T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME YÖNTEMLERİ KULLANARAK BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN COVİD-19'UN TESPİT EDİLMESİ

Semiha GÜNGÖR

Yüksek Lisans Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

HAZİRAN 2021

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

DERİN ÖĞRENME YÖNTEMLERİ KULLANARAK BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN COVİD-19'UN TESPİT EDİLMESİ

Tez Yazarı
Semiha GÜNGÖR

Danışman
Prof. Dr. Mehmet KAYA

HAZİRAN 2021
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Derin Öğrenme Yöntemleri Kullanarak Bilgisayarlı Tomografi Görüntülerinden Covid-19'un Tespit Edilmesi
Yazarı:	Semiha GÜNGÖR
İlk Teslim Tarihi:	08.06.2021
Savunma Tarihi:	28.06.2021

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

	İmza	
Danışman:	Prof. Dr. Mehmet KAYA Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Başkan:	Prof. Dr. Burhan ERGEN Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Hüseyin VURAL Adıyaman Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun ...../...../20..... tarihli toplantısında tescillenmiştir.

İmza

Doç. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım "Derin Öğrenme Yöntemleri Kullanarak Bilgisayarlı Tomografi Görüntülerinden Covid-19'un Tespit Edilmesi" Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

28.06.2021

Semiha GÜNGÖR

ÖNSÖZ

Covid-19, 2019 yılında ortaya çıkmış ve çok kısa sürede tüm dünyaya yayılarak pandemiye dönüşmüştür. Pandemiyi tamamen önlemek veya en azından virüsün vereceği muhtemel zararları minimize etmek için hastalığın erken teşhisi çok büyük önem arz etmektedir. Yani, en azından şüpheli vakaların düşük hata ile doğru ve hızlı bir şekilde tespiti gerekmektedir. Bu noktada, derin öğrenme teknikleri ile Covid-19'un tespit edilmesi hastalığın doğru ve hızlı bir şekilde tespit edilmesine katkı sağlayabilir.

Bu çalışmada bilgi ve deneyimleri ile beni yönlendiren, ilgi ve desteklerini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım ve her konuda yardımcı olmaya çalışan, sayın hocam Prof. Dr. Mehmet KAYA 'ya sonsuz teşekkürlerimi sunarım. Bugünlere gelmemde çok büyük fedakârlıkları olan aileme ve maddi manevi hiçbir yardımı esirgemeyen eşime tüm kalbimle teşekkürlerimi sunarım.

Bu tez çalışması, Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) tarafından **MF.20.40** protokol numaralı proje ile desteklenmiştir.

Semiha GÜNGÖR
ELAZIĞ, 2021

İÇİNDEKİLER

Sayfa

ÖNSÖZ iv
İÇİNDEKİLER v
ÖZET vi
ABSTRACT vii
ŞEKİLLER LİSTESİ viii
TABLOLAR LİSTESİ ix
KISALTMALAR x

1. GİRİŞ 11
1.1. Tezin Amacı 13
1.2. Tezin Yapısı 13

2. COVİD-19 TESPİTİ İÇİN KULLANILAN YAKLAŞIMLAR 14

3. MATERYAL VE METOT 27
3.1. Derin Öğrenme 27
3.2. Evrişimsel Sinir Ağları (CNN) 28
3.3. DenseNet 30
3.4. Veri Seti 31
3.4.1. DeOldify 31
3.5. Ön İşleme 33
3.5.1. Görüntü Yeniden Boyutlandırma 33
3.5.2. Görüntü Normalleştirme 33
3.5.3. Veri Arttırma 33
3.5.4. Veri Bölme 34
3.6. Deneysel Çalışma 34
3.6.1. Hiperparametreler 35
3.7. Değerlendirme Ölçütleri 36

4. BULGULAR VE TARTIŞMA 39

5. SONUÇ 44
KAYNAKLAR 45
ÖZGEÇMİŞ

ÖZET

Derin Öğrenme Yöntemleri Kullanarak Bilgisayarlı Tomografi Görüntülerinden Covid-19'un Tespit Edilmesi

Semiha GÜNGÖR

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Haziran 2021, Sayfa: x + 49

Aralık 2019'un sonlarından bu yana Çin'in Wuhan kentinde yeni bir koronavirüs hastalığı Covid-19 kaydedildi ve daha sonra dünya çapında pandemik hale geldi. Covid-19'un, alveollerde bıraktığı hasar ve ilerleyen solunum yetmezliğinin bir sonucu olarak ölümle sonuçlanabilir. Klinik tanı için kullanılan transkripsiyon polimeraz zincir reaksiyonu (RT-PCR) altın standart olmasına rağmen testler yanlış negatifler üretebilir. Ayrıca pandemik durumda RT-PCR test kaynaklarının yetersizliği, tanıyı ve tedaviyi de geciktirebilir. Bu koşullar altında göğüs BT görüntülemesi, Covid-19 hastalarının hem tanı hem de prognozu için değerli bir araç haline gelmiştir. Yakın zamanda BT taramalarında Covid-19 tanısını kolaylaştırmak ve sağlık çalışanlarına yardımcı olmak için derin öğrenme teknikleriyle geliştirilmiş birçok çalışma önerilmiştir.

Çalışmamız, DeOldify kütüphanesini kullanarak renklendirilen BT veri seti ile derin öğrenme tekniklerinden DenseNet121'i kullanarak Covid-19'u, Covid-19 olmayan vakalardan ayırt etmeye odaklanmaktadır. Çalışmamızın sonunda %98'lik doğruluk elde edilmiştir.

Anahtar Kelimeler: Derin Öğrenme, Covid-19, Bilgisayarlı Tomografi, DeOldify.

ABSTRACT

Detecting Covid-19 from Computed Tomography Images Using Deep Learning Methods

Semiha GÜNGÖR

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences

Department of Computer Engineering

June 2021, Pages: x + 49

A new coronavirus disease Covid-19 has been recorded in Wuhan, China since late December 2019 and later became a worldwide pandemic. It can result in death as a result of covid-19's damage to the alveoli and progressive respiratory failure. Although transcription polymerase chain reaction (RT-PCR) is the gold standard used for clinical diagnosis, tests can produce false negatives. In addition, in the event of a pandemic, the lack of RT-PCR testing resources may delay diagnosis and treatment. Under these circumstances, Computed Tomography (CT) scans have become a valuable tool for both early diagnosis and prognosis of Covid-19 patients. Recently, many studies developed with deep learning techniques have been proposed to facilitate the diagnosis of Covid-19 in CT scans and to assist healthcare professionals.

This thesis focuses on distinguishing COVİD-19 from non-Covid-19 cases using DenseNet121, one of the deep learning techniques, with the CT dataset colored using the DeOldify library. At the end of our study, an accuracy of 0.98 was obtained.

Keywords: Deep Learning, Covid-19, Computer Tomography, DeOldify.

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.1. Dünya genelinde Covid-19 ile enfekte kişilerin ayrıntılı istatistikleri. 12

Şekil 3.1. Covid-19 tespiti için kullanılan çeşitli DL yöntemlerinin illüstrasyonu [41]..... 27

Şekil 3.2. DL kullanarak Covid-19 tespiti için blok diyagramı [41]..... 28

Şekil 3.3. DenseNet mimarisinin şematik gösterimi. 30

Şekil 3.4. DeOldify ile renklendirilip karıştırılan Covid-19 BT tarama görüntülerine örnekler. 32

Şekil 3.5. DeOldify ile renklendirilip karıştırılan non-Covid-19 BT tarama görüntülerine örnekler. 32

Şekil 4.1. Normal veri seti ile elde ettiğimiz karışıklık matrisi. 39

Şekil 4.2. Renklendirdiğimiz veri seti ile elde ettiğimiz karışıklık matrisi. 430

Şekil 4.3. Karıştırdığımız veri seti ile %96,87 başarı elde ettiğimiz karışıklık matrisi. 40

Şekil 4.4. Modelin karışıklık matrisi. 42

Şekil 4.5. Kayıp eğrisi. 43

TABLOLAR LİSTESİ

Sayfa

Tablo 2.1. Derin öğrenme tabanlı Covid-19 tespiti yapan çalışmaların özeti. 22

Tablo 3.1. Veri sayıları. 33

Tablo 3.2. Kullanılan veri arttırma teknikleri ve aralıkları. 34

Tablo 3.3. Karışıklık matrisi 36

Tablo 4.1. Performans metriklerinin sonuçları 41

Tablo 4.2. Yöntemlerin karşılaştırılması. 41

KISALTMALAR

Kısaltmalar

BT : Bilgisayarlı Tomografi
CNN : Convolutional Neural Network
DL : Deep Learning
WHO : World Health Organization

1. GİRİŞ

Covid-19, 2019 yılı Aralık ayında Çin'in Wuhan kentinde ortaya çıkmış, çok kısa zamanda tüm dünyaya yayılarak pandemiye dönüşmüş ve birçok ülkenin sağlık sisteminde büyük sorunlara sebep olmuş ciddi bir salgın hastalıktır. Covid-19 dünya çapında birçok ülkenin karantina kararı almasına ve sayısız endüstriyel sektörün iflas etmesine sebep oldu. Bu da dünya çapında bir mali krize neden oldu. Şiddetli akut solunum sendromu Covid-19, bulaştığı canlılarda önemli düzeyde solunum yetmezliğine sebep olmakta, akciğerde kalıcı hasarlara neden olmakta ve hastalığın ilerlemesi halinde ise ölümcül sonuçlarla karşılaşılmaktadır.

Hastalığın en belirgin semptom ve enfeksiyon belirtileri; ateş, kuru öksürük, boğaz ağrısı, baş ağrısı, halsizlik, kas ağrısı, ishal ve nefes darlığı olarak bilinmektedir ancak bazı senaryolarda hiçbir belirti görülmez (asemptomatik). Daha ileri durumlarda, şiddetli zatürreye yol açarak oksijen farklılığından kaynaklı akciğerlerde iltihaplanmalara ve kalp ve damar sistemlerinin organlara yeterli kanı uygun oranda götürememesi nedeniyle oluşan ani dolaşım yetmezliği ile çoklu organ yetmezliğine neden olmaktadır. Kronik rahatsızlıkları olanları, vücut direnci veya bağışıklık sistemi zayıf olanları, sigara kullananları ve yaşlıları Covid-19 hastalığı daha çok etkilemektedir [1]. Erken teşhis ve tanı, Covid-19 yayılımını kontrol etmek ve önlemek için kritik bir faktördür.

Covid-19, genellikle virüsü taşıyan kişilerle nefes, el veya mukoza teması yolu gibi fiziksel temas ile bulaşmaktadır. Virüs kendini solunum sistemi yoluyla akciğer hücrelerine sokar ve orada çoğalır, bu da akciğer hücrelerini yok eder. Covid-19 bir RNA içerir ve mutasyon özellikleri nedeniyle teşhis edilmesi ve tedavi edilmesi çok zordur. Hastalığın bulaşması sonrasında tedavi edilmesinde, genel olarak antibiyotik, sıtma ilacı, ateş düşürücü, öksürük ilacı ve ağrı kesici kullanılmaktadır. Virüs bulaşmış hastanın, hastalık düzeyine, şikâyetlerine ve ciddiyetine göre hastaneye yatırılması kararlaştırılmaktadır [2].

Dünya genelinde, Covid-19 virüslü hasta sayısı hastalığın ilk evrelerinden bu yana, çarpıcı bir şekilde arttı ve Covid-19, dünya sağlık örgütü tarafından uluslararası bir halk sağlığı acil durumu olarak kaydedildi. 31 Mayıs 2021'e kadar dünya sağlık örgütü (WHO) tarafından sağlanan Covid-19 durum raporuna göre 169,597,415 doğrulanmış vaka olduğu ve Covid-19'un 3,530,582 insanın ölümüne sebep olduğu belirtilmiştir. İstatistiksel bir Covid-19 salgını Şekil 1.1.'de temsil edilmiştir. Bu veriler her geçen gün değişiyor çünkü Covid-19 kuvvetli bir şekilde yayılıyor. Bütün bu bilgiler ışığında, sağlık sistemini de dikkate alarak pandemiyi tamamen önlemek veya en azından virüsün vereceği muhtemel zararları minimize etmek için hastalığın erken teşhisi çok büyük önem arz etmektedir. Yani, en azından şüpheli vakaların düşük hata ile doğru ve hızlı bir şekilde tespiti gerekmektedir.

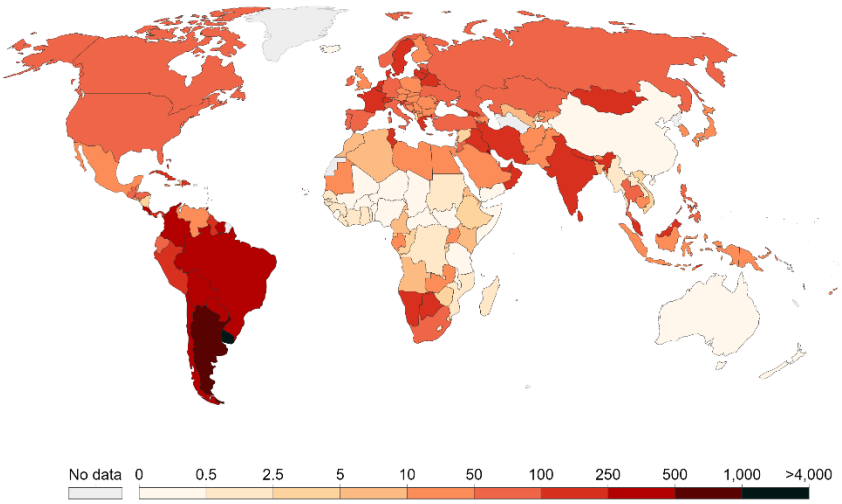

Şekil 1.1. Dünya genelinde Covid-19 ile enfekte kişilerin ayrıntılı istatistikleri

Hâlihazırda Covid-19 tanı ve teşhisi amacıyla, gerçek zamanlı bir ters transkripsiyon-polimeraz zincir reaksiyonu (RT-PCR) tekniği yaygın olarak kullanılmaktadır. Erken evrelerde Covid-19 tanısını koymak için Bilgisayarlı Tomografi (BT) ve X-ışını gibi göğüs radyolojik görüntüleme yöntemleri tercih edilmektedir [1].

BT görüntülerinde enfeksiyon bölgelerinin düşük kontrastı ve farklı hastalarda lezyonların hem şekil hem de pozisyonlarındaki büyük farklılıklar nedeniyle, göğüs BT taramalarında enfeksiyon bölgelerinin tanımlanması çok zordur. BT görüntüleri, organların, kemiklerin, yumuşak dokuların ve kan damarlarının ayrıntılı görüntülerini üretir. BT taramaları, doktorların içyapıları tanımlamalarına ve şekillerini, boyutlarını, yoğunluklarını ve dokularını görmelerine imkân sağlar. Geleneksel X-Işınlarından farklı olarak, BT görüntüleri, farklı vücut yapılarını kaplamadan vücudun belirli bir bölgesinin bir dilimini üretir. Bu nedenle, BT görüntüleri, hastanın durumunun geleneksel X-Işınlarından çok daha ayrıntılı bir görüntüsünü verir bu da hasta prognozunun belirlenmesi ve doktorlar tarafından Covid-19 hastalığının seyrinin değerlendirilmesine yardımcı olmak için göğüs BT muayenelerin artan bir şekilde kullanılmasına yol açmıştır. Bu ayrıntılı bilgiler, tıbbi bir sorunun olup olmadığını, sorunun büyüklüğünü ve tam yerini belirlemek için kullanılabilir. Bu nedenlerden dolayı, BT taramalarında Covid-19 taraması için yakın zamanda bir dizi derin öğrenme temelli yöntem önerilmiştir.

Bu geleneksel tıbbi görüntüleme yöntemleri, hastalığın hızlı yayılmasının kontrolünde hayati bir rol oynamaktadır. Söz konusu hastalığın çok hızlı yayılması ve birçok ülkede ölüm oranlarının artması etkili bir tedavi yönteminin geliştirilmesi gerektiğini ortaya koymaktadır. Bu nedenle teşhis, erken karantina ve takip dâhil olmak üzere hastalığın kontrolü zorunlu hale gelmektedir. Bu noktada, derin öğrenme teknikleri, yukarıdaki perspektiflere katkıda bulunabilir.

Günümüzde, özellikle tıbbi alanda, retina görüntüsü, göğüs röntgeni ve beyin MRG gibi görüntü veri setleri ile derin öğrenme tekniklerini kullanarak başarılı sonuçlar elde edilmektedir [3]. Derin öğrenme ve makine öğrenimi teknikleri; verilerden kalıpları çıkarmak, analiz etmek ve tanımak için birçok uygulamada kullanılmaktadır [4].

