



**EVRIŞİMSEL SİNİR AĞLARI İLE AKCİĞER X-RAY
GÖRÜNTÜLERİNDEN COVID-19 TESPİTİ VE HİBRİT MODEL ÖNERİSİ**

Furkan ERYILMAZ

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR BİLİMLERİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ**

KASIM 2021

ETİK BEYAN

Gazi Üniversitesi Bilişim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İmza
Furkan ERYILMAZ
...../...../.....

EVRIŞİMSEL SİNİR AĞLARI İLE AKCİĞER X-RAY GÖRÜNTÜLERİNDEN COVID-19 TESPİTİ VE HİBRİT MODEL ÖNERİSİ

(Yüksek Lisans Tezi)

Furkan ERYILMAZ

GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ
Kasım 2021

ÖZET

2019 yılının sonunda ortaya çıkan COVID-19 salgını etkisini hala sürdürmektedir. Salgının ilk günlerinde virüse karşı herhangi bir ilaç bulunamamıştır. Zamanla geliştirilen pasif ve mRNA tabanlı aşılardan; virüsün farklı mutasyonlarına karşı etkinliğinin değişkenlik göstermesi, olası yan etkilerinin bilinmemesi, toplumlarda aşı olmayan kişilerin bulunması, aşının tedariki ve saklanmasıyla ilgili yaşanması muhtemel problemler gibi göstergeler salgının yakın gelecekte sonlanmayacağını göstermektedir. Dünya Sağlık Örgütü'nün salgın ile mücadelede tavsiye kararları vermesine rağmen ülkeler virüse karşı farklı yöntemler izlemektedir. Fakat tüm farklılıklara rağmen izlenen ortak yöntem hastalığın tespiti ve izolasyonu şeklindedir. Bu yüzden koronavirüs tanısının doğru konması kritik öneme sahiptir. Dünya üzerinde hala test kitlerine ulaşamayan birçok ülkenin bulunması ve yeni bir alt yapı kurmanın kendine özgü zorlukları göz önüne alındığında ortaya konacak çözümün mevcut tıbbi kabiliyetleri kullanması oldukça önemlidir. Sağlık merkezlerinde standart ekipman kabul edilen, maliyet etkin ve kolay erişilebilir olan X-Ray görüntüleme yöntemi bu hususta umut vaat etmektedir. Tez kapsamında akciğer X-Ray görüntülerinden COVID-19 tespiti üzerine çalışılmıştır. X-Ray görüntülerinden diğer akciğer hastalıkları ile karıştırılabilen koronavirüs tespiti ancak uzman radyologlar tarafından yapılabilmektedir. İlgili problemlerin yüksek doğrulukta sınıflandırma yapabilen evrişimsel sinir ağları ile aşılması mümkün gözükmemektedir. Son zamanlarda birleştirilmiş sistemler yani birden çok sınıflandırıcıyı barındıran mimariler sağlık ve bilgisayarlı görüye ait gerçek dünya problemlerinde çok daha etkili sonuçlar ortaya koymaktadır. Bu mimarilerde toplam sistem hatasında düşüş elde edilirken daha başarılı sınıflandırmalar yapılmaktadır. İlgili çalışma kapsamında MobileNetV2, DenseNet121, InceptionResNetV2 ve Xception ağları kullanılarak ikili ve çoklu sınıflandırma performansları incelenmiştir. Sonraki adımda bu modeller topluluk öğrenmesi ile birleştirilerek daha etkili ikili ve çoklu sınıflandırma için hibrit model ortaya konmuştur.

Bilim Kodu : 92431

Anahtar Kelimeler : Makine öğrenmesi, transfer öğrenimi, görüntü sınıflandırma, X-Ray, topluluk öğrenimi, evrişimsel sinir ağları

Sayfa Adedi : 66

Danışman : Doç. Dr. Hacer KARACAN

COVID-19 DETECTION FROM CHEST X-RAY IMAGES AND HYBRID MODEL RECOMMENDATION WITH CONVOLUTIONAL NEURAL NETWORKS

(M. Sc. Thesis)

Furkan ERYILMAZ

GAZİ UNIVERSITY
INFORMATICS INSTITUTE
November 2021

ABSTRACT

The COVID-19 pandemic, which emerged at the end of 2019, continues to be effective. In the first days of the epidemic, no medicine was found against the virus. Indicators such as the variability of the effectiveness of passive and mRNA-based vaccines against different mutations of the virus, the unknown possible side effects, the presence of unvaccinated people in the population, possible problems with the supply and storage of the vaccine show that the epidemic will not end in the near future. Despite the World Health Organization's recommendations to combat the epidemic, countries follow different methods against the virus. However, despite all the differences, the common method followed is the detection and isolation of the disease. That's why the correct diagnosis of coronavirus is critical. Considering the fact that there are many countries in the world that still cannot reach test kits and the unique difficulties of establishing a new infrastructure, it is very important that the solution to be put forward uses existing medical capabilities. X-Ray imaging devices, which is accepted as standard equipment in health centers, seems promising for this issue since it is cost effective and easily accessible. Within the scope of the thesis, the detection of COVID-19 from lung X-Ray images was studied. Corona virus detection, which can be confused with other lung diseases from X-Ray images, can only be made by expert radiologists. It seems possible to overcome the related problems with convolutional neural networks that can classify with high accuracy. Ensembled systems, that is, architectures with multiple classifiers, show much more effective results in real-world problems of health and computer vision. In these architectures, while a reduction in total system error is achieved, more successful classifications are made. Within the scope of the related study, binary and multiple classification performances were examined using MobileNetV2, DenseNet121, InceptionResNetV2 and Xception networks. In the next step, these models are combined with ensemble learning and a hybrid model is developed for more effective binary and multiple classification.

Science Code : 92431

Key Words : Machine learning, transfer learning, image classification, X-Ray, ensemble learning, convolutional neural networks

Page Number : 66

Supervisor : Assoc. Prof. Dr. Hacer KARACAN

TEŞEKKÜR

Bilinmezliklerle dolu COVID-19 salgını boyunca mücadelede en ön safta yer alan ve hayatını kaybeden tüm sağlık çalışanlarına, tez çalışmam boyunca değerli katkılarıyla beni yönlendiren danışman hocam Sayın Doç. Dr. Hacer KARACAN'a, her zaman yanımda olan eşime ve aileme teşekkürü borç bilirim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ	x
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI.....	7
3. TEKNİK ARKA PLAN	19
3.1. Evrişimsel Sinir Ağları (Convolutional Neural Networks).....	19
3.1.1. Evrişim Katmanı (Convolutional Layer).....	20
3.1.2. Ortaklama Katmanı (Pooling Layer)	22
3.1.3. Tam Bağlantılı Katman (Fully-Connected Layer).....	23
3.2. Optimizasyon Algoritmaları	23
3.3. Transfer Öğrenimi (Transfer Learning).....	25
3.4. Topluluk Derin Öğrenmesi (Ensemble Deep Learning).....	27
4. YÖNTEM VE UYGULAMA	29
4.1. Veri Seti	29
4.2. Veri Ön İşleme.....	30
4.3. Kullanılan Araçlar.....	31
4.4. Üzerinde Çalışılan Evrişimsel Sinir Ağları.....	32
4.4.1. MobileNetV2	33
4.4.2. DenseNet121.....	34
4.4.3. Xception.....	36

	Sayfa
4.4.4. InceptionResNetV2.....	37
4.5. Önerilen Yaklaşım	40
5. BULGULAR	45
6. SONUÇLAR VE TARTIŞMA.....	53
KAYNAKLAR	55
EKLER.....	63
EK-1. Evrimsel sinir ağlarının günümüz modern mimarilerine zamansal gelişimi.....	64
EK-2. Topluluk öğrenmesiyle birleştirilmiş hibrit modele ait özet bilgi.....	65
ÖZGEÇMİŞ	66

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Optimizasyon algoritmalarının karşılaştırılması.....	25
Çizelge 4.1. Veri setinde sınıflandırma etiketine göre görüntü dağılımı	29
Çizelge 4.2. Veri setinden oluşturulan alt veri setleri	30
Çizelge 4.3. Alt veri setlerinin sınıflandırma etiketlerine göre dağılımı	30
Çizelge 4.4. Virgülle ayrılmış dosya yapısı	31
Çizelge 4.5. Çalışmada kullanılan ESA mimarilerinin karşılaştırılması	39
Çizelge 4.6. Modellere ait parametre bilgisi	44
Çizelge 5.1. İkili sınıflandırma sonuçları	45
Çizelge 5.2. Çoklu sınıflandırma sonuçları	46
Çizelge 5.3. Mevcut çalışma ve diğer çalışmaların karşılaştırılması	51

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Ağustos 2021 dünya koronavirüs istatistiği.....	1
Şekil 3.1. Evrişimsel sinir ağ taksonomisi	19
Şekil 3.2. Geleneksel evrişimsel sinir ağ mimarisi	20
Şekil 3.3. Sigmoid aktivasyon fonksiyonu	21
Şekil 3.4. Tanjant aktivasyon fonksiyonu.....	21
Şekil 3.5. Doğrultulmuş doğrusal birim aktivasyon fonksiyonu	22
Şekil 3.6. Sızdırılmış doğrultulmuş doğrusal birim aktivasyon fonksiyon.....	22
Şekil 3.7. Transfer öğrenimi kategorileri.....	26
Şekil 4.1. Sınıflandırma etiketine göre akciğer X-Ray görüntüleri	30
Şekil 4.2. Çalışma kapsamında izlenen transfer öğrenimi yaklaşımı	33
Şekil 4.3. MobileNetV2 mimarisi.....	34
Şekil 4.4. DenseNet121 yoğun bloklar ve geçiş katmanları arasındaki ilişki.....	35
Şekil 4.5. DenseNet121 mimarisi	35
Şekil 4.6. Xception mimarisi	37
Şekil 4.7. InceptionResNetV2 mimarisi	38
Şekil 4.8. Kullanılan ESA modellerinin ImageNet Top-1 Accuracy performansları.	39
Şekil 4.9. Kullanılan ESA modellerinin ImageNet Top-5 Accuracy performansları	40
Şekil 4.10. ESA modellerinin ikili ve sınıflandırma blokları	41
Şekil 4.11. ESA modellerine eklenen yeni çıkış katmanları.....	42
Şekil 4.12. Çalışmada izlenen topluluk öğrenmesi yaklaşımı	43
Şekil 4.13. İkili sınıflandırma için önerilen hibrit model mimarisi	43
Şekil 4.14. Çoklu sınıflandırma için önerilen hibrit model mimarisi	44
Şekil 5.1. Hibrit modele ait ESA modellerinin çoklu sınıflandırma performansları	47
Şekil 5.2. Hibrit modele ait ESA modellerinin ikili sınıflandırma performansları.....	48
Şekil 5.3. Alt modellerin çoklu ve ikili sınıflandırma hata matrisleri	49

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

hu

Açıklamalar

Hounsfield units

Kısaltmalar

ADASYN

Uyarlanabilir sentetik öğrenme (Adaptive synthetic sampling approach for imbalanced learning)

AUC

Roc eğrisi altında kalan alan (Area under roc curve)

BiLSTM

Çift yönlü uzun kısa süreli bellek (Bidirectional long short term memory)

BSIF

İkilileştirilmiş istatistiksel görüntü özellikleri (Binarized statistical image features)

BT

Bilgisayarlı tomografi

CNN

Evrişimsel Sinir Ağları (Convolutional neural networks)

CXR

Göğüs X-Ray (Chest X-Ray)

DENSENET

Yoğun bağlantılı sinir ağları (Densely connected neural networks)

DNN

Derin sinir ağları (Deep neural networks)

DPI

Difraktif faz interferometrisi (Diffractive phase interferometry)

ENN

Düzenlenmiş en yakın komşu (Edited nearest neighbours)

