

Atıf İçin: Pacal, I. (2023). Göğüs Röntgeni Görüntülerinden Otomatik COVID-19 Teşhisi için Görü Transformatörüne Dayalı Bir Yaklaşım. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(2), 778-791.

To Cite: Pacal, I. (2023). A Vision Transformer-based Approach for Automatic COVID-19 Diagnosis on Chest X-ray Images. *Journal of the Institute of Science and Technology*, 13(2), 778-791.

Göğüs Röntgeni Görüntülerinden Otomatik COVID-19 Teşhisi için Görü Transformatörüne Dayalı Bir Yaklaşım

Ishak PACAL^{1*}

Öne Çıkanlar:

- COVID-19 tespiti
- Akciğer enfeksiyon tespiti

Anahtar Kelimeler:

- COVID-19
- COVID-19 tespiti
- Görü transformatörler
- Akciğer hastalık tespiti
- Derin Öğrenme

ÖZET:

Son yıllarda ortaya çıkan yeni tip Koronavirüs hastalığı (COVID-19), dünya çapında sağlığı tehdit eden ciddi bir hastalık olmuştur. COVID-19 çok hızlı bir şekilde bulaşabilen ve ciddi ölüm artışları ile birçok endişeye zemin hazırlamıştır. Salgının evrensel boyuta taşınmasıyla bu hastalığın erken teşhisine yönelik birçok çalışma yapılmıştır. Erken teşhis ile hem ölümcül vakaların önüne geçilmiş olunmakta hem de salgının planlanması daha kolay olabilmektedir. X-ışını görüntülerinin zaman ve uygulanabilirlik açısından diğer görüntüleme tekniklerine nazaran çok daha avantajlı olması ve ayrıca ekonomik olması erken teşhis bazı uygulama ve yöntemlerin bu görüntülerin üzerine yoğunlaşmasına neden olmuştur. Derin öğrenme yaklaşımları birçok hastalık teşhisinde olduğu gibi COVID-19 teşhisinde de çok büyük bir etki oluşturmuştur. Bu çalışmada, derin öğrenmenin CNN tabanlı yaklaşımları gibi daha önceki tekniklerinden ziyade en güncel ve çok daha popüler bir mimarisi olan transformatör yöntemine dayalı bir teşhis sistemi önerdik. Bu sistem, görü transformatör modelleri temelli bir yaklaşım ve yeni bir veri seti olan COVID-QU-Ex üzerinde COVID-19 hastalığının daha efektif bir teşhisini içermektedir. Deneysel çalışmalarda, görü transformatör modellerinin CNN modellerinden daha başarılı olduğu gözlemlenmiştir. Ayrıca, ViT-L16 modeli %96'nın üzerinde test doğruluğu ve F1-skoru sunarak, literatürde benzer çalışmalara kıyasla çok daha yüksek bir başarıyı göstermiştir.

A Vision Transformer-based Approach for Automatic COVID-19 Diagnosis on Chest X-ray Images

Highlights:

- COVID-19 detection
- Lung infection detection

Keywords:

- COVID-19
- COVID-19 detection
- Vision transformers
- Lung disease detection
- Deep learning

ABSTRACT:

The new type of coronavirus disease (COVID-19), which has emerged in recent years, has become a serious disease that threatens health worldwide. COVID-19, which can be transmitted very quickly and with serious increases in death, has paved the way for many concerns. With the spread of the epidemic to a universal dimension, many studies have been carried out for the early diagnosis of this disease. With early diagnosis, both fatal cases are prevented and the planning of the epidemic can be easier. The fact that X-ray images are much more advantageous than other imaging techniques in terms of time and applicability, and also that they are economical, has led to the focus of early diagnosis-based applications and methods on these images. Deep learning approaches have had a great impact in the diagnosis of COVID-19, as in the diagnosis of many diseases. In this study, we propose a diagnostic system based on the transformer method, which is the most up-to-date and much more popular architecture than previous techniques of deep learning such as CNN-based approaches. This method includes an approach based on vision transformer models and a more effective diagnosis of COVID-19 disease on a new dataset, the COVID-QU-Ex dataset. In experimental studies, it has been observed that vision transformer models are more successful than CNN models. In addition, the ViT-L16 model showed a much higher performance compared to similar studies in the literature, providing test accuracy and F1-score of over 96%.

¹ Ishak PACAL ([Orcid ID: 0000-0001-6670-2169](https://orcid.org/0000-0001-6670-2169)), İğdır Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İğdir, Türkiye

*Sorumlu Yazar/Corresponding Author: İshak PAÇAL, e-mail: ishak.pacal@igdir.edu.tr

GİRİŞ

Koronavirüs hastalığı (COVID-19), 2019 yılında ilk kez Çin Halk Cumhuriyeti'nde ortaya çıkan şiddetli akut solunum sendromu neden olan SARS-CoV-2 tabanlı bir hastalıktır (Ciotti ve ark., 2020). Koronavirüs, öncelikle solunum yollarını ele geçirdikten sonra furin adı verilen bir enzim yoluyla vücut hücrelerini hedef alır ve bağışıklık sistemini düşürmeye çalışan patojenik bir hastalıktır (Pascarella ve ark., 2020a; Kanne ve ark., 2021). Bu hastalık ilk kez yarasalar yoluyla insanlara yayıldığı görülmüştür (Ciotti ve ark., 2020). COVID-19 boğaz ağrısı, göğüs ağrısı, baş ağrısı ve kuru öksürük gibi birçok yaygın semptomlara sahiptir. Son istatistiklere göre 5 milyondan fazla ölüme neden olduğu belirtilmiştir (Revel ve ark., 2020). Hastalığın çok agresif bir yayılma göstermesi nedeniyle birçok ülke kapanmaya yani pandemi sürecine girmiştir. Bu şekilde hastalığın bulaşma eğilimi azalsa da salgın halen az da olsa devam etmektedir. COVID-19'a neden olan patojenin tespiti için PCR (Polymerase chain reaction) testleri genelde kullanılmaktadır fakat bu testler bazen yanıltıcı olabilmektedir (Cleverley ve ark., 2020; Pascarella ve ark., 2020a). COVID-19'un etkili teşhisi ve akciğerlerdeki enfeksiyonun derecesini ölçmek için genellikle öncelikle röntgen ve daha sonra ise gerekli durumlarda bilgisayarlı tomografi (BT) görüntüleri kullanılmaktadır (Fang ve ark., 2020; Xie ve ark., 2020). Böylece, hastalığın kesin teşhisi konulmaktadır. Röntgen ya da diğer adıyla X-ışını görüntüleri BT'ye göre hem sağlık açısından daha az zararlı hem de ekonomik ve daha hızlı bir tekniktir (Cleverley ve ark., 2020; Xie ve ark., 2020).

Alanında uzman hekimler ve radyologlar röntgen ya da BT görüntülerini kullanarak hastalıkların teşhisini koyabilmektedirler. COVID-19 teşhisi için X-ışını görüntüleri verimliliklerinden dolayı çok kullanılmaktadır. Ayrıca, bu görüntüleme yöntemi tıp merkezlerinde kolayca bulunur ve çok kısa bir sürede görüntüleme yapılmaktadır, bu da ona daha efektif bir kullanım avantajlarını artırır. Alanında uzman bir hekim, röntgen görüntüsüne bakarak hastanın COVID-19 ya da akciğer enfeksiyonlarını teşhis edebilir (Cleverley ve ark., 2020). Bazı durumlarda, özellikle hekimin yoğun bir çalışma temposu, anı dalgınlığı ya da ikincil bir hekim olmadığı durumlarda hastaya yanlış teşhis edebilir. Bu yüzden, özellikle radyoloji alanında bilgisayar destekli teşhis sistemleri (CAD) geliştirilmiştir (Pacal ve ark., 2020; Wang ve ark., 2021). Son zamanlarda ise CAD sistemlerinde ciddi gelişmeler olmuştur. Özellikle yapay zekâ alanındaki son gelişmeler, bilhassa derin öğrenme algoritmalarının artan önemi ile birçok yeni gelişmeler literatüre girmiştir (Bayat ve Işık, 2022). Birçok hastalık teşhisinde olduğu gibi, COVID-19 teşhisinde de yapay zekâ en önemli yeri edinmiştir denilebilir (Wang ve ark., 2021).

