



**COVID-19 VAKALARININ TESPİTİ İÇİN
DERİN ÖĞRENME TEKNİKLERİNİN
UYGULANMASI**

Hafize ARDUÇ

**Yüksek Lisans Tezi
Biyomedikal Mühendisliği Anabilim Dalı
Danışman: Dr. Öğr. Üyesi Yaşar DAŞDEMİR**

2022

Her hakkı saklıdır.



**FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZİ**

**COVID-19 VAKALARININ TESPİTİ İÇİN DERİN ÖĞRENME
TEKNİKLERİNİN UYGULANMASI**

Hafize ARDUÇ

Tez Danışmanı: Dr. Öğr. Üyesi Yaşar DAŞDEMİR

Anabilim Dalı: Biyomedikal Mühendisliği

Erzurum

2022

Her hakkı saklıdır

ETİK KURALLARA UYGUNLUK BEYANI

Erzurum Teknik Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki tüm bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

08 / 04 / 2021

Hafize ARDUÇ

ÖZET

YÜKSEK LİSANS TEZİ

COVID-19 VAKALARININ TESPİTİ İÇİN DERİN ÖĞRENME TEKNİKLERİNİN UYGULANMASI

Hafize ARDUÇ

Erzurum Teknik Üniversitesi

Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Ana Bilim Dalı

Danışman: Dr. Öğr. Üyesi Yaşar DAŞDEMİR

Yeni Koronavirüs Hastalığı (COVID-19), ateş, öksürük, nefes darlığı gibi solunum yolu enfeksiyon belirtileri gösteren bir grup hastada yapılan araştırmalar sonucunda ortaya çıkan yeni bir virüstür. Hızlı teşhis yöntemleri ile hastalığın yayılmasını önlemek ve pozitif vakaları erken tespit etmek çok önemlidir. COVID-19 teşhisi için kullanılan en yaygın test tekniği, gerçek zamanlı tersine test tekniği olan RT-PCR'dir. Ancak, patolojik laboratuvar testlerinin uzun sürmesi ve yanlış test sonuçları, araştırmacıları farklı alanlara yöneltmiştir. Radyolojik görüntüleme, çeşitli akciğer hastalıklarının tespitinde yararlı olduğu gibi COVID-19 hastalığını izlemek için de kullanılmaya başlanmıştır. Radyolojik görüntüleme ile birlikte derin öğrenme tekniklerinin uygulanması bu hastalığın doğru tespitinde oldukça önemlidir. Bu çalışmada, COVID-19 X-Ray veri seti kullanılarak temel füzyon fonksiyonlarının topluluk öğrenme algoritmaları üzerindeki sınıflandırma performansına etkisi araştırılmıştır. Farklı derin öğrenme modellerini birleştirmek için iki farklı topluluk modeli oluşturulmuştur; ENS-1 ve ENS-2. Bu topluluk modellerinde Max, Mode, Sum, Mean ve Product gibi temel füzyon fonksiyonları test edilmiştir. Elde edilen değerler incelendiğinde Max ve Product temel füzyon fonksiyonlarının sınıflandırma performansı üzerinde olumlu bir etkiye sahip olduğu görülmektedir. Çoklu sınıflandırmada, hem ENS-1 hem de ENS-2 için Max işlevi sırasıyla %85 ve %86 doğruluk oranıyla öne çıkmaktadır. Product fonksiyonu, ikili sınıflandırmada %99 ile en yüksek performansı elde etmiştir. Sonuçlar, füzyon yöntemlerinin ikili sınıflandırmada daha iyi sınıflandırma performansı elde edebileceğini göstermektedir.

2022, 50 sayfa

Anahtar Kelimeler: COVID-19, X-Ray, Topluluk Öğrenimi, Transfer Öğrenimi, Füzyon, Maksimum Oylama

ABSTRACT

MS. Thesis

APPLICATION OF DEEP LEARNING TECHNIQUES FOR DETECTION OF COVID-19 CASES

Hafize ARDUÇ

Erzurum Technical University

Graduate School of Natural and Applied Sciences

Department of Biomedical Engineering

Supervisor: Assist. Prof. Dr. Yaşar DAŞDEMİR

The New Coronavirus Disease (COVID-19) is a new virus that emerged as a result of research in a group of patients who showed respiratory tract infection symptoms such as fever, cough, and shortness of breath. It is very important to prevent the spread of the disease with rapid diagnosis methods and to detect positive cases early. The most common testing technique used for diagnosing COVID-19 is RT-PCR, which is a real-time reverse testing technique. However, the long duration of pathological laboratory tests and inaccurate test results have led researchers to different fields. Radiological imaging has begun to be used to monitor COVID-19 disease as well as being useful in detecting various lung diseases. The application of deep learning techniques together with radiological imaging is very important in the correct detection of this disease. In this study, the effect of basic fusion functions on the classification performance of ensemble learning algorithms was investigated using the COVID-19 X-Ray dataset. Two different ensemble models were created to combine different deep learning models; ENS-1 and ENS-2. In these ensemble models, basic fusion functions such as Max, Mode, Sum, Mean and Product have been tested. When the obtained values are examined, it is seen that the Max and Product basic fusion functions have a positive effect on the classification performance. In multiclassification, the Max function for both ENS-1 and ENS-2 stands out with %85 and %86 accuracy, respectively. Product function achieved the highest performance with %99 in binary classification. The results show that fusion methods can achieve better classification performance in binary classification.

2022, 50 pages

Keywords: COVID-19, X-Ray, Ensemble Learning, Transfer Learning, Fusion, Max Voting

TEŞEKKÜR

Tezimin konusunun belirlenmesinde, araştırma aşamasında ve tamamlanma sürecindeki destek ve katkılarından dolayı danışmanım Sayın Dr. Öğr. Üyesi Yaşar DAŞDEMİR' e teşekkür ederim. Tez çalışması sırasında sürekli yanımda olan iş arkadaşlarıma desteklerinden dolayı teşekkür ederim. Bu süreçte manevi desteklerini hep üzerimde hissettiğim değerli aileme sonsuz teşekkürü borç bilirim.

Hafize ARDUÇ
Nisan 2022



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
SİMGELER VE KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ	1
1.1. Tezin Amacı	3
1.2. Tezin Kapsamı	4
2. KAYNAK ÖZETLERİ	5
3. MATERYAL ve YÖNTEM	9
3.1. Dijital X-ray Görüntü Veri Seti.....	9
3.1.1. COVID-19 veri seti.....	9
3.1.2. ChestX-ray8	9
3.2. Derin Öğrenme.....	11
3.2.1. Derin inanç ağları.....	12
3.2.2. Derin nöron ağlar	12
3.2.3. Derin oto-kodlayıcılar	12
3.2.4. Boltzmann makineleri	12
3.2.5. Sınırlı boltzmann makineleri.....	13
3.2.6. Tekrarlayan sinir ağları	13
3.2.7. Konvolüsyonel sinir ağları	13
3.3. Transfer Öğrenimi.....	16
3.3.1. Residual sinir ağı (ResNet) modeli	17
3.3.2. VGG blokları.....	18
3.3.3. DenseNet (densely connected convolutional networks) modeli	19
3.4. Çapraz Doğrulama	20
3.4.1. K katlamalı çapraz doğrulama	21
3.5. Deneysel Çalışma.....	21

3.6. Hiperparametler.....	21
3.7. Model Değerlendirme Metrikleri	24
3.8. Topluluk Öğrenimi ve Füzyon Modelleri	27
4. ARAŞTIRMA BULGULARI ve TARTIŞMA.....	31
4.1. Çoklu Sınıf (COVID-19, Pnömoni ve Normal) için Kesinlik, Duyarlılık, F1 Puan Değerlendirmesi ve Karışıklık Matrisi.....	33
4.2. İkili Sınıf (COVID-19 ve Normal) için Kesinlik, Duyarlılık, F1 Puan Değerlendirmesi ve Karışıklık Matrisi.....	35
4.3. İkili Sınıf (COVID-19 ve Pnömoni) için Kesinlik, Duyarlılık, F1 Puan Değerlendirmesi	37
4.4. Çoklu Sınıf (COVID-19, Pnömoni ve Normal) için Füzyon Yöntem Değerlendirmesi	39
4.5. İkili Sınıf (COVID-19 ve Normal) için Füzyon Yöntem Değerlendirmesi	41
4.6. İkili Sınıf (COVID-19, Pnömoni) için Füzyon Yöntem Değerlendirmesi.....	43
5. SONUÇ ve ÖNERİLER.....	46
KAYNAKLAR	48

SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
AI	Yapay Zekâ
BT	Bilgisayarlı Tomografi
CNN	Evrişimli Sinir Ağı
COVID-19	Yeni Koronavirüs Hastalığı
CXR	Göğüs Röntgeni
DL	Derin Öğrenme
DSÖ	Dünya Sağlık Örgütü
GPU	Grafik İşlem Birimi
MERS	Orta Doğu Solunum Sendromu
MRI	Manyetik Rezonans Görüntüleme
RSNA	Radyoloji Derneği
RT-PCR	Gerçek Zamanlı Tersine Test Tekniği
SARS	Şiddetli Akut Solunum Sendromu
SARS-COV-2	Şiddetli Akut Solunum Sendromu-Koronavirus-2

ŞEKİLLER DİZİNİ

Şekil 3.1. Hazırlanan veri setinden göğüs röntgeni görüntüleri örnekleri.	11
Şekil 3.2. ResNet-50 mimarisinin şematik gösterimi	18
Şekil 3.3. COVID-19 sınıflandırması için VGG-19'un ince ayarlı mimarisi.....	19
Şekil 3.4. DenseNet mimarisinin şematik gösterimi.....	20
Şekil 3.5. Kayıp ve öğrenme oranı grafiği.....	23
Şekil 3.6. Topluluk derin öğrenme yaklaşımının akış şeması	28
Şekil 4.1. Veri setini eğitim ve doğrulamaya bölmek için kullanılan 5 katlı çapraz doğrulama şeması	32
Şekil 4.2. Temel füzyon yöntemleri ile ENS-1 için çoklu sınıf (COVID-19, Pnömoni ve Normal) sonuçları.....	40
Şekil 4.3. Temel füzyon yöntemleri ile ENS-2 için çoklu sınıf (COVID-19, Pnömoni ve Normal) sonuçları.....	40
Şekil 4.4. Temel füzyon yöntemleri ile ENS-1 için ikili (COVID-19 ve Normal) sınıf sonuçları	42
Şekil 4.5. Temel füzyon yöntemleri ile ENS-2 için ikili (COVID-19 ve Normal) sınıf sonuçları	42
Şekil 4.6. Temel füzyon yöntemleri ile ENS-1 için ikili (COVID-19 ve Pnömoni) sınıf sonuçları	44
Şekil 4.7. Temel füzyon yöntemleri ile ENS-2 için ikili (COVID-19 ve Pnömoni) sınıf sonuçları	44

ÇİZELGELER DİZİNİ

Çizelge 3.1. Veri seti özeti.....	10
Çizelge 3.2. Karışıklık matrisi	26
Çizelge 3.3. Füzyon modelleri (i:sınıflandırıcı numarası, j:sınıf etiketi).....	30
Çizelge 4.1. 5 kat çapraz doğrulama ile çoklu sınıf (COVID-19, Pnömoni ve Normal) için kesinlik, duyarlılık, F1 puanı ve doğruluk performansları ...	33
Çizelge 4.2. Çoklu sınıf (COVID-19, Pnömoni ve Normal) için karışıklık matrisi	34
Çizelge 4.3. 5 kat çapraz doğrulama ile ikili sınıf (COVID-19 ve Normal) için kesinlik, duyarlılık, F1 puanı ve doğruluk performansları.....	35
Çizelge 4.4. İkili sınıf (COVID-19 ve Normal) için karışıklık matrisi.....	36
Çizelge 4.5. 5 kat çapraz doğrulama ile ikili sınıf (COVID-19 ve Pnömoni) için kesinlik, duyarlılık, F1 puanı ve doğruluk performansları.....	37
Çizelge 4.6. İkili sınıf (COVID-19 ve <i>Pnömoni</i>) için karışıklık matrisi	38
Çizelge 4.7. Füzyon yöntemleri ile çoklu sınıf (COVID-19, Normal, Pnömoni) için ENSEMBLE-1 ve ENSEMBLE-2 modellerinin doğruluk değerleri	39
Çizelge 4.8. Füzyon yöntemleri ile ikili sınıf (COVID-19 ve Normal) için ENSEMBLE-1 ve ENSEMBLE-2 modellerinin doğruluk değerleri	41
Çizelge 4.9. Füzyon yöntemleri ile ikili sınıf (COVID-19 ve Pnömoni) için ENSEMBLE-1 ve ENSEMBLE-2 modellerinin doğruluk değerleri	43
Çizelge 4.10. COVID-19 sınıflandırma yöntemlerinin doğruluk oranlarının karşılaştırılması.....	45

1. GİRİŞ

Yeni Koronavirüs Hastalığı (COVID-19), ateş, öksürük, nefes darlığı gibi solunum yolu enfeksiyon belirtileri gösteren bir grup hastada yapılan araştırmalar sonucunda ortaya çıkan yeni bir virüstür. Yeni koronavirüs hem hayvanları, hem de insanları etkileyebilen koronavirüs ailesinin bir türüdür. Geriye dönüp bakıldığında, korona virüsler son 20 yılda MERS (Orta Doğu Solunum Sendromu), SARS (Şiddetli Akut Solunum Sendromu) ve COVID-19 olmak üzere 3 salgına neden olmuştur (Li et al. 2020). Dünya Sağlık Örgütü (DSÖ) (WHO-World Health Organization), Çin menşeli ölümcül virüsü "COVID-19" olarak adlandırmıştır. Kurum bu ismi verirken aşağıdaki kısaltmaları kullanmıştır; "co" korona, "vi" virüs anlamına gelir ve "d" İngilizce "dease" kelimesinin baş harflerinden gelmektedir.

DSÖ tarafından virüsün resmi adı SARS-COV-2 (Şiddetli Akut Solunum Sendromu-Koronavirus-2) olarak belirlenmiştir. DSÖ virüsün neden olduğu hastalığı tanımlamak için COVID-19 terimini kullanmaktadır. 31 Ocak 2020'de COVID-19, DSÖ tarafından küresel bir sağlık acil durumu ilan edilmiştir. 11 Mart 2020 tarihinde ise virüs pandemi, yani küresel salgın hastalık olarak ilan edilmiştir. COVID-19 yaygın klinik özellikleri arasında ateş, öksürük, boğaz ağrısı, baş ağrısı, yorgunluk, kas ağrısı ve nefes darlığı vardır (Singhal 2020).

COVID-19 başta insan sağlığı olmak üzere ekonomi, eğitim, spor ve bireylerin günlük yaşamlarını ciddi oranda etkilemiştir. Bu nedenle COVID-19'un hızlı ve zamanında teşhisi, pandeminin yayılma hızını ve bulaş riskini azaltmada çok kritik bir faktördür. COVID-19 teşhisi için kullanılan en yaygın test tekniği, gerçek zamanlı tersine test tekniği olan RT-PCR 'dir. Ancak, RT-PCR test tesisi, COVID-19 salgınının olduğu alanların çoğunda yetersizdir. Ayrıca RT-PCR testi, karmaşık manuel prosedürle zaman alıcı ve yorucu olarak kabul edilmektedir. COVID-19 dahil olmak üzere göğüs akciğer hastalıklarını erken tespit ve teşhis etmek için kullanılan ikinci yöntem ise standart tarama araçları olan, göğüs röntgeni (CXR-Chest X-Ray) ve bilgisayarlı tomografi (BT) (CT-Computed Tomography) gibi radyolojik görüntüleme teknikleridir (Ozturk et al. 2020). Bu geleneksel tıbbi görüntüleme yöntemleri, hastalığın hızlı yayılmasının kontrolünde hayati bir rol oynamaktadır. Radyoloji görüntüleme tekniklerinin avantajı, bazı

durumlarda tarama negatif olsa dahi hastalığın başlangıç evrelerinde tespit edilebilmesidir. Ayrıca, başlangıçta RT-PCR testi sonuçları negatif olan hastaların kötüleşen semptomlar verdiği durumlarda X-Ray görüntülemenin faydalı olabileceği de önerilmektedir. Dezavantajları ise röntgen analizinin bir radyoloji uzmanı gerektirmesi ve manuel olarak okunmasının zaman alıcı olmasıdır. Bu nedenle sağlık uzmanlarına zaman kazandırmak için taramalarda anormallik olup olmadığını tespit edecek otomatik bir analiz sisteminin geliştirilmesi gerekmektedir (Ouchicha et al. 2020). Böylece, Amerika'nın beyaz sarayı 16 Mart 2020'de uzmanları ve araştırmacıları yeni COVID-19 salgınıyla savaşmak için yapay zekâ (AI) tekniklerini kullanmaya teşvik ettiğini duyurmuştur (Alimadadi et al. 2020).

COVID-19 ile mücadelede dijital teknolojilerle desteklenen iki önemli bilimsel topluluk tespit edilebilir. Bu konudaki ana dijital çaba, BT taramalarından ve X-ray görüntülerinden otomatik COVID-19 tespiti şeklinde Yapay Zekâ (AI-Artificial Intelligence) topluluğundan geliyor. Dijital teknolojilerin desteklediği bu tür ikinci topluluk, çeşitli hareketlilik ve sosyal mesafe senaryoları altında virüsün yayılmasını tahmin etmek için karmaşık virüs yayılımı ve bulaşma modelleri geliştiren matematikçiler ve epidemiyologlardır (Shuja et al. 2020).

Hastalığın çok hızlı yayılması ve birçok ülkede ölüm oranlarının artması etkili bir tedavi yönteminin geliştirilmesi gerektiğini ortaya koymaktadır. Bu nedenle erken teşhis için, karantina ve takip dâhil olmak üzere hastalığın kontrolü zorunlu hale gelmektedir. Bu noktada, derin öğrenme teknikleri, yukarıdaki perspektiflere katkıda bulunabilir.

Popüler bir araştırma alanı olan derin öğrenme, manuel özellik çıkarımına ihtiyaç duymadan girdi verilerini kullanarak istenilen sonuçlara ulaşmak için uçtan uca modellerin oluşturulmasını sağlar (Ozturk et al. 2020). Derin öğrenme ve makine öğrenimi teknikleri; verilerden kalıpları çıkarmak, analiz etmek ve tanımak için birçok uygulamada kullanılmaktadır (Apostolopoulos et al. 2020). Son zamanlarda özellikle tıp alanında otomatik tanı için makine öğrenimi yöntemlerinin uygulanması, uzmanlar için yardımcı bir araç haline gelerek popülerlik kazanmıştır (Litjens et al. 2017; Shen et al. 2017). Derin öğrenme (DL), beyin anormalliklerinin sınıflandırılması, cilt kanseri sınıflandırması, meme kanseri tespiti, göğüs röntgeni görüntülerinden pnömoni tespiti,

patojenik bakterilerin sınıflandırılması ve biyomedikal görüntü segmentasyonu gibi tıbbi veri setleriyle uğraşmak ve başarılı sonuçlar elde etmek için kullanılan en yaygın yöntem olmuştur.

COVID-19 salgınının hızla yükselişi bu alanda uzmanlık ihtiyacını zorunlu hale getirmiştir. Bu, AI tekniklerine dayalı otomatik algılama sistemlerinin geliştirilmesine olan ilgiyi artırmıştır. Sınırlı sayıda radyolog nedeniyle basit, doğru ve hızlı AI modelleri bu sorunun üstesinden gelmek ve hastalara zamanında yardım sağlamak için yardımcı olabilir. Radyologlar bu alandaki engin deneyimleri nedeniyle kilit bir rol oynasalar da, radyolojideki yapay zekâ teknolojileri doğru tanı elde etmek için yardımcı olabilir (Caobelli 2020). Ek olarak, AI yaklaşımları, yetersiz sayıda mevcut RT-PCR test kiti, test maliyetleri ve test sonuçlarının bekleme süresi gibi dezavantajların ortadan kaldırılmasında faydalı olabilir.

1.1. Tezin Amacı

Bu çalışmada derin öğrenme yöntemleri ile birlikte COVID-19 hastalığının tespiti amaçlanmıştır. Literatürde COVID-19 pozitifini COVID-19 negatifinden ayırmak yaygındır. Ayrıca diğer akciğer hastalık türlerini COVID-19 pozitifinden ayırt etmek de çok önemlidir. Bu nedenle bu çalışmada hem ikili sınıflandırma (COVID-19, Normal, COVID-19, Pnömoni) hem de çoklu sınıflandırma (COVID-19, Pnömoni ve Normal) tercih edilmiştir. Pnömoni, bakterilerin, virüslerin veya mantarların neden olabileceği bir akciğer enfeksiyonudur. Bu çalışmada, etkili bir model oluşturmak için X-Ray görüntüleri ile birlikte yaygın olarak kullanılan derin öğrenme yaklaşımları kullanılmıştır. Önceden eğitilmiş olan bu yaklaşımlardan ResNet-34, ResNet-50, ResNet-101, ResNet-152, VGG-19 ve DenseNet201 yöntemleri seçilmiştir. Bu yöntemler ile birlikte farklı 3 senaryo uygulanmıştır. İlk olarak üç farklı durum (COVID-19, Pnömoni ve Normal) içerisinde COVID-19 olan hastaların sınıflandırılması gerçekleştirilmiştir. İkinci olarak 2 farklı durum (COVID-19, Normal) içerisinde COVID-19 olan hastaların sınıflandırılması gerçekleştirilmiştir. Üçünü olarak 2 farklı durum (COVID-19, Pnömoni) içerisinde COVID-19 olan hastaların sınıflandırılması gerçekleştirilmiştir. Sınıflandırma başarımını artırmak için bu modellerin sonuçları karar seviyesinde maksimum oylama ile birleştirilmiştir. Bu modeller kullanılarak yeni 2 model

1. GİRİŞ

oluşturulmuştur. İlk model ENSEMBLE-1 ResNet-152, VGG-19, DenseNet201 modellerinden, ikinci model ENSEMBLE-2 ise ResNet-50, VGG-19, DenseNet201 modellerinden oluşmaktadır. Önceden eğitilmiş ResNet34-50-101-152 modelleri arasından en iyi performansı gösteren ResNet-50 ve ResNet-152 bu modeller için kullanılmıştır. Bu topluluk modellerinde Max, Mode, Sum, Mean ve Product gibi temel füzyon fonksiyonları test edilmiştir.

1.2. Tezin Kapsamı

Tez çalışması, beş farklı ana bölüm başlığı altında yazılmıştır.

Giriş bölümünde COVID-19 hastalığı hakkında bilgi verilmiştir. COVID-19 hastalığının belirtileri, bulaş yolları ve test teknikleri hakkında bilgi verilmiştir.

Kaynak özetleri bölümünde ise COVID-19 hastalığının tespiti için kullanılan yapay zekâ yöntemleri ile ilgili literatürde yapılan çalışmalar hakkında bilgiler verilmiştir. Tez çalışmasında, derin öğrenme teknikleri ile COVID-19 tespiti yapıldığından daha çok derin öğrenme teknikleri ve transfer öğrenme yöntemlerini kullanan çalışmalar taranmıştır. Bu sebeple kaynak özetlerinde tez konusu ile ilgili çalışmaların yer alması uygun bulunmuştur.

Materyal ve yöntem bölümünde COVID-19 teşhisi için kullanılan sistemin veri seti ve mimarisi detaylı olarak açıklanmıştır. Kullanılan veri seti içeriği detaylı olarak açıklanmıştır. Derin öğrenme, transfer öğrenme ve topluluk öğrenim hakkında bilgi verilmiştir. Çalışmada kullanılan derin öğrenme teknikleri detaylı bir şekilde anlatılmıştır.

Araştırma bulguları ve tartışma bölümünde ise geliştirilen yönteme ait uygulama aşamaları verilerek, deneysel sonuç analizleri sunulmuştur. Önerilen yöntemin avantajları açıklanmış, sonuçlarının şematik ve tablo olarak gösterimi yapılmıştır.

Son olarak sonuç ve öneriler bölümünde ise tez çalışmasında elde edilen sonuçlar değerlendirilmeye alınmıştır.

2. KAYNAK ÖZETLERİ

Literatürdeki X-Ray ve BT çalışmaları incelendiğinde el yapımı ve son zamanlarda evrişimli sinir ağı (CNN) tabanlı yöntemlerin kullanıldığı görülmektedir. CNN, çeşitli hastalıkların bilgisayar destekli tespiti ve teşhisi alanında umut verici sonuçlar göstermiştir. CNN, sıfırdan eğitim için büyük miktarda veri gerektirir. Tıbbi görüntüler söz konusu olduğunda, çok sayıda etiketli görüntü elde etmek zordur. Bu gibi durumlarda, önceden eğitilmiş CNN'ler, çok sayıda olan doğal ImageNet gibi resimler kullanılabilir. Önceden eğitilmiş CNN, COVID-19'u tahmin etmede başarılı bulunmuştur. Röntgen görüntülerinin hızlı bir şekilde yorumlanması ihtiyacından motive olan birçok bilim insanı, göğüs röntgeni görüntülemesinden COVID-19 bulaşmış vakaları tespit etmek için özellikle evrişimli sinir ağları olmak üzere derin öğrenme modelleri önermiştir.

Kırbaş et al. (2020), Otomatik Regresif Entegre Hareketli Ortalama (ARIMA), Doğrusal Olmayan Otoregresyon Sinir Ağı (NARNN) ve Uzun Kısa Süreli Bellek (LSTM) olmak üzere üç yaklaşım kullanarak birkaç Avrupa ülkesinde yeni COVID-19 vakalarının tahminini tartışmıştır.

CNN tekniklerinin kullanılmaya başlanmasıyla el yapımı yöntemlere olan ilgi azalmaya başlamıştır. CNN, görüntülerden öznitelikleri otomatik olarak çıkaran ve sınıflandıran bir derin öğrenme mimarisidir.

X-Ray görüntülerini kullanarak DarkNet modeline dayalı olan DarkCovidNet adında yeni bir model sunan Ozturk et al. (2020), COVID-19 tespiti için ikili sınıflandırma (COVID-19 ve Normal) ve çok sınıflı sınıflandırma (COVID-19, Pnömoni ve Normal) üzerinde çalışmıştır. Veri seti olarak 125 COVID-19, 500 pnömoni ve 500 normal akciğer röntgeni görüntülerini içeren halka açık bir veri seti kullanılmıştır. Bu model, her katmanında farklı filtreleme yapılan 17 evrişim katmanından oluşmaktadır. DarkCovidNet, çok sınıflı durumlar için %87,02 ve ikili sınıflar için %98,08 doğruluk elde etmiştir.

Ouchicha et al. (2020) COVID-19 vakalarını teşhis etmek için CVDNet adlı bir model önermiştir. Bu model, çeşitli çekirdek boyutlarına sahip iki paralel katman kullanarak göğüs röntgeni görüntülerinin yerel ve küresel özelliklerini kullanan, sinir ağına odaklanan bir modeldir. Veri seti olarak 219 COVID-19, 1345 pnömoni ve 1341 normal akciğer röntgeni görüntülerini içeren halka açık bir veri seti kullanılmıştır. Bu veri setinin %20'si test verisi olarak ayrılmıştır. Önerilen CVDNet, COVID-19 vakalarını tespit etmek için ikili sınıflandırmada %97,20 ve çoklu sınıflandırmada %96,69 doğruluk elde etmiştir.

BT görüntüleri ile CNN mimarisini kullanan Ardakani et al. (2020), rutin klinik uygulamada COVID-19'u yönetmek için derin öğrenme tekniğini uygulamıştır. COVID-19 hastalarını COVID-19 olmayan hastalardan ayırmak için 10 ünlü evrişimsel sinir ağını kullanıp ve bu ünlü ağların özelliklerini özetlemiştir.

Ayrıca el yapımı tekniklerle birlikte CNN modelleri de kullanılmıştır.

Abraham et al. (2020), COVID-19'un X-Ray görüntülerinden hızlı bir şekilde taranması için korelasyona ve BayesNet sınıflandırıcısına dayalı özellik seçimi yaklaşımını kullanarak çoklu CNN'den alınan özelliklerin birleştirilmesini kullanan bir yöntem önermiştir.

Hassantabar et al. (2020), fraktal öznitelikler üzerinde MLP ve CXR üzerinde CNN kullanarak algılama ve tanılama gerçekleştirmiştir. CXR'den fraktal öznitelikler çıkarmak için ilk önce görüntüler 1 boyutlu vektörlere yeniden şekillendirilip, kovaryans matrisi hesaplanıp ve fraktal özniteliklerin çıkarılması için öz değer ve öz vektör kullanılmıştır. CNN mimarisi %93,2 gibi daha yüksek bir doğruluğa ulaşmıştır.

Ismael and Şengür (2021), göğüs röntgeni görüntülerinden özellik çıkarımı için önceden eğitilmiş ResNet-18, ResNet-50, ResNet-101, VGG-16 ve VGG-19 modellerini kullanmıştır. COVID-19 teşhisi için kullanılan veri setinde, 80 adet COVID-19 ve 200 adet normal akciğer röntgeni görüntüsü bulunmaktadır. En yüksek doğruluk oranı ResNet-50 modelinden çıkarılan derin özellikleri kullanarak doğrusal çekirdek fonksiyonlu DVM sınıflandırıcısından %94,7 doğruluk elde etmişlerdir.

CNN, sıfırdan eğitim için büyük miktarda veri gerektirir. Tıbbi görüntüler söz konusu olduğunda, çok sayıda etiketli görüntü elde etmek zordur. Bu sorunu gidermek için transfer öğrenme yöntemleri de kullanılmıştır.

Xu et al. (2020), X-Ray görüntülerini kullanarak, tıbbi görüntü dengesizliği problemini gidermek için transfer öğrenme yöntemi ile GoogleNet, ResNet-101, Xception ve MobileNetv2 performanslarını karşılaştırmışlardır.

X-Ray görüntüleri ile Sahinbas and Catak (2020), COVID-19 teşhisi için VGG16, VGG19, ResNet, DenseNet ve InceptionV3 modelleri üzerinde çalışmıştır.

Tsiknakis et al. (2020), çalışmalarında COVID-19 teşhisi için Inception-V3 önermiştir. COVID-19 veri kümesini sınırlı sayıda veri içermesi nedeniyle transfer öğrenimi ile birleştirilmiştir. 122 COVID-19 akciğer röntgeni görüntüsü, 150 bakteriyel pnömoni akciğer röntgeni görüntüsü, 150 viral pnömoni akciğer röntgeni görüntüsü ve 150 normal akciğer röntgeni görüntüsü içeren çalışmada ikili sınıflandırma için %100 ve dörtlü sınıflandırma için %76 doğruluk oranı elde edilmiştir.

Horry et al. (2020), COVID-19 vakalarının tespiti için önceden eğitilmiş dört farklı derin öğrenme modelinin kullanıldığı bir şema sunmuştur. Modeller arasında VGG16 ve VGG19 ile yüksek performans elde edilmiştir. VGG19 kullanarak %81 doğruluk oranı elde edilmiştir.

Das et al. (2020), X-Ray görüntüleri ile değiştirilmiş bir Inception modeli (Xception) kullanarak %97,40 doğruluk elde etmişlerdir.

Hemdan et al. (2020), X-Ray görüntüleri ile birlikte COVID-19'u tespit etmek için VGG19 ve Google MobileNet gibi yedi farklı derin evrişimli sinir ağı modeli içeren bir COVIDX-Net modeli önermiştir. 25 COVID-19 ve 50 normal akciğer röntgeni görüntüsü kullanarak %90 doğruluk elde etmişlerdir.

2. KAYNAK ÖZETLERİ

Dey et al. (2021), değiştirilmiş bir VGGNet19 kullanarak göğüs röntgeninden elde edilen özellikleri hesaplayarak pnömونيي tespit etmek için yeni bir yöntem geliştirmiştir. Bu yöntem %97,94 sınıflandırma doğruluğu elde etmiştir.

BT görüntülerini kullanan Wang et al. (2020), geliştirilen değiştirilmiş Inception (M-Inception) derin modeli ile ikili sınıf üzerinde %82,9 doğruluk elde etmişlerdir.

Tuncer et al. (2020), ResExLBP adlı bir artık örnek yerel ikili model kullanarak bir COVID-19 sınıflandırma yöntemi denemiştir. Ancak çalışmada sınırlı sayıda pozitif ve negatif etiketli veri kullanılmıştır.

Narin et al. (2021), Cohen et al. (2020) tarafından paylaşılan 50 açık erişimli COVID-19 göğüs röntgeni görüntüsünü ve kaggle deposundan alınan 50 normal görüntüyü kullanarak üç farklı CNN modeli (ResNet50, InceptionV3 ve InceptionResNetV2) kullanmıştır. Bu modelden %98'lik bir COVID-19 saptama doğruluğu elde etmiştir.

3. MATERYAL ve YÖNTEM

Bu bölümde, COVID-19 teşhisi için kullanılan sistemin veri seti ve mimarisi detaylı olarak açıklanmıştır.

3.1. Dijital X-ray Görüntü Veri Seti

Bu çalışmada önerilen yöntemin sınıflandırma başarısını doğrulamak için, veri seti halka açık iki veri setinin birleşimi ile oluşturulmuştur (Ozturk et al. 2020).

3.1.1. COVID-19 veri seti

Çeşitli açık erişim kaynaklarından gelen görüntüleri kullanan, Cohen et al. (2020) tarafından yayınlanan, COVID-19 X-ray görüntü veri seti kullanılmıştır. Yazarlar, COVID-19 vakalarının çeşitli özgün kaynaklarından (Radyoloji Derneği (RSNA), Radiopaedia vb.) radyoloji görüntülerini araştırma amacıyla derlemiştir ve COVID-19 ile ilgili çalışmaların çoğu bu kaynaktan görüntüler kullanmaktadır.

Bu görüntüler, uzman araştırmacıların COVID-19 krizini tahmin etmeye ve anlamaya yönelik derin öğrenme yaklaşımlarına dayalı yapay zekâ geliştirmelerine yardımcı olmak için herkese açıktır. Veri seti, farklı bölgelerden araştırmacılar tarafından paylaşılan verilerle sürekli güncellenmektedir.

Bu veri setinden 125 COVID-19 görüntüsü alınmıştır.

3.1.2. ChestX-ray8

Wang et al. (2017) tarafından sağlanan ChestX-ray8, sekiz yaygın farklı akciğer hastalığının teşhisi için mevcut olan en sık ve yaygın olarak erişilebilir tıbbi görüntüleme veri setidir. Bu görüntüler, uzman araştırmacıların COVID-19 ve diğer göğüs hastalıklarını tespit etmeye ve anlamaya yönelik derin öğrenme yaklaşımlarına dayalı yapay zekâ geliştirmelerine yardımcı olmak için herkese açıktır.

3. MATERYAL ve YÖNTEM


ChestX-ray8 veri seti pnömoni ve normal göğüs görüntüleri için kullanılmıştır. Bu veri setinden 500 normal, 500 pnömoni görüntüsü alınmıştır.

Bu iki kaynaktan toplam 1.125 resim toplanmıştır. Veri seti 500 normal, 500 pnömoni ve 125 COVID-19 vakasından oluşmaktadır. X-Ray görüntülerinin %80'i eğitim ve %20'si doğrulama için kullanılmıştır. Çizelge 3.1. hazırlanan veri setinin özetini göstermektedir.

Çizelge 3.1. Veri seti özeti

	Kategori	Toplam
1	Normal	500
2	Pnömoni	500
3	COVID-19	125
4	Total	1.125

Şekil 3.1. hazırlanan veri setinden bazı göğüs röntgeni görüntü örneklerini göstermektedir.



Şekil 3.1. Hazırlanan veri setinden göğüs röntgeni görüntüleri örnekleri (Üst: Normal, Orta: COVID-19, Alt: Pnömoni).

3.2. Derin Öğrenme

Derin öğrenme (DL), beynin yapısından ilham alan makine öğrenimi alanının bir alt dalıdır. Son yıllarda kullanılan derin öğrenme teknikleri birçok alanda olduğu gibi medikal görüntü işleme alanında da etkileyici bir performans sergilemeye devam etmektedir. Derin öğrenme, tıbbi verilerin sınıflandırılması, segmentasyonu ve lezyon tespiti gibi tıbbi veri setleriyle uğraşmak için kullanılan en yaygın yöntemdir. Çeşitli DL mimarileri yardımıyla MRI, BT ve X-Ray gibi tıbbi görüntüleme teknikleri ile görüntü ve sinyal verilerinin analizi elde edilmiştir. Bu analizler sonucunda beyin tümörü, cilt kanseri ve meme kanseri gibi hastalıkların tespiti ve teşhisine yönelik çalışmalarda kolaylık sağlanmaktadır.

Derin öğrenmenin kendine özgü mimari yapıları bulunur. Bu yapılara tekrarlayan sinir ağları (RNN'ler), derin oto-kodlayıcılar, derin inanç ağları (DBN'ler), konvolüsyonel sinir ağları (CNN'ler) örnek verilebilir. Bu mimarilerden özellikle CNN görüntü ve ses işleme uygulamalarında kayda değer başarılar elde etmiştir. Bu yüzden literatürde CNN kullanılarak biyomedikal alanda görüntü işleme ile yapılan çalışmalara oldukça sık rastlanmaktadır.

3.2.1. Derin inanç ağları

Derin bir inanç ağı (DBN), sonuç üretmek için denetimsiz bir makine öğrenme modeli kullanan karmaşık bir tür üretken sinir ağıdır. Gizli değişkenlerin katmanlarından oluşan olasılıksal bir modeldir. Derin inanç ağları mimarileri genel olarak görüntü tanıma ve üretme konularında uygulanmaktadır.

3.2.2. Derin nöron ağlar

Ağırlıkları tamamen bağlı olan ve çoğu zaman denetimsiz veya denetimli bir ön eğitim tekniği kullanılarak başlatılan birçok gizli katmana sahip bir mimaridir.

3.2.3. Derin oto-kodlayıcılar

Diabola ağı olarak adlandırılan Oto-Kodlayıcılar (Auto Encoders-AE) denetimsiz öğrenme için kullanılan özel bir yapay sinir ağı mimarisidir (Liou et al. 2014). AE, bir veri seti üzerinde boyut indirgemeyi amaçlar. AE, kabaca girdi verisinin indirgenmiş yapısından en iyi özelliklerin öğrenilmesi hedefleyen bir ileri beslemeli sinir ağıdır (Deng et al. 2014).

3.2.4. Boltzmann makineleri

Boltzmann Makineleri, stokastik tekrarlayan sinir ağı modelidir. Boltzmann makineleri Hopfield ağlarının stokastik üretken karşılığı olarak görülür. Bu yapı, iç temsilleri öğrenebilen ilk sinir ağlarından biridir.

3.2.5. Sınırlı boltzmann makineleri

Sınırlı Boltzmann Makineleri (RBM) girdi veri seti üzerinde olasılık dağılımını öğrenebilen üretken bir rastgele yapay sinir ağıdır. RBM, Boltzmann makinelerinin bir türüdür. Görünür ve gizli olmak üzere aralarında simetrik bağlantı bulunan iki parçalı graflardan oluşur.

3.2.6. Tekrarlayan sinir ağları

Tekrarlayan sinir ağları (RNN), düğümler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu yapay sinir ağı sınıfıdır. RNN mimarisinin yinelenen olarak adlandırılmasının sebebi, bir dizinin her ögesi için aynı görevi önceki çıktılara bağlı olarak yerine getirmesidir. Denetimsiz öğrenme kullanımında, önceki veri örneklerini kullanarak gelecekteki veri dizisini tahmin etmek için RNN kullanılır ve öğrenme için ilave sınıf bilgisi kullanılmaz. RNN, ses veya metin gibi verilerin modellenmesi için çok etkilidir. Fakat uzun ardışık yapıları yakalamak ve eğitmek ise zordur (Deng et al. 2014).

3.2.7. Konvolüsyonel sinir ağları

Bir evrişimli sinir ağı (CNN), görüntü tanıma problemlerinde kullanılan bir derin sinir ağları sınıfıdır. CNN'nin nasıl çalıştığına gelince, girdi olarak verilen görüntülerin bilgisayarlar tarafından tanınması ve işlenebilecek bir formata dönüştürülmesi gerekir. Bu nedenle görüntüler önce matris formatına dönüştürülür. Sistem, görüntülerdeki ve dolayısıyla matrislerdeki farklılıklara göre hangi görüntünün hangi etikete ait olduğunu belirler. Eğitim aşamasında bu farklılıkların etiket üzerindeki etkilerini öğrenir ve ardından bunları kullanarak yeni görüntüler için tahminlerde bulunur.

Standart bir RGB görüntü kırmızı, yeşil ve mavi olmak üzere üç renk kanalından meydana gelmektedir. Görüntü, her bir renk kanalında $n \times n$ boyutunda piksel değerlerini belirten matrisler şeklinde ifade edilmektedir. Görüntünün bu şekilde ifade edilmesi evrişimsel sinir ağlarının verimli bir şekilde kullanılabileceğini göstermektedir. CNN'lerin diğer derin öğrenme mimarilerine kıyasla avantajı, ilgili özellikleri herhangi bir insan gözetimi olmaksızın otomatik olarak tanımlamasıdır.

CNN, bu işlemleri etkin bir şekilde gerçekleştirmek için evrişimsel katman, havuzlama katmanı ve tam bağlantılı katman olmak üzere üç ana katmandan oluşur. Bu katmanların her biri farklılaştırılabilir bir işlevle bir aktivasyon hacmini diğerine dönüştürür. Bu bölümde, CNN mimarisini oluşturmak için en sık kullanılan katmanlardan bazıları açıklanacaktır.

Evrişim Katmanı

Evrişim katmanı, CNN algoritmalarında görüntüyü ele alan ilk katmandır. Girdinin özelliklerini algılamaktan sorumludur. Bu katmanda, görüntüdeki düşük ve yüksek seviyeli özellikleri çıkarmak için girdiye bazı filtreler uygulanır. Bu filtreler genellikle çok boyutludur ve piksel değerleri içerir. Filtreler 2x2, 3x3, 5x5 gibi farklı boyutlarda olabilir. Filtreler, bir önceki katmandan gelen görüntülere konvolüsyon işlemini uygulayarak çıkış verisini oluştururlar. Bu konvolüsyon işlemi sonucu özellik haritası oluşur. Evrişim işlemi şu şekilde verilir:

$$F(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n) \quad (3.1)$$

Relu Katmanı

Bir görüntüde doğrusal olmayan bölgelerin (kenar, piksel) doğrultulmasında kullanılan katmandır. Bu katman negatif görüntü değerlerini sıfıra eşitler ve pozitif görüntü değerlerini doğrusal olarak değerlendirir (Agarap 2018). Matematiksel gösterimi şu şekildedir:

$$R(x) = \max(0, x) \quad (3.2)$$

Havuzlama Katmanı

Evrişim katmanından sonraki ikinci katman havuzlama katmanıdır. Temel amacı, sonraki konvolüsyon katmanı için giriş boyutunu azaltmaktır. Havuzlama katmanı,

genellikle karşılık gelen matematiksel hesaplamayı uygulayarak özellik haritalarının ve ağ parametrelerinin sayısını azaltmak için oluşturulan özellik haritalarına uygulanır. İlk basamakta gerçekleştirilen konvolüsyon işlemi gibi, havuzlama katmanında da belli filtreler tanımlanır. Bu filtreler görüntü üzerinde belli bir adım atma değerine göre gezdirilerek görüntüdeki piksellerin maksimum değerlerini (maksimum havuzlama) veya değerlerin ortalamasını (ortalama havuzlama) alarak işlem yapılır. Genellikle maksimum havuzlama, daha iyi performans gösterdiği için tercih edilir. Havuzlama işlemi, konvolüsyon katmanı sonucu oluşan filtre adedince görüntülerin hepsi için gerçekleştirilir.

Tam Bağlantılı Katman

Bu katman, CNN'nin son ve en önemli katmanıdır. Bu katman, çok katmanlı bir algılayıcı gibi işlev görür. Rectified linear unit (ReLU) aktivasyon fonksiyonu, tam bağlantılı katmanda yaygın olarak kullanılırken, softmax aktivasyon fonksiyonu, tam bağlantılı katmanın son katmanındaki çıktı görüntülerini tahmin etmek için kullanılır.

Dropout Katmanı

Derin öğrenme katmanlarında öğrenimi gerçekleştirilmiş bir ağda aşırı öğrenmeyi yani ezberlemeyi ortadan kaldırmak için kullanılan bir katmandır. Ağın ezber yapmaması için bu katman fazla bağlantıları silerek ağın tekrarlayan ağ öğrenimini engelleyerek onun ezber yapmasına engel olmaktadır (Baldi et al. 2013).

Normalizasyon Katmanı

Derin yapay sinir ağında ağın normalize edilmesi ağın performansını etkilemektedir. Bu katman, diğer katmanlardan elde edilen verileri düzenli hale getirmek için kullanılmaktadır.

Sınıflandırma Katmanı

Bu katman tam bağlantılı katmandan sonra gelir. Derin öğrenme mimarilerinin bu katmanında sınıflandırma işlemi yapılmaktadır. Bu katmanın çıkış değeri, sınıflandırması yapılacak nesne sayısına eşittir. Bu katmanda farklı sınıflandırıcılar kullanılmaktadır. Çoğunlukla başarısından dolayı softmax sınıflandırıcı tercih edilmektedir.

3.3. Transfer Öğrenimi

Bir CNN tarafından verilen verilerden çıkarılan bilginin, bir CNN'yi sıfırdan eğitmek için genellikle daha küçük bir popülasyona sahip olan yeni verileri içeren farklı ancak ilgili bir görevi çözmek için aktarıldığı bir stratejidir. Bu yöntem, çok fazla eğitim verisi gerektirmediğinden tıbbi uygulamalar için özellikle yararlı olabilir. Tıbbi verilerin analizinde, araştırmacıların karşılaştığı en büyük zorluklardan biri, veri setlerinin sınırlı sayıda olmasıdır. Derin öğrenme modelleri genellikle çok fazla veriye ihtiyaç duymaktadır. Bu verilerin uzmanlar tarafından etiketlenmesi hem zaman alıcı hem de maliyetlidir. Transfer öğrenme yöntemi, daha az veri ile veri eğitimine olanak sağlar ve daha az hesaplama maliyeti gerektirir.

Model Uyarlama İnce Ayar (Finetuning)

Derin öğrenme modellerinin eğitimi, (ResNet-50, InceptionResNet-v2, vb.) büyük miktarda kaynak ve zaman gerektirir. Bu ağlar, ImageNet üzerinde nispeten mükemmel performans elde ederken, onları bir CPU üzerinde eğitmek boşuna bir alıştırmadır. Bu CNN'ler, karmaşık veri kümelerinde iyi sonuçlar elde etmek için genellikle birkaç hafta veya daha fazla Grafik İşlem Birimi (GPU) dizileri kullanılarak eğitilir. Çoğu derin CNN'de, ilk birkaç evrişim katmanı, düşük seviyeli özellikleri (kenarlar, eğriler) öğrenir ve ilerleme ile ağ aracılığıyla, devam eden görevle ilişkili daha fazla orta/yüksek seviye özellik veya kalıp öğrenir. İnce ayarda amaç, bu eğitilmiş düşük seviyeli öznitelikleri tutmak veya dondurmak ve sadece yeni görüntü sınıflandırma problemi için gerekli olan yüksek seviyeli öznitelikleri eğitmektir (Punn et al. 2021).

Bu çalışmada, COVID-19 sınıflandırması için derin CNN tabanlı ResNet-34, ResNet-50, ResNet-101, ResNet-152, VGG-19 ve DenseNet201 modelleri kullanılmıştır. Ayrıca yetersiz veri ve eğitim süresi problemlerini gidermek için ImageNet verileri

kullanılarak gerçekleştirilen finetuning transfer öğrenimi yöntemi uygulanmıştır. Kullanılan transfer öğrenimi modelleri sırasıyla aşağıda açıklanmıştır.

3.3.1. Residual sinir ağı (ResNet) modeli


CNN'nin geliştirilmiş bir versiyonudur. ResNet, bir sorunu çözmek için katmanlar arasına kısa yollar ekler. Bu sayede ağ derinleştikçe ve karmaşıklıklaştıkça oluşan bozulmaları engeller. Ayrıca ResNet modelinde eğitimi daha hızlı hale getirmek için darboğaz blokları kullanılmaktadır. ResNet, bir sorunu çözmek için katmanlar arasında bağlantılar ekler. Bu sayede derinleşen ve karmaşık ağda meydana gelen aksamaların önüne geçer. Ayrıca darboğaz blokları ile eğitim daha hızlı yapılmaya çalışılmaktadır.

ResNet-34

34 katmana sahip olduğu için ResNet-34 olarak adlandırılmıştır. 33 evrişim katmanı, 3 x 3 boyutunda bir maksimum havuz katmanı ve ardından tamamen bağlı bir katman içerir.

ResNet-50

50 katmana sahip olduğu için ResNet-50 olarak adlandırılmıştır. ResNet-50, ImageNet veri kümesinde eğitilmiş 50 katmanlı bir ağıdır. ImageNet, görüntü tanıma yarışmaları için oluşturulmuş 20.000'den fazla kategoriye ait 14 milyondan fazla görüntü içeren bir görüntü veri tabanıdır. Bu çalışmada kullanılan önceden eğitilmiş ResNet-50 modelinin blok diyagramı Şekil 3.2.'de gösterilmektedir.




Şekil 3.2. ResNet-50 mimarisinin şematik gösterimi (Talo 2019)

ResNet-101-152

Daha fazla 3 katmanlı blok kullanarak 101 katmanlı ve 152 katmanlı ResNet’ler oluşturulur. 50/101/152-katmanlı ResNet’ler, 34 katmanlı olanlardan önemli ölçüde daha doğrudur. Artık ağlar sayesinde bozulma problemlerinin önüne geçilerek önemli ölçüde artan derinlikten önemli doğruluk kazanımları elde edilmiştir.

3.3.2. VGG blokları


VGG (Visual Geometry Group) ağının (VGG-19) mimarisi, eğitilebilir 19 ağırlıklı katman içerir (Simonyan and Zisserman 2014). VGG ağının blok yapısı, evrişim ve maksimum havuzlama işlemlerinin bir kombinasyonundan oluşur. VGG blokları, sırasıyla 64 ve 128 filtreli iki evrişim katmanı ile başlar. Daha sonra üçüncü katman 256 filtre içerir. VGG-19, ImageNet ağırlıkları ile başlatılmıştır ve transfer öğrenme modeli olarak tercih edilmiştir. Şekil 3.3. VGG-19’un ince ayarlı mimarisinin gösterimidir.



Şekil 3.3. COVID-19 sınıflandırması için VGG-19'un ince ayarlı mimarisi

3.3.3. DenseNet (densely connected convolutional networks) modeli

Huang et al. (2017) tarafından önerilen derin bir CNN'dir. DenseNet'te her katman diğer tüm katmanlara ileri beslemeli bir şekilde bağlanır, yani DenseNet toplamda $n(n+1)/2$ bağlantıya sahiptir. Her katman için, önceki tüm katmanların özellik haritaları girdi olarak kullanılır ve kendi özellik haritaları, sonraki tüm katmanlara girdi olarak kullanılır. Geleneksel CNN ile karşılaştırıldığında DenseNet, daha az sayıda veya eşdeğer sayıda parametre gerektirir. Bunun nedeni DenseNet'te özellik haritaları gereksiz yere öğrenilmez bu da önemli bir avantaja dönüşür. Böyle bir mimarinin toplamda düşük sayıda parametreyi korurken özellikleri yeniden kullanma yeteneği vardır. DenseNet mimarisinin şematik gösterimi Şekil 3.4.'de gösterildiği gibidir.



Şekil 3.4. DenseNet mimarisinin şematik gösterimi (Huang et al. 2017)

3.4. Çapraz Doğrulama

Çapraz doğrulama, makine öğrenmesi modelinin görmediği örnekler üzerindeki performansını mümkün olduğunca objektif ve doğru bir şekilde değerlendirmek için kullanılan istatistiksel bir yeniden örnekleme yöntemidir. Aşırı öğrenmeyi (overfitting) önlemek için kullanılan yöntemlerden biridir. Çapraz doğrulamada amaç, eğitim veri setinden doğrulama kümeleri olarak bilinen örnek gözlem bölümlerini oluşturmaktır. Bir modeli eğitim verilerine yerleştirdikten sonra, performansı, her yeni doğrulama kümesine karşı ölçülür ve daha sonra, yeni gözlemleri öngörmek istenildiğinde modelin nasıl performans göstereceğine ilişkin daha iyi bir değerlendirme elde edilir. Yapılacak bölüm sayısı, örnek veri kümesindeki gözlem sayısına ve önyargı varyansı dengelemesine ilişkin kararın, daha fazla bölünmenin daha küçük bir yanlılığa yol açmasına ve daha fazla varyansa bağlı olarak değişmesine bağlıdır.

3.4.1. K katlamalı çapraz doğrulama

K katlamalı çapraz doğrulama, sınıflandırma modellerinin değerlendirilmesi ve modelin eğitilmesi için veri setini parçalara ayırma yöntemlerinden biridir. Bu yöntem, verileri yaklaşık olarak aynı uzunlukta k alt kümeye böler. Böylece yaklaşık olarak aynı uzunluktaki alt veri kümelerinden bir k-kat oluşturulur. Bu çalışmada 5 katlı çapraz doğrulama prosedürü ile her kat için ayrı değerlendirilmiş ve modelin ortalama sınıflandırma performansı hesaplanmıştır.

3.5. Deneysel Çalışma

Bu çalışmada Python programlama dili kullanılmıştır. Tüm deneyler, Merkezi İşlem Birimi (CPU), Tesla K80 GPU donanımı ile çevrimiçi bulut hizmeti kullanılarak Ubuntu 16.04 işletim sistemine sahip Google Colaboratory (Colab) Linux sunucusunda ücretsiz olarak gerçekleştirilmiştir. İşlemler Python’da fastai kütüphanesi kullanılarak gerçekleştirilmiştir.

Fastai Kütüphanesi

Facebook'un derin öğrenme için PyTorch çerçevesinin üzerinde yer alan Python ‘da bir derin öğrenme kitaplığıdır. Derin öğrenmede verileri hızlı bir şekilde ve yüksek doğruluk ile eğitir. Özel bir modele ihtiyaç duyulması halinde diğer kütüphaneler yerine fastai kütüphanesi kullanılabilir.

3.6. Hiperparametreler

Hiperparametreler, ağ yapısını ve ağın nasıl eğitildiğini belirleyen değişkenleri belirleyen parametrelerdir. Hiperparametreler eğitimden önce ayarlanır.


Bu çalışmada Batch Size = 16, Random Seed=41, Size=256 x 256, Num Workers=4 olarak belirlenip veri seti normalize() işlemi ile normalleştirilmiştir.

Veri Seti Boyutu

Derin öğrenme uygulamalarında veri setinin büyüklüğü en önemli faktörlerden biridir. Veri seti büyüklüğü ne kadar fazla ise öğrenme oranı da o kadar fazla olur. Ayrıca veri setinin büyüklüğü iyi bir model için yeterli değildir, bununla birlikte çeşitliliği de önemlidir. Çeşitlilik arttıkça oranda modelin başarımı da artış gösterecektir.

Öğrenme Oranı

Derin öğrenme modelini ayarlamak için en önemli parametrelerden biri öğrenme oranıdır. Öğrenme oranı, hem hız açısından hem de elde edilen başarı oranı açısından önemlidir. Aynı zamanda hata düzeltme katsayısı olarak da adlandırılmaktadır. Derin öğrenme algoritmalarında stokastik eğitim inişi (SGD) ile hesaplanmaktadır. Doğru öğrenme oranını seçmek önemlidir ve ona rastgele bir tahmin veya birden fazla deneme yapılma vermek yerine, modelin öğrenebileceği oldukça iyi bir öğrenme oranı belirlenmelidir. Bu algoritmanın temelinde evrensel en küçük değerin tespiti vardır. Adım aralığı ne kadar düşük verirse ulaşılması gereken uygun değere daha fazla zaman harcayarak ulaşacaktır. Bu değer eğer büyük seçilirse ulaşılması gereken uygun değeri atlayarak farklı bir değer saptayabilir. Bu yüzden öğrenme sayısı seçilecek en ideal değerde olmalıdır. Birden fazla katmanlı sinir ağları için öngörülen değer birden küçük ve $1e-6$ arasında olmalıdır (Smith 2018). Fastai'de `lr_find()` fonksiyonu, hangi öğrenme hızının daha iyi olduğunu ölçen fonksiyondur.



Şekil 3.5. Kayıp ve öğrenme oranı grafiği

Öğrenme oranı, kaybın önemli ölçüde artmaya başladığı orandan daha düşük olacak şekilde seçilmelidir. Şekil 3.5.'te $1e-4$, son katman grubu için makul bir öğrenme oranıdır. Maksimum öğrenme oranının $1e-4$ ve minimum öğrenme oranının (ilkine uygulanacak) olduğu oranlar için bir aralık seçilerek öğrenme oranları ağız katmanlarına dağıtılabilir. Minimum öğrenme oranı maksimum öğrenme oranının onda biri olabilir, bu durumda minimum öğrenme oranı $1e-5$ seçilebilir.

Epoch (Döngü) Sayısı

Epoch (döngü) sayısı, eğitim sırasında tüm eğitim verilerinin ağıza gösterilme sayısıdır. Bir model için epoch sayısı arttıkça ağızdaki ağırlık güncelleme sayıları da artar. Epoch sayısı düşük olduğunda, yetersiz uyum oluşur. Epoch'un modeli iyi bir uyum sağlamak için doğru miktarı aldığı en uygun bir nokta vardır. Belli bir performans noktasına aşırı öğrenme (overfitting) durumu oluşmadan önce ulaşıldığında, epoch yinelenmeleri, belirli erken durdurma algoritmaları ile bu noktalarda durdurulmalıdır.

Batch Size

Eğitim aşamasında kullanılan eğitim hızını etkileyen bir parametredir. Tek seferde verilerin eğitilmesi yerine veri seti alt kümeleri üzerinde eğitim yapmak için kullanılan bir yöntemdir. Batch size yüksek tutulduğunda tek bir seferde işlenecek veri artacağından ayrıntılara daha az dikkat eden bir model oluşturulur. Batch size çok düşük tutulduğunda detaylı inceleme artacağından, bu işlem modelin oluşma sürecini artırır. Batch Size = 16 tek seferde 16 görüntü beslenebileceği anlamına gelmektedir. Bu sayı 32, 64 olarak artırılabilir. Daha küçük GPU RAM nedeniyle bu çalışmada batch size 16 olarak alınmıştır.

Random Seed

Başlangıç değeri ile üretilen sözde rastgele sayılar her seferinde aynı noktadan başlayacaktır.

Num Workers

Veri yüklemesi için kaç tane alt işlem kullanılacağını belirtir.

Normalize Yöntemi

Normalize yöntemi, ImageNet veri setinden gelen RGB kanallarının istatistiklerine dayalı olarak veri setini normalleştirmek için kullanılır.

3.7. Model Değerlendirme Metrikleri

Performans ölçümleri, öğrenme algoritmalarının performansını yani başarısını değerlendirmede kullanılmaktadır. Bu çalışmada seçilen modellerin sınıflandırma performansını ölçmek için doğruluk, kesinlik, duyarlılık ve F1 puanı olmak üzere 4 metrik kullanılmıştır. Bu metriklerin her biri için metrik değeri ne kadar yüksekse, bir sınıflandırıcının performansı da o kadar yüksek olur. Bu değerlendirme ölçütleri, tıbbi

görüntüleme sistemlerine yönelik çalışmaları değerlendirirken yaygın olarak kullanılır ve yüksek performans gösterirler. Bu nedenle bu çalışmada COVID-19 hastalığını tahmin ederken bu performans metrikleri de kullanılmıştır. Daha yüksek duyarlılık değeri, düşük yanlış negatif (FN) vakaları anlamına gelmektedir ve düşük FN değeri COVID-19 tespiti için iyi bir sonuçtur. Bu metrik değerinin ölçülmesinin önemi kaçırılan COVID-19 vakalarını mümkün olduğunca en aza indirmektir.

Bir sınıflandırıcıyı test ettiğimizde Gerçek Pozitif (TP), Yanlış Pozitif (FP), Gerçek Negatif (TN) ve Yanlış Negatif (FN) olmak üzere dört farklı sayı elde ederiz. Bu sayılar ile kullanılan metrikleri aşağıda verilen denklemlerle hesaplamak mümkündür.

Doğruluk: Verilen derin öğrenme sınıflandırıcılarının sonuçları için en önemli metriktir. Kaç örneğin doğru şekilde sınıflandırıldığını gösterir. Karışıklık matrisi bileşenlerinin toplam değerlerine bölünen gerçek pozitiflerin ve gerçek negatiflerin toplamıdır.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.3)$$

Kesinlik: Modelde doğru tanımlanmış pozitif örneklerin (TP) toplam sayısının, pozitif sınıfa (TP+FP) ait olarak tanımlanan toplam eleman sayısına oranıdır. Model tarafından tahmin edilen gerçek pozitifleri analiz ederek modelin ne kadar doğru performans gösterdiğini hesaplar.

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.4)$$

Duyarlılık: Modelde doğru tanımlanmış pozitif örneklerin (TP) toplam sayısının gerçek pozitif sınıfa (TP+FN) ait olan toplam eleman sayısına oranıdır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.5)$$

F1 Puanı: Duyarlılık ve kesinlik arasındaki dengeyi bulmaya çalışan bir duyarlılık ve kesinlik işlevidir. Özellikle görüntü segmentasyonunda gerçek görüntü ile sonuç görüntü arasındaki örtüşme başarısını ölçmek için F1 Puan kullanılması, model sonucunu değerlendirmek için daha güvenlidir.

$$F1 \text{ Puanı} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (3.6)$$

Karışıklık Matrisi: 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. Çizelge 3.2.'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.

Çizelge 3.2. 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): TP, başlangıçta pozitif olan ve ayrıca derin öğrenme modeline göre pozitif tahminlerdir.

Yanlış Pozitif (FP): FP, başlangıçta negatif olan ve derin öğrenme modeline göre pozitif olması beklenen tahminlerdir.

Gerçek Negatif (TN): TN, başlangıçta negatif olan ve ayrıca derin öğrenme modeline göre negatif tahminlerdir.

Yanlış Negatif (FN): FN, başlangıçta pozitif olan ve derin öğrenme modeline göre negatif olması beklenen tahminlerdir.

3.8. Topluluk Öğrenimi ve Füzyon Modelleri

Topluluk öğrenimi, aynı sorunu çözmek için birden fazla öğrenenin eğitildiği bir makine öğrenimi paradigmasıdır. Eğitim verilerinden bir hipotez öğrenmeye çalışan sıradan makine öğrenimi yaklaşımlarının aksine, topluluk yöntemleri bir dizi hipotez oluşturmaya ve bunları kullanmak için birleştirmeye çalışır (Zang and Ma 2020). Modeli tek bir öğrenenle eğitmek yerine, birden fazla öğrenenle modelin oluşturulmasını sağlayan öğrenmedir. Her bireyin veya tek bir öğrenenin çıktısı 'oy' olarak alınır, nihai çıktı (karar) çoğunluğun yanıtına dayanır. Bu şemaların en popüler olanları, Çoğunluk (Majority) veya Maksimum oylama, Ortalama alma (Averaging) ve Ağırlıklı ortalama (Weighted averaging) almadır.


Maksimum Oylama: Bu yaklaşımda, her bir veri noktası için tahminler yapmak için birden fazla model kullanılır. Her modelin tahminleri bir 'oy' olarak kabul edilir. Modellerin çoğundan elde edilen tahminler, nihai tahmin olarak kullanılır. Maksimum oylama genellikle sınıflandırma görevleri için kullanılır.

Ortalama Alma: Bu teknikte, her bir veri noktası için birden fazla tahmin yapılır. Tüm modellerden gelen tahminlerin ortalaması daha sonra hesaplanır ve nihai tahminde bulunmak için kullanılır. Ortalama alma genellikle regresyon görevlerinde kullanılır.

Ağırlıklı Ortalama: Bu, ortalama alma şemasının bir uzantısıdır. Bu teknikte, her modele tahmin için önemini tanımlayan farklı ağırlıklar atanır.

Bu çalışmada, sınıflandırma doğruluğunu artırmak ve farklı derin öğrenme modellerini birleştirmek için max, majority vote, sum, mean, product yaklaşımları kullanılmıştır. Ele alınan problemin tipik bir sınıflandırma görevi olduğu gerçeğinden yola çıkılarak, bu çalışmada bu yaklaşımlar uygulanmıştır. Bir topluluk, genellikle temel öğrenenler olarak adlandırılan birkaç öğrenenden oluşur. Yaklaşımımızda bu temel öğrenenler ResNet-34, ResNet-50, ResNet-101, ResNet-152, VGG-19 ve

DenseNet201'dir. Bu tür öğrenenler genellikle bir kombinasyon şemasına dayanır. Seçilen bu öğrenenlerden farklı derin öğrenme modellerini birleştirmek için özellikle iki farklı topluluk modeli oluşturulmuştur. Oluşturulan ENSEMBLE-1 modeli ResNet-152, VGG-19, DenseNet201 modellerinden, ENSEMBLE-2 modeli ise ResNet-50, VGG-19, DenseNet201 modellerinden oluşmaktadır.



Şekil 3.6. Topluluk derin öğrenme yaklaşımının akış şeması

Şekil 3.5. bu çalışmada uygulanan topluluk derin öğrenme yaklaşımının şemasını göstermektedir. Burada CNN tabanlı 4 sınıflandırıcı görülmektedir. Bu sınıflandırıcılar temel öğrenenler olarak kabul edilmektedir. Her öğrenen y_i , $\{c_1:COVID-19, c_2:Pnömoni, c_3:Normal\}$ sınıf kümesinden bir sonucu tahmin edecektir. Topluluk stratejisi aşağıdaki gibi formüle edilmiştir.

$$y_{e(nsemble)} = c_{\arg \max_j \sum_{i=1}^T y_i^j} \quad (3.7)$$

Burada, çok boyutlu vektör $(y_{i1}, y_{i2}, \dots, y_{iT})$, eğitim verisi örneğindeki tahmini y_i çıktısını temsil eder ve $y_{i,j}$, c_j sınıfındaki y_i çıktısını temsil eder. T değeri 4 olan öğrenen sayısıdır. Girdi öznelik vektörü X verildiğinde, çoklu sınıflandırıcının i . çıktısı aşağıdaki denklemde gösterildiği gibidir.

$$y_i(X) = [y_{i,1}(X), y_{i,2}(X), y_{i,3}(X)]^T \quad (3.8)$$

Dörtlü sınıflandırıcının çıktısı aşağıdaki denklemde gösterildiği gibidir.

$$y(X) = \text{Fusion}(y_1(X), y_2(X), y_3(X), y_4(X)) \quad (3.9)$$

Tüm temel öğrenenlerin çıktıları, aşağıdaki denklemdeki gibi 4x3 matris biçiminde bir karar profili olarak temsil edilebilir.

$$DP(X) = \begin{bmatrix} y_{1,1}(X) & y_{1,2}(X) & c_{1,3}(X) \\ y_{2,1}(X) & y_{2,2}(X) & y_{2,3}(X) \\ y_{3,1}(X) & y_{3,2}(X) & c_{3,3}(X) \\ y_{4,1}(X) & y_{4,2}(X) & y_{4,3}(X) \end{bmatrix} \quad (3.10)$$

Ek olarak, füzyon sonucu $y(X)$, aşağıdaki denklemde gösterildiği gibi ölçü katmanı formu (d , her sınıf için kararı temsil eder) ile temsil edilen 3 boyutlu bir vektördür.

$$y(X) = [d_1(X), d_2(X), d_3(X)]^T \quad (3.11)$$

Çizelge 3.3.'de verilen füzyon kuralları, $DP(X)$ 'nin her sütununa uygulanır ve işlem sonucunda füzyon çıktısını verir. Füzyon kurallarına göre topluluk puanlaması Denklem 3.7'de verilmiştir.

Çizelge 3.3. Füzyon modelleri (i:sınıflandırıcı numarası, j:sınıf etiketi)

Füzyon Modeli	Formül
Max	$d_j(X) = \max_{i=1}^l y_{i,j}(X), j = 1, 2, \dots, m$
Majority Vote	$d_j(X) = \underset{i=1}{l} \operatorname{argmax} y_{i,j}(X), j = 1, 2, \dots, m$
Sum	$d_j(X) = \sum_{i=1}^l y_{i,j}(X), j = 1, 2, \dots, m$
Mean	$d_j(X) = \frac{1}{l} \sum_{i=1}^l y_{i,j}(X), j = 1, 2, \dots, m$
Product	$d_j(X) = \prod_{i=1}^l y_{i,j}(X), j = 1, 2, \dots, m$


4. ARAŞTIRMA BULGULARI ve TARTIŞMA

COVID-19 hastalığının tespitinde yapay zekâ tekniklerinin kullanımı oldukça yaygınlaşmıştır. Çizelge 4.10.'da verildiği gibi literatürde bu konu ile ilgili derin öğrenme modellerine dayalı birçok çalışma tasarlanmış ve sunulmuştur. Bu çalışmalarda, ikili sınıflandırmada, COVID-19 pozitifini COVID-19 negatifinden ayırmak yaygındır. Ayrıca diğer akciğer hastalık türlerini COVID-19 pozitifinden ayırt etmek de çok önemlidir. Bu nedenle bu çalışmada hem ikili sınıflandırma (COVID-19 ve Normal, COVID-19 ve Pnömoni) hem de çoklu sınıflandırma (COVID-19, Pnömoni ve Normal) tercih edilmiştir. Bu çalışmada, etkili bir model oluşturmak için X-Ray görüntüleri ile birlikte yaygın olarak kullanılan derin öğrenme yaklaşımları kullanılmıştır. Bu yaklaşımlar ResNet-34, ResNet-50, ResNet-101, ResNet-152, VGG-19 ve DenseNet201 olarak seçilmiştir.

Bu çalışmada COVID-19'u tespit etmek ve sınıflandırmak için, X-Ray görüntüleri kullanılarak derin CNN tabanlı ResNet-50, ResNet-152, VGG-19 ve DenseNet201 modellerinden oluşan bir topluluk derin öğrenme sistemi önerilmiştir. Ayrıca yetersiz veri ve eğitim süresi problemlerini gidermek için transfer öğrenim yöntemi uygulanmıştır. Seçilen bu modellerden farklı 2 model oluşturulmuştur. Oluşturulan ENSEMBLE-1 modeli ResNet-152, VGG-19, DenseNet201 modellerinden, ENSEMBLE-2 modeli ise ResNet-50, VGG-19, DenseNet201 modellerinden oluşmaktadır. Önceden eğitilmiş ResNet-34, ResNet-50, ResNet-101 modelleri arasından en iyi performansı gösteren ResNet-50 ve ResNet-152 bu modeller için kullanılmıştır. Bu modeller ile birlikte farklı üç senaryo uygulanmıştır. İlk olarak X-Ray görüntülerini 3 kategoride sınıflandırmak için modeller, Çizelge 4.1.'de görüldüğü gibi 3 sınıf (COVID-19, Pnömoni ve Normal) için eğitilmiştir. İkinci olarak modeller, Çizelge 4.3.'te görüldüğü gibi iki sınıfı (COVID-19 ve Normal) tespit etmek için eğitilmiştir. Üçüncü olarak modeller, Çizelge 4.5.'te görüldüğü gibi iki sınıfı (COVID-19 ve Pnömoni) tespit etmek için eğitilmiştir.

Modeli geliştirmek için toplam 1125 görüntü (125 COVID-19, 500 Pnömoni ve 500 Normal) kullanılmıştır. X-Ray görüntülerinin %80'i eğitim ve %20'si doğrulama için kullanılmıştır. Önerilen modelin performansı, hem ikili hem de çoklu sınıflandırma problemi için Şekil 4.1.'de gösterildiği gibi 5 katlı çapraz doğrulama prosedürü ile her

kat için ayrı değerlendirilmiş ve modelin ortalama sınıflandırma performansı hesaplanmıştır.



Şekil 4.1. Veri setini eğitim ve doğrulamaya bölmek için kullanılan 5 katlı çapraz doğrulama şeması.

Bu topluluk modellerinde Max, Mode, Sum, Mean ve Product gibi temel füzyon fonksiyonları test edilmiştir. Elde edilen değerler incelendiğinde Max ve Product temel füzyon fonksiyonlarının sınıflandırma performansı üzerinde olumlu bir etkiye sahip olduğu görülmektedir. Çoklu sınıflandırmada, hem ENS-1 hem de ENS-2 için Max işlevi sırasıyla %85 ve %86 doğruluk oranıyla öne çıkmaktadır. Product fonksiyonu, ikili sınıflandırmada %99 ile en yüksek performansı elde etmiştir. Sonuçlar, füzyon yöntemlerinin ikili sınıflandırmada daha iyi sınıflandırma performansı elde edebileceğini göstermektedir.

Topluluk derin öğrenme sistemimizin en büyük gücü, tahmininin füzyon yöntemlerine göre seçilen 2 model tarafından yapılmasıdır. Önerilen model ayrıca birden fazla topluluk modeli ile yeni örneği öngördüğü için yanlış sınıflandırma hatasını da azaltmaktadır.





















4.1. Çoklu Sınıf (COVID-19, Pnömoni ve Normal) için Kesinlik, Duyarlılık, F1 Puan Değerlendirmesi ve Karışıklık Matrisi

Veri setinde COVID-19 X-ray görüntülerinin düşük oranda olması nedeniyle, doğruluk dışında Çizelge 4.1.'de görüldüğü gibi kesinlik, duyarlılık ve F1 puanına göre de değerlendirilmiştir. Bu tablodaki değerler Max Voting fonksiyonuna göre elde edilmiştir. Çoklu performanslar %80 ve %83 seviyelerinde sabit kalmıştır. VGG-19 ve DenseNet201 modelleri en düşük performansı göstermiştir. ResNet-50 ve ResNet-152 en yüksek performansı göstermiş olup performans değerleri %83'tür. Çizelge 4.2'de görüldüğü gibi önerilen modellerin karışıklık matrisinin sonucu hesaplanmıştır.

Çizelge 4.1. 5 kat çapraz doğrulama ile çoklu sınıf (COVID-19, Pnömoni ve Normal) için kesinlik, duyarlılık, F1 puanı ve doğruluk performansları.

Models	Folds	Fold-1	Fold-2	Fold-3	Fold-4	Fold-5	Average
ResNet-50	Precision	1,00	0,94	1,00	1,00	1,00	0,99
	Recall	0,92	0,68	0,96	0,92	0,96	0,89
	F1-Score	0,96	0,79	0,98	0,96	0,98	0,93
	Accuracy	0,85	0,79	0,80	0,84	0,89	0,83
ResNet-152	Precision	1,00	0,94	1,00	0,96	1,00	0,98
	Recall	0,84	0,64	1,00	0,88	0,92	0,86
	F1-Score	0,91	0,76	1,00	0,92	0,96	0,91
	Accuracy	0,87	0,78	0,84	0,77	0,89	0,83
VGG-19	Precision	0,95	1,00	1,00	1,00	0,96	0,98
	Recall	0,76	0,64	0,96	0,84	0,88	0,82
	F1-Score	0,84	0,78	0,98	0,91	0,92	0,89
	Accuracy	0,83	0,80	0,76	0,77	0,86	0,80
DenseNet201	Precision	1,00	1,00	1,00	1,00	1,00	1,00
	Recall	0,72	0,64	1,00	0,84	0,84	0,80
	F1-Score	0,84	0,78	1,00	0,91	0,91	0,89
	Accuracy	0,83	0,76	0,82	0,82	0,89	0,82

Çizelge 4.2. Çoklu sınıf (COVID-19, Pnömoni ve Normal) için karışıklık matrisi

	ResNet-50	ResNet-152	VGG-19	DenseNet201
Fold-1	Confusion matrix 	Confusion matrix 	Confusion matrix 	Confusion matrix 
Fold-2	Confusion matrix 	Confusion matrix 	Confusion matrix 	Confusion matrix 
Fold-3	Confusion matrix 	Confusion matrix 	Confusion matrix 	Confusion matrix 
Fold-4	Confusion matrix 	Confusion matrix 	Confusion matrix 	Confusion matrix 
Fold-5	Confusion matrix 	Confusion matrix 	Confusion matrix 	Confusion matrix 

4.2. İkili Sınıf (COVID-19 ve Normal) için Kesinlik, Duyarlılık, F1 Puan Değerlendirmesi ve Karışıklık Matrisi

Veri setinde COVID-19 X-ray görüntülerinin düşük oranda olması nedeniyle, doğruluk dışında Çizelge 4.3.'de gösterildiği gibi kesinlik, duyarlılık ve F1 puanına göre de değerlendirilmiştir. Bu tablodaki değerler Max Voting fonksiyonuna göre elde edilmiştir. ResNet-152 ve DenseNet201 modelleri en düşük performansı göstermiştir. ResNet-50 ve VGG-19 en yüksek performansı göstermiş olup performans değerleri %99'dur. Çizelge 4.4.'de gösterildiği gibi önerilen modellerin karışıklık matrisinin sonucu hesaplanmıştır.

Çizelge 4.3. 5 kat çapraz doğrulama ile ikili sınıf (COVID-19 ve Normal) için kesinlik, duyarlılık, F1 puanı ve doğruluk performansları.