EQP

Uzatılmış kunary modelleri (Elongated kunary patterns)

ESA

Evrişimsel sinir ağı

FLOPS

Saniyede kayan nokta işlemleri (Floating point operations per second)

GGO

Buzlu cam opaklığı (Ground glass opacity)

HOG

Histogram temelli gradyan (Histogram-oriented gradient)

Kısaltmalar**Açıklamalar**

KNN	K en yakın komşu (k-nearest neighbors)
LBP	Yerel ikili örüntü (Local binary pattern)
LDN	Yerel yön sayısı (Local directional number)
LETRIST	Yerel olarak kodlanmış dönüştürme özelliği histogramı (Locally Encoded transform feature histogram)
LPQ	Yerel faz niceleme (Local phase quantization)
MADF	Modifiye anizotropik difüzyon filtreleme (Modified anisotropic diffusion filtering)
MERS	Ortadoğu solunum sendromu (Middle east respiratory syndrome)
MLP	Çok katmanlı algılayıcı (Multilayer perceptron)
MRI	Manyetik rezonans görüntüleme (Magnetic resonance imaging)
N-CLAHE	Normalleştirilmiş kontrast sınırlı uyarlanabilir histogram eşitleme (Normalized contrast limited adaptive histogram equalization)
NASNet	Sinir mimarisi arama ağı (Neural architecture search network)
OBIF	Yönlendirilmiş temel görüntü temel görüntü özellikleri (Oriented basic image features)
RENN	Kural gömülü sinir ağları (Rule-embedded neural networks)
RESNET	Artık sinir ağı (Residual neural network)
ROI	Odak alanı (Region of interest)
RT-PCR	Ters transkripsiyon polimeraz zincir reaksiyonu (Reverse transcription polymerase chain reaction)
SARS	Ağır akut solunum sendromu (Severe acute respiratory syndrome)
SGD	Stokastik gradyan inişi (Stochastic gradient descent)
SMOTE	Sentetik azınlık aşırı örnekleme tekniği (Synthetic minority over-sampling technique)
SVM	Destek vektör makineleri (Support vector machine)

Kısaltmalar**Açıklamalar****TL**

Tomel linkleri (Tomel links)

VGG

Görsel geometri grubu (Visual geometry group)

WHO

Dünya Sağlık Örgütü (World Health Organization)

YOLO

Sadece bir kez bak (You only live once)


YSA

Yapay Sinir Ağları



1. GİRİŞ

2009 yılı sonunda Çinli yetkililer tarafından Dünya Sağlık Örgütü'ne pnömoni semptomları gösteren ve kökeni belli olmayan yeni bir olası virüs varlığı bildirilmiştir. İlk vakalar Çin'in Wuhan kentinin Hubei bölgesinde görülmüştür [1, 2]. Dünya sağlık örgütü tarafından bu yeni virüs SARS-CoV-2 olarak adlandırılmıştır. SARS (Severe Acute Respiratory Syndrome) koronavirüsü 2003 yılında Çin'in Guangdong bölgesinde, MERS (Middle East Respiratory Syndrome) 2012 yılında orta doğuda, COVID-19 ise 2019 yılında Wuhan'da görüldüğü bildirilmiştir. Bu üç koronavirüsü bulaşıcı ve virüs kaynaklıdır [2-5].



Şekil 1.1.Ağustos 2021 dünya koronavirüs istatistiği

COVID-19 insanlar arasında öksürük ve hapşıрма sonucunda çıkan su damlacıkları vasıtasıyla ya da fiziksel temas ile bulaşmaktadır [3]. Tam olarak sürelerin bilinmemesine karşın son yapılan araştırmalarda; virüs havada 3 saat, bakır materyallerde 4 saat, plastik ve çelikte ise 72 saate kadar canlı olarak kalmaktadır [4]. Hastalığın ilk aşamalarında bazıları belirti göstermezken 5-6 gün sonra ortaya çıkan semptomlar; ateş, öksürük, boğaz kuruluğu, halsizlik, kas ağrısı, koku-tat kaybı ve solunum zorluğu şeklinde belirtilmiştir [5, 6]. Hiç kimse hastalığa doğuştan bir bağışlık gösterememiştir. Salgının ilk etaplarında belirtiler, pozitif testler ve durumu hızla kötüleşen hastalar arasındaki ilgileşim ayakta tedavi ve acil servis ortamlarında iyi anlaşılammıştır [7].

Koronavirüs salgınına dünya hazırlıksız yakalanmış, virüsü kısmen ya da tamamen etkisiz hale getirebilecek bir ilaç ilk aşamada bulunamamıştır. Hastalığın yayılmasını azaltmak için

lkeler maske kullanımını zorunlu kılmış, bulaş riski olan sosyal aktiviteleri yasaklamış ve birçok sanayi kuruluşu retime ara vermek zorunda kalmıştır. Vaka sayılarının bu tarz nlemlere rağmen artması zerine lkeler kısmen ya da tamamen sokağa çıkma yasağı ilan etmiştir. Tm bu tedbirlere karřın çoęu lke ikinci ve nc dalga vakaları yařamıştır. Ayrıca virsn mutasyon geirerek farklı varyantlarının çıkması, daha hızlı bulařma zellięini kazanması salgın ile mcadelede elde edilen kazanımları byk lde geri almıştır. Dnya Saęlık rgt verilerine gre řu ana kadar 200 milyon insan hastalanmış ve 4,24 milyon insan hayatını kaybetmiştir [8].

Vaka sayılarında meydana gelen byk artıřlar mevcut saęlık alıřan sayısının yetersiz kalmasına ve lkelerin saęlık alt yapılarının sıkıntı yařamasına yol amıştır. Koronavirs teřhisinin konmasında RT-PCR testi, DPI testi, salya testi, antikor testi, akcięer doku biyopsisi, akcięer rntgeni ve bilgisayarlı tomografi yntemleri kullanılmaktadır [9]. Sonu verme sresinin uzun olması ve yksek yanlış sonu retme yatkınlıęına rağmen altın standart olarak kabul edilen ters transkripsiyon polimeraz zincir reaksiyonu (RT-PCR) yaygın olarak kullanılmaktadır [10]. RT-PCR testleri olduka spesifik, zaman gereksinimi olan, zahmetli ve kısa sre iinde karmařık manuel iřlem gerektiren bir yntemdir [11]. Sonuların çıkıř sresi bir saatten birkaç gne kadar deęiřkenlik gstermektedir [9]. RT-PCR testleri %60-%70 hassaslıęa sahip olup koronavirs belirtileri gsteren vakalarda dahi negatif sonu verebilmektedir [12]. Sonular zellikle test kitindeki antijen konsantrasyonuna baęlıdır [3].

RT-PCR testlerinden sonra en yaygın yntem olarak radyoloji grntleme yntemlerinden gęs rntgeni (Chest X-Ray) ve bilgisayarlı tomografi (BT) kullanılmaktadır. Ekim 2020’de Dnya Saęlık rgt tarafından aıklanan tavsiye kararlarına gre gęs grntleme yntemleri virsten etkilenmiş ve iyileřmiş kiřilerin klinik semptomlarının tespiti iin etkili bir yntem olarak kabul edilmektedir [4].

Radyoloji uzmanları tarafından grntler zerinde yapılan analizlerde SARS-CoV-2 virsne zg eřitli bulgular elde edilmiştir [1, 2, 11]. COVID-19’a ait ayırt edici zellikler dzensiz glgelerin iki taraflı daęılımı ve buzlu cam opaklıęı řeklinde ifade edilmektedir [13]. Yapılan alıřmalarda RT-PCR testi negatif ıkan hastaların %9’unun gęs X-Ray grntlerinde bu bulgulara rastlanmıştır [14].

Bilgisayarlı Tomografi yöntemi salgının ilk dönemlerinde RT-PCR test sayısının kısıtlı olduğu ülkelerde COVID-19 tanısı konmasında yaygın olarak kullanılmıştır [12]. BT görüntüleme yüksek maliyetli bir yöntem olup hastaların yüksek dozda radyasyona maruz kalması, hamileler ve çocuklar için uygulanabilir olmaması ve hastaların BT odalarına naklinin gerektirmesi gibi dezavantajlara sahiptir [15]. BT cihazlarının görüntüleme süreleri uzun olup çoğu gelişmemiş ülkelerde bu cihazlardan bulunmamaktadır [4]. Hastalığın yayılma hızının kontrolden çıkması nedeniyle bu yöntem kısıtlı imkân ve personeli olan radyoloji bölümlerine büyük bir yük getirmiş ve bilgisayarlı tomografi ortamının hastalık bulaş riskini artırması gibi etkileri ortaya çıkmıştır. BT görüntüleme yöntemi teşhis aşamasından ziyade COVID-19 hastalarının durumunun takip edilmesinde faydalı bulunmaktadır [16]. Bu nedenle göğüs X-Ray görüntüleme yöntemlerinin kullanımı artmaktadır [14].

Akciğer X-Ray görüntüleme cerrahi müdahale gerektirmeyen, düşük doz radyasyon ile hasta muayene imkânı sunan ve zaman-maliyet verimi açısından oldukça etkili bir yöntem olarak kabul edilmektedir [15]. Göğüs X-Ray görüntüleri yaklaşık 15-20 dakika arasında çıkmaktadır [3]. COVID-19 hastalarının X-Ray görüntülerinde gözlemlenen ortak özellikler; diğer pnömoni özelliklerine benzer itratlar veya opasitelerdeki düzensizliktir [16]. Günümüzde çoğu hastane ve klinik, hastaların göğüs X-Ray görüntülerini 2 Boyutta sunan röntgen cihazlarına sahiptir [20]. X-Ray görüntüleri hastalığın ilk aşamalarında herhangi bir anomali göstermezken zamanla akciğerlerin orta, alt ve üst bölgelerinde konsolidasyon kanıtı ile nüfuz alanlarını göstermektedir [16]. Salgın sürecinde COVID-19 tanısı koymada X-Ray yaklaşımının tercih edilmesinin başlıca nedenleri: hızlı triyaj, modülerlik, kullanılabilirlik ve erişilebilirliktir [11].

- Hızlı triyaj: negatif testlerin ikinci kontrolü, testlerin yetersiz kalması ya da salgından en çok etkilenen bölgelerin (İtalya, İspanya, New York) sağlık alt yapısının çökmesi durumunda öncelikli tedavi edilmesi gereken hasta tespiti için yapılmasıdır [17].
- Kullanılabilirlik ve Erişilebilirlik: X-Ray röntgen cihazları hastane ve kliniklerde standart ekipman olarak kabul edilmekte olup günümüzde çoğu tıp merkezinde bulunmaktadır [11].
- Modülerlik: X-Ray cihazlarının modüler yapıda olması röntgen çekiminin izolasyon odalarında yapılmasına imkân sağlamaktadır. Sabit bilgisayarlı tomografi sistemlerine göre bulaş riskini de önemli ölçüde azaltmaktadır [1-2, 17].

Yukarıdaki nedenlerden dolayı X-Ray görüntüleme, erken COVID-19 tanısı koyma sürecinde tercih edilmektedir. Ancak COVID-19'un radyolojik özelliklerinin diğer pnömonilerle ortaklık göstermesi radyoloji uzmanları tarafından algılanmasını zorlaştırmaktadır [2-3, 15]. Akciğer X-Ray görüntüleme yöntemi pandemi süresince modülerliği ve erişilebilirliği nedeniyle tanı koyma işlemlerinde diğer metotlara göre tercih edilmesine rağmen sağlıklı ve hasta arasındaki fark ancak uzman radyologlar tarafından anlaşılabilir. İyi eğitilmiş tecrübeli bir radyoloğun X-Ray görüntüsünü analiz etmesi ortalama 5-6 dakika sürmektedir. X-Ray verisinin okunması ve değerlendirilmesi işlemi sistematik bir süreç olduğu için bu sürenin kısaltılması mümkün gözükmemektedir [3-4, 18].