Yapay zekâ uygulamaları, birçok hastalıkların teşhisinde uzun zamandan beri kullanılmakta ve sürekli gelişen bir alandır. Önceki yıllarda genellikle makine öğrenimi tabanlı yaklaşımlar hem hastalık teşhisinde hem de bilgisayar bilimlerinin birçok alanında kullanılmıştır (Arı ve ark., 2021; Burukanli ve ark., 2021; Bülbül ve ark., 2022). Son yıllarda, özellikle görüntü analizi konusunda, derin öğrenme ile teşhis sistemlerinde çok ciddi bir yer edinmiş ve başarılı sonuçlar vermiştir (Adem ve Kılıçarslan, 2021; Karaman ve ark., 2022; Pacal ve ark., 2022). Derin öğrenme ise yapay zekânın şu an için en popüler ve oldukça önemi artan bir alandır. Derin öğrenme, savunma sanayisi, otonom araç, dil işleme, nesne tespiti ve medikal görüntü işleme gibi birçok alanda başarılarla adından söz ettirmektedir (Gulum ve ark., 2021; Pacal ve Karaboga, 2021; Alici-Karaca ve ark., 2022; Ozkok ve Celik, 2022; Karaman ve ark., 2023). Derin öğrenme klasik makine öğrenimi yaklaşımlarına nazaran, yüksek miktarda veri ile etkili sonuçlar veren ve özellik keşiflerini otomatik bir şekilde yapabilen ve daha nice kompleks başarılı özellikleri barındıran bir disiplindir (Pacal, 2022). Derin öğrenmeye dayalı uygulamalar, tıbbi görüntüleme yaygın olarak kullanılmakla beraber COVID-19'a karşı mücadelede oldukça yoğun bir şekilde kullanılmıştır (Subramanian ve ark., 2022). Birçok sebepten dolayı, sağlık ekibi görüntü analizinde yetersiz kalabilir. Derin öğrenme uygulamaları bu yükü azaltmakla beraber birçok uzman hekimin

deneyimlerini öğrenebilir ve hastalık teşhisinde etkili bir şekilde kullanılabilir. Bu nedenle, COVID19'u daha efektif bir şekilde tespit etmek için X-ışını görüntülerinin daha iyi ve daha hızlı analizi için derin öğrenme modellerine ihtiyaç vardır.

COVID-19 hastalığı teşhisinde son zamanlara kadar genellikle derin öğrenme yöntemlerinin görüntü tabanlı yaklaşımlarından olan ve oldukça popüler olan evrimsel sinir ağları (CNNs) kullanılmıştır (Ibrahim ve ark., 2021). CNN'ler derin öğrenme yaklaşımları en üst seviyeye taşıyan mimarilerin başında gelir. Literatürde CNN yaklaşımları temelli birçok çalışma sunulmuş ve COVID-19 teşhisinde başarılı sonuçlar sunmuştur. Bu çalışmalardan bazıları şu şekildedir. Bhattacharyya ve arkadaşları (Bhattacharyya ve ark., 2022) göğüs röntgen görüntülerini kullanarak COVID-19 teşhisi için bütünlük bir yöntem önerdiler. Önerilen yöntemde ilk adım akciğer görüntülerini elde etmek için koşullu üretken çekişmeli ağ (C-GAN), ikinci adım ise ayırt edici özellik çıkarımı için CNN ağları kullanılırken, son adımda ise sınıflandırma işlemi için birkaç makine öğrenimi algoritmaları kullanılmaktadır. Önerilen yöntem diğer yöntemlere nazaran daha yüksek bir doğruluk sunmaktadır. Yine benzer şekilde, Deb ve arkadaşları (Deb ve ark., 2022) göğüs röntgeninin görüntülerinden oluşan bir yöntemle COVID-19 tespiti yapmışlardır. Önerdikleri yöntem ise topluluk öğrenmeye dayalı bir yöntem olmakla beraber popüler olan VGGNet, GoogleNet, DenseNet ve NASNet gibi ağlar uygulamada kullanılmıştır. Önerdikleri yöntemi iki tane halka açık veri seti ve bir tane özel veri seti üzerine uygulanmıştır. Gafoor ve arkadaşları (Abdul ve ark., 2022) derin öğrenme teknolojilerini COVID-19 teşhisi için önerdiler. Bu çalışmada, derin öğrenme algoritmalarının COVID-19 ile enfekte olmuş hastaları başarılı bir şekilde teşhis ettiği gözlemlenmiştir. Dhiman ve arkadaşları (Dhiman ve ark., 2022) derin öğrenme teknikleri ve optimizasyon algoritmalarını beraber efektif bir şekilde kullanarak X-ışınları üzerinde COVID-19 hastalarının teşhisi için bütünlük bir yöntem önerdiler. Bu yöntem, ResNet, VGG, DenseNet gibi CNN modellerinden oluşurken, deneysel çalışmalarda önerilen yöntemin diğer çalışmalara kıyasla daha başarılı oldukları belirtilmiştir. Sedik ve arkadaşları (Sedik ve ark., 2022) CNN ve LSTM mimarilerini beraber kullanan hibrit bir yapı ile COVID-19 hastalarının teşhisi için bir yöntem önerdiler. Bu yöntemde hem BT ve hem de X-ışını görüntüleri için eğitim ve test aşamaları gerçekleştirilmiştir.

Bu çalışmada, derin öğrenme mimarilerinin son zamanlarda popüler bir alan haline gelen görü tabanlı transformatör (transformer) modellerinin efektif COVID-19 teşhisi için bir yöntem önerilmiştir. Literatürde yapılan nerdeyse bütün çalışmalar CNN tabanlıdır. Son zamanlarda transformatör modellerinin görüntüler için uyarlanması ile CNN'lerden daha efektif sonuçlar elde edilmiştir. Hem yüksek doğruluk sunması hem de çoğu zaman CNN'lerden daha yüksek başarımların sunması ile birçok yeni çalışmada görü transformatör modelleri kullanılmaya başlanmıştır. Bu çalışmada, transformatör modellerinin COVID-19 teşhisindeki başarısı incelenmiş ve transformatör modellerinin detayları ile karşılaştırmaları sunulmuştur. Çalışmanın nesneliği ve diğer yöntemlerle karşılaştırılabilirliği için halka açık bir veri seti kullanılmıştır. Yapılan deneysel çalışmalarda, görü transformatörlerinin CNN yaklaşımlarından daha başarılı olduğu ve COVID-19 teşhisinde başarılı bir performans ve genelleme yeteneği sunduğu görülmüştür. Çalışma, medikal görüntü işlemede transformatör yapılarının başarımını ve genelleme kabiliyetini ölçmektedir. Makalenin geri kalanı şu şekildedir. Bölüm 2'de transformatör yapılarının detaylı bir açıklaması, kullanılan halka açık veri seti ve önerilen metod sunulmaktadır. Bölüm 3, deneysel sonuçları, değerlendirme metrikleri ve kullanılan sistemden bahsederken, Bölüm 4 ise önerileri ve sonuçları verilmektedir.