Derin öğrenme (DL), beyin anormalliklerinin sınıflandırılması, farklı kanser türlerinin sınıflandırılması, patojenik bakterilerin sınıflandırılması ve biyomedikal görüntü segmentasyonu gibi tıbbi veri setleriyle uğraşmak ve başarılı sonuçlar elde etmek için en yaygın ve doğru yöntemdir.

Bu çalışmada, etkili bir model oluşturmak için yaygın olarak kullanılan derin öğrenme yaklaşımlarından DenseNet121 yöntemi kullanılarak BT görüntülerinden iki farklı durum (Covid-19 ve non-Covid-19) içerisinden Covid-19 olan hastaların tanı ve tespiti üzerine yapılan çalışmalar anlatılmıştır.

1.1. Tezin Amacı

Bu tezin amacı, derin öğrenme yöntemi kullanarak bilgisayarlı tomografi görüntülerinden otomatik olarak Covid-19'u tespit etmektir.

1.2. Tezin Yapısı

Tezin bundan sonraki bölümleri aşağıdaki gibi organize edilmiştir: Bölüm 2'de Covid-19'u tespit etmek için şimdiye kadar önerilen yöntemler sunulmuştur. Bölüm 3'de materyal ve metot detaylı olarak açıklanmıştır. Bölüm 4'de bulgular ve tartışma anlatılmıştır. Bölüm 5 ise tezin sonuç kısmını içerir.

2. COVİD-19 TESPİTİ İÇİN KULLANILAN YAKLAŞIMLAR

Geleneksel makine öğrenimi ve derin öğrenme, yapay zekânın iki önemli dalıdır, ancak derin öğrenme aslında geleneksel makine öğreniminin daha gelişmiş bir versiyonudur. Çeşitli derin öğrenme ağları, birçok genel veri tabanını kullanarak Covid-19'u doğru bir şekilde teşhis etmek için yaygın olarak kullanılmıştır.

Wu ve ark. [5] çoklu görünüm füzyonu kavramını kullanarak derin öğrenmeye dayalı bir koronavirüs tarama sistemi tanıttı. Sistem, CNN varyantı olan ResNet50'yi kullandı. Veri seti Çin'deki iki hastaneden toplanmıştır. 368'i doğrulanmış Covid-19 vakaları ile ilişkili olduğu ve 127'si diğer pnömoni grubuna dahil olduğu, deney için toplam 495 görüntü dikkate alınmıştır. Bu şemada, veri kümesi sırasıyla eğitim, test ve doğrulama için %80, %10 ve %10'luk bir orana bölünmüştür. Sistemde ele alınan görüntülerin her biri, ağ geliştirmeden önce 256 × 256 olarak yeniden boyutlandırılır. Test durumunda, geliştirilen sistem %76 doğruluk, %81.1 duyarlılık, %61.5 özgüllük ve %81.9 eğri altındaki alan (AUC) elde etti. Sonuçlar hem tek görünüm hem de çoklu görünüm füzyon modeli için analiz edilmiştir, ancak çoklu görünüm füzyon modeli üstün performans göstermiştir.

Başka bir çalışmada, Covid-19'un doğru teşhisi için Yousefzadeh ve ark. [6] BT görüntülerine dayanarak çalışan AI-Corana adlı derin öğrenme sistemini tanıtmıştır. Sistem, DenseNet, ResNet, Xception ve EfficientNetB0 adlı çeşitli CNN varyantlarından oluşmuştur. Kullanılan veri seti, 1418 görüntünün Covid-19 olmayan ve 706'sının Covid-19 ile enfekte olmuş vakalardan oluştuğu genel olarak 2124 BT görüntüsü içeriyordu. Veri seti, eğitim ve doğrulama seti için sırasıyla %80 ve %20 oranını ile bölünmüştür. Önerilen sistem, deneyden %96.4 doğruluk, %92.4 duyarlılık, %98.3 özgüllük, %95.3 F1-Skoru ve %98.9 AUC buldu.

Jin ve ark. [7] ResNet152 adlı bir CNN varyantı kullanarak yapay zekâ tabanlı Covid-19 tespit sistemi geliştirdi. Önceden eğitilmiş model 152 konvolüsyonel alt örnekleme ve tam bağlı katman kullandı. Veri seti üç ünlü Çin hastanesinden ve halka açık iki veri tabanından toplanmıştır. 496 vakanın Covid-19 ile enfekte hastalar için olduğu ve 1385 vakanın negatif olduğu toplam 1881 vaka göz önünde bulundurulmuştur. Sistem deneyden %94.98 doğruluk, %94.06 duyarlılık, %95.47 özgüllük, %91.53 hassasiyet, %92.78 F1-Skoru ve %97.91 AUC elde etti.

Başka bir çalışmada, Xu ve ark. [8] CNN varyantlarını kullanarak sağlıklı bireyleri, Covid-19 hastalarını ve İnfluenza-A viral pnömonisini sınıflandırmak için bir sistem geliştirdi. Bu sistemde kullanılan önceden eğitilmiş model ResNet18'dir. Bu çalışmada, Covid-19 ile enfekte olmuş hastalardan 219, İnfluenza-A viral pnömoniden 224 ve normal bireylerden 175 görüntü ile elde edilen toplam 618 BT görüntüsünü ele almaktadır. Modeli eğitmek için toplam %85.4 (528) görüntü kullanılmış ve kalan örnekler geliştirilen modeli test etmek için kullanılmıştır. Sistem, deneyden %86.7 doğruluk, %81.5 hassasiyet, %80.8 duyarlılık ve %81.1 F1-Skoru elde etti.

Jin ve ark. [9] derin öğrenme tekniklerini kullanarak Covid-19 taraması için tıbbi bir sistem tanıttı. Sistemleri, 3D U-NetCC ile DPN-92, Inception-v3, ResNet50 ve Attention ResNet50 gibi çeşitli önceden eğitilmiş CNN modellerini kullandı. Veri seti Çin'deki farklı beş hastaneden alındı. Bu sistemde, Covid-19'dan 850 örnek ve negatif olarak kabul edilen diğer vakalardan 541 örnek olmak üzere toplam 1391 örnek kullanılmaktadır. Toplam veriler rastgele performans değerlendirmesi için eğitim ve test setlerine ayrılmıştır. Değerlendirme ölçütleri olarak, en iyi model olarak kabul edilen 3D UnetCC-ResNet50 kullanılarak sırasıyla %97.4, %92.2 ve %99.1 duyarlılık, özgüllük ve AUC elde etti.

Javaheri ve ark. [10] BT görüntüleri ile koronavirüs enfeksiyonunu tespit etmek için CovidCTNet adlı derin öğrenme yaklaşımı geliştirdi. Sistem U-Net temelinde geliştirilen BCDU-Net mimarisini kullanır. Sistem, Covid-19'u CAP ve diğer akciğer hastalıklarından ayırdı. Deney için, sistem toplamda 89,145 BT görüntü kullandı; burada 32,230 BT görüntüsü Covid-19 ile doğrulandı, 25,699 BT görüntüsü CAP ile doğrulandı ve 31,216 BT görüntüsü sağlıklı akciğerler veya başka bir bozuklukla doğrulandı. Veri kümesi hold-out yöntemi kullanılarak bölümlendirilir, yani %90 eğitim için kullanılır ve %10 test için kullanılır. Deneysel sonuçlardan, geliştirilen sistemin sırasıyla %91.66, %87.5, %94 ve %95 doğruluk, duyarlılık, özgüllük, AUC elde ettiği açıktır.

Ardakani ve ark. [11] BT görüntülerinde CNN tekniklerinin on varyantını kullanarak Covid-19'un tespiti için bir sistem önerdi. Tanı için kullanılan popüler varyantlar AlexNet, VGG-16, VGG-19, SqueezeNet, GoogleNet, MobileNet-V2, ResNet-18, ResNet-50, ResNet-101 ve Xcepsiyon'dur. Önerilen sistemde, Covid-19 ve Covid-19 olmayan vakalardan toplam 1020 BT örneği ele alınmıştır. Veri kümesi, sırasıyla %80 ve %20 oranında eğitim ve doğrulama kümesine ayrılmıştır. Bu on ağın arasından ResNet-101 ve Xception diğerlerinden nispeten daha iyi performans gösterdi. Deneysel sonuçlardan, ResNet-101 modelinin %99.51 doğruluk, %100 duyarlılık, %99.4 AUC ve %99.02 özgüllük elde ettiği açıktır. Başka bir ağ olan Xception, sırasıyla %99.02, %98.04, %87.3 ve %100 doğruluk, duyarlılık, AUC ve özgüllüğü buldu.

Başka bir çalışmada, Chen ve ark. [12], Covid-19 tespiti için yüksek çözünürlüklü BT görüntülerine UNetCC adlı önceden eğitilmiş modelin uygulandığı derin öğrenmeye dayalı bir şema tanıttı. Başlangıçta, UNetCC BT görüntülerinde geçerli bölgeleri çıkardı. Bu çalışmada bir hastaneden, 51 Covid-19 enfekte hasta ve 55 diğer hastalıklarla enfekte olan hastalardan 46.096 görüntü toplanmıştır. Veri kümesinde filtreleme kullanılarak düşük görüntüleri ortadan kaldırarak görüntüler seçilir ve sırasıyla eğitim ve test setine bölünür. %94.34 duyarlılık, %99.16 özgüllük, %98.85 doğruluk, %88.37 hassasiyet ve %99.61 negatif prediktif değer (npv) elde edilir.

Cifci [13], derin transfer öğrenimi ile önceden eğitilmiş çeşitli modeller kullanarak koronavirüsün erken teşhisi için bir şema sunmuştur. Önceden eğitilmiş modeller, tıbbi görüntü analizi için popüler olan AlexNet ve Inception-V4'tür. Çalışma BT görüntüleri ile gerçekleştirilir. Sistemi geliştirmek için, 5800 BT görüntüleri bir kamu deposundan alınır. Eğitim için, 4640 (%80) BT

numunesi kullanılırken, test için 1160 (%20) numune kullanılır. AlexNet, deneysel sonuçlarla bulunan Inception-V4'ten nispeten daha iyi performans gösterdi. AlexNet, sırasıyla % 87.37 duyarlılık ve % 87.45 ve özgüllük ile % 94.74 genel doğruluk elde etti.

Apostolopoulos ve Bessiana [14], Covid-19 vakalarının otomatik teşhisi için bir sistem geliştirdi. Sistemde kullanılan önceden eğitilmiş modeller VGG19, MobileNet-V2, Inception, Xception ve InceptionResNet-V2'dir. Sistem, ilk senaryoda Covid-19 için 224, ortak pnömoni için 700 ve sağlıklı vakalar için 504 dahil olmak üzere 1427 görüntüyü ele aldı. İkinci senaryoda, 224 Covid-19 görüntüsü, 714 bakteriyel ve viral pnömoni görüntüsü ve 504 sağlıklı birey görüntüsünü dikkate almıştır. Veri kümesi 10 kat çapraz doğrulama yöntemi kullanılarak bölünmüştür. MobileNet-V2 kullanılarak ikinci veri seti için en yüksek %96.78 doğruluk, %98.66 duyarlılık ve %96.46 özgüllük elde edildiği görülmüştür.

Horry ve ark. [15] , X-ışını görüntüleri ile önceden eğitilmiş modelleri kullanarak Covid-19'u tespit etmek için bir sistem önerdi. Önerilen sistemde, VGG19, Inception, Xception ve ResNet gibi popüler önceden eğitilmiş dört model kullanıldı. Kullanılan veri seti, deneyler için 100 Covid-19 vakası, 100 pnömoni ve 200 sağlıklı vakadan oluşuyordu. Veri seti eğitim için %80, test için %20 oranlarına bölündü. Deneysel bulgular, sistemin üç sınıflı veriler göz önüne alındığında çalışmada en yüksek performans olarak ölçülen VGG19 kullanılarak sırasıyla %83, %80 ve %80'lik hassasiyet, duyarlılık ve F1-Skoru elde ettiğini ortaya koymaktadır.

Sethy ve Behera [16], önceden eğitilmiş CNN ve destek vektör makinesi (SVM) modellerini kullanarak Covid-19 vakalarının teşhisi için bir sistem tanıttı. Algoritma, özelliklerin otomatik olarak çıkarılması için on bir önceden eğitilmiş model ve sınıflandırma için SVM kullandı. Bu sistemde, ilk veri setinin 25 pozitif Covid-19 ve 25 negatif Covid-19 X-ışını görüntüsünü içerdiği iki ayrı veri seti kullanılmıştır. İkinci veri setinde pozitif örnek olarak Orta Doğu solunum sendromu (MERS), SARS ve akut solunum sıkıntısı sendromu (ARDS) içeren toplam 133 görüntü ve negatif örnek olarak 133 normal X-ışını görüntüsü kullanılmıştır. Deneysel sonuçlardan, SVM'li ResNet50'nin doğruluk, yanlış pozitif oranı (FPR), Matthews korelasyon katsayısı (mm) ve Kappa'nın sırasıyla %95.38, %95.52, %91.41 ve %90.76 olduğu bulunmuştur.

Minaee ve ark. [17] X-ışını görüntülerinde Covid-19 tahmini için derin transfer öğrenme kavramını kullanarak Deep-COVID adlı bir sistem önerdi. Bu çalışmada Covid-19 tanısı için ResNet18, ResNet50, SqueezeNet ve DenseNet-121 gibi dört popüler önceden eğitilmiş model düşünülmüştür. Toplamda, farklı açık erişim kaynaklarından 5071 görüntü toplanır. Bunlar arasında, eğitim için 31 Covid-19 vakası olan 2000 görüntü ve deneylerde test için 40 Covid-19 enfekte vakası olan 3000 görüntü kullanılmıştır. Elde edilen veri kümesi COVID-Xray-5k olarak adlandırıldı. Sistem tarafından SqueezeNet kullanılarak elde edilen en iyi performans, %100 duyarlılık ve %95,6 özgüllüktür.

Başka bir çalışmada, Punn ve Agarwal [18] , az sayıda X-ışını görüntüsü ile ResNet, Inception-v3, Inception ResNet-V2, DenseNet169 ve NASNetLarge gibi önceden eğitilmiş birkaç model kullanarak otomatik bir Covid-19 teşhis sistemi geliştirdi. Sistem, transfer öğrenme olarak bilinen ince ayar için rastgele aşırı örnekleme ve ağırlıklı bir sınıf kaybı işlevi kullandı. Bu sistemde, deneyler için toplam 1076 göğüs röntgeni görüntüsü göz önünde bulunduruldu. Veri kümesi, eğitim, test ve doğrulama için sırasıyla %80, %10 ve %10 oranlarına bölünmüştür. Deneysel sonuçlardan, NASNetLarge'ın nispeten daha iyi performans gösterdiği görülmüştür ve doğruluk, hassasiyet, duyarlılık, AUC, özgüllük ve F1-Skoru için sırasıyla %98, %88, %91, %99, %98, ve %89 elde ettiği görülmüştür.

Narin ve ark. [19] , Covid-19 ile enfekte olmuş hastaları CNN varyantlarını kullanarak X-ışını görüntülerinden otomatik olarak sınıflandırmak için bir yöntem tanıttı. Kullanılan önceden eğitilmiş modeller ResNet50, InceptionV3 ve Inception-ResNetV2'dir. Sistem, 50 görüntü Covid-19 hastalarından, geri kalan 50'sinin sağlıklı bireylerden olduğu toplam 100 X-ışını görüntüsü kullandı. Deney için veri kümesini bölümlemek için 5 kat çapraz doğrulama kullanıldı. Sistem, test durumlarında sırasıyla ResNet50, InceptionV3 ve Inception-ResNetV2'den %98, %97 ve %87'lik bir doğruluk elde etti. Diğer değerlendirme metrikleri açısından, en iyi performans %96 duyarlılık, %100 özgüllük, %100 hassasiyet ve %98 F1-Skoru ile RecNet50 kullanılarak elde edildi.

Bukhari ve ark. [20] Resnet50 adlı bir CNN varyantı kullanarak Covid-19 tanı sistemi sundu. Sistem, üç sınıf üzerinden çalıştırıldı. 89 Covid-19 örneğinin 278 X-ışını görüntüsünü, 93 sağlıklı katılımcı örneğini ve 96 pnömoni hastasını ele aldı. Toplanan veri seti, %80 (223 görüntü) ve %20 (55 görüntü) oranında eğitim ve test gibi iki kümeye bölünmüştür. Tanı sürecinde, deneyden sırasıyla %98.18, %98.14, %98.24 ve %98.19 doğruluk, hassasiyet, duyarlılık ve F1-Skoru elde etti.