Akciğer grafisinde pnömoniyi düşündüren en yaygın bulgu hava boşluğu opasiteleridir [3]. COVID-19' a ait akciğer x-ray bulguları şunlardır; pnömoni yani iki taraflı periferik ve/veya subplevral buzlu cam opasitesi (GGO-Ground Glass Opacity) ve/veya konsolidasyon, tek taraflı segmental olmayan lobar buzlu cam veya konsolidatif opasiteler veya multifokal buzlu cam/konsolidatif opasiteler olmadan birçok özel dağılım şeklinde sıralanmaktadır [9].

Vaka sayılarının kontrolden çıkmasına karşın tıp altyapısı ve sağlık personeli sayısının sınırlı olması birçok trajik ve travmatik olayın yaşanmasına neden olmuştur. Koronavirüs ile mücadelede en ön safta mücadele eden sağlık personelleri ise en ağır bedeli ödemekte ve hayatlarını kaybetmektedir. Salgın ile mücadele kapsamında eczacılar, tıp öğrencileri ve diğer branş hekimleri salgın hastanelerinde vazife almaya başlamıştır. Sağlık personeli üzerindeki bu yükün hafifletilmesi için derin öğrenme ve yapay zekâ tabanlı sistemler geliştirilmeye başlanmıştır. Özellikle ileri vakalarda doktorlar tarafından hastanede müşahade, yoğun bakım ve mekanik ventilasyon desteği kararı verilmektedir. Bu da mevcut kaynaklara yüksek bir talep getirmekte olup eldeki verilerden gelecekte oluşabilecek yoğunluğa karşı planlama ihtiyacı doğurmaktadır. Makine öğrenmesi destekli sistemler, uzmanlara yoğun bakım kararı ve kaynak planlaması gibi konularda yardımcı olabilmektedir [5-7, 19].

Tıbbi vakalarda makine öğrenmesi destekli yaklaşımların medikal verilere uygulanmasıyla otomatik tanı koyma oldukça yaygınlaşmıştır. Derin öğrenme yöntemleri ile oluşturulan uçtan uca modeller herhangi bir manuel işlem yapmaksızın veriler üzerinden tanıya dair başarılı özellik çıkarımı yapabilmektedir. Derin öğrenmenin başarılı bir şekilde kullanıldığı alanlar; kalp ritmindeki bozulmaların tespiti, deri kanseri sınıflandırması, göğüs kanseri

tespiti, beyin hastalıklarının sınıflandırılması, X-Ray görüntülerinden pnömoni tespiti, görüntü bölütleme olarak sıralanabilir [1-3, 12].

Akciğer X-Ray görüntülerinin COVID-19 tanısı koymada geçerli bir yöntem olarak kabul edilmesine rağmen verilerin yorumlanmasının uzmanlık gerektirmesi, yavaş tanı konması ve diğer pnömonilerle benzerlik göstermesi gibi sorunlar mevcuttur ve söz konusu bu sorunlar makine öğrenmesi yöntemleri ile aşılabilmektedir. Modellerin yüksek başarılı sınıflandırma yapabilmesi için büyük veri setlerine ihtiyaç duyulmasına rağmen açık kaynaklarda COVID-19 akciğer görüntü sayısı sınırlı ve azdır. Limitli sayıda veriye sahip durumlarda başarılı ve etkili sınıflandırma ön eğitilmiş evrimsel sinir ağları ile mümkündür [2-3, 21].

Akciğer X-Ray görüntülerinden koronavirüs tespitinde an başarılı sonuçlar evrimsel sinir ağlarında elde edilmiş olup yapay sinir ağları, destek vektör makineleri ve KNN algoritmalarına göre daha yüksek doğrulukta sınıflandırma yapmıştır [5]. Mevcut çalışma kapsamında literatürde yer alan ve en çok kullanılan evrimsel sinir ağlarından MobileNetV2, DenseNet121, Xception, InceptionResNetV2 akciğer X-Ray görüntülerine uygulanmıştır. Transfer öğrenimi yaklaşımı ile çalışmaya sıfırdan başlamak yerine başlangıç ağırlıkları ImageNet veri setinden bu modellere aktarılmıştır. Yukarıda bahsedilen dört ağın avantajları topluluk öğrenmesi yaklaşımı ile bir araya getirilerek ikili ve çoklu sınıflandırma yapabilen hibrit bir çözüm öne sürülmüştür.



2. LİTERATÜR TARAMASI

Dünya sağlık örgütü tarafından salgın olarak deklare edilen ve kontrolden çıkarak tüm dünyaya yayılan COVID-19 virüsü insanlık için vahim sonuçlar doğurmuştur. Salgının kontrol altına alınabilmesinde izlenmesi gereken ilk yöntem hızlı ve doğru tanı koyarak hastaların karantina altına alınmasıdır. Diğer pnömonilerle ortak belirtiler gösteren koronavirüsü; X-Ray, bilgisayarlı tomografi, MRI gibi medikal görüntüleme yöntemleri ile tespit edilebilmektedir.

Açık kaynaklarda COVID-19 ile ilgili verinin artması ile yapay zekâ araştırmacıları klasik makine öğrenmesi algoritmaları, yeni mimariler ve hibrit çözümlerle COVID-19 ile mücadelede tıp camiasına destek olmaya başlamışlardır. Bu çalışmalarda sayısallaştırılmış COVID-19 görüntüleri üzerinde oldukça efektif sonuçlar veren evrimsel sinir ağları kullanılarak sonuca ulaşmaya çalışılmıştır [18]. Tıbbi görüntülere uygulanan evrimsel sinir ağları ile hızlı ve yüksek doğrulukta tanı koyma başarı ile yapılabilmektedir [22].

Karthik ve arkadaşları [3], COVID-19 sınıflandırması yapan ve nüfuz eden bölgeleri tespit eden iki evrimsel sinir ağının hibrit şekilde birleştirilmesi ile meydana gelen bir model önermişlerdir. Literatürde evrim katmanında derin öğrenme kullanan filtre uygulaması yapan ilk çalışma olduğu vurgulanmıştır. Önerilen mimari kanal karışık çift dallı ESA modeli ve bu modele filtre öğrenimi gerçekleştiren katmanın bir araya getirilmesinden oluşturulmuştur. Hibrit modelde; bloklar arasında ikili artık bağlantılar, bağlı ağ yolları, kanal karıştırma ve korelasyon gibi adımlar mevcuttur. Akıllı filtrenin arkasındaki fikir, filtrenin hedef pnömoni sınıfına tepkisinin ölçülmesi ve bu faktörün optimizasyon algoritmasına aktarılmasıdır. 5’li çapraz doğrulama performans ölçme yöntemi ile önerilen model %93,42 doğruluk oranında sınıflandırma yaptığı belirlenmiştir.

X-ray görüntülerinden koronavirüs tanısı için gereken özellik çıkarımı problemine yoğunlaşan Alam ve arkadaşları [4], histogram temelli nitelik (HOG) çıkarımı ve evrimsel sinir ağ temelli nitelik çıkarımı üzerine çalışmışlardır. Bu iki yolla elde edilen nitelikler birleştirilerek VGGNet modeli ile sınıflandırma çalışmalarında kullanılmıştır. Görüntülerdeki gürültüyü azaltmak için değiştirilmiş anizotropik difüzyon filtreleme (MADF) yöntemi uygulanmıştır. Önerilen mimari gerçek durumlara benzerlik göstermesi adına farklı boyutlarda görüntüleri işleyecek şekilde tasarlanmıştır. Görüntüler ilk etapta gri tonlara

çevrilmektedir. Dönüştürme işlemi sonrası ilgi bölgeleri(ROI) belirlenip görüntünün kalan kısımları kaldırılmaktadır. Hazırlanan görüntülere ilk histogram temelli özellik çıkarımı akabinde evrimsel sinir ağları uygulanarak modelin ihtiyaç duyduğu özellikler çıkarılmaktadır. Bu adımdan sonra bu bilgiler füzyon edilerek modele verilmekte ve sınıflandırma işlemi gerçekleştirilmektedir. Sınıflandırma sonucu pozitif çıkan görüntüler üzerinde segmentasyon işlemleri uygulanarak virüs nüfuz etmiş bölgeler daire içine alınarak süreç sonlandırılmaktadır. Çalışmada kullanılan veri seti 1,979 COVID-19 pozitif ve 3,111 negatif görüntüden oluşmaktadır. Performans değerlendirme yöntemi olarak 5'li çapraz doğrulama tercih edilmiş olup %98,36 doğruluk oranında sınıflandırma gerçekleştirilmiştir.

Evrimsel sinir ağlarının performansını artırmak için veri artırımı ve hiper parametrelere odaklanan Monshi ve arkadaşları [5], EfficientNet-B0 mimarisi temelli CovidXrayNet adını verdikleri çözümü öne sürmüşlerdir. Çalışmada iki farklı veri seti kullanılmış olup ilk veri seti 960 ikinci veri seti ise 15,496 X-Ray görüntüsünden oluşmaktadır. Sınıflandırma normal, COVID-19 ve diğer pnömoni etiketlerine göre yapılmıştır. Veri artırım yöntemi olarak görüntü üzerinde yeniden boyutlandırma, döndürme, yakınlaştırma, çevirme, aydınlatma, yeniden şekillendirme ve normalleştirme işlemleri uygulanmıştır. Hiper parametre olarak adam optimizasyon algoritması, döngü sayısı 10'dan 100'e kadar olan bir skala ve verinin modele gönderilmesinde 8, 32, 64 ve 128'lik paketler denenmiştir. Yapılan denemeler sonucunda en iyi veri artırım boru hattı; 480x480 piksel boyutlandırma, 20 derece döndürme, 1,2 oranında yakınlaştırma, 0,2 oranında yeniden şekillendirme, 0,3 oranında aydınlatma ve normalleştirme şeklinde belirlenmiştir. En iyi hiper parametre değerleri ise çapraz entropi kayıp fonksiyonu, 32'lik veri paketi ve 30 döngü olarak tayin edilmiştir. Veri artırım boru hattı ve hiper parametreler ile VGG-19 ağının doğruluk oranında %11,93, ResNet50 ağında ise %4,97 iyileştirme sağlanmıştır. EfficientNet-50 temelli CovidXrayNet ağı yapılan değerlendirmeler sonucunda %95,82 doğruluk oranında üçlü sınıflandırma gerçekleştirmiştir.

Lin ve arkadaşları çalışmalarında [11], açık kaynaklardan elde ettikleri akciğer X-Ray görüntülerini kullanarak evrimsel sinir ağ tabanlı yeni bir yaklaşım ortaya koymuşlardır. COVID-Net adı verilen yöntem ile çeşitli yaş gruplarına ait 13,800 akciğer görüntüsü üzerine çalışılmıştır. Veri setinin dağılımı 8,066 sağlıklı, 5,538 bakteriyel ya da viral pnömoni ve 183 COVID-19 pozitif şeklindedir. COVID-Net ağında kolay eğitilebilir olması ve yüksek performans göstermesi nedeniyle kalıntı ağ (Residual Network) yapısı

kullanılarak sağlıklı, COVID-19 olmayan ama viral ya da bakteriyel kaynaklı hasta ve COVID-19 pozitif hasta sınıflandırması yapılmıştır. Önerilen COVID-NET ağı imageNet veri seti kullanılarak ön eğitilmiş hale getirildikten sonra çalışmada kullanılan veri seti üzerinde eğitilmiştir. Sonuçlar çalışmanın %96,4 doğru pozitif yani çok düşük yanlış pozitif sınıflandırma yaptığını ortaya koymuştur. Önerilen çözüm %92,6 doğruluk oranı ile çalışmaktadır. COVID-Net algoritması enfeksiyon türüne göre hassaslık oranı; Normal: %97,0, Bakteriyel ya da viral pnömoni: %90,0 ve COVID-19 pozitif %87,1 olarak elde edilmiştir.

