

Derin öğrenme tabanlı yaklaşımlarla akciğer röntgen görüntüleri üzerinden COVID-19 ve bakteri kaynaklı zatürrenin otomatik teşhisi

Automatic diagnosis of COVID-19 and bacterial pneumonia from lung x-ray images with deep learning-based approaches

Ömer Faruk NASİP* 

Tokat Gaziosmanpaşa Üniversitesi, Tıp Fakültesi, Temel Tıp Bilimleri Bölümü, Tıp Eğitimi ve Bilişimi Anabilim Dalı, 60100, Tokat

• Geliş tarihi / Received: 20.05.2024

• Kabul tarihi / Accepted: 04.10.2024

Öz

COVID-19 tüm dünyada yüksek ölüm oranına neden olan virüs kaynaklı bir hastalıktır. Virüsle enfekte olan hastalar kuru öksürük, nefes darlığı, ateş ve diğer semptomların yanı sıra belirgin radyografik görsel özelliklere sahiptir. Bununla birlikte benzer semptomları içeren bir başka hastalık ise zatürredir. COVID-19 ve zatürrenin doğru teşhisi, hekimlerin hastalara uygun tedavilerle müdahale etmesine yardımcı olmak için büyük önem taşımaktadır. Ters Transkripsiyon - Polimeraz Zincir Reaksiyonu (RT-PCR) testi, COVID-19 teşhisi için rutin olarak kullanılmasına rağmen maliyetli, zaman alıcı ve yanlış sonuçlara eğilimlidir. Bu nedenle teşhis için düşük maliyetli, hızlı ve başarılı sonuç veren tıbbi görüntüleme tabanlı bilgisayar destekli çalışmalar önemli bir alternatiftir. Bu çalışmada, COVID-19 hastaları, bakteri kaynaklı zatürre hastaları ve sağlıklı bireylerin akciğer röntgen görüntüleri üzerinden otomatik olarak teşhis edilmesini amaçlayan derin öğrenme tabanlı üç farklı yaklaşım önerilmiştir. İlk yaklaşımda öğrenme aktarımı, ikinci yaklaşımda öznitelik çıkarımı ve üçüncü yaklaşımda ise öznitelik seçimi yöntemi uygulanmıştır. Önceden eğitilmiş evrişimli derin sinir ağları Vgg19, ResNet50 ve DenseNet201 öğrenme aktarımı ve öznitelik çıkarımı amacıyla kullanılmıştır. Öznitelik çıkarımı ve öznitelik seçimi yaklaşımında sınıflandırıcı olarak Destek Vektör Makinesi tercih edilmiştir. Çalışmada Kaggle tarafından erişime sunulan ve herkese açık üç farklı akciğer röntgen görüntüsü veri tabanından elde edilen her bir sınıfa ait 1500 adet olmak üzere toplamda 4500 adet röntgen görüntüsü kullanılmıştır. Öğrenme aktarımı yaklaşımında ResNet50 ile %99.2, öznitelik çıkarımı yaklaşımında DenseNet201 ile %98.7, öznitelik seçimi yaklaşımında ise ResNet50 ile %98.3 doğruluk elde edilmiştir. Bunun yanı sıra önerilen öznitelik seçimi yaklaşımı sayesinde sınıflandırma doğruluğunda belirgin bir düşüş yaşanmadan sınıflandırma hızı yaklaşık beş kat artmıştır.

Anahtar kelimeler: Derin öğrenme, COVID-19, Zatürre

Abstract

COVID-19 is a virus-induced disease that causes a high mortality rate around the world. Patients infected with the virus have distinct radiographic visual features as well as dry cough, shortness of breath, fever, and other symptoms. However, another disease with similar symptoms is pneumonia. Accurate diagnosis of COVID-19 and pneumonia is of great importance to help physicians treat patients with appropriate treatments. Although Reverse Transcription - Polymerase Chain Reaction (RT-PCR) testing is routinely used for COVID-19 diagnosis, it is costly, time-consuming, and prone to false results. For this reason, medical imaging-based computer-aided studies that provide low-cost, fast and successful results for diagnosis are an important alternative. In this study, three different deep learning-based approaches are proposed, aiming to automatically diagnosis COVID-19 patients, bacterial pneumonia patients and healthy individuals through lung X-ray images. In the first approach, the learning transfer method was applied, in the second approach, feature extraction, and in the third approach, the feature selection method was applied. Pre-trained convolutional deep neural networks Vgg19, ResNet50 and DenseNet201 were used for learning transfer and feature extraction. Support Vector Machine was preferred as the classifier in the feature extraction and feature selection approach. A total of 4500 x-ray images, 1500 of each class obtained from three different publicly available lung x-ray image databases made available by Kaggle, were used in the study. In the learning transfer approach, 99.2% accuracy was achieved with ResNet50, in the feature extraction approach, 98.7% accuracy was achieved with DenseNet201, and in the feature selection approach, 98.3% accuracy was achieved with ResNet50. In addition, thanks to the proposed feature selection approach, the classification speed increased approximately five times without a significant decrease in classification accuracy.

Keywords: Deep learning, COVID-19, Pnomoni

* Ömer Faruk NASİP; omerfaruk.nasip@gop.edu.tr

1. Giriş

1. Introduction

COVID-19 2019 yılı Aralık ayında Çin'in Wuhan eyaletinde ortaya çıktı ve kısa sürede pandemi halini alarak dünya çapında bir sağlık sorunu haline geldi. Dünya Sağlık Örgütü (WHO) istatistiklerine göre, 2024 yılının Ocak ayında 770 milyondan fazla onaylanmış COVID-19 vakası bulunurken bu vakaların 7 milyondan fazlası ölümlerle sonuçlanmıştır (WHO, 2024). COVID-19'a, β -koronavirüs ailesine ait olan SARS-Cov-2 adlı bir koronavirüs neden olur. Bu virüs, Orta Doğu solunum sendromuna (MERS-Cov) ve şiddetli akut solunum sendromuna (SARS-Cov) neden olan virüslere kıyasla oldukça bulaşıcıdır (Nanshan vd., 2020; Narin vd., 2021). Virüsün en yaygın bulaşma yolu, solunum damlacıkları ve yakın temastır. Semptomatik bir hasta öksürdüğünde veya hapşırıldığında solunum damlacıkları üretilir. Koronavirüs, ya bu solunum damlacıklarının solunmasıyla ya da enfekte olan yüzeye dokunulup ardından ağız, burun veya gözlere dokunulmasıyla bulaşır.

Vaka ve ölüm sayılarının artması, sağlık hizmetlerine binen ağır yüke ek olarak, sokağa çıkma kısıtlamaları, maske ve fiziksel mesafe gibi tedbirler nedeniyle hem sosyal hayatı hem de ekonomik hayatı olumsuz etkilemektedir. Bu nedenle salgının önüne geçilmesi adına hastalığın erken dönemde ve doğru teşhisi büyük önem arz etmektedir. Gerçek Zamanlı Ters Transkripsiyon Polimeraz Zincir Reaksiyonu (RT-PCR) testi, COVID-19'u teşhis etmek için yaygın olarak kullanılır. Belirti gösteren kişiden boğaz sürüntüsü örneği alınarak yapılmaktadır. RT-PCR testinde sonuçların elde edilmesi birkaç saatten 48 saate kadar sürebilmektedir. Bu test yönteminin zaman alıcı, maliyetli ve hasta için huzursuz edici olmasının yanı sıra düşük duyarlılığı nedeniyle COVID-19'un hızlı ve doğru teşhisi için alternatif araçlara ihtiyaç duyulmaktadır (Kanne vd., 2020).

COVID-19 hastalığında enfekte bir kişinin solunum sisteminde meydana gelen hasar radyolojik görüntüleme yöntemleri ile teşhis edilebilmektedir. Akciğer röntgeni (CXR) ve bilgisayarlı tomografi (BT) bu yöntemlerin başlıcalarıdır. Röntgen, tomografi taramalarından daha hızlı, daha az maliyetli ve daha az radyasyona maruz bırakması sebebiyle, COVID-19 teşhisi için ideal görüntüleme yöntemidir (Abdelhamid vd., 2022). Bunun yanı sıra röntgen cihazlarının çoğu sağlık kuruluşunda bulunması ve ulaşılabilir olması da bir başka tercih sebebidir (Singh vd., 2022; Wong vd., 2020). Bununla birlikte röntgen görüntülerinin analizi ile teşhis edilen bir başka solunum yolu rahatsızlığı da zatürredir. Bu iki hastalığı birbirinden ayırt edebilmek için uzman radyologların röntgende bulunan radyolojik özellikleri analiz etmesi gerekir. Ancak artan hasta sayısı ile birlikte iş yüklerinin son derece artmış olması uzmanların teşhis sürelerini uzatabilmekte, bu da hastalar için ölümcül sonuçlara yol açabilmektedir. Bu durum radyolojik görüntüleri analiz etmek için bilgisayar destekli otomatik teşhis sistemlerinin gerekliliğini ortaya koymaktadır.

Görüntü işleme, derin evrişimli sinir ağları ve karmaşık hesaplama algoritmaları sayesinde son yıllarda hızlı bir gelişim göstermiştir. Derin öğrenme, yapay zekâ alanında en popüler yöntemlerden biridir. Özellikle evrişimli derin sinir ağları mimarisi, nesne tespiti, örüntü tanıma, segmentasyon ve sınıflandırma gibi problemlerin çözümünde uygulanmaktadır (Pławiak & Tadeusiewicz, 2014). Bu yöntemlerin klasik makine öğrenmesi tekniklerinden farkı, hesaplama açısından çok zaman alan bir aşama olan görüntü özelliklerinin iyi bir şekilde, otomatik olarak çıkarılması ve öğrenilmesidir. Paralel işlem yeteneğine sahip grafik işlemcilerin (GPU) geliştirilmesi eğitim sürelerini oldukça kısaltmaktadır. Büyük veri setlerine erişim iyi performans gösteren derin sinir ağlarının geliştirilmesine olanak sağlamaktadır (Korot vd., 2021; Kaissis vd., 2020).

Literatürde röntgen görüntüleri üzerinden COVID-19 ve zatürre teşhisi yapılan çeşitli çalışmalar mevcuttur. Rahaman vd. (2020) önceden eğitilmiş 15 farklı derin sinir ağ modelini transfer öğrenme yaklaşımı ile test ederek en uygun modeli bulmayı amaçlamışlardır. Kullandıkları veri seti 860 bireye ait (260 COVID-19, 300 zatürre, 300 normal) akciğer röntgen görüntüsünden oluşmaktadır. Öztürk vd. (2020) DarkNet ağının 17 katmanının her katmanına filtre ekleyerek bir model önermiştir. Bu model, 125 COVID-19, 500 zatürre ve 500 normal sınıfa ait röntgen görüntüsü veri seti ile test edilmiştir. Toraman vd. (2020) CapsNet adlı 11 katmanlı yapay sinir ağı ile 231'i COVID-19, 1050'si zatürre ve 1050'si normal sınıfa ait olan toplam 2331 röntgen görüntüsü kullanmışlardır. Wang vd. (2020) 358 COVID-19, 5538 zatürre ve 8066 normal kategorideki röntgen görüntülerini sınıflandıran COVID-Net adlı bir sinir ağı sunmuşlardır. Loey vd. (2020) dört sınıfa ait (COVID-19, bakteriyel zatürre, viral zatürre ve normal) toplam 306 röntgen görüntüsü ile çalışmışlardır. Çalışmada Alexnet, GoogleNet ve ResNet18 derin sinir ağları transfer öğrenme yöntemi ile kullanılmıştır. Çalışmanın ilk senaryosunda tüm sınıflar işleme alınarak, ikinci senaryoda üç sınıf (COVID-19, bakteriyel zatürre, normal) işleme alınarak, üçüncü senaryoda iki sınıf (COVID-19, normal) işleme alınarak sınıflandırma

yapılmıştır. [Sethy vd. \(2020\)](#) çalışmalarında 127 COVID-19, 127 zatürre, 127 normal kategoriye ait toplam 381 adet röntgen görüntüsü kullanmışlardır. ResNet50 ağını öznelik çıkarıcı, destek vektör makinesini (DVM) sınıflandırıcı olarak kullandıkları model ile sınıflandırma yapmışlardır. [Apostolopoulos ve Mpesiana \(2020\)](#) MobileNetV2 ağını transfer öğrenme yaklaşımı ile kullanarak üç kategoriye ait röntgen görüntüsünü sınıflandırmışlardır. [Marques vd. \(2020\)](#) üç sınıfa ait 500'er adet röntgen görüntüsü ile çalışmış, EfficientNet adını verdikleri derin sinir ağı ile sınıflandırma yapmışlardır. [Uçar ve Korkmaz \(2020\)](#) çalışmalarında önerdikleri Bayes-SqueezeNet yöntemi ile 1536 COVID-19, 1536 zatürre ve 1536 normal röntgen görüntüsünü kullanmışlardır. [Chowdhury vd. \(2020\)](#) çeşitli derin sinir ağlarını transfer öğrenme yaklaşımı kullanarak 423 COVID-19, 1485 viral zatürre, 1579 normal sınıfa ait röntgen görüntüleri ile çalışmışlardır. [Abiyev ve Ismail \(2021\)](#) 186 COVID-19, 1084 zatürre ve 1082 normal olmak üzere üç farklı sınıfa ait toplam 2352 akciğer röntgen görüntüsü kullanmıştır. Çalışmada veri seti evrişimli sinir ağı ve öğrenme aktarımı yöntemi ile test etmiştir. [Aggarwal vd. \(2022\)](#) 709 adet röntgen görüntüsü içeren veri seti ile DenseNet121 ağını öğrenme aktarımı yöntemi ile kullanarak işleme almışlardır. [Gopatoti ve Vijayalakshmi \(2022\)](#) genetik algoritmali optimizasyon (EGWO-GA) olarak adlandırılan optimal özellik seçim tekniği ile derin öğrenme evrişimli sinir ağlarını (DLCNN) kullanan üç aşamalı bir röntgen görüntü tabanlı COVID-19 sınıflandırma modeli önermişlerdir. Bakteri tabanlı zatürre, COVID-19 ve normal sınıf için sınıflandırma yapmışlardır. [Kaya ve Eriş \(2023\)](#) D3SENet adını verdikleri öznelik çıkarma yaklaşımı içeren ağ modeli önermişlerdir. Önerilen ağ modeli 1409 sağlıklı, 1210 COVID-19 ve 1345 zatürre sınıfına ait röntgen görüntüleri kullanılarak test edilmiştir.

Bu çalışmada COVID-19 ve bakteri kaynaklı zatürre hastalığının röntgen görüntüleri kullanılarak otomatik teşhisini amaçlayan derin öğrenme tabanlı modeller önerilmiştir. Önerilen modellerde önceden eğitilmiş evrişimli derin sinir ağlarından Vgg19, ResNet50 ve DenseNet201 kullanılmıştır. İlk modelde görüntüler öğrenme aktarımı yaklaşımı ile eğitilmiş ve sınıflandırılmıştır. İkinci modelde derin sinir ağları öznelik çıkarıcı olarak kullanılmış ve öznelikler farklı bir sınıflandırıcı ile sınıflandırılmıştır. Üçüncü modelde ise öznelikler öznelik seçim algoritması ile seçildikten sonra sınıflandırılmıştır. Çalışmada kullanılan veri seti Kaggle'de bulunan ve herkese açık üç farklı röntgen görüntüsü veri setindeki görüntülerin birleştirilmesi ile elde edilmiştir ([Kaggle, 2023](#)). Oluşturulan veri setinde COVID-19 hastası, bakteri kaynaklı zatürre hastası ve sağlıklı bireylere ait 1500'er adet, toplamda 4500 adet röntgen görüntüsü bulunmaktadır. Önerilen modeller ile elde edilen performans değerleri literatürdeki benzer çalışmalarla karşılaştırılmıştır.

Literatürdeki benzer çalışmalara kıyasla çalışmada kullanılan veri setindeki toplam görüntünün sayıca fazla ve her bir sınıf için dengeli dağıtılmış olması sayesinde başarılı ve tutarlı sonuçlar elde edilmiştir. Ayrıca önceden eğitilmiş derin sinir ağları kullanılarak elde edilen büyük boyutlu öznelik vektöründen farklı seçim algoritmaları ile en iyi/değerli olanları seçilerek sonuca etkisi olmayanlar çıkarılmış, boyutu küçültülen öznelik vektörü sayesinde modelin hesaplama karmaşıklığı önemli ölçüde azaltılarak sınıflandırma hızı artırılmıştır. Bu sayede insan gücü ve klinik uzmanlık gerektirmeden röntgen görüntülerini çok kısa sürede, yüksek başarı oranlarıyla sınıflandırma yeteneği ile klinikte ön tanı ve tanı süreçlerini hızlandırmaya yardımcı olacak modeller geliştirilmiştir.

2. Materyal ve yöntem

2. Material and method

2.1. Veri seti ve ön işleme

2.1. Data set and preprocessing

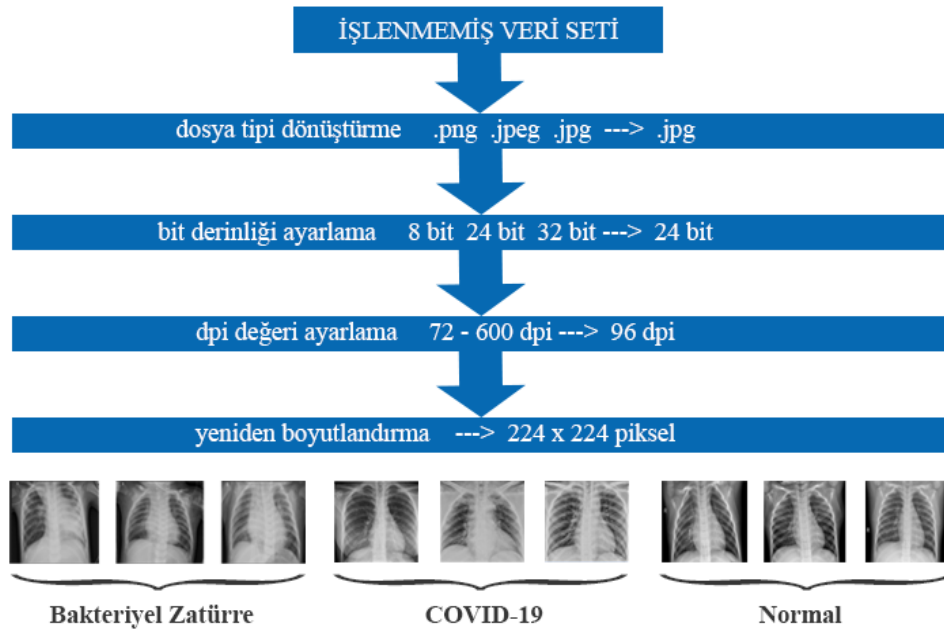
Bu çalışmada Kaggle tarafından erişime sunulan ve herkese açık üç farklı akciğer röntgen görüntüsü veri seti kullanılmıştır. Bunlardan ilki olan [Pneumonia & COVID-19 Image Dataset \(2023\)](#) veri seti COVID-19, bakteriyel zatürre, normal, viral zatürre olmak üzere dört farklı sınıfa ait görüntü içermektedir. Veri setinde bulunan görüntüler yine Kaggle'de bulunan farklı veri setlerinin birleştirilmesiyle elde edilmiştir ([Chest X-Ray Images \(Pneumonia\), 2023](#); [CoronaHack-Chest X-Ray-Dataset, 2023](#); [COVID-19 Radiography Database, 2023](#); [COVID-19 Detection X-Ray Dataset, 2023](#); [Covid-19 Image Dataset, 2023](#)). Çalışmada kullanılan ikinci veri seti olan [Classification of COVID viral bacterial pneumonia \(2023\)](#) veri setinde de ilk veri setinde olduğu gibi dört sınıfa ait röntgen görüntüleri bulunmaktadır. Kullanılan bir diğer veri seti olan [Chest X-ray Covid-19 & Pneumonia \(2023\)](#) ise COVID-19, zatürre (bakteriyel-viral karışık) ve normal olmak üzere üç sınıf bulunan röntgen görüntüleri içermektedir. Yine bu veri seti de çeşitli kaynaklardan elde edilen veri setlerinin birleştirilmesi ile elde edilmiştir ([Agchung, 2023](#); [Chest X-Ray Images \(Pneumonia\), 2023](#); [Covid-chestxray-](#)

dataset, 2023). Çalışmada bu üç veri setinde bulunan COVID-19, bakteriyel zatürre ve normal sınıfa ait görüntüler birleştirilmiştir. Veri setinde her bir sınıflara ait örnek sayısının dengeli olması oluşturulan modelin tutarlılığı ve performansı açısından önemlidir. Bu sebeple her bir sınıfa ait 1500 adet röntgen görüntüsü rasgele seçilerek toplamda 4500 adet görüntüden oluşan bir veri seti elde edilmiştir. Tablo 1’de çalışmada kullanılan veri setlerine ait sınıflar ve toplam görüntü sayıları ile oluşturulan veri setine dahil edilen görüntü sayıları ifade edilmiştir.

Tablo 1. Çalışmada kullanılan veri setlerindeki görüntü sayıları
Table 1. The number of images in the datasets used in the study

Sınıf	Pneumonia & COVID-19 Image Dataset	Classification of COVID-viral bacterial pneumonia	Chest X-ray (Covid-19 & Pneumonia)	Çalışmada Kullanılan
COVID-19	980	576	576	1500
Bakteriyel Zatürre	2727	2780	-	1500
Normal	1443	1583	1583	1500
Viral Zatürre	1512	1503	-	-
Zatürre	-	-	4273	-

Oluşturulan veri setindeki röntgen görüntüleri farklı kaynaklardan elde edildiği için teknik özellikleri farklılık gösterebilmektedir. Ön işleme aşamasında çeşitli görüntü işleme teknikleri kullanılarak görüntülerin tümünün aynı standarda sahip olması sağlanmıştır. Bu sayede veri setindeki görüntüler çalışmada kullanılan derin sinir ağları ile kullanıma uygun hale getirilmiştir. İşlenmemiş haldeki veri seti için uygulanan ön işleme adımları Şekil 1’de ifade edilmiştir.



Şekil 1. Çalışmada kullanılan veri seti ön işleme adımları
Figure 1. Data set pre-processing steps used in the study

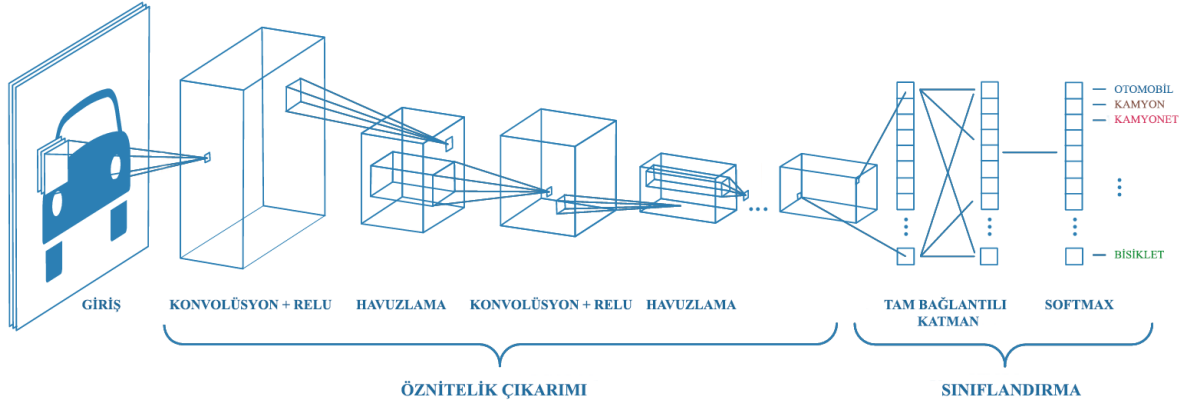
2.2. Derin öğrenme ve evrişimli sinir ağları

2.2. Deep learning and convolutional neural networks

Derin öğrenme biyolojik sinir ağ yapısının veri işleme yöntemlerinden esinlenen, yapay sinir ağları olarak bilinen yapıları kullanır. Derin öğrenmede makine öğrenmesinden farklı olarak çok katmanlı yapay sinir ağları kullanılmaktadır. Derin öğrenmeyi daha başarılı kılan da bu çok katmanlı yapay sinir ağlarından oluşmasıdır (Nasip & Zengin, 2018). Ağdaki katman sayısının fazla olması, modelin yüksek başarı oranlarıyla sonuç vermesine olanak tanır. Ancak katman sayısı arttıkça eğitim için gerekli işlem sayısı da logaritmik olarak

artmaktadır. Gelişen donanım teknolojisi paralel işlem yeteneğine sahip grafik işlemcilerin derin öğrenme alanında kullanımını yaygınlaştırmıştır. Bu sayede eğitim süreci için gereken süre makul seviyelere indirilmiştir.

Evrişimli Sinir Ağları (ESA), derin öğrenmenin en sık kullanılan mimarisidir. Görüntü ve videolar üzerinde işlem yapılan ESA iki bölüme ayrılmaktadır. Birinci bölümde girdilere ait özniteliklerin çıkarıldığı katmanlar, diğer bölümde ise sınıflandırmanın yapıldığı katmanlar bulunmaktadır. ESA hiyerarşik öznitelik çıkarma konusunda oldukça iyi sonuçlar üretmektedir. Diğer sinir ağları gibi, ESA’da bir giriş katmanına, bir çıkış katmanına ve bunların arasında bir çok gizli katmana sahiptir (Haryanto vd., 2017). Şekil 2’de ESA’nın temel mimarisi ifade edilmektedir.



Şekil 2. Temel ESA Mimarisi

Figure 2. Basic CNN Architecture

2.3. Öğrenme aktarımı, öznitelik çıkarımı ve öznitelik seçimi

2.3. Transfer learning, feature extraction and feature selection

Veri setine ait öznitelikler, sınıflandırma açısından büyük önem teşkil etmektedir. Eğer öznitelikler başarılı olarak ifade edilirse sınıflandırma işlemi de aynı şekilde başarılı olur. Önceden eğitilmiş derin sinir ağları, ImageNet gibi binlerce farklı kategorideki milyonlarca görüntü içeren veri setleri ile eğitilmiş ve belirli başarı oranlarının üzerinde sonuçlar veren derin sinir ağlardır (Marmanis vd., 2016). Ağlarda bulunan katman yapısı ve içerdikleri parametreler öznitelik çıkarma anlamında oldukça iyi sonuçlar vermektedir (Zhao vd., 2017). Bu çalışmada önceden eğitilmiş derin sinir ağlarından Vgg19, ResNet50 ve DenseNet201 kullanılmıştır (Simonyan & Zisserman, 2014; He vd., 2015; Huang vd., 2017). Tablo 2’de kullanılan önceden eğitilmiş derin sinir ağlarına ait özellikler verilmiştir.

Tablo 2. Çalışmada kullanılan önceden eğitilmiş derin sinir ağlarının özellikleri

Table 2. The properties of the pre-trained deep neural networks used in the study

Özellik	Vgg19	ResNet50	DenseNet201
Girdi Boyutu (piksel)	224x224x3	224x224x3	224x224x3
Derinlik	19	50	201
Katman Sayısı	47	177	708
Bağlantı Sayısı	46	192	805
Parametre Sayısı (milyon)	144	25,6	20

Önceden eğitilmiş bir ağın tüm katmanlarını veya bazı katmanlarını farklı görevler için kullanmaya öğrenme aktarımı adı verilir. Bazı alanlar için büyük miktarlarda veri toplama hem maliyetli hem de zaman alıcı olabilmektedir. Öğrenme aktarımı veri setinin yeterli büyüklükte olmadığı durumlarda yaygın olarak kullanılmaktadır (Tan vd., 2018). Öğrenmede aktarımında aktarılan bilgi katmanlardaki ağırlık değerleridir. Bu yaklaşım sayesinde bir ağı güncellemek ve yeniden eğitmek, genellikle ağı sıfırdan eğitmekten daha hızlı, kolay ve performanslıdır. Yaygın kullanım ağın son katmanlarının yeniden oluşturulması, ondan önceki katmanlarının ise olduğu gibi aktarılması şeklindedir (Zhuang vd., 2021).

Makine öğrenmesi ve derin öğrenme genel yapısı itibarıyla iki ana kısma ayrılmaktadır. Bunlardan birincisi veri setine ait özniteliklerin elde edildiği öznitelik çıkarma aşaması, diğeri ise çıkarılan özniteliklere sınıflandırma işleminin uygulandığı sınıflandırma aşamasıdır. Öznitelik çıkarma, ham veri setinin işlenmek üzere daha yönetilebilir gruplara indirildiği bir boyut azaltma işlemidir. Ağın yapısına göre çeşitli katman, filtre ve parametreler kullanılarak uygulanan bu işlemlere ESA'dan örnek verecek olursak, giriş verisine hiyerarşik şekilde uygulanan konvolüsyon ve havuzlama katmanları sonrasında ilk aşamalarda veriyi temsil eden genel özellikler elde edilirken sonraki aşamalarda ise verinin ayırt edici öznitelikleri elde edilir. Matris formunda elde edilen öznitelik haritaları, son tam bağlı katman sayesinde tek boyutlu öznitelik vektörü haline alır. Burada öznitelik çıkarımı için kullanılan modellerin barındırdığı katman sayısı, katmanlardaki filtre boyutları ve parametrelerinin veri setine uygunluğu da büyük önem arz etmektedir. Aynı zamanda veri setinde bulunan verilerin sayısı ve nitelik bakımından ilgili veri setini iyi ifade etmesi yapılan işlemin doğru sonuçlar verebilmesi için önemlidir.

Öznitelik seçimi, kullanılan veri setini ifade eden öznitelikleri içeren öznitelik vektöründen temsil oranı en yüksek alt kümelerin seçimi şeklinde tanımlanmaktadır. Temsil oranı daha düşük olan özniteliklerin çıkarılmasıyla birlikte verinin boyutu ve işlem karmaşıklığı azalır. Dolayısıyla boyutu azaltılmış veriyi kullanan algoritmaların performansı artar (Chen vd., 2020). Öznitelik seçimi yöntemleri veri madenciliği de dahil olmak üzere birçok alanda uzun zamandır kullanılmaktadır. Ancak son yıllarda büyük boyutlu veri setlerinden elde edilen öznitelik vektörlerinin boyutunun azaltılmasında önemli rol oynamaktadır. Özniteliklerin seçimi istatistiksel hesaplamalar yardımıyla yapılan filtreleme, özniteliklerin birbiri ile bağlantısının incelendiği sarmal ve içinde sınıflandırma algoritmasını da barındıran gömülü yöntemler olmak üzere 3 gruba ayrılmaktadır (Saeyns vd., 2007). Tablo 3'de çalışmada kullanılan filtre tabanlı iki öznitelik seçim algoritması ifade edilmiştir.

Tablo 3. Çalışmada kullanılan öznitelik seçim algoritmaları

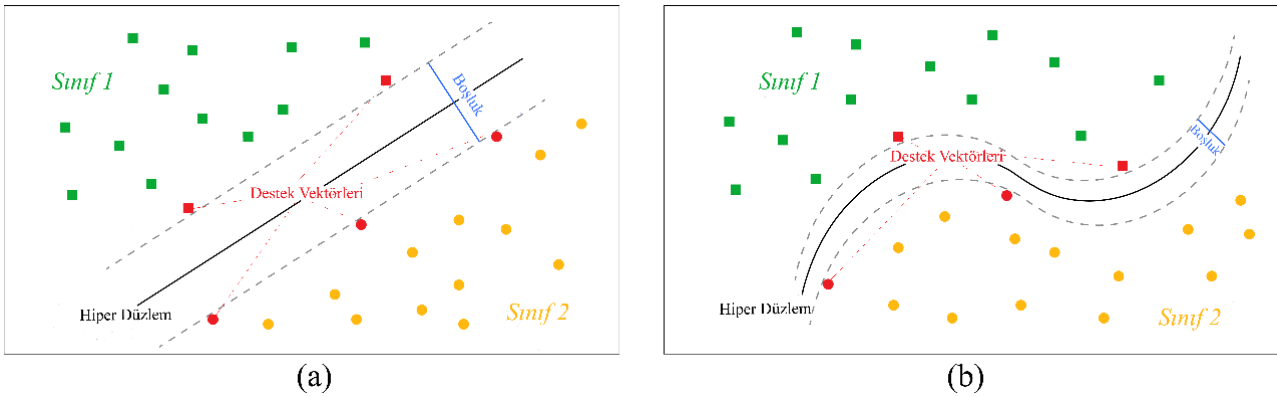
Table 3. Feature selection algorithms used in the study

Algoritma	Açıklama
Bilgi Kazancı (Omuya ve ark., 2021)	Her bir özneliğin rastgelelik, belirsizlik ve beklenmedik durumlarının oluşma olasılığını gösteren entropi hesaplama işlemi uygulanır.
Kazanç Oranı (Priyadarsini ve ark., 2010)	Her öznitelik için bölme bilgileri hesaplanır. Bir özneliğin bilgi kazanç değeri, o özneliğin bilgi kazanç değerinin bölme değerine bölünmesiyle elde edilir.

2.4. Destek vektör makinesi

2.4. Support vector machine

Destek Vektör Makinesi (DVM) çok boyutlu bir uzayda olası en iyi sınıflandırma için alanı bölen bir hiper düzlem bulur. İlk olarak ikili sınıflandırma amacıyla tasarlanan bu algoritma daha sonra çoklu sınıflandırma için de kullanılacak şekilde geliştirilmiştir (Wang vd., 2021; Azimi-Pour vd., 2020). Barındırdığı çekirdek fonksiyonuna bağlı olarak doğrusal ve doğrusal olmayan şekilde ifade edilebilen DVM'nin düzlem üzerinde ifadesi Şekil 3'de gösterilmektedir.



Şekil 3. (a) Doğrusal (b) Doğrusal olmayan destek vektör makinesi modeli

Figure 3. (a) Linear (b) Nonlinear support vector machine model

Büyük boyutlu uzaylarda işlem yapmak için DVM çeşitli çekirdek fonksiyonları yardımıyla daha başarılı sonuçlar verebilmektedir. Kullanılan verinin niteliğine göre belirlenen bu çekirdek fonksiyonların en yaygın kullanılanları polinomal, lineer, sigmoid, radyal tabanlı olarak ifade edilebilir (Kilicarslan vd., 2020). Eşitlik 1, 2, 3 ve 4’de bu çekirdek fonksiyonları verilmiştir.

$$F_{lineer}(x, y) = x^T y \quad (1)$$

$$F_{polinomal}(x, y) = (\gamma x^T y + r)^d \quad \gamma > 0 \quad (2)$$

$$F_{sigmoid} = \tanh(\gamma x^T y + r) \quad (3)$$

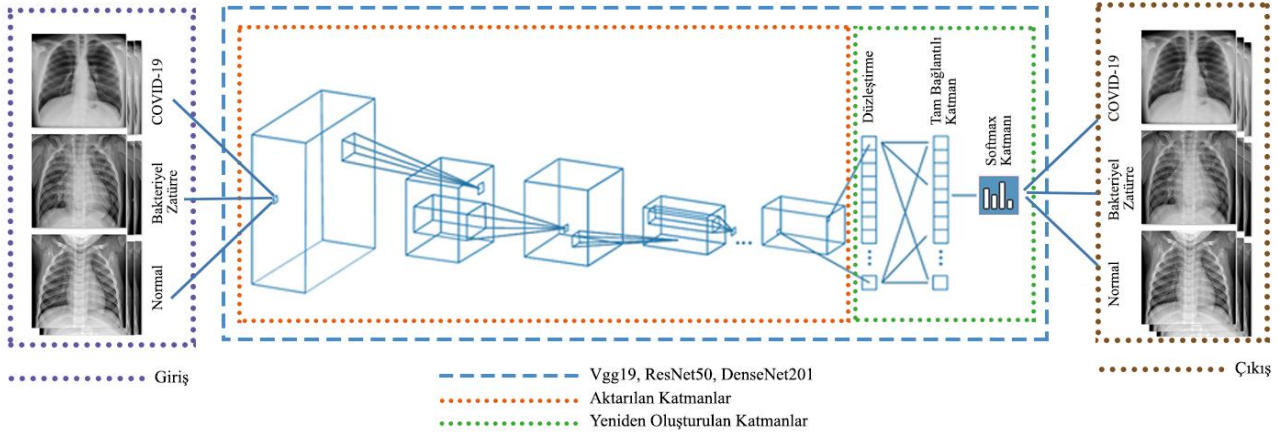
$$F_{radyal} = \exp(-\sigma |x - y|^2) \quad \sigma > 0 \quad (4)$$

Eşitlik (2)’de γ eğim, r sabit terim ve d polinom derecesidir. Bu çalışmada, çıkarılan ve seçilen öznelikleri sınıflandırmak için polinom derecesi üç olan DVM’nin polinomal çekirdek fonksiyonu kullanılmıştır. Bu fonksiyona kübik çekirdek fonksiyonu adı verilmektedir.

2.5. Önerilen yöntemler

2.5. Proposed methods

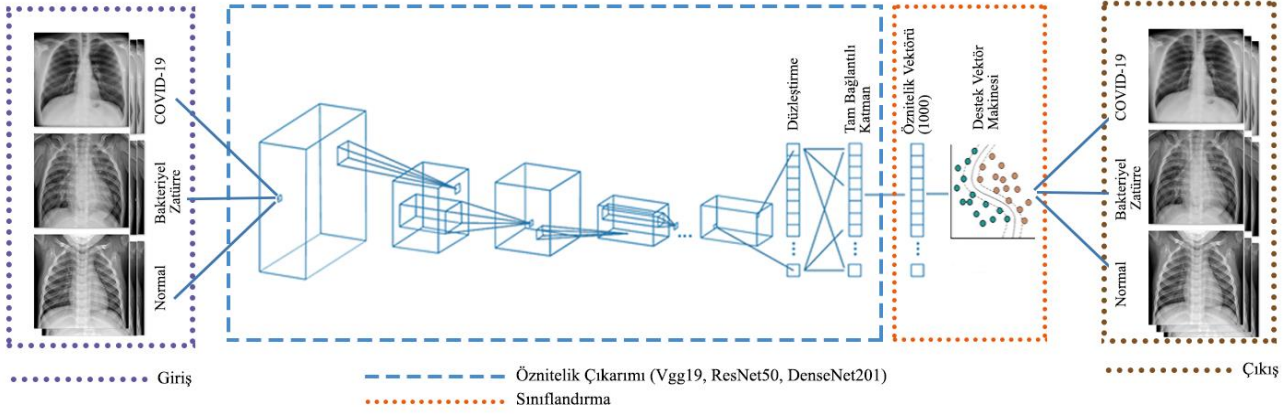
Çalışmada akciğer röntgen görüntülerini sınıflandırmak amacıyla üç farklı yaklaşım önerilmiştir. Tüm yöntemlerde önceden eğitilen Vgg19, ResNet50 ve DenseNet201 derin sinir ağlarından yararlanılmıştır. İlk yaklaşımda önceden eğitilmiş evrişimli sinir ağları öğrenme aktarımı yöntemi ile kullanılmıştır. Ağın son tam bağlı katmanına kadar olan kısmı olduğu gibi aktarılmış, son üç katmanı ise yeniden oluşturularak eğitim ve test işlemi gerçekleştirilmiştir. Veri setindeki görüntülerin %60’ı eğitim, %10’u validasyon, %30’u test için kullanılmıştır. Şekil 4’de bu yaklaşım görsel olarak ifade edilmiştir.



Şekil 4. Öğrenme aktarımı yaklaşımı

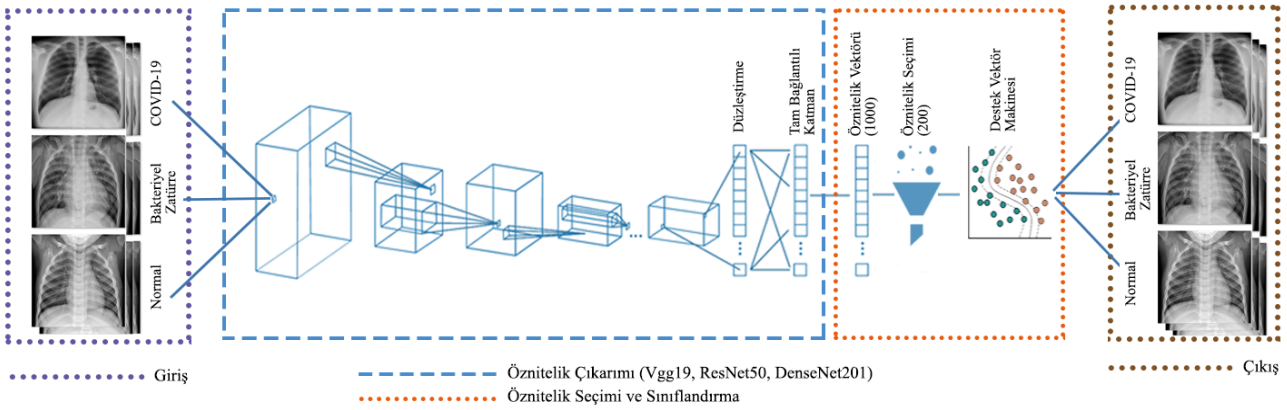
Figure 4. Transfer learning approach

İkinci yaklaşımda önceden eğitilmiş evrişimli derin sinir ağları öznelik çıkarma amacıyla kullanılmıştır. Ağın son tam bağlı katmanından elde edilen ve 1000 adet öznelik içeren öznelik vektörü, kübik çekirdek fonksiyonlu Destek Vektör Makinesi ile sınıflandırılmıştır. Veri setinin %70’i eğitim %30’u test için kullanılmıştır. Şekil 5’de bu yaklaşım görsel olarak ifade edilmiştir.



Şekil 5. Öznitelik çıkarımı yaklaşımı
Figure 5. Feature extraction approach

Üçüncü yaklaşımda ise ikinci yaklaşımdaki yöntemle elde edilen ve 1000 adet öznitelik içeren öznitelik vektörü öznitelik seçim algoritmaları ile işleme alınmış ve veri setindeki temsil oranı en yüksek 200 öznitelik seçilmiştir. Seçilen bu öznitelikler ikinci yaklaşımda olduğu gibi kübik çekirdek fonksiyonlu Destek Vektör Makinesi ile sınıflandırılmıştır. Bu yaklaşımda da veri setinin %70'i eğitim %30'u test için kullanılmıştır. Şekil 6'da bu yaklaşım görsel olarak ifade edilmiştir.



Şekil 6. Öznitelik seçimi yaklaşımı
Figure 6. Feature selection approach

3. Bulgular

3. Results

Önerilen modellerin performanslarını değerlendirmek için Eşitlik 5,6,7 ve 8'de belirtilen metrikler kullanılmıştır. Eşitliklerde belirtilen ifadeleri doğru-yanlış kavramı üzerinden açıklayacak olursak DP (Doğru Pozitif) doğru olan sınıfa doğru, DN (Doğru Negatif) yanlış olan sınıfa yanlış, YP (Yanlış Pozitif) doğru olan sınıfa yanlış, YN (Yanlış Negatif) yanlış olan sınıfa doğru olarak tahminde bulunma sayısıdır. Veri setinde bulunan eğitim, test ve validasyon için kullanılan görüntüler her deneme için rastgele olarak seçilerek işleme alınmıştır. Önerilen modeller için ifade edilen sonuçlar yapılan denemelerin ortalaması alınarak belirtilmiştir.

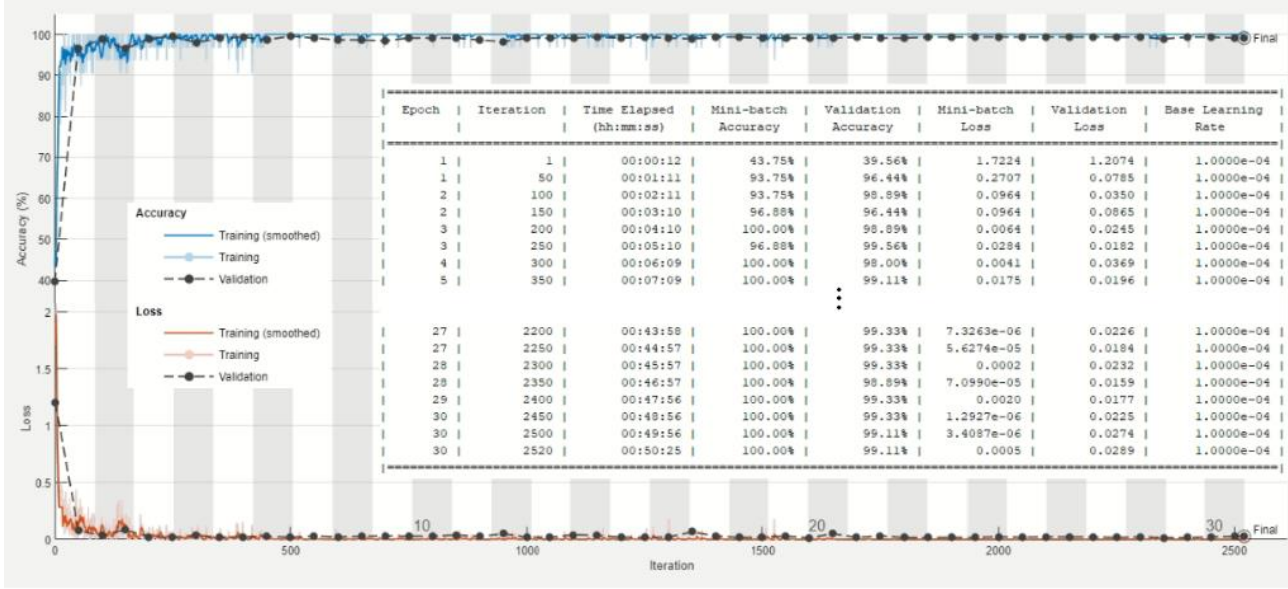
$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \times 100 \quad (5)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \times 100 \quad (6)$$


$$\text{Duyarlılık} = \frac{DP}{DP + YN} \times 100 \quad (7)$$

$$\text{F1 Skoru} = 2x \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \times 100 \quad (8)$$


Öğrenme aktarımı yaklaşımı eğitim işlemine ait elde edilen örnek sonuçlar Şekil 7, Şekil 8 ve Şekil 9’da gösterilmiştir. Eğitim işleminde parametreler optimizier ‘sgdm’, epoch sayısı ‘30’, InitialLearningRate ‘0.0001’, MiniBatchSize ‘32’, ValidationFrequency ‘50’ olarak belirlenmiştir. Modelin eğitimi Vgg19 için ortalama 50 dakika, ResNet50 için ortalama 45 dakika, DenseNet201 için ortalama 128 dakikada tamamlanmıştır.



Şekil 7. Öğrenme aktarımı yaklaşımı ile Vgg19 ağınnın eğitimi
Figure 7. Training of Vgg19 network with transfer learning approach



Şekil 8. Öğrenme aktarımı yaklaşımı ile ResNet50 ağınnın eğitimi
Figure 8. Training of ResNet50 network with transfer learning approach



Şekil 9. Öğrenme aktarımı yaklaşımı ile DenseNet201 ağının eğitimi

Figure 9. Training of DenseNet201 network with transfer learning approach

Öğrenme aktarımı yaklaşımı ile eğitilen modeller test veri setinde bulunan görüntüler ile test edilmiş ve elde edilen ortalama performansları Tablo 4’de gösterilmiştir. ResNet50 ağı kullanılarak oluşturulan model diğer iki modele göre daha başarılı sonuçlar vermiştir.

Tablo 4. Öğrenme aktarımı yaklaşımı ile eğitilen modellerin test sonuçları

Table 4. Test results of models trained with the transfer learning approach

Model	Sınıf	Duyarlılık (%)	Kesinlik (%)	F1-Skoru (%)	Doğruluk (%)
VGG19	Bakteriyel Zatürre	98.44	99.11	98.77	
	COVID-19	99.33	99.78	99.55	99.11
	Normal	99.56	98.46	99.01	
ResNet50	Bakteriyel Zatürre	98.22	99.55	98.88	
	COVID-19	99.78	99.78	99.78	99.19
	Normal	99.56	98.25	98.90	
DenseNet201	Bakteriyel Zatürre	97.78	98.88	98.32	
	COVID-19	99.78	99.78	99.78	98.74
	Normal	98.67	97.58	98.12	

Öznitelik çıkarımı yaklaşımı ile önceden eğitilmiş derin sinir ağında bulunan son tam bağlı katmandan elde edilen 1000 adet özneliğin kübik çekirdek fonksiyonlu Destek Vektör Makinesi ile eğitimi sonucu elde edilen test sonuçları Tablo 5’de ifade edilmiştir. Bu yaklaşımda DenseNet201 ağı kullanılarak elde edilen sonuçlar diğer ağlara kıyasla daha başarılıdır.

Tablo 5. Öznitelik çıkarımı yaklaşımı ile elde edilen test sonuçları

Table 5. Test results obtained with the feature extraction approach

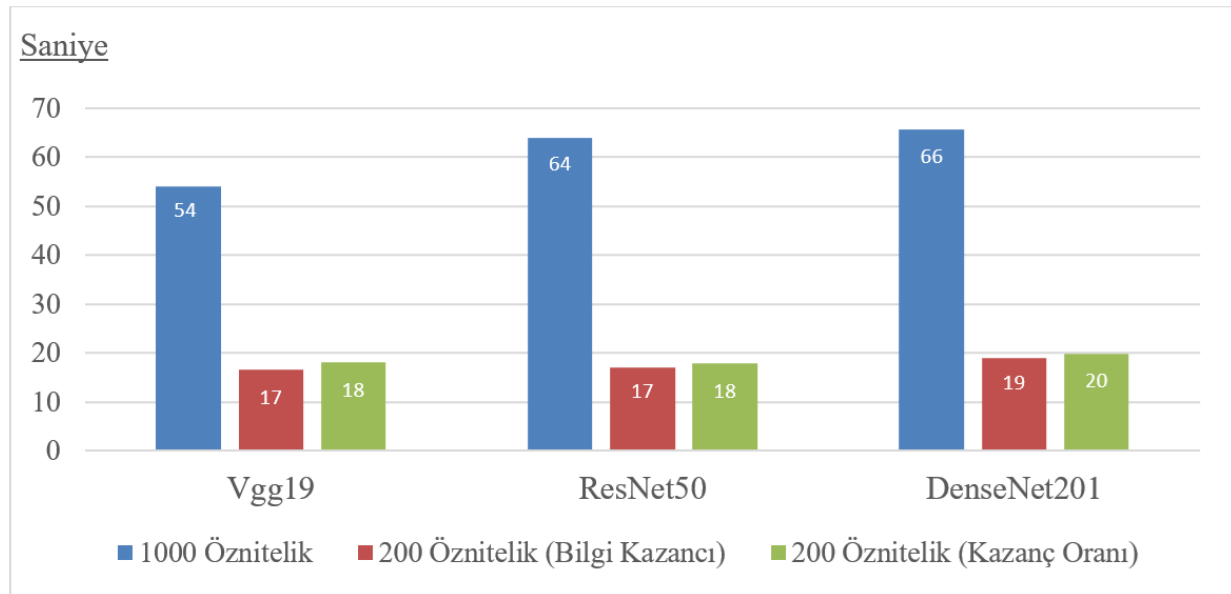
Model	Sınıf	Duyarlılık (%)	Kesinlik (%)	F1-Skoru (%)	Doğruluk (%)
VGG19	Bakteriyel Zatürre	97.33	97.12	97.23	
	COVID-19	98.89	100.00	99.44	98.07
	Normal	98.00	97.14	97.57	
ResNet50	Bakteriyel Zatürre	98.00	97.78	97.89	
	COVID-19	99.33	100.00	99.67	98.44
	Normal	98.00	97.57	97.78	
DenseNet201	Bakteriyel Zatürre	97.11	99.54	98.31	
	COVID-19	99.56	99.56	99.56	98.67
	Normal	99.33	96.96	98.13	

Önceden eğitilmiş derin sinir ağında bulunan son tam bağlı katmandan elde edilen 1000 adet özneliğin öznelik seçim algoritması ile temsil oranı en yüksek 200 adedinin belirlenerek kübik çekirdek fonksiyonlu destek vektör makinesi ile eğitimi sonucu elde edilen ortalama test değerleri Tablo 6'da ifade edilmiştir. Bu yaklaşımda en başarılı sonuçlar ResNet50 ağı ve Kazanç Oranı seçim algoritması kullanılarak elde edilmiştir.


Tablo 6. Öznelik seçimi yaklaşımı ile elde edilen test sonuçları
Table 6. Test results obtained with the feature selection approach

Algoritma	Model	Sınıf	Duyarlılık(%)	Kesinlik(%)	F1-Skoru(%)	Doğruluk(%)
Bilgi Kazancı	VGG19	Bakteriyel Zatürre	96.89	96.89	96.89	97.70
		COVID-19	98.44	100	99.22	
		Normal	97.78	96.28	97.02	
	ResNet50	Bakteriyel Zatürre	97.33	96.26	96.8	97.68
		COVID-19	99.11	100	99.55	
		Normal	96.63	96.88	96.77	
	DenseNet201	Bakteriyel Zatürre	96	98.86	97.41	98.07
		COVID-19	99.78	99.34	99.56	
		Normal	98.44	96.1	97.26	
Kazanç Oranı	VGG19	Bakteriyel Zatürre	96.89	97.11	97	97.93
		COVID-19	98.89	100	99.44	
		Normal	98	96.71	97.35	
	ResNet50	Bakteriyel Zatürre	98	97.14	97.57	98.30
		COVID-19	99.56	100	99.78	
		Normal	97.33	97.77	97.55	
	DenseNet201	Bakteriyel Zatürre	95.78	97.96	96.85	97.72
		COVID-19	99.33	99.56	99.44	
		Normal	98.1	95.66	96.82	

Öznelik çıkarımı yaklaşımı sayesinde 1000 adet öznelikten 200 adedi seçilerek öznelik vektör boyutu beş kat küçültülmüştür. Bu sayede tüm özneliklerin kullanıldığı modele kıyasla işlem karmaşıklığı azaltılmış, hesaplama süresi kısalmış ve sınıflandırma hızı artmıştır. Bu işlem sonrasında modelin sınıflandırma başarısında ise belirgin bir düşüş yaşanmamıştır. Şekil 10'da bu modellerin ortalama eğitim süresi, Şekil 11'de ortalama sınıflandırma hızlarının karşılaştırıldığı grafikler ifade edilmiştir. Grafiklerde belirtilen süreler ve sınıflandırma hızları kullanılan donanıma göre değişebilmekle birlikte, yaklaşımlar birbiri ile kıyaslandığında oransal olarak benzer sonuçlar elde edilmektedir.



Şekil 10. Öznelik çıkarımı ve öznelik seçimi yaklaşımı ortalama eğitim süresi
Figure 10. Average training time for feature extraction and feature selection approach



Şekil 11. Öznitelik çıkarımı ve öznitelik seçimi yaklaşımı ortalama sınıflandırma hızı
Figure 11. Average classification speed for feature extraction and feature selection approach

Çalışmada önerilen yaklaşımlar ile elde edilen sonuçların literatürdeki benzer çalışmalar ile karşılaştırması Tablo 7’de ifade edilmiştir (C: COVID-19, Z: Zatürre, N: Normal). Tabloda da görüldüğü gibi kullanılan görüntü sayısı, görüntülerin sınıflara dengeli dağılımı itibariyle çalışmada anlamlı sonuçlar elde edildiği söylenebilir.

Tablo 7. Çalışmada elde edilen sonuçların literatürdeki diğer çalışmalarla karşılaştırılması
Table 7. Comparison of the results obtained in the study with other studies in the literature

Çalışma	Görüntü Sayısı (C ; Z ; N)	Yöntem	Doğruluk (%)
(Rahaman vd., 2020)	260; 300; 300	Öğrenme Aktarımı/Vgg19	89.3
(Öztürk vd., 2020)	125; 500; 500	DarkCOVIDNet	87
(Toraman vd., 2020)	231; 1050; 1050	CapsNet	84.2
(Wang vd., 2020)	358; 5538; 8066	COVID-Net	83.5
(Loey vd., 2020)	69; 79; 79	Öğrenme Aktarımı/AlexNet	85.2
(Sethy vd., 2020)	127; 127; 127	Öznitelik Çıkarımı/ResNet50 + DVM	95.3
(Apostolopoulos & Mpesiana, 2020)	224; 714; 504	Öğrenme Aktarımı/MobileNetV2	94.7
(Marques vd., 2020)	500; 500; 500	EfficientNet	96.7
(Uçar & Korkmaz, 2020)	1536; 1536; 1536	Bayes-SqueezeNet	98.3
(Chowdhury vd., 2020)	423; 1485; 1579	Öğrenme Aktarımı/DenseNet201	97.9
(Narin & İşler, 2021)	219; 1345; 1341	Öğrenme Aktarımı/ResNet50	97.3
(Tiwari & Jain, 2021)	219; 1345; 1341	VGG-CapsNet	92
(Abiyev & Ismail, 2021)	186; 1084; 1082	Öğrenme Aktarımı/CNN	98.3
(Aggarwal vd., 2022)	209; 250; 250	Öğrenme Aktarımı/DenseNet121	97
(Gopatoti & Vijayalakshmi, 2022)	Belirtilmemiş	DLCNN +EGWO-GA	97.05
(Kaya & Eriş, 2023)	1210; 1345; 1409	D3SENet	98.74
Bu Çalışma	1500; 1500; 1500	Öğrenme Aktarımı/ResNet50	99.2
Bu Çalışma	1500; 1500; 1500	Öznitelik Çıkarımı/DenseNet201+DVM	98.7
Bu Çalışma	1500; 1500; 1500	Öznitelik Seçimi/ResNet50 + DVM	98.3

4. Tartışma ve sonuçlar

4. Discussion and conclusions

COVID-19 salgını günümüzde hala etkinliğini sürdürmektedir. RT-PCR testi gibi teşhis yöntemleri özellikle maliyet, zaman ve sonuç duyarlılığı bakımından alternatif yöntemlerin gerekliliğini ortaya koymaktadır. Bununla birlikte bakteri kaynaklı zatürre de belirtileri bakımından bu hastalıkla karıştırılabilmektedir. Bu çalışmada COVID-19 hastaları, bakteri kaynaklı zatürre hastaları ve sağlıklı bireyleri ait akciğer röntgen görüntüleri üzerinden otomatik olarak sınıflandıran derin öğrenme tabanlı üç farklı yaklaşım önerilmiştir. İlk yaklaşımda öğrenme aktarımı yöntemi ve ResNet50 ağı kullanılarak geliştirilen model ile %99.2 sınıflandırma doğruluğu elde edilmiştir. İkinci yaklaşımda önceden eğitilmiş derin sinir ağı öznelik çıkarıcı olarak kullanılmıştır. DenseNet201 ağı ile elde edilen öznelik vektörünün Destek Vektör Makinesi ile sınıflandırıldığı model ile %98.7 sınıflandırma doğruluğuna ulaşılmıştır. Üçüncü yaklaşımda öznelik çıkarıcı olarak kullanılan önceden eğitilmiş derin sinir ağından elde edilen öznelik vektörü öznelik seçim işlemine tabi tutulmuştur. ResNet50 ağı ile elde edilen ve boyutu beş kat küçültülen öznelik vektörü Destek Vektör Makinesi ile sınıflandırılarak %98.3 doğruluk elde edilmiştir. Çalışma sonunda değerli özneliklerin seçilerek öznelik vektörünün boyut küçültülmesinin hem modelin eğitim süresini kısalttığı hem de modelin sınıflandırma hızına katkı sağladığı görülmüştür. Aynı zamanda önerilen öznelik seçimi yaklaşımı sayesinde sınıflandırma doğruluğunda belirgin bir kayıp yaşanmamıştır. Çalışma sınıflara ait toplam görüntü sayısı, bu görüntülerin eşit dağılımı, öznelik çıkarımı ve seçimi yaklaşımları bakımından literatürdeki nadir çalışmalardandır. Çalışmada önerilen modeller, akciğer röntgen görüntüleri üzerinden COVID-19 ve zatürre hastalığının tespitinde umut verici sonuçlar sunmuş olup, erken teşhis ve tedavi noktasında uzmanlara yardımcı olabilir. Yüksek sınıflandırma hızı ve doğruluğu sayesinde özellikle gerçek zamanlı karar destek sistemleri için kullanılabilir.

Yazar katkısı

Author contribution

Çalışmanın tüm aşamaları ilgili yazar tarafından gerçekleştirilmiştir. Bu makale 8-10 Mayıs 2024 tarihleri arasında Tokat'ta düzenlenen "Uluslararası Tıp, Eczacılık, Tarım, Gıda, Ormancılık, Çevre ve Mühendislikte Bilişim Teknolojileri Kongresi (INFTEC-2024)" adlı etkinlikte yazar tarafından sözlü bildiri olarak sunulan "Derin öğrenme tabanlı yaklaşımlarla akciğer röntgen görüntüleri üzerinden COVID-19 ve bakteri kaynaklı zatürrenin otomatik tespiti" başlıklı bildirinin tamamlanmış halidir.

Etik beyanı

Declaration of ethical code

Bu makalenin yazarı, bu çalışmada kullanılan materyal ve yöntemlerin etik kurul izni veya yasal-özel izin gerektirmediğini beyan etmektedir.

Çıkar çatışması beyanı

Conflicts of interest

Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

Kaynaklar

References

- Abdelhamid, A.A., Abdelhalim, E., Mohamed, M.A., & Khalifa, F. (2022). Multi-classification of chest x-rays for Covid-19 diagnosis using deep learning algorithms. *Applied Sciences*, 12(4):2080. <https://doi.org/10.3390/app12042080>
- Abiyev, R. H., & Ismail, A. (2021). Covid-19 and pneumonia diagnosis in x-ray images using convolutional neural networks. *Mathematical Problems in Engineering*, 2021, 14 pages. <https://doi.org/10.1155/2021/3281135>
- Agchung. (2023, December 21). <https://github.com/agchung>

- Aggarwal, S., Gupta, S., Alhudhaif, A., Koundal, D., Gupta, R., & Polat, K. (2022). Automated Covid-19 detection in chest X-ray images using fine-tuned deep learning architectures. *Expert Systems*, 39(3), <https://doi.org/10.1111/exsy.12749>
- Apostolopoulos, I. D., & Mpesiana, T. A. (2020). Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, 43(2), 635–640. <https://doi.org/10.1007/s13246-020-00865-4>
- Azimi-Pour, M., Eskandari-Naddaf, H., & Pakzad, A. (2020). Linear and non-linear SVM prediction for fresh properties and compressive strength of high volume fly ash self-compacting concrete. *Construction and Building Materials*, vol 230. <https://doi.org/10.1016/j.conbuildmat.2019.117021>
- Chen, C. W., Tsai, Y. H., Chang, F.R., & Lin, W.C. (2020). Ensemble feature selection in medical datasets: Combining filter, wrapper, and embedded feature selection results. *Expert Systems*, 37(5). <https://doi.org/10.1111/exsy.12553>
- Chest X-ray (Covid-19 & Pneumonia). (2023, December 21). <https://www.kaggle.com/prashant268/chest-xray-covid19-pneumonia>
- Chest X-Ray Images (Pneumonia). (2023, December 21). <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>
- Chowdhury, M., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M., Mahbub, Z., Islam, K., Khan, M. S., Iqbal, A., Al-Emadi, N., Reaz, M.B.I., & Islam, M. (2020). Can AI help in screening viral and Covid-19 pneumonia?. *IEEE Access*. 8. 132665 -132676. doi: 10.1109/ACCESS.2020.3010287
- Classification of COVID viral bacterial pneumonia. (2023, December 21). <https://www.kaggle.com/sriramthakur/classification-of-covid-viral-bacterial-pneumonia>
- CoronaHack-Chest X-Ray-Dataset. (2023, December 21). <https://www.kaggle.com/datasets/praveengovi/coronahack-chest-xraydataset>
- COVID-19 Detection X-Ray Dataset. (2023, December 21). <https://www.kaggle.com/datasets/darshan1504/covid19-detection-xray-dataset>
- COVID-19 Radiography Database. (2023, December 21). <https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>
- Covid-19 Image Dataset (2023, December 21). <https://www.kaggle.com/datasets/pranavraikokte/covid19-image-dataset>
- Covid-chestxray-dataset. (2023, December 21). <https://github.com/ieee8023/covid-chestxray-dataset>
- Gopatoti, A., & Vijayalakshmi, P. (2022). CXGNet: A tri-phase chest X-ray image classification for Covid-19 diagnosis using deep CNN with enhanced grey-wolf optimizer. *Biomedical Signal Processing and Control*, Vol. 77, 103860, ISSN 1746-8094. <https://doi.org/10.1016/j.bspc.2022.103860>.
- Haryanto, T., Wasito, I., & Suhartanto, H. (2017). Convolutional neural network (CNN) for gland images classification. *11th International Conference on Information & Communication Technology and System (ICTS)*, pp. 55-60. doi: 10.1109/ICTS.2017.8265646.
- He, K., Zhang, X., Ren, S., & Sun J. (2015). Deep residual learning for image recognition. *arXiv:1512.03385v1*. <https://doi.org/10.48550/arXiv.1512.03385>
- Huang, G., Liu, Z., Maaten, L.V.D., & Weinberger, K.Q. (2017). Densely connected convolutional networks. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2261-2269. doi: 10.1109/CVPR.2017.243
- Kaggle. (2023, December 5). <https://www.kaggle.com>
- Kaissis, G.A., Makowski, M.R., Rückert, D., & Braren, R.F. (2020). Secure, privacy-preserving and federated machine learning in medical imaging. *Nature Machine Intelligence* 2, 305-311. <https://doi.org/10.1038/s42256-020-0186-1>
- Kanne, J.P., Little, B.P., Chung, J.H., Elicker, B.M., & Ketai, L.H. (2020). Essentials for radiologists on Covid-19: An Update-Radiology Scientific Expert Panel. *Radiology*, 296(2). <https://doi.org/10.1148/radiol.2020200527>

- Kaya, M., & Eris, M. (2023). D3SENet: A hybrid deep feature extraction network for Covid-19 classification using chest X-ray images. *Biomedical Signal Processing and Control*, Vol. 82, 104559, ISSN 1746-8094. <https://doi.org/10.1016/j.bspc.2022.104559>
- Kilicarslan, S., Adem, K., & Celik, M. (2020). Diagnosis and classification of cancer using hybrid model based on ReliefF and convolutional neural network. *Medical Hypotheses*, 137, 109577. <https://doi.org/10.1016/j.mehy.2020.109577>
- Korot, E., Guan, Z., Ferraz, D., Wagner, S.K., Zhang, G., Liu, X., Faes, L., Pontikos, N., Finlayson, S.G., Khalid, H., Moraes, G., Balaskas, K., Denniston, A.K., & Keane, P.A. (2021). Code-free deep learning for multi-modality medical image classification. *Nature Machine Intelligence* 3, 288-298. <https://doi.org/10.1038/s42256-021-00305-2>
- Loey, M., Smarandache, F., & Khalifa, N.E. (2020). Within the lack of chest Covid-19 X-ray dataset: A novel detection model based on GAN and deep transfer learning. *Symmetry*, 12(4), 651. <https://doi.org/10.3390/sym12040651>
- Marmanis, D., Datcu, M., Esch, T., & Stilla, U. (2016). Deep learning Earth observation classification using ImageNet pretrained networks. *IEEE Geoscience and Remote Sensing Letters*, 13(1), pp. 105-109. doi: 10.1109/LGRS.2015.2499239
- Marques, G., Agarwal, D., & de la Torre Diez, I. (2020). Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network. *Applied soft computing*, 96, 106691. <https://doi.org/10.1016/j.asoc.2020.106691>
- Chen, N., Zhou, M., Dong, X., Qu, J., Gong, F., Han, Y., Qiu, Y., Wang, J., Liu, Y., Wei, Y., Xia, J., Yu, T., Zhang, X., & Zhang, L. (2020). Epidemiological and clinical characteristics of 99 cases of 2019 novel coronavirus pneumonia in Wuhan, China: a descriptive study. *Lancet (London, England)*, 395(10223), 507–513. [https://doi.org/10.1016/S0140-6736\(20\)30211-7](https://doi.org/10.1016/S0140-6736(20)30211-7)
- Narin, A. & Isler, Y. (2021). Detection of new coronavirus disease from chest x-ray images using pre-trained convolutional neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(4):2095-2107. <https://doi.org/10.17341/gazimmfd.827921>
- Narin, A., Kaya, C., & Pamuk, Z. (2021). Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks. *Pattern Analysis and Applications : PAA*, 24(3), 1207–1220. <https://doi.org/10.1007/s10044-021-00984-y>
- Nasip, Ö.F., & Zengin, K. (2018). Deep learning based bacteria classification. *2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), Ankara, Turkey*, pp. 1-5. doi: 10.1109/ISMSIT.2018.8566685
- Omuya, E.O., Okeyo, G.O., & Kimwele, M.W. (2021). Feature selection for classification using principal component analysis and information gain. *Expert Systems with Applications*, 174(11):114765. <https://doi.org/10.1016/j.eswa.2021.114765>
- Ozturk, T., Talo, M., Yildirim, E.A., Baloglu, U.B., Yildirim, O., & Acharya, U.R. (2020). Automated detection of Covid-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine*, 121:103792. <https://doi.org/10.1016/j.compbimed.2020.103792>
- Pławiak, P. & Tadeusiewicz, R. (2014). Approximation of phenol concentration using novel hybrid computational intelligence methods. *International Journal of Applied Mathematics and Computer Science*, 24, 165-181. doi: 10.2478/amcs-2014-0013
- Pneumonia & COVID-19 Image Dataset. (2023, December 21). <https://www.kaggle.com/gibi13/pneumonia-covid19-image-dataset>
- Priyadarsini, R.P., Valarmathi, M.L., & Sivakumari, S. (2010). Gain ratio based feature selection method for privacy preservation. *ICTACT Journal on Soft Computing* 01(04):201-205. doi: 10.21917/ijsc.2011.0031
- Rahaman, M.M., Li, C., Yao, Y., Kulwa, F., Rahman, M.A., Wang, Q., Qi, S., Kong, F., Zhu, X., & Zhao, X. (2020). Identification of Covid-19 samples from chest X-Ray images using deep learning: A comparison of transfer learning approaches. *Journal of X-ray Science and Technology*, 28(5), 821–839. <https://doi.org/10.3233/XST-200715>

- Saeys, Y., Inza, I., & Larranaga, P. (2007). A review of feature selection techniques in bioinformatics. *Bioinformatics*, 23(19):2507-17. <https://doi.org/10.1093/bioinformatics/btm344>
- Sethy, P.K., Behera, S.K., Ratha, P.K., & Biswas, P. (2020). Detection of coronavirus disease (Covid-19) based on deep features and support vector machine. *International Journal of Mathematical, Engineering and Management Sciences*, 5(4), 643-651. <https://doi.org/10.33889/IJMEMS.2020.5.4.052>
- Simonyan, K. & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv*. <https://doi.org/10.48550/arXiv.1409.1556>
- Singh, D., Kumar, V., Kaur, M., & Kumari, R. (2022). Early diagnosis of Covid-19 patients using deep learning-based deep forest model. *Journal of Experimental & Theoretical Artificial Intelligence*. <https://doi.org/10.1080/0952813X.2021.2021300>.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., & Liu, C. (2018). A survey on deep transfer learning. *arXiv*. <https://doi.org/10.48550/arXiv.1808.01974>
- Tiwari, S. & Jain, A. (2021). Convolutional capsule network for Covid-19 detection using radiography images. *International Journal of Imaging Systems and Technology*, 31(2):525-539. <https://doi.org/10.1002/ima.22566>
- Toraman, S., Alakus, T.B., & Turkoglu, I. (2020). Convolutional capsnet: A novel artificial neural network approach to detect Covid-19 disease from X-ray images using capsule networks. *Chaos, Solitons & Fractals*, Vol. 140, 110122, ISSN 0960-0779. <https://doi.org/10.1016/j.chaos.2020.110122>
- Ucar, F. & Korkmaz, D. (2020). COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. *Medical Hypotheses*, Vol. 140, 109761, ISSN 0306-9877. <https://doi.org/10.1016/j.mehy.2020.109761>
- Wang, L., Lin, Z.Q., & Wong, A. (2020). COVID-Net: A tailored deep convolutional neural network design for detection of Covid-19 cases from chest X-ray images. *Scientific Reports*, 10, 19549. <https://doi.org/10.1038/s41598-020-76550-z>
- Wang, L., Johnson, D., & Lin, Y. (2021). Using EEG to detect driving fatigue based on common spatial pattern and support vector machine. *Turkish Journal of Electrical Engineering & Computer Sciences*; 29(3): 1429-1444. <https://doi.org/10.3906/elk-2008-83>
- WHO COVID-19 Dashboard. (2024, February 10). <https://covid19.who.int>
- Wong, H.Y.F., Lam, H.Y.S, Fong, A.H., Leung, S.T., Chin, T.W., Lo, C.S.Y., Lui, M.M., Lee, J.C.Y., Chiu, K.W., Chung, T.W., Lee, E.Y.P., Wan, E.Y.F., Hung, I.F.N., Lam, T.P.W., Kuo, M.D., & Ng, M.Y. (2020). Frequency and distribution of chest radiographic findings in patients positive for Covid-19. *Radiology*. 296(2), E72–E78. <https://doi.org/10.1148/radiol.2020201160>
- Zhao, B., Huang, B., & Zhong, Y. (2017). Transfer learning with fully pretrained deep convolution networks for land-use classification. *IEEE Geoscience and Remote Sensing Letters*, 14(9), pp. 1436-1440. doi: 10.1109/LGRS.2017.2691013
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., & He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, pp. 1-34. doi: 10.1109/JPROC.2020.3004555