Başka bir araştırmada, Moutounet-Cartan [21], yeni koronavirüsün yanı sıra X-ışını görüntülerinden diğer pnömoni hastalıklarını teşhis etmek için derin öğrenme tabanlı bir sistem geliştirdi. Sistem, teşhis için VGG16, VGG19, InceptionResNetV2, InceptionV3 ve Xception adlı mimarileri kullandı. Bu çalışmada 152 sağlıklı insanlardan, 125 Covid-19 vakasından ve kalan 50 vakanın diğer pnömoni hastalıklarından olduğu toplam 327 X-ışını görüntüsü alınmıştır. Veri kümesi, 5 kat çapraz doğrulama ilkesi kullanılarak bölümlendirilir. Sistem, VGG16'yı en iyi performans gösteren model olarak buldu ve %84.1 genel doğruluk, duyarlılık %87.7 ve AUC için %97.4'lük değerlerini elde etti.

Maguolo ve Nanni [22] , Covid-19'u X-ışını görüntülerinden tespit etmek için AlexNet adlı modeli kullandı. Sistem, performansı değerlendirmek için dört farklı kamuya açık veri kümesi kullandı. Covid-19 hastaları için 144 görüntü, Covid-19 hariç 108.948 pnömoni ve bakteri örneği, 224.316 bakteri ve pnömoni göğüs radyografisi ve 5.863 pediatrik görüntü viral ve bakteriyel pnömoni olmak üzere toplam 339.271 görüntü alınmıştır. Veri kümesi, eğitim ve test için 10 kat çapraz

doğrulamaya bölünmüştür. Derin transfer öğrenme kavramını kullanarak, sistem çalışmada %99.97'lik en yüksek AUC'u elde etti.

Ayrıca, Luz ve ark. [23] , X-ışını görüntülerinden koronavirüs saptanması için EfficientNet adlı etkili bir derin öğrenme şeması sundu. EfficientNet'in en büyük avantajı, diğer önceden eğitilmiş modellerden yaklaşık 30 kat daha az parametre kullanmasıdır. Sistem, 183 Covid-19, normal olarak 16.132 görüntü ve diğer pnömoni vakaları olarak 14.348 görüntü ile toplam 30.663 görüntü deney için kabul edildi. Sistemden elde edilen genel doğruluk %93.9, duyarlılık %96.8, ve hassasiyet %100'dür.

Hemdan ve ark. [24] , X-ışını görüntülerinde CNN varyantlarını kullanarak koronavirüsü teşhis etmek için COVİDX-Net adlı bir sistem önerdi. Bu çalışmada toplam yedi önceden eğitilmiş model ele alınmıştır. Veri seti, sağlıklı insanlardan 25 görüntü ve Covid-19 vakalarından 25 görüntü toplamda 50 görüntüden oluşuyordu. Deney için veri seti sırasıyla eğitim ve test seti için %80 ve %20'lik bir orana bölünmüştür. Deneysel sonuçlar, VGG19 ve DenseNet'in %90 doğruluk ve %91'lik F1-Skoru ile diğer önceden eğitilmiş modellerden daha iyi performans gösterdiğini ortaya koydu. InceptionV3 en kötü sonuçları elde etti.

Elghamrawy ve Hassanien [25] , BT örneklerinden CNN ve Whale Optimizasyon algoritmasının (WOA) bir kombinasyonunu kullanarak koronavirüs ile enfekte hastaların tanı ve tahmini için bir şema önermiştir. Geliştirilen sistem, biri segmentasyon için CNN'lere odaklanan iki temel özelliğe sahipti ve diğeri (WOA), hastanın farklı değişkenlere dayanarak tedaviye cevap verme yeteneğini tahmin etmeyi önerdi. Kullanılan veri seti, 617 BT taramasından oluşan halka açık veri tabanlarından toplanır. Bunlar arasında, akciğer dışı bölge içerdiğinden 134 görüntü hariç tutulmuştur. Covid-19'un doğrulandığı toplam 432 görüntü ve diğer viral pnömoni vakalarının 151'i göz önünde bulunduruldu. Daha iyi performans elde etmek için, veri seti sırasıyla eğitim ve test için %65 ve %35 oranına bölünmüştür. Önerilen sistem, tanı için sırasıyla %96.40, %97.25 ve %97.3 genel doğruluk, duyarlılık ve hassasiyet elde etti.

He ve ark. [26] BT görüntülerini kullanarak Covid-19'un tespiti için CRNet adlı derin bir öğrenme yöntemi önerdi. Sistem, aşırı uyum gösterme problemlerini en aza indirmek için etkili ve tarafsız özellik temsillerini öğrenen self-trans olarak bilinen kontrastlı kendi kendini denetleyen öğrenme ile birlikte yeni bir transfer öğrenme yöntemi tanıttı. Bu sistemde, 349'unun Covid-19 vakaları ve 397'sinin Covid-19 vakaları ile ilişkili olduğu toplam 746 BT görüntüsü analiz edildi. Veri kümesi, sırasıyla %60, %25 ve %15 oranında eğitim, test ve doğrulama seti olarak adlandırılan üç kümeye bölünmüş, üç kamuya açık veri kümesinin birleştirilmesiyle oluşturulmuştur. Önerilen sistem, deneysel sonuçlardan %86 genel doğruluk , %85 F1-Skoru ve %94 AUC elde etmiştir.

Wang ve ark. [27] modified-Inception adlı değiştirilmiş bir CNN tekniği kullanarak Covid-19 tanısı için bir şema tanıttı. Inception ve modified-Inception arasındaki temel fark, modified-Inception, son sınıflandırmadan önce özniteliklerin boyutunu azaltır. Önerilen sistemde, verilen örnekler

üzerinde ROI oluşturulur, ROI görüntüleri önceden eğitilmiş başlangıç mimarisi kullanılarak tek boyutlu özellik vektörlerine dönüştürülür ve son olarak, sınıflandırma tamamen bağlı katmanda yapılır. Deneyde, 740'ının Covid-19 pozitif ve 325'inin Covid-19 negatif olarak etiketlendiği 1040 BT görüntüsü kullandı. Veri kümesi, eğitim, test ve doğrulama kümesine rastgele bölünmüştür. Deneysel sonuçlar, şemanın test örneklerinde sırasıyla %79,3, %83, %67, %55 ve %63 doğruluk, duyarlılık, özgüllük, kesinlik ve F1-Skoruna ulaştığını ortaya koydu.

Ayrıca Liu ve ark. [28] BT görüntüleri ile derin öğrenme yöntemini kullanarak otomatik bir Covid-19 tanı sistemi geliştirdi. Sistem, modelin 4 yoğun bloktan oluştuğu teşhis için modifiye DenseNet-264 (COVİDNet) kullandı. Her blok, özellik haritalarının önceki tüm birimlerden yoğun bağlantılar yoluyla alındığı her bir ünitede bir örnek normalleştirme katmanı, bir konvolüsyon katmanı ve ReLU aktivasyon katmanı ile ardışık olarak bağlanmış iki yığına sahip birkaç birim içeriyordu. Bu sistemde deney için 920 Covid-19 ve 1.073 Covid-19 dışı vaka düşünülmüştür. Daha iyi performans elde etmek için veri kümesi sırasıyla %60, %20 ve %20 oranında eğitim, test ve doğrulama olmak üzere üç kümeye ayrılır. Geliştirilen sistem %94,3 doğruluk, %98,6 AUC, %93,1 duyarlılık, %95,1 özgüllük, %93,9 hassasiyet, %94,5 NPV ve %93,5 F1-Skoru elde etti.

Başka bir çalışmada, Ying ve ark. [29] BT görüntülerini kullanan Covid-19 vakalarının teşhisi için Deeppneumonia adlı Details Relation Extraction Neural Network'e (DRE-Net) dayanan derin öğrenme tekniğini tanıttı. Önerilen sistem ResNet50 ve Feature Pyramid Network kombinasyonu ile geliştirilmiştir. Veri seti Çin'deki iki popüler hastaneden toplandı. Bu sistemde, toplam 1990'da Covid-19 için 777 görüntü, bakteriyel pnömoni için 505 dilim ve normal insanlardan 708 örnek alındı. Veri seti, eğitim, test ve doğrulama seti için %60, %30 ve %10 oranlarında bölünmüştür. Önerilen sistem %94 doğruluk, %93 duyarlılık, %96 kesinlik, %94 F1-Skoru ve %99 AUC elde etmiştir.

Ayrıca Amyar ve ark. [30] BT örneklerinden Covid-19 hastalarını teşhis etmek için derin öğrenme yöntemini kullanan bir sistem geliştirdi. Sistem, yeniden yapılanma için bir kodlayıcı ve segmentasyon için iki kod çözücüden oluşur ve sınıflandırma amacıyla çok katmanlı bir algılayıcı kullanılır. BT örneklerinin girdi olarak beslendiği üç görev için ortak bir kodlayıcı kullanılır, sırasıyla yenileme ve segmentasyon için iki kod çözücü kullanılır ve görüntüler çok katmanlı algılayıcı içindeki Covid-19 vakalarının varlığına göre kategorize edilir. Kullanılan veri seti, 449 vakanın doğrulanmış Covid-19 olduğu 1044 vakayı, sağlıklı bireylerden 100 vakayı, 98 numunenin doğrulanmış akciğer kanseri hastalarını ve diğer çeşitli patolojilerden 397'sini içeriyordu. Veri kümesi, sırasıyla %80, %10 ve %10 oranında eğitim, doğrulama ve test kümesine bölünmüştür. Önerilen sistem %86 doğruluk, %94 duyarlılık, %79 özgüllük, %93 AUC değerlerini elde etmiştir.

Singh ve ark. [31] CNN derin öğrenme tekniğini kullanarak negatif vakalardan Covid-19 ile enfekte (pozitif) vakaları sınıflandırdı. Bu sistemde, CNN'nin başlangıç parametreleri çok amaçlı diferansiyel mod uygulaması ile ayarlandı ve son olarak sınıflandırma CNN, yapay sinir ağı (ANN)

ve CNN'nin umut verici sonuçlar elde ettiği yapay sinir ağı, bulanık çıkarım sistemi (ANNFIS) aracılığıyla yapıldı. Covid-19 pozitif için 75 örnek ve Covid-19 negatif için 75 görüntü olmak üzere toplam 150 BT örneği alındı. Eğitim ve test veri kümesi oranındaki farklı varyasyonlar deneyi yapmak için sırasıyla %20:80, %30:70, %40:60, %50:50, %60:40, %70:30, %80:20, ve %90:10 alınır. Önerilen sistem için en iyi performans oranı %90 eğitim ve test için %10'dur. Sistem deneyden %93.25 doğruluk, %90.70 duyarlılık, %90.72 özgüllük, %89.96 F1-Skoru ve %90.60 Kappa elde etti.

Başka bir çalışmada, Farid ve ark. [32] BT görüntülerinden elde edilen nitelikleri kullanarak Covid-19 enfeksiyonlarını sınıflandırmak için yeni bir yaklaşım getirmiştir. Görüntü parametreleri, geliştirilen hibrit kompozit ekstraksiyon yöntemine ek olarak dört görüntü filtresi kullanılarak alınmıştır. Çıkarılan özellikler, SHC'nin geliştirilen sistemin performansını artırmak için topluluk öğrenmesi gibi çeşitli modelleri entegre ettiği Stack Hybrid Classification (SHC) tekniği kullanılarak kategorize edildi. Sistem, her biri 51 görüntüden oluşan Covid-19 ve SARS adlı iki veri sınıfını ele aldı. Veri kümesi, daha iyi bir sonuç elde etmek için 10 kat çapraz doğrulama tekniği kullanılarak bölümlendi. Geliştirilen sistem sırasıyla %94.11, %99.4, %94 ve %99.4 doğruluk, hassasiyet, F1-Skoru ve AUC elde etti.

Wong ve ark. [33] COVID-Net adı verilen göğüs röntgeni verilerinden bir koronavirüs tespit mekanizması geliştirdi. Önerilen mimari, sınıflandırma için projeksiyon-genişleme projeksiyon-uzatma tasarım modelini takip eden artık mimariyi kullandı. Sistem, iki açık erişim veri kümesini birleştirerek ve değiştirerek COVIDx veri kümesini oluşturdu. Bu çalışmada, veri seti 13.645 hastadan toplam 13.800 göğüs röntgeni örneğinden oluşuyordu. Sistem, bakteriyel ve viral sınıfları negatif bir durumda birleştirerek üç sınıf olarak tasarlandı. Toplam veriler arasında %90'ı eğitim için, geri kalan %10'u doğrulama için kullanılmıştır. Önerilen ağ, test vakaları için 10 yinelemede %92.4 doğruluk , %80 duyarlılık ve %88.9 hassasiyet elde etti.

Başka bir çalışmada, Ucar ve Korkmaz [34], X-ışını örnekleri kullanarak koronavirüs tanısı için Bayes-Squeezenet'e dayanan bir COVİDiagnosis-Net geliştirdi. Hafif ve daha verimli bir CNN modeli geliştirmek için SqueezeNet konvolüsyon mimarisi Squeeze'i kullanır ve yangın modüllerin katmanlarını büyütür. Sistem, veri seti olarak Covid-19 olmayan 1591 pnömoni vakası, 45 Covid-19 vakası ve toplam 1203 enfekte olmayan normal hasta kullandı. Veri kümesi, kamuya açık üç veri kümesinin birleşiminden oluşur. Toplam verilerden, önerilen sistemde eğitim için %80, doğrulama için %10 ve test için %10 oranları kullanılır. Deneysel sonuçlar doğruluk, uygunluk, tamlık, özgüllük, F1-Skoru ve toplamda bireysel olarak %98,26, % 98,26, %98,26, %99,13, %98,25 ve % 97,39 oranında MCC elde etti.

Rahimzadeh ve Attar [35] , X-ışını örnekleri kullanarak yeni koronavirüs vakalarının teşhisi için değiştirilmiş bir CNN ağı önerdi. Sistem, Xception ve ResNet50V2 adlı iki iyi bilinen CNN mimarisini birleştirdi ve bu da sistemi birden fazla özellik çıkarma özelliğini kullanarak sağlam

hale getirdi. Başlangıç ve artık katmanların kullanımı, sınıflandırma için son derece uygun oluşturulan semantik özelliklerin kalitesini arttırdı. 15085 görüntü arasında 180'i Covid-19, 6054'ü pnömoni ve 8851'i normal vaka olarak doğrulandı. Şema, veri bölümleme için 5 kat çapraz doğrulama kullandı. Ağ, Covid-19 tespiti için %99.50 doğruluk, %80.53 duyarlılık, %99.56 özgüllük ve %35.27 hassasiyet elde etti.

Mukherjee ve ark. [36] göğüs röntgeni radyografilerinde CNN kullanarak yeni koronavirüsün saptanması için bir sistem önerdi. Önerilen mimari, tek bir konvolüsyon katmanı, ardından bir maksimum havuzlama katmanı, 256 boyutlu yoğun bir katman ve 2 boyutlu bir çıktı katmanı içerir. Geliştirilen ağ, az sayıda parametre nedeniyle nispeten hafiftir. Bu sistem, 130 pozitif Covid-19 vakası ve 130 Covid-19 olmayan vakalardan oluşur. Covid-19 olmayan vakaların MERS, SARS, pnömoni ve normal göğüs Röntgenlerini içerdiği düşünülmüştür. Daha iyi performans elde etmek için, veri kümesi 5 kat çapraz doğrulama kullanılarak bölünmüştür. Sistemin performansı, CNN mimarisinin toplu iş boyutunu ayarlayarak değerlendirildi. Deneysel sonuçlardan, sistemin sırasıyla %96.92, %94.20, %100, %100, %97.01 ve %99.22'lik doğruluk, duyarlılık, özgüllük, kesinlik, F1-Skoru ve AUC elde ettiği bulunmuştur.

Khobahi ve ark. [37] Covid-19 ile enfekte olmuş hastaları tespit etmek için CoroNet adlı otomatik kodlayıcılara dayanan yarı denetimli bir derin öğrenme sistemi geliştirdi. Son derece uyarlanmış ağ, gerekli özellikleri çıkardı ve bunları verimli bir şekilde sınıflandırdı. Geliştirilen mimarinin yarı denetimli özelliği, az sayıda Covid-19 verisi ile ilgili sorunu çözdü. Önerilen sistem, deneyler için üç açık erişim veri kümesini birleştirdi. Bu şemada, farklı kategorilerde 18.529 görüntü kullanılmıştır. Görüntüler arasında 99 örnek Covid-19 sınıfı, 9579'u Covid-19 olmayan pnömoni ve 8851 örnek sağlıklı vakalarla ilişkiliydi. Veri seti, eğitim ve test seti için sırasıyla %90 ve %10 oranında bölünmüştür. Genel olarak deneyden %93.50, %93.63, %93.50 ve %93.51 doğruluk, hassasiyet, duyarlılık ve F1-Skoru elde edildi.