X-Ray görüntülerini kullanarak otomatik COVID-19 tanı koyma işlemi için Ozturk ve arkadaşları [12], DarkCovidNet isimli çalışmayı yapmışlardır. Önerilen metotta ikili ve çoklu sınıflandırma olmak üzere iki farklı yol izlenmiştir. İkili sınıflandırmada COVID-19 ve normal, çoklu sınıflandırmada ise COVID-19, normal ve pnömoni şeklide yapılmıştır. Uçtan uca mimari şeklinde geliştirilen yöntemde herhangi bir nitelik çıkarımı yapılmamış olup ham X-Ray görüntüsü ile çalışılmıştır. DarkCovidNet ağının temelinde DarkNet-19 kullanılmıştır. Bu ağ ise gerçek zamanlı nesne tanımlama mimarisi YOLO temellidir. Önerilen sistem mimarisi evrişim, toplu normalleştirme ve aktivasyon fonksiyonu içeren 4 adet DarkNet katmanı, 5 adet ortaklama katmanı ve toplam 17 evrişim katmanından oluşmaktadır. Tüm ortaklama işlemleri maksimum değere göre yapılmıştır. Model oluşturulduktan sonra ikili ve çoklu sınıflandırma işlemlerini gerçekleştirmiştir. Performans değerlendirmesinden 5'li çapraz geçerlilik yaklaşımı uygulanmış olup bu geçerlemelerin ortalaması alınarak model performansı çıkarılmıştır. Model ikili sınıflandırmada %98,08, çoklu sınıflandırmada ise %87,02 doğruluk oranıyla sınıflandırma yapmıştır.

Oh ve arkadaşları [14], yaptıkları çalışma ile sınırlı sayıda veri üzerine derin öğrenme yöntemlerinin nasıl daha etkili uygulanabileceğini araştırmışlardır. Bütün akciğer görüntülerinden küçük bölütler oluşturulup bu alt kümlere evrişimsel sinir ağ yaklaşımları uygulanmıştır. Bölütlerin sınıflandırma sonuçları çoğunluk oylaması metodu ile birleştirildikten sonra X-Ray görüntüsü üzerinden hastaya tanı koyulmaktadır. Veri seti 502 akciğer X-Ray örüntüsünden oluşmakta olup 191 adet normal, 57 adet tüberküloz, 54 adet bakteriyel pnömoni, 20 adet viral pnömoni ve 180 adet COVID-19 pnömonisi olmak üzere 5 sınıftan oluşmaktadır. Önerilen çalışmada küçük veri setinde kompleks model uygulanması nedeniyle oluşabilecek ezberlemenin önüne geçilmesi ve ImageNet veri setinden ön eğitim ile elde edilmiş ağırlıkları kullanabilmek için ResNet-18 algoritması

tercih edilmiştir. Çalışmada performans karşılaştırılması yapabilmek için önerilen ağa görüntünün 224x224 boyutlarına indirgenmiş hali ve orijinal verinin 224x224 bölütlenmiş formu sokulmuştur. Elde edilen sonuçlar bütün veri için %70,7, bölütler üzerinden gidilen sınıflandırma da ise %88,9 doğruluk göstermiştir. Mevcut çalışma aynı zamanda COVID-Net [11] ile karşılaştırılmıştır. COVID-Net 116,6M parametre ile %92,4 doğruluk oranında sınıflandırırken ilgili çalışma ise 11,6M parametre ile %91,9 doğruluk oranı ile çalışmaktadır.

Wang ve arkadaşları [15], derin öğrenme tabanlı otomatik COVID-19 tespiti ve doku üzerinde enfeksiyon lokalizasyonu yapan bilgisayar destekli bir sistem ortaya koymuşlardır. Çalışmada 3,583 akciğer X-Ray görüntüsü kullanılarak pnömoni tespiti yapılmıştır. Önerilen bilgisayar destekli sistem ilk adımda sağlıklı ve hasta ayrımı, ikinci adımda ise hasta olarak sınıflandırılan görüntüler üzerinde bulaş olmuş bölgenin tespitini gerçekleştirmektedir. Discrimination-DL adımı ResNet mimari kullanarak bir özellik piramidi çıkarıp kategoriler arasında farklılaştırılmış bir olasılık tablosu oluşturmaktadır. Sınıflandırma işleminden sonra veriye Localization-DL adımı uygulanarak enfeksiyonun akciğerin sağında, solunda yani hangi bölgede olduğunu tespit edilmektedir. Sonuçların değerlendirilmesinde önerilen yöntemin sınıflandırma ve lokalizasyon çıktıları ile radyologlar tarafından yapılan sınıflandırma ve lokalizasyon çıktılarının karşılaştırılması yöntemi izlenmiştir. Sınıflandırma adımı doğrulama veri setinde %98,71 doğrulukta çalışmış olup lokalizasyon adımı ise %94,62 doğruluk oranına sahiptir.

X-ray, ultrason ve BT görüntüleri üzerinde evrimsel sinir ağlarıyla koronavirüs teşhisi üzerine çalışan Horry ve arkadaşları [16], transfer öğrenimi temelli VGG16/VGG19, ResNet50, InceptionV3, Xception, InceptionResNet, DenseNet ve NASNetLarge ağlarını kullanmışlardır. Sınıflandırmanın ilk basamağında sağlıklı ve pnömoni ayrımı yapılırken ikinci adımda ise COVID-19 ve diğer pnömoni veri tasniflemesi yapılmaktadır. Performansı artırmak için veri ön işleme aşamasında akciğer görüntüsü dışındaki alanların kaldırılması gibi gürültü azaltma işlemleri uygulanmaktadır. Veri sınıflandırma boru hattı; renkli görüntünün gri tonlamaya çevrilmesi ile başlar, görüntüden daha iyi özellik çıkarımı için histogram temelli N-CLAHE algoritması uygulama, görüntü tekrardan renkli formata çevirme, yeniden boyutlandırılan görüntü üzerine veri artırım yöntemleri uygulama ve son adımda sınıflandırma işlemi gerçekleştirilerek tamamlanmaktadır. En iyi sonuç VGG-19

modelinde yakalanmış olup X-ray için %86, ultrasonda %100 ve BT görüntülerinde %84 doğruluk oranında sınıflandırma başarısı elde edilmiştir.

X-Ray görüntüleri üzerinde evrimsel sinir ağı kullanarak COVID-19 tanısı koymayı amaçlayan Hemdan ve arkadaşları [17], çalışmalarına COVIDX-Net adını vermiştir. Toplam veri seti büyüklüğü 50 X-Ray görüntüsü olan bu çalışmada yeterince büyük olmayan veri setlerinde daha iyi sonuç veren ön eğitilmiş yedi farklı CNN algoritması en uygun çözüm için denenmiştir. COVIDX-Net önermesinde kullanılan algoritmalar VGG19, DenseNet201, InceptionV3, ResNetV2, InceptionResNetV2, Xception ve MobileNetV2 şeklindedir. Çalışma sonunda en başarılı sonuçlar VGG19 ve DenseNet201 ağlarında elde edilmiştir. MobileNetV2 ağının da sonucunun yüksek olması mobil cihazlar için bu tarz bir uygulama geliştirilmesinin mümkün olduğunu göstermektedir.

Arru ve arkadaşları [19], SARS-CoV-2 pnömonisinde göğüs BT bulgularının derin öğrenme, radyomik ve sübjektif değerlendirmesinin karşılaştırılması üzerine çalışmışlardır. Çalışmanın temel amacı ise hasta için yoğun bakım kararının en iyi hangi yolla alınabileceğini tespit etmektir. Sübjektif değerlendirme 14 yıl tecrübeli göğüs radyoloğu tarafından yapılmıştır. Derin öğrenme tarafından yapılan değerlendirme ise Siemens Healthineers cihazı tarafından 1,000 BT görüntüsü üzerinden gerçekleştirilmiştir. Teşhis için akciğer opasite değeri -200 Hu'ya eşit ve büyük olan bölgeler aranmıştır. Radyomik değerlendirmesinde yine Siemens cihazı kullanılmış olup 221 BT görüntüsü üzerine çalışılmıştır. Değerlendirme parametreleri olarak gri seviye uzunluk matrisi, gri seviye büyüklük matrisi, gri ton komşuluk matrisi ve gri seviye bağımlılık matrisi seçilmiştir. Çalışma sonucunda sübjektif analiz, derin öğrenme ve radyomik yöntemlerinin sınıflandırma için AUC değerleri sırası ile; 0,76, 0,88 ve 0,83 olarak elde edilmiştir. Yoğun bakım kararı için bu değerler; 0,77, 0,80 ve 0,82 şeklinde sonuçlanmıştır.

Bir başka çalışmada Narin ve arkadaşları [20], 7,406 X-Ray görüntüsü üzerinde en sık kullanılan evrimsel sinir ağlarından ResNet50, ResNet101, ResNet152, InceptionV3 ve Inception-ResNetV2 algoritmalarını koşmuşlardır. Çalışmada üç farklı veri seti kullanılmış olup veri seti-1 341 COVID-19 ve 2,800 normal, veri seti-2 341 COVID-19 ve 1,493 viral pnömoni, veri seti-3 ise 2,772 bakteriyel pnömoni ve 341 COVID-19 X-ray görüntüsünden oluşmaktadır. Veri seti normal(sağlıklı), COVID-19 ve bakteriyel-viral pnömoni olmak üzere toplam 3 sınıftan oluşmaktadır. Sonuçların değerlendirilmesinde 5'li çapraz geçişleme

yöntemi tercih edilmiştir. Ön eğitilmiş CNN ağlarının değerlendirme sonuçlarına göre en başarılı ResNet50 algoritması olup veri setleri için sırasıyla %96,1, %99,5 ve %99,7 doğruluk oranları elde edilmiştir.

Abbas ve arkadaşları [21] ise evrimsel sinir ağ tabanlı yeni bir yaklaşım öne sürmüşlerdir. DeTraC isimli algoritma; ayrıştırma(Decompose), transfer ve birleştirme(Compose) olmak üzere üç adımdan oluşmaktadır. DeTraC, büyük veri setine ihtiyaç duymadan kolay ve hızlı bir şekilde eğitildiği için çoğu tıbbi görüntü işleme çalışmalarında tercih edilmeye yatkındır. Ayrıştırma adımı esnek ve düşük varyanslı sınıflandırma için uygulanmakta olup veri setinin yapısının basitleştirilmesinde ve veri yapısı üzerindeki düzensizliklerin üstesinden gelme amacı taşımaktadır. DeTaC mimarisinde ilk fazda ön eğitilmiş CNN ağları uygulanarak derin lokal özellik çıkarımı yapılmaktadır. İkinci fazda ise ayrıştırma uygulanarak veri dağılımının yapısı daha basit hale indirgenmektedir. Bu adımdan sonra gradyan iniş optimizasyon yöntemi kullanılarak ağın eğitimi tamamlanmaktadır. Üçüncü fazda ise X-Ray görüntüleri üzerinde nihai sınıflandırma işlemi yapılarak model tamamlanmaktadır. Özellik çıkarım aşamasından sonra ortaya çıkan yüksek boyutluluk sorunu PCA yöntemi ile aşılmıştır. Çalışmada kullanılan veri setinde 80 normal, 105 COVID-19 ve 11 SARS X-Ray görüntüsü bulunmaktadır. Transfer öğrenme adımı üzerinde çalışılan ön eğitilmiş CNN ağlar; AlexNet, VGG19, ResNet, GoogleNet ve SqueezeNet. En yüksek doğruluk oranı %98,23 ile VGG19'da elde edilmiştir. DeTraC uygulanan çalışmaların doğruluk oranları uygulanmayanlara göre tüm algoritmalarda daha yüksek çıkmıştır.