Models	Folds	Fold-1	Fold-2	Fold-3	Fold-4	Fold-5	Average
ResNet-50	Precision	1,00	1,00	1,00	1,00	1,00	1,00
	Recall	0,96	1,00	0,88	0,96	0,92	0,95
	F1-Score	0,98	1,00	0,94	0,98	0,96	0,97
	Accuracy	0,99	1,00	0,98	0,99	0,98	0,99
ResNet-152	Precision	1,00	0,94	1,00	0,96	1,00	0,98
	Recall	1,00	0,88	0,92	0,96	0,92	0,94
	F1-Score	1,00	0,94	0,96	0,98	0,96	0,97
	Accuracy	1,00	0,98	0,95	0,99	0,98	0,98
VGG-19	Precision	1,00	1,00	1,00	0,96	0,95	0,98
	Recall	0,96	0,92	1,00	1,00	0,88	0,95
	F1-Score	0,98	0,96	1,00	0,98	0,94	0,97
	Accuracy	0,99	0,98	1,00	0,99	0,98	0,99
DenseNet201	Precision	1,00	1,00	1,00	1,00	1,00	1,00
	Recall	1,00	0,72	0,92	0,96	0,96	0,91
	F1-Score	1,00	0,84	0,96	0,98	0,98	0,95
	Accuracy	1,00	0,95	0,95	0,99	0,99	0,98

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Çizelge 4.4. İkili sınıf (COVID-19 ve Normal) için karışıklık matrisi

	ResNet-50	ResNet-152	VGG-19	DenseNet201																																																
Fold-1	Confusion matrix <table><tr><td>Covid-19</td><td>24</td><td>1</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	24	1	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>25</td><td>0</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	25	0	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>23</td><td>2</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	23	2	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>24</td><td>1</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	24	1	No_findings	0	100		Covid-19	No_findings		Predicted	
Covid-19	24	1																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	25	0																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	23	2																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	24	1																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Fold-2	Confusion matrix <table><tr><td>Covid-19</td><td>25</td><td>0</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	25	0	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>22</td><td>3</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	22	3	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>23</td><td>2</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	23	2	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>18</td><td>7</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	18	7	No_findings	0	100		Covid-19	No_findings		Predicted	
Covid-19	25	0																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	22	3																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	23	2																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	18	7																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Fold-3	Confusion matrix <table><tr><td>Covid-19</td><td>22</td><td>3</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	22	3	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>23</td><td>2</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	23	2	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>25</td><td>0</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	25	0	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>23</td><td>2</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	23	2	No_findings	0	100		Covid-19	No_findings		Predicted	
Covid-19	22	3																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	23	2																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	25	0																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	23	2																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Fold-4	Confusion matrix <table><tr><td>Covid-19</td><td>23</td><td>2</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	23	2	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>24</td><td>1</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	24	1	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>25</td><td>0</td></tr><tr><td>No_findings</td><td>1</td><td>99</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	25	0	No_findings	1	99		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>24</td><td>1</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	24	1	No_findings	0	100		Covid-19	No_findings		Predicted	
Covid-19	23	2																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	24	1																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	25	0																																																		
No_findings	1	99																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	24	1																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Fold-5	Confusion matrix <table><tr><td>Covid-19</td><td>23</td><td>2</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	23	2	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>23</td><td>2</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	23	2	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>22</td><td>3</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	22	3	No_findings	0	100		Covid-19	No_findings		Predicted		Confusion matrix <table><tr><td>Covid-19</td><td>24</td><td>1</td></tr><tr><td>No_findings</td><td>0</td><td>100</td></tr><tr><td></td><td>Covid-19</td><td>No_findings</td></tr><tr><td></td><td>Predicted</td><td></td></tr></table>	Covid-19	24	1	No_findings	0	100		Covid-19	No_findings		Predicted	
Covid-19	23	2																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	23	2																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	22	3																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			
Covid-19	24	1																																																		
No_findings	0	100																																																		
	Covid-19	No_findings																																																		
	Predicted																																																			

4.3. İkili Sınıf (COVID-19 ve Pnömoni) için Kesinlik, Duyarlılık, F1 Puan Değerlendirmesi

Veri setinde COVID-19 X-ray görüntülerinin düşük oranda olması nedeniyle, doğruluk dışında Çizelge 4.5.'de gösterildiği gibi kesinlik, duyarlılık ve F1 puanına göre de değerlendirilmiştir. Bu tablodaki değerler Max Voting fonksiyonuna göre elde edilmiştir. ResNet-152 ve DenseNet201 modelleri en düşük performansı göstermiştir. ResNet-50 ve VGG-19 en yüksek performansı göstermiş olup performans değerleri %99'dur. Çizelge 4.6.'da gösterildiği gibi önerilen modellerin karışıklık matrisinin sonucu hesaplanmıştır.

Çizelge 4.5. 5 kat çapraz doğrulama ile ikili sınıf (COVID-19 ve Pnömoni) için kesinlik, duyarlılık, F1 puanı ve doğruluk performansları.

Models	Folds	Fold-1	Fold-2	Fold-3	Fold-4	Fold-5	Average
ResNet-50	Precision	0,92	1,00	0,85	1,00	1,00	1,00
	Recall	0,96	0,52	0,88	0,88	0,96	0,95
	F1-Score	0,94	0,68	0,86	0,94	0,98	0,97
	Accuracy	0,97	0,90	0,94	0,98	0,99	0,99
ResNet-152	Precision	0,96	1,00	1,00	1,00	1,00	1,00
	Recall	0,88	0,64	0,96	0,92	0,92	0,94
	F1-Score	0,92	0,78	0,98	0,96	0,96	0,97
	Accuracy	0,97	0,93	0,99	0,98	0,98	0,98
VGG-19	Precision	0,94	0,93	0,95	0,95	0,90	0,98
	Recall	0,68	0,52	0,84	0,84	0,76	0,95
	F1-Score	0,79	0,67	0,89	0,89	0,83	0,97
	Accuracy	0,93	0,90	0,96	0,96	0,94	0,99
DenseNet201	Precision	1,00	0,74	1,00	1,00	1,00	1,00
	Recall	0,80	0,56	0,96	0,96	0,76	0,91
	F1-Score	0,89	0,64	0,98	0,98	0,86	0,95
	Accuracy	0,96	0,87	0,99	0,99	0,95	0,98

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Çizelge 4.6. İkili sınıf (COVID-19 ve Pnömoni) için karışıklık matrisi

	ResNet-50	ResNet-152	VGG-19	DenseNet201																																				
Fold-1	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>20</td><td>5</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	20	5	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>24</td><td>1</td></tr><tr><td>Actual Pneumonia</td><td>1</td><td>99</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	24	1	Actual Pneumonia	1	99	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>21</td><td>4</td></tr><tr><td>Actual Pneumonia</td><td>2</td><td>98</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	21	4	Actual Pneumonia	2	98	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>19</td><td>6</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	19	6	Actual Pneumonia	0	100
	Covid-19	Pneumonia																																						
Actual Covid-19	20	5																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	24	1																																						
Actual Pneumonia	1	99																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	21	4																																						
Actual Pneumonia	2	98																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	19	6																																						
Actual Pneumonia	0	100																																						
Fold-2	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>20</td><td>5</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	20	5	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>15</td><td>10</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	15	10	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>17</td><td>8</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	17	8	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>17</td><td>8</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	17	8	Actual Pneumonia	0	100
	Covid-19	Pneumonia																																						
Actual Covid-19	20	5																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	15	10																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	17	8																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	17	8																																						
Actual Pneumonia	0	100																																						
Fold-3	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>22</td><td>3</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	22	3	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>24</td><td>1</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	24	1	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>23</td><td>2</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	23	2	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>24</td><td>1</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	24	1	Actual Pneumonia	0	100
	Covid-19	Pneumonia																																						
Actual Covid-19	22	3																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	24	1																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	23	2																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	24	1																																						
Actual Pneumonia	0	100																																						
Fold-4	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>21</td><td>4</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	21	4	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>23</td><td>2</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	23	2	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>21</td><td>4</td></tr><tr><td>Actual Pneumonia</td><td>1</td><td>99</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	21	4	Actual Pneumonia	1	99	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>24</td><td>1</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	24	1	Actual Pneumonia	0	100
	Covid-19	Pneumonia																																						
Actual Covid-19	21	4																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	23	2																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	21	4																																						
Actual Pneumonia	1	99																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	24	1																																						
Actual Pneumonia	0	100																																						
Fold-5	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>23</td><td>2</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	23	2	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>23</td><td>2</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	23	2	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>19</td><td>6</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	19	6	Actual Pneumonia	0	100	Confusion matrix <table><tr><td></td><td>Covid-19</td><td>Pneumonia</td></tr><tr><td>Actual Covid-19</td><td>19</td><td>6</td></tr><tr><td>Actual Pneumonia</td><td>0</td><td>100</td></tr></table>		Covid-19	Pneumonia	Actual Covid-19	19	6	Actual Pneumonia	0	100
	Covid-19	Pneumonia																																						
Actual Covid-19	23	2																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	23	2																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	19	6																																						
Actual Pneumonia	0	100																																						
	Covid-19	Pneumonia																																						
Actual Covid-19	19	6																																						
Actual Pneumonia	0	100																																						


4.4. Çoklu Sınıf (COVID-19, Pnömoni ve Normal) için Füzyon Yöntem Değerlendirmesi

Füzyon yöntemleri arasında Max işlevi Çizelge 4.7.'de gösterildiği gibi, hem ENS-1 hem de ENS-2 için çoklu sınıflandırma senaryosunda en yüksek sınıflandırma performansını elde etmiştir.


Çizelge 4.7. Füzyon yöntemleri ile çoklu sınıf (COVID-19, Normal, Pnömoni) için ENSEMBLE-1 ve ENSEMBLE-2 modellerinin doğruluk değerleri.

	ENS-1					ENS-2				
	MAX	MODE	SUM	MEAN	PRODUCT	MAX	MODE	SUM	MEAN	PRODUCT
Fold-1	0,87	0,86	0,88	0,88	0,88	0,87	0,85	0,88	0,88	0,87
Fold-2	0,79	0,78	0,79	0,79	0,78	0,79	0,76	0,78	0,78	0,79
Fold-3	0,83	0,80	0,80	0,80	0,82	0,85	0,81	0,83	0,83	0,83
Fold-4	0,84	0,82	0,80	0,80	0,80	0,86	0,84	0,85	0,85	0,85
Fold-5	0,90	0,93	0,92	0,92	0,92	0,91	0,93	0,90	0,90	0,88
Average	0,85	0,84	0,84	0,84	0,84	0,86	0,84	0,85	0,85	0,84

Şekil 4.2. ENS-1 ve Şekil 4.3. ENS-2 her kat için füzyon işlevlerinin doğruluk oranlarını göstermektedir. ENS-1'de tüm füzyon yöntemleri aynı ortalamaya yakın devam ederken, Max işlevi en yüksek performansı göstermiştir. Benzer şekilde ENS-2'de Max işlevi en yüksek performansı gösterirken, en düşük performans Mod ve Product ile elde edilmiştir.



Şekil 4.2. Temel füzyon yöntemleri ile ENS-1 için çoklu sınıf (COVID-19, Pnömoni ve Normal) sonuçları.



Şekil 4.3. Temel füzyon yöntemleri ile ENS-2 için çoklu sınıf (COVID-19, Pnömoni ve Normal) sonuçları.


4.5. İkili Sınıf (COVID-19 ve Normal) için Füzyon Yöntem Değerlendirmesi

İkili sınıflandırma performansları, Çizelge 4.8.'de gösterildiği gibi her bir füzyon işlevi için çoklu sınıflandırmadan daha yüksektir. COVID-19 ve Normal için sınıflandırma performansı hem ENS-1 hem de ENS-2 için %99'dur. Füzyon yöntemleri arasında en düşük değeri Sum fonksiyonu elde ederken, diğer fonksiyonlar %99 düzeyine ulaşmıştır.


Çizelge 4.8. Füzyon yöntemleri ile ikili sınıf (COVID-19 ve Normal) için ENSEMBLE-1 ve ENSEMBLE-2 modellerinin doğruluk değerleri.

ENS-1						ENS-2				
	MAX	MODE	SUM	MEAN	PRODUCT	MAX	MODE	SUM	MEAN	PRODUCT
Fold-1	1,00	0,99	0,98	1,00	1,00	1,00	1,00	1,00	1,00	0,99
Fold-2	0,98	0,98	0,98	0,98	0,98	0,99	0,99	0,99	0,99	0,99
Fold-3	0,98	0,99	0,98	0,99	0,99	0,99	0,99	0,99	0,99	1,00
Fold-4	0,99	0,99	0,99	1,00	1,00	0,99	0,99	0,99	0,99	1,00
Fold-5	0,98	0,99	0,98	0,99	0,99	0,98	0,98	0,98	0,98	0,98
Average	0,99	0,99	0,98	0,99	0,99	0,99	0,99	0,99	0,99	0,99

Normal ve COVID-19 röntgenlerindeki bariz fark, ikili sınıflandırma performanslarına da yansır. Şekil 4.4. ve Şekil 4.5.'te gösterildiği gibi ENS-1'deki hemen hemen tüm kıvrımlar için Sum işlevi en düşük seviyedeysen, diğer işlevler hem ENS-1'de hem de ENS-2'de %99'u aşmıştır.



Şekil 4.4. Temel füzyon yöntemleri ile ENS-1 için ikili (COVID-19 ve Normal) sınıf sonuçları.



Şekil 4.5. Temel füzyon yöntemleri ile ENS-2 için ikili (COVID-19 ve Normal) sınıf sonuçları.


4.6. İkili Sınıf (COVID-19, Pnömoni) için Füzyon Yöntem Değerlendirmesi

COVID-19 ve Pnömoni benzer semptomlara sahip iki hastalık olduğundan, buradaki sınıflandırma performansı COVID-19 ve Normal sınıflandırmasından nispeten daha düşüktür. Çizelge 4.9.'da gösterildiği gibi ENS-1 için tüm füzyon yöntemleri aynı performansı gösterirken, ENS-2 için Product fonksiyonu ile %98 başarı sağlanmıştır.


Çizelge 4.9. Füzyon yöntemleri ile ikili sınıf (COVID-19 ve Pnömoni) için ENSEMBLE-1 ve ENSEMBLE-2 modellerinin doğruluk değerleri.

ENS-1						ENS-2				
	MAX	MODE	SUM	MEAN	PRODUCT	MAX	MODE	SUM	MEAN	PRODUCT
Fold-1	0,97	0,97	0,98	0,97	0,97	0,96	0,95	0,96	0,96	0,97
Fold-2	0,93	0,94	0,92	0,93	0,93	0,94	0,95	0,95	0,95	0,95
Fold-3	1,00	0,99	0,99	1,00	1,00	0,99	0,99	1,00	1,00	0,99
Fold-4	0,98	0,98	0,97	0,99	0,99	0,99	0,98	0,99	0,99	0,99
Fold-5	0,96	0,96	0,97	0,96	0,96	0,95	0,97	0,97	0,97	0,98
Average	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,98

COVID-19 ve Pnömoni ikili sınıflandırmasında ENS-2 için Product yöntemi %98 ile en yüksek performansı elde etmiştir. Şekil 4.6. ve Şekil 4.7.'de gösterildiği gibi ENS-1'de Mean ve Sum için sırasıyla sadece bir kat %92 ve %93 değerleri elde edilmiştir. ENS-1'deki kıvrımlardaki performanslar arasındaki boşluk ENS-2'ye göre daha yüksektir.



