



T.C.

**BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**X-RAY GÖRÜNTÜLERİNDEN ALT SOLUNUM
YOLU ENFEKSİYONLARININ TEŞHİSİNDE
TRANSFER ÖĞRENME YÖNTEMLERİ VE
TOPLULUK ÖĞRENMEYE DAYALI YENİ BİR
YAKLAŞIM**

Berivan ÖZAYDIN

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Anabilim Dalı

**Haziran-2023
BATMAN
Her Hakkı Saklıdır**

TEZ KABUL VE ONAYI

Berivan ÖZAYDIN tarafından hazırlanan “X-RAY GÖRÜNTÜLERİNDEN ALT SOLUNUM YOLU ENFEKSİYONLARININ TEŞHİSİNDE TRANSFER ÖĞRENME YÖNTEMLERİ VE TOPLULUK ÖĞRENMEYE DAYALI YENİ BİR YAKLAŞIM” adlı tez çalışması 20/06/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Doç. Dr. Erdal BAŞARAN

Danışman

Doç.Dr. Ramazan TEKİN

Üye

Dr. Öğr. Üyesi Abidin ÇALIŞKAN

İmza

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Osman PAKMA
Lisansüstü Eğitim Enstitüsü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Berivan ÖZAYDIN

Tarih:

ÖZET
YÜKSEK LİSANS TEZİ

**X-RAY GÖRÜNTÜLERİNDEN ALT SOLUNUM YOLU
ENFEKSİYONLARININ TEŞHİSİNDE TRANSFER ÖĞRENME
YÖNTEMLERİ VE TOPLULUK ÖĞRENMEYE DAYALI YENİ BİR
YAKLAŞIM**

Berivan ÖZAYDIN

**Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik- Elektronik Mühendisliği Anabilim Dalı**

Danışman: Doç.Dr. Ramazan TEKİN

2023, 55 Sayfa

Juri

Doç.Dr. Ramazan TEKİN

Doç.Dr. Erdal BAŞARAN

Dr.Öğr.Üyesi Abidin ÇALIŞKAN

Günümüzde virüslerin neden olduğu hastalıklar büyük salgınlara neden olarak milyonlarca insanın hayatını etkilemektedirler. Bu virüslerin neden olduğu hastalıklardan bazıları alt solunum yolu enfeksiyonları olup bunlar arasında COVID-19 salgını Corona virüsünün neden son yılların en akut ve şiddetli virüslerinden birisidir. Virüs aşılı geliştirilmesine rağmen dünya genelinde COVID-19 vaka oranları hızla artmaktadır. COVID-19 ve diğer alt solunum yolları hastalıklarının teşhisi için yapay zekâ tekniklerinin de kullanıldığı görülmektedir. Özellikle derin öğrenme teknikleri klasik PCR testi ve X-ray görüntülerin manuel yorumlanmasına göre daha hızlı ve başarılı sonuçlar üretmektedir. Derin öğrenme olarak da bilinen derin yapılandırılmış öğrenme, yorumlamalı öğrenme, aktarılmış öğrenme gibi metotlar yapay sinir ağı tabanlı yöntemlerdir. Bu çalışmada 9 farklı transfer derin öğrenme metodu tabanlı topluluk sınıflandırıcılı hibrit bir model ile X-ray görüntüleri kullanılarak COVID-19 ve diğer alt solunum yolu enfeksiyonu hastalıklarının teşhisi gerçekleştirilmiştir. DeepFeat-E olarak isimlendirilen hibrit yaklaşım transfer modellerinden elde edilen derin öznitelikler ve klasik makine öğrenimi yöntemlerinden oluşan sınıflandırıcılar kullanılarak teşhis işlemi gerçekleştirilmektedir. Önerilen yaklaşımı test etmek için 10.192 Normal, 6012 Akciğer Opaklığı (COVID Dışı akciğer enfeksiyonu), 1345 Viral Pnömoni ve 3616 COVID-19 (Hasta) toplamda 21.165 X-ray görüntüsünden oluşan veri seti kullanılmıştır. Önerilen yaklaşım ile en yüksek başarı DenseNet201 TÖ (Transfer Öğrenme) modellerine ait derin öznitelikler ve İstifleme topluluk öğrenme yöntemiyle elde edildiği görülmüştür. Dört, üç ve iki sınıfa sahip veri seti ile yapılan deneysel çalışmalarda sırasıyla test doğruluğu %90,17, %94,99 ve %94,93 olarak elde edilmiştir. Ayrıca sistemin tüm TÖ modellerinde elde edilen doğruluk değerlerini değişen miktarlarda arttırdığı görülmüştür. Bu tez çalışması kapsamında elde edilen sonuçlara göre, önerilen DeepFeat-E isimli hibrit sistemin alt solunum yolu enfeksiyon hastalıklarının teşhisinde hızlı ve güvenilir bir şekilde kullanılabileceğini göstermiştir.

Anahtar Kelimeler: Alt solunum yolu enfeksiyonları, COVID-19, Topluluk Sınıflandırıcı, Transfer Öğrenme

ABSTRACT

MS THESIS

A NEW APPROACH BASED ON TRANSFER LEARNING METHODS AND ENSEMBLE LEARNING IN THE DIAGNOSIS OF LOWER RESPIRATORY TRACT INFECTIONS FROM X-RAY IMAGES

Berivan ÖZAYDIN

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
BATMAN UNIVERSITY**

**THE DEGREE OF MASTER OF SCIENCE
IN ELECTRIC AND ELECTRONIC ENGINEERING**

Advisor: Assof.Prof. Ramazan TEKİN

2023, 55 Pages

Jury

Assoc. Prof.Dr. Ramazan TEKİN

Assoc. Prof.Dr. Erdal BAŞARAN

Asst.Prof.Dr. Abidin ÇALIŞKAN

Today, diseases caused by viruses cause major epidemics, affecting the lives of millions of people. Some of the diseases caused by these viruses are lower respiratory tract infections, and the COVID-19 pandemic caused by the Corona virus is one of the most acute and severe viruses of recent years. Despite the development of virus vaccines, the rates of COVID-19 cases are increasing rapidly around the world. It is seen that artificial intelligence techniques are also used for the diagnosis of COVID-19 and other lower respiratory tract diseases. Especially deep learning techniques produce faster and more successful results than classical PCR testing and manual interpretation of X-ray images. Methods such as deep structured learning, interpretive learning, and transferred learning, also known as deep learning, are artificial neural network-based methods. In this study, COVID-19 and other lower respiratory tract infections were diagnosed using X-ray images with an ensemble classifiers hybrid model based on 9 different deep learning methods. The hybrid approach called DeepFeat-E performs diagnosis using deep features obtained from transfer models and classifiers consisting of classical machine learning methods. A dataset of 21,165 X-ray images in total of 10,192 Normal, 6012 Lung Opacity (Non-COVID lung infection), 1345 Viral Pneumonia and 3616 COVID-19 (Patients) were used to test the proposed approach. With the proposed approach, it was seen that the highest success was obtained with the deep features and Stacking ensemble learning method of DenseNet201 TL(Transfer Learning) models. In experimental studies with datasets with four, three and two classes, the test accuracy was 90.17%, 94.99% and 94.93%, respectively. In addition, it was observed that the system increased the accuracy values obtained in all DR models by varying amounts. According to the results obtained within the scope of this thesis study, it has been shown that the proposed DeepFeat-E hybrid system can be used quickly and reliably in the diagnosis of lower respiratory tract infectious diseases.

Keywords: Lower respiratory tract infections, COVID-19, Ensemble Classifier, Transfer Learning

ÖNSÖZ

Zorlu bir yüksek lisans eğitimi neticesinde danışman hocam Doç.Dr. Ramazan TEKİN önderliğinde, büyük bir emek sonucu bu çalışmayı gerçekleştirdik. Literatüre güzel bir katkı sağlayacağını düşündüğüm bu çalışmamda öncelikle emeği geçen Doç.Dr. Ramazan TEKİN'e, literatür araştırmasında yardımlarını esirgemeyen yakın arkadaşım Şehriban YILDIRIM'a sonsuz teşekkürlerimi sunarım. Ayrıca çalışmamda desteklerini hiçbir zaman eksik etmeyen, bana olan güvenlerini hiç kaybetmeyen aileme teşekkür ederim.

Berivan ÖZAYDIN
BATMAN-2023



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
ŞEKİLLER DİZİNİ.....	viii
TABLolar DİZİNİ	ix
SİMGELER VE KISALTMALAR	x
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	6
3. MATERYAL VE YÖNTEM.....	13
3.1. Materyal	14
3.2. Önerilen Hibrit Sistem	16
3.3. Transfer Öğrenme Yöntemleri	19
3.3.1. Xception Transfer Yöntemi	20
3.3.2. NaSNet Transfer Yöntemi	21
3.3.3. MobileNet Transfer Yöntemi.....	22
3.3.4. DenseNet Transfer Yöntemi	24
3.3.5. VGG Transfer Yöntemi	25
3.3.6. Inception (GoogleNet) Transfer Yöntemi.....	26
3.3.7. ResNet Transfer Yöntemi	28
3.4. Ekstra Ağaç Sınıflandırıcı ile Öznetelik Seçimi.....	29
3.5. Topluluk Öğrenme Yöntemleri.....	30
3.5.1. Oylama Topluluk Öğrenme	30
3.5.3. İstifleme (Stacking) Topluluk Öğrenme	31
3.6. Performans Ölçütleri.....	32
4. DENEYSEL ANALİZLER	34
4.1. Dört Sınıflı Analizler	34
4.2. Üç Sınıflı Analizler	37
4.2. İki Sınıflı Analizler	41
5. TARTIŞMA.....	45
6. SONUÇ	49
KAYNAKLAR	50
ÖZGEÇMİŞ	56

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 3.1. Önerilen hibrit sistemin aşamaları	13
Şekil 3.2. Veri setindeki dört sınıfa ilişkin örnek görüntüler	15
Şekil 3.3. Önerilen sistemin blok diyagram yapısı	18
Şekil 3.4. Xception modeli mimarisi	20
Şekil 3.5. NasNet Mimarisi	22
Şekil 3.6. Artık darboğaz bloğu	23
Şekil 3.7. MobilNet modeli mimarisi	24
Şekil 3.8. DenseNet ağı mimarisi	25
Şekil 3.9. VGG ağı mimarisi	26
Şekil 3.10. GoogleNet modülüne ait şematik yapı	27
Şekil 3.11. GoogleNet Ağı mimarisi	28
Şekil 3.12. ResNet Ağı Mimarisi	29
Şekil 4.1. TÖ modellere göre gruplandırılmış dört sınıflı test doğrulukları ve iyileştirme miktarları	36
Şekil 4.2. Dört sınıflı test veri seti için en iyi doğruluk karışıklık-matrisleri	37
Şekil 4.3. TÖ modellere göre gruplandırılmış üç sınıflı test doğrulukları ve iyileştirme miktarları	40
Şekil 4.4. Üç sınıflı test veri seti için en iyi doğruluk karışıklık-matrisleri	41
Şekil 4.5. TÖ modellere göre gruplandırılmış iki sınıflı test doğrulukları ve iyileştirme miktarları	43
Şekil 4.6. İki sınıflı test veri seti için en iyi doğruluk karışıklık-matrisleri	44

TABLÖLAR DİZİNİ

Tablo	Sayfa
Tablo 3.1: Eğitim ve test veri seti görüntü sayıları.	14
Tablo 3.2: Veri seti ile ilgili bilgiler	15
Tablo 3.3: COVID-19 veri seti oluşturulma web adresleri	15
Tablo 3.4: Kullanılan TÖ yöntemler ve derin öznitelikler.	16
Tablo 3.5: Karışıklık matrisi gösterimi	31
Tablo 4.1: TÖ modellerinin dört sınıflı eğitim ve test başarı değerleri.	35
Tablo 4.2: Derin Öznitelikler ve Topluluk sınıflandırıcıların dört sınıflı test başarı değerleri.	33
Tablo 4.3: Uygulamaların dört sınıflı test başarılarının karşılaştırması ve iyileştirme miktarları.	36
Tablo 4.4: TÖ modellerinin üç sınıflı eğitim ve test başarı değerleri.	38
Tablo 4.5: Derin Öznitelikler ve Topluluk sınıflandırıcıların üç sınıflı test başarı değerleri.	39
Tablo 4.6: Uygulamaların üç sınıflı test başarılarının karşılaştırması ve iyileştirme miktarları.	40
Tablo 4.7: TÖ modellerinin iki sınıflı eğitim ve test başarı değerleri.	42
Tablo 4.8: Derin Öznitelikler ve Topluluk sınıflandırıcıların iki sınıflı test başarı değerleri.	42
Tablo 4.9: Uygulamaların iki sınıflı test başarılarının karşılaştırması ve iyileştirme miktarları.	43
Tablo 5.1: COVID-19 ve alt solunum yolları hastalık teşhisi yapılan çalışmaların karşılaştırması	46

SİMGELER VE KISALTMALAR

ESA: Evrişimsel Sinir Ağları
TÖ: Transfer Öğrenme
BT: Bilgisayarlı Tomografi
MÖ: Makine Öğrenmesi
EAS: Ekstra Ağaç Sınıflandırıcı
DVM: Destek Vektör Makinesi
Knn: k-En Yakın Komşu
RO: Rastgele Orman
KA: Karar Ağaçları
NB: Naive Bayes
DP: Doğru Pozitif
DN: Doğru Negatif
YN: Yanlış Negatif
YP: Yanlış Pozitif

1. GİRİŞ

Virüsler, canlılarda hastalıklara neden olan gözle görülemeyecek kadar küçük olan ancak mikroskopla görüntülenen, çoğalmak için canlı bir yapıya ihtiyaç duyan organizmalardır. Büyüklükleri 0,02 ila 0,3 μm arasında değişmektedir (Hu ve ar.,2022). Virüs, yapısında bulunan replikasyonu (çoğaltmayı) başlatabilmek için gerekli olan enzimlere, RNA'ya veya DNA çekirdeğine ihtiyaç duyar. Çoğalmak için hayvan veya bitki hücrelerine ihtiyaç duyduklarından parazit olarak ifade edilirler. Virüsler nükleik asidin tek veya çift sarmallı olmasına, replikasyon tarzlarına veya bulunduğu aileye göre sınıflandırılırlar. Tarihte virüslerin sebep olduğu canlıların yok olmasına neden olduğu parazitler olmuştur. Çocuk felci ve çiçek hastalığı gibi hastalıklar insanlar üzerinde yıkıcı etkiye neden olmuştur (Ghrieb vd., 2022).

Günümüzde virüslerin neden olduğu hastalıklarla mücadele etmek zor bir görev olarak tanımlanmaktadır. Bunlardan biri olan COVID-19, bir alt solunum yolları enfeksiyon hastalığıdır. Bugüne kadar HCoV-229E, HCoV-HKU1, HCoV-OC43, HCoV NL63, şiddetli akut solunum sendromu koronavirüsü (SARS-CoV) ve Orta Doğu solunum sendromu koronavirüsü (MERS-CoV) dahil olmak üzere altı insan koronavirüsü (HCoV) tespit edilmiştir. Bunlar arasında SARS-CoV ve MERS-CoV geçmişte pandemiye neden olmuştur (Ilkhani vd., 2021).

Bronşit, KOAH, zatürre, akciğer hastalığına bağlı zatürre ve verem diğer alt solunum yolları hastalıklarıdır. Bronşit, bir alt solunum yolu akut enfeksiyonudur (Magrelli vd., 2021). Gelişmekte olan ülkelerde çocuk ölümlerinin önde gelen en önemli nedenlerden biri olduğu görülmektedir (Chen vd, 2020). Bronş zarlarının kalıcı olarak iltihaplanması ise KOAH olarak isimlendirilmektedir. KOAH özellikle kış aylarında görülen öksürük ve balgam attıran bir alt solunum yolu hastalığıdır (Alshmrani vd ,2023).

Verem hastalığı ise Mycobacterium tuberculosis mikrobun sebep olduğu bulaşıcı bir akciğer hastalığıdır (Alshmrani vd ,2023).

Bir diğer alt solunum yolları hastalığı olan Zatürre ise akciğer dokusunda meydana gelen enfeksiyonlardır. Zatürre çeşitli bakteri veya virüslerden kaynaklanıp sık görülen ve ciddi ölümlere neden olan bir hastalıktır. Teşhis için klinik bulgular gerekmektedir. Ancak klinik yöntemlerin duyarlılığı ve özgünlüğü yetersiz kalmaktadır. Bunun için X-ray gibi tıbbi görüntüleme teknikleri önerilmektedir (Magrelli vd., 2021). Hızlı klinik kararlar vermek için MR görüntüleme, göreceli güvenliği, taşınabilirliği,

tekrarlanabilirliği, maliyet etkinliği ve operatör konforu nedeniyle doktorlar ve radyologlar için en sık kullanılan görüntüleme teşhis araçlarından biridir.

COVID-19 alt solunum yolu hastalığına Corona virüsler neden olmaktadır. Corona virüsler, Coronaviridae ailesinin üyeleri olup solunum ve nörolojik hastalıklara neden olabilirler (Ilkhani vd., 2021). Son ve yeni şiddetli akut olarak adlandırılan koronavirüs ailesinin yeni virüsü COVID-19 üyesi dünya çapında milyonlarca insanı etkilemektedir. Dünya sağlık örgütü (WHO), Mart 2020'de ciddi akut solunum sendromuna neden olan bu virüsün neden olduğu salgını küresel bir salgın olarak ilan etti. COVID-19 pandemisi dünyanın en önemli salgınlarından biri olmuştur. Son yıllarda tüm dünyayı aynı anda etkileyen oldukça bulaşıcı olan bu viral patojenle tüm insanlık mücadele etmektedir. Bu viral patojen yani şiddetli akut solunum sendromu corona virüsü (Sars-Cov-2) dünya çapında yaklaşık 6.2 milyon ölüm ve 500 milyonun üzerinde enfeksiyon vakasına neden olmuştur (Abir vd., 2022). Sağlık ve teknoloji alanında ilerlemelere rağmen pandemiye karşı insanlık önemli bir sınav vermektedir. Milyonlarca insanın yaşam ve çalışma koşulları, farklı mesafe koşulları ve karantinalar yüzünden bozuldu.