Gao çalışmasında [22], VGG19 evrimsel sinir ağı ile X-Ray görüntüleri üzerinden görüntüyü elimine edip COVID-19 tanısı için faydalı bilgiler çıkarmayı amaçlamıştır. Öğrenme kümesi 400 normal, 400 bakteriyel pnömoni, 400 viral pnömoni ve 200 COVID-19 kaynaklı pnömoni görüntüsünden oluşmaktadır. Test kümesi ise her sınıftan 100 kayıt olacak şekilde ayrılmıştır. Deney sonucunda elde edilen verilere göre algoritma ortalama %95 üstü doğruluk oranı ile sınıflandırma işlemini gerçekleştirmiştir.

X-Ray görüntüleri üzerinde COVID-19 tespiti için Rahimzadeh ve Attar [23], yaptıkları çalışmada az sayıda COVID-19 görüntüsü içeren veri seti üzerine Xception ve ResNet50 evrimsel sinir ağlarını uygulamışlardır. Eğitim seti; 149 COVID-19, 1,634 pnömoni ve 2,000 normal veriden, test kümesi ise 31 COVID-19, 4,420 pnömoni ve 6,851 normal X-Ray görüntüsünden oluşmaktadır. Çalışmada veri setinin dengesiz olmasının genel

sınıflandırma başarı oranının yüksek, COVID-19 doğru tespit edilme oranının ise düşük çıkmasına yol açacağı vurgulanmıştır. Yani COVID-19 tanı konmasında modelin başarısız sonuçlar vereceği öngörülmüştür. Bu problemi aşmak için eğitim fazında modellerin sınıflara ait eşit sayıda veri ile beslenmesi ile çözüm aranmıştır. Modellere eğitim aşamasında 8 ardışık adım uygulanmıştır. Her adımda 250 normal, 234 pnömoni ve 149 COVID-19 görüntüsü ile 633'lük alt set işleme alınmıştır. İlgili yaklaşımın verideki COVID-19 özelliklerinin daha net çıkarabilmesi ve normal, pnömoni ayrımının daha başarılı yapabilmesi olmak üzere iki avantajı bulunmaktadır. İki modelin çıktı katmanlarının birleştirilmesi sonucunda ortalama %99,50 doğruluk ve %80,53 hassaslık oranı ile COVID-19 sınıflandırma başarıları elde edilmiştir. 5 çapraz doğrulama yönetiminde bu sonuç ortalama %91,4 doğruluk oranı olarak çıkmıştır.

Akciğer X-Ray görüntüleri yerine bilgisayarlı tomografi verileri üzerinde çalışan Ardakani ve arkadaşları [24], sık kullanılan 10 evrimsel sinir ağ modelini incelemişlerdir. Veri seti COVID-19 ve diğer pnömoni hastalıkları olmak üzere iki sınıftan oluşmaktadır. Çalışmada 108 COVID-19 hastasında ait 1,020 BT dilimi ile 86 diğer pnömoni hastasının verileri üzerine AlexNet, VGG-16, VGG-19, SqueezeNet, GoogleNet, MobileNet-V2, ResNet18, ResNet50, ResNet101 ve Xception modelleri uygulanmıştır. Model performansının değerlendirilmesinde yaş ve cinsiyet gibi parametreler de kullanılmış olup t-test ve ki-kare test yöntemi tercih edilmiştir. P-değerinin 0,05'den küçük olması istatistiksel olarak kayda değer nitelendirilmiştir. Algoritma sonuçlarına göre cinsiyet parametresinin iki sınıf için ayırt edici bir özellik olmadığı, COVID-19 vakalarında ise yaş ortalamasının düşük çıkmasının önemli bir sonuç olduğu vurgulanmıştır. Model performansları değerlendirildiğine en yüksek doğrulukta sınıflandırma %99,26 ile ResNet101 ve %99,38 ile Xception ağlarında gerçekleşmiştir. Kalan sinir ağı yapısının kolay optimize edilmesi ve derinliğinin artırılması ile model başarısının orantılı olması nedeniyle bu alanda umut vaat ettiği ifade edilmiştir.

Brunese ve arkadaşları [25], çalışmalarında X-Ray görüntülerini kullanarak üç fazdan oluşan derin öğrenme tabanlı COVID-19 tanısı koyan bir çözüm önermişlerdir. İlk adımda verinin sağlıklı ya da pnömoni olup olmadığı kararı verilmektedir. İkinci adımda hasta olarak sınıflandırılan kaydın COVID-19 mu yoksa diğer pnömoni mi tespiti yapılmaktadır. Son adımda ise COVID-19 olduğu karar verilen hastaların akciğer görüntülerinde enfekte olmuş bölgelerin lokalizasyonu yapılmaktadır. Algoritmaların uygulandığı veri seti 250 COVID-

19, 2,753 diğ er pn moni ve 3,520 saėlıklı X-Ray g r nt s nden oluřmaktadır. İlk iki adımda yapılan sınıflandırmada VGG16 derin  ėrenme aėı ve ImageNet veri setinde elde edilen aėırlıklar kullanılmıřtır.  nerilen  alıřmada VGG16 aėının tam baėlantılı katmanı  ıkarılarak yerine ortalama ortaklama, tam baėlantılı katman, seyreltme ve softmax aktivasyon iřlemlerini i eren daha b y k bir katman eklenmiřtir. Son adımda ise gradyan aėırlıkları kullanarak aktivasyon haritası  ıkarılarak enfekte olmuř dokuların lokasyonları tespit edilmiřtir.  alıřma sonucunda yaklařık 2,5 saniye i inde %97 doėruluk oranında COVID-19 tespiti yapan bir aė ortaya  ıkmıřtır.

Hassantabar ve arkadařları [26], yapay sinir aėları ve evriřimsel sinir aėlarını beraber kullanarak akciėer bilgisayarlı tomografi g r nt leri  zerinden COVID-19 tespiti yapmıřlardır.  alıřmanın ilk adımımda fraktal metotlar kullanılarak veri  zerinden  zellik  ıkarımı yapılmıřtır. Fraktal algoritma ve kovaryans analizleri yardımıyla veriden  z deėerler  ıkarılarak boyut azaltılmıřtır. B ylelikle tanı koymak i in gereken ayırt edici ve en iliřkili  zellikler elde edilmiřtir. Bir sonraki adımda DNN mimarisi; 20 ve 10 n rondan oluřan iki gizli katman, 4  zellik kabul eden giriř katmanı ve tek sonu  veren  ıkıř katmanı olarak kurulmuřtur. Bu aė %82,39 doėruluk oranı ile verinin COVID-19 olup olmadıėını tespit etmektedir.  alıřmanın diėer bacasında ise     evriřim aėı olmak  zere toplam 16 katmandan oluřan CNN mimarisi kurulmuřtur. CNN aėının performansı ise %93,20 doėrulukta COVID-19 tanısı koyma olarak belirlenmiřtir.  alıřmanın son bacasında ise bilgisayarlı tomografi g r nt leri kullanılarak evriřimsel aė tabanlı enfeksiyon b lge tespiti yapılmıřtır. Aėın eėitilmesinde enfeksiyonlu b lgesi bilinen 100 g r nt  kullanılmıřtır.

Jain ve arkadařları [27], X-Ray g r nt leri  zerinde en sık kullanılan evriřimsel sinir aėlarından InceptionV3, Xception ve ResNetXt  zerine  alıřmıř olup performanslarını karřılařtırmıřlardır. Veri setinde toplam 6,432 kayıt bulunmaktadır. Aėların  ıkıř katmanına daha iyi sonu  vermesi i in d zleřtirme, gizli katman ve seyreltme gibi optimizasyonlar yapılmıřtır. Elde edilen bulgulara g re en y ksek sonu  Xception aėında elde edilmiřtir.

Diėer bir  alıřmada Aslan ve arkadařları [28], otomatik COVID-19 tespiti i in derin  ėrenme tabanlı iki farklı yaklařım  ne s rm řlerdir. İlk Mimari tamamen AlexNet alt yapısını kullanırken ikinci mimari ise AlexNet ve  ift y nl  uzun kısa s reli bellek (BiLSTM) yapısının hibrit bir hali tercih edilmiřtir. Transfer  ėrenimi ile  n eėitimi aėırlıkların kullanılması, modelin  zellik  ıkarım kabiliyetini g  lendireceėi gibi eėitim

zamanı ve maliyetlerde ciddi iyileştirmeler yapacağı vurgulanmıştır. Modelin sınıflandırma performansını artırmak için ilk adımda görüntüler üzerinde yapay zekâ tabanlı segmentasyon işlemi yapılmıştır. Görüntülerin standart olmaması nedeniyle segmentasyon ağının eğitimi için gereken veri manuel oluşturulmuştur. Alt sol, alt sağ ve üst orta olmak üzere üç nokta seçimi el yordamı ile 50 görüntü için yapılmıştır. Segmentasyon ağı 100 nöronlu gizli katman ve manuel seçilen noktalara ait ikili koordinatları çıkaran 6 nöronlu çıkış katmanından oluşmaktadır. Çalışmadaki ilk ağ olan AlexNet üzerinde bilgisayarlı tomografi verileri için küçük değişiklikler yapılmıştır. İkinci ağda ise AlexNet mimarisine BiLSTM katmanı eklenerek çok daha iyi sonuç elde etmek hedeflenmiştir. Veri setinde 219 COVID-19, 1,345 viral pnömoni, 1,341 normal olmak üzere toplam 2,905 kayıt bulunmaktadır. Çalışma sonucunda AlexNet mimarisi %99,14, hibrit çözüm AlexNet tabanlı BiLSTM ise %99,70 doğruluk oranında sınıflandırma yapmıştır.

Pereira ve arkadaşları [29], COVID-19 teşhisi için çok sınıflı ve hiyerarşik sınıflandırma yapabilen iki farklı yaklaşım üzerine çalışmışlardır. Araştırmada veri setinin dengesiz olması sorunu üzerine özellikle durulmuş olup yeniden örnekleme yöntemleri uygulanarak bu soruna da çözüm aranmıştır. Çalışma özellik çıkarımı, erken füzyon, yeniden örnekleme, yatay ve hiyerarşik sınıflandırma olmak üzere dört faza bölünmüştür. İlk fazla literatürde yer alan el yordamı gerektiren ve gerektirmeyen InceptionV3, LBP, LPQ, LDN, EQP, LETRIST, BSIF, OBIF özellik çıkarım yöntemlerinin hepsi denenmiştir. İkinci fazda ilk fazda uygulanan yöntemlerin çıktıları birleştirilerek diğer faza aktarılmıştır. Füzyon sonucunda özellik çıkarım algoritmalarından LDN, EQP ve OBIF birleşiminin en iyi sonucu vereceği değerlendirilmiştir. Veri artırım yöntemlerinin modellerde aşırı öğrenmeye neden olacağı düşünüldüğü için çalışmada yeniden örnekleme yaklaşımı tercih edilmiştir. İkili yeniden örnekleme algoritmalarından ADASYN, SMOTE, SMOTE-B1, SMOTE-B2, AllKNN, ENN, RENN, Tomek Links (TL), ve SMOTE-TL kullanılmıştır. Özellik çıkarım algoritmalarının değerlendirilmesinde makro F1-Score kullanılmış olup düşük değere sahip olan daha iyi sonuç vermiştir. Bu bağlamda çoklu sınıflandırmada LPQ, hiyerarşik sınıflandırmada ise BSIF özellik çıkarım yöntemi en iyi sonucu vermiştir. Çoklu sınıflandırma mimarisinde KNN, RF, SVM, DT ve MLP algoritmaları seçilmiş olup makro F1-Score metriğine göre en iyi sonuç MLP'den elde edilmiştir. Yeniden örnekleme algoritmalarında ise çoklu sınıflandırmada ENN, hiyerarşik sınıflandırmada ise SMOTE yaklaşımları ile en etkili sonuçlar elde edilmiştir. Çoklu sınıflandırma ve hiyerarşik

sınıflandırma karşılaştırıldığında ise COVID-19 tespitinde hiyerarşik yaklaşımın daha etkili olduğu tespit edilmiştir.