Şekil 4.6. Temel füzyon yöntemleri ile ENS-1 için ikili (COVID-19 ve Pnömoni) sınıf sonuçları.



Şekil 4.7. Temel füzyon yöntemleri ile ENS-2 için ikili (COVID-19 ve Pnömoni) sınıf sonuçları.

Çizelge 4.10.'da görüldüğü gibi en iyi sonuçların genellikle ikili sınıflandırma çalışmalarında elde edildiği görülmektedir. Doğruluk oranlarını sadece iki modeli birleştirerek elde ettiğimiz düşünüldüğünde, önerilen bu sistemin farklı füzyon

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

fonksiyonlarının yanı sıra diğer büyük veri setlerinde de dikkate değer bir kullanım bulacağı görülmektedir.

Çizelge 4.10. COVID-19 sınıflandırma yöntemlerinin doğruluk oranlarının karşılaştırılması.

Çalışma	Veri Seti	Sınıflandırma	#sayı	Doğruluk (%)
(Wang et al. 2020)	Chest CT	M-Inception	2	82,90
(Loey et al. 2020)	Chest CT	AlexNet, VGG16, VGG19, GoogleNet, and ResNet-50	2	82,91
(Sahinbas and Catak 2020)	Chest X-ray	VGG16, VGG19, ResNet, DenseNet ve InceptionV3	2	80,00
(Xu et al. 2020)	Chest X-ray	ResNet+Location Attention	3	86,70
(Hemdan et al. 2020)	Chest X-ray	COVIDX-Net	2	90,00
(Ouchicha et al. 2020)	Chest X-ray	CVDNet	3	97,20
Önerilen Model	Chest X-ray	DarkCovidNet	2	98,08
			3	87,02
		ENS-1	3	85,00
		ENS-2	3	86,00
		ENS-1 (COVID-19&Pneumonia)	2	97,00
		ENS-2 (COVID-19&Pneumonia)	2	98,00
		ENS-1 (COVID-19&Normal)	2	99,00
		ENS-2 (COVID-19&Normal)	2	99,00

5. SONUÇ ve ÖNERİLER

COVID-19'un erken teşhisi, hastalığın diğer insanlara yayılmasını önlemek için hayati önem taşımaktadır. Bu çalışmada, COVID-19, Pnömoni ve Normal olan hastalardan elde edilen 1125 X-Ray görüntüsünden COVID-19 hastalarını otomatik olarak tespit etmek ve sınıflandırmak için transfer öğrenme tabanlı bir topluluk derin öğrenme sistemi önerilmiştir. Bu topluluk sistemlerinde füzyon fonksiyonlarının sınıflandırma performansı üzerindeki etkisini incelemek önemlidir. Füzyon fonksiyonları daha önce çalışılmış ve birçok alanda iyi çalıştığı gösterilmiştir. Bu nedenle, bu işlevlerin COVID-19 veri kümelerine uygulanması önemlidir. Çalışma, çoklu ve ikili sınıf problemleri için derin CNN tabanlı ResNet-50, ResNet-152, VGG-19 ve DenseNet201 modellerini kullanmıştır. Bu sistem tarafından elde edilen performans doğruluğu, çoklu sınıf için %86 ve ikili sınıf için %99'dur. Sonuçlardan elde edilen bir diğer olumlu gözlem, COVID-19 vakaları için kesinlik, hassasiyet ve F1 puan değerlendirmesidir. Daha yüksek duyarlılık değeri, düşük yanlış negatif (FN) vakaları anlamına gelmektedir ve düşük FN değeri COVID-19 tespiti için iyi bir sonuçtur. Bu metrik değerinin ölçülmesinin önemi kaçırılan COVID-19 vakalarını mümkün olduğunca en aza indirmektir.

Önerilen model, X-Ray görüntüleri kullanılarak COVID-19 otomatik tespiti için kullanılabilir. X-Ray görüntüleri, hastalık teşhisi için kolayca erişilebilir oldukları için tercih edilir. Pandemi sırasında dünya çapında sağlık merkezlerinde yaygın olarak kullanılmaktadırlar. BT maliyetli bir süreçtir ve genellikle yalnızca daha büyük sağlık merkezlerinde bulundukları için kolayca erişilebilir değildir. Ayrıca BT röntgen ile karşılaştırıldığında hastanın aldığı radyasyon miktarı daha fazladır. Bu nedenle, BT'ye kıyasla daha düşük radyasyon dozu ile daha erişilebilir olduğu için X-Ray görüntülü bir derin öğrenme modelinin kullanılması tavsiye edilir. Model tarafından COVID-19 pozitif olarak teşhis edilen hastalar, onay için ileri merkezlere yönlendirilebilir ve ardından gecikmeden tedavi edilebilir. Ayrıca model ile negatif teşhis konulan hastaların RT-PCR testi yaptırmaları ve sağlık ocaklarını gereksiz yere işgal etmeleri engellenebilir. Yetersiz sayıda mevcut RT-PCR test kiti, test maliyetleri ve test sonuçlarının bekleme süresi gibi dezavantajların ortadan kaldırılmasında faydalı olabilir. COVID-19 hastalarının X-Ray tarama görüntülerinin sınıflandırma işleminde önerilen sistem, COVID-19 hastalarına

erken tanı koymak, tedavinin etkinliğini arttırmak, uzman radyolog sorununun önüne geçmek ve salgının kontrolünü sağlamak için büyük bir potansiyele sahiptir. Ayrıca diğer akciğer hastalık türlerini COVID-19 pozitifinden ayırt etmek de çok önemlidir. Önerilen sistemin diğer bir gücü ise, pnömoni gibi göğüs ile ilgili diğer hastalıkları sınıflandırmak için de kullanılabilmesidir.



KAYNAKLAR

- Abraham, B. ve Nair, M. S. 2020. Computer-aided detection of COVID-19 from X-ray images using multi-CNN and Bayesnet classifier. *Biocybernetics and Biomedical Engineering*, 40, 6.
- Agarap, A. F. 2018. Deep learning using rectified linear units (relu). *arXiv Preprint arXiv:1803.08375*, 1-8.
- Alimadadi, A., Aryal, S., Manandhar, I., Munroe, P. B., Joe, B. ve Cheng, X. 2020. Artificial intelligence and machine learning to fight COVID-19. *Physiol Genomics*, 52, 200–202.
- Apostolopoulos, I. D., Aznaouridis, S. I. ve Tzani, M. A. 2020. Extracting possibly representative COVID-19 biomarkers from X-ray images with deep learning approach and image data related to pulmonary diseases. *Journal of Medical and Biological Engineering*, 40(3), 462-469.
- Ardakani, A. A., Kanafi, A. R., Acharya, U. R., Khadem, N. ve Mohammadi, A. 2020. Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks. *Computers in Biology and Medicine*, 121, 6.
- Baldi, P. ve Sadowski, P. J. 2013. Understanding dropout. *Advances in Neural Information Processing Systems*, 26, 2814–2822
- Caobelli, F. 2020. Artificial intelligence in medical imaging: Game over for radiologists?. *European Journal of Radiology*, 126, 108940
- Cohen, J. P., Morrison, P. ve Dao, L. 2020. COVID-19 image data collection. *Computers & Education*, 164.
- Deng, L. ve Yu, D. 2014. Deep learning: methods and applications. *Foundations and Trends in Signal Processing*, 7(3–4), 197-387.
- Dey, N., Zhang, Y.D., Rajinikanth, V., Pugalenth, R. ve Raja, N. S. M. 2021. Customized VGG19 architecture for pneumonia detection in chest X-Rays. *Pattern Recognition Letters*, 143, 67–74.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. ve Thrun, S. 2017. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.
- Hassantabar, S., Ahmadi, M. ve Sharif, A. 2020. Diagnosis and detection of infected tissue of COVID-19 patients based on lung x-ray image using convolutional neural network approaches. *Chaos, Solitons & Fractals*, 140, 6.
- Hemdan, E. E. D., Shouman, M. A. ve Karar, M. E. 2020. Covidx-net: A framework of deep learning classifiers to diagnose COVID-19 in X-ray images. *arXiv Preprint arXiv:2003.11055*, 1-14.

- Horry, M. J., Chakraborty, S., Paul, M., Ulhaq, A., Pradhan, B., Saha, M. ve Shukla, N. 2020. COVID-19 detection through transfer learning using multimodal imaging data. *Ieee Access*, 8, 149808-149824.
- Huang, G., Liu, Z., van der Maaten, L. ve Weinberger, K. Q. 2017. Densenet: densely connected convolutional networks. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 30, 82–84.
- Ismael, A. M. ve Şengür, A. 2021. Deep learning approaches for COVID-19 detection based on chest X-ray images. *Expert Systems With Applications*, 164, 6.
- Kırbaş, I., Sözen, A., Tuncer, A. D. ve Kazancıoğlu, F. S. 2020. Comparative analysis and forecasting of COVID-19 cases in various European countries with ARIMA, NARNN and LSTM approaches. *American Physiological Society Bethesda*, 1, 6.
- Li, X., Geng, M., Peng, Y., Meng, L. ve Lu, S. 2020. Molecular immune pathogenesis and diagnosis of COVID-19. *Journal of Pharmaceutical Analysis*, 10, 102-108.
- Liou, C. Y., Cheng, W. C., Liou, J. W. ve Liou, D. R. 2014. Autoencoder for words. *Neurocomputing*, 139, 84-96.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J.A.W.M., van Ginneken, B., Sánchez, C. I. 2017. A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- Loey, M., Manogaran, G. ve Khalifa, N. E. M. 2020. A deep transfer learning model with classical data augmentation and CGAN to detect COVID-19 from chest CT radiography digital images. *Neural Computing and Applications*, 1, 13.
- Narin, A., Kaya, C. ve Pamuk, Z. 2021. Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks. *Pattern Anal Applications*, 24, 1207–1220.
- Ouchicha, C., Ammor, O. ve Meknassi, M. 2020. CVDNet: A novel deep learning architecture for detection of coronavirus (Covid-19) from chest X-ray images. *Chaos, Solitons and Fractals*, 140.
- Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O. ve Acharya, U. R. 2020. Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine*, 121.
- Punn, N. S. ve Agarwal, S. 2021. Automated diagnosis of COVID-19 with limited posteroanterior chest X-ray images using fine-tuned deep neural networks. *Applied Intelligence*, 51(5), 2689-2702.
- Sahinbas, K. ve Catak, F. O. 2021. Transfer learning based convolutional neural network for COVID-19 detection with X-ray images. In *Data Science for COVID-19*, 451-466.
- Shen, D., Wu, G. ve Suk, H. I. 2017. Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19, 221-248.

- Shuja, J., Alanazi, E., Alasmay, W. ve Alashaikh, A. 2020. Covid-19 open source data sets: A comprehensive survey. *Applied Intelligence*, 51(3), 1296-1325.
- Simonyan, K. ve Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. *American Physiological Society Bethesda*, 1, 6.
- Singhal, T. 2020. A review of Coronavirus Disease-2019 (COVID-19). *The Indian Journal of Pediatrics*, 87, 281–286.
- Smith, L. N. 2018. A disciplined approach to neural network hyper-parameters: Part 1-- learning rate, batch size, momentum, and weight decay. *ArXiv Preprint arXiv:1803.09820*, 1-21.
- Tsiknakis, N., Trivizakis, E., Vassalou, E. E., Papadakis, G. Z., Spandidos, D. A., Tsatsakis, A., Sánchez-García, J., López-González, R., Papanikolaou, N., Karantanas, A. H., Marias, K. 2020. Interpretable artificial intelligence framework for COVID-19 screening on chest X-rays. *Experimental and Therapeutic Medicine*, 20(2), 727-735.
- Talo, M. 2019. Convolutional neural networks for multi-class histopathology image classification. *arXiv Preprint arXiv:1903.10035*, 1-16.
- Tuncer, T., Dogan, S. ve Ozyurt, F. 2020. An automated residual exemplar local binary pattern and iterative reliefF based COVID-19 detection method using chest X-ray image. *Chemometrics and Intelligent Laboratory Systems*, 203, 6.
- Wang, S., Kang, B., inlu Ma, Zeng, X., Xiao, M., Guo, J., Cai, M., Yang, J., aodong Li, Meng, X. ve Xu, B. 2020. A deep learning algorithm using CT images to screen for Corona virus disease (COVID-19). *European Radiology*, 31.
- Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M. ve Summers, R. M. 2017. ChestX-ray8: Hospital-scale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2097–2106.
- Xu, X., Jiang, X., Ma, C., Du, P., Li, X., Lv, S., Yu, L., Ni, Q., Chen, Y., Su, J., Lang, G., Li, Y., Zhao, H., Liu, J., Xu, K., Ruan, L., Sheng, J., Qiu, Y., Wu, W., Liang, T., Li, L. 2020. A deep learning system to screen novel coronavirus disease 2019 pneumonia. *Engineering*, 6(10), 1122–1129.