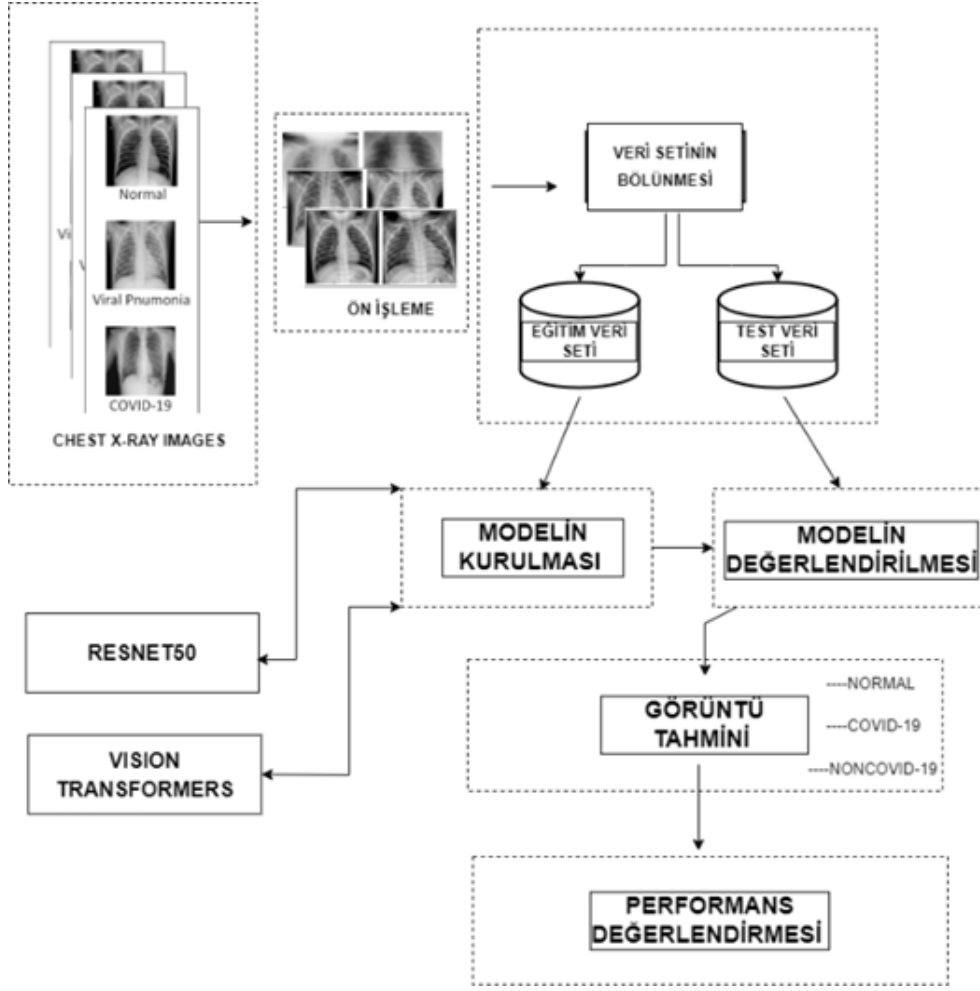
| | | | | |
|----------------|-------------|--------------|-----|------|
| Aparna ve diğ. | Covid-19 | VGG16 | C*N | 0,93 |
| | Radiography | MobileNet | | 0,91 |
| | Database | Önerilen CNN | | 0,98 |

3. METARYAL VE METOT

Bu çalışmada, veri bilimindeki gelişmeleri göz önünde bulundurarak, COVID-19 tespiti için Görüntü Dönüştürücü (Vision Transformers, VİT) tabanlı bir derin öğrenme sistemi kullanılmıştır.

COVID-19, Pnömoni(Non-covid-19) ve sağlıklı(normal) bireylere ait X-Ray göğüs görüntülerinden oluşan veri kümesi ele alınarak VİT mimarisi ile eğitim gerçekleştirilmiştir. Ardından oluşturulan modelin doğruluğunu değerlendirmek için aynı veri kümesi üzerinde Aktarım Öğrenme (Transfer Learning) yöntemi ele alınarak CNN mimarilerinden literatürde yaygın olarak kullanılmakta olan ve özellikle COVID-19'un tespit edilmesi alanında büyük başarılar elde eden Resnet50 mimarisinde ince ayar yapılarak yeniden eğitime işlemi gerçekleştirilmiştir. Modellerin eğitilmesi işleminden sonra ele alınan mimarilerin sınıflandırma görevindeki sonuçlarının değerlendirilmesi ve karşılaştırılması için performans metriklerinden doğruluk, kesinlik, hassasiyet ve F1-skoru değerleri hesaplanmıştır.

Önerilen sistemin akış şeması Şekil 1 'de verilmiştir. Şekilde görüldüğü gibi, X-ray göğüs görüntülerinden oluşan veri kümesini giriş verisi olarak programa verilmiş ve veri kümesinde yer alan tüm görüntüler ön işlemenin bir parçası olarak yeniden boyutlandırılmış ve ele alınan etiket değerleri üzerinde sayısallaştırma işlemi gerçekleştirilmiştir. 12000 X-Ray göğüs görüntüsünü içeren eğitim veri kümesini kullanarak VİT ve RESNET50 mimarileri aynı veri kümesi üzerinden farklı zamanlarda eğitilmiş ve ardından modellerin test edilmesi için test veri kümesinde yer alan 3000 X-Ray göğüs görüntüsü ele alınarak performans değerlendirilmesi yapılmıştır.



Şekil 1:

Akış şeması

Tam eğitilmiş ve doğrulanmış modeller üzerinde, test veri kümesi kullanılarak verilen görüntünün hangi sınıfa ait olduğu üzerine tahminleme işlemi yapılmıştır. Son adımda, test verisi için elde edilen tahminler gerçek etiket değerleri ile karşılaştırılarak performans ölçümü yapılmıştır.

3.1. Çalışmada Kullanılan Veri Kümesi

Veri kümesinde yer alan görüntüler açık kaynak kodlu Kaggle ve GitHub veri kaynakları üzerinden elde edilmiştir(<https://kaggle.com/tawsifurrahman/covid19-radiography-database>),(<https://www.kaggle.com/datasets/cf77495622971312010dd5934ee91f07ccbcfdea8e2f7778977ea8485c1914df>),(<https://github.com/ieee8023/covid-chestxray-dataset>). Ardından elde edilmek istenen sınıflandırma işlemine uygun bir veri kümesini hazırlamak için bir araya getirilmiştir. Veri kümesi, normal(sağlıklı) bireylerin, COVID-19'lu hastaların ve bakteriyel veya normal pnömoni hastalarına ait X-Ray göğüs görüntülerini içermektedir. İlk olarak, veri kümesinin tüm görüntülerini tekdüze bir boyuta ölçeklendirdiğimiz ve daha sonra verileri eğitim, doğrulama ve test kümeleri olmak üzere üç bölüme dağıttığımız kullanılabilir bir forma dönüştürmek için ön işlemden geçirilmiştir. Modelin eğitilmesi, test edilmesi ve doğrulanması için kullanılacak veri kümesi, üç sınıfın X-Ray göğüs görüntülerini içermektedir. Bir sınıf, COVID-19 hastalarının X-ray göğüs görüntülerini tutarken, ikinci sınıf Pnömoni (Non-COVID-

19) X-Ray göğüs görüntülerini ve diğer sınıfta normal(sağlıklı) hastaların X-Ray göğüs görüntülerini tutmaktadır.

Yeni veri toplamadan veri çeşitliliğini artırmak için elde veriler üzerine veri çoğaltma işlemi uygulanmıştır. Veri çoğaltma tekniği ile veri kümesinde yer alan görüntüleri yeniden boyutlandırdık, ardından görüntüleri rastgele çevirdik ve yakınlaştırdık. Bu prosedür, sıralı yöntemlerle ve Keras tarafından sağlanan katmanlar kullanılarak tamamlandı. Bunun bir parçası olarak, giriş görüntülerinin [0,1] aralığında (orijinal görüntülerde 0–255 arasında) piksel değerlerine sahip olacak şekilde ölçeklendiği normalleştirme işlemi uygulandı.

Etiket verileri 0:Covid-19, 1: Pnömoni (Non-Covid-19) ve 2:Normal olacak şekilde sayısallaştırılmıştır. Ele alınan verilerden her sınıfa ait birer örnek görüntüler Şekil 2’deki gibidir..



Şekil 2:

*Veri kümesinde bulunan X-ray göğüs görüntülerinden örnekler <ve mevcutsa kaynakları>;
a. Covid-19 görüntüsü b. Pnömoni(Non-covid-19)görüntüsü c. Normal(Sağlıklı birey) görüntüsü*

Bu veri kümesindeki görüntülerin eğitim, test, doğrulama ve COVID-19, Pnömoni ve Normal olmak üzere dağılımı Tablo 2’de detaylı olarak verilmiştir.

Tablo 2. Veri kümesindeki her bir sınıf için ele alınan görüntü sayısı

| | COVID-19 | Pnömoni(Non-Covid-19) | Normal | Toplam |
|-----------|----------|-----------------------|--------|--------|
| Eğitim | 4000 | 4000 | 4000 | 12000 |
| Test | 1000 | 1000 | 1000 | 3000 |
| Doğrulama | 500 | 500 | 500 | 1500 |
| Toplam | 5500 | 5500 | 5500 | 16500 |

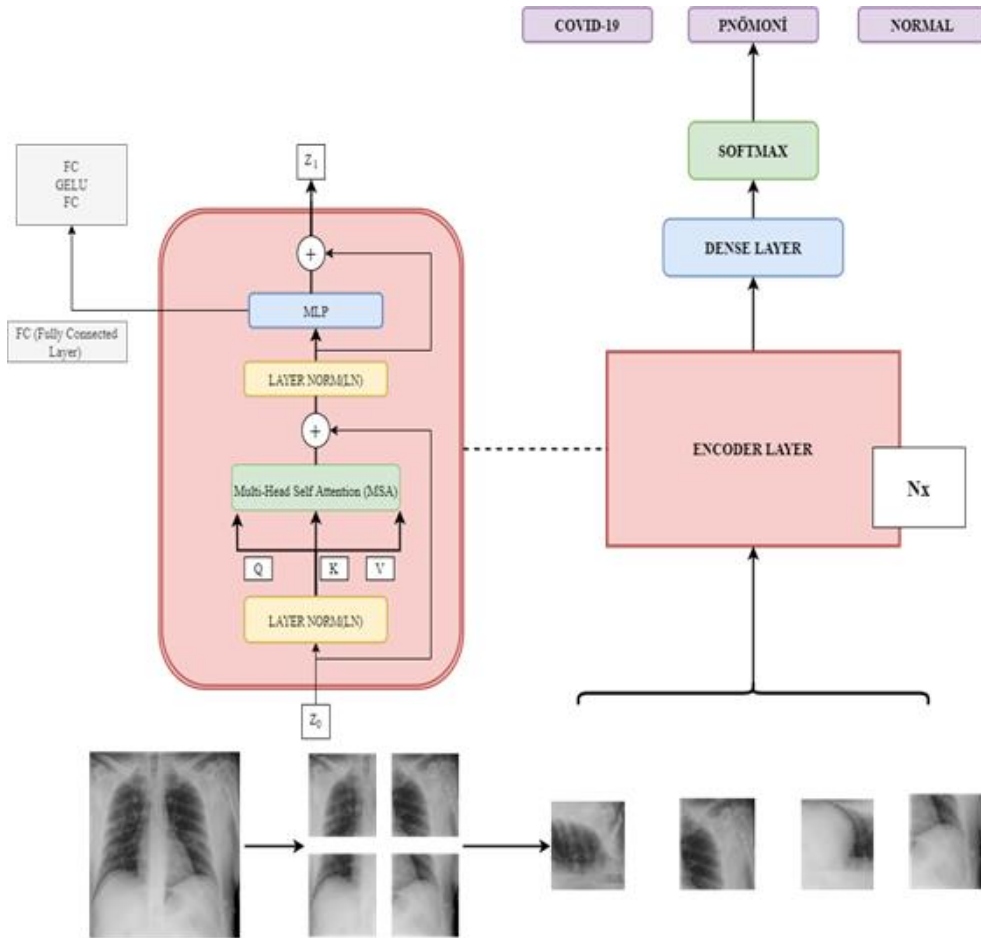
3.2. Görüntü Dönüştürücüler

Dönüştürücü mimarisi, sıralı verilerin herhangi bir tekrarlayan ağ kullanılmadan paralel olarak işlenmesine izin veren kodlayıcı-kod çözücü bloklarından oluşur. Dönüştürücü modellerinin başarısı, büyük ölçüde, dizinin öğeleri arasındaki uzun vadeli ilişkileri yakalamak için önerilen öz-dikkat mekanizmasından gelir (Dosovitskiy ve diğ., 2020). Görüntü Dönüştürücüler (VİT), standart dönüştürücülerin kullanımını görüntü sınıflandırmasına uygulama girişimi olarak önerilmiştir. Bir dizi görüntü parçasını anlamsal etikete eşleyerek sınıflandırma gerçekleştirmek için dönüştürücünün kodlayıcı modülünü kullanır. Örnek bir resim için patch gösterimi Şekil 3 ‘deki gibidir.

VİT mimarisi Şekil 4’de verilmiştir. Buna göre, görüntü parçaları öz-dikkat mekanizmasına dayalı kodlayıcı tarafından işlendikten sonra, bir Çok Katmanlı Algılayıcıya (MLP) iletilir. MLP tam bağımlı ve dropout (bırakma) katmanlarından oluşmaktadır, burada elde edilen çıktı softmax katmanına gönderilerek sınıflandırma işlemi tamamlanmış olur. Bu mimari içerisinde, kodlayıcının öz-dikkat biriminde Sorgu(Q)-Anahtar(K)-Değer(V) atamaları Vaswani ve diğ. (2017) önerdiği şekilde gerçekleştirilir.



Şekil 3:
Görüntü patch örneği



Şekil 4:
VİT mimarisi

3.3. Öğrenme Aktarımı

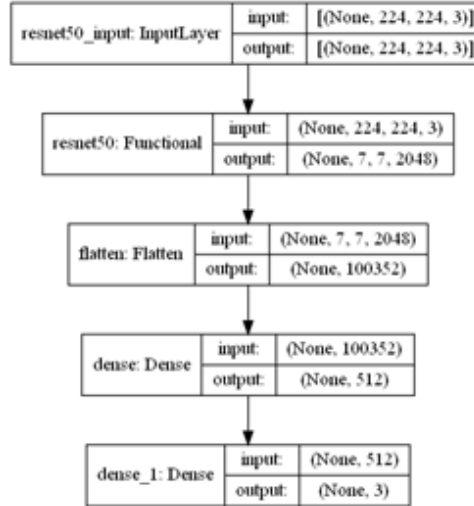
Derin öğrenme yöntemleri makine öğrenmesi problemlerinde yüksek performans göstermiştir. Sağladığı yüksek performans avantajı ile çok tercih edilmesine rağmen, büyük veriye ihtiyaç duyması en önemli dezavantajı olarak karşımıza çıkmaktadır. COVID-19 gibi yeni ortaya çıkan ve büyük verinin mevcut olmadığı problemlerde öğrenim aktarımı yöntemi kullanılabilir. Bu yöntemde, daha önce farklı bir veri kümesi ile muhtemelen farklı bir problem için eğitilmiş bir derin mimarinin, mevcut problem için kullanımı söz konusudur.

Derin mimarilerde, genelleştirilmiş bir görüntü sınıflandırma görevi için çok derin bir sinir ağı göz önüne alındığında, ilk katmanlar ve ağırlıkları görevden bağımsızdır. Sadece son katmanlar ne tür bir görüntü sınıflandırma görevi olacağına karar verir, böylece önceden eğitilmiş bir modelin ilk katmanlarının ağırlıklarını kolayca içe aktarabilir ve ardından elimizdeki verilerle son olanları eğitebiliriz. Yapılan araştırmalar doğrultusunda COVID-19'un tespit edilmesinde başarılı sonuçlar vermiş olan 50 ağırlık katmanına sahip ResNet50 mimarisi kullanılmıştır. Ele aldığımız modeli göreve özgü hale getirmek için ResNet50 mimarisi ile öğrenme aktarımı gerçekleştirilmiştir.

ResNet50 mimarisi 50 katmandan oluşmakta ve bu katmanların arasında beş adet evrişimsel blok yer almaktadır. Bu bloklar, 1×1 , 3×3 ve 1×1 boyutlarındadır. 1×1 evrişimsel blokları ile giriş imgeleri daha düşük boyuta indirgenmiş ve 3×3 evrişimsel bloğu ile daha yüksek boyutlarda filtreleme işlemi gerçekleştirilmiştir (He ve diğ., 2016). Global ortalama havuz katmanı ile boyut küçültme işlemi gerçekleştirilmiştir. Mimarinin son katmanlarında Softmax aktivasyon fonksiyonunun kullanıldığı tam bağımlı katman kullanılmış 1000 kategorilik sınıflandırma yapılabilmesi için 1000 adet çıkış verilmiştir. ResNet-50 mimarisi 25,6 milyon parametreden oluşmaktadır. ResNet50 evrişimsel sinir ağının mimarisi Şekil 5'te verilmiştir. Şekilde Functional kısım; konvolüsyon, aktivasyon ve havuzlama (pooling) katmanlarını içermektedir. Sonrasında, Flatten ile düzleştirme gerçekleştirilmekte ve elde edilen çıktı iki katlı tam bağlı katmana (fully-connected) iletilmektedir.

Aktarım öğrenme kapsamında, mimarinin 'ImageNet' ile eğitilen modeli yükledikten sonra, modelin " derin katmanları" dondurulmuş ve yalnızca son birkaç katmanı kendi verilerimizle yeniden eğitilmiştir.

Resnet50 mimarisi Şekil 5'te verilmiştir. Mimarinin 'ImageNet' ile eğitilen modeli yükledikten sonra, modelin "daha derin katmanları" dondurulmuş ve yalnızca son birkaç katmanı kendi verilerimizle yeniden eğitilmiştir.



Şekil 5:
ResNet50 Mimari

4. PERFORMANS DEĞERLENDİRME KRİTERLERİ

Bu çalışmada, 0: Covid-19, 1: Pnömoni (Non-Covid-19), 2: Normal sınıfları için elde edilen sonuçlar, aşağıdaki kriterler ile değerlendirilmiştir:

4.1. Karmaşıklık Matrisi

Test veri kümesinin VİT modeli ile sınıflandırılması sonucu elde ettiğimiz karmaşıklık matrisi Şekil 6 'da Resnet50 ile sınıflandırılması sonucu elde ettiğimiz karmaşıklık matrisi Şekil 7 'de gösterilmiştir.

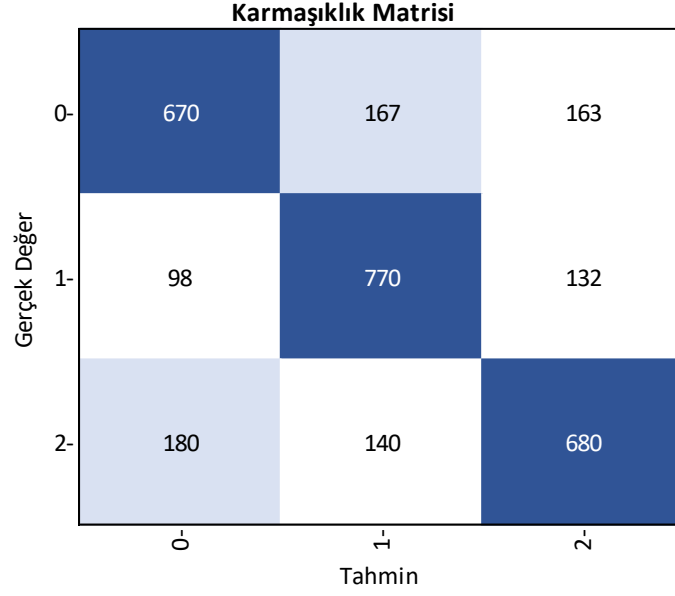
Karmaşıklık Matrisi

| | | | |
|----|--------|-----|-----|
| 0- | 800 | 103 | 97 |
| 1- | 74 | 765 | 161 |
| 2- | 117 | 113 | 770 |
| | 0 | 1 | 2 |
| | Tahmin | | |

Şekil 6:

0,1 ve 2 etiketlerinin sırasıyla COVID-19, Non-COVID-19 ve normal sınıflarını temsil ettiği veri kümesinin test kümesindeki değerlendirme için VİT karmaşıklık matrisi

Şekil 6'da, toplam 3000 görüntü içeren test veri kümesi üzerinden VİT mimarisi sonucunda elde edilen tahminleme sonucunda 1000 adet görüntü içerisinde 800 COVID-19 görüntüsü doğru şekilde, 103'ü yanlış şekilde non-Covid-19, 97 tanesi de yanlış şekilde Normal olarak sınıflandırılmıştır. Aynı şekilde yine test veri kümesindeki görüntü içerisinde 1000 tane Non-COVID-19 olmayan görüntüden 765 tanesi Non-COVID-19 olarak doğru şekilde, 74'ünü Covid-19 ve 161'ini Normal olmak üzere yanlış sınıflandırılmıştır. Normal sınıfı için; 1000 tane Normal sağlıklı bireye ait görüntüden 770 tanesi Normal olarak doğru şekilde, 117'sini COVID-19 ve 113'ünü Non-COVID-19 olarak yanlış sınıflandırılmıştır.



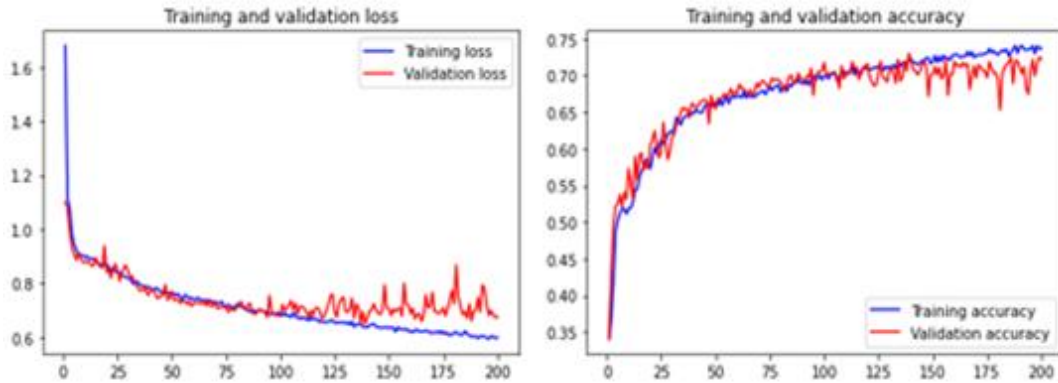
Şekil 7:

0, 1 ve 2 etiketlerinin sırasıyla Covid-19, Non-Covid-19 ve Normal sınıflarını temsil ettiği veri kümesinin test kümesindeki değerlendirme için ResNet50 karmaşıklık matrisi

Şekil 7 'de 1000 adet görüntü içerisinde 670 COVID-19 görüntüsünü doğru, 167'sinin non-COVID-19 olarak ve 163 tanesinin de Normal olmak üzere yanlış sınıflandırıldığı görülmektedir. Aynı şekilde yine test veri kümesindeki 1000 tane Non-COVID-19 görüntüsünden 770 tanesi Non-COVID-19 olarak doğru, 132'si COVID-19 ve 98'i Normal olmak üzere yanlış sınıflandırılmıştır. Normal sınıfında 1000 adet Normal sağlıklı bireylere ait görüntülerden 680 tanesi Normal olarak doğru, 180'i COVID-19 ve 140'ı Non-COVID-19 olarak yanlış sınıflandırılmıştır.

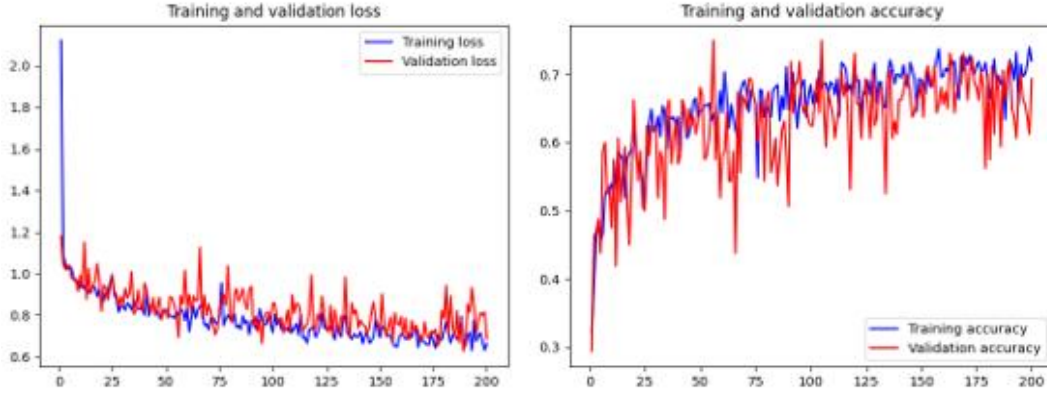
4.2. Doğruluk ve Kayıp Grafikleri

Önerilen model için 200 iterasyonluk eğitim gerçekleştirilmiş. VİT modelinin eğitimi sırasında elde edilen doğruluk ve kayıp grafikleri Şekil 8'de ve Resnet50'nin eğitimi sırasında elde edilen doğruluk ve kayıp grafikleri Şekil 9'da verilmiştir.



Şekil 8:

VİT kayıp ve doğruluk grafikleri



Şekil 9:
Resnet50 kayıp ve doğruluk grafikleri

Her iki modelin eğitiminde de doğruluğun artışı ve kaybın azalışı hem eğitim hem de doğrulama kümeleri üzerinde gözlemlenmiştir.

4.3. Performans Kriterleri

Doğruluk, modelde doğru tahmin edilen verinin toplam veri kümesine oranı ile hesaplanmaktadır. Daha yüksek bir doğruluk değeri modelin etkinliğini onaylar. Doğruluk hesaplama denklem 1'deki gibidir.

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

Kesinlik, doğru sınıflandırılmış pozitiflerin (TP) sayısının pozitif olarak tahmin edilen toplam numunelere (TP ve FP) bölünmesiyle hesaplanan pozitif tahminlerden kaçının doğru olduğunu belirler. Hesaplama için kullanılan denklem 2'de verilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

Hassasiyet/Duyarlılık; (Recall) ise doğru olarak tahmin etmemiz gereken işlemlerin ne kadarını doğru olarak tahmin ettiğimizi gösteren bir metriktir. Bir modelin enfekte vakaları belirleme eğilimini ifade eder. Denklem 3'te verilmiştir.

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

F1-Skoru, doğruluk kriterine alternatif olabilecek bir başka değerlendirme yöntemidir. F-ölçümü veya F1 puanı diye de anılmaktadır, kesinlik ve hassasiyet arasındaki bir denge olarak kabul edilir. Hesaplama için kullanılan denklem 4' te gösterilmektedir.

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

Her iki mimariden elde edilen kesinlik (precision), hassasiyet (recall), F1-skor ve doğruluk (accuracy) değerleri Tablo 3.'te gösterilmiştir. Tabloda her bir yöntemin üç ayrı sınıf için elde ettiği performansları, son sütunda ise, yöntemlerin tüm sınıflar için genel doğruluk performansları verilmiştir.

Tablo 3. VİT Mimarisinin CNN Mimarileri ile Karşılaştırmalı Performans Metriklerinin Sonuçları

| MİMARİ | SINIF KÜMESİ | DOĞRULUK | KESİNLİK | HASSASİYET | F1 SKOR | GENEL DOĞRULUK |
|-------------|--------------|----------|----------|------------|---------|----------------|
| VİT | COVID-19 | 0,87 | 0,81 | 0,80 | 0,80 | 0,85 |
| | NON-COVID-19 | 0,85 | 0,78 | 0,77 | 0,77 | |
| | NORMAL | 0,84 | 0,75 | 0,77 | 0,76 | |
| RESNET50 | COVID-19 | 0,79 | 0,68 | 0,67 | 0,69 | 0,81 |
| | NON-COVID-19 | 0,82 | 0,71 | 0,77 | 0,74 | |
| | NORMAL | 0,81 | 0,72 | 0,68 | 0,69 | |
| VGG16 | COVID-19 | 0,91 | 0,93 | 0,80 | 0,86 | 0,81 |
| | NON-COVID-19 | 0,79 | 0,88 | 0,42 | 0,56 | |
| | NORMAL | 0,73 | 0,55 | 0,92 | 0,68 | |
| InceptionV3 | COVID-19 | 0,87 | 0,82 | 0,81 | 0,81 | 0,85 |
| | NON-COVID-19 | 0,85 | 0,79 | 0,76 | 0,77 | |
| | NORMAL | 0,85 | 0,76 | 0,77 | 0,76 | |

VİT Modelinin COVID-19'u tanınmasında doğruluk oranı yaklaşık %87, ResNet50 modelinin COVID-19'u tanınmasında doğruluk oranı yaklaşık %80'dir. Tablo 3 'de görüldüğü gibi VİT mimarisi her metrik için ortalama 0.70'in üzerinde etkinlik değerleri sunar ve %80 hassasiyet değeri modelin yanlış pozitif üretme olasılığının düşük olduğunu gösterir. Diğer kriterler de VİT modelinin sınıflandırmada Resnet50 mimarisine göre daha başarılı olduğunu doğrulamaktadır.

VİT mimarisinin literatürdeki diğer CNN mimarileri ile karşılaştırmak amacı ile, literatürde çok yaygın kullanılan ve Tablo 1'de çok sınıflı veri kümelerinde yüksek performans elde ettiği kaydedilen VGG16 ve InceptionV3 mimarileri ele alınmıştır. Bu mimariler öğrenme aktarımı yöntemi ile ilk katmanları dondurulup, son katmanları eğitilerek kullanılmış ve Tablo 3'te verilen performans sonuçları elde edilmiştir. Tablodaki sonuçlara göre, VİT mimarisinin VGG16'dan daha başarılı, InceptionV3 ile başa baş sonuçlar elde ettiği söylenebilir.

Böylece bu çalışma COVID-19 hastalarına erken tanı koymak, izolasyon sağlamak, tedavisinin etkinliğini arttırmak, radyologların iş yükünü hafifletmek ve salgının kontrolünü sağlamak için önerilen sistemin bir potansiyele sahip olduğunu göstermektedir.

5. SONUÇ

Bu çalışmada, X-ray tıbbi göğüs görüntülerinin görüntü dönüştürücü, VİT mimarisi, ve literatürde en yaygın kullanılan üç konvolüsyonel sinir ağı, Resnet50, VGG16 ve InceptionV3, mimarileri ile sınıflandırılması ve COVID-19 hastalığının tespiti gerçekleştirilmiştir. Ve elde edilen sonuçlar çeşitli kriterlere göre görsel ve niceliksel olarak karşılaştırılmıştır. VİT modelinden ve InceptionV3 mimarisinden %85, ResNet50 ve VGG16 mimarilerinden %81 doğruluk elde edilmiştir. VİT mimarisi son yıllarda araştırmacıların dikkatini çekmiş ve bildiğimiz kadarı ile bugüne kadar COVID-19 çalışmalarında bu çalışmada olduğu gibi problemi çok sınıflı olarak ele alarak kullanılmamıştır. Bu çalışma ile VİT mimarisinin bu alanda iyi sonuçlar verebileceği teyit edilmiştir. Önerilen mimari, doğruluk, kesinlik, hassasiyet ve F1 skoru açısından değerlendirilerek X-ray görüntü verileri üzerinde en son teknoloji yöntemlere göre kullanılabilirliğini teyit etmiş ve sınırlı eğitim verileri altında sağlamlığını göstermiştir. VİT modelinin karşılaştırılan diğer yöntemlere göre dezavantajı hesaplama karmaşıklığıdır. Çalışmada ele alınan diğer modellerin öğrenme aktarımı ile eğitilmiş olmaları sebebi ile hesaplama karmaşıklıkları, VİT modeline göre daha düşüktür. Gelecek çalışmalarda VİT modelinin hesaplama karmaşıklığını azaltabilecek yöntemler araştırılacaktır.

Sonuç olarak çalışmamız doktorların COVID-19 hastalarını tespit etmelerine ve X-Ray göğüs görüntülerinden otomatik olarak tanımlamalarına yardımcı olmak için görüntü dönüştürücülerin, iyi bilinen konvolüsyonel sinir ağı mimarilerine alternatif olarak COVID-19 hastalarına erken tanı koymak, izolasyon sağlamak, tedavinin etkinliğini arttırmak, radyologların iş yükünü hafifletmek ve salgının kontrolünü sağlamak için büyük bir potansiyele sahip olduğunu göstermiştir.

ÇIKAR ÇATIŞMASI

Yazar(lar), bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

YAZAR KATKISI

Dilek Civil çalışmada kullanılan veri kümesine ulaşmış, karşılaştırılan sistemleri geliştirmiş ve deneyleri gerçekleştirmiştir. Özge Öztimur Karadağ çalışmayı tasarlamış, deneyler sonucunda elde edilen sonuçları yorumlamıştır.

KAYNAKLAR

1. Amyar, A., Modzelewski, R., Li, H., ve Ruan, S. (2020) Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia: Classification and segmentation, *Computers in Biology and Medicine*, 126, 104037. doi: 10.1016/j.compbiomed.2020.104037. Epub 2020 Oct 8. PMID: 33065387; PMCID: PMC7543793
2. Ardakani, A. A., Kanafi, A. R., Acharya, U. R., Khadem, N., ve Mohammadi, A. (2020) Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks, *Computers In Biology And Medicine*, 121, 103795. doi: 10.1016/j.compbiomed.2020.103795. Epub 2020 Apr 30. PMID: 32568676; PMCID: PMC7190523.

3. Bercovich, E. ve Javitt, M.C. (2018) Medical Imaging: From Roentgen to the Digital Revolution, and Beyond, *Rambam Maimonides Medical Journal*, 9(4):e0034. <https://doi.org/10.5041/RMMJ.10355>
4. Bozkurt, F., ve Yağanoğlu, M. (2021) Derin Evrişimli Sinir Ağları Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti, *Veri Bilimi*, 4(2), 1-8.
5. Calderon-Ramirez, S., Yang, S., Moemeni, A., Colreavy-Donnelly, S., Elizondo, D. A., Oala, L., ... ve Molina-Cabello, M. A. (2021) Improving uncertainty estimation with semi-supervised deep learning for covid-19 detection using chest x-ray images, *IEEE Access*, 9,85442-85454. doi:10.1109/ACCESS.2021.3085418.
6. Demir, F.B., ve Yılmaz, E. (2021) X-Ray Görüntülerinden COVID-19 Tespiti için Derin Öğrenme Temelli Bir Yaklaşım, *Avrupa Bilim ve Teknoloji Dergisi*, (32), 627-632. doi: 10.31590/ejosat.1039522.
7. Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... ve Houlsby, N. (2020) An image is worth 16x16 words: Transformers for image recognition at scale, ArXiv Preprint, arXiv:2010.11929. doi: 10.48550/arXiv.2010.11929.
8. Güngör, S., Kaya, M. ve Alhadj, R. (2021) Görüntülerinden Covid-19 Tespiti İçin Derin Öğrenmeye Dayalı Bir Yöntem, *Computer Science, Special*: 391-399. doi: doi.org/10.53070/bbd.990750.
9. He, K., Zhang, X., Ren, S., ve Sun, J. (2016) Deep residual learning for image recognition, *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778). doi:10.48550/arXiv.1512.03385.
10. Heidari, M., Mirniaharikandehi, S., Khuzani, A. Z., Danala, G., Qiu, Y., ve Zheng, B. (2020) Improving the performance of CNN to predict the likelihood of COVID-19 using chest X-ray images with preprocessing algorithms, *International journal of medical informatics*, 144, 104284. doi:10.1016/j.ijmedinf.2020.104284.
11. <https://kaggle.com/tawsifurrahman/covid19-radiography-database>, Erişim Tarihi: 04.11.2021, Konu: *COVID-19 Radyografi veri tabanı*.
12. <https://www.kaggle.com/datasets/cf77495622971312010dd5934ee91f07ccbcfdea8e2f7778977ea8485c1914df>, Erişim Tarihi: 04.11.2021, Konu: *COVID-QU-Ex veri tabanı*.
13. <https://github.com/ieee8023/covid-chestxray-dataset>, Erişim Tarihi: 05.11.2021, Konu: *Cohen J.P. Covid-chestxray-dataset veri tabanı*.
14. Jacofsky, D., Jacofsky, E.M. ve Jacofsky, M. (2020) Understanding antibody testing for COVID-19, *J Arthroplasty*, 35(7S):S74-S81, doi: 10.1016/j.arth.2020.04.055, PMID: 32389405; PMCID: PMC7184973.
15. Karaman, O. (2021). Boosting performance of transfer learning model for diagnosis of COVID-19 from computer tomography scans, *Süleyman Demirel Üniversitesi Fen Edebiyat Fakültesi Fen Dergisi*, 16(1), 35-45. doi:10.29233/sdufeffd.830351.
16. Ko, H., Chung, H., Kang, W. S., Kim, K. W., Shin, Y., Kang, S. J., ... ve Lee, J. (2020) COVID-19 pneumonia diagnosis using a simple 2D deep learning framework with a single chest CT image: model development and validation, *Journal of Medical Internet Research*, 22(6), e19569. doi: 10.2196/19569.
17. Korkmaz, A. ve Atilla, B. Ü. (2021) Derin Öğrenme Teknikleriyle Akciğer Röntgeninden Covid-19 Tespiti, *Artificial Intelligence Studies*,4(1), 1-13. doi:10.30855/AIS.2021.01.

18. Kumar, S., Mishra, S., ve Singh, S. K. (2021) Deep transfer Learning-based COVID-19 prediction using chest X-rays, *Journal of Health Management*, 23(4), 730-746. doi:10.1177/09720634211050425.
19. Li, J., Wang, Y., Wang, S., Wang, J., Liu, J., Jin, Q., ve Sun, L. (2021) Multiscale attention guided network for COVID-19 diagnosis using chest X-ray images, *IEEE Journal of Biomedical and Health Informatics*, 25(5), 1336-1346. doi: 10.1109/JBHI.2021.3058293.
20. Narin, A., Kaya, C., ve Pamuk, Z. (2021) Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks, *Pattern Analysis and Applications*, 24(3), 1207-1220. doi:10.1007/s10044-021-00984-y.
21. Özbay, E., ve Özbay, F. A. (2021) Derin Öğrenme ve Sınıflandırma Yaklaşımları ile BT görüntülerinden Covid-19 Tespiti, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(2), 211-219. doi: 10.24012/dumf.812810.
22. Tahamtan, A. ve Ardebili, A. (2020) Real-time RT-PCR in COVID-19 detection: issues affecting the results, *Expert Review Of Molecular Diagnostics Journal*, 20(5):453-454. doi:10.1080/14737159.2020.1757437.
23. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser L. ve Polosukhin, I. (2017) Attention is all you need, *Advances in Neural Information Processing Systems*, 30. doi:10.48550/arXiv.1706.03762.
24. YILMAZ, A. (2021) Çok kanallı CNN mimarisi ile X-Ray görüntülerinden COVID-19 tanısı, *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 36(4), 1761–1774. doi:10.17341/gazimmfd.746883.