Alqudah ve ark. [38] , X-ışını verilerinden koronavirüs ile etkilenen hastaların teşhisi için hibrit bir yöntem önerdi. Önerilen sistem derin öğrenme (CNN) ve makine öğrenimi (SVM, RF) mimarisini birleştirdi. Derin öğrenme, makine öğreniminin sadece sınıflandırma görevi için kullanıldığı hem özellik çıkarma hem de sınıflandırma amaçları için kullanılmıştır. Bu sistemde, 48'i pozitif, 23'ü negatif olmak üzere toplam 71 göğüs röntgeni kullanıldı. Sistem eğitim için %70, test için %30 oranını kullandı ve deneyler CNN-Softmax, CNN-SVM ve CNN-RF gibi çeşitli kombinasyonlarda yapıldı. Sistem, CNN-Softmax sınıflandırıcısı için sırasıyla %95.2, %93.3, %100 ve %100 doğruluk, duyarlılık, özgüllük ve hassasiyet elde etti.

Daha sonra, Farooq ve Hafeez [39] , COVID-ResNet adlı Covid-19 ile enfekte olmuş hastaları tespit etmek için önceden eğitilmiş bir ResNet-50 ağı ile derin öğrenme şeması sundu. Önerilen mimari, öğrenme hızını ayırt etmeyi, öğrenme hızının aranmasını döngülemeyi ve en iyi parametreleri seçmek için ince ayar yapmayı içerir. Önerilen sistem toplamda 50 katmana sahip bir

ResNet-50 ile geliştirildi. Bu çalışmada, veri seti toplam 13.645 hastadan 13.800 göğüs röntgeni örneğinden oluşuyordu. Sistem, COVİDx veri kümesini kullanarak 41 yineleme ile genel olarak %96.23 doğruluk elde etti.

Ayrıca Afshar ve ark. [40] 3D X-ışını örnekleri kullanarak Covid-19 hastalarının teşhisi için COVID-CAPS adlı bir kapsül ağ tabanlı sistem geliştirdi. Geliştirilen ağ, son kapsül katmanının sınıflandırma için kullanıldığı ve geri kalan katmanların özelliklerin çıkarılması için kullanıldığı 4 konvolüsyonel katman ve 3 kapsül katmanı kullandı. Önerilen çerçeve, küçük bir veri kümesiyle çalışmak için çok uygundur. Ağda kullanılan veri kümesi, Covid-19 araştırması için popüler olan Covidx veri kümesiydi. Geliştirilen şemada, deneyler için 13.645 hastadan 13.800 göğüs röntgeni görüntüsü kullanıldı. Veri kümesinde dört sınıf olmasına rağmen sistem görüntüleri, bakteriyel ve viral olarak tek bir negatif sınıfa göre üç sınıfa ayırır. COVID-CAPS sırasıyla %95.7, %90, %95.8 ve %97 doğruluk, duyarlılık, özgüllük ve AUC elde etti.

Tablo 2.1. derin öğrenme yöntemleri kullanarak BT veya X-ışınları örneklerinden yukarıda belirtilen derin öğrenme tabanlı Covid-19 tanı sistemlerini özetlemektedir. Görüntü sayısı, veri bölümleme tekniği, tanı teknikleri ve geliştirilen sistemlerin performans ölçüleri gibi bazı önemli faktörleri açıklamaktadır.

Tablo 2.1. Derin öğrenme tabanlı Covid-19 tespiti yapan çalışmaların özeti

Yazarlar	**Görüntü Sayısı**	**Bölümleme**	**Teknik**	**Performans (%)**
Wu ve ark. [5]	495 (Covid-19=368,diğer pnömoni 127)	Eğitim %80 Test %10 Doğrulama %10	ResNet50	Doğruluk=76, Hassasiyet=81.1, Özgüllük=61.5, AUC 81,9
Yousefzadeh ve ark. [6]	2124 (Covid-19= 706, non-Covid-19= 1418)	Eğitim %80 Doğrulama %20	DenseNet, ResNet, Xception, EfficeNetB0	Doğruluk=96.4, Hassasiyet=92.4, Özgüllük=98.3, AUC=98.9, F1-Skoru=95.3, Kappa= 91.7
Jin ve ark. [7]	1881 (Covid-19=496, non-Covid-19=1385)	Rastgele Bölüm	ResNet152	Doğruluk=94.98, Hassasiyet=94.06, Özgüllük=95.47, Kesinlik=91.53, F1-Skoru=92.78 97.91 AUC.
Xu ve ark. [8]	618(Covid-19 =219, İnfluenza-A=224,normal =175)	Eğitim %85,4 Test %14,6	ResNet18	Doğruluk=86.7, Hassasiyet=81.5, Kesinlik= 80.8 F1-Skoru =81.1

Jin ve ark. [9]	1391(Covid-19=850, normal=541)	Rastgele Bölüm	DPN-92, Inception-v3, ResNet50, Attention ResNet50	Hassasiyet= 97,4 Özgüllük=92.2 AUC=99,1
Javaheri ve ark. [10]	89,145(Covid-19=32,230 CAP=25,699 diğer=31,216)	Eğitim %90, Doğrulama %10	BCDU-Net (U-Net)	Doğruluk=91,66 Hassasiyet= 87,5 Özgüllük=94, AUC=95
Ardakani ve ark. [11]	1020 (Covid-19=510, normal=510)	Eğitim %80, Doğrulama %20	AlexNet, VGG-16, VGG-19, SqueezeNet, GoogleNet, MobileNet-V2, ResNet-18, ResNet-50, ResNet-101 Xcepsiyon	Doğruluk=99,51 Hassasiyet= 100 Özgüllük=99,02, Kesinlik= 99,27 AUC=99,4 NPV=100
Chen ve ark. [12]	35,355	Rastgele Bölümleme	UNet++	Doğruluk =98,85 Hassasiyet= 94,34 Özgüllük=99,16, Kesinlik= 88,37 AUC=99,4 NPV=99,61
Cifci [13]	5800	Eğitim %80 Test %20	AlexNet, Inception-V4	Doğruluk =94,74 Hassasiyet=87,37 Özgüllük=87,45
Apostolopoulos ve Bessiana [14]	1442(Covid-19=224, pnömoni=714, normal =504)	10 kat çapraz doğrulama	VGG19, MobileNet-V2, Inception, Xception, InceptionResNet-V2	Doğruluk =96,78 Hassasiyet=98,66 Özgüllük=96,46
Horry ve ark. [15]	400 (Covid-19=100, pnömoni=100, diğer=200)	Eğitim %80 Test %20	VGG16, VGG19, ResNet50, InceptionV3, Xception	Hassasiyet=80 Kesinlik= 83 F1-Skoru =80

Sethy ve Behera [16]	316	Eğitim %60 Test %20 Doğrulama %20	AlexNet, VGG-16, VGG-19, GoogleNet, ResNet18, ResNet50, ResNet101 InceptionResNet-V2, InceptionV3 DenseNet201 Xception,SVM	Doğruluk =95,38 Hassasiyet= 97,47 Özgüllük=93,43 Kesinlik= 95,95 F1-Skoru=95,52 MCC=91,41 FPR=95,52 Kappa=90,76
Minaee ve ark. [17]	5071(Covid-19=71, non-Covid-19=5000)	Eğitim %40 Test %60	ResNet18, ResNet50, SqueezeNet, DenseNet121	Hassasiyet= 100 Özgüllük=95,6 AUC=99,6
Punn ve Agarwal [18]	1076 (Covid-19=108, pnömoni=515, normal=453)	Eğitim %80 Test %10 Doğrulama %10	ResNet, ResNetV2, Inception, InceptionV3, DenseNet169 NASNetL	Doğruluk =98 Hassasiyet= 91 Özgüllük=91 Kesinlik= 98 F1-Skoru=89 AUC=99
Narin ve ark. [19]	100 (Covid-19=50, normal=50)	5 kat çapraz doğrulama	ResNet, InceptionV3, Inception-ResNetV2	Doğruluk =98 Hassasiyet= 96 Özgüllük=100 Kesinlik= 100 F1-Skoru=98 AUC=100
Bukhari ve ark. [20]	278 (Covid-19=89, normal=93)	Eğitim %80 Test %20	ResNet50	Doğruluk =98,18 Hassasiyet= 98,24 Kesinlik= 98,14 F1-Skoru=98,19
Moutounet-Cartan [21]	327 (Covid-19=125, normal=152, pnömoni=50)	5 kat çapraz doğrulama	VGG16, VGG19, InceptionResNetV2, InceptionV3, Xception	Doğruluk =84,1 Hassasiyet= 87,7 AUC=97,4
Maguolo ve Nanni [22]	339,271(Covid-19=144, pnömoni=339,127)	10 kat çapraz doğrulama	AlexNet	AUC=99,97

Luz ve ark. [23]	30,663(Covid-19 =183, non-Covid-19= 14,348, sağlıklı=16,132)	Eğitim %90 Test %10	EfficientNet	Doğruluk =93,9 Hassasiyet= 96,8 Kesinlik= 100
Hemdan ve ark. [24]	50 (Covid-19= 25, Normal=25)	Eğitim %80 Test %20	VGG19, DenseNet121, InceptionV3, ResNetV2, InceptionResNetV2, Xception, MobilNetV2	Doğruluk =90 Hassasiyet= 100 Özgüllük=100 Kesinlik= 100 F1-Skoru=91 AUC=90
Elghamrawy ve Hassanien [25]	583 (Covid-19=432, pnömoni=151)	Test %65 Eğitim %35	WOA-CNN	Doğruluk=96,4 Hassasiyet=97,25 Kesinlik= 97,3
He ve ark. [26]	746 (Covid-19= 349, non-Covid-19 =397)	Eğitim %60 Doğrulama %15 Test %25	CRNet	Doğruluk =86 F1-Skoru=85 AUC=94
Wang ve ark. [27]	1065 (Covid-19=740, non-Covid-19=325)	Rastgele bölümleme	Modified-Inception	Doğruluk =79,3 Hassasiyet= 83 Özgüllük=67 Kesinlik= 55 NPV=90 F1-Skoru=63 AUC=81 Kappa=48 Yoden Index=50
Liu ve ark. [28]	1993(Covid-19=920, non-Covid-19=1073)	Eğitim %60 Doğrulama %20 Test %20	Modified DenseNet264	Doğruluk =94,3 Hassasiyet= 93,1 Özgüllük=95,1 Kesinlik= 93,9 NPV=94,5 F1-Skoru=93,5 AUC=98,6
Ying ve ark. [29]	1990 (Covid-19=777, normal=708, pnömoni=505)	Eğitim %60 Doğrulama %10 Test %30	DRE-Net	Doğruluk =94,3 Hassasiyet=93 Kesinlik= 96 F1-Skoru=94 AUC=99
Farid ve ark. [32]	102 (Covid-19=51, non-Covid-19=51)	10 kat çapraz doğrulama	CNN	Doğruluk =94,11 Kesinlik= 99,4 F1-Skoru=94 AUC=99,4

Wong ve ark. [33]	13,800	Eğitim %90 Test %10	COVID-Net (CNN)	Doğruluk =92,4 Hassasiyet= 80 Kesinlik= 88,9
Ucar ve Korkmaz [34]	2839 (Covid-19=45, normal=1203, pnömoni=1591)	Eğitim %80 Doğrulama %10 Test %10	Bayes-SqueezeNet	Doğruluk =92,4 Hassasiyet=80 F1-Skoru=98,25 Correctness=98,26 Complenetess=98,26
Rahimzadeh ve Attar [35]	15085 (Covid-19=180, pnömoni=6054, normal=8851)	5 kat çapraz doğrulama	Concatenated CNN	Doğruluk =99,5 Hassasiyet= 80,53 Özgüllük=99,56 Kesinlik= 35,27
Mukherjee ve ark. [36]	260 (Covid-19=130, non-Covid19=130)	5 kat çapraz doğrulama	Shallow CNN	Doğruluk =96,92 Hassasiyet= 94,2 Özgüllük=100 Kesinlik= 100 F1-Skoru=97,01 AUC=99,22
Khobahi ve ark. [37]	18,529 (Covid-19=99, non-Covid-19=9579, sağlıklı=8851)	Eğitim %90 Test %10	CoroNet	Doğruluk =93,5 Hassasiyet= 93,5 Kesinlik= 93,63 F1-Skoru=93,51
Alqudah ve ark. [38]	71 (Covid-19=48, non-Covid-19=23)	Eğitim %70 Test %30	CNN, SVM, RF	Doğruluk =95,2 Hassasiyet= 93,3 Özgüllük=100 Kesinlik= 100
Farooq ve Hafeez [39]	13,800	Eğitim %90 Test %10	COVID-ResNet (CNN)	Doğruluk =96,23 Hassasiyet= 100 Kesinlik= 100 F1-Skoru=100
Afshar ve ark. [40]	13,800	Eğitim %90 Test %10	COVID-CAPS (Capsule Network)	Doğruluk =95,7 Hassasiyet= 90 Kesinlik= 95,8 AUC=97

3. MATERYAL VE METOT

Bu bölümde, Covid-19 taraması için önerilen sistemin mimarisi BT taramalarına dayalı olarak sunulur. Bu amaçla, DenseNet ailesinin bir mimarisi olan DenseNet121 ile sistemi gerçekleştirdik ve modeli sağlıklı ve Covid-19 ile enfekte hastalardan alınan BT görüntüleri ile eğittik. BT görüntüleri, veri seti bölümünde açıklanan veri kümelerinden gelir ve aşağıda açıklanan işlemlerden geçer.

3.1. Derin Öğrenme

Derin öğrenme (DL), son yıllarda araştırmacıların yoğun ilgi gösterdiği yapay sinir ağlarına dayalı bir tür makine öğrenmesi (ML) yöntemidir. Geleneksel makine öğrenimi yöntemleri daha büyük veri kümeleriyle ilgilenemezken derin öğrenme yöntemleri, daha fazla veri ile daha iyi sonuçlar elde etmektedir. Görüntü sınıflandırma, makine çevirisi ve diğer birçok görev gibi yapay zekâ görevlerinin performansını önemli ölçüde iyileştirdi buda derin öğrenmeyi kısa zamanda vazgeçilmez bir konuma getirmiştir. DL mimarilerinin derin yapısı, DL'ye en karmaşık yapay zekâ görevlerinin çoğunu çözme yeteneği verir.

Çeşitli DL ağları, birçok genel veri tabanını kullanarak Covid-19'u doğru bir şekilde teşhis etmek için yaygın olarak kullanılmıştır. DL mimarileri, konvolüsyonel sinir ağları (CNN'ler), tekrarlayan sinir ağları (RNN'ler), otoenkoderler (AEs), derin inanç ağları (DBN'ler), üretken rakip ağlar (GANs), CNN-RNN ve CNN-AE gibi hibrit ağlar kullanarak Covid-19'un otomatik tespiti için geliştirilmiştir. Şekil 3.1.'de DL ağlarının alt kategorileri gösterilmektedir.

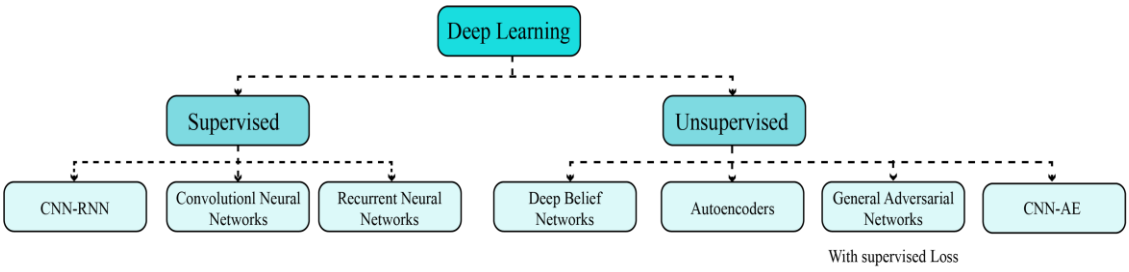

Şekil 3.1. Covid-19 tespiti için kullanılan çeşitli DL yöntemlerinin illüstrasyonu [41]

Derin öğrenme modelleri Covid-19'u tespit etmek için sınıflandırma modelleri ve akciğer bölgelerini segmentlere ayırmak için geliştirilen segmentasyon modellerini kullanır. Şekil 3.2. bahsedilen DL yöntemleri ile Covid-19'un tespit edilmesini göstermektedir. Biz çalışmamızda sınıflandırma tabanlı işlemler gerçekleştirdik.