COVID-19 alt solunum yolu enfeksiyonu hastalığına ait ilk vaka Çin'in Wuhan şehrinde kayıt edildi (Kumari vd., 2021; Pang vd., 2020; Khan vd., 2021) ve son yüzyılın yaygın pandemisi olarak kabul edilmektedir. Dünya genelinde bu kadar vaka sağlık çalışmaları üzerinde çok büyük bir yük oluşturmaktadır. Virüsün etkisi hala sürüp yeni vakalar ve ölümler devam etmektedir. Birbirleri ile yakın temasta olan kişiler arasında solunum damlacıkları ile kolayca bulaşan virüs bulaştığı kişilerde 2-14 gün arasında belirti göstermeye başlamaktadır. Uzun kuluçka dönemi, virüsü taşıyan insanların virüsü taşıdıklarını fark edinceye kadar rutin günlük yaşamlarına devam ederken, diğer insanlarla etkileşime girmektedirler. Bunun sonucu olarak, daha fazla enfeksiyona yol açan bu durum COVID-19'u daha bulaşıcı hale getirmektedir (Ilkhani vd., 2021). COVID-19, genellikle akciğerler gibi alt solunum sistemini etkiler ve zatüre benzeri semptomlara da neden olduğu görülmektedir. Bu nedenle, enfeksiyonun yayılmasının düzenlenmesi için özellikle kişiler arasında mesafe, maske takma ve enfekte hastayı karantinaya alma gibi önleyici tedbirler önerilmektedir (Lewnard vd., 2020). COVID-19'un ilk semptomlarının çoğu soğuk algınlığı veya gribe benzerdir. Bu durum COVID-19 vakalarının ilk evre tespitini zorlaştırmaktadır (Lewnard vd., 2020). COVID-19 enfeksiyon oranlarını azaltmak için özel aşılar geliştirilmiştir. Ancak birçok yoksul ülkenin aşıya ulaşımının

zorluğu ve yeterli aşılamanın yapılamaması yüzünden enfeksiyon dalgaları veya dalgalanmaları hala yaşanmaktadır. İnsanların çoğunda hafif ve orta dereceli semptomlarla, hastaneye yatış gerektirmeden geçmektedir. Baş ağrısı, vücut ağrıları, ateş COVID-19'un ve diğer alt solunum yolları enfeksiyon hastalıklarının yaygın ilk belirtileridir. Bunun yanında halsizlik, iştahsızlık, göğüste ağırlık, kuru balgam gibi solunum problemleri yüzünden nefes alma zorlukları görülmektedir. Akut solunum sıkıntısının fazla ilerlemesi durumunda sitokin solunum sendromuna sebep olmakta ve çoklu organ yetmezliği ve ölüm gibi sonuçlar gerçekleşebilmektedir (Wang vd., 2020).

COVID-19, özellikle diyabet, kardiyovasküler, astım gibi kronik hastası olan kişilerde bu virüs çok tehlikeli olmaktadır. Bunun yanında vaka sayılarındaki büyük boyutlar nedeniyle ülke ekonomilerinde de ciddi sorunlar oluşturmaktadır (Wang vd., 2020). Bununla beraber yasaklayıcı düzenlemeler ve fiyatlar nedeniyle sağlık sistemlerine sınırlı erişime sahip ülkeler veya özel sağlık sistemleri sınırlı olan ülkelere finansal sorunları da beraberinde getirmektedir. COVID-19'un presemptomatik enfeksiyon oranı, viral bulaşma süresi ve farklı ülkelerdeki özelliklerin değişkenliği, pandeminin daha öngörülemez kılmakta ve kontrol altına alınmasını zorlaştırmaktadır (Abir vd., 2022). COVID-19'u kontrol altına almayı başarmak, taşıyıcıların tespit edilmesi ve karantinaya alınmasının yanında sık test edilmelerine bağlıdır. Bu hastalığının hızlı ve doğru tespiti, virüsün yayılmasını yavaşlatmak ve hassas grupların hayatını kurtarmak için kritik bir öneme sahiptir. Hastalardan boğaz ve burun örnekleri alınarak polimeraz zincir reaksiyonu (PCR) testi ile COVID-19 ve diğer alt solunum yolları enfeksiyon hastalıkları tespit edilebilmektedir (Wang vd., 2020). Ancak bu test kitleri yeterli güvenilirlikte olmadığından alt solunum yolu sorunlarını tespit etmek için alternatif hızlı yöntemlere ihtiyaç duyulmaktadır. Günümüzde yapay zekâ ve özellikle de derin öğrenme yöntemleri COVID-19 ve benzeri alt solunum yolları hastalıkların teşhisinde güvenilir bir şekilde kullanılmaktadır (Verma vd., 2022).

Bununla birlikte, çeşitli sektörlerden araştırmacılar, alt solunum yolları enfeksiyonların teşhisi, takibi, iyileştirme amaçlı çalışmalar gerçekleştirmişlerdir. Kısa sürede etkili aşılarda keşfi, dijital teknolojileri kullanan pandemi yönetiminde iyileştirme de dahil olmak üzere mevcut teknolojilerimizi etkin bir şekilde kullanarak bu salgınla mücadele etmek için çeşitli çalışmalar gerçekleştirilmiştir. Son gelişmelerde makine öğrenmesi (MÖ) ve özellikle derin öğrenme metotları tabanlı geliştirilen karar destek sistemleri alt solunum yolları enfeksiyonlarının teşhisi için yoğun bir şekilde

kullanılmaktadır. Genel olarak Evrişimsel Sinir Ağı (ESA) veya TÖ yöntemleri kullanılmaktadır (Khan vd., 2021). Alt solunum yolları hastalıkların teşhisi için X-ray ve Bilgisayarlı Tomografi (BT) görüntüler kullanan karar destek sistemleri teşhis işlemini kolay ve hızlıca gerçekleştirmektedir (Khan vd., 2020; Shetty vd., 2021). COVID-19 teşhisi konulmuş hastaların akciğerlerindeki enfeksiyon yayılımının takibi için sıklıkla X-ray görüntüleri kullanılmaktadır (Wang vd., 2021). Hasta sayısının yüksekliği ve manuel analizi göğüs röntgeni görüntülemesi radyologlar üzerinde önemli bir yük oluşturmuştur. Bu nedenle, alt solunum yolları enfeksiyonunun hızlı taranması ve zamanında iyileşme için yapay zekâ tabanlı karar destek sistemleri geliştirmeye ihtiyaç duyulmaktadır. Yapay zekanın bir alt alanı olan Derin Öğrenme ve özellikle de TÖ modelleri görüntülerden alt solunum yolları enfeksiyon türü tespiti ve takibi ile ilgili uygulamalarda yoğun bir şekilde kullanılmaktadır (Sarkar vd., 2018). Bunun yanında yapay zekâ sistemleri, dudak okuma uygulamalarından (Tung ve Tekin, 2022), doküman dili (Noyan vd., 2022) ve hareket tanımayla (Kuncan vd., 2022), Epileptik nöbet (Kaya ve Tekin, 2018) ve kalp rahatsızlıklarının tespitine (Kaya vd., 2022) kadar çok geniş alanda da başarılı bir şekilde uygulanabilmektedir. Benzer şekilde COVID-19 teşhisinde, öksürük sesine (Sobahi vd., 2022; Ren vd., 2022) ve özellikle de göğüs görüntülerine (X-Ray ve BT tarama) dayalı yapay zekâ sistemleri yaygın bir şekilde kullanılmaktadır (Ahamed vd., 2021; Ozcan, 2021).

Bu amaçla bu çalışmada, COVID-19 ve diğer alt solunum yolu enfeksiyonlarının teşhisi için DeepFeat-E isimli hibrit bir yapay zekâ sistemi önerilmiştir. Önerilen sistem, belirli bir ön-eğitilmiş (pre-trained) TÖ modelinden elde edilen derin öznitelikler ve eğitim veri setine ait bu öznitelikler kullanılarak 14 farklı MÖ yöntemi arasından 10 katlı çapraz-doğrulama sonucuna göre en iyi başarıyı (UAC (Under Area Curve'a göre) veren ilk 5 yöntem seçilmiştir. Önerilen yöntem seçilen en başarılı beş Makine Öğrenme (MÖ) yönteminin topluluk öğrenme algoritmalarında sınıflandırıcı olarak kullanılması esasına dayanmaktadır. Hesaplama maliyetini düşürmek amacıyla derin öznitelikler kullanılmadan önce Ekstra Ağaç Sınıflandırıcı (EAS) yöntemiyle indirgenmiştir. Daha sonra indirgenmiş öznitelikler 10-kat çapraz doğrulama sonucuna göre seçilen en iyi beş MÖ yöntemi uygulanmıştır. Bu sınıflandırıcıların nihai kararları İstifleme, Yumuşak ve Katı oylama topluluk öğrenme yöntemleri kullanılarak elde edilmiştir. Önerilen hibrit modelin performansı, 10.192 Normal, 6012 Akciğer Opaklığı, 1345 Viral Pnömoni ve 3616 COVID-19 olmak üzere toplam 21.165 göğüs X-Ray görüntüsü içeren açık erişimli

olduka geniř bir veri seti kullanılarak analiz edilmiřtir. TÖ modellerinin veri setine dođrudan uygulandıđı ve önerilen hibrit sistem kapsamında üç topluluk öğrenme yöntemine göre ayrı ayrı uygulandıđı dört farklı uygulama gerçekleştirilmiřtir. Her bir uygulamada ayrı ayrı iki sınıflı (COVID-19 ve Normal), üç sınıflı (COVID-19, Viral-Pnömoni ve Normal) ve dört sınıflı (COVID-19, Akciđer-Opaklıđı, Viral-Pnömoni ve Normal) uygulamalar gerçekleştirilmiřtir.



2. KAYNAK ARAŞTIRMASI

Bu bölümde X-ray, BT görüntülerinden COVID-19 ve diğer alt solunum yolları enfeksiyon hastalıklarının teşhisi ile ilgili çalışmalar özetlenmiştir. Özellikle derin öğrenme tabanlı çalışmalar verilmiştir. COVID-19, verem, zatürre, bronşit gibi alt solunum yolları hastalıkları ile ilgili çalışmalar üzerinde odaklanmıştır.

COVID-19 pandemisi, benzeri görülmemiş insan hayatı kaybı, büyük ekonomik ve finansal aksilikler ile modern tarihin en ölümcül olaylarından biri haline geldi ve tüm dünyayı birkaç on yıl geriye götürdü. Bununla birlikte, virüsün mutasyona uğrayan doğası ve asemptomatik vakalardaki artış nedeniyle COVID-19 virüsünün tespiti giderek zorlaştı. COVID-19 teşhisi için farklı yaklaşımların kullanıldığı görülmektedir. Bu bölümde başta topluluk sınıflandırma yöntemine dayalı çalışmalar olmak üzere COVID-19 teşhisi ile ilgili güncel derin öğrenme mimarisine sahip çalışmalar sunulmuştur. Literatüre bakıldığında çok fazla çalışmanın olduğu görülmektedir. Araştırmacılar genellikle kendi küçük boyutlu veri setleri ile birlikte transfer yöntemler veya iyileştirilmiş (Fine-Tuning) transfer yöntemleri tercih etmişlerdir (Gilanie vd., 2021; Subramanian vd.,2022). Bu yaklaşımların ön-eğitilmiş modellerini kullanmak, eğitimleri için gerekli etiketlenmiş veri seti ihtiyacını ve eğitim sırasında gerekli fiziki kaynaklar ihtiyacını azaltır (Basu vd., 2022). Literatürde COVID-19 teşhisi ile ilgili oldukça fazla çalışma yer almaktadır. Aşağıda, bu çalışmanın da odak noktalarından biri olan topluluk öğrenme yöntemleri başta olmak üzere derin öğrenme temelli yöntemler içeren çalışmalar sunulmuştur.

Chowdhury vd., (2020) yaptıkları çalışmalarında 16493 X-Ray görüntüden oluşan bir veri seti kullanarak COVID-19'u tespit etmek için ECOVNet adlı EfficientNet'e dayalı bir derin ESA topluluğu önermişlerdir. Bu yöntem, ön-eğitilmiş EfficientNet'e eklemlenmiş bir ESA mimariye sahiptir. Önerilen model kullanılarak birkaç eğitim tahminine ait anlık görüntüler topluluk sınıflandırıcıya girilmektedir. Çalışmada COVID-19, normal ve pnömoniye ait örnekler içeren X-Ray görüntüler kullanılmış ve üç sınıflı en yüksek doğruluk 97% olarak elde edilmiştir.

Bir diğer çalışmada Mahmud ve arkadaşları (Mahmud vd., 2020), ESA tabanlı CovXNet isimli bir mimari önermişlerdir. Çalışmalarında CovXNet isimli bu mimarinin farklı formların ait tahminler bir arada istifleme topluluk sınıflandırıcı yöntemle değerlendirilmiştir. Çalışmada yapılan uygulamalarda, iki sınıflı (COVID-19/Normal),

üç sınıflı (COVID-19, Viral ve bakteriyel pnömoni) ve çok sınıflı (COVID-19, normal, Viral ve bakteriyel pnömoni) için sırasıyla 97,4%, 89,6% ve 90,2% başarı elde edilmiştir.

Karim vd. (2020) tarafından yapılan bir diğer çalışmada, DenseNet, ResNet ve VGGNet mimarilerinin eğitimi ve eğitilmiş modellerin anlık görüntüleri kullanılarak oluşturulan Softmax sınıfı sonsal ortalama (SCPA) ve tahmin maksimizasyonu (PM) topluluklarına dayanan bir model önerilmektedir.

Tang vd. (2021), EDL-COVID isimli derin öğrenme ve topluluk öğrenme temelli hibrit bir model önermişlerdir. EDL-COVID modeli, COVID-19 tespiti için geliştirilmiş olan COVID-Net isimli mimariye ait birden çok anlık görüntü modelini ağırlıklı ortalama yöntemine dayalı olarak topluluk sınıflandırıcıda kullanılmaktadır. Çalışmada COVID-19, normal ve pnömoniyeye ait örnekler içeren X-Ray görüntüler kullanılmış ve üç sınıflı için test doğruluğu 95% olarak elde edilmiştir.

Banerjee vd. (2022) yaptıkları çalışmalarında, DenseNet-201 mimarisine sahip bir modelin tek bir eğitim sürecindeki lokal minimum noktalardan ağır anlık görüntülerini çekerek topluluk yapısına sahip bir model geliştirmişlerdir. Topluluk sınıflandırıcı olarak harmanlama (Blending) yöntemini ve meta-model olarak Rastgele Orman (RO) yöntemini kullanmışlardır. Çalışmada biri büyük sayıda diğeri düşük sayıda X-Ray görüntülerden oluşan üç kategoriye (COVID-19, Pnömoni, ve Normal) sahip iki farklı veri seti kullanılmıştır. Önerilen modelin büyük ve küçük veri setlerinde üç sınıf için doğruluk değerleri sırasıyla 94,55% ve 98,13% olarak elde edilmiştir.

Gour ve Jain (2022) yaptıkları çalışmada, Xception ve Vgg19 tabanlı yeni bir yığın evrişimli sinir ağı modeli önermişlerdir. Önerilen yaklaşımda, eğitim sırasında VGG19 ve Xception modellerinden elde ettikleri alt-modelleri softmax sınıflandırıcı ile stack (yığın) yöntemine göre topluluk sınıflandırıcı olarak kullanmışlardır. Çalışmada iki kategoriye (COVID-19 ve Normal) sahip BT ve üç kategoriye (COVID-19, Pnömoni ve Normal) sahip X-Ray görüntüler kullanılmış olup sırasıyla 98,30% ve 97,27% doğruluk başarıları elde edilmiştir.

COVID-19 teşhisinde, topluluk sınıflandırıcı temelli çalışmaların yanında TÖ ya da özgün evrişimsel mimarilere dayalı modellerinde literatürde yoğun bir şekilde kullanıldığı görülmektedir. Apostolopoulos ve Mpesiana (Apostolopoulos ve Mpesiana, 2020) X-ray görüntüleri üzerinde VGG, Inception, MobileNet gibi bazı derin mimarileri incelemişlerdir. Çalışmada, COVID-19, pnömoni ve normal kategorisine sahip X-Ray görüntülerinden oluşan bir veri kümesi kullanılmıştır. TÖ modelleri arasında en yüksek

doğruluk 3 sınıf ve 2 sınıf için sırasıyla 93,48% ve 98,75% ile VGG19 model ile elde edildiği ifade edilmiştir.

Ozturk vd. (2020) COVID-19 teşhisi için ham X-ray görüntüleri kullanılarak otomatik COVID-19 tespiti için CovidDarkNet isimli yeni bir model önermişlerdir. YOLO (You Only Look Once) gerçek zamanlı nesne algılama sistemi için bir sınıflandırıcı olarak kullanılan CovidDarkNet isimli model 17 evrimsel katman içermektedir. Bu çalışmada önerilen yöntem, iki sınıflı (COVID-19 ve Normal) ve üç sınıflı (COVID-19, Normal, Pnömoni) veri setlerine uygulanmıştır. İkili ve üçlü sınıflar için sırasıyla 98,08% ve 87,02% sınıflandırma doğruluğu elde edilmiştir.

Khan vd. (2020), X-ray görüntülerden COVID-19 teşhisi için Xception mimarisine dayalı CoroNet isimli bir derin evrimsel sinir ağı modeli önermişlerdir. Önerilen model, ImageNet veri kümesi üzerinde önceden eğitilmiş Xception mimarisine dayanmaktadır. Önerilen modelle 4, 3 ve 2 sınıflı veri setlerinde sırasıyla 89,5%, 94,59% ve 99% doğruluk elde edilmiştir.

Huang ve Liao (2022) çalışmalarında, InceptionV3, ResNet50V2, Xception, DenseNet121, MobileNetV2, EfficientNet ve EfficientNetV2 transfer yöntemlerini kullanarak COVID-19 teşhisi gerçekleştirmişlerdir. Çalışmada ayrıca LightEfficientNetV2 isminde yeni bir mimari de önermişlerdir. Uygulamalar üç kategoriye sahip X-Rays ve BT görüntülerden oluşan 2 farklı veri seti üzerinde gerçekleştirilmiştir. X-Ray ve BT görüntülerde üç sınıflı en yüksek doğruluk sırasıyla 98,33% ve 97,48% ile LightEfficientNetV2 modelde elde edilmiştir.

Benzer şekilde Ahamed vd. (2021) çalışmalarında, X-Ray ve BT görüntülerden oluşan veri setleri ile COVID-19 tespiti için modifiye edilmiş bir ResNet50V2 mimarisi geliştirmişlerdir. Çalışmada kullanılan veri setleri COVID-19, Normal, viral pnömoni ve bakteriyel pnömoni olmak üzere dört sınıf içermektedir. Önerilen model kullanıldığında, dört (COVID-19/Normal/Bakteriyel pnömoni/Viral pnömoni), üç (COVID-19/Normal/Bakteriyel pnömoni) ve iki (COVID-19/Viral pnömoni) sınıflı X-Ray görüntülerde sırasıyla 96,45%, 97,24% ve 98,95% doğruluk elde edilmiştir. BT görüntülerde ise, üç (COVID-19/Normal/Pnömoni) ve iki (Normal/ COVID-19) sınıflı görüntülerde sırasıyla 99,01% ve 99,99% doğruluk elde edilmiştir.

Islam vd. (2022) yaptıkları çalışmada, BT ve X-ray görüntülerden COVID-19'un teşhis için Cov-RADNet isimli yeni bir evrimsel sinir ağı modeli önermişlerdir. Bu çalışmada kullanılan ilk veri seti COVID-19, viral pnömoni, akciğer-opaklığı ve normal

olmak üzere dört kategoriye sahip X-Ray görüntülerden oluşmaktadır. Diğer veri seti BT ise COVID-19 ve Non-COVID-19 kategorilerine sahip görüntüler içermektedir. Önerdikleri modelin X-Ray görüntülerde dört sınıf (COVID-19, Viral Pnömoni, Akciğer-Opaklığı ve Normal), üç sınıf (COVID-19, Viral Pnömoni, Normal) ve iki sınıf (COVID-19 ve COVID-olmayan) için tahmin doğruluğu sırasıyla 97%, 99,5% ve 99,72% olarak elde edilmiştir. BT görüntülerde ise tahmin doğruluğu 99.25% olarak elde edilmiştir.

Koronavirüs ve diğer alt solunum enfeksiyon hastalıkları milyonlarca insanın ölümüne ve insanlık üzerinde olumsuz fiziksel ve zihinsel bir tahribat oluşturdu. İnsanoğlu, benzeri virüs pandemilerine karşı yapay zeka tabanlı teşhis algoritmaları ile hazır olmalıdır.

Hopstaken vd. (2004) verem hastalığının tespiti için göğüs röntgen görüntüleri kullanmışlardır. Sağlıklı ve verem hastası olan görüntülerin birbirinden ayrıştırılması için Kappa gibi istatistiksel ölçütlerinden faydalanmışlar. Elde ettikleri başarı verem hastalığının tespiti %59, sağlıklı kişilerin tespiti ise %95 olarak rapor etmişlerdir. Ortalama başarı oranları ise %77 olarak gözlenmiştir.

Syrjala vd. (2017) ise yetişkinlerde alt solunum yolu enfeksiyonunun teşhisinde MR görüntülerin kullanılabileceğini tespit etmek için 7 gün boyunca ateşi 37,8 üzerinde hastalardan elde edilen akciğer MR görüntüleri kullanmışlardır. 77 hastadan elde edilen görüntüler ile %93.8 duyarlılık ve %97.8 özgüllük gözlenmiştir.

Srivastava vd. (2022)'nın çalışmalarında X-ray görüntüleri kullanılarak InceptionV3 ve EfficientNet transfer yöntemler ile COVID-19 teşhisi gerçekleştirmişlerdir. Çalışmalarında ayrıca 15 katmandan oluşan ESA tabanlı CoviXNet modelini önermişlerdir. Önerdikleri model ile ikili sınıflandırmada %99.47 ve 3-sınıfta %96.61'lik bir başarı elde etmişler.

COVID-19'un ekonomi üzerindeki yıkıcı etkilerinden dolayı pozitif vakaların hızlı teşhis edilmesi önemli olmaktadır. PCR testi hız, maliyet ve güvenilirlik açısından yetersiz kalan bir COVID-19 testidir. Bunun yerine X-ray veya BT görüntüleri kullanmak yapay zeka tabanlı sistemler üzerinde daha güvenli olmaktadır. Verma vd., (2022) VGG16 derin transfer yönteminin son katmanından elde edilen derin öznitelikleri Destek Vektör Makinesi (DVM) modeline giriş olarak vererek COVID-19 teşhis etmeye çalışmışlardır. Önerdikleri bu yaklaşımı CovXmle olarak isimlendirmişlerdir. Bu yaklaşım ile %95 gibi bir başarı elde edildiği raporlanmıştır.

Gupta vd. (2022) yaptıkları çalışmalarında, COVID-19 teşhisi için kapsül ağırları tabanlı COVID-WideNet isimli bir model önermişlerdir. Önerdikleri model diğer ESA tabanlı modellere göre 20 kat daha az eğitilebilir parametreye sahip olduğunu dolayısıyla daha hızlı olduğunu belirtmişlerdir. Çalışmalarında %91 gibi bir başarı rapor etmişlerdir. COVID-19'un hızla patlak vermesi, insanların büyük bir bölümünün yaşamını ve geçim kaynaklarını etkilemiştir. Bu nedenle, bu virüsün hızlı yayılmasını sınırlamak için COVID-19'un erken tespiti son derece önemlidir. COVID-19 teşhis edilmesinde X-ray görüntülerin kullanılması yaygın bir şekilde tercih edilmektedir. Son zamanlarda X-ray görüntüleri üzerinde yapay zeka tabanlı sistemler kullanılmaktadır.

Dey vd. (2022)'nin çalışmasında ESA ağı tam bağlantılı (Fully Connected) katmanından bir önceki katmandan elde edilen derin öznitelikler LSTM ile sınıflandırma işlemi gerçekleştirilmiştir. Önerdikleri yaklaşımı VGG19, InceptionV3 ve MobileNet ile test etmişlerdir. Modelin çıkış aşamasında Sugeno bulanık integral tabanlı ensemble yöntemi ile karar işlemi gerçekleştirilmiştir ve %98,62 başarı rapor edilmiştir.

Breve (2022), yaptığı çalışmada tüm dünyada topladığı 16352 X-ray görüntüleri üzerinde 21 farklı derin TÖ yöntemi uygulamıştır. Derin transfer yöntemler topluluk modeller olarak kullanılmıştır. Yöntemlerin ensemble olarak kullanılması tek tek kullanılmasından daha başarılı sonuçlar oluşturmuştur. Ensemble modelin başarısı %99,25 olarak rapor edilmiştir.

COVID-19 pandemisi tüm dünyaya bir salgın durumunda mücadele anlamında önemli tecrübeler kazandırdı. Bir virüsün erken teşhisi yayılımını kesmek için önemli olmaktadır. COVID-19 pandemisi ile mücadelede yapay zeka sistemlerin başarısı göz ardı edilemeyecek kadar büyüktür. Benzer salgınlarda bu tür sistemler kullanılmaya devam edilecektir.

Sani ve Sehermeh (2022), yaptıkları çalışmada COVID-19 teşhisini BT görüntülerden Hopfield sinir ağı kullanarak gerçekleştirmişlerdir. Kullandıkları veri setleri için önerdikleri yöntem ile %98.5 başarı oranı rapor edilmiştir.

COVID-19 pandemisinin yayılımını engellemek için hızlı teşhis yöntemlerine ihtiyaç duyulmaktadır. Son zamanlarda yapay zeka sistemlerinden yararlanıldığı görülmektedir. Özellikle derin öğrenme tabanlı sistemler yaygın bir şekilde kullanılmaktadır. Bazı çalışmalarda derin öğrenme metotları yerine geniş öğrenme metotlarının da kullanıldığı görülmektedir. Derin öğrenme metotları veri setinin yeterli büyüklükte olmaması durumunda ağırlarda ezberleme (overfitting) sorunları meydana

gelmektedir. Bunun yanında derin öğrenme metotları öğrenme sürecinde zaman almaktadır.

Wu ve Duan (2022), COVID-19 teşhisi için geniş öğrenme tabanlı yeni bir yaklaşım önermişlerdir. Giriş verileri yeniden yapılandırılarak temsili girişler ile yeni bir işbirlikçi-rekabetçi temsil tabanlı otomatik kodlayıcı (CCRAE) ve buna bağlı işbirlikçi-rekabetçi geniş öğrenme sistemi (CCBLS) önermişlerdir. Önerilen yaklaşımı BT görüntüler ile COVID-19 teşhisi gerçekleştirmişlerdir. 3 farklı veri seti üzerinde yaptıkları denemelerde %84,73-%91,56 arasında başarı rapor etmişlerdir. X-ray ve BT görüntülerini analiz eden yöntemlerin yanında COVID-19 hastası kişilerden elde edilen öksürük seslerinden de teşhis işlemi gerçekleştiren sistemler de geliştirilmiştir.

Ren vd. (2022) yaptıkları çalışmada, COVID-19 teşhisi için öksürük sesleri kullanmışlardır. Ses sinyallerinden elde edilen akustik öznelikler ile teşhis işlemi gerçekleştirmişlerdir. Ses sinyallerinden istatistiksel, Mel-frekans kestral katsayıları gibi öznelikler çıkarılmıştır. Çalışmada %87 başarı rapor edilmiştir.

COVID-19 tanısında kullanılan PCR testinin sonuçlanması sırasında hasta karantinaya alınmadığı için hastalık yayılmaya devam ediyor. Bu nedenle hızlı karar sistemlerine ihtiyaç duyulmaktadır. Oğuz ve Yağanoğlu (2022), yaptıkları çalışmada ResNet-50, ResNet-101, AlexNet, Vgg-16, Vgg-19, GoogLeNet, SqueezeNet ve Xception transfer derin öğrenme metotlarından elde ettikleri derin öznelikleri Destek Vektör Makinesi (DVM), k-En Yakın Komşu (Knn), Rastgele Orman (RO), Karar Ağaçları (KA), Naive Bayes (NB) gibi sınıflandırma yöntemlerine vererek COVID-19 teşhisi gerçekleştirmişlerdir. Siirt Eğitim ve Radyografi veri tabanından elde edilen 1345 BT görüntüsü üzerinde yaptıkları çalışmada en iyi model Resnet50+DVM olarak rapor edilmiştir ve %96.29 başarı elde edilmiştir. Aslan ve arkadaşları (2022)'nin çalışmasında transfer derin öğrenme metotları (AlexNet, ResNet18, ResNet50, Inceptionv3, Densenet201, Inceptionresnetv2, MobileNetv2, GoogleNet) için aktivasyon fonksiyonlarını Bayes optimizasyon yöntemi ile ayarlayarak en iyi sonucu bulmaya çalışmışlardır. X-ray görüntüler üzerinde uyguladıkları yöntem ile % 96,29 başarı oranı gözlenmiştir.

Başlangıçta SARS-CoV-2 olarak bilinen COVID-19 hastalığı, ilk olarak Aralık 2019'un başlarında rapor edildi ve küresel olarak insanlarda büyük hasara neden oldu. PCR testi COVID-19 için en yaygın kullanılan klinik tarama yöntemidir. Hastaların solunum örneklerini kullanır. Karmaşık, zahmetli ve çok güvenli olmayan bir yöntemdir.

Bunun yanında sağlık personeli için de büyük bir risk oluşturur. Bu yüzden hızlı teşhis sistemlerine ihtiyaç duyulmuştur. Dwivedy ve vd., (2022) COVID-19 teşhisi için ESA tabanlı LMNet denilen bir model önerdiler. Mevcut modellerden daha az karmaşık ve hesaplama maliyetine sahiptir. Model DenseNet169 ve MobileNetV2 transfer yöntemler ile karşılaştırılmış daha başarılı bulunmuştur. Çalışmalarında %98 başarı rapor edilmiştir. Buonsenso vd., (2022) çocuklarda alt solunum yolları hastalıklarını tespit etmek için X-ray ve klinik bulgular kullandılar. Toplamda 188 çocuk bilgilerini kullanarak istatistiksel yöntemler ile solunum hastalığının viral, bakteriyel veya atipik olduğu tespit edilmiştir. Bir diğer çalışmada Chen vd., (2020) çocuklarda farklı bronşit türlerinin sınıflandırılması için derin öğrenme metotları kullanmışlardır. Çocuklarda yaygın olmayan X-ray görüntüleri kullanılarak bronşit türü tespiti gerçekleştirilmiştir. Görüntülerden öncelikle akciğer tespiti için YoloV3 kullanılmış, daha sonra kırılan görüntüler kullanılarak ESA ile sınıflandırma işlemi gerçekleştirilmiştir. %92,47 başarı rapor edilmiştir.

Bhandari vd. (2022)'nin yaptıkları çalışmada X-ray görüntülerinden COVID-19, zatürre ve verem hastalıkları tespit edilmiştir. Transfer derin öğrenme metotları ile gerçekleştirdikleri teşhis işlemlerini SHAP, LIME ve GradCam ısı haritaları ile doğrulamışlardır. Yaptıkları çalışmada %94,54 başarı rapor edilmiştir.


Çelik (2023)'in yaptığı çalışmada COVID-19, Akciğer Opasitesi, Normal ve Viral Pnömoniye ait X-ray görüntüleri derin öğrenme metotları ile birbirinden ayrıştırılmıştır. Önerdiği CovidDWNNet+GB(Gradient Boosting) derin öğrenme mimarisi ile %96,32 başarı elde edilmiştir. CovidDWNNet ağı tekrar kullanılabilen artık bloğu ve derine genişlemiş konvolüsyonlar birimlerine dayanmaktadır. Bu birimler ile X-ray görüntülerinden daha etkin özneteliklerin elde edildiğini belirtmiştir.

Bir diğer çalışmada Alshmrani vd. (2023) göğüs X-ray görüntülerinden zatürre, akciğer kanseri, tüberküloz, akciğer opaklığı ve COVID-19 hastalıkları teşhis edilmiştir. Çoklu sınıflandırma gerçekleştirilmiştir. VGG19+ESA ile büyük bir veri seti üzerinde gerçekleştirildikleri çalışmada %96,48 başarı rapor etmişlerdir. Son olarak derin öğrenme metotlarının akciğer hastalıklarını teşhis etmeden insani müdahale olmadan X-ray görüntülerinden teşhis edebileceğini rapor etmişlerdir.

Sonuç olarak COVID-19 ve alt solunum yolları enfeksiyon hastalıklarının teşhisi ve tedavisi için yoğun bir şekilde çalışıldığı görülmektedir. Özellikle teşhis için X-ray ve BT görüntülerden derin öğrenme tabanlı çok fazla çalışmanın olduğu anlaşılmaktadır.

3. MATERYAL VE YÖNTEM

Bu çalışmada önerilen DeepFeat-E isimli hibrit modelde, TÖ modellerden elde edilen derin öznitelikler kullanılarak klasik makine öğrenme (MÖ) yöntemler ve topluluk sınıflandırıcılar yardımıyla COVID-19 ve diğer alt solunum yolları enfeksiyon hastalıkları teşhisi gerçekleştirilmektedir. Önerilen sistem Şekil 3.1’de gösterildiği gibi genel olarak dört temel aşamadan oluşmaktadır. Çalışmada kullanılan veri seti, dört kategoride (Normal, Akciğer Opaklığı, Viral Pnömoni ve COVID-19) toplamda 21.135 göğüs X-Ray görüntüsü içeren oldukça geniş bir veri seti olup bu veri seti Kaggle komitesi tarafından en iyi COVID-19 veri seti olarak seçilmiştir (Chowdhury vd., 2020).



Şekil 3.1. Önerilen hibrit sistemin aşamaları.

Aşama 1 (Önilem): İlk aşama olan önilem aşamasında, tüm görüntüler standart bir boyuta (224x224x3) getirildikten sonra; döndürme, ölçeklendirme, yatay/dikey öteleme, yatay çevirme, parlaklık ayarlama gibi yöntemlerle veri artırma gerçekleştirilmektedir. Ardından veri setinin 80%'i eğitim ve 20%'si test olmak üzere ikiye ayrılmakta ve sonraki aşamaya geçilmektedir.

Aşama 2 (Öznitelikler ve İndirgeme): İkinci aşamada, geçerli ön-eğitilmiş TÖ yönteminden eğitim ve test görüntülerine ait ayrı ayrı elde edilen derin öznitelikler indirgenmekte ve bir sonraki aşamaya aktarılmaktadır. Her TÖ modeli için bu aşama ayrı ayrı gerçekleştirilmektedir.

Aşama 3 (MÖ-Model Seçimi): Üçüncü aşamada, eğitim veri setine ait indirgenmiş derin öznitelikler kullanılarak en iyi beş MÖ yöntemi seçilmektedir. Seçim işlemi 10 çapraz doğrulama sonucunda AUC metriğine göre gerçekleştirilmektedir. Daha sonra seçilen en iyi beş MÖ model topluluk sınıflandırıcıda kullanılmak üzere sonraki aşamaya aktarılmaktadır.

Aşama 4 (Topluluk Sınıflandırıcı): Son aşama olan dördüncü aşamada, denemeler sonucunda en başarılı beş MÖ model kullanılarak geçerli topluluk öğrenme yöntemiyle tahminlemeler yapılmaktadır. Çalışma kapsamında kullanılan İstifleme

(Stacking), Yumuşak Oylama (Soft Voting) ve Katı Oylama (Hard Voting) topluluk öğrenme yöntemlerinin her biri için dört sınıflı, üç sınıflı ve iki sınıflı veri setleriyle bu aşama ayrı ayrı gerçekleştirilmiştir.

Bu çalışmada tüm uygulamalar, Python programla dili ile Tensorflow, Keras ve scikit-learn paketleri kullanılarak gerçekleştirilmiştir. Modeller ve analizler AMD Ryzen 7 5800H (16 CPU, ~3,2GHz) işlemciye, Nvidia GeForce RTX 3050 GPU (4GB GDDR6, ~1,5GHz) ve 16 GB RAM'e sahip bir kişisel bilgisayar üzerinde gerçekleştirilmiştir. Transfer öğrenme (TÖ) modellerinde hiper parametreler, grup büyüklüğü (batch size) 32 ve epok (epoch) değerleri 100 olarak seçilmiştir. EAS için orman içi ağaç sayısı 50 seçilmiş ve bölünmenin kalite ölçütü olarak ise GINI kullanılmıştır.

3.1. Materyal

Bu tez çalışmasında kullanılan veri seti farklı ülkelerden (Katar, Bangladeş, Pakistan vb.) bir grup araştırmacı tarafından toplanan COVID-19, Viral Pnömoni, Normal Akciğer Opaklığı ve Normal olmak üzere dört kategoriye sahip X-Ray görüntülerden oluşmaktadır (Chowdhury vd., 2020; Rahman vd., 2021). Çalışmada kullanılan “COVID-19 Radiography Dataset” isimli veri seti Kaggle üzerinden indirilebilir (<https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>). Veri seti çalışma grubu tarafından belirli aralıklarla güncellenmekte olup, bu çalışmada kullanılan son güncel halinde 10.192 Normal, 6012 Akciğer Opaklığı (COVID Dışı akciğer enfeksiyonu), 1345 Viral Pnömoni ve 3616 COVID-19 örneğin göğüs X-Ray görüntüsü bulunmaktadır (Rahman vd., 2020). Tablo 3.1’de veri setinin eğitim ve test veri setleri dağılımları gösterilmektedir.

Tablo 3.1: Eğitim ve test veri seti görüntü sayıları

Veri Seti	COVID-19	Akciğer-Opaklığı	Normal	Viral-Pnömoni
Toplam	3616	6012	10192	1345
Eğitim	2893	4809	8154	1076
Test	723	1203	2038	269

Farklı kaynaklardan alınarak oluşturulan veri setine ilişkin kategori, görüntü sayıları ve kaynak bilgileri Tablo 3.2’de verilmiştir. Literatürdeki benzer çalışmaların aksine veri setinde yer alan her bir kategoriye ilişkin görüntü sayıları eşitlenmemiştir. Fakat aşırı öğrenmenin önüne geçmek için döndürme, ölçekleme, yatay/dikey kaydırma,


yatay döndürme vb. veri artırma teknikleri uygulanmıştır. Veri setindeki görüntülere ait bilgiler Tablo 3.2’deki görüntülerin indirildiği adresler Tablo 3.3’te ve örnek görüntüler Şekil 3.2’de verilmiştir.

Tablo 3.2. Veri seti ile ilgili bilgiler

Görüntü	Görüntü Adet	Kaynak (Tablo 3 Satırları)
COVID-19	2473	1
COVID-19	183	2
COVID-19	559	2,3,5,6
COVID-19	400	7
Normal	8851	8
Normal	1341	9
Akciğer Opaklığı	6012	8
Viral Pnömoni	1345	9

Tablo 3.3. COVID-19 veri seti oluşturulma web adresleri

Kaynak	Web Adres Bilgisi
1	https://bimcv.cipf.es/bimcv-projects/bimcv-covid19/#1590858128006-9e640421-6711
2	https://github.com/ml-workgroup/covid-19-image-repository/tree/master/png
3	https://sirm.org/category/senza-categoria/covid-19/
4	https://eurorad.org
5	https://github.com/ieee8023/covid-chestxray-dataset
6	https://figshare.com/articles/COVID-19_Chest_X-Ray_Image_Repository/12580328
7	https://github.com/armiro/COVID-CXNet
8	https://www.kaggle.com/c/rsna-pneumonia-detection-challenge/data
9	https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia



Şekil 3.2. Veri setindeki dört sınıfa ilişkin örnek görüntüler. a) COVID-19, b) Akciğer-Opaklığı, c) Normal/Sağlıklı, d) Viral-Pnömoni.


3.2. Önerilen Hibrit Sistem

Çalışma kapsamında, ön-eğitilmiş TÖ mimarilerin doğrudan kullanıldığı topluluk öğrenmesiz ve üç farklı topluluk öğrenmeli tekniğin kullanıldığı toplamda dört farklı sistem için uygulamalar gerçekleştirilmiştir. Topluluk öğrenmeli sistemlerde ön-eğitilmiş TÖ mimarilerden elde edilen derin öznitelikler seçilen beş MÖ modeline girilerek İstifleme, Yumuşak ve Katı Oylama topluluk yöntemleriyle analiz edilmiştir. Her bir model için iki (COVID-19 ve COVID-olmayan), üç (COVID-19, Viral Pnömoni ve Normal) ve dört (COVID-19, Viral Pnömoni, Normal ve Akciğer-Opaklığı) sınıflı veri setleri oluşturularak ayrı ayrı analizler gerçekleştirilmiştir. Çalışma kapsamında kullanılan ön-eğitilmiş TÖ modeller Tablo 3.4’te listelenmiş olup uygulamalar her biri için ayrı ayrı gerçekleştirilmiştir. Önerilen sistemde topluluk sınıflandırıcı için seçilen en iyi beş MÖ yöntemi her bir TÖ için farklı olup dört sınıflı uygulamalara ait seçilmiş yöntemler başarı sırasına göre Tablo 3.4’te listelenmiştir. Tablo 3.4’te ayrıca her bir TÖ için parametre sayıları, indirgenmeden önce ve indirgenmeden sonraki derin öznitelik sayıları sunulmuştur.

Tablo 3.4. Kullanılan TÖ yöntemler ve derin öznitelikler.

S.NO	Model ismi	Seçilen MÖ yöntemi	Parametre Sayısı	Öznitelik Sayısı	İndirgenmiş Öznitelik sayısı
1	Xception (Chollet, 2017)	[lr, lda, xgb, lgbm, gb]	20,869,676	2048	550
2	NASNet (Zoph vd., 2018)	[lr, lda, xgb, lgbm, gb]	84,932,950	4032	1163
3	MobileNet (Howard vd., 2017)	[xgb, lgbm, lr, lda, gb]	3,232,964	1024	263
4	DenseNet169 (Huang vd., 2017)	[xgb, lda, lgbm, gb, lr]	12,649,540	1664	398
5	DenseNet201 (Huang vd., 2017)	[xgb, lgbm, lda, gb, rf]	18,329,668	1920	461
6	VGG16 (Simonyan ve Zisserman, 2014)	[xgb, lgbm, lr, lda, gb]	14,716,740	512	189
7	InceptionV3 (Szegedy vd., 2016)	[xgb, lr, lgbm, lda, gb]	21,810,980	2048	520
8	ResNet50V2 (He vd., 2016)	[xgb, lgbm, lr, lda, gb]	23,572,996	2048	508
9	ResNet101V2 (He vd., 2016)	[xgb, lgbm, lr, lda, gb]	42,634,756	2048	521

Topluluk öğrenmesiz ilk modelde, önerilen topluluk sınırlandırıcılı modelin performansını karşılaştırabilmek amacıyla eğitim ve test veri setlerine doğrudan TÖ modellerine uygulanmıştır. Çalışma kapsamında önerilen topluluk öğrenmeli yöntemlere dayalı DeepFeat-E isimli hibrit sisteme ait blok diyagram ise Şekil 3'te sunulmuştur. Şekil 3'te *Öznitelik Seçimi* bloğunda gösterildiği gibi ön-eğitilmiş TÖ modellerinin her birinden elde edilen derin öznitelikler çeşitli öznitelik seçim yöntemleri denenerek indirgenmiştir. En başarılı sonuçlar EAS ile elde edildiğinden bu öznitelik seçim yöntemiyle öznitelik seçimi yapılarak indirgendikten sonra sırasıyla İstifleme, Yumuşak Oylama ve Katı Oylama topluluk öğrenme teknikleriyle teşhis edilmiştir. Topluluk öğrenme modellerinde; Şekil 3.3'te *Model Seçimi* bloğunda gösterildiği gibi bilinen 14 farklı MÖ yöntemi arasından 10 katlı çapraz-doğrulama sonucuna göre en iyi başarıyı veren ilk 5 yöntem seçilmektedir. Seçilen MÖ yöntemler her bir TÖ modelinde öncelik sırası değişmekle birlikte lr (Logistic Regression), lda (Linear Discriminant Analysis), xgb (eXtreme Gradient Boosting), lgbm (Light Gradient Boosting Machine), gb (Gradient Boosting), rf (Random Forest) olduğu görülmektedir. Daha sonra seçilen bu beş en iyi MÖ yöntemi Şekil 3.3'te *Topluluk Öğrenme* bloğunda görüldüğü gibi sınıflandırıcı olarak kullanılmıştır.



Şekil 3.3. Önerilen sistemin blok diyagram yapısı.


3.3. Transfer Öğrenme Yöntemleri

Makine öğrenimi için transfer öğrenimi, önceden eğitilmiş bir modelin öğelerinin yeni bir makine öğrenimi modelinde yeniden kullanılmasıdır. İki model benzer görevleri yerine getirmek için geliştirilirse, aralarında genelleştirilmiş bilgi paylaşılabilir. Makine öğrenimi geliştirmeye yönelik bu yaklaşım, yeni modelleri eğitmek için gereken kaynakları ve etiketlenmiş veri miktarını azaltır. Makine öğrenimi algoritmaları, çeşitli sektörlerde karmaşık görevleri tamamlamak için kullanılıyor. Bir dizi farklı makine öğrenimi türü vardır, ancak en popüler süreçlerden biri denetimli makine öğrenimidir. Bu tür makine öğrenimi, modelleri eğitmek için etiketlenmiş eğitim verilerini kullanır. Veri kümelerini doğru bir şekilde etiketlemek uzmanlık gerektirir ve makinelerin eğitim süreci genellikle zaman alıcıdır. Transfer öğrenimi bu sorunlara bir çözümdür ve bu nedenle makine öğrenimi ortamında önemli bir teknik haline gelmektedir. Makine öğrenimi için transfer öğrenimi, mevcut öğrenmiş modellerin yeni bir problemde veya uygulamada yeniden kullanılmasıdır. Transfer öğrenimi, farklı bir makine öğrenimi algoritması türü değildir, bunun yerine modelleri eğitirken kullanılan bir teknik veya yöntemdir. Önceki eğitimden geliştirilen bilgi, yeni bir görevin gerçekleştirilmesine yardımcı olmak için geri dönüştürülür. Orijinal eğitilmiş model, genellikle yeni görünmeyen verilere uyum sağlamak için yüksek düzeyde bir genelleme gerektirir. Transfer öğrenimi, her yeni görev için eğitimin sıfırdan yeniden başlatılması gerekmediği anlamına gelir. Yeni makine öğrenimi modellerini eğitmek için hem kaynak yetersiz hem de zaman alıcı olabilir, bu nedenle transfer öğrenimi hem kaynaklardan hem de zamandan tasarruf sağlar. Büyük veri kümelerinin doğru şekilde etiketlenmesi de çok fazla zaman alır. Kuruluşların karşılaştığı verilerin çoğu, özellikle bir makine öğrenimi algoritmasını eğitmek için gereken kapsamlı veri kümeleriyle, genellikle etiketsiz olabilir. Transfer öğrenimi ile, bir model mevcut bir etiketli veri kümesi üzerinde eğitilebilir, ardından etiketlenmemiş verileri içerebilecek benzer bir göreve uygulanabilir (Aswathy vd.,2021). Makine öğrenimi için transfer öğrenimi, genellikle yeni bir görevi çözmek için bir sistemin eğitiminin çok büyük miktarda kaynak alacağı durumlarda kullanılır. Süreç, mevcut bir makine öğrenimi modelinin ilgili kısımlarını alır ve bunu yeni ancak benzer bir sorunu çözmek için uygular. Transfer öğreniminin önemli bir parçası genellemedir. Bu, yalnızca başka bir model tarafından farklı senaryolarda veya koşullarda kullanılabilecek bilgilerin aktarıldığı anlamına gelir. Modellerin bir eğitim veri kümesine sıkı sıkıya bağlı olması

yerine, transfer öğreniminde kullanılan modeller daha genelleştirilecektir. Bu şekilde geliştirilen modeller, değişen koşullarda ve farklı veri setleri ile kullanılabilir. Bu çalışmada Tablo 3.4’te listelenen dokuz TÖ modeli kullanılmıştır.

3.3.1. Xception Transfer Yöntemi

Xception modeli iki aşamalı olarak uygulanan derinlemesine iki evrişim işlemine dayanmaktadır. Bu evrişim işlemlerin ilki uzaysal evrişimde her bir giriş kanalı birbirinden bağımsız olarak evrişim işlemine tabi tutulur. Daha sonra noktasal evrişimde 1x1 filtreler kullanılarak noktadan noktaya evrişme işlemi gerçekleştirilmektedir. Xception modeli ayrılabilir evrişim katmanlarına dayanan bir evrişim sinir ağıdır. Xception modelinde amaç girişlerdeki farklı kanallar arasındaki uzamsal korelasyonları birbirinden ayırarak her bir kanal için bağımsız öznetelik haritaların oluşturulmasına dayanmaktadır. InceptionV3 transfer derin öğrenme modelinden esinlenmiş ve ismi ‘Extreme Inception’ ifadelerine dayanarak Xception şeklinde belirtilmiştir (Chollet, 2017). Bu aşamalar hem parametre sayısını azaltmak hem de hesaplama maliyetini düşürmek için kullanılır. Xception modeli mimarisi Şekil 3.4’de gösterilmiştir (Chen vd., 2021). Şekil 3.4’te görüldüğü gibi Xception modeli 14 artık katmandan oluşmaktadır. Bu model bir girdi katmanı, evrişim katmanı, tam bağlantı katmanı ve çıktı katmanını içerir. Bu modelde, evrişim katmanında doğrusal artıklar yoluyla bağlanan derinlikle ayrılabilir evrişim katmanları vardır. Özellik çıkarma ağı olarak Xception ağı kullanılır. İlk olarak, normalleştirilmiş girdi görüntüsü, özellik görüntüsünün uzamsal korelasyonunu ve kanal korelasyonunu işlemek için iki standart evrişim işlemiyle işlenir. Daha sonra, uzaysal ve kanal bilgilerini ayırmak için altı derinlikte ayrılabilir evrişim kullanılır.




Şekil 3.4. Xception modeli mimarisi (Chen vd., 2021)

Max-pooling katmanı, çıktı verilerinin boyutunu seçmek ve azaltmak için kullanılır. Son olarak, tam bağlantı katmanı, özellik değerlerinin sınıflandırılmasında kullanılır (Zhu vd., 2022).

3.3.2. NaSNet Transfer Yöntemi

Nöral Mimari Arama (Neural Architecture Search, NAS) transfer derin öğrenme ağı, Google MÖ grubu tarafından geliştirilmiştir. Ağ mimarisi pekiştirmeli öğrenmeye dayanmaktadır. Bu ağda, alt bloğun etkinliği üst blok tarafından gözden geçirilir ve bu değişikliklere göre ağ ayarlaması yapılır. Ağ mimarisi içinde bir ESA ve bir denetleyici tekrarlayan sinir ağı blokları bulunmaktadır (Nigam vd., 2021). NASNet mimari bloklarının şematik gösterimi Şekil 3.5'te gösterilmektedir. Ağdan en iyi performansı elde etmek için mimaride ağırlıklar, katmanlar, düzenlileştirme yöntemleri, optimize edici fonksiyonlar vb. gibi evrimsel algoritmalar ile çeşitli modifikasyonlar yapıldı. NasNet'in farklı mimarilerde NasNet-A, NasNet-B ve NasNet-AC gibi versiyonları da bulunmaktadır (Zoph vd., 2018). Ağda en kötü performans gösteren hücreler, turnuva seçim algoritmaları kullanılarak elenir. Mimarideki en küçük birim blok olarak bilinir ve bu blokların birleşimi hücre olarak bilinir. Ağın arama alanı, onu hücrelere bölerek ve ardından hücreleri bloklara bölerek yapılır. Hücre ve blok sayısı, veri kümesinin türüne göre belirlenir, sabit değildir. Bir blokta gerçekleştirilen işlemler konvolüsyonlar, havuzlama, haritalama vb.'dir.




Şekil 3.5. NasNet Mimarisi (Zoph vd., 2018)

3.3.3. MobileNet Transfer Yöntemi

Son yıllarda GPU ve CPU ‘da hızlanmalardan dolayı derin öğrenme metotları daha yaygın bir şekilde kullanılmaya başlanmıştır. Bunun yanında son zamanlarda, momentumlu stokastik gradyan inişi (SGDM) ve RMSprop gibi gelişmiş öğrenme algoritmaları ile ESA eğitimi daha hızlı ve başarılı kılınmıştır. Bu yüzden AlexNet, VGG, ResNet ve MobileNet gibi transfer derin öğrenme metotları geliştirilmiştir. Geleneksel MÖ metotlarına göre çok daha başarılı yöntemlerdir. Ancak ağlar derinleştikçe hesaplama maliyeti artmakta ve eğitim süreci için daha büyük veri setlerine ihtiyaç duyulmaktadır (Nan vd., 2022). Bu tür yöntemler çeşitli problemlerin çözümünde kullanılmıştır. MobileNet hesaplama maliyeti ile performans arasında bir denge sağlayarak eğitim işlemini gerçekleştirmektedir. Ayrılabilir evrişim (separable convolution) ve derinlikli evrişim (depthwise convolution) ile MobileNet’in sınıflandırma başarısı korunurken evrişim katmanlarının parametrelerini önemli ölçüde azaltmaktadır. Diğer bir deyişle karmaşık ve hesaplama maliyeti yüksek klasik evrişim katmanları yerine, her bloğun girişini filtreleyen 3×3 derinlikte evrişim katmanından ve ardından bu filtrelenmiş değerleri birleştiren 1×1 noktasal evrişim katmanından oluştuğu derinlemesine ayrılabilir evrişim bloklarını kullanmaktadır (Michele vd., 2019).

Klasik ESA modeller daha az donanım kaynaklarına sahip cep telefonu gibi cihazlarda çalışmayı imkânsız hale getiren belleklere ihtiyaç duymaktadır. Bu yüzden mobil cihazlarda çalışmak için Google tarafından önerilmiştir. MobileNet’de, Şekil 3.6’da

gösterilen özellik haritalarını yeniden kullanmak için artık darboğaz blokları da önerilmiştir. MobileNet transfer derin öğrenme ağına ait mimari Şekil 3.7’de verilmiştir. Bu nedenle, MobileNet çok daha az eğitim süresi ile iyi bir sınıflandırma performansı elde edilmiştir (Lu vd., 2020; Ashwinkumar vd., 2022). ImageNet veri seti üzerinde iyi bir performans göstermiştir.



Şekil 3.6. Artık darboğaz bloğu (Lu vd., 2020).


Katman türü/Adım	Filtre türü	Giriş Boyutu
Conv / s2	3 x 3 x 3 x 32	224 x 224 x 3
Conv dw / s1	3 x 3 x 32 dw	112 x 112 x 32
Conv / s1	1 x 1 x 32 x 64	112 x 112 x 32
Conv dw / s2	3 x 3 x 64 dw	112 x 112 x 64
Conv / s1	1 x 1 x 64 x 128	56 x 56 x 64
Conv dw / s1	3 x 3 x 128 dw	56 x 56 x 128
Conv / s1	1 x 1 x 128 x 128	56 x 56 x 128
Conv dw / s2	3 x 3 x 128 dw	56 x 56 x 128
Conv / s1	1 x 1 x 128 x 256	28 x 28 x 128
Conv dw / s2	3 x 3 x 256 dw	28 x 28 x 256
Conv / s1	1 x 1 x 256 x 256	28 x 28 x 256
Conv dw / s1	3 x 3 x 256 dw	28 x 28 x 256
Conv / s1	1 x 1 x 256 x 512	14 x 14 x 256
5 x	Conv dw / s1	3 x 3 x 512 dw
	Conv / s1	1 x 1 x 512 x 512
	Conv dw / s2	3 x 3 x 512 dw
Conv / s1	1 x 1 x 512 x 1024	7 x 7 x 512
Conv dw / s2	3 x 3 x 1024 dw	7 x 7 x 1024
Conv / s1	1 x 1 x 1024 x 1024	7 x 7 x 1024
Avg Pool / s1	Pool 7 x 7	7 x 7 x 1024
FC / s1	1024 x 7	1 x 1 x 1024
PNN / s1	Classifier	1 x 1 x 5

Şekil 3.7. MobilNet modeli mimarisi (Ashwinkumar vd., 2022)

3.3.4. DenseNet Transfer Yöntemi

Huang ve ark., (2018) tarafından önerilen DenseNet algoritması, girdiye yakın katmanlar ve çıktıya yakın katmanlar kısa olduğunda, evrişimli ağların önemli ölçüde daha derin, daha doğru ve verimli bir şekilde eğitilebileceği göstermiştir. Bu yaklaşım ResNet ve benzer bazı ağlarda da kullanıldı. ResNet'lerin aksine, DenseNet, öznetelikleri bir katmana geçirilmeden önce asla toplama yoluyla birleştirmez, bunun yerine, öznetelik haritalarını birleştirerek öznetelik vektörü ile birleştirir.

DenseNet ağı farklı katman sıraları ile çeşitli mimarilerde olabilirler. *Densenet 121*, *Densenet 169*, *Densenet 201* şeklinde farklı sayıda katman içeren modeller mevcuttur. Şekil 3.8'deki model 201 dense katmanlı DenseNet201 modelidir. Şekilden görüldüğü gibi 4 dense ağ bloğundan oluşmaktadır. Bu dense bloklar geçişli Pooling(havuzlama) katmanlarına bağlıdır. Son aşamada bu katmanlar global havuzlama katmanına verilmiştir. Global havuzlama katmanı sınıflandırma işlemleri için Softmax katmanına bağlanmıştır. SoftMax hesaplanan son öznitelik vektörünü oluşturmaktadır. DenseNet ağ içinde özniteliklerin tekrar tekrar kullanımlarını bağlantılar ile sağlar. Bu işlemi bağlantılar ile atlama(bypass) ve birleştirme ile gerçekleştirir. Gradyan kaybolması ağın derin katmanlarında meydana gelmesinden dolayı bypass katmanlarını ağın derin katmanlarına yerleştirilmektedir. Dense mekanizması her katmanı sonraki katmanlara giriş olarak bağlanmasını sağlayan katmanlardır. Bu şekilde bir mekanizma ile ağın parametre sayısı düştüğü gibi kaybolan gradyan problemini de çözmektedir (Kong ve Cheng,2022; Yuan vd., 2022).




Şekil 3.8. DenseNet ağı mimarisi (Kong ve Cheng,2022)

3.3.5. VGG Transfer Yöntemi

Bir diğer transfer derin öğrenme metotları VGG modellerdir. VGG modeller ağın derinliğini artıran modeller olup buna bağlı olarak performansı da arttıran modellerdir. Basit modül, küçük bir evrişim çekirdeği, küçük havuzlama çekirdeği ve ReLU'dan oluşur. Şekil 3.9'da görüldüğü gibi 5 evrişimsel katman, 3 tam bağlantılı katman ve bir softmax çıktı katmanı vardır. Katmanları ayırmak için maksimum havuzlama kullanılır ve tüm gizli katmanların etkinleştirme birimleri için ReLU aktivasyon fonksiyonu kullanılır (Kong ve Cheng,2022). Bu nedenle VGG ağlarının en büyük avantajlarından biri, sinir ağlarının yapısını basitleştirmesidir. Elde edilen $7 \times 7 \times 512$ öznitelik haritası

tam bağlantılı katmana ve ardından COVID-19 teşhisi için softmax aktivasyonu gerçekleştirilir.




Şekil 3.9. VGG ağı mimarisi (Kong ve Cheng,2022)

3.3.6. Inception (GoogleNet) Transfer Yöntemi

GoogleNet veya Inception, ImageNet LSVRC 2014 yarışmasının kazananı, görüntü sınıflandırma ve tespit etme işlemleri için geliştirilmiş derin evrişimli bir sinir ağı mimarisidir. GoogleNet, 2014 yılında Google'da (çeşitli üniversitelerin iş birliğiyle) yapılan bir araştırma ile "Going Deeper with Convolutions" başlıklı araştırma makalesinde önerildi (Szegedy vd., 2015). Bu mimari, ILSVRC 2014 görüntü sınıflandırma yarışmasında kazanan oldu. Önceki kazananlar AlexNet (ILSVRC 2012 Kazanan) ve ZF-Net (ILSVRC 2013 Kazanan) ile karşılaştırıldığında hata oranında önemli bir düşüş ve VGG'den (2014 ikincisi) önemli ölçüde daha başarılı bulundu. GoogleNet mimarinde, ağın ortasında 1×1 evrişim ve küresel ortalama havuzlama katmanları bulunmaktadır. Sistem Inception adını verdikleri modüllerden oluşmaktadır. Bir Inception modülü, önceki katmandan alınan veriyi 1×1 , 3×3 ve 5×5 'lik evrişim katmanları ile 3×3 'lük maksimum havuzlama katmanına iletir. Bu katmanlardan elde edilen çıktılar ise filtre birleştirme katmanında birleşirler. Şekil 10 bir inception modülüne ait şematik yapıyı göstermektedir (Das vd., 2020).

GoogleNet 224×224 boyutunda renkli RGB görüntüler ile çalışır. Ağ içindeki tüm aktivasyon fonksiyonları ReLU'dur. GoogleNet ağına ait mimari Şekil 3.10'de verilmiştir (Szegedy vd., 2015).




Şekil 3.10. GoogleNet modülüne ait şematik yapı, (a) Saf versiyon inception modülü, (b) boyut küçültmeli Inception modülü (Szegedy vd., 2015)

GoogLeNet mimarisi, AlexNet ve ZF-Net gibi önceki transfer yöntemlerin mimarilerden farklıdır. 1×1 evrişim ve daha derin bir mimari oluşturmasını sağlayan küresel ortalama havuzlama gibi farklı yapılar içermektedir (Szegedy vd., 2015). GoogleNet'i diğer transfer yöntemlerden ayıran özellikler aşağıda özetlenmiştir.

Küresel Ortalama Havuzlama: FC katmanında gerçekleştirilen işlemler klasik yapay sinir ağlarına benzer. Bu katman ESA ağların önemli bir katmanıdır. Ancak hesaplama maliyetini arttıran birçok parametre içermektedir. AlexNet, VGG gibi önceki transfer derin öğrenme mimarilerde ağın sonunda tamamıyla bağlı katmanlar kullanılmaktadır. Google mimarisinde ise bu katmandan önce küresel ortalama havuzlama katmanı denilen bir katman bulunur. Bu katman 7×7 'lik öznitelik haritalarının ortalamalarını alarak 1×1 'lik öznitelik haritalarına dönüştürür. Bu işlem ile eğitilebilir

parametre sayısını düşürdüğü gibi ImageNet veriseti üzerinde %0,6 başarı oranının da artırdığı gözlenmiştir (Szegedy vd., 2015).

Inception (Başlangıç) Modülü: GoogleNet'in bir diğer önemli özelliği başlangıç modülünün önceki AlexNet, ZF-Net gibi önceki mimarilerden farklı olmasıdır. Önceki mimarilerde her evrişim katmanlarının filtreleri sabit boyutlu olarak tanımlanır. Ancak GoogleNet mimarisinde başlangıç modülü farklı boyutlarda paralel olarak gerçekleştirilen evrişimler (1×1 , 3×3 , 5×5) mevcuttur. Bunların çıktıları 3×3 max havuzlama ile havuzlanır. Bu paralel işleyen evrişim işlemlerinde amaç görüntülerin birden çok ölçekte daha iyi öznitelik haritaların sağlanmasıdır (Szegedy vd., 2015). GoogleNet 144 katmandan oluşup genel mimarisi Şekil 3.11'de verilmiştir.




Şekil 3.11. GoogleNet Ağı mimarisi (Szegedy vd., 2015)

3.3.7. ResNet Transfer Yöntemi

Derin öğrenme metotları sınıflandırma problemlerinde genel olarak başarılıdır. Ancak farklı nedenlerden dolayı ağların eğitimi zor olmaktadır. Birincisi patlayan (yok olan) gradyanlar olarak isimlendirilen, bir nöronun eğitim sürecinde ölür ve aktivasyon fonksiyonuna bağlı olarak asla geri gelmemesi durumudur. İkincisi ise transfer yöntemlerin parametrelerinin optimizasyon problemidir. Ağın derinliği arttıkça bu parametrelerin fazla olmasından dolayı eğitim zorlaşmaktadır (Srivastava, 2015).

Önerilen bu problemleri çözmenin etkili bir yolu ResNet Ağlar'dır (He vd., 2015). ResNets'teki temel fark, normal evrişimli katmanlarına paralel kısayol bağlantılarına sahip olmalarıdır. Evrişim katmanlarının aksine, bu kısayol bağlantıları her zaman canlıdır ve hatayı kolayca geri yayabilir. ResNet mimarisi ILSVRC 2015 ve COCO 2015

yarışmalarında birincilik kazanan bir model olup diğer sınıflandırma problemlerinde de başarılıdır. ResNet18, ResNet34, ResNet50, ResNet101 ve ResNet152 farklı mimarilerde ResNet ağlar önerilmiştir. Örneğin 50 katmandan oluşan Resnet-50 mimarisinin inşasında beş evrimsel blok kullanılmıştır. Bu bloklar, 1×1 , 3×3 ve 1×1 evrişim katmanlarından meydana gelmektedir. 1×1 evrişimleri ile giriş imgeleri daha düşük boyuta indirgenirmiş ve 3×3 evrişimleri ile daha yüksek boyutlarda filtreleme işlemi gerçekleştirilmiştir. Mimaride boyut küçültme amacıyla, global ortalama havuz katmanı kullanılmıştır. ResNet50 evrimsel sinir ağı genel olarak; konvolüsyon katmanı, aktivasyon katmanı, altörnekleme (pooling) katmanı ve tam bağlı katman (fully-connected) gruplarından meydana gelmektedir. ResNet ağı mimarisi Şekil 3.12’de verilmiştir.



Şekil 3.12. ResNet Ağı Mimarisi (Kılıç vd., 2022)

3.4. Ekstra Ağaç Sınıflandırıcı ile Öznitelik Seçimi

Transfer derin öğrenme metotlarından elde edilen derin özniteliklerden uygun özniteliklerin seçimi için EAS öznitelik seçim yöntemi kullanılmıştır (Geurts vd., 2006). Öznitelik seçimi, özellikle yüksek boyutlu verilerde tahmin yöntemine maksimum katkı sağlayacak olan önemli özniteliklerin seçimini sağlayan veri ön-işleme sürecidir. Önemsiz özniteliklerin elenmesi, problemi daha basit hale getirerek hem modellerin hesaplama maliyetini azaltmakta hem de model doğruluğu arttırabilmektedir. EAS, öznitelik seçme ve sınıflandırma arasında ortak bir çatı sunan karar-tabanlı bir yöntemdir. Birçok alt-ağaç oluşturma ve rastgele alt kümeler seçme gibi karakteristikleri nedeniyle RO sınıflandırıcısına oldukça benzerdir. Ana düğüm ve devamında yaprağa kadarki alt

düğümelerde rastgele bir bölme işlemi gerçekleştirilir. Daha sonra tüm ağaçların tahinleri çoğunluk kararını tespit etmek için birleştirilir. Öznitelik seçimi için ormanın oluşturulması sırasında her bir öznitelik için Gini önem değeri hesaplanır. Öznitelik seçimi için öznitelikler Gini önemine göre azalan düzende sıralanır ve istenen kadar öznitelik üst öznitelikler arasında seçilebilir.

$$Gini = 1 - \sum_{i=0}^{c-1} p_i(t)^2 \quad (3.1)$$

burada $p_i(t)$, i sınıfının t düğümündeki frekansdır, ve c bu düğümdeki tekil sınıf sayısıdır.

3.5. Topluluk Öğrenme Yöntemleri

Topluluk öğrenme teknikleri, karar verme aşamasında tek bir karar verici yerine birden çok karar verici (sınıflandırıcı) kullanarak başarıyı arttırmayı amaçlamaktadır. Sınıflandırma için bir grup klasik MÖ modeli içinden eğitim setine göre 10 çapraz-doğrulama sonrasında AUC metriğine göre en iyi beşi seçilerek topluluk sınıflandırıcılarda kullanılmıştır. TÖ yöntemlerinden elde edilen derin öznitelikler bu sınıflandırıcılara girilerek İstifleme ve Oylama (Yumuşak ve Katı) topluluk öğrenme teknikleri kullanılarak sınıflandırılmıştır. Oylama yönteminde, sınıf etiketlerini tahmin etmek için çoğunluk oyu ve sınıf tahmin olasılıkların ortalamasını esas alan sırasıyla Katı Oylama ve Yumuşak Oylama teknikleri kullanılmıştır.

3.5.1. Oylama Topluluk Öğrenme

Oylama topluluk öğrenme yönteminin temel dayanağı, farklı MÖ yöntemlerinin tahminlerini birleştirerek ortak bir topluluk kararı elde etmektir. Bu ortak karar, bu çalışmada da kullanılan çoğunluk oyu (Katı oylama) ve ortalama tahmin olasılıkları (Yumuşak oylama) şeklinde elde edilebilmektedir. Bu sayede tekil bir modelin sebep olacağı yanlış tahminler dengelenerek daha iyi performans elde edilebileceği öngörülmektedir. Varsayalım ki x örneği için, n tane ayrı sınıflandırıcı $\{h_1, h_2, h_3, \dots, h_n\}$ ile k adet sınıf $\{s_1, s_2, s_3, \dots, s_k\}$ arasından sınıfın tahminini yapmak isteyelim (Zhou, 2012).

Katı oylama (Hard Voting) yönteminde, belirli bir örnek için tahmin sonucu topluluğu oluşturan sınıflandırıcıların çoğunluğunun tahmini örneğin sınıfı olarak kabul edilmektedir. Buna göre katı oylama yöntemine göre x örneğinin tahmin edilen sınıfı aşağıdaki gibi ifade edilir (Zhou, 2012),

$$H(x) = S_{\sum_{i=1}^n h_i^j(x)} \quad (3.2)$$

Yumuşak oylama (Soft Voting) yönteminde ise, ağırlıklı olasılıksal tahminlerin ortalaması alınarak sınıf tahmini yapılır. En yüksek ortalamaya sahip sınıf topluluğun tahmini olarak değerlendirilir. Buna göre yumuşak oylama yöntemine göre x örneğinin tahmin edilen sınıfı aşağıdaki gibi ifade edilir (Zhou, 2012),

$$H(x) = S_{\sum_{i=1}^n w_i h_i^j(x)} \quad (3.3)$$

burada w_i değeri h_i sınıflandırıcısının topluluk içindeki ağırlığını ifade etmektedir.

Topluluk öğrenmede her sınıflandırıcı bir sınıf etiketi için oy verir ve nihai çıktı sınıf etiketi oyların yarısından fazlasını alan etikettir. Sınıf etiketlerinden hiçbiri oyların yarısından fazlasını alamazsa, bir ret seçeneği verilir ve birleşik sınıflandırıcı hiçbir tahminde bulunmaz. Yani grubun sınıf etiketi aşağıdaki eşitlik ile bulunmuş olur.

$$h(x) = \left\{ \begin{array}{ll} C_j & \text{eğer } \sum_{i=1}^N h_i^j(x) \\ & > \frac{1}{2 \sum_{k=1}^M \sum_{i=1}^N h_i^k} \text{ ret,} \end{array} \right. \quad \text{diğer durumlarda} \quad (3.4)$$

3.5.3. İstifleme (Stacking) Topluluk Öğrenme

İstifleme topluluk öğrenme yöntemi, Wolpert (Wolpert, 1992) tarafından geliştirilmiş olup iki aşamalı bir yöntemdir. İlk aşamada aynı veri seti (eğitim) kullanılarak farklı sınıflandırıcılar tarafından tahminler üretmekte ve ikinci aşamada bu tahminler bir meta-sınıflandırıcı tarafından işlenerek topluluğun tahmini elde edilmektedir. Burada amaçlanan topluluk sınıflandırıcının daha yüksek doğruluğa sahip tahminler elde etmesidir (Wolpert, 1992).

3.6. Performans Ölçütleri

Transfer derin öğrenme metotların performanslarını değerlendirmek için karışıklık matrisi kullanılır. Veri setimizdeki gerçek çıkış etiketleri ile modellerin tahmin etiketleri yanlış ve doğru sayılarını tablo olarak göstermektedir.

Tablo 3.5: Karışıklık matrisi gösterimi

		Gerçek	
Tahmin		COVID	Non-COVID
	COVID	Doğru Pozitif (DP)	Doğru Negatif (DN)
	Non-COVID	Yanlış Negatif (YN)	Yanlış Pozitif (YP)

Burada;

Doğru Pozitif (DP): COVID-19 olarak etiketlenmiş görüntülerin model tarafından da COVID-19 olarak tahmin edilmesidir. Bu durumda doğru sınıflandırma sayısıdır.

Doğru Negatif (DN): COVID-19 olarak etiketlenmiş görüntülerin model tarafından Non-COVID-19 (Normal) olarak tahmin edilmesidir. Bu durumdaki yanlış sınıflandırma sayısıdır.

Yanlış Pozitif (YP): Non-COVID olarak etiketlenmiş görüntülerin model tarafından COVID-19 olarak etiketlenmiş görüntülerin sayısını belirtir.

Yanlış Negatif (YN): COVID-19 olarak etiketlenmiş görüntülerin model tarafından Non-COVID-19 olarak etiketlenmiş görüntülerin sayısını belirtir.

Transfer derin öğrenme metotların performanslarını değerlendirmek için aşağıdaki dört ölçüt kullanılmıştır (Bohmrah ve Kaur, 2021).

$$Başarı = \frac{DP + DN}{DP + DN + YN + YP} \quad (3.5)$$

$$Kesinlik = \frac{DP}{DP + YP} \quad (3.6)$$

$$Hatırlama = \frac{DP}{DP + YN} \quad (3.7)$$

$$F - \text{Ölçütü} = 2 * \frac{Kesinlik * Hatırlatma}{Kesinlik + Hatırlatma} \quad (3.8)$$

Sınıflandırma işlemleri 10 katlı çapraz geçerlilik testine göre gerçekleştirilmiştir. 10 katlı çapraz geçerlilik testi, bir modelin performansını değerlendirmek için yaygın olarak kullanılan bir yöntemdir. Bu test, veri setinin ayrılmış alt kümelerini kullanarak modeli on kez eğitir ve değerlendirir.



4. DENEYSEL ANALİZLER

Çalışma kapsamında önerilen sistemin performansını karşılaştırabilmek amacıyla ilk olarak topluluk sınıflandırıcı kullanmadan TÖ modeli ile doğrudan sınıflandırma yapılmıştır. Diğer üç uygulama ise İstifleme, Yumuşak ve Katı Oylama topluluk sınıflandırıcılarla gerçekleştirilmiş ve toplamda dört ayrı uygulama yapılmıştır. Çalışma kapsamında kullanılan dokuz TÖ modeli her bir uygulamada ayrı ayrı denenmiştir. Ayrıca bu dört uygulamanın her birinde iki sınıflı (COVID-19 ve Normal), üç sınıflı (COVID-19, Viral-Pnömoni ve Normal) ve dört sınıflı (COVID-19, Akciğer-Opaklığı, Viral-Pnömoni ve Normal) uygulamalar gerçekleştirilmiştir. Uygulamalara ilişkin performans ölçütleri tablolar halinde ayrı ayrı sunulmuştur.

4.1. Dört Sınıflı Analizler

Bu bölümde dört sınıflı eğitim ve test veri setlerine ilişkin performans analizleri sunulmuştur. Tablo 4.1’de topluluk sınıflandırıcı kullanmadan TÖ modellerinin eğitim ve test veri setlerine ait başarı ölçütleri sunulmuştur. Tablo 4.2’de ise test veri seti için derin özniteliklerle ve önerilen topluluk sınıflandırıcı sistemle elde edilmiş başarı ölçütleri sunulmuştur. Topluluk sınıflandırıcı kullanılmadığında eğitim ve test veri setleri için en yüksek doğruluklar sırasıyla 84,83% (Kesinlik: 85,67%, Duyarlılık: 83,49%, f1-ölçütü: 84,49) ve 85,09% (Kesinlik: 87,18%, Duyarlılık: 82,05%, f1-ölçütü: 84,14) MobileNet ile elde edilmiştir. En düşük tahmin doğruluğu ise eğitim ve test veri setleri için sırasıyla 63,17% ve 63,17% ile VGG16 TÖ modelinde elde edilmiştir.

Önerilen DeepFeat-E isimli hibrit modele göre, derin öznitelikler ve topluluk sınıflandırıcılarla yapılan uygulamalarda, İstifleme modeli için en yüksek doğruluk 90,17% (Kesinlik: 92,29%, Duyarlılık: 89,65%, f1-ölçütü: 90,88) ile DenseNet201 TÖ modeliyle, Yumuşak ve Katı oylama yöntemlerinde ise sırasıyla 88,45% (Kesinlik: 90,84%, Duyarlılık: 87,05%, f1-ölçütü: 88,72) ve 87,93% (Kesinlik: 90,15%, Duyarlılık: 86,35%, f1-ölçütü: 88,03) ile DenseNet169 TÖ modeliyle elde edilmiştir. Diğer taraftan en düşük doğruluk değerleri İstifleme modeli ve Yumuşak Oylama için sırasıyla 82,35% ve 81,53% ile Xception TÖ modeli ile elde edilirken, Katı Oylama için 80,75% ile NASNet TÖ modelinde elde edilmiştir.

Tablo 4.2’de sınıflandırma doğruluklarını karşılaştırmak ve önerilen derin öznitelikler temelli sistemin avantajını göstermek için, topluluk sınıflandırıcı kullanmadan doğrudan TÖ modellerle ve derin öznitelikler kullanılarak sırasıyla İstifleme, Yumuşak oylama ve Katı oylama topluluk sınıflandırıcılarla elde edilen test doğruluk değerleri ve iyileştirme miktarları listelenmiştir.

Tablo 4.1: TÖ modellerinin dört sınıflı eğitim ve test başarı değerleri.

Model İsmi	Eğitim (%)				Test (%)			
	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.
Xception	80,86	81,73	77,85	79,52	80,60	82,75	76,53	79,09
NASNet	80,74	82,53	77,59	79,54	79,09	81,68	72,86	75,91
MobileNet	84,83	85,67	83,49	84,49	85,09	87,18	82,05	84,14
DenseNet169	84,33	85,72	82,18	83,53	84,88	86,75	82,31	84,06
DenseNet201	83,75	85,53	81,55	83,26	82,45	84,96	78,42	80,90
VGG16	63,17	76,38	41,23	37,82	63,17	75,61	40,62	37,08
InceptionV3	81,22	81,26	78,18	79,45	80,75	81,78	77,23	78,87
ResNet50V2	84,37	85,90	81,95	83,61	84,17	86,65	80,36	82,81
ResNet101V2	83,41	84,49	80,72	82,25	83,70	85,93	79,90	82,00

Tablo 4.2: Derin Öznitelikler ve Topluluk sınıflandırıcıların dört sınıflı test başarı değerleri


Model İsmi	İstifleme Model (%)				Yumuşak Oylama (%)				Katı Oylama (%)			
	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.
Xception	82,35	83,65	79,76	81,46	81,53	84,19	77,43	80,09	80,75	83,42	76,18	78,93
NASNet	84,08	86,37	80,09	82,72	81,74	85,21	76,95	79,97	80,75	84,43	75,50	78,70
MobileNet	88,09	89,17	87,18	88,09	86,16	89,28	82,99	85,53	85,64	89,08	82,23	84,95
DenseNet169	89,63	91,33	89,57	90,34	88,45	90,84	87,05	88,72	87,93	90,15	86,35	88,03
DenseNet201	90,17	92,29	89,65	90,88	87,81	91,06	85,51	87,87	87,24	90,54	85,01	87,30
VGG16	87,15	89,43	85,08	86,99	84,08	88,48	79,89	83,09	84,03	88,51	79,50	82,85
InceptionV3	83,13	84,13	80,37	81,87	82,07	84,58	77,62	79,98	81,29	84,00	76,46	78,95
ResNet50	88,33	89,97	86,96	88,32	86,51	89,63	82,70	85,51	85,99	89,38	81,76	84,76
ResNet101	86,96	89,43	84,66	86,67	84,74	88,45	80,28	83,21	84,57	88,45	79,79	82,92

Şekil 4.1(a)’da bu dört uygulamalara ait test doğruluk değerleri gruplanarak sunulmuştur. Şekil 4.1(b)’de ise önerilen topluluk sınıflandırıcı sistemin TÖ model doğruluğunu iyileştirme miktarları gösterilmiştir. Tablo 4.3 ve Şekil 4.1’te görüldüğü gibi Topluluk sınıflandırıcıların tümü TÖ modellerinin doğruluğu önemli ölçüde arttırmış ve TÖ modellerinden daha yüksek tahmin doğruluğu elde edilmesini sağlamıştır. Tablo 4.3 ve Şekil 4.1(a)’da görüldüğü gibi en yüksek tahmin doğruluğu 90,17% ile istifleme

topluluk sınıflandırıcı ve DenseNet201 TÖ modelin derin öznitelikleri kullanılarak önerilen DeepFeat-E isimli hibrit model ile elde edilmiştir. Bu TÖ modelinin doğruluğunun önerilen sistemle +7,73 puan iyileştirildiği görülmektedir. Bununla birlikte en yüksek doğruluk iyileştirmelerin istifleme topluluk sınıflandırıcı ile +23,98 puan VGG16 TÖ modelinde gerçekleştiği ve aynı TÖ modelinin yumuşak ve katı oylama teknikleriyle de sırasıyla +20,91 ve +20,86 puan ile önemli ölçüde iyileştirildiği görülmektedir.

Tablo 4.3: Uygulamaların dört sınıflı test başarılarının karşılaştırması ve iyileştirme miktarları.


Model İsmi	TÖ Model	Doğruluk (%)			İyileştirme		
		İstifleme Model	Yumuşak Oylama	Katı Oylama	İstifleme Model	Yumuşak Oylama	Katı Oylama
Xception	80,60	82,35	81,53	80,75	1,75	0,92	0,14
NASNet	79,09	84,08	81,74	80,75	4,98	2,65	1,65
MobileNet	85,09	88,09	86,16	85,64	3,00	1,06	0,54
DenseNet169	84,88	89,63	88,45	87,93	4,75	3,57	3,05
DenseNet201	82,45	90,17	87,81	87,24	7,73	5,36	4,80
VGG16	63,17	87,15	84,08	84,03	23,98	20,91	20,86
InceptionV3	80,75	83,13	82,07	81,29	2,39	1,32	0,54
ResNet50V2	84,17	88,33	86,51	85,99	4,16	2,34	1,82
ResNet101V2	83,70	86,96	84,74	84,57	3,26	1,04	0,87



Şekil 4.1. TÖ modellere göre gruplandırılmış dört sınıflı test doğrulukları ve iyileştirme miktarları.

Şekil 4.2’te çalışma kapsamında gerçekleştirilen dört uygulamaya ilişkin test veri seti için karışıklık-matrisleri sunulmuştur. Şekil 4.2(a)’da X-Ray görüntülerin doğrudan kullanıldığı ilk uygulamada TÖ modeller arasında en yüksek doğruluk değerinin elde edildiği MobileNet (85,09%) modeline ait karışıklık matrisi gösterilmiştir. Şekil

4.2(b)'de dört sınıflı uygulamalarda en yüksek doğruluk değerinin (90,17%) elde edildiği DenseNet201 modeline ait derin öznitelikler (DenseNet201F) ve İstifleme topluluk sınıflandırıcısıyla gerçekleştirilen uygulamanın karışıklık matrisini göstermektedir. Şekil 14(c ve d)'de ise DenseNet169 TÖ modeline ait derin öznitelikler (DenseNet169(F)) kullanıldığında sırasıyla Yumuşak ve Katı Oylama topluluk sınıflandırıcılarla elde edilen en yüksek doğruluk değerlerinin (88,45 ve 87,93) elde edildiği uygulamalara ait karışıklık-matrisleri gösterilmiştir.



Şekil 4.2. Dört sınıflı test veri seti için en iyi doğruluk karışıklık-matrisleri.

4.2. Üç Sınıflı Analizler

Bu bölümde üç sınıflı eğitim ve test veri setlerine ilişkin performans analizleri sunulmuştur. Tablo 4.4'te topluluk sınıflandırıcı kullanmadan TÖ modellerinin eğitim ve test veri setlerine ait başarı ölçütleri sunulmuştur. Tablo 4.5'te ise test veri seti için derin özniteliklerle ve önerilen topluluk sınıflandırıcı sistemle elde edilmiş başarı ölçütleri sunulmuştur. Topluluk sınıflandırıcı kullanılmadığında eğitim ve test veri setleri için en

yüksek doğruluklar sırasıyla DenseNet201 ile 91,26% (Kesinlik: 92,29%, Duyarlılık: 87,60%, f1-ölçütü: 89,69) ve MobileNet ile 90,53% (Kesinlik: 93,10%, Duyarlılık: 84,39%, f1-ölçütü: 88,09) olarak elde edilmiştir. En düşük tahmin doğruluğu ise eğitim ve test veri setleri için sırasıyla 73,07% ve 72,42% ile VGG16 TÖ modelinden elde edilmiştir. Önerilen DeepFeat-E isimli hibrit modele göre, derin öznetelikler ve topluluk sınıflandırıcılarla yapılan uygulamalarda, İstifleme modeli için en yüksek doğruluk 94,99% (Kesinlik: 95,99%, Duyarlılık: 91,65%, f1-ölçütü: 93,68) ile DenseNet201 TÖ modeliyle, Yumuşak ve Katı oylama yöntemlerinde ise sırasıyla 93,17% (Kesinlik: 95,00%, Duyarlılık: 88,70%, f1-ölçütü: 91,55) ve 92,91% (Kesinlik: 94,59%, Duyarlılık: 88,34%, f1-ölçütü: 91,17) ile DenseNet169 TÖ modeliyle elde edilmiştir. Diğer taraftan en düşük doğruluk değerleri İstifleme modeli için 89,84% ile Xception TÖ modelinde, Yumuşak Oylama ve Katı Oylama için ise sırasıyla 88,52% ve 88,29% ile InceptionV3 TÖ modelinde elde edilmiştir.

Tablo 4.4: TÖ modellerinin üç sınıflı eğitim ve test başarı değerleri.

Model İsmi	Eğitim (%)				Test (%)			
	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.
Xception	87,72	88,20	82,80	85,13	88,06	90,13	81,03	84,84
NASNet	88,04	88,66	83,98	85,91	87,73	90,64	79,64	84,08
MobileNet	90,99	92,08	87,59	89,61	90,53	93,10	84,39	88,09
DenseNet169	90,75	91,84	87,01	89,14	90,20	92,37	83,76	87,48
DenseNet201	91,26	92,29	87,60	89,69	90,47	93,42	83,27	87,48
VGG16	73,07	78,14	45,85	45,94	72,42	80,50	43,70	43,97
InceptionV3	88,12	88,84	82,96	85,47	86,34	87,90	78,63	82,41
ResNet50V2	90,40	90,71	87,03	88,65	89,64	91,92	83,44	87,04
ResNet101V2	90,29	90,98	86,49	88,45	88,95	91,91	81,70	85,85


Tablo 4.5: Derin Öznitelikler ve Topluluk sınıflandırıcıların üç sınıflı test başarı değerleri.

Model İsmi	İstifleme Model (%)				Yumuşak Oylama (%)				Katı Oylama (%)			
	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.
Xception	89,84	90,79	84,92	87,56	89,15	91,43	82,62	86,37	88,49	90,75	81,60	85,46
NASNet	90,70	92,43	85,17	88,37	89,05	92,19	81,34	85,80	88,55	91,61	80,93	85,32
MobileNet	93,67	94,43	90,12	92,09	91,95	94,45	85,57	89,41	91,45	94,09	84,74	88,74
DenseNet169	94,52	94,72	92,78	93,68	93,17	95,00	88,70	91,55	92,91	94,59	88,34	91,17
DenseNet201	94,99	95,99	91,65	93,68	92,97	95,36	87,27	90,80	92,35	94,95	86,26	90,02
VGG16	94,09	94,31	89,93	91,97	90,83	92,88	83,48	87,42	90,37	92,98	82,52	86,81
InceptionV3	90,10	90,27	85,72	87,78	88,52	90,51	82,03	85,54	88,29	90,58	81,27	85,13
ResNet50	93,27	94,41	89,75	91,90	91,42	93,88	85,33	89,01	91,09	93,34	84,80	88,47
ResNet101	92,51	94,07	88,27	90,89	90,37	93,67	83,94	87,94	90,10	93,28	83,38	87,46


Tablo 4.6’da topluluk sınıflandırıcı kullanmadan doğrudan TÖ modellerle ve derin öznitelikler kullanılarak sırasıyla İstifleme, Yumuşak oylama ve Katı oylama topluluk sınıflandırıcılarla elde edilen test doğruluk değerleri ve iyileştirme miktarları listelenmiştir. Şekil 4.3(a)’da uygulamalara ait test doğruluk değerleri gruplanarak sunulmuştur. Şekil 4.3(b)’de ise önerilen topluluk sınıflandırıcı sistemin TÖ model doğruluğunu iyileştirme miktarları gösterilmiştir. Tablo 4.6 ve Şekil 4.3’te görüldüğü gibi üç sınıflı uygulamalarda da Topluluk sınıflandırıcıların tümünün TÖ modellerinin doğruluğunu önemli ölçüde arttırmış ve TÖ modellerinden daha yüksek tahmin doğruluğu elde edilmesini sağlamıştır. Tablo 4.6 ve Şekil 4.3(a)’te görüldüğü gibi en yüksek tahmin doğruluğu 94,99% ile istifleme topluluk sınıflandırıcı ve DenseNet201 TÖ modelin derin öznitelikleri kullanılarak önerilen DeepFeat-E isimli hibrit model ile elde edilmiştir. Bu TÖ modelinin doğruluğunun önerilen sistemle +4,52 puan iyileştirildiği görülmektedir. Bununla birlikte önceki bölümde olduğu gibi en yüksek doğruluk iyileştirmelerin istifleme topluluk sınıflandırıcı ile +21,68 puan VGG16 TÖ modelinde gerçekleştiği ve aynı TÖ modelinin yumuşak ve katı oylama teknikleriyle de sırasıyla +18,41 ve +17,95 puan ile önemli ölçüde iyileştirildiği görülmektedir.

Tablo 4.6: Uygulamaların üç sınıflı test başarılarının karşılaştırması ve iyileştirme miktarları

Model İsmi	TÖ Model	Doğruluk (%)			İyileştirme		
		İstiflem e Model	Yumuşak Oylama	Katı Oylama	İstiflem e Model	Yumuşak Oylama	Katı Oylama
Xception	88,06	89,84	89,15	88,49	1,78	1,09	0,43
NASNet	87,73	90,70	89,05	88,55	2,97	1,32	0,82
MobileNet	90,53	93,67	91,95	91,45	3,13	1,42	0,92
DenseNet169	90,20	94,52	93,17	92,91	4,32	2,97	2,71
DenseNet201	90,47	94,99	92,97	92,35	4,52	2,51	1,88
VGG16	72,42	94,09	90,83	90,37	21,68	18,41	17,95
InceptionV3	86,34	90,10	88,52	88,29	3,76	2,18	1,95
ResNet50V2	89,64	93,27	91,42	91,09	3,63	1,78	1,45
ResNet101V2	88,95	92,51	90,37	90,10	3,56	1,42	1,15

**Şekil 4.3.** TÖ modellere göre gruplandırılmış üç sınıflı test doğrulukları ve iyileştirme miktarları.

Şekil 4.4'te çalışma kapsamında gerçekleştirilen dört uygulamaya ilişkin test veri seti için karışıklık-matrisleri sunulmuştur. Şekil 16(a)'da X-Ray görüntülerin doğrudan kullanıldığı ilk uygulamada TÖ modeller arasında en yüksek doğruluk değerinin elde edildiği MobileNet (90,53%) modeline ait karışıklık matrisi gösterilmiştir. Şekil 4.4(b)'de üç sınıflı uygulamalarda en yüksek doğruluk değerinin (94,99%) elde edildiği DenseNet201 modeline ait derin öznetelikler (DenseNet201F) ve İstifleme topluluk sınıflandırıcısıyla gerçekleştirilen uygulamanın karışıklık matrisini göstermektedir. Şekil 4.4(c ve d)'de ise DenseNet169 TÖ modeline ait derin öznetelikler (DenseNet169(F)) kullanıldığında sırasıyla Yumuşak ve Katı Oylama topluluk sınıflandırıcılarla elde edilen en yüksek doğruluk değerlerinin (93,17 ve 92,91) elde edildiği uygulamalara ait karışıklık-matrisleri gösterilmiştir.



Şekil 4.4. Üç sınıflı test veri seti için en iyi doğruluk karışıklık-matrisleri.

4.2. İki Sınıflı Analizler

Bu bölümde iki sınıflı eğitim ve test veri setlerine ilişkin performans analizleri sunulmuştur. Tablo 4.7’de topluluk sınıflandırıcı kullanmadan TÖ modellerinin eğitim ve test veri setlerine ait başarı ölçütleri sunulmuştur. Tablo 4.8.’de ise test veri seti için derin özniteliklerle ve önerilen topluluk sınıflandırıcı sistemle elde edilmiş başarı ölçütleri sunulmuştur. Topluluk sınıflandırıcı kullanılmadığında eğitim ve test veri setlerinin her ikisi için en yüksek doğruluklar MobileNet ile sırasıyla 91,13% (Kesinlik: 90,15%, Duyarlılık: 86,30%, f1-ölçütü: 87,97) ve 91,53% (Kesinlik: 92,35%, Duyarlılık: 85,38%, f1-ölçütü: 88,12) olarak elde edilmiştir. En düşük tahmin doğruluğu ise eğitim ve test veri setleri için sırasıyla 78,49% ve 78,93% ile dört ve üç sınıflı uygulamada olduğu gibi VGG16 TÖ modelinde elde edilmiştir. Önerilen DeepFeat-E isimli hibrit modele göre, derin öznitelikler ve topluluk sınıflandırıcılarla yapılan uygulamalarda, İstifleme ve Yumuşak oylama yönteminde en yüksek doğruluk sırasıyla 94,93% (Kesinlik: 95,17%, Duyarlılık: 91,57%, f1-ölçütü: 93,18) ve 93,63% (Kesinlik: 94,83%, Duyarlılık: 88,63%, f1-ölçütü: 91,18) ile DenseNet201 TÖ modeliyle, Katı oylama yönteminde ise 93,52% (Kesinlik: 94,29%, Duyarlılık: 88,78%, f1-ölçütü: 91,09) ile MobileNet TÖ modeliyle

elde edilmiştir. Diğer taraftan en düşük doğruluk değerleri İstifleme, Yumuşak Oylama ve Katı Oylama yöntemlerinde sırasıyla 90,59%, 89,79% ve 89,90% ile InceptionV3 TÖ modelinde elde edilmiştir. Tablo 4.8’te önceki bölümlerde olduğu gibi topluluk sınıflandırıcı kullanmadan doğrudan TÖ modellerle ve derin öznitelikler kullanılarak sırasıyla İstifleme, Yumuşak oylama ve Katı oylama topluluk sınıflandırıcılarla elde edilen test doğruluk değerleri ve iyileştirme miktarları listelenmiştir.

Tablo 4.7: TÖ modellerinin iki sınıflı eğitim ve test başarı değerleri.

Model İsmi	Eğitim (%)				Test (%)			
	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.
Xception	87,72	86,51	80,42	82,77	88,09	88,54	79,66	82,74
NASNet	87,94	86,78	80,77	83,10	87,91	87,47	80,03	82,75
MobileNet	91,13	90,15	86,30	87,97	91,53	92,35	85,38	88,12
DenseNet169	90,14	89,26	84,46	86,46	90,55	89,95	84,90	86,99
DenseNet201	90,74	90,31	85,07	87,23	91,09	92,68	84,10	87,28
VGG16	78,49	73,38	64,96	66,79	78,93	76,93	63,05	64,80
InceptionV3	88,49	87,49	81,62	83,93	86,82	85,36	78,98	81,37
ResNet50V2	90,48	89,86	84,78	86,89	90,70	91,15	84,24	86,93
ResNet101V2	89,73	89,20	83,40	85,72	89,86	91,41	82,02	85,34

Tablo 4.8: Derin Öznitelikler ve Topluluk sınıflandırıcıların iki sınıflı test başarı değerleri.


Model İsmi	İstifleme Model (%)				Yumuşak Oylama (%)				Katı Oylama (%)			
	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.	Doğ.	Kes.	Duy.	f1-öl.
Xception	90,91	90,53	85,32	87,47	90,66	91,01	84,26	86,90	90,30	90,61	83,65	86,34
NASNet	92,43	91,99	88,00	89,74	91,53	92,01	85,65	88,19	91,24	91,62	85,23	87,78
MobileNet	93,99	93,15	91,06	92,04	93,56	94,20	88,94	91,16	93,52	94,29	88,78	91,09
DenseNet169	94,93	93,75	93,04	93,39	93,59	93,65	89,50	91,31	93,34	93,51	88,97	90,93
DenseNet201	94,93	95,17	91,57	93,18	93,63	94,83	88,63	91,18	93,41	94,63	88,26	90,86
VGG16	94,75	94,89	91,36	92,94	93,08	94,35	87,68	90,37	92,83	94,18	87,20	89,98
InceptionV3	90,59	89,58	85,37	87,17	89,79	89,51	83,27	85,72	89,90	89,75	83,34	85,85
ResNet50	94,24	93,86	91,01	92,31	93,37	94,07	88,59	90,89	93,30	93,86	88,59	90,81
ResNet101	93,85	94,51	89,40	91,57	92,25	93,80	86,09	89,07	92,07	93,35	85,97	88,85

Şekil 4.5(a)’te uygulamalara ait test doğruluk değerleri gruplanarak sunulmuştur. Şekil 4.5(b)’te ise önerilen topluluk sınıflandırıcı sistemin TÖ model doğruluğunu iyileştirme miktarları gösterilmiştir. Tablo 4.9 ve Şekil 4.5’te görüldüğü gibi iki sınıflı uygulamalarda da Topluluk sınıflandırıcıların tümünün TÖ modellerinin doğruluğunu önemli ölçüde arttırmış ve TÖ modellerinden daha yüksek tahmin doğruluğunun elde

edilmesini sağlamıştır. Tablo 4.9 ve Şekil 4.5(a)'te görüldüğü gibi en yüksek tahmin doğruluğu 94,93% ile istifleme topluluk sınıflandırıcı ve DenseNet201 TÖ modelin derin öznetelikleri kullanılarak önerilen DeepFeat-E isimli hibrit model ile elde edilmiştir. Bu TÖ modelinin doğruluğunun önerilen sistemle +3,84 puan iyileştirildiği görülmektedir. Bununla birlikte önceki dört ve üç sınıflı veri setlerinde olduğu gibi en yüksek doğruluk iyileştirmelerin istifleme topluluk sınıflandırıcı ile +15,82 puan VGG16 TÖ modelinde gerçekleştiği ve aynı TÖ modelinin yumuşak ve katı oylama teknikleriyle de sırasıyla +14,16 ve +13,90 puan ile önemli ölçüde iyileştirildiği görülmektedir.

Tablo 4.9: Uygulamaların iki sınıflı test başarılarının karşılaştırması ve iyileştirme miktarları


Model İsmi	Doğruluk (%)				İyileştirme		
	TÖ Model	İstifleme Model	Yumuşak Oylama	Katı Oylama	İstifleme Model	Yumuşak Oylama	Katı Oylama
Xception	88,09	90,91	90,66	90,30	2,82	2,57	2,21
NASNet	87,91	92,43	91,53	91,24	4,53	3,62	3,33
MobileNet	91,53	93,99	93,56	93,52	2,46	2,03	1,99
DenseNet169	90,55	94,93	93,59	93,34	4,38	3,04	2,79
DenseNet201	91,09	94,93	93,63	93,41	3,84	2,53	2,32
VGG16	78,93	94,75	93,08	92,83	15,82	14,16	13,90
InceptionV3	86,82	90,59	89,79	89,90	3,77	2,97	3,08
ResNet50V2	90,70	94,24	93,37	93,30	3,55	2,68	2,61
ResNet101V2	89,86	93,85	92,25	92,07	3,98	2,39	2,21



Şekil 4.5. TÖ modellere göre gruplandırılmış iki sınıflı test doğrulukları ve iyileştirme miktarları.

Şekil 4.6'da çalışma kapsamında gerçekleştirilen dört uygulamaya ilişkin test veri seti için karışıklık-matrisleri sunulmuştur. Şekil 4.6(a)'da X-Ray görüntülerin doğrudan kullanıldığı ilk uygulamada TÖ modeller arasında en yüksek doğruluk değerinin elde

edildiği MobileNet (91,53%) modeline ait karışıklık matrisi gösterilmiştir. Şekil 4.6(b)'de iki sınıflı uygulamalarda en yüksek doğruluk değerinin (94,93%) elde edildiği DenseNet201 modeline ait derin öznitelikler (DenseNet201F) ve İstifleme topluluk sınıflandırıcısıyla gerçekleştirilen uygulamanın karışıklık matrisini göstermektedir. Şekil 4.6(c)'de Yumuşak Oylama topluluk sınıflandırıcılarla en yüksek doğruluk değerlerinin (93,63) elde edildiği DenseNet201 TÖ modeline ait derin özniteliklerin (DenseNet201(F)) kullanıldığı uygulamaya ait karışıklık-matrisini göstermektedir. Şekil 4.6(d)'de ise Katı Oylama topluluk sınıflandırıcılarla en yüksek doğruluk değerlerinin (93,52) elde edildiği MobileNet TÖ modeline ait derin özniteliklerin (MobileNet(F)) kullanıldığı uygulamaya ait karışıklık-matrisini göstermektedir.



Şekil 4.6. İki sınıflı test veri seti için en iyi doğruluk karışıklık-matrisler

5. TARTIŞMA

Bu çalışmada, X-Ray görüntülerden ön-eğitilmiş TÖ modeller kullanılarak elde edilmiş derin öznitelikler ve bu özniteliklerin seçilmiş en iyi beş klasik MÖ modeli tarafından işlendiği topluluk öğrenme yapısına dayalı DeepFeat-E isimli hibrit bir yapay zekâ sistemi önerilmiştir. Literatürde COVID-19 ve diğer alt solunum yolları enfeksiyon hastalıkları teşhisiyle ilgili derin ağlara dayalı birçok yapay zekâ sistemleri olmakla birlikte bu çalışma topluluk öğrenme yöntemlerine dayalı olduğundan bunlardan ayrılmaktadır (Apostolopoulos ve Mpesiana, 2020; Wang vd., 2020; Ozturk vd., 2020; Khan vd., 2020; Ahamed vd., 2021; Huang ve Liao, 2022; Islam vd., 2022). Diğer taraftan literatürde topluluk sınıflandırıcı kullanılan benzer çalışmalar olmakla birlikte, bu çalışmalarda aynı evrimsel sinir ağının ya da TÖ modelinin eğitim süreci sırasındaki anlık görüntülerinin topluluk sınıflandırıcıda ayrı sınıflandırıcılar olarak kullanıldığı çeşitli çalışmalar olduğu görülmektedir (Chowdhury vd. 2020; Mahmud vd., 2020; Karim vd. 2020; Tang vd., 2021; Banerjee vd., 2022; Gour ve Jain, 2022). Oysa bu çalışmada önerilen sistemde, ön-eğitilmiş TÖ modellerden derin öznitelikler alınmakta ve bu öznitelikler klasik MÖ yöntemleri kullanılarak topluluk öğrenme yöntemlerinde sınıflandırılmaktadır. Önerilen sistemde yalnızca topluluk öğrenme yöntemlerinde bir eğitim söz konusudur. Ayrıca çalışmayı değerli kılan diğer hususlar, veri setinin genişliği, sınıf sayısı, kullanılan TÖ modelleri çeşitliliği ve derin özniteliklerin elde edilme, işleme biçimi olarak sıralanabilir.

Karşılaştırma amacıyla, bu çalışmada önerilen hibrit modelin ve literatürde yapılan benzer diğer çalışmaların performansları Tablo 5.1’de listelenmiştir. Tabloda X-Ray görüntülerle ilgili çalışmalarda kullanılan derin öğrenme modelleri, mimarileri, kullanılan veri ve sınıf sayıları ve elde edilen başarı oranları verilmiştir. Tablo 5.1.’e bakıldığında başarı oranlarının görüntülerin kategorik sınıf sayılarına ve kullanılan veri setlerine göre farklılık gösterdiği görülmektedir.

Tablo 5.1. COVID-19 ve alt solunum yolları hastalık teşhisi yapılan çalışmaların karşılaştırması

Çalışma	Mimari	Yöntem	Topluluk Yapısı	Örnek Sayısı	Sınıf Sayısı	Doğ. (%)
Karim vd. (2020)	VGG19, ResNet-18, ve DenseNet-161	DeepCOVIDExplainer	Evet	COVID-19: 358, Pnömoni: 5538, Normal: 8066	3	96,10
Mahmud vd., (2020)	ESA	CovXNet	Evet	COVID-19: 305, Pnömoni-Bakteriyel: 305, Pnömoni-Viral: 305, Normal: 305	4 3 2	90,3 89,6 97,4
Chowdhury vd. (2020)	EfficientNet	ECOVNet	Evet	COVID-19: 589, Pnömoni: 6053, Normal: 8851	3	97,00
Apostolopoulos ve Mpesiana (2020)	ESA	VGG19	Hayır	COVID-19: 224, Pnömoni-Bakteriyel: 700, Normal: 504	3 2	93,48 98,75
Wang vd. (2020)	COVID-Net	COVID-Net	Hayır	COVID-19: 358, Pnömoni: 5538, Normal: 8066	3	93,30
Ozturk vd. (2020)	Yolo	DarkCovidNet	Hayır	COVID-19: 125, Pnömoni: 500, Bulgu-Yok: 500	3 2	87,02 98,08
Khan vd. (2020)	Xception	CoroNet	Hayır	COVID-19: 284, Pnömoni-Bakteriyel: 330, Pnömoni-Viral: 327, Normal: 310	4 3 2	89,65 94,59 99,0
Ahamed vd. (2021)	Transfer yöntem	Modifiye ResNet50V2	Hayır	COVID-19: 1143, Pnömoni: 1150, Bakteriyel Pnömoni: 1150, normal: 1150	4 3 2	96,45 97,24 99,35
Tang vd., 2021	COVID-Net	EDL-COVID	Evet	COVID-19: 573, Pnömoni: 6053, Normal: 8851	3	95,00
Huang ve Liao, 2022	Transfer yöntem	LightEfficientNetV2	Hayır	COVID-19: 600, Pnömoni: 600, Normal: 600	3	98,33
Islam vd. (2022)	ESA	Cov-RADNet	Hayır	COVID-19: 3616, Akciğer-Opaklığı: 6012	4 3 2	97,0 99,5 99,72

				Viral-Pnömoni:	1345,		
				Normal:	10192		
Banerjee vd., 2022	DenseNet-201	DenseNet-201+Blending wRF	Evet	COVID-19: Pnömoni:	568, 6052, Normal: 8851	3	94,55
Banerjee vd., 2022	DenseNet-201	DenseNet-201+Blending (RF)	Evet	COVID-19: Pnömoni:	219, 1345, Normal: 1341	3	94,13
Gour ve Jain, 2022)	Xception ve Vgg19	Yığın ESA	Evet	COVID-19: Pnömoni:	546, 1355, Normal: 1139	3	97,27
Hopstaken vd, 2004	Kappa	İstatistiksel Yaklaşımlar	Yok	Verem MR		2	77.00
Chen vd, 2020	Yolo, ESA	YOLOV3, ESA	Yok	Çocuklarda Bronşit		5	92.47
Çelik, 2023	CovidDW Net+GB	CovidDWNet	Yok	Akciğer Opasitesi, Normal ve Viral Pnömoni		3	96.32
Bhandari vd, 2022	ESA	CHAP, LIME, GRADCAM	Yok	Verem, zatürre, Covid-19		3	94.57
Alshmrani vd, 2023	ESA	VGG19	Yok	zatürre, akciğer kanseri, tüberküloz, akciğer opaklığı ve COVID-19		5	96.48
Bu çalışma	Derin	DeepFeat-E	Evet	COVID-19:	3616,	4	90,17
	öznitelikle			Akciğer-Opaklığı:	6012,	3	94,99
	r+Toplulu			Normal:	10192, Viral-	2	94,93
	k öğrenme			Pnömoni:	1345		

Bu çalışmada önerilen sistemde en yüksek doğruluk değerleri DenseNet201 TÖ modeline ait derin öznitelikler ve İstifleme topluluk öğrenme yöntemi kullanılarak elde edilmiştir. Buna göre, test veri seti için dört, üç ve iki sınıflı veri setlerinin doğruluk değerleri sırasıyla 90,17%, 94,99% ve 94,93% olarak elde edilmiştir. Dolayısıyla önerilen hibrit yaklaşımın kabul edilebilir makul bir doğruluğa sahip olduğu ve 10 örnekten yaklaşık olarak en az 9'unu doğru teşhis edebildiği anlaşılmaktadır. Literatürdeki diğer çalışmalarla kıyaslandığında daha yüksek doğruluk değerlerine ulaşılan çalışmalar bulunduğu görülmektedir (Tablo 5.1). Ancak buradaki çalışmada kullanılan veri setinin çok daha geniş olmasının bu başarı farkının altında yatan sebep olduğu düşünülmektedir. Aynı veri setini kullanan İslam ve arkadaşları (İslam vd., 2022) yaptıkları çalışmada da daha başarılı sonuçlar elde etmişlerdir (Tablo 5.1). Fakat söz konusu çalışmalarında, her bir sınıf için farklı örnekler içeren bu veri setinin sınıf bazlı örnek sayısını eşitleyerek

(dengeli) analizlerini gerçekleştirmişlerdir. Aksine bu çalışmada veri setindeki sınıf bazlı örnek sayıları eşitlenmemiş ve dengesiz sınıf örnek sayıları kullanılarak analizler gerçekleştirilmiştir.

Ayrıca önerilen DeepFeat-E isimli hibrit modelin, TÖ modelleri doğrudan kullanıldığında elde edilen performanslara kıyasla daha başarılı olduğunu ve teşhis doğruluğunu arttırdığı görülmüştür. Buna göre dört sınıflı test veri seti için TÖ modelleri doğrudan kullanıldığında en yüksek doğruluk MobileNet ile 85,09% olarak elde edilmiş ve aynı model için önerilen hibrit sistemin kullanıldığı doğruluk İstifleme topluluk öğrenme yöntemiyle 88,09% (+3 puan) değerine yükselmiştir. Benzer şekilde üç ve iki sınıflı test veri setleri için en yüksek doğruluk sırasıyla 90,53% ve 91,53% olarak MobileNet TÖ modeli ile elde edilmiştir. Aynı şekilde önerilen hibrit sistem kullanıldığında doğruluk İstifleme topluluk öğrenme yöntemiyle 93,99% (+2,46 puan) ve 93,67% (+3,13 puan) değerlerine yükselmiştir. Tablo 4.8 ve Tablo 4.9’de görüldüğü gibi topluluk sınıflandırıcıların tümü TÖ modellerinden daha yüksek doğruluk değerlerine sahip olup önerilen hibrit sistemin başarıyı önemli ölçüde arttırdığı görülmektedir. Sonuç olarak, önerilen hibrit modelin COVID-19 ve diğer alt solunum yolu enfeksiyonların teşhisinde TÖ modellerinden daha başarılı olduğu ve literatürde yer alan diğer çalışmalarla da kıyaslandığında makul seviyede bir başarıya sahip olduğu görülmektedir.

6. SONUÇ

COVID-19 ve diğer alt solunum yolları enfeksiyon hastalıklarının neden olduğu gerek insan sağlığı gerekse ekonomik zararların etkisini azaltma hastalığın hızlı ve doğru bir şekilde teşhisi ile doğrudan ilişkilidir. Bu nedenle alt solunum yolları enfeksiyon hastalıklarının hızlı teşhis edilmesi, tanımlanması, tedavisi ve izolasyonu son derece önemlidir. Hastalığın teşhisinde kullanılan, PCR testi ya da BT veya X-Ray görüntülerin manuel yorumlanması gibi yöntemler bilinen geleneksel yöntemlerdir. Bununla birlikte günümüzde daha hızlı ve daha güvenli yöntemler olduklarından tıbbi görüntü tabanlı yapay zekâ sistemleri ve özellikle derin öğrenme yöntemleri COVID-19 ve diğer alt solunum yolları enfeksiyon hastalıklarının teşhisinde başarılı bir şekilde uygulanmaktadır.

Literatürde topluluk öğrenme yöntemlerinin kullanıldığı alt solunum yolları enfeksiyon hastalıklarının teşhisi yapılan benzer yapay zekâ çalışmaları olmakla birlikte bu çalışmalarda aynı eğitim sürecinde elde edilen anlık yansılardan topluluk sınıflandırıcı olarak kullanıldığı görülmektedir. Bu çalışmada önerilen DeepFeat-E isimli hibrit teşhis sistemiyle ise ön-eğitilmiş TÖ modellerinden elde edilen derin öznitelikler ve klasik makine öğrenimi yöntemlerinden oluşan sınıflandırıcılar kullanılarak X-Ray görüntülerden alt solunum yolları enfeksiyon hastalıklarının teşhisi gerçekleştirilmeye çalışılmıştır. Önerilen sistemin en yüksek başarıyı DenseNet201 TÖ modellerine ait derin öznitelikler ve İstifleme topluluk öğrenme yöntemiyle elde edildiği görülmüştür. Buna göre dört, üç ve iki sınıflı uygulamalarda sırasıyla test doğruluğu 90,17%, 94,99% ve 94,93% olarak elde edilmiştir. Ayrıca sistemin tüm TÖ modellerinde elde edilen doğruluk değerlerini değişen miktarlarda arttırdığı görülmüştür (Tablo 4.8). Önerilen sistemin ön-eğitilmiş TÖ modelleri kullanması, hem modellerin eğitimi için gerekli büyük verinin ihtiyacını ortadan kaldırmak hem de kaynak ve zaman maliyetlerini düşürmek gibi önemli avantajlara sahiptir. Dolayısıyla bu çalışmada elde edilen sonuçlar, önerilen DeepFeat-E isimli hibrit sisteminin COVID-19 ve alt solunum yolu enfeksiyonlarının teşhisinde hızlı ve güvenilir bir şekilde kullanılabileceğini göstermektedir. İleriki çalışmalarda bu yöntemin veya benzer hibrit modeller ile farklı görüntülerin sınıflandırılmasında da kullanılabileceği ile ilgili çalışmalar yapılacaktır.

KAYNAKLAR

- Abir, F. F., Alyafei, K., Chowdhury, M. E., Khandakar, A., Ahmed, R., Hossain, M. M. and Naji, K. K., 2022, PCovNet: A presymptomatic COVID-19 detection framework using deep learning model using wearables data, *Computers in biology and medicine*, 147, 105682.
- Ahamed, K. U., Islam, M., Uddin, A., Akhter, A., Paul, B. K., Yousuf, M. A., ... and Moni, M. A., 2021, A deep learning approach using effective preprocessing techniques to detect COVID-19 from chest CT-scan and X-ray images, *Computers in biology and medicine*, 139, 105014.
- Alshmrani, G. M. M., Ni, Q., Jiang, R., Pervaiz, H. and Elshennawy, N. M., 2023, A deep learning architecture for multi-class lung diseases classification using chest X-ray (CXR) images, *Alexandria Engineering Journal*, 64, 923-935.
- Apostolopoulos, I. D. and Mpesiana, T. A., 2020, Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks, *Physical And Engineering Sciences in Medicine*, 43 (2), 635-640.
- Ashwinkumar, S., Rajagopal, S., Manimaran, V. and Jegajothi, B., 2022, Automated plant leaf disease detection and classification using optimal MobileNet based convolutional neural networks, *Materials Today: Proceedings*, 51, 480-487.
- Aslan, M. F., Sabanci, K., Durdu, A., and Unlarsen, M. F., 2022, COVID-19 diagnosis using state-of-the-art CNN architecture features and Bayesian Optimization, *Computers in biology and medicine*, 142, 105244.
- Aswathy, A. L., Hareendran, A., and S. S., V. C., 2021, COVID-19 diagnosis and severity detection from CT-images using transfer learning and back propagation neural network. *Journal of Infection and Public Health*, 14 (10), 1435-1445.
- Basu, A., Sheikh, K. H., Cuevas, E., and Sarkar, R., 2022, COVID-19 detection from CT scans using a two-stage framework, *Expert Systems with Applications*, 193, 116377.
- Banerjee, A., Sarkar, A., Roy, S., Singh, P. K., and Sarkar, R., 2022, COVID-19 chest X-ray detection through blending ensemble of CNN snapshots, *Biomedical Signal Processing and Control*, 78, 104000.
- Bhandari, M., Shahi, T. B., Siku, B., and Neupane, A., 2022, Explanatory classification of CXR images into COVID-19, Pneumonia and Tuberculosis using deep learning and XAI, *Computers in Biology and Medicine*, 150, 106156.
- Bohmrah, M. K. and Kaur, H., 2021, Classification of Covid-19 patients using efficient fine-tuned deep learning DenseNet model, *Global Transitions Proceedings*, 2 (2), 476-483.

- Buonsenso, D., Musolino, A., Ferro, V., De Rose, C., Morello, R., Ventola, C. and Valentini, P., 2022, Role of lung ultrasound for the etiological diagnosis of acute lower respiratory tract infection (ALRTI) in children: a prospective study. *Journal of Ultrasound*, 25 (2), 185-197.
- Breve, F. A., 2022, COVID-19 detection on Chest X-ray images: A comparison of CNN architectures and ensembles, *Expert Systems With Applications*, 204, 117549.
- Celik, G., 2023, Detection of Covid-19 and other pneumonia cases from CT and X-ray chest images using deep learning based on feature reuse residual block and depthwise dilated convolutions neural network, *Applied Soft Computing*, 133, 109906.
- Chen, Y., Yi, H., Liao, C., Huang, P. and Chen, Q., 2021, Visual measurement of milling surface roughness based on Xception model with convolutional neural network, *Measurement*, 186, 110217.
- Chen, K. C., Yu, H. R., Chen, W. S., Lin, W. C., Lee, Y. C., Chen, H. H., ... and Lu, H. H. S., 2020, Diagnosis of common pulmonary diseases in children by X-ray images and deep learning, *Scientific reports*, 10(1), 17374.
- Chollet, F., 2017, Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition* (pp. 1251-1258).
- Chowdhury, M. E., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., and Islam, M. T., 2020, Can AI help in screening viral and COVID-19 pneumonia?, *IEEE Access*, 8, 132665-132676.
- Das, D., Santosh, K. C. and Pal, U., 2020, Truncated inception net: COVID-19 outbreak screening using chest X-rays, *Physical And Engineering Sciences in Medicine*, 43 (3), 915-925.
- Dey, S., Bhattacharya, R., Malakar, S., Schwenker, F., and Sarkar, R., 2022, CovidConvLSTM: A fuzzy ensemble model for COVID-19 detection from chest X-rays, *Expert Systems with Applications*, 206, 117812.
- Dwivedy, V., Shukla, H. D., and Roy, P. K., 2022, LMNet: Lightweight multi-scale convolutional neural network architecture for COVID-19 detection in IoMT environment, *Computers and Electrical Engineering*, 103, 108325.
- Geurts, P., Ernst, D. and Wehenkel, L., 2006, Extremely randomized trees, *Machine Learning*, 63 (1), 3-42.
- Gilanig, G., Bajwa, U. I., Waraich, M. M., Asghar, M., Kousar, R., Kashif, A., and Rafique, H., 2021, Coronavirus (COVID-19) detection from chest radiology images using convolutional neural networks, *Biomedical Signal Processing and Control*, 66, 102490.

- Ghrieb, Z., Salmona, M., Michonneau, D., De Saisset, C., Allaoua, S., Kiladjian, J. J., and Benajiba, L., 2023, Impact of the COVID-19 pandemic on antiviral drug development for other community-acquired respiratory viruses' infections. *Therapies*, 78(3), 241-245.
- Gour, M., and Jain, S., 2022, Automated COVID-19 detection from X-ray and CT images with stacked ensemble convolutional neural network, *Biocybernetics and Biomedical Engineering*, 42(1), 27-41.
- Gupta, P. K., Siddiqui, M. K., Huang, X., Morales-Menendez, R., Panwar, H., Terashima-Marin, H., and Wajid, M. S., 2022, COVID-WideNet—A capsule network for COVID-19 detection, *Applied Soft Computing*, 122, 108780.
- He, K., Zhang, X., Ren, S. and Sun, J., 2016, Identity mappings in deep residual networks. In *European conference on computer vision* (pp. 630-645). Springer, Cham.
- Hopstaken, R. M., Witbraad, T., Van Engelshoven, J. M. A. and Dinant, G. J., 2004, Inter-observer variation in the interpretation of chest radiographs for pneumonia in community-acquired lower respiratory tract infections, *Clinical radiology*, 59 (8), 743-752.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T. and Adam, H., 2017, Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Huang, G., Liu, S., Van der Maaten, L. and Weinberger, K. Q., 2018, Condensenet: An efficient densenet using learned group convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2752-2761).
- Hu, Z., Yang, L., Han, J., Liu, Z., Zhao, Y., Jin, Y., and Hu, B., 2022, Human viruses lurking in the environment activated by excessive use of COVID-19 prevention supplies, *Environment International*, 163, 107192.
- Huang, M. L., and Liao, Y. C., 2022, A lightweight CNN-based network on COVID-19 detection using X-ray and CT images, *Computers in Biology and Medicine*, 146, 105604.
- Ilkhani, H., Hedayat, N., and Farhad, S., 2021, Novel approaches for rapid detection of COVID-19 during the pandemic: A review, *Analytical biochemistry*, 634, 114362.
- Islam, M. K., Habiba, S. U., Khan, T. A., and Tasnim, F., 2022, COV-RadNet: A Deep Convolutional Neural Network for Automatic Detection of COVID-19 from Chest X-Rays and CT Scans, *Computer Methods and Programs in Biomedicine Update*, 2, 100064.
- Karim, M. R., Döhmen, T., Cochez, M., Beyan, O., Rebholz-Schuhmann, D. and Decker, S., 2020, Deepcovidexplainer: explainable COVID-19 diagnosis from chest X-ray images. In *2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)* (pp. 1034-1037). IEEE.

- Kaya, Y. and Tekin, R., 2018, Epileptik EEG İşaretlerinin Sınıflandırılması İçin Yeni Bir Öznitelik Çıkarım Yöntemi. *Journal of Natural and Applied Sciences*, 22, 529-535.
- Khan, S. H., Sohail, A., Khan, A., Hassan, M., Lee, Y. S., Alam, J., and Zubair, S., 2021, COVID-19 detection in chest X-ray images using deep boosted hybrid learning, *Computers in Biology and Medicine*, 137, 104816.
- Kong, L., and Cheng, J., 2022, Classification and detection of COVID-19 X-Ray images based on DenseNet and VGG16 feature fusion, *Biomedical Signal Processing and Control*, 77, 103772.
- Kumari, S., Ranjith, E., Gujjar, A., Narasimman, S. and Zeelani, H. A. S., 2021, Comparative analysis of deep learning models for COVID-19 detection, *Global Transitions Proceedings*, 2 (2), 559-565.
- Kuncan, F., Kaya, Y., Yiner, Z., and Kaya, M., 2022, A new approach for physical human activity recognition from sensor signals based on motif patterns and long-short term memory, *Biomedical Signal Processing and Control*, 78, 103963.
- Lewnard, J. A. and Lo, N. C., 2020, Scientific and ethical basis for social-distancing interventions against COVID-19, *The Lancet infectious diseases*, 20 (6), 631-633.
- Lu, S. Y., Wang, S. H. and Zhang, Y. D., 2020, A classification method for brain MRI via MobileNet and feedforward network with random weights, *Pattern Recognition Letters*, 140, 252-260.
- Mahmud, T., Rahman, M. A., and Fattah, S. A., 2020, CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization, *Computers in biology and medicine*, 122, 103869.
- Magrelli, S., Valentini, P., De Rose, C., Morello, R., and Buonsenso, D., 2021, Classification of lung disease in children by using lung ultrasound images and deep convolutional neural network, *Frontiers in Physiology*, 12, 693448.
- Michele, A., Colin, V. and Santika, D. D., 2019, Mobilenet convolutional neural networks and support vector machines for palmprint recognition, *Procedia Computer Science*, 157, 110-117.
- Nan, Y., Ju, J., Hua, Q., Zhang, H., and Wang, B., 2022, A-MobileNet: An approach of facial expression recognition, *Alexandria Engineering Journal*, 61(6), 4435-4444.
- Nigam, B., Nigam, A., Jain, R., Dodia, S., Arora, N., and Annappa, B., 2021, COVID-19: Automatic detection from X-ray images by utilizing deep learning methods, *Expert Systems with Applications*, 176, 114883.
- Noyan, T., Kuncan, F., Tekin, R. and Kaya, Y., 2022, A new content-free approach to identification of document language: Angle patterns, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (3), 1277-1292.

- Oğuz, Ç., and Yağanoğlu, M., 2022, Detection of COVID-19 using deep learning techniques and classification methods, *Information Processing & Management*, 59(5), 103025.
- Ozcan, T., 2021, A new composite approach for COVID-19 detection in X-ray images using deep features, *Applied Soft Computing*, 111, 107669.
- Pang, L., Liu, S., Zhang, X., Tian, T., and Zhao, Z., 2020, Transmission dynamics and control strategies of COVID-19 in Wuhan, China. *Journal of Biological Systems*, 28(03), 543-560.
- Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Kashem, S. B. A., ... and Chowdhury, M. E., 2021, Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images, *Computers in biology and medicine*, 132, 104319.
- Ren, Z., Chang, Y., Bartl-Pokorny, K. D., Pokorny, F. B., and Schuller, B. W., 2022, The acoustic dissection of cough: diving into machine listening-based COVID-19 analysis and detection, *Journal of Voice*, 4,124
- Sani, S., and Shermeh, H. E., 2022, A novel algorithm for detection of COVID-19 by analysis of chest CT images using Hopfield neural network, *Expert Systems with Applications*, 197, 116740.
- Sarkar, D., Bali, R. and Ghosh, T., 2018, Hands-On Transfer Learning with Python: Implement advanced deep learning and neural network models using TensorFlow and Keras. Packt Publishing Ltd.
- Shetty, A. A., Hegde, N. T., Vaz, A. C. and Srinivasan, C. R., 2021, Deep learning methodologies for diagnosis of respiratory disorders from chest X-ray images: A Comparative Study, *In Computer Sciences & Mathematics Forum*, 2(1),1-20
- Syrjala, H., Broas, M., Ohtonen, P., Jartti, A. and Pääkkö, E., 2017, Chest magnetic resonance imaging for pneumonia diagnosis in outpatients with lower respiratory tract infection. *European Respiratory Journal*, 49 (1),12345.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. and Wojna, Z., 2016, Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition* (pp. 2818-2826).
- Simonyan, K., and Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Sobahi, N., Atila, O., Deniz, E., Sengur, A., and Acharya, U. R., 2022, Explainable COVID-19 detection using fractal dimension and vision transformer with Grad-CAM on cough sounds, *Biocybernetics and Biomedical Engineering*, 42(3), 1066-1080.
- Srivastava, G., Chauhan, A., Jangid, M., and Chaurasia, S., 2022, CoviXNet: A novel and efficient deep learning model for detection of COVID-19 using chest X-Ray images, *Biomedical Signal Processing and Control*, 78, 103848.

- Subramanian, N., Elharrouss, O., Al-Maadeed, S., and Chowdhury, M., 2022, A review of deep learning-based detection methods for COVID-19, *Computers in Biology and Medicine*, 143, 105233.
- Tang, S., Wang, C., Nie, J., Kumar, N., Zhang, Y., Xiong, Z. and Barnawi, A., 2021, EDL-COVID: Ensemble deep learning for COVID-19 case detection from chest X-ray images. *IEEE Transactions on Industrial Informatics*, 17 (9), 6539-6549.
- Tung, H., 2021, Görüntüye dayalı dudak okuma uygulamalarında uzamsal dudak noktaları temelli yeni öznitelik yaklaşımları, Yüksek Lisans Tezi, *Batman Üniversitesi Fen Bilimleri Enstitüsü*.
- Verma, S. S., Prasad, A., and Kumar, A., 2022, CovXmlc: High performance COVID-19 detection on X-ray images using Multi-Model Classification, *Biomedical signal processing and control*, 71, 103272.
- Wang, Y., Kang, H., Liu, X., and Tong, Z., 2020, Combination of RT-qPCR testing and clinical features for diagnosis of COVID-19 facilitates management of SARS-CoV-2 outbreak, *Journal of medical virology*, 92(6), 538.
- Wolpert, D. H., 1992, Stacked generalization, *Neural networks*, 5 (2), 241-259.
- Yuan, J., Liu, H., Liu, W., Wang, F., and Peng, S., 2022, A method for melt pool state monitoring in laser-based direct energy deposition based on DenseNet, *Measurement*, 195, 111146.
- Zhou, K., Greenspan, H. and Shen, D., 2017, Deep learning for medical image analysis. Academic Press.
- Zhou, Z. H., 2021, Ensemble learning. In *Machine Learning* (pp. 181-210). Springer, Singapore.
- Zhu, Y., JiaYI, H., Li, Y., and Li, W., 2022, Image identification of cashmere and wool fibers based on the improved Xception network, *Journal of King Saud University-Computer and Information Sciences*, 34(10), 9301-9310.
- Zoph, B., Vasudevan, V., Shlens, J. and Le, Q. V., 2018, Learning transferable architectures for scalable image recognition. In *Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition* (pp. 8697-8710).

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Berivan ÖZAYDIN
Uyruğu : TC

EĞİTİM

Derece	Adı, İl	Bitirme Yılı
Üniversite :	Siirt Üniversitesi, Siirt	2020
Yüksek Lisans :	Batman Üniversitesi, Batman	2023
Doktora :		

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2021-2022	TEGV	Bilgi Teknolojileri Uzmanı
2022-...	Akbank	Sistem Yönetimi Uzmanı

UZMANLIK ALANI

YABANCI DİLLER

YAYINLAR

Özaydın, B., & Tekin, R. (2023). A Hybrid Model Based On Deep Features And Ensemble Learning For The Diagnosis Of Covid-19: Deepfeat-E. *Turkish Journal Of Science And Technology*, 18(1), 183-198.

Özaydın, B., & Tekin, R. (2023). X-Ray Görüntülerden Densenet Derin Öznitelikler Ve Oylama Topluluk Sınıflandırıcılar Temelli Covid-19 Teşhisi, Uluslararası Bilişim Kongresi, Batman-2023

Özaydın, B., & Tekin, R. (2022). Kümeleme Yöntemleri İle Kodon Frekansları Temelli Dna-Tür Ve Alem Tahmini, Uluslararası Bilişim Kongresi, Batman-2022