Ammar ve arkadaşları [30], veri gizliliği nedeniyle eldeki verilerini paylaşamayan klinikleri de kapsayacak bir sistem önerisinde bulunmuşlardır. Amerika ve Avrupa’da hastaya ait veriler katı kanunlar ile koruma altına alınmıştır. Bu kanunlar nedeniyle yapay zekâ gibi son teknoloji sistemlerin eğitimi için gereken veri setleri istenen büyüklüğe ulaşamamaktadır. Google tarafından dağıtık makine öğrenmesi geliştirilmiş olup federe mimari yapısı ile istemciler birbirlerinin verisine ulaşmaksızın aynı yapay zekâ ağında çalışabilmektedirler. Federe mimarilerde her istemci kendi lokal verisi üzerinde eğitimini yapmaktadır. Aynı zamanda istemcilerin farklı miktarda veriye sahip olması nedeniyle mimaride dengesiz bir veri dağılımı söz konusudur. COVID-19 tanısı için önerilen federe mimaride eğitim işlemleri istemci tarafında yapılırken çıktıların toplanması ve değerlendirilmesi sunucu tarafında gerçekleşmektedir. Veriden özellik çıkarımı ve sınıflandırılması VGG16 ve ResNet50 CNN ağları kullanılarak yapılmaktadır. Federe mimaride sınıflandırma işlemleri 4 adımda tamamlanmaktadır. İlk adımda merkezi sunucu modelin başlangıç ağırlıklarını belirler ve istemcilere bu parametreleri iletmektedir. İkinci adımda ise istemciler bu parametreleri alıp lokal veri üzerinde eğitim işlemine başlamaktadır. Lokal eğitim işlemi tamamlandıktan sonra her istemciden elde edilen ağırlıklar merkezi sunucuya akmaktadır. Son adımda ise istemcilerden toplanan ağırlık bilgisinin ortalamaları alınarak tekrardan istemcilere bu parametreler iletilmektedir. Bu dört adımın tamamına bir iterasyon denmekte olup federe sistemin olgunlaşması için çok sayıda iterasyon gerekmektedir. İlgili çalışmada odak noktası verinin gizliliğini koruyarak bir yapay zekâ modeli geliştirmek olduğu için tercih edilen CNN ağlarının üzerinde durulmamıştır. Federe mimarinin etkisini ölçmek için merkezi VGG-16 ve ResNet50 ağ mimarileri kullanılarak ayrı bir yapı kurulmuş olup sonuçlar karşılaştırılmıştır. Performans değerlendirmesinde 5’li çapraz geçerleme yapılmıştır. Federe mimaride VGG-16 %93,57, ResNet50 %95,4 doğruluk oranıyla sınıflandırma yapılmıştır. Veri artırım teknikleri ile bu oran biraz daha artmaktadır. Merkezi klasik sınıflandırmada ise VGG-16 %93,75, ResNet50 ise %95,3 doğruluk oranında sonuçlar üretmiştir. Veri gizliliği sorunu göz önüne alındığında merkezi ve federe mimarinin sonuçlarının yüksek çıkması ve birbirine yakın olması federe mimarilerin tüm klinikleri kapsayacak şekilde uygulanabileceğini göstermektedir.

Bilgisayarlı tomografi ve X-Ray görüntülerinin COVID-19 sınıflandırma başarısını karşılaştıran Benmalek ve arkadaşları [31], iki veri türüne de aynı evrişimsel sinir ağlarını uygulamışlardır. Mobil cihazlara uygulanabilirliği dikkate alınarak ResNet18, InceptionV3 ve MobileNetV2 ağları tercih edilmiştir. Veri seti olarak 19,685 BT görüntüsü ve 5,026 X-Ray görüntüsü kullanılmıştır. Performans değerlendirmesi olarak 5'li çapraz geçerleme yöntemi tercih edilmiştir. Hassaslık, duyarlılık, özgüllük ve F1-Skor metrikleri değerlendirme için seçilmiştir. Çalışma sonucunda BT görüntülerine ait metrikler X-Ray görüntülerine göre çok daha yüksek çıkmıştır. BT görüntülerinin daha fazla zıtlık içermesi ve kalitesinin X-Ray görüntülerine göre yüksek olması bu sonuçları doğurmuştur.

Ouchicha ve arkadaşları [32], COVID-19 sınıflandırma problemine çözüm olarak evrişimsel sinir ağ tabanlı CVDNet adını verdikleri yeni bir yaklaşım öne sürmüşlerdir. CVDNet ağı kalan sinir ağ mimarisini temel alarak veriyi normal, COVID-19 ve diğer pnömoni etiketi ile sınıflandırmaktadır. ResNet ağları tıbbi görüntü işlemede başarılı olması ve kaybolan gradyan problemini aşması nedeniyle tercih edilmiştir. Mimari birbirine paralel ve farklı özelliklere sahip katmanlardan oluşmakta olup veriye ait yerel ve genel özelliklerin çıkarılmasına odaklanmıştır. CVDNet mimarisi aynı yapıda birbirine paralel iki kolondan oluşmaktadır. İki yapının farklılaştığı nokta ise veriye uyguladıkları filtre boyutudur. Görüntülerden lokal özellikleri çıkarmak için 5x5 küçük filtre, global özellikleri çıkarmak içinse 13x13 büyük filtre gerekmektedir. İki filtre tarafından elde edilen özellikler kalan ağ bağlantıları yardımıyla birleştirilmektedir. Ağda birbirine paralel 4'er evrişim katmanı bulunmaktadır. Her evrişim katmanı çıkışında paralel kolonlar arasında bu veriler diğer kolondaki evrişim katmanına girdi olarak iletilmektedir. Paralel kolonların çıktıları ayrı bir evrişim katmanı ile birleştirilip sıralı 3 tam bağlantılı katman ile mimari tamamlanmaktadır. Önerilen sistemin performansı 5'li çapraz geçerleme ile yapılmıştır. CVDNet ağı, COVID-19 tespitini ortalama %97,20, üçlü sınıflandırmayı ise %96,69 doğruluk oranıyla gerçekleştirmiştir.

Bhardwaj ve arkadaşları [33], topluluk öğrenmesi yaklaşımları ile InceptionV3, DenseNet121, Xception ve InceptionResNetV2 modellerini birleştirerek ikili ve çoklu sınıflandırma yapmışlardır. Aşırı öğrenmeye karşı veri artırımı uygulanmış ve modeller ön eğitilmiş hale getirilmiştir. Çalışmadaki topluluk öğrenmesinde zor oylama yani çoğunluğun oyu ve olasılıksal ortalama olan kolay oylama yöntemleri seçilmiştir. İkili ve çoklu sınıflandırma için sırası ile %98,33 ve %92,36 doğruluk oranı elde edilmiştir. Topluluk derin

öğrenmesi üzerine başka bir çalışmada Ahmad ve arkadaşları [34], MobileNet, ResNet50 ve InceptionV3 modellerini kullanmışlardır. İlk adımda modellerin bireysel performansları incelenmiş ve birleştirme adımı için MobileNet ve InceptionV3 uygun görülmüştür. Test veri setinde hibrit model %88,64 doğruluk oranında sınıflandırma gerçekleştirmiştir.




3. TEKNİK ARKA PLAN

Bu bölümde tez çalışması kapsamında kullanılan evrişimsel sinir ağları, optimizasyon algoritmaları, transfer öğrenimi ve topluluk derin öğrenmesi hakkında teorik bilgilere yer verilmiştir.


3.1. Evrişimsel Sinir Ağları (Convolutional Neural Networks)

Evrişimsel sinir ağları, derin öğrenme yaklaşımlarının bir varyasyonu olup gözetimli ve gözetimsiz sınıflandırma yapabilen son derece modern bilgisayarla görü ve görüntü işleme çözümüdür [35, 36]. Evrişimsel sinir ağlarında veri en, boy ve kanal parametrelerine sahiptir [36]. Veri analizinde belirlenen dörtgen boyutunda matris filtre kullanılarak çözüm için gereken özellikler çıkarılmaktadır [35]. Bu ağlar yüksek performanslarını ağıdaki gizli katmanların bir önceki katmanlara ile tamamen bağlantılı olmamasına borçludur [36].



Şekil 3.1.Evrişimsel sinir ağ taksonomisi [73]

Evrişimsel sinir ağları ileri beslemeli yapıda olup görüntüye ait topolojik özellikleri çıkararak değişkenler arasında örüntüyü başarıyla tespit edebildiği için çoğu çalışmada tercih edilmektedir [37]. Geleneksel derin sinir ağlarının görüntü işlemede karşılaştığı en büyük sorun ciddi hesaplama karmaşıklığı gerektirmesidir. ESA ise tamamen yönetilebilir bir karmaşıklık çerçevesinde görüntü işlenmektedir [35]. ESA mimarisi, birbirinden farklı görevlere sahip evrişim katmanı, ortaklama katmanı ve tam bağlantı olmak üzere 3 katmandan oluşmaktadır [38].




Şekil 3.2. Geleneksel evrişimsel sinir ağı mimarisi

3.1.1. Evrişim Katmanı (Convolutional Layer)

Evrişim katmanı ESA mimarilerinde görüntünün ilk ele alındığı ve en temel işlemlerin yapıldığı yani veriden bilgi çıkarımının yapıldığı katmandır [32]. Evrişimsel ağların hesaplama yükünün büyük bölümü bu katmanda gerçekleşmektedir. Evrişim katmanında kullanılan parametre filtre ya da çekirdek adı verilen matristir [2-3, 36]. Veriye uygulanan filtreden sonra özellik haritası elde edilmektedir [32]. Bu katmanda özellik haritası üzerinde yapılacak optimizasyonla tüm modelin karmaşıklığı ciddi derecede düşürülebilmektedir. Optimizasyon uygulanabilen hiper parametreler; filtre boyutları, adım aralığı ve sıfır ekleme/doldurmadır [38]. Evrişim katmanının başlıca avantajları; özellik haritalarında yer alan ağırlık paylaşım mekanizmasıyla parametre sayısında ciddi bir azalma sağlaması, yerel bağlantılar ile komşu pikseller arasında bağlantıları öğrenebilmesi ve veride nesnenin yerinin farklı olmasına karşın modelin stabil davranış sergilemesi şeklinde ifade edilebilmektedir [26].


Yapay sinir ağının hesaplama hızında iyileştirme yapabilmek ve giriş fonksiyonlarından arzu edilen çıktıları elde edebilmek için ağın kolay türevlenebilir olması gerekmektedir [26, 39]. ESA mimarisinde evrişim katmanı sonucunda elde edilen çıktılar doğrusal yapıda olup doğrusal olmayan yapıya çevirmek için aktivasyon fonksiyonları uygulanmaktadır [32]. Böylelikle çıktılar türevlenebilir forma dönüştürülmektedir.

- **Sigmoid Aktivasyon Fonksiyonu:** Yapay sinir ağlarında sıklıkla kullanılmakta olup girdiler 0 ve 1 arasındaki çıktıları dönüştürülmektedir [39]. ESA yaklaşımında kaybolan eğim yani türevlenen elemanların sıfıra yakınsaması problemi en büyük dezavantajdır [38].