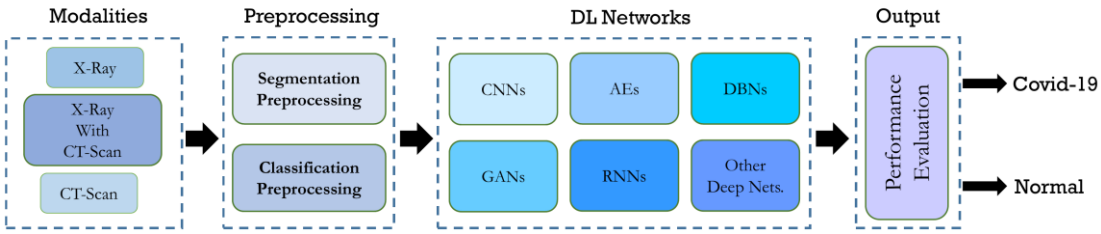

Şekil 3.2. DL kullanarak Covid-19 tespiti için blok diyagramı [41]

Ayrıca derin öğrenme (DL), beyin anormalliklerinin sınıflandırılması, farklı kanser türlerinin sınıflandırılması, patojenik bakterilerin sınıflandırılması ve biyomedikal görüntü segmentasyonu gibi tıbbi veri setleriyle uğraşmak için en yaygın kullanılan yöntemdir.

3.2. Evrişimsel Sinir Ağları (CNN)

Evrişim sinir ağları, görüntüleri analiz etmek için en yaygın kullanılan derin öğrenme modelleridir. Görüntülerin özelliklerini tespit etmek için sinir ağları kavramını kullanır.

CNN mimarileri, konvolüsyonel taban ve sınıflandırıcı taban olmak üzere iki tabandan oluşur. Konvolüsyonel taban, üç ana katman türünü içerir; özellik haritaları olarak adlandırılan giriş görüntülerinin kritik özelliklerini keşfetmek için kullanılan bir konvolüsyonel katman, bir aktivasyon katmanı ve bir havuzlama katmanı. Sınıflandırıcı tabanı, bir dizi nöron kullanarak sınıflandırma görevini hızlandırmak için özellik haritalarını bir boyut vektörüne dönüştüren yoğun katmanları içerir. Bu bölümde, CNN mimarisini oluşturmak için en sık kullanılan katmanlardan bazıları açıklanacaktır.

Evrişimsel Katmanlar

Bu katmanlar çeşitli özellik haritaları üretir. Bir özellik haritası, doğrusal bir filtre kullanarak giriş görüntüsüne veya önceki özelliklere konvolüsyon işlemleri gerçekleştirerek bir önyargı terimini birleştirerek ve daha sonra bu özellik haritasını doğrusal olmayan bir aktivasyon fonksiyonundan geçirerek elde eder. Başka bir deyişle, bir özellik haritasındaki her nöron, önceki katmanların tüm özellik haritalarının bir alt kümesinin bir n×n bölgesinin veya giriş katmanının bir alt kümesinin birleşiminden girdi alır. Kombine bölgeler bu nöronun alıcı alanları olarak bilinir. Aynı özellik haritasındaki her nöron, karşılık gelen alıcı alanla aynı ağırlıkları paylaşır, çünkü konvolüsyonel katmandaki aynı filtre, önceki özellik haritalarının tüm katlanılabilir alıcı alanlarına bakmak için kullanılır. Filtreler veya çekirdekler olarak da bilinen paylaşılan ağırlıklar, eğitim aşamasında öğrenilir. Evrişimsel katmanlar genellikle havuzlama katmanları ile birleştirilir ve çıktıları tamamen bağlı katmanları besler [42]. Ağda birden fazla evrişimli katman kullanmak, ağın daha

önemli özellikleri öğrenmesine yardımcı olabilir, çünkü ilk evrişimsel katmanlar çizgiler gibi basit özellikleri tespit eder ve son evrişimsel katmanlar burun ve göz gibi daha önemli özellikleri tespit eder [43].

Aktivasyon Fonksiyonu Katmanları

Aktivasyon fonksiyonları, bir sinir ağının çıktısına karar veren matematiksel denklemlerdir. İşlev, ağ içindeki her nörona bağlıdır ve her nöronun girdisinin modelin öngörüsü için uygun olup olmadığına bağlı olarak, etkinleştirilip etkinleştirilmeyeceğine karar verir. Her nöron için girdi, nörondaki ağırlıklarla çarpılır ve sonra birleştirilir. Bu işlemin sonucu nöronun özet aktivasyonu olarak adlandırılır ve daha sonra nöronun çıktılarına karar veren aktivasyon fonksiyonu kullanılarak dönüştürülür [44]. Aktivasyon fonksiyonlarının iki formu vardır: lineer aktivasyon fonksiyonları ve lineer olmayan aktivasyon fonksiyonları. Lineer aktivasyon fonksiyonları çok basittir ve nöronların çıktılarına herhangi bir dönüşüme yol açmazlar. Lineer olmayan aktivasyon fonksiyonları, nöronların herhangi bir veri setinde daha karmaşık bilgileri algılamasına izin verdiği için lineer aktivasyon fonksiyonlarına tercih edilir. Sigmoid, Rectified Linear Unit gibi birçok lineer olmayan aktivasyon fonksiyonu türü vardır. Biz çalışmamızda aktivasyon fonksiyonu olarak Rectified Linear Unit (ReLU)'i kullandık.

Havuzlama Katmanları

Konvolüsyonel katmanlardan üretilen özellik haritalarının bir kısıtlaması vardır; bu özelliklerin giriş görüntüsündeki tam yerleşimini kaydetmesidir. Bu, özelliğin giriş görüntüsündeki yerleşimindeki küçük bir değişikliğin tamamen farklı bir özellik haritasına yol açacağı anlamına gelir. Kırpma ve döndürme gibi veri artırma teknikleri uygulanarak değişiklikler meydana gelebilir. Bu sorunu çözmek için popüler bir yöntem aşağı örnekleme olarak bilinir. Bu yöntemle, giriş görüntüsünün yalnızca önemli özelliklerini içeren ve görev için yararlı olmayabilecek özellikler olmadan daha düşük çözünürlüklü bir sürümünü oluşturur. Daha güçlü bir yöntem ise bir havuz katmanı kullanmaktır. Havuzlama katmanı, doğrusal olmayan etkinleştirme işlevi tarafından etkinleştirilen evrişimsel katmanı izleyen bir katmandır. Bu katman özellik haritalarında yalnızca en önemli değerleri belirterek önceki evrişim katmanından üretilen özellik haritalarındaki değerlerin sayısını en aza indirmekten sorumludur [45].

Dropout

DL mimarileri karşılaşabileceğiniz aşırı öğrenmeyi en aza indirmek ve genelleme geliştirmek için tasarlanmış etkili bir düzenlileştirme tekniğidir. Bırakma (dropout), bazı nöronların veya birimlerin, diğer birimlerle olan bağlantılarıyla birlikte, eğitim aşamasında ağdan düştüğünü veya geçici olarak kaldırıldığını gösterir. Bu teknik, eğitim operasyonunu gürültülü hale getirme, bir katman içindeki düğümleri girdiler için daha fazla veya daha az sorumluluk almaya zorlama

etkisine sahiptir. Bırakma, sinir ağı mimarisinin katmanları için gerçekleştirilir. Yoğun katmanlar, kıvrımlı katmanlar gibi çoğu katman formuyla kullanılabilir ancak çıktı katmanına uygulanamaz. Bırakma tekniği, katmanın çıktılarının çıkarılma olasılığını veya karşılıklı olarak katmanın çıktılarının tutulma olasılığını belirleyen bırakma oranı adı verilen yeni bir hiperparametre tanıttı. Tipik olarak bırakma oranı 0.1 ila 0.9 aralığında ayarlanır [46].

Transfer Learning

Küçük bir görüntü veri setinde popüler ve son derece verimli bir yaklaşım önceden eğitilmiş bir ağ kullanmaktır. Önceden eğitilmiş bir ağ, genellikle görüntüleri kategorize etme görevinde büyük bir veri kümesi üzerinde eğitilmiş ve ardından mimarisi ve ağırlıkları korunan bir ağdır. Bu ilk veri seti yeterince büyük ve yeterince genelse, önceden eğitilmiş ağ tarafından öğrenilen özelliklerin miktarı, görsel dünyanın genel bir modeli olarak etkili olabilir. Bu nedenle yeni görevler ilk görevin kategorilerinden tamamen farklı kategoriler içerse bile bu özellikler birkaç tamamen farklı bilgisayarla görme görevi için yardımcı olabilir [47,48]. Örneğin, bir görüntüdeki kedileri doğru bir şekilde sınıflandıran bir ağ, köpekleri sınıflandırmada elbette mükemmel değildir. Transfer öğrenme fikri, adından da anlaşılacağı gibi görev Ta'yı çözerken öğrenilen bilgiyi görev Tb'yi sıfırdan çözen yeni bir ağı eğitmek yerine görev Tb'yi çözen bir modelin eğitimine aktarmaktır. Somut olarak bu Ta'yı çözen ağdan bazı düşük seviyeli özellik çıkarıcılarını yeniden kullanmak ve bunları Tb'ye uygulamak anlamına gelebilir. DenseNet121 [49] gibi ImageNet veri tabanı üzerinde eğitilmiş ağlar, tıbbi görüntü özelliklerini keşfetmek gibi model eğitimine katkıda bulunabilir.

3.3. DenseNet

Huang ve ark. tarafından önerilen DenseNet [49] , esasen her katmanı diğer her katmana bağlayan yoğun bağlantılar ekleyerek ResNet mimarisini geliştirir. Katmanlar arasındaki yoğun bağlantı nedeniyle DenseNet olarak adlandırılır. Bu tür yoğun bağlantılı mimariler, her katmanın önceki her katmandan özellik haritalarını almasını ve kendi özellik haritasını sonraki her katmana geçirmesini sağlar. Geleneksel CNN ile karşılaştırıldığında DenseNet, daha az sayıda veya eşdeğer sayıda parametre gerektirir çünkü DenseNet'te özellik haritaları gereksiz yere öğrenilmez buda önemli bir avantaja dönüşür. Böyle bir mimarinin toplamda düşük sayıda parametreyi korurken özellikleri yeniden kullanma yeteneği vardır. DenseNet katmanlara yalnızca küçük bir dizi yeni özellik haritası ekler ve katmanları dardır yani filtre sayısı çok azdır. Derin sinir ağlarında bahsedilen bir bilgi akışı ve gradyanlar olduğu için girdinin eğitiminde sorun ortaya çıkmaktadır. DenseNet, orijinal girdi ve kayıp işlevinden gradyanlara doğrudan erişim sağlayarak bu sorunu çözebilir. Bir DenseNet mimarisinin şematik gösterimi Şekil 3.3.'de gösterilebilir [49].

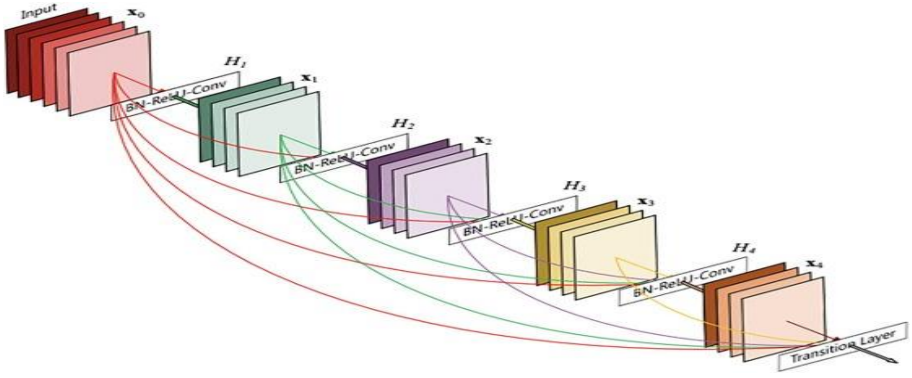

Şekil 3.3. DenseNet mimarisinin şematik gösterimi

Özellik haritalarının birleştirilmesi için dikkat edilmesi gereken bir şey, özellik haritalarının boyutunun tutarlı olması gerektiğidir; bu da evrişim katmanının çıktısının girdi ile aynı boyutta olması gerektiği anlamına gelir [50]. Yoğun şekilde birleştirilmiş evrişimlerin çalışması denklem (3.1) ile gösterilebilir.

$$x^l = \mathrm{H}([x_0, x_1, \ldots, x_{l-1}]) \tag{3.1}$$

Burada l katman sayısıdır ve H(.) doğrusal olmayan bir transformatördür; Toplu Normalleştirme, ReLU, Havuzlama ve Evrişim'den oluşan kombine bir işlemdir.

Yaygın olarak kullanılan DenseNet mimarisinin çeşitli varyantları vardır; DenseNet121, DenseNet169, DenseNet201 gibi. Bunların arasından DenseNet121 mimarisini çalışmamızda kullanılmaktadır. Buradaki 121 modelin derinliğini göstermektedir. DenseNet isteğe bağlı olarak ImageNet üzerinde ön eğitim gerçekleştirebilir.

3.4. Veri Seti

Covid-19 tespiti için herkese açık platform olan Kaggle'dan gerçek veriler (BT görüntüleri) alınmıştır. Covid-19'un BT görüntülerinden elde edilen bu veri seti Covid-19 pozitif ve negatif olmak üzere iki kategoriden oluşmaktadır.

Çalışmamızda öncekilerden farklı olarak veri setinde bulunan resimleri DeOldify kütüphanesi kullanarak renklendirdik ve orijinal veri seti ile renklendirdiğimiz veri setini karıştırdık. Bu sayede elimizde bulunun veri sayısını artırmış olduk.

3.4.1. DeOldify

DeOldify [51] , MIT Lisansı kullanan ücretsiz olarak dağıtılan bir ağ mimarisidir ve önceden eğitilmiş bir U-Net'e dayanır. Siyah beyaz görüntüleri ve gri skaladaki görüntüleri başarıyla renklendirebilir. Geleneksel eğitim yöntemlerini ve GANs teknikleriyle eğitim modelini kullanarak

jeneratörü ve ayırıcıyı ayrı ayrı eğitmeye odaklanan NoGAN adlı yeni bir yöntem kullanarak eğitilmiştir. Şekil 3.4' de DeOldify ile renklendirilip karıştırılan Covid-19 BT tarama görüntülerine örnekler, Şekil 3.5' de ise DeOldify ile renklendirilip karıştırılan non-Covid-19 BT tarama görüntülerine örnekler gösterilmiştir.

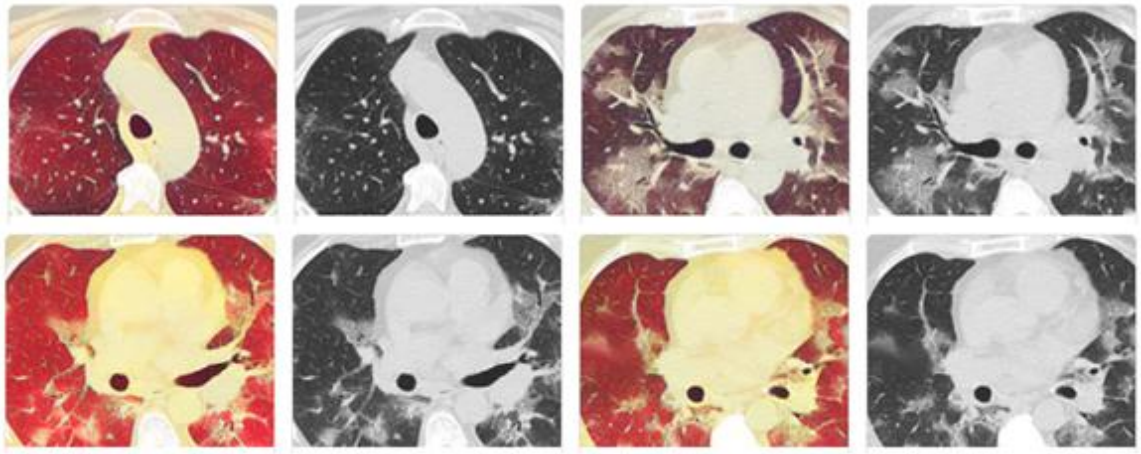

Şekil 3.4. DeOldify ile renklendirilip karıştırılan Covid-19 BT tarama görüntülerine örnekler

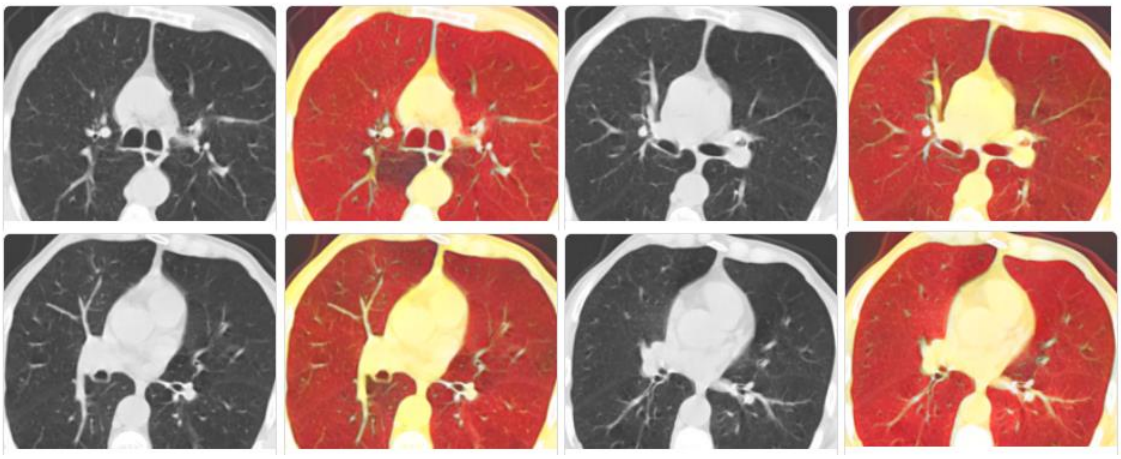

Şekil 3.5. DeOldify ile renklendirilip karıştırılan non-Covid-19 BT tarama görüntülerine örnekler

Modeli oluşturmak için toplam 4962 adet veri kullanılmıştır. Tablo 3.1'de kategori adı, eğitim ve teste girecek veri sayıları başlıklarıyla tüm verilere yer verilmiştir.

Tablo 3.1. Veri sayıları

Kategori Adı	Eğitim (%90)	Test (%10)	Toplam
Covid-19	2252	250	2502
Normal	2214	246	2460
Toplam			4962

3.5. Ön İşleme

Eğitim sürecinin optimizasyonu çeşitli ön işleme tekniklerinin uygulanmasıyla geliştirilebilir. Ön işleme, görüntüde mevcut olan gürültüyü azaltarak giriş görüntüsünün kalitesinin artmasıyla sonuçlandığından sistemin verimliliğini artırılabilir. Bu nedenle bu çalışmada veri ön işleme teknikleri olarak görüntü yeniden boyutlandırma ve görüntü normalizasyonu uygulanarak görüntünün kalitesi artırılabilir.

3.5.1. Görüntü Yeniden Boyutlandırma

Görüntü boyutları farklı boyutlarda olduğundan veri kümesindeki tüm görüntüler sabit boyuta ulaşmak için 64x64 piksel boyutuna yeniden ölçeklendirilir. Eğitim sürecini hızlandırarak sistemin etkinliğini artırmak için görüntü yeniden boyutlandırma yapıldı.

3.5.2. Görüntü Normalleştirme

Bu çalışmada veri setindeki her bir görüntünün piksel değerlerini 0'dan 255'e kadar temel standart dağılıma normalleştiren görüntü normalizasyonu gerçekleştirilmiştir. Bu teknik, yanlılığı ortadan kaldırarak ve veri kümesindeki görüntüler arasında düzgün dağılım elde ederek modelin yakınsamasını hızlandırmaya yardımcı olur.

3.5.3. Veri Arttırma

Bu bölümde Keras ImageDataGenerator ile Covid-19 veri setinin, eğitim setinin görüntü sayısını artırmak için görüntü ön işleme adımlarından biri olan veri arttırma yapılmıştır. Bir modeli doğru sonuçlarla eğitmek için verilerden neredeyse tüm özellikleri öğrenmek adına daha fazla sayıda parametreye ihtiyacımız vardır. Tüm bu parametreleri barındırmak için iyi miktarda veriye ihtiyacımız vardır. Derin öğrenme modelleri genellikle her zaman mevcut olmayan daha fazla veri gerektirir.

Veri arttırma, mevcut eğitim verilerinden yapay olarak yepyeni eğitim verileri üretmek anlamına gelir ve görüntüleri korur. Veri arttırma, tıp uzmanlarının yeni veri biriktirmeden modeli eğitmek için mevcut veri çeşitliliğini yaklaşık olarak geliştirmesine olanak tanıyan bir prosedürdür. Amaç eğitim verilerini yeni örneklerle genişletmektir. Böylece model için mevcut olan veriden daha fazla

veri elde edilmiş olur. Örneğin nesnenin yönünü, konumunu ve hizalamasını değiştirmek; bu tür bir dönüştürme görüntüleri korur ve bir doktorun görüntüleri yorumlamasını engellemez. Biz bu tekniği eğitimden önce veri oluşturma sırasında uyguladık. Kullanılan veri arttırma teknikleri ve her teknik için kullanılan aralık Tablo 3.2.'de listelenmiştir.

Tablo 3.2. Kullanılan veri arttırma teknikleri ve aralıkları

Teknik	Aralık
Rotation	360
Zooming	0,2
Width shift	0,2
Height shift	0,2
Vertical flip	True
Horizontal flip	True

3.5.4. Veri Bölme

Bu çalışmada, görüntü veri kümesi 90:10 oranına bölünmüştür; burada görüntülerin %90'ı modeli eğitmek için ve görüntülerin %10'u da modeli doğrulamak için kullanılır.

3.6. Deneysel Çalışma

Verileri almadan önce proje için çalışma ortamını kurmak gerekir. Google Colaboratory (Colab), kurulum gerektirmeyen ücretsiz bir bulut tabanlı Jupyter dizüstü bilgisayar ortamıdır. Colaboratory, kullanıcıların kod yazmasına ve çalıştırmasına ve tarayıcıdan ücretsiz olarak güçlü bilgi işlem kaynaklarına erişmesine olanak tanır. En önemlisi, Colab cömertçe yoğun bilgi işlem sürecini önemli ölçüde hızlandırmaya yardımcı olan bir GPU sağlar. Bu nedenlerden dolayı, Colab, pahalı GPU'lara sahip bir PC'ye sahip olmayan derin öğrenme ve veri bilimi meraklıları arasında çok popüler hale gelmiştir.

Ancak küçük bir sorun kaydetmede ve verileri Colab'a yüklemede oluşur. Veri kümesi doğrudan Colab diskine indirilebilir ve kaydedilebilir ancak çalışma zamanı sıfırlandıktan sonra kaybolur. Verileri korumak ve indirme kodunu tekrar tekrar çalıştırmaktan kaçınmak için Colab'ın verilerin kaydedildiği Google Drive'a bağlanması gerekir. Veriler işlenir ve Google Drive'daki veri kümesi klasörüne kaydedilir.

Deney, ücretsiz olarak erişilebilen Google Colab tarafından sağlanan bir NVİDİA Tesla P4 GPU kullanılarak eğitildi. Model, arka uç olarak Tensorflow ile Python3 derin öğrenme kütüphanesi olan Keras kullanılarak uygulandı.

3.6.1. Hiperparametreler

DenseNet-121 ağı, 64x64x3 ile her katmanda bir giriş görüntüsü ile beslendi. DenseNet121, içinde 121 katman bulunan son teknoloji bir modeldir. Modelin eğitimi %90 eğitim verisi ile gerçekleştirilir, %10'luk kısım test için ayrılır.

Modelin konvolüsyon ve havuzlama parçalarını her biri ReLU aktivasyonuna sahip olan katmanlar izler. ReLU en popüler aktivasyon fonksiyonu olarak kabul edilir. ReLU çok etkili ve basit bir aktivasyon fonksiyonudur; hem doğrusal olmayan bir aktivasyon fonksiyonu hem de doğrusal aktivasyon fonksiyonu olarak işlev görür. Herhangi bir dönüşüm olmadan girdi olarak sağlanan değeri döndürür veya giriş değeri 0 veya daha az ise 0 döndürür. ReLU resmi olarak (6.1)' de gösterildiği gibi tanımlanır [52].

$$F(x) = \max(0, x) \tag{6.1}$$

Son olarak Softmax aktivasyon fonksiyonuna sahip olan katman izler. Softmax, çıktımızı bir [0,1] aralığına eşlemekle kalmaz aynı zamanda her çıktıyı toplam toplamı 1 olacak şekilde eşler. Softmax'ın çıktısı bu nedenle bir olasılık dağılımıdır.

Dense (256, ReLU), BatchNormalization, Dense (2, Softmax) katmanları, sırasıyla sınıflandırma için tamamen bağlı katmanda kullanılır. Toplu normalleştirme işlemi, katmanın çıktısını belirli bir aralıkta kısıtlar ve sıfır ortalama ve standart sapmayı zorlar. Bu düzenli olarak çalışır, sinir ağının stabilizesini arttırır ve eğitimi hızlandırır.

Nöronları rastgele atan yoğun katmanlardan önce bir Dropout katmanı da kullanılır. Dropout, derin öğrenme mimarileri karşılaşabileceğiniz aşırı öğrenmeyi en aza indirmek ve genelleme geliştirmek için tasarlanmış etkili bir düzenlileştirme tekniğidir. Dropout bazı nöronların veya birimlerin diğer birimlerle olan bağlantılarıyla birlikte eğitim aşamasında ağdan düştüğünü veya geçici olarak yeniden taşındığını gösterir. Bu teknik, eğitim operasyonunu gürültülü hale getirme etkisine sahiptir, bir katman içindeki düğümleri girdiler için daha fazla veya daha az sorumluluk almaya zorlar. Dropout, sinir ağı mimarisinin katmanları için gerçekleştirilir. Yoğun katmanlar, kıvrımlı katmanlar gibi çoğu katman formuyla kullanılabilir ancak çıktı katmanına uygulanamaz. Tipik olarak bırakma oranı 0.1 ila 0.9 aralığında ayarlanır. Biz dropout katman değerini 0.5 olarak ayarladık. Aşırı beslenmeyi önlemeye yardımcı olan bu katman, sağlam özelliklerin öğrenilmesine yardımcı olur. Her ne kadar yakınsama için yineleme sayısını arttırsa da her dönem için eğitim süresi azalır.

Model optimizasyonu, Adam stokastik gradyan inişine sahip iyileştiricisi kullanılarak gerçekleştirilir. Adam optimizasyonu, birinci dereceden ve ikinci dereceden momentlerin uyarlanabilir tahminine dayanan stokastik bir gradyan iniş yöntemidir.

Eğitim sürecinde Epoch = 50, Batch Size = 64, Öğrenme hızı = 0.002 olarak belirlenmiştir. Kayıp işlevi çapraz entropidir.

Eğitim sırasında Keras Apı'sindeki ReduceLROnPlateau kullanılmıştır. Modeller genellikle öğrenme durgunlaştığında öğrenme oranını 2-10 kat azaltmaktan yararlanır. Bu geri arama bir miktarı izler ve 'sabır' sayısı için herhangi bir gelişme görülmezse öğrenme oranı düşer. ReduceLROnPlateau bir metriğin gelişmesi durduğunda öğrenme oranını 6.2'de ki gibi günceller. Bu da öğrenme oranı durgunlaştığında öğrenme oranını azaltmaya yardımcı olur.

$$new_lr = lr * factor \tag{6.2}$$

Factor değerini 0,5 ve öğrenme hızının alt sınırını da 1e-3 olarak belirledik. Bu ayarlamalar sayesinde öğrenme hızı dinamik olarak azaltılır ve kontrol altına alınmış olur. Ayrıca modelde veri arttırmayı denedik ve 50 Epoch için eğittik.

3.7. Değerlendirme Ölçütleri

Bu çalışmadaki modelin deneysel değerlendirmesini yapmak için karışıklık matrisi tabanlı metrikler kullandık. Karışıklık matrisi, sınıflandırma problemiyle ilgili tahmin sonuçlarının bir özetidir. Derin öğrenme ile yapılan birçok sınıflandırma sistemlerinin değerlendirilmesinde karışıklık matrisi kullanılır. Karışıklık matrisi yalnızca sınıflandırıcı tarafından yapılan hatalar hakkında değil daha da önemlisi geliştirilen sistemde yapılan hata türleri hakkında da fikir verir. Tablo 3.3'de gösterildiği gibi bir karışıklık matrisinin aşağıdaki gibi dört beklenen sonucu vardır. Bu sonuçlar doğrultusunda geliştirilen sistem için sınıflandırma ile ilgili tahmini ve hata türleri hakkında genel bir bakış sağlar.

Tablo 3.3. Karışıklık matrisi

	Tahmin Edilen Pozitif	Tahmin Edilen Negatif
Gerçek Pozitif	True Positive (TP)	False Negative (FN)
Gerçek Negatif	False Positive (FP)	True Negative (TN)

Gerçek Pozitif (TP)

Gerçek pozitif, ilk başta pozitif olan ve ek olarak derin öğrenme modeli tarafından pozitif olarak beklenen tahminlerdir.

Yanlış Pozitif (FP)

Yanlış pozitifler, başlangıçta negatif olan ve derin öğrenme modeli tarafından pozitif olarak beklenen tahminlerdir.

Gerçek Negatif (TN)

Gerçek negatifler, başlangıçta negatif olan ve derin öğrenme modeli tarafından olumsuz olarak beklenen tahminlerdir.

Yanlış Negatif (FN)

Yanlış negatifler, başlangıçta pozitif olan ve derin öğrenme modeli tarafından negatif olarak beklenen tahminlerdir.

Bir karışıklık matrisinde (x ekseninin tahmin edilen sınıf etiketi ve y ekseninin gerçek etiket olduğu varsayılırsa) bir sınıf için toplam TP sayısı, tahmin edilen sınıfın hedef sınıfla eşleşmesidir. Bir sınıf için FN, TP değeri hariç karşılık gelen satırdaki değerlerin toplamıdır. Bir sınıf için FP, TP değeri hariç karşılık gelen bir sütundaki değerlerin toplamıdır. Belirli bir sınıf için TN, o sınıfın sütun ve satırı hariç tüm sütun ve satırların toplamı olacaktır.

Modelin sınıflandırma performansını ölçmek için kullanılan değerlendirme metriklerini aşağıdaki gibi açıklayabiliriz.

Doğruluk

Doğruluk, verilen derin öğrenme sınıflandırıcılarının sonuçları için en önemli metriktir. Bu sadece karışıklık matrisi bileşenlerinin toplam değerlerine bölünen gerçek pozitiflerin ve gerçek negatiflerin toplamıdır. En güvenilir model en iyisidir ancak neredeyse eşit yanlış pozitif değerlere ve yanlış olumsuz değerlere sahip simetrik veri kümelerinin bulunduğundan emin olmak önemlidir. Bu nedenle önerilen DenseNet121 modelimizin sınıflandırma kalitesini değerlendirmek için karışıklık matrisinin yukarıdaki bileşenleri hesaplanmalıdır.

$$\text{Doğruluk} = \frac{(\text{TP}+\text{FN})}{(\text{TP}+\text{TN}+\text{FP}+\text{FN})}, \tag{7.1}$$

Kesinlik

Kesinlik, gerçek pozitif tahmin edilen değerler ile tam pozitif tahmin edilen değerler arasındaki ilişkiyi vermek için temsil edilir [53].

$$\text{Kesinlik} = \frac{\text{TP}}{(\text{TP}+\text{FP})}, \tag{7.2}$$

Duyarlılık

Duyarlılık, tahminin gerçek pozitif değerleri ile tahmin edilen gerçek pozitif değerlerin toplamı arasındaki orandır [53].

$$\text{Duyarlılık} = \frac{\text{TP}}{(\text{TP}+\text{FN})}, \tag{7.3}$$

Özgüllük

Özgüllük negatif örneklerin doğru tanıma oranıdır.

$$\text{Özgüllük} = \frac{\text{TN}}{(\text{TN}+\text{FP})}, \tag{7.4}$$

Hassasiyet

Hassasiyet pozitif örneklerin doğru tanıma oranıdır.

$$\text{Hassasiyet} = \frac{\text{TP}}{(\text{TP}+\text{FN})}, \tag{7.5}$$

F1-Skoru

F1-Skoru, kesinlik ve duyarlılığı birleştiren modelin doğruluğunun genel bir ölçüsüdür. F1-Skoru, çarpma ile kesinlik ve duyarlılık metriklerinin toplamı arasındaki oranın iki katıdır [53].

$$\text{F1} - \text{Skoru} = \frac{2 * (\text{Kesinlik} * \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})}. \tag{7.6}$$

Bu değerlendirme metrikleri, tıbbi görüntüleme sistemleri için yapılan çalışmaları değerlendirirken genel olarak kullanılırlar ve yüksek performans sergilerler. Bu nedenle Covid-19 tanısını tahmin ederken de bu performans metrikleri kullanılırlar.

4. BULGULAR VE TARTIŞMA

Bu bölümde, modelin sınıflandırma performansını ölçmek için kullanılan değerlendirme metriklerini ve yapılan çalışmalar sonucunda elde edilen verileri açıklıyoruz. Model Covid-19'u tespit etmek için hastalık etiketlerini (Covid-19 pozitif veya değil) tahmin etmek üzere tasarlanmıştır. Renklendirme işlemini yapmadan önce veri setini DenseNet121 modeli ile çalıştırdığımızda elde ettiğimiz başarı oranı %90,74 oldu. Bu çalışmaya yönelik karışıklık matrisi Şekil 4.1.'de gösterilmiştir.

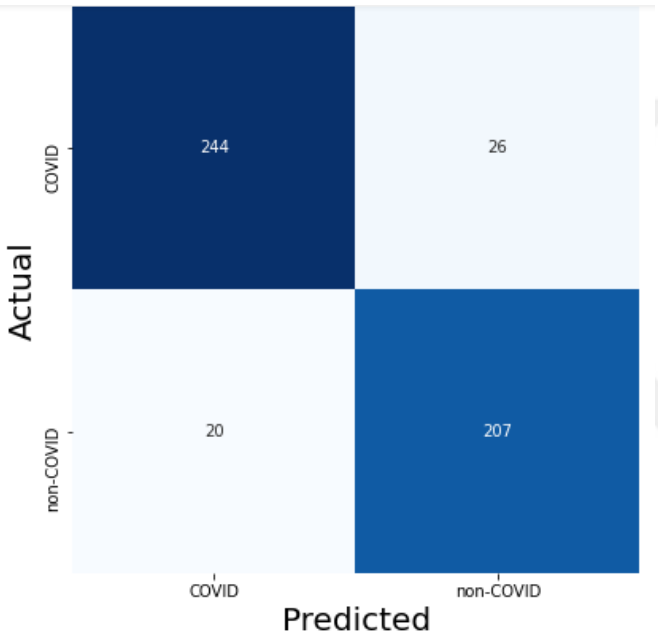

Şekil 4.1. Normal veri seti ile elde ettiğimiz karışıklık matrisi

Covid-19 tespit oranımızı arttırmak için veri setini DeOldify Kütüphanesi ile renklendirip daha sonra renklendirilmiş veri seti ile çalışmamızı gerçekleştirdik. Gerçekleştirilen bu çalışma sonucunda elde ettiğimiz başarı oranı %91,75 oldu. Bu çalışmaya yönelik karışıklık matrisi Şekil 4.2.'de gösterilmiştir.

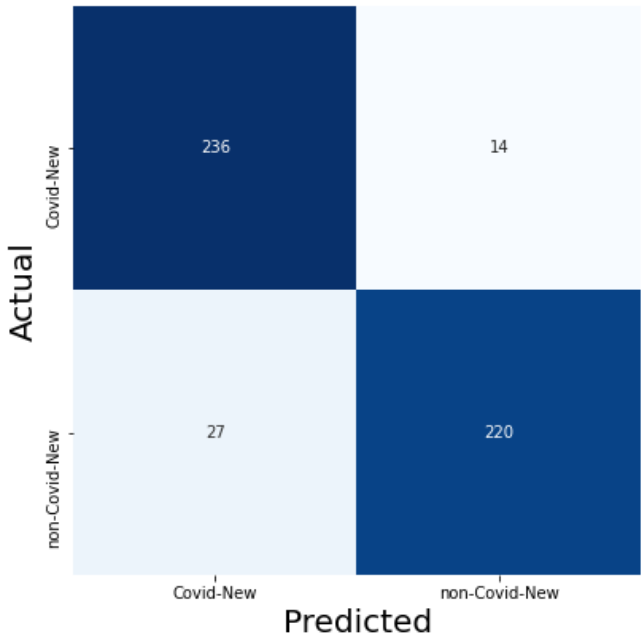

Şekil 4.2. Renklendirdiğimiz veri seti ile elde ettiğimiz karışıklık matrisi

Covid-19'u daha yüksek başarı oranı ile tespit etmek için veri seti ile renklendirdiğimiz veri setini karıştırdık. Eğitim için %80 test için %20 olacak şekilde bölümlendirdik. Bu çalışma sonucunda elde ettiğimiz başarı oranı %96,87 oldu. Bu çalışmaya yönelik karışıklık matrisi Şekil 4.3.'de gösterilmiştir.

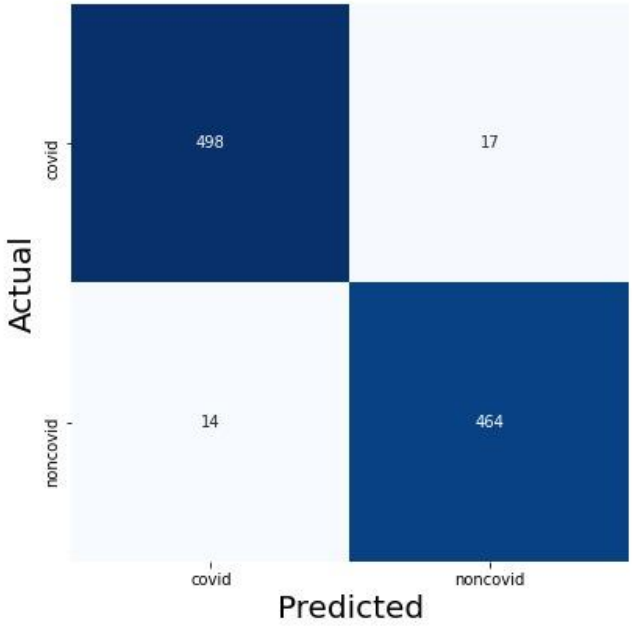

Şekil 4.3. Karıştırdığımız veri seti ile %96,87 başarı elde ettiğimiz karışıklık matrisi

Son olarak modelimizin başarı oranını arttırmak için eğitim %90, test %10 oranlarında olacak şekilde karıştırdığımız veri setini bölüp modelimizi çalıştırdık. Ölçümler için elde edilen sonuçlar Tablo 4.1.'de gösterilmiştir.

Tablo 4.1. Performans metriklerinin sonuçları

Doğruluk	0.9819
Hassasiyet	0.9879
Özgüllük	0.9758
Kesinlik	0.9761
Duyarlılık	0.9879
F1-Skoru	0,9819

Tablo 4.1.'de de görüldüğü gibi sistem her metrik için 0.97'in üzerinde etkinlik değerleri sunar. Tablo 4.1.'de görüldüğü gibi en yüksek sonuç hassasiyet değerine aittir bu da modelin yanlış pozitif üretme olasılığının düşük olduğunu gösterir. Modelin yanlış pozitif üretme olasılığının düşük olduğunun göstergesi en yüksek sonucun hassasiyet değerine eşit olmasıdır.

Bununla birlikte metriklerin geri kalanı, hem gerçek pozitifleri hem de negatifleri tanımlayan modelin iyi bir performans gösterdiğini kanıtlayan yüksek değerler sunar. Metrikler, modelin bu tür görüntülerle bu hastalığın tanımlanmasına karşı oldukça hassas olduğunu ve düşük oranda yanlış negatif olduğunu göstermektedir. Böylece bu çalışma Covid-19 hastalarına erken tanı koymak, izolasyon sağlamak, tedavisinin etkinliğini arttırmak, radyologların iş yükünü hafifletmek ve salgının kontrolünü sağlamak için sistemin büyük bir potansiyele sahip olduğunu göstermektedir. Son olarak yöntemimizin sonuçlarını, renklendirme olmadan kullandığımız BT veri seti üzerindeki önceki çalışmaların sonuçlarıyla karşılaştırdık. Tablo 4.2. 'de gösterildiği gibi yöntemimiz diğer yaklaşımlardan daha üstün sonuçlar vermiştir.

Tablo 4.2. Yöntemlerin karşılaştırılması

Yazar	**Yöntem**	**Doğruluk (%)**
Soares ve ark. [54]	xDNN	97.38
Bansal ve ark. [55]	ResNet	95.16
Lawton ve ark. [56]	VGG19	95.75
Jaiswal ve ark. [57]	DenseNet201	96.25
Silva ve ark. [58]	EfficientNet	87.68
Bizim Yöntemimiz	**DenseNet121**	**98.19**

Çalışmamızın başarısını doğrulamak için Şekil 4.4.'de karışıklık matrisi gösterilmiştir. Karışıklık matrisi, sınıflandırma problemiyle ilgili tahmin sonuçlarının bir özetidir. Karışıklık matrisi, yalnızca sınıflandırıcı tarafından yapılan hatalar hakkında değil daha da önemlisi yapılan hata türleri hakkında da fikir verir [59].

Sınıflandırma sonuçları, eğitim ve kayıp eğrisi kullanılarak da temsil edilebilir. Eğitim veri setinden modelin, eğitim sürecindeki varyasyonları temsil etmek için kayıp eğrisi hesaplanır. Derin öğrenme modelinin nihai doğruluk seviyesi 0,98 ve kayıp 0,05 olarak kaydedilmiştir. Ayrıca model için kayıp eğrisi de Şekil 4.5.'de görülebilir.

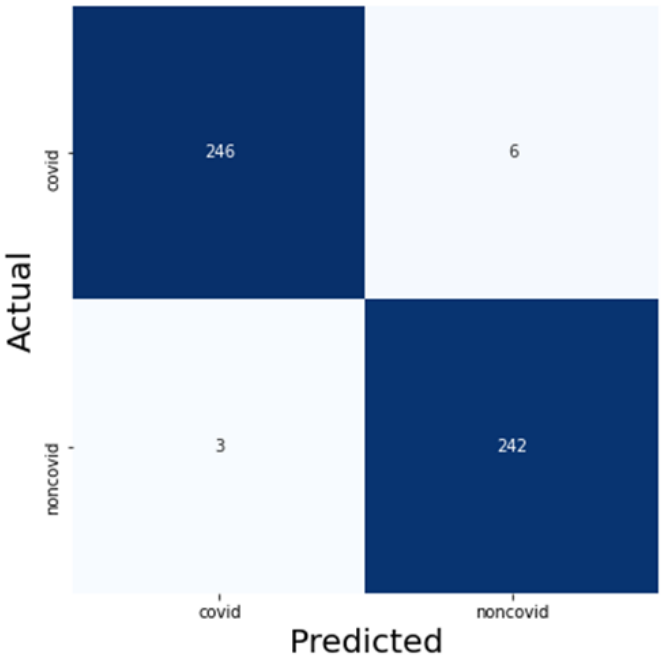

Şekil 4.4. Modelin karışıklık matrisi

DenseNet121'in karışıklık matrisine bakıldığında 249 Covid-19 pozitif BT taramasından 246 Covid-19 olan olarak doğru şekilde, 3'ünü yanlış şekilde sınıflandırıp non-Covid-19 olarak sınıflandırıldı. 248 Covid-19 olmayan BT taramasından 242 Covid-19 olmayan olarak doğru şekilde, 6'sı da Covid-19 olarak yanlış sınıflandırıldı.

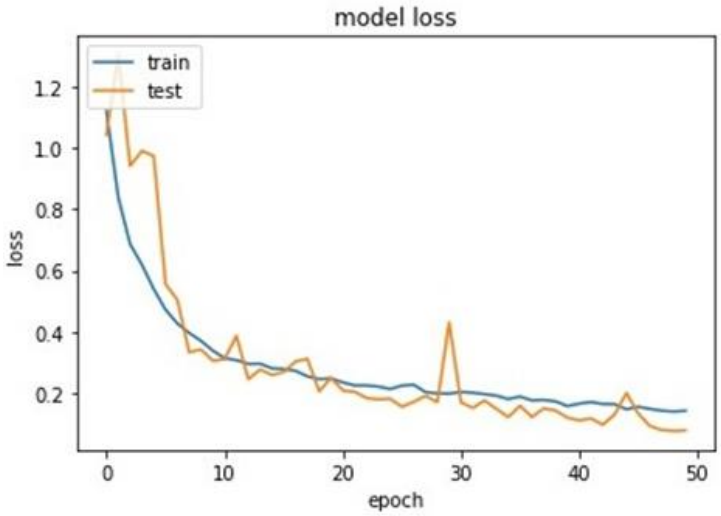

Şekil 4.5. Kayıp eğrisi

Bir öğrenme eğrisi, deneyim veya zaman üzerinden model öğrenme performansının bir grafiğidir. Bir öğrenme eğrisinin şekli ve dinamikleri, bir makine öğrenimi modelinin davranışını teşhis etmek için kullanılabilir ve belki de öğrenmeyi veya performansı iyileştirmek için yapılabilecek yapılandırma değişikliklerinin türüne ilişkin önerilerde bulunabilir. Şekil 4.5.'deki eğrilere baktığımızda çok fazla sapma olmadığından veri kümesinin temsil edilebilir bir veri kümesi olduğunu söyleyebiliriz.

5. SONUÇ

Bu çalışmada, göğüs BT tarama görüntülerinden Covid-19 pozitif vakalarını tanımlamak için mevcut CNN tabanlı görüntü sınıflandırma yaklaşımlarından DenseNet121'in deneysel bir değerlendirmesi sunulmuştur. Kapsamlı deneyden, önerilen yaklaşımın dikkate alınan her performans metriği açısından %97'nin üzerinde yanlış pozitiflerin sayısında iyi bir azalmaya sahipken çok etkileyici sonuçlar elde edebileceği görülmektedir. Deneysel gözlemlerden derin öğrenme modeli yaklaşımlarının hızlı tarama sağlayarak Covid-19'un yayılma kontrolü üzerinde potansiyel olarak büyük bir etkisi olabileceği açıktır. DL tabanlı yaklaşımlar diğer tıbbi görüntüleme görevlerinde yaygın olarak kullanıldığından bu tür yaklaşımların mevcut pandeminin tarama sürecinde de kullanılmasının zamanı gelmiştir.

Sonuç olarak çalışmamız doktorların Covid-19 hasta tanısını tespit etmelerinde ve BT görüntülerinden doku bozukluğunu otomatik olarak tanımlamalarına yardımcı olmak için derin öğrenme yaklaşımlarından DenseNet121'in fizibilitesini göstermiştir. Covid-19 hastalarının BT tarama görüntülerinin sınıflandırma işleminde yüksek performans elde eden sitem, Covid-19 hastalarına erken tanı koymak, izolasyon sağlamak, tedavisinin etkinliğini arttırmak, radyologların iş yükünü hafifletmek ve salgının kontrolünü sağlamak için büyük bir potansiyele sahiptir.

Son olarak ağların eğitiminde ne kadar çok veri kullanılırsa yani yöntemleri gerçekçi bir senaryoda değerlendirmek için daha büyük ve daha çeşitli veri kümeleri elde edilirse daha güvenilir ve daha gerçekçi bir derin öğrenme modeli elde edilebilir. Bu nedenle diğer akciğer hastalıkları hakkında etiketli bilgilere sahip bilgisayarlı tomografi görüntüleri ile Covid-19 bilgisayarlı tomografi görüntülerinin kombinasyonundan daha güvenilir sistemler sağlanabileceğini varsayıyoruz.

KAYNAKLAR

[1] R.M. Pereira, D. Bertolini, L.O. Teixeira, C.N. Silla, Y.M.G. Costa, COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios, Comput. Methods Programs Biomed. 194 (2020) 105532. https://doi.org/10.1016/j.cmpb.2020.105532.

[2] L. Brunese, F. Mercaldo, A. Reginelli, A. Santone, Explainable Deep Learning for Pulmonary Disease and Coronavirus COVID-19 Detection from X-rays, Comput. Methods Programs Biomed. 196 (2020) 105608. https://doi.org/10.1016/j.cmpb.2020.105608.

[3] A.I. Khan, J.L. Shah, M.M. Bhat, CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images, Comput. Methods Programs Biomed. 196 (2020) 105581. https://doi.org/10.1016/j.cmpb.2020.105581.

[4] I.D. Apostolopoulos, S. Aznaouridis, M. Tzani, Extracting possibly representative COVID-19 Biomarkers from X-Ray images with Deep Learning approach and image data related to Pulmonary Diseases, (2020). https://doi.org/10.1007/s40846-020-00529-4.

[5] X. Wu, H. Hui, M. Niu, L. Li, L. Wang, B. He, X. Yang, L. Li, H. Li, J. Tian, Y. Zha, Deep learning-based multi-view fusion model for screening 2019 novel coronavirus pneumonia: A multicentre study, Eur. J. Radiol. 128 (2020) 1–9. https://doi.org/10.1016/j.ejrad.2020.109041.

[6] M. Yousefzadeh, P. Esfahanian, S. Mohammad, S. Movahed, S. Gorginid, D. Rahmatiid, A. Abedini, A. Nadji, S. Haseli, M.B. Karam, A. Kiani, M. Hoseinyazdi, J. Roshandel, R. Lashgariid, ai-corona: Radiologist-assistant deep learning framework for COVID-19 diagnosis in chest CT scans, (2021). https://doi.org/10.1371/journal.pone.0250952.

[7] C. Jin, W. Chen, Y. Cao, Z. Xu, Z. Tan, X. Zhang, L. Deng, C. Zheng, J. Zhou, H. Shi, J. Feng, Development and evaluation of an artificial intelligence system for COVID-19 diagnosis, (n.d.). https://doi.org/10.1038/s41467-020-18685-1.

[8] X. Xu, X. Jiang, C. Ma, P. Du, X. Li, S. Lv, L. Yu, Y. Chen, J. Su, G. Lang, Y. Li, H. Zhao, K. Xu, L. Ruan, W. Wu, Deep learning system to screen coronavirus disease 2019 pneumonia, ArXiv. XIII (2020) 1563–1572.

[9] S. Jin, B. Wang, H. Xu, C. Luo, L. Wei, W. Zhao, X. Hou, W. Ma, Z. Xu, Z. Zheng, W. Sun, L. Lan, W. Zhang, X. Mu, C. Shi, Z. Wang, J. Lee, Z. Jin, M. Lin, H. Jin, L. Zhang, J. Guo, B. Zhao, Z. Ren, S. Wang, Z. You, J. Dong, X. Wang, J. Wang, W. Xu, AI-assisted CT imaging analysis for COVID-19 screening: Building and deploying a medical AI system in four weeks, MedRxiv. (2020) 1–22. https://doi.org/10.1101/2020.03.19.20039354.

[10] T. Javaheri, M. Homayounfar, Z. Amoozgar, R. Reiazi, F. Homayounieh, E. Abbas, A. Laali, A. Reza Radmard, M. Hadi Gharib, S. Ali Javad Mousavi, O. Ghaemi, R. Babaei, H. Karimi Mobin, M. Hosseinzadeh, R. Jahanban-Esfahlan, K. Seidi, M.K. Kalra, G. Zhang, L. Chitkushev, B. Haibe-Kains, R. Malekzadeh, R. Rawassizadeh, CovidCTNet: An Open-Source Deep Learning Approach to Identify Covid-19 Using CT Image Equal contribution in the paper ‡, n.d.

[11] A.A. Ardakani, A.R. Kanafi, U.R. Acharya, N. Khadem, A. Mohammadi, Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10

convolutional neural networks, Comput. Biol. Med. 121 (2020) 103795. https://doi.org/10.1016/j.compbiomed.2020.103795.

[12] J. Chen, L. Wu, J. Zhang, L. Zhang, D. Gong, Y. Zhao, S. Hu, Y. Wang, X. Hu, B. Zheng, K. Zhang, H. Wu, Z. Dong, Y. Xu, Y. Zhu, X. Chen, L. Yu, H. Yu, Deep learning-based model for detecting 2019 novel coronavirus pneumonia on high-resolution computed tomography: a prospective study, MedRxiv. (2020). https://doi.org/10.1101/2020.02.25.20021568.

[13] M. Akif Cifci, Deep Learning Model for Diagnosis of Corona Virus Disease from CT Images, Int. J. Sci. Eng. Res. 11 (2020) 273–278. http://www.ijser.org.

[14] I.D. Apostolopoulos, T.A. Mpesiana, Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks, Phys. Eng. Sci. Med. 43 (2020) 635–640. https://doi.org/10.1007/s13246-020-00865-4.

[15] M. Horry, S. Chakraborty, M. Paul, A. Ulhaq, B. Pradhan, M. Saha, N. Shukla, X-Ray Image based COVID-19 Detection using Pre-trained Deep Learning Models, (2020). https://doi.org/10.31224/osf.io/wx89s.

[16] P.K. Sethy, S.K. Behera, P.K. Ratha, P. Biswas, Detection of Coronavirus Disease (COVID-19) Based on Deep Features and Support Vector Machine, (2020). https://www.preprints.org/manuscript/202003.0300/v2 (accessed May 14, 2021).

[17] S. Minaee, R. Kafieh, M. Sonka, S. Yazdani, G. Jamalipour Soufi, Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning, Med. Image Anal. 65 (2020) 101794. https://doi.org/10.1016/j.media.2020.101794.

[18] N.S. Punn, S. Agarwal, Automated diagnosis of COVID-19 with limited posteroanterior chest X-ray images using fine-tuned deep neural networks, (2020). https://doi.org/10.1007/s10489-020-01900-3.

[19] A. Narin, C. Kaya, Z. Pamuk, Automatic Detection of Coronavirus Disease (COVID-19) Using X-ray Images and Deep Convolutional Neural Networks, (2020). https://doi.org/10.1007/s10044-021-00984-y.

[20] S.U. khalid Bukhari, S.S.K. Bukhari, A. Syed, S.S.H. Shah, The diagnostic evaluation of convolutional neural network (CNN) for the assessment of chest X-ray of patients infected with COVID-19, MedRxiv. (2020). https://doi.org/10.1101/2020.03.26.20044610.

[21] P.G.B. Moutounet-Cartan, Deep Convolutional Neural Networks to Diagnose COVID-19 and other Pneumonia Diseases from Posteroanterior Chest X-Rays, (2020). http://arxiv.org/abs/2005.00845 (accessed May 14, 2021).

[22] G. Maguolo, L. Nanni, A Critic Evaluation of Methods for COVID-19 Automatic Detection from X-Ray Images, (2020). http://arxiv.org/abs/2004.12823 (accessed May 14, 2021).

[23] E. Luz, P.L. Silva, R. Silva, L. Silva, G. Moreira, D. Menotti, Towards an Effective and Efficient Deep Learning Model for COVID-19 Patterns Detection in X-ray Images, (2020). https://doi.org/10.1007/s42600-021-00151-6.

[24] E.E.-D. Hemdan, M.A. Shouman, M.E. Karar, COVIDX-Net: A Framework of Deep Learning Classifiers to Diagnose COVID-19 in X-Ray Images, (2020). https://arxiv.org/abs/2003.11055 (accessed May 14, 2021).

[25] S. Elghamrawy, A.E. Hassanien, Diagnosis and Prediction Model for COVID-19 Patient's Response

to Treatment based on Convolutional Neural Networks and Whale Optimization Algorithm using CT images, MedRxiv. 2019 (2020). https://doi.org/10.1101/2020.04.16.20063990.

[26] X. He, X. Yang, S. Zhang, J. Zhao, Y. Zhang, E. Xing, P. Xie, Sample-efficient deep learning for COVID-19 diagnosis based on CT scans, MedRxiv. XX (2020). https://doi.org/10.1101/2020.04.13.20063941.

[27] B.X. Shuai Wang, Bo Kang, Jinlu Ma, Xianjun Zeng5, Mingming Xiao1, Jia Guo, Mengjiao Cai, Jingyi Yang, Yaodong Li, Xiangfei Meng, A deep learning algorithm using CT images to screen for Corona Virus Disease (COVID-19), (2020) 1–27.

[28] B. Liu, P. Liu, L. Dai, Y. Yang, P. Xie, Y. Tan, J. Du, W. Shan, C. Zhao, Q. Zhong, X. Lin, X. Guan, N. Xing, Y. Sun, W. Wang, Z. Zhang, X. Fu, Y. Fan, M. Li, N. Zhang, L. Li, Y. Liu, L. Xu, J. Du, Z. Zhao, X. Hu, W. Fan, R. Wang, C. Wu, Y. Nie, L. Cheng, L. Ma, Z. Li, Q. Jia, M. Liu, H. Guo, G. Huang, H. Shen, L. Zhang, P. Zhang, G. Guo, H. Li, W. An, J. Zhou, K. He, Assisting scalable diagnosis automatically via CT images in the combat against COVID-19, Sci. Reports |. 11 (123AD) 4145. https://doi.org/10.1038/s41598-021-83424-5.

[29] Y. Song, S. Zheng, L. Li, X. Zhang, X. Zhang, Z. Huang, J. Chen, R. Wang, H. Zhao, Y. Zha, J. Shen, Y. Chong, Y. Yang, Deep learning Enables Accurate Diagnosis of Novel Coronavirus (COVID-19) with CT images, IEEE/ACM Trans. Comput. Biol. Bioinforma. 14 (2021). https://doi.org/10.1109/TCBB.2021.3065361.

[30] A. Amyar, R. Modzelewski, H. Li, S. Ruan, Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia: Classification and segmentation, Comput. Biol. Med. 126 (2020) 104037. https://doi.org/10.1016/j.compbiomed.2020.104037.

[31] D. Singh, V. Kumar, & Vaishali, M. Kaur, Classification of COVID-19 patients from chest CT images using multi-objective differential evolution-based convolutional neural networks, (n.d.). https://doi.org/10.1007/s10096-020-03901-z/Published.

[32] A.A. Farid, G.I. Selim, H.A.A. Khater, A Novel Approach of CT Images Feature Analysis and Prediction to Screen for Corona Virus Disease (COVID-19), (2020). https://doi.org/10.20944/PREPRINTS202003.0284.V1.

[33] L. Wang, Z.Q. Lin, A. Wong, COVID-Net: a tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images, (2020). https://doi.org/10.1038/s41598-020-76550-z.

[34] F. Ucar, D. Korkmaz, COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images, Med. Hypotheses. 140 (2020) 109761. https://doi.org/10.1016/j.mehy.2020.109761.

[35] M. Rahimzadeh, A. Attar, A NEW MODIFIED DEEP CONVOLUTIONAL NEURAL NETWORK FOR DETECTING COVID-19 FROM X-RAY IMAGES, ArXiv. 19 (2020) 100360. https://doi.org/10.1016/j.imu.2020.100360.

[36] H. Mukherjee, S. Ghosh, A. Dhar, · Sk, M. Obaidullah, · K C Santosh, · Kaushik Roy, Shallow Convolutional Neural Network for COVID-19 Outbreak Screening Using Chest X-rays, (n.d.). https://doi.org/10.1007/s12559-020-09775-9.

[37] S. Khobahi, C. Agarwal, M. Soltanalian, CoroNet: A Deep Network Architecture for Semi-

Supervised Task-Based Identification of COVID-19 from Chest X-ray Images, MedRxiv. (2020) 1–16. https://doi.org/10.1101/2020.04.14.20065722.

[38] H.A. Ali Mohammad Alqudah, Shoroq Qazan, A. Isam Abu Qasmieh, Alqudah, COVID-2019 detection using X-ray images and artificial intelligence hybrid systems, 5 (2020) 50–51. https://doi.org/10.5455/jjee.204-158531224.

[39] M. Farooq, A. Hafeez, COVID-ResNet: A Deep Learning Framework for Screening of COVID19 from Radiographs, (2020). http://arxiv.org/abs/2003.14395 (accessed May 14, 2021).

[40] P. Afshar, S. Heidarian, F. Naderkhani, A. Oikonomou, K.N. Plataniotis, A. Mohammadi, COVID-CAPS: A Capsule Network-based Framework for Identification of COVID-19 cases from X-ray Images, (2020). http://arxiv.org/abs/2004.02696 (accessed May 14, 2021).

[41] A. Shoeibi, M. Khodatars, R. Alizadehsani, N. Ghassemi, M. Jafari, P. Moridian, A. Khadem, D. Sadeghi, S. Hussain, A. Zare, Z.A. Sani, J. Bazeli, F. Khozeimeh, A. Khosravi, S. Nahavandi, U.R. Acharya, P. Shi, Automated Detection and Forecasting of COVID-19 using Deep Learning Techniques: A Review, ArXiv. (2020).

[42] L. Zhang, M. Wang, M. Liu, D. Zhang, A Survey on Deep Learning for Neuroimaging-Based Brain Disorder Analysis, Front. Neurosci. 14 (2020) 1–19. https://doi.org/10.3389/fnins.2020.00779.

[43] W. Rawat, Z. Wang, Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review, Neural Comput. 29 (2017) 2352–2449. https://doi.org/10.1162/neco_a_00990.

[44] J. Jang, H. Cho, J. Kim, J. Lee, S. Yang, Deep neural networks with a set of node-wise varying activation functions, Neural Networks. 126 (2020) 118–131. https://doi.org/10.1016/j.neunet.2020.03.004.

[45] V. Suárez-Paniagua, I. Segura-Bedmar, Evaluation of pooling operations in convolutional architectures for drug-drug interaction extraction, BMC Bioinformatics. 19 (2018). https://doi.org/10.1186/s12859-018-2195-1.

[46] N.S.G. Hinton, A.K.I. Sutskever, R. Salakhutdinov, Dropout: A Simple Way to Prevent Neural Networks from Overfitting, Phys. Lett. B. 299 (2014) 1929–1958. https://doi.org/10.1016/0370-2693(93)90272-J.

[47] J.G.A. Barbedo, Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification, Comput. Electron. Agric. 153 (2018) 46–53. https://doi.org/10.1016/j.compag.2018.08.013.

[48] A. Lumini, L. Nanni, Deep learning and transfer learning features for plankton classification, Ecol. Inform. 51 (2019) 33–43. https://doi.org/10.1016/j.ecoinf.2019.02.007.

[49] G. Huang, Z. Liu, L. van der Maaten, K.Q. Weinberger, Densely Connected Convolutional Networks, (2016). https://arxiv.org/abs/1608.06993 (accessed May 20, 2021).

[50] B. Nigam, A. Nigam, R. Jain, S. Dodia, N. Arora, B. Annappa, COVID-19: Automatic detection from X-ray images by utilizing deep learning methods, Expert Syst. Appl. 176 (2021) 114883. https://doi.org/10.1016/j.eswa.2021.114883.

[51] Antic, J.: Deoldify (2018). https://github.com/jantic/DeOldify, (n.d.).

[52] X. Glorot, A. Bordes, Y. Bengio, Deep sparse rectifier neural networks, J. Mach. Learn. Res. 15

(2011) 315–323.

[53] C. Goutte, E. Gaussier, A Probabilistic Interpretation of Precision, Recall and F-Score, with Implication for Evaluation, Lect. Notes Comput. Sci. 3408 (2005) 345–359. https://doi.org/10.1007/978-3-540-31865-1_25.

[54] E. Soares, P. Angelov, S. Biaso, M.H. Froes, D.K. Abe, SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification, MedRxiv. (2020) 1–8.

[55] A. Bansal, G. Thakur, D. Verma, Detection of covid-19 using the ct scan image of lungs, CEUR Workshop Proc. 2786 (2021) 219–227.

[56] S. Lawton, S. Viriri, Detection of COVID-19 from CT Lung Scans Using Transfer Learning, Comput. Intell. Neurosci. 2021 (2021). https://doi.org/10.1155/2021/5527923.

[57] A. Jaiswal, N. Gianchandani, D. Singh, V. Kumar, M. Kaur, Classification of the COVID-19 infected patients using DenseNet201 based deep transfer learning, J. Biomol. Struct. Dyn. (2020). https://doi.org/10.1080/07391102.2020.1788642.

[58] P. Silva, E. Luz, G. Silva, G. Moreira, R. Silva, D. Lucio, D. Menotti, COVID-19 detection in CT images with deep learning: A voting-based scheme and cross-datasets analysis, Informatics Med. Unlocked. 20 (2020). https://doi.org/10.1016/j.imu.2020.100427.

[59] K.M. Ting, Confusion Matrix, in: C. Sammut, G.I. Webb (Eds.), Encycl. Mach. Learn., Springer US, Boston, MA, 2010: p. 209. https://doi.org/10.1007/978-0-387-30164-8_157.

ÖZGEÇMİŞ

Semiha GÜNGÖR

[redacted]

[redacted]

[redacted]

[redacted]

ARAŞTIRMA DENEYİMİ

- ✓ Derin Öğrenme
- ✓ Java, Python, C#
- ✓ Mobil uygulama(React Native)