MATERYAL VE METOT

Transformatör yapısı

Derin öğrenme ailesinin en popüler yaklaşımlarından olan transformer ya da transformatörler, doğal dil işleme (NLP) alanında başarılı görevler elde etmiştir (Dosovitskiy ve ark., 2020). Son yıllarda, Transformatörler, Dosovitskiy ve arkadaşları tarafından, derin öğrenme mimarilerinin en önemli görevlerinden olan görüntü işlemeye uygulamışlardır (Dosovitskiy ve ark., 2020). Görüntü işleme alanında başarılı sonuçlar elde eden transformatörler, hızlıca birçok alanda kendine yer edindi. Transformatörler, dikkat mekanizmalarına dayanan basit bir ağ içerir ve bu şekilde girdilerin sadece bazı kısımlarına odaklanma gerçekleşir. Doğal dil işlemede gerçekleştirilen işlemlere benzer şekilde girdi yani görüntü bir kelime gibi birden çok yamalara bölünür (Dosovitskiy ve ark., 2020). Bir dizi doğrusal işlemlerinden sonra bu yamalar girdi olur. Görüntüleri girdi olarak ele alan ilk transformatör mimarisi olan görü transformatör (ViT), saf bir transformatör uygulamak için yapılan ilk büyük girişimdir. Orijinal transformatör modeli hem kodlayıcı hem de kod çözücünün bir kombinasyonunu içerirken, ViT modelinin yapısında sadece bir kodlayıcı yer almaktadır. Görü transformatörlerin işleyişi doğal dil işleyişine oldukça benzerdir. ViT mimarisinde giriş görüntüsü I olarak ele alınır; I görüntüsü $R^{H \times W \times C}$ şeklinde ifade edilir. Bu görüntü daha sonra $P \times P \times C$ boyutunda N tane görüntü yamasına bölünür. N ise matematiksel olarak Eşitlik 1'deki gibi ifade edilir.

$$N = \frac{HW}{p^2} \quad (1)$$

Burada, H görüntünün yüksekliğini, W genişliğini, P yama boyutunu ve C ise kanal sayısını ifade eder. N parçaya bölünen görüntü yamaları düzleştirilir ve bu yamalar doğrusal bir gömme işlemine tabi tutulur. Daha sonra ise yamaların konum bilgisinin saklanması için konum gömme işlemi uygulanır. Görü transformatörlerin işleyişi doğal dil işleyişine benzer şekilde devam eder. ViT mimarisi genel olarak, bir gömme katmanı, kodlayıcı katmanı ve sınıflandırıcı katmandan oluşmaktadır. Bu yapı şekil 1'de görselleştirilmiştir.

Gömme katmanı: Bu katmanda, her bir yama ayrı bir belirteç olarak işlenir ve bu yamalar öğrenilebilir bir doğrusal izdüşüm olan E ve D boyutlarına eşleşme yapar. Gömülü projeksiyonlar, öğrenilebilir bir sınıf belirteci olan U_{class} ile birleştirilir. U_{class} ise sınıflandırma sürecini tamamlayan öğrenilebilir bir belirteçtir. Konumsal gömme, E_{pos} , her bir yamanın düzenini izler ve bunları sürdürmeyi sağlar, böylece gerçek görüntü tanımlanmaya çalışılır. Yama kodlu seri, Z_0 belirteci ile aşağıdaki Eşitlik 2'deki gibi matematiksel olarak ifade edilmiştir.

$$Z_0 = [U_{class}; X_p^1 E; X_p^2 E; \dots; X_p^N E] + E_{pos} \quad (2)$$

Kodlayıcı katmanı: Transformatör kodlayıcı, daha önce elde edilen bir dizi gömülü yamalar olan Z_0 serisini almak için kullanılır. Görü transformatörlerde kodlayıcı birimi L özdeş katmandan oluşmaktadır. L özdeş katman ise çok başlı bir öz-dikkat bloğu (MSA) (Eşitlik 3) tam bağlantılı bir ileri beslemeli yoğun blok (MLP) (Eşitlik 4) yapılarından oluşmaktadır. MSA bloğu, transformatör kodlayıcının temel ögesidir ve kendi kendine dikkat ve birleştirme katmanlarını içerir. Bloklar iki yoğun katmandan oluşur ve bunu GeLU aktivasyonu takip eder. Bu kısımda, kodlayıcıda bir atlama bağlantısı kullanılır ve çıktıdan önce katman normalizasyonu (LN) gelir.

$$Z'_1 = \text{MSA}(\text{LN}(Z_{l-1})) + Z_{l-1}, l = 1 \dots L \quad (3)$$

$$Z_1 = \text{MLP}(\text{LN}(Z'_1)) + Z'_1, l = 1 \dots L \quad (4)$$

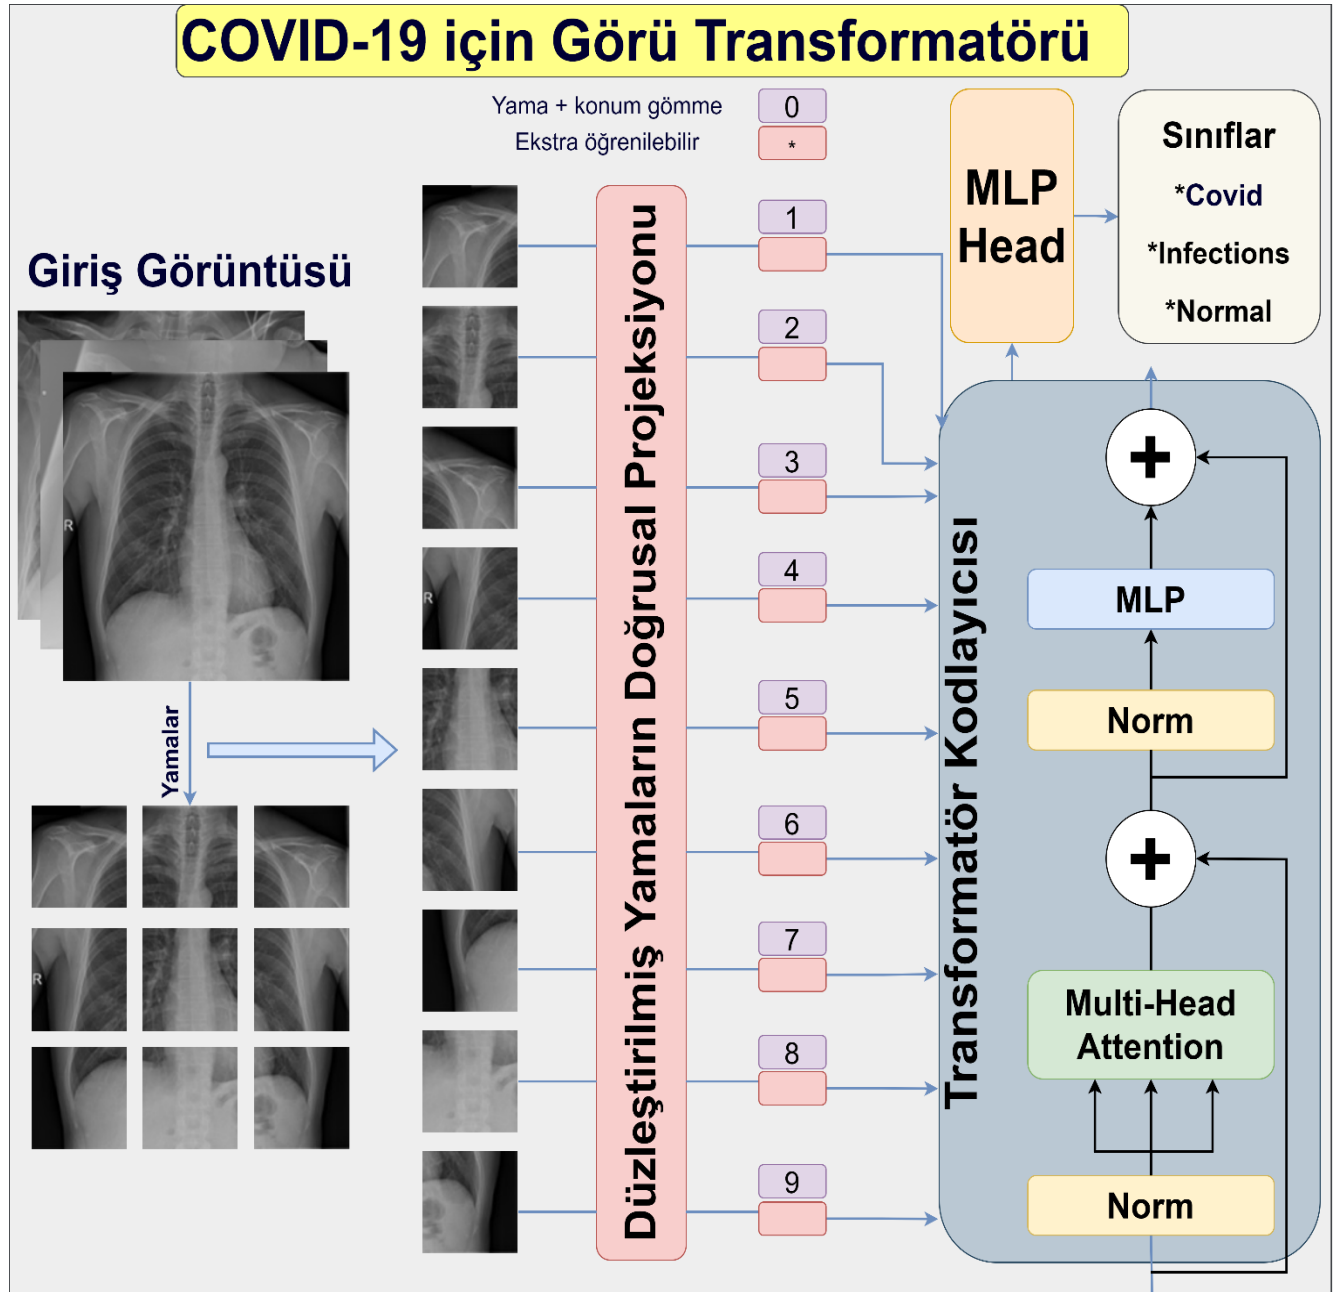
Transformatör kodlayıcısındaki MSA çıkışı, içindeki birkaç öz-dikkat başlığın sıralanmasından elde edilir. Matematiksel olarak, öz-dikkat, Eşitlik 5'te gösterilmiştir.

$$H = \text{Atten}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{D_K}}\right)V \quad (5)$$

Eşitlik 5'te, matris çarpımlarında sonra elde edilen sorgu, Q, anahtar ise K, ve değer matrisi ise V ile temsil edilir. Görü transformatörlerinde MSA'nın son çıktısı, tüm öz-dikkat kafalarının sıralanmasının doğrusal bir katmandan geçirilmesiyle elde edilir. Bu doğrusal katman Eşitlik 6'da matematiksel olarak ifade edilmiştir.

$$\text{MSA}(Q, K, V) = [H_1, H_2, \dots, H_h]W_0 \quad (6)$$

W_0 , öğrenilebilir çıktı dönüşüm matrisidir iken, H ise öz-dikkat kafaların sayısını temsil eder.



Şekil 1. Görü transformatör mimarisinin genel yapısı

Sınıflandırma katmanı: Sınıflandırma işleminin yapıldığı bu birimde, Z_l^0 ögesi öncelikle alınır ve daha sonra ise kodlayıcı sınıflandırma için son katmanını tahmin etmek için harici diğer bir baş sınıflandırıcı ile beslenir. Bu işlem Eşitlik 7'de matematiksel olarak ifade edilmiş ve burada y modelin çıktısı iken Z_l^0 ise karar için alınan ilk öğedir.

$$y = \text{katman normalizasyonu}(Z_i^0) \quad (7)$$

Bu çalışmada, akciğer röntgen görüntülerinden COVID-19 teşhisi için üç farklı transformatör tabanlı model uygulanmıştır. Her bir görü transformatör modeline ait detaylar Tablo 1’de gösterilmiştir. ViT-B modeli; ViT-B16 ve ViT-B32 olmak üzere iki farklı modelden oluşmaktadır. Aslında ViT-B modeli yani temel modelin yama boyutları 16x16 ya da 32x32 olarak değiştirilerek iki model elde edilmektedir fakat 12 katman sayısında herhangi bir değişiklik yapılmamıştır. Aynı şekilde ViT-L yani büyük modelde ise ViT-L16 ve ViT-L32 modelleri yama sayısı değiştirilerek elde edilmiştir. ViT-H modeli yani daha büyük model ise RTX-2080-TI ekran kartında çalışmadığı için yani en düşük küme boyutu 1 seçilmesine rağmen GPU yetersiz kaldığından dolayı çalışmada kullanılmamıştır. Yine Tablo 1’de görüldüğü üzere MLP boyutu temel modelde 3072 iken, yüksek modelde ise 5120 gibi daha büyük bir boyuta çıkmıştır. Bilindiği üzere, büyük-ölçekli veri olması durumunda büyük modeller daha efektif sonuçlar sunmaktadır.

Çizelge 1. Görü transformatör modellerine ait veriler

Model	Katman sayısı	MLP boyutu	Gizli katman	Parametre sayısı (M)
ViT-B	12	3072	768	86
ViT-L	24	4096	1024	307
ViT-H	32	5120	1280	632

Veri seti


Bir derin öğrenme mimarisinin istenilen başarıyı göstermesinde kuşkusuz ki veri setinin önemi tartışılmaz bir mahiyettedir. Klasik makine öğrenimi yaklaşımları elle öznitelik çıkarması ve küçük verilere odaklanırken, derin öğrenme mimarilerinde veri setinin büyük ölçekli olması ve özniteliklerin otomatik çıkartılması iki yaklaşım arasındaki en ciddi farkların başında gelmektedir. Son yıllarda hastane ve araştırma merkezlerinde artan tıbbi görüntüler derin öğrenmenin tıbbi görüntü işlemede etkili yöntem olmasını sağlamıştır çünkü derin öğrenme mimarilerinde doğasında veriye aç bir öznitelik bulunmaktadır. Bu çalışmada, halka açık COVID-19 veri seti kullanılarak deneysel sonuçların ve tartışmanın daha objektif olması amaçlanmıştır. Literatürde halka açık birkaç veri seti olmasına rağmen, ortak bir değerlendirme kurallarının olmamasıdır. Bu durumu göz önüne aldığımızda, COVID-QU-Ex (Tahir ve ark., 2021) hem ortak bir değerlendirme kuralı içermektedir hem de eğitim, validasyon ve test klasörlerinin kendine ait X-ışını görüntüleri bulunmaktadır. Böylece, eğitilip test edilen modelin gerçek başarıyı test verisi üzerinde değerlendirilebilecek hem de diğer güncel yöntemlerle başarıyı karşılaştırılabilecektir. Bu veri setine ait görüntülerin eğitim, validasyon ve test verisine ait detayları Tablo 2’de gösterilmektedir.

Çizelge 2. COVID-QU-Ex veri setine ait detaylar

Sınıf Tipi	Eğitim setindeki görüntü sayısı	Doğrulama setindeki görüntü sayısı	Test setindeki görüntü sayısı
COVID-19	7658	1903	2395
COVID dışı enfeksiyon (viral veya bakteriyel pnömoni)	7208	1802	2253
Normal (sağlıklı)	6849	1712	2140

COVID-QU-Ex veri setinde derin öğrenme yaklaşımlarının eğitim ve değerlendirme görüntüleri önceden ayrılmış olarak gelmektedir. Böylesi bir durumun en büyük avantajı, çalışmanın diğer çalışmalarda kolay bir şekilde karşılaştırılabilir olması ve modelin gerçek performansının ölçülebilir olmasıdır. COVID-QU-Ex veri seti farklı veri setlerinden alınan görüntülerin oluşan ve genişletilmiş

halka açık bir veri setidir. Bu veri setinde 11.956 COVID-19 vakası, 11.263 COVID dışı enfeksiyon (viral veya bakteriyel pnömoni) vakası ve 10.701 Normal (sağlıklı) vaka bulunmaktadır. Tablo 1’den de görüleceği üzere, eğitim, validasyon ve test verilerindeki sınıf dağılımları iyi bir şekilde ayarlanmış ve herhangi bir veri dengesizliği (data imbalance) bulunmamaktadır. Böylece, model veri setindeki her bir sınıfı daha iyi bir şekilde öğrenmeye çalışacak, herhangi bir sınıfa yönelme durumu azalacaktır. COVID-QU-Ex veri setindeki rastgele alınmış bazı örnek görüntüler Şekil 2’de gösterilmiştir.




Şekil 2. COVID-QU-Ex veri setindeki sınıflara ait bazı örnek görüntüler

Önerilen Yöntem

COVID-19 hastalığının otomatik bir şekilde tespit edilmesi için önerilen sistem temelde üç parçadan oluşmaktadır. Şekil 3, önerilen sistemin temel bileşenlerini göstermektedir. Derin öğrenme yöntemlerinin medikal görüntü işlemedeki başarısını göğüs röntgen görüntülerine uyarlayarak daha efektif bir sistem önerilmiştir. Üç parçadan oluşan derin öğrenme tabanlı bu sistemin ilk parçasını veri seti birimi oluşturmaktadır. 33920 görüntüden oluşan veri seti derin öğrenme yaklaşımları için ideal bir veri setidir. Ayrıca her sınıf başına 10000’den fazla görüntü düştüğü ve veri dengesizliğinin olmaması ile beraber oldukça etkili bir veri setidir denilebilir. Veri setinden sonraki birim ise veri ön-işleme ve veri artırma tekniklerinin beraber olduğu birimdir. Bu birimde temel amaç veri setindeki görüntülerin aynı boyuta indirgenmesi ve bazı temel veri artırma tekniklerinin uygulanmasıdır. Veri setindeki görüntü sayısı yeterli olduğu için eğitim esnasında çevirme, döndürme ve kaydırma gibi en temel veri artırma teknikleri uygulanmıştır. Büyük ölçekli veri setlerinde veri artırma çok etkili olmasa da başarıma katkısı olurken, küçük ölçekli ve çeşitliliğin az olduğu veri setlerinde ise veri artırma oldukça etkilidir. Önerilen yöntemin son birimini ise derin öğrenme yaklaşımlarının olduğu birimdir. Bu birimde öğrenme aktarımı ve sınıflandırma için görü transformatörü yer almaktadır. Transfer öğrenme ya da öğrenme aktarımı bir alanda eğitilen bir modelin ağırlıklarının farklı bir alan için kullanılması yani ağırlıkların aktarılması işlemidir. Bu çalışmada, ImageNet (Russakovsky ve ark., 2015) veri seti üzerinde eğitilen görü transformatörlerin ağırlıkları COVID-19 veri seti için kullanılmıştır. Öğrenme aktarımı özellikle küçük ölçekli veri setlerinde çok ciddi performans sağlar. Bu veri setimizde hem performansa hem de yakınsamanın sıfırdan eğitime göre daha hızlı olmasını sağlamıştır. Öğrenme aktarımında sonra

sınıflandırma için görü transformatörleri kullanıldı. Bu mimari materyal ve metot kısmında detaylıca anlatılmıştır. Ayrıca, önerilen yöntemin karşılaştırılabilir bir düzeyde olması için temel başlangıç hiperparametreleri kullanılmıştır. Yani, optimize edici için SGD, öğrenme adımı 0.001 ve 0.9 momentum oranı kullanılmıştır. Daha önce belirtildiği üzere veri artıma için ise en temel teknikler kullanılmıştır.



Şekil 3. Önerilen yöntemin genel bir yapısı

BULGULAR VE TARTIŞMA

Uygulama detayları

Derin öğrenme algoritmalarının başarılı bir şekilde eğitim gerçekleştirmesi GPU tabanlı bilgisayardan oluşması gereklidir. GPU'lar içerisindeki CUDA çekirdekleri sayesinde paralel işlem yapabilme ve tensör işlemlerini CPU'ya göre daha hızlı bir şekilde yapabilme kabiliyetlerine sahiptirler. Bu çalışmamızda gerçekleştirilen deneyler şu donanımlara sahip bir bilgisayardan oluşmaktadır. İşletim sistemi olarak Linux tabanlı Ubuntu 22.04, GPU donanımı olarak, NVIDIA RTX 2080TI (11 GB GDDR6 ve 4352 CUDA çekirdekli) grafik kartı, Intel Core i9 9900X (10 çekirdekli 3.50 GHz, 19.25 MB Intel® Smart Önbellek) işlemci ve son olarak ise 32 GB DDR4 RAM'dan oluşmaktadır. Programlama dili olarak Python, derin öğrenme çerçevesi olarak PyTorch kullanılmıştır.

Değerlendirme metrikleri

Başarım metrikleri bir modeli birçok farklı açıdan değerlendirmeye çalışır. Nesne sınıflandırma algoritmaları ya da mimarilerinde genellikle doğruluk, kesinlik, duyarlılık ve F1-skoru gibi en temel metrikler yaygın bir şekilde kullanılmaktadır. Bu metriklerin hesaplanmasında ise doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif değerlerinin bilinmesi ile elde edilir. Bu değerler genelde karışıklık matrisinin de temelini oluşturur. Doğru pozitif gerçekte pozitif sınıfta yer alan ve doğru bir şekilde tahmin edilen kısımları oluşturur. Doğru negatif ise aynı şekilde negatif sınıfta yer alan ve doğru tahminin yapıldığı durumu gösterir. Yanlış pozitif gerçekte pozitif sınıfın yanlış bir şekilde tahmin edildiği durum iken, yanlış negatif ise modelin yanlış sınıfı tahmin ettiği durumu gösterir. Doğruluk, doğru tahminlerin toplam tahmin sayısına oranını ifade eder. Kesinlik doğru pozitif tahminlerin toplam pozitif tahminlere olan oranını vermektedir. Duyarlılık metriği olarak da bilinen Geri Çağırma, belirli bir gerçek sınıftaki doğru pozitif tahminlerin toplam tahminlere oranını vermektedir. F1-skoru ise kesinlik ve duyarlılık metriklerinin arasındaki ağırlıklı ortalamanın sonucunda elde edilir. Bu metriklerin matematiksel hesaplamaları şu şekilde formülize edilmiştir.

$$\text{Doğruluk} = \frac{\text{Doğru tahmin sayısı}}{\text{Toplam tahmin sayısı}} \quad (8)$$

$$\text{Kesinlik} = \frac{\text{Doğru pozitif}}{\text{Doğru pozitif} + \text{Yanlış pozitif}} \quad (9)$$

$$\text{Duyarlılık} = \frac{\text{Doğru pozitif}}{\text{Doğru pozitif} + \text{Yanlış negatif}} \quad (10)$$

$$\text{F1 - skor} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (11)$$

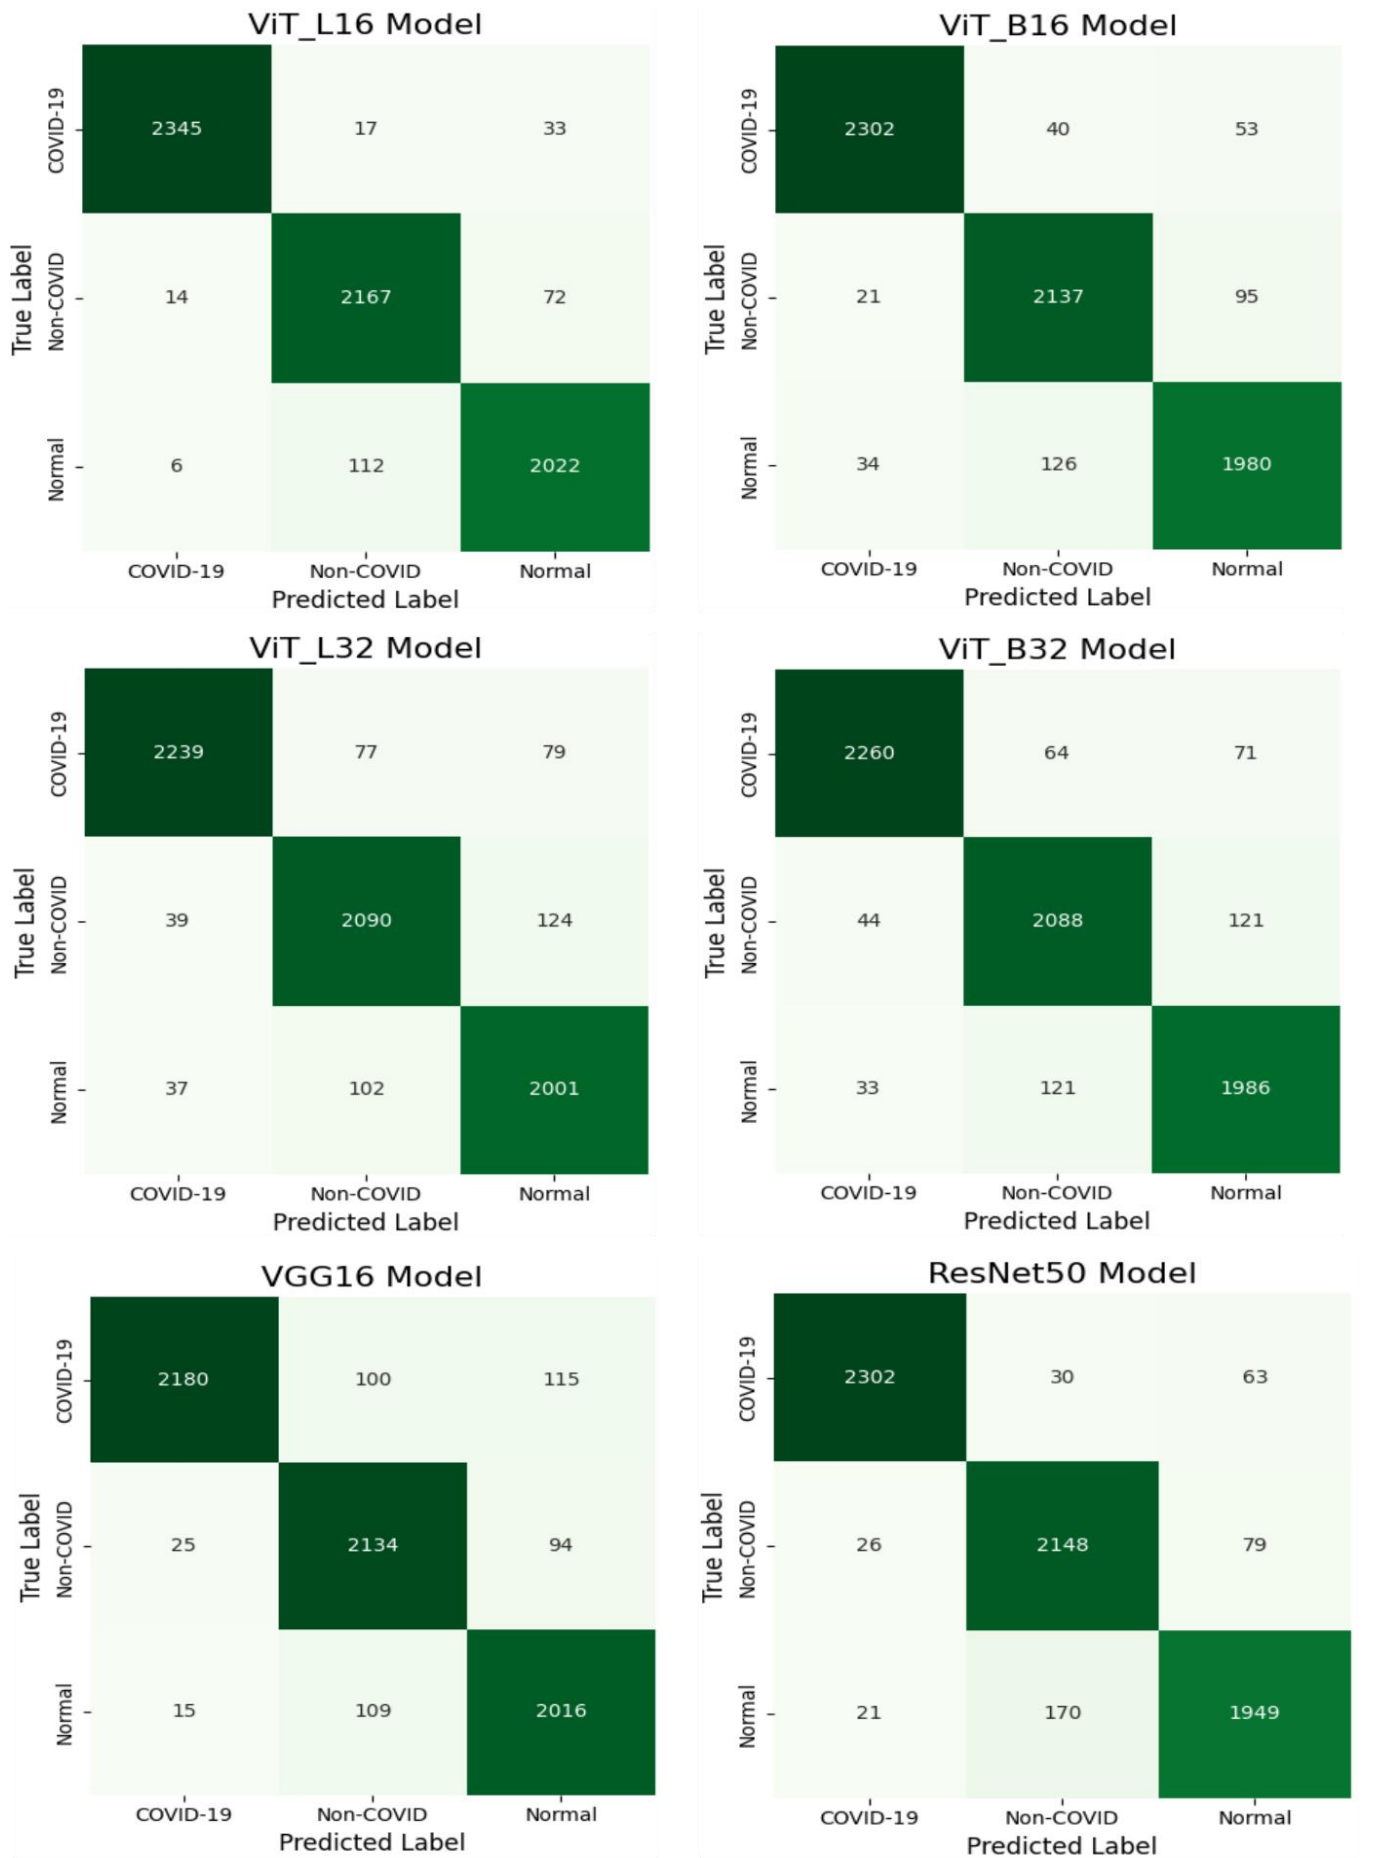
Deneysel sonuçlar

Yapılan deneysel çalışmada, her bir modelin başlangıç değerleri kullanılarak eğitim ve değerlendirme gerçekleştirilmiştir. Transformatör modellerinin başarımını CNN modelleriyle karşılaştırmak için VGG (Simonyan ve Zisserman, 2015) ve ResNet (He ve ark., 2016) modellerine ait deneysel sonuçlar da çalışmaya eklenmiştir. Modellerin eğitimi için öğrenme adımı 0.001, momentum 0.9, optimize edici için SGD ve eğitimdeki görüntü boyutu olarak ise 224x224 kullanıldı. Böylece, herhangi bir hiper-parametre optimizasyonu olmadan modellerin birbirlerine göre başarımları daha objektif bir şekilde karşılaştırılmış olmaktadır.

Şekil 4, çalışmada kullanılan her bir modele ait karışıklık (hata) matrisini göstermektedir. Karışıklık matrisinin x eksenini tahmin edilen sınıfı (predicted label), y eksenini gerçek sınıfı (True Label) göstermektedir. Karışıklık matrisi sayesinde her bir sınıfa ait doğru ve yanlış pozitif ve negatif değerleri görmemize ve böylece daha iyi bir gözlem yapma olanağı sunar. Tablo 3 ise her bir modele ait deneysel sonuçları göstermektedir.

Çizelge 3. Eğitilen modellerin test verisi üzerindeki başarımını gösteren metrik değerleri

Model	Doğruluk	Kesinlik	Duyarlılık	F1-skor
VGG16	0.9325	0.9329	0.9332	0.9331
ResNet50	0.9427	0.9423	0.9418	0.9421
ViT-B16	0.9456	0.9450	0.9450	0.9450
ViT-B32	0.9331	0.9325	0.9328	0.9327
ViT-L16	0.9626	0.9620	0.9619	0.9620
ViT-L32	0.9325	0.9321	0.9325	0.9323



Şekil 4. Çalışmada uygulanan her bir modele ait karışıklık matrisi

Tablo 3 incelendiğinde, bütün modellerinin başarılı sonuçlar verdiği gözlemlenmektedir. CNN tabanlı yaklaşımlardan olan VGG16 ve ResNet50'in metrik değerlerine bakıldığında, ResNet50'nin daha başarılı olduğu görülmektedir. Diğer taraftan, transformatör tabanlı modellerin CNN yaklaşımlarına göre daha başarılı olduğu görülmektedir. ViT temel modeli (ViT-B16), ViT büyük modeline (ViT-L16) göre daha az başarı sunmaktadır. Bunun temel nedeni her bir modelin farklı veri setleri üzerindeki başarısının farklılık göstermesidir ve ayrıca COVID veri setinin büyük ölçekli olmasından dolayı, büyük modellerin daha yüksek bir başarı sunmasıdır. Yani, ViT-L (large) modeli düşük yama boyutu olan 16 ile daha yüksek doğruluk sunmaktadır. Yine Tablo 3 incelendiğinde, ViT-B ve ViT-L modelleri kendi içerisinde karşılaştırıldığında yama boyutu 16 olan (patch = 16) olan modellerin yüksek yama yani 32'ye göre daha yüksek bir doğruluk sunduğu görülmektedir. Genel olarak özetlenirse, COVID-19 veri seti için düşük yamaya sahip modeller daha başarılı sonuçlar sunmuştur. ViT-L32 modeli diğer bütün modellere kıyasla en düşük başarıyı verdiği görülürken ViT-L16 modeli ise en yüksek başarıyı sunarken, diğer taraftan CNN tabanlı VGG16 ise ViT-L32'ye sonra en düşük doğruluğu sunmaktadır. Ayrıca VGG16 ve ViT-L32 modellerinin başarıyı aynıdır denilebilir çünkü F1-skoru ve doğruluk değerleri neredeyse aynıdır. Metrik bazında bakıldığında, doğruluk, kesinlik, hatırlama ve F1-skor gibi metriklerin hepsinde ViT-L16 modeli çok daha yüksek ve büyük bir farkla diğer modellere göre daha yüksek bir başarı sunmuştur.

Şekil 4 incelendiğinde, ViT-L16 modelinin diğer modellere kıyasla çok daha başarılı bir sınıflandırma gerçekleştirdiği görülmektedir. Toplamda 6788 tane test görüntüsü içeren bu veri setinde, ViT-L16 modeli toplamda 6537 tane test görüntüsü doğru tespit ederken 254 tane görüntüyü ise yanlış sınıflandırmıştır. Sınıf bazında bakıldığında, COVID-19 sınıfı enfeksiyon ve normal sınıfa göre daha iyi tespit edilmiştir. Aynı zamanda, diğer modeller bazında da en iyi tespit edilen sınıf COVID-19 sınıfıdır. Normal görüntülerden oluşan sınıf ise diğer sınıflara nispeten daha az tespit edilmiştir. COVID-19 sınıfı dikkate alındığı, başarıyı en düşük model VGG16 modeli iken, enfeksiyon sınıfında ise en az tespit edilen sınıf ise 2088 doğru tespitle ViT-B32 modeli olmuştur. Kısaca özetlemek gerekirse, ViT-L16 modeli bütün sınıflarda ve metriklerde en yüksek başarıyı elde ederken, VGG16 ise en düşük başarıyı göstermiştir. Sonuç olarak COVID-QU-Ex gibi büyük ölçekli bir veri setinde 16 yama ile büyük görü transformatör modelleri CNN modellerine kıyasla daha başarılı bir sınıflama gerçekleştirmiştir.

SONUÇ

Koronavirüs hastalığı (COVID-19) tüm dünyadaki toplumlarda çok hızlı yayılmış ve çok yüksek ölüm oranlarına ulaşmış ölümcül bir hastalıktır. Tıbbi görüntüleme tekniklerinin bu hastalığın ilerleyişinde ve teşhisinde en etkin araç olduğu kanıtlanmıştır. Derin öğrenme COVID-19 teşhisinde oldukça başarılı sonuçlar vermiş ve bu konu üzerine birçok çalışma sunulmuş. Akciğer röntgen görüntüleri COVID-19 teşhisinde kullanılan en hızlı ve ekonomik görüntüleme tekniğidir. Bu çalışmada, derin öğrenme yaklaşımlarının son günlerde en popüler yaklaşımı olan görü transformatör mimarisi COVID-19'un daha etkin bir şekilde teşhisi için uygulanmıştır. Görü transformatörleri halka açık yeni ve popüler bir veri seti olan COVID-QU-Ex ile eğitilmiş ve değerlendirilmiştir. Deneysel çalışmalarda ViT-L16 modelinin hem CNN hem de diğer transformatör modellerine kıyasla çok daha yüksek başarı gösterdiği gözlemlenmiştir. Böyle güçlü modellerin klinik ortama aktarılması ve yaygın bir şekilde kullanılması teşhisin daha erken bir şekilde ve sağkalım oranında artış sağlayacağı öngörülmektedir. Bir sonraki çalışmalarda, özellikle yeni görü transformatör modellerinin COVID-19 teşhisi ya da akciğer enfeksiyon teşhisi için yapılandırılmış mimarileri ele alınıp performansları değerlendirilecektir.

KAYNAKLAR

- Abdul Gafoor, S., Sampathila, N., Madhushankara, M., & Swathi, K. S. (2022). Deep learning model for detection of COVID-19 utilizing the chest X-ışını images. *Cogent Engineering*, 9(1). <https://doi.org/10.1080/23311916.2022.2079221>
- ADEM, K., & KILIÇARSLAN, S. (2021). COVID-19 Diagnosis Prediction in Emergency Care Patients using the Convolutional Neural Network. *Afyon Kocatepe University Journal of Sciences and Engineering*, 21, 300–309. <https://doi.org/10.35414/akufemubid.788898>
- Alici-Karaca, D., Akay, B., Yay, A., Suna, P., Nalbantoglu, O. U., Karaboga, D., ... Baran, M. (2022). A new lightweight convolutional neural network for radiation-induced liver disease classification. *Biomedical Signal Processing and Control*, 73. <https://doi.org/10.1016/j.bspc.2021.103463>
- ARI, D., & ALAGÖZ, B. B. (2021). A Review of Genetic Programming Popular Techniques, Fundamental Aspects, Software Tools and Applications. *Sakarya University Journal of Science*. <https://doi.org/10.16984/saufenbilder.793333>
- Bayat, S., & Işık, G. (2022). Recognition of Aras Bird Species From Their Voices With Deep Learning Methods. *Journal of the Institute of Science and Technology*, 12(3): 1250 - 1263.
- Bhattacharyya, A., Bhaik, D., Kumar, S., Thakur, P., Sharma, R., & Pachori, R. B. (2022). A deep learning based approach for automatic detection of COVID-19 cases using chest X-ışını images. *Biomedical Signal Processing and Control*, 71. <https://doi.org/10.1016/j.bspc.2021.103182>
- Burukanlı, M., Çibuk, M., & Budak, Ü. (2021). Saldırı Tespiti için Makine Öğrenme Yöntemlerinin Karşılaştırmalı Analizi Comparative Analysis of Machine Learning Methods for Intrusion Detection. In *BEU Journal of Science* (Vol. 10).
- Bülbül, M. A., & Öztürk, C. (2022). Optimization, modeling and implementation of plant water consumption control using genetic algorithm and artificial neural network in a hybrid structure. *Arabian Journal for Science and Engineering*, 47(2), 2329-2343.
- Ciotti, M., Ciccozzi, M., Terrinoni, A., Jiang, W. C., Wang, C. bin, & Bernardini, S. (2020). The COVID-19 pandemic. *Critical Reviews in Clinical Laboratory Sciences*, pp. 365–388. Taylor and Francis Ltd. <https://doi.org/10.1080/10408363.2020.1783198>
- Cleverley, J., Piper, J., & Jones, M. M. (2020, July 16). The role of chest radiography in confirming covid-19 pneumonia. *The BMJ*, Vol. 370. BMJ Publishing Group. <https://doi.org/10.1136/bmj.m2426>
- Deb, S. D., Jha, R. K., Jha, K., & Tripathi, P. S. (2022). A multi model ensemble based deep convolution neural network structure for detection of COVID19. *Biomedical Signal Processing and Control*, 71. <https://doi.org/10.1016/j.bspc.2021.103126>
- Dhiman, G., Chang, V., Kant Singh, K., & Shankar, A. (2022). ADOPT: automatic deep learning and optimization-based approach for detection of novel coronavirus COVID-19 disease using X-ışını images. *Journal of Biomolecular Structure and Dynamics*, 40(13), 5836–5847. <https://doi.org/10.1080/07391102.2021.1875049>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... Houlsby, N. (2020). *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale*. Retrieved from <http://arxiv.org/abs/2010.11929>
- Fang, Y., Zhang, H., Xie, J., Lin, M., Ying, L., Pang, P., & Ji, W. (2020, August 1). Sensitivity of chest CT for COVID-19: Comparison to RT-PCR. *Radiology*, Vol. 296, pp. E115–E117. Radiological Society of North America Inc. <https://doi.org/10.1148/radiol.2020200432>

- Gulum, M. A., Trombley, C. M., & Kantardzic, M. (2021). A review of explainable deep learning cancer detection models in medical imaging. *Applied Sciences (Switzerland)*, 11(10). <https://doi.org/10.3390/app11104573>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Ibrahim, D. M., Elshennawy, N. M., & Sarhan, A. M. (2021). Deep-chest: Multi-classification deep learning model for diagnosing COVID-19, pneumonia, and lung cancer chest diseases. *Computers in Biology and Medicine*, 132, 104348. <https://doi.org/10.1016/j.compbiomed.2021.104348>
- Kanne, J. P., Bai, H., Bernheim, A., Chung, M., Haramati, L. B., Kallmes, D. F., ... Sverzellati, N. (2021, June 1). COVID-19 imaging: What we know now and what remains unknown. *Radiology*, Vol. 299, pp. E262–E279. Radiological Society of North America Inc. <https://doi.org/10.1148/radiol.2021204522>
- Karaman, A., Karaboga, D., Pacal, I., Akay, B., Basturk, A., Nalbantoglu, U., Sahin, O. (2022). Hyper-parameter optimization of deep learning architectures using artificial bee colony (ABC) algorithm for high performance real-time automatic colorectal cancer (CRC) polyp detection. *Applied Intelligence*. <https://doi.org/10.1007/s10489-022-04299-1>
- Karaman, A., Pacal, I., Basturk, A., Akay, B., Nalbantoglu, U., Coskun, S., Sahin, O., & Karaboga, D. (2023). Robust real-time polyp detection system design based on YOLO algorithms by optimizing activation functions and hyper-parameters with artificial bee colony (ABC). *Expert Systems with Applications*, 221. <https://doi.org/10.1016/j.eswa.2023.119741>
- Ozkok, F. O., & Celik, M. (2022). A hybrid CNN-LSTM model for high resolution melting curve classification. *Biomedical Signal Processing and Control*, 71, 103168. <https://doi.org/10.1016/J.BSPC.2021.103168>
- PACAL, İ. (2022). Deep Learning Approaches for Classification of Breast Cancer in Ultrasound (US) Images. *Journal of the Institute of Science and Technology*, 1917–1927. <https://doi.org/10.21597/jist.1183679>
- Pacal, I., & Karaboga, D. (2021). A robust real-time deep learning based automatic polyp detection system. *Computers in Biology and Medicine*, 134. <https://doi.org/10.1016/J.COMPBIOMED.2021.104519>
- Pacal, I., Karaboga, D., Basturk, A., Akay, B., & Nalbantoglu, U. (2020). A comprehensive review of deep learning in colon cancer. *Computers in Biology and Medicine*, 126. <https://doi.org/10.1016/J.COMPBIOMED.2020.104003>
- Pacal, I., Karaman, A., Karaboga, D., Akay, B., Basturk, A., Nalbantoglu, U., & Coskun, S. (2022). An efficient real-time colonic polyp detection with YOLO algorithms trained by using negative samples and large datasets. *Computers in Biology and Medicine*, 141. <https://doi.org/10.1016/J.COMPBIOMED.2021.105031>
- Pascarella, G., Strumia, A., Piliago, C., Bruno, F., del Buono, R., Costa, F., ... Agrò, F. E. (2020a, August 1). COVID-19 diagnosis and management: a comprehensive review. *Journal of Internal Medicine*, Vol. 288, pp. 192–206. Blackwell Publishing Ltd. <https://doi.org/10.1111/joim.13091>
- Pascarella, G., Strumia, A., Piliago, C., Bruno, F., del Buono, R., Costa, F., ... Agrò, F. E. (2020b, August 1). COVID-19 diagnosis and management: a comprehensive review. *Journal of Internal Medicine*, Vol. 288, pp. 192–206. Blackwell Publishing Ltd. <https://doi.org/10.1111/joim.13091>

- Revel, M.-P., Parkar, A. P., Prosch, H., Silva, M., Sverzellati, N., Gleeson, F., & Brady, A. (n.d.). *COVID-19 patients and the radiology department-advice from the European Society of Radiology (ESR) and the European Society of Thoracic Imaging (ESTI)*. <https://doi.org/10.1007/s00330-020-06865-y>/Published
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... Fei-Fei, L. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, 115(3), 211–252. <https://doi.org/10.1007/s11263-015-0816-y>
- Sedik, A., Hammad, M., Abd El-Samie, F. E., Gupta, B. B., & Abd El-Latif, A. A. (2022). Efficient deep learning approach for augmented detection of Coronavirus disease. *Neural Computing and Applications*, 34(14), 11423–11440. <https://doi.org/10.1007/s00521-020-05410-8>
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–14.
- Subramanian, N., Elharrouss, O., Al-Maadeed, S., & Chowdhury, M. (2022, April 1). A review of deep learning-based detection methods for COVID-19. *Computers in Biology and Medicine*, Vol. 143. Elsevier Ltd. <https://doi.org/10.1016/j.combiomed.2022.105233>
- Tahir, A. M., Chowdhury, M. E. H., Khandakar, A., Rahman, T., Qiblawey, Y., Khurshid, U., ... Hamid, T. (2021). COVID-19 infection localization and severity grading from chest X-ray images. *Computers in Biology and Medicine*, 139. <https://doi.org/10.1016/j.combiomed.2021.105002>
- Wang, J., Zhu, H., Wang, S. H., & Zhang, Y. D. (2021). A Review of Deep Learning on Medical Image Analysis. *Mobile Networks and Applications*, 26(1), 351–380. <https://doi.org/10.1007/s11036-020-01672-7>
- Wang, T., Lei, Y., Fu, Y., Wynne, J. F., Curran, W. J., Liu, T., & Yang, X. (2021). A review on medical imaging synthesis using deep learning and its clinical applications. *Journal of Applied Clinical Medical Physics*, 22(1), 11–36. <https://doi.org/10.1002/acm2.13121>
- Xie, X., Zhong, Z., Zhao, W., Zheng, C., Wang, F., & Liu, J. (2020). Chest CT for Typical Coronavirus Disease 2019 (COVID-19) Pneumonia: Relationship to Negative RT-PCR Testing. *Radiology*, 296(2), E41–E45. <https://doi.org/10.1148/radiol.2020200343>