Şekil 3.3.Sigmoid aktivasyon fonksiyonu [44]

- **Tanjant Aktivasyon Fonksiyonu:** Sigmoid fonksiyonunun büyütülmüş hali şeklinde değerlendirilebilir. Girdiler -1 ve 1 arasındaki çıktıya dönüştürülür. Kaybolan eğim problemi tanjant aktivasyon fonksiyonunda da devam etmektedir [38]. Çıktıların sıfır merkezli olması nedeniyle sigmoid fonksiyonuna göre daha fazla tercih edilmektedir [39].




Şekil 3.4.Tanjant aktivasyon fonksiyonu [39]

- **Doğrultulmuş Doğrusal Birim Aktivasyon Fonksiyonu (Rectified Linear Unit):** Girdiler 0 ve sonsuz arasındaki çıktıya dönüştürülür. Gradyan yakınsamasına karşı direnç göstermesi, az maliyetli olması ve öğrenme fazında çok daha iyi performans sergilemesi nedeniyle yaygın olarak tercih edilmektedir [32]. Evrişim katmanında tüm piksel değerlerine uygulanır ve negatif piksellere sıfır değerini atar [26].



Şekil 3.5.Doğrultulmuş doğrusal birim aktivasyon fonksiyonu [44]

- **Sızdırılmış Doğrultulmuş Doğrusal Birim Aktivasyon Fonksiyonu (Leaky Rectified Linear Unit):** Doğrultulmuş doğrusal birim aktivasyon fonksiyonunun negatif değerlerde davranışını değiştirmek için 0,01 gibi küçük bir sabitin eklenmesi şeklinde güncellenmiş halidir [38, 39].



Şekil 3.6.Sızdırılmış doğrultulmuş doğrusal birim aktivasyon fonksiyon [12]

3.1.2. Ortaklama Katmanı (Pooling Layer)

ESA mimarisinde ortaklama katmanı yardımıyla evrişim katmanı ile elde edilen aktivasyon haritalarında herhangi bir bilgi kaybı olmaksızın uzamsal boyutlar düşürülmektedir. Bu sayede toplam ağıın işlem karmaşıklığı daha da azalmakta ve model aşırı öğrenme yani ezberlemeye karşı direnç kazanmaktadır [1-2, 38]. Başka bir ifadeyle veriye ait ve modelin

ihtiyaç duyduğu en önemli özellikler süzülerek diğer katmana aktarılmaktadır. Başlıca ortaklama yöntemleri; maksimum ortaklama, ortalama ortaklama, stokastik ortaklama, spektreal ortaklama ve boyutsal piramit ortaklama şeklindedir [36].

3.1.3. Tam Bağlantılı Katman (Fully-Connected Layer)

Geleneksel yapay sinir ağları ile aynı yapıda olup bu ağın nöronları ve bir önceki ağın nöronları tamamen birbirlerine bağlıdır [36]. Tam bağlantılı katman, görüntü üzerinden çıkarılan özelliğin konumu ile sınıflandırma etiketi arasındaki bağı tanımlar [32]. Bu katmandan sonra evrişim katmanı uygulanması mümkün değildir [36].

3.2. Optimizasyon Algoritmaları

Günümüzde verinin ve karşılaşılan problemlerin karmaşıklığının ciddi boyutlarda artması problemi makine öğrenmesi mimarilerinin en önemli kısımları olan optimizasyon algoritmaları ile aşılmaktadır. Optimizasyon algoritmaları ağırlıkları en uygun hale getirerek modeli başarılı sınıflandırma yapabileceği forma sokmaktadır. Gradyan bilgisi açısından optimizasyon yöntemleri; birinci dereceden optimizasyon, yüksek dereceli optimizasyon ve sezgisel türevsiz optimizasyon olmak üzere üç gruba ayrılmaktadır. Denetimli öğrenme için optimizasyon fonksiyonlarının amacı, eğitim örneklerinin kayıp fonksiyonunu en aza indirmek için en uygun $f(x)$ eşleşme fonksiyonunu bulmaktır [3-4, 40].

$$f(x) = \min_{\theta} \frac{1}{N} \sum_{i=1}^N L(y^i, f(x^i, \theta)) \quad (3.1)$$

Eş. 3.1’de gösterilen denetimli öğrenme için optimizasyon fonksiyonunda; N, eğitim örneklerinin sayısı, θ , eşleme fonksiyonunun parametresi, x^i , i. örneklerin özellik vektörü, y^i , karşılık gelen etiket ve L ise kayıp fonksiyonudur.

Literatürde; Stokastik Gradyan İniş (SGD), adam, adadelta, RMSProp, adagrad, adamax, nadam gibi çeşitli optimizasyon algoritmaları bulunmasına rağmen bu çalışma kapsamında SGD, RMSProp, adam ve adadelta detaylandırılmıştır.

- **Stokastik Gradyan İniş (SGD)**

SGD yaklaşımında ana fikir, gradyanın değerini doğrudan hesaplamak yerine her iterasyonda bu değer rastgele belirlenmesidir. Gerçek gradyan değerine tahmin edilerek ulaşılmaktadır. Bu yöntemde maliyet, örnek sayısından bağımsız olup büyük veri setlerinde hesaplama süresini önemli oranda hızlandırarak işlem yükünü azaltmaktadır [1-3, 40].

- **RMSPProp**

Gradyanların üssel ortalamasının alınması mantığı ile çalışmaktadır. Bu işlemi yaparken tüm gradyanlar ile çalışmak yerine sabit bir aralıkta kalanlar dikkate alınmaktadır [1, 2, 40]. RMSPProp ile dikey salınım sınırlandırılırken öğrenme oranı yatayda güncellenmektedir [41].

- **Adam**

Adam, kompakt hafıza kullanma kabiliyeti sayesinde etkili sonuçlar vermektedir [41]. Uyarlanabilir bir yöntem olup RMSPProp algoritmasının avantajı olan geçmiş gradyan noktalarının kareleri ortalamasının yanı sıra momentum değerini kullanmaktadır [41, 42].

- **AdaDelta**

Bu optimizasyon yönteminde öğrenme oranı geçmiş oranlar dikkate alınarak monoton olarak azaltılmaktadır [41, 42].

Çizelge 3.1. Optimizasyon algoritmalarının karşılaştırılması [40]

Optimizasyon Yöntemi	Özellik	Avantaj	Dezavantaj
SGD	Rastgele seçilmiş küçük veri paketleri ile güncelleme parametreleri tayin edilir.	Her iterasyonda yapılan güncelleme için gereken hesaplama süresi, toplam eğitim örneği sayısına bağlı değildir ve hesaplama maliyetinden ciddi oranda tasarruf edilir.	Uygun bir öğrenme oranı seçmek zordur. Tüm parametreler için aynı öğrenme oranını kullanmaktadır.
RMSProp / AdaDelta	Gradyan değişimi hareketli üssel ortalama ile yapılmaktadır.	Durağan olmayan problemlerde etkili sonuçlar vermektedir.	Gradyan güncellemesi lokal minimum değerine takılması muhtemeldir.
Adam	Uyarlanabilir yöntemler momentum ile birleştirilmiştir.	Gradyan inişi daha stabil olduğu için büyük ve çok boyutlu veri setleri için uygun bir yöntemdir.	Bazı vakalarda yöntem yakınsamamaktadır.


3.3. Transfer Öğrenimi (Transfer Learning)

Günümüzde makine öğrenmesi ve veri madenciliği yöntemleri sosyal medya, ulaşım, üretim, tarım, doğal dil işleme, savunma sanayi, tıp, robotik gibi birçok alanda karşılaşılan problemlerin çözümü ve verimin artırılması amacıyla kullanılmaktadır. Makine öğrenmesi yaklaşımlarının kurgulanabilmesi ve efektif bir şekilde uygulanabilmesi için büyük miktarda eğitim ve test verisine ihtiyaç duyulmaktadır. Ancak yeterli miktarda verinin toplanması çoğu zaman mümkün değildir.

Tıp veya biyoenformatik gibi makine öğrenmesi uygulama alanlarında yetersiz eğitim verisi problemi kaçınılmazdır. Verinin toplanması karışık ve maliyetli bir süreç olup büyük ölçekli ve yüksek kaliteli bir veri seti oluşturmak oldukça zordur. Bu veriler yüksek bedeller ödenerek elde edilse dahi kolaylıkla güncelliğini yitirebilmektedir [1-3, 43].

Transfer öğrenimi, sağlıklı verilerden oluşan ve dengeli bir veri dağılımı gösteren alanlardan elde edilen bilginin, birbirlerinden farklı fakat ilişkili alanlara ve hedef algoritmalara aktarılarak bu çalışma alanlarındaki uygulamaların performansını artırmaya yönelik işlemlerdir.

Transfer öğrenimi ile hedef çalışma alanının öğrenme performansında artış olmakta ve eğitim için gereken veri gereksiniminde, süresinde önemli ölçüde azalma meydana gelmektedir. Ancak transfer öğrenimi her zaman olumlu sonuçlar getirmemektedir. Eğer kaynak ve hedef çalışma alanları arasında benzerlik, aktarılabilecek bilgi çok az ya da yoksa transfer öğrenimi sınıflandırma performansına zarar vermektedir. Bu zayıf ilişki kaynaklı duruma negatif transfer öğrenimi adı verilmektedir [1-5, 45].



Şekil 3.7. Transfer öğrenimi kategorileri [45]

Transfer öğrenimi problemleri etikete göre transdüktif, endüktif ve gözetimsiz transfer öğrenimi olmak üzere üç gruba ayrılmaktadır. Verinin etiket bilgisinin sadece kaynak çalışma alanında bulunduğu senaryolara transdüktif, hedef çalışma alanında bulunmasına ise endüktif transfer öğrenimi olarak adlandırılmaktadır. Kaynak ve hedef çalışma alanlarının her ikisinde de bu bilgi mevcut değilse bu senaryolarda gözetimsiz transfer öğrenimi kavramı söz konusudur [1-3, 45].

Kaynak ve hedef etki alanı arasındaki özellik farklılıklara göre transfer öğrenimi homojen ve heterojen olmak üzere iki gruba ayrılır [45]. Homojen transfer öğreniminde kaynak ve hedef çalışma alanına ait anlamsal ve boyutsal özellik uzayı benzerlik göstermektedir [46]. Hedef çalışma alanıyla ilgili olan ancak tam olarak eşleşmeyen bir alandan alınan veri seti mevcutsa ve iki çalışma alanının giriş özellik uzayı benzerlik gösteriyorsa homojen transfer öğrenimi bu senaryolarda uygulanabilmektedir [47]. Bunun aksine heterojen transfer öğreniminde anlamsal ve boyutsal özelliklerde benzerliğe rastlanmamaktadır [46].

Heterojen aktarım öğrenimi, özellik alanlarındaki bu farklılıklar arasında köprü kurarak hedef çalışma alanını için gereken tahmin modelini oluşturmak için kullanılmaktadır [47].

Transfer öğrenimi yaklaşımları çözüme göre örnek, özellik, parametre ve ilişki tabanlı olmak üzere dört gruba ayrılmaktadır [45]. Örneğe dayalı transfer öğreniminde spesifik ağırlık aktarımı söz konusu olup kaynak çalışma alanından kısmi örnekler toplanarak hedef çalışma alanının eğitiminde kullanılacak ağırlıklar çıkarılmaktadır. Özellik uzayında meydana gelen eşleşmeye dayalı transfer öğreniminde ise kaynak ve hedef alanlar arasında benzerliğin ve transfer öğrenimi uygulanabilirliğin daha fazla olduğu yeni bir özellik uzayı oluşturulmaktadır. Ağ tabanlı transfer öğreniminde kaynak çalışma alanında önceden eğitilmiş kısmi bir ağı mimarisi, bağlantıları ve ağırlıkları ile hedef çalışma alanında tahminde kullanılacak ağa bütün olarak aktarılması söz konusudur [2-4, 43].

Derin öğrenme yaklaşımlarında transfer öğrenimi aktarılabilecek ağ için sığ, derin ve ince düzenleme olmak üzere üç ana senaryoda uygulanmaktadır. Ağda yapılacak sığ düzenleme ile yeni ağ için sadece son katman üzerinde güncelleme yapılmaktadır. Kalan katmanlardaki parametreler dondurularak öğrenme gerçekleştirilmektedir. Derin düzenlemede ise önceden eğitilmiş ağ uçtan uca yeniden eğitilmektedir. Ağ üzerinde yapılan ince ayarada birden fazla katman yeniden düzenlenmekte olup ve öğrenme parametreleri kayda değer performans artışı elde edilinceye kadar güncellenmektedir [1-5, 18]

3.4. Topluluk Derin Öğrenmesi (Ensemble Deep Learning)

Topluluk derin öğrenmesi, ortak bir problemin çözümü için bir veya birden fazla veri seti kullanılarak eş zamanlı yapay sinir ağlarının eğitilmesi işlemidir [48]. Evrimsel sinir ağlarının birleştirilerek ortaya çıkan entegre ağ; bilgisayarlı görü, konuşma tanıma, doğal dil işleme gibi büyük ölçekli problemlerde tekil modellere göre çok daha yüksek genelleştirme elde etmektedir. Ancak topluluk öğrenmesinin en büyük dezavantajı ESA mimarilerinin karmaşıklığını artırması, hesaplama maliyetlerini yükseltmesi, eğitim ve test fazlarında yüksek boyutluluğa sahip veri üretmesi şeklinde sıralanmaktadır [2-3, 49].

Derin öğrenme modellerinin birbirlerine göre farklı avantajlarının bir araya getirilerek çok daha güçlü bir final model oluşturabilmesi için çok çeşitli yöntemler bulunmaktadır. Bunlar; torbalama(bagging), yükseltme (boosting), istifleme (stacking), negatif korelasyona dayalı

topluluk derin öğrenmesi (negative correlation based deep ensemble models), açık/örtük (explicit/implicit), homojen/heterojen (homogeneous/heterogeneous), karar birleştirme stratejisi (decision fusion strategies), gözetimsiz (unsupervised), yarı gözetimli (semi-supervised), pekiştirmeli (reinforcement), çevrimiçi/artırımlı (online/incremental) ve çoklu etiket tabanlı topluluk öğrenmesi (multi-label based deep ensemble models) [1-2, 50].



4. YÖNTEM VE UYGULAMA

Bu bölümde çalışma kapsamında kullanılan evrişimsel sinir ağları, veri seti, izlenen yöntemler ve uçtan uca oluşturulan sınıflandırma hattı hakkında detaylı bilgilere yer verilmiştir.


4.1. Veri Seti

İlgili çalışma kapsamında kullanılan akciğer X-Ray görüntüleri, COVID-19 Radyoloji veri tabanından elde edilmiştir. İlgili veri seti [24], Katar ve Dakka Üniversitelerinden oluşan araştırma ekibi ve bu ekibi destekleyen Pakistanlı ve Malezyalı tıp doktorları tarafından oluşturulmuştur. Veri seti; BIMCV Tıbbi Görüntü Bankası [51], GitHub [52], İtalyan Tıbbi ve Girişimsel Radyoloji Derneği [53], Avrupa Radyoloji Derneği [54], GitHub [55], FigShare COVID-19 Göğüs X-Ray Görüntü Deposu [56], GitHub [57], Kuzey Amerika Radyoloji Derneği [58] ve Kaggle Chest X-Ray Images (Pneumonia) [59] bağlantılarından derlenmiştir. Daha sonra derlenen veri seti Kaggle üzerinden araştırmacıların derin öğrenme yaklaşımları ile COVID-19 tanısı koyabilen modeller oluşturabilmesi için herkese açık bir şekilde sunulmuştur. İlgili veri seti sayesinde salgın süresinde yeterli tıbbi alt yapıya sahip olmayan ülkelerin hastalık ile mücadelesine destek verebilecek karar destek sistemleri geliştirilebilmektedir.

Çizelge 4.1. Veri setinde sınıflandırma etiketine göre görüntü dağılımı

COVID-19	Akciğer Opasitesi	Sağlıklı	Viral Pnömoni	Toplam
3,616	6,012	10,192	1,345	21,165

Veri seti; sağlıklı, viral pnömoni, akciğer opasitesi ve COVID-19 hastalarına ait akciğer röntgenlerinden oluşmaktadır. Yapısı gereği veri seti uzman radyologlar tarafından ayırt edilebilecek düzeyde veri çeşitliliğine sahiptir. Bu çeşitlilik sayesinde geliştirilecek sistemler ile salgın sürecince yaşanan en büyük sorunlardan olan yanlış tanı koyma probleminde de direnç sağlanacaktır.



Şekil 4.1.Sınıflandırma etiketine göre akciğer X-Ray görüntüleri

Yapılan çalışma kapsamında veri seti her iki sınıflandırma yöntemi için eğitim, doğrulama ve test olmak üzere üç gruba bölünmüştür. Veri seti %80-%20 oranında eğitim ve test kümesi şeklinde ayrılmıştır. Modelin aşırı öğrenmesinin önüne geçmek ve davranışını takip edebilmek için eğitim kümesinin %20'si doğrulama kümesi olarak belirlenmiştir.

Çizelge 4.2.Veritinden oluşturulan alt veri setleri

Eğitim Kümesi	Validasyon Kümesi	Test Kümesi
13,546	3,386	4,233

Çizelge 4.3.Alt veri setlerinin sınıflandırma etiketlerine göre dağılımı

Veri Seti	COVID-19	Akciğer Opasitesi	Sağlıklı	Viral Pnömoni
Eğitim	2,905	4,799	8,152	1,076
Test	711	1,213	2,040	269

4.2. Veri Ön İşleme

Veri setinde yer alan tüm X-Ray görüntüleri 299x299 boyutlarında olup 3 kanallı bir yapıdadır. Sette herhangi bir sapan veriye rastlanmamıştır. ESA ağlarının uygulanabilmesi için farklı dizinlerde bulunan veriler tek dizinde toplanıp virgülle ayrılmış çalışma dosyasının oluşturulabilmesi için python ile kod bloğu yazılarak bu dizin taranmıştır. Mevcut ve gelecek zamanda gerçekleştirilebilecek çalışmalar için veriler özelliklerine göre farklı şekilde ikili ve çoklu etiketlenmiştir.

Çizelge 4.4. Virgülle ayrılmış dosya yapısı

imageName	isInfected	isCovid	infectionTypeNmrc	infectionTypeChrc
String	Boolean	Boolean	İnt(1:Covid, 2: Lung Opacity,3:Normal,4: Viral Pnemuonia)	Char(C:Covid, L: Lung Opacity, N: Normal, V: Viral Pneumonia)

Aşırı öğrenmeyi önlemek için farklı veri artırım yöntemleri kullanılmıştır. Literatürde çok fazla yöntem bulunmasına karşın en uygun kombinasyon için bu alanda yapılan geçmiş çalışmalar dikkate alınmıştır. Monshi ve arkadaşları [5] tarafından X-Ray görüntüleri üzerine yapılan çalışmada, en iyi veri artırım yöntemleri ve hiper parametreler tespit edilmeye çalışılmıştır. Tez kapsamında X-Ray görüntülerine uygulanan veri artırım yöntemlerinde bu çalışmanın çıktıları baz alınmıştır. Görüntülere; 20 derece rotasyon, 1,2 oranında yakınlaştırma, 0,2 oranında eğilme, 0,3 oranında aydınlatma ve 0,2 oranında genişlik ve yükseklikte öteleme uygulanmıştır.

4.3. Kullanılan Araçlar

Tez kapsamında üzerinde çalışılan tüm yapay sinir ağları Tensorflow ve Keras derin öğrenme kütüphaneleri yardımıyla koşulmuştur. Google mühendisleri tarafından geliştirilen açık kaynak kodlu Tensorflow Kütüphanesi, başlangıç düzeyinden uzman düzeyine kadar tüm araştırmacıların üzerinde çalışabileceği uçtan uca modeller oluşturabileceği oldukça esnek bir kütüphanedir [60]. API yapısında olup platform bağımsız CPU ve GPU kullanarak geliştiricilere çalışma imkânı sunmaktadır. Tez çalışmasında geliştirme dili olarak Python tercih edilmiş olmasına rağmen Tensorflow Kütüphanesi R, Javascript, C++ ve C# programlama dilleriyle de kodlama kabiliyetine sahiptir.

Keras, python programlama dili ile yazılmış derin öğrenme kütüphanesidir. Tensorflow 2 kütüphanesinin yüksek seviyeli API haline getirilmiş şeklidir. Geliştiriciler ve araştırmacılar Keras API'si ile Tensorflow 2'ye ait ölçeklenebilirlik ve platform bağımsız çalışma avantajlarından yararlanabilmektedirler [61]. Keras, TPU ve büyük GPU kümelerinde çalışabilmekte olup çıktılar tarayıcılar veya mobil cihazlarda kullanılabilir. Keras, TPU ve büyük GPU kümelerinde çalışabilmekte olup çıktılar tarayıcılar veya mobil cihazlarda kullanılabilir.

Tez çalışmasında geliştirme ortamı olarak Anaconda, Google Colab ve Kaggle platformları kullanılmıştır. Google Colab ve Kaggle, veri bilimciler ve makine öğrenimi üzerine


alışanlar iin bulut tabanlı evrim ii geliřtirme imkânı sunmaktadır. Kullanıcılara ücretsiz GPU, TPU ve 100 GB kadar depolama alanı hakkına sahiptir. Kaggle, NVIDIA TESLA P100 GPU alt yapısı ile hizmet vermektedir.

Kaggle üzerinde birçok alana ait veri seti makine öğrenmesi ve yapay zekâ topluluğunun kullanabilmesi iin evrim ii ve ücretsiz sunulmuřtur. Ayrıca kurumsal firmalar tarafından bu platform üzerinden görüntü işleme, veri madenciliği, semantik analizi, doğal dil işleme vb. alanlarda yarışmalar düzenlenmektedir.

4.4. Üzerinde alışılan Evriřimsel Sinir Ağları

Tez kapsamında en sık tercih edilen görüntü işleme algoritmalarından 4 tanesi üzerinde alışılmıştır. Bu ağlar kullanılmadan önce imageNet veri seti üzerinde eğitilip transfer öğrenimi yaklaşımı ile başlangı ağırlıklarına ait bilgi aktarımı yapılarak mevcut alışmada kullanılmıştır. Transfer öğrenimi küçük veri setleri üzerinde alışılırken başarılı sonuçlar elde edebilmek iin ağıın ok daha büyük setlerde eğitilip elde edilen bilginin yapılacak alışmaya aktarılması şeklinde özetlenebilmektedir. ImageNet veri seti 1,4 milyon görüntü ve 1,000 sınıftan oluşmaktadır [3-4, 44]. Veri sıkıntısı yařayan birçok problemde bu veri seti kullanılarak başarı sonuçlar elde edilebilmektedir. alışmada kullanılan ESA modelleri;

- MobilNetV2
- DenseNet121
- InceptionResNetV2
- Xception




Şekil 4.2.Çalışma kapsamında izlenen transfer öğrenimi yaklaşımı

4.4.1. MobileNetV2

MobileNetV2 mimarisi işlem gücü düşük mobil cihazlar için geliştirilmiş son teknoloji ve yüksek performanslı evrimsel sinir ağıdır. MobileNet ağı ile işlem ve parametre sayısında ciddi oranda azalma sağlanırken model aynı başarı oranıyla sınıflandırma yapmaya devam etmektedir. Evrişim katmanında gerçekleştirilen özellik çıkarımında tensörlerin tamamı kullanılmadığı için diğer modellere göre çok daha az bellek ihtiyacı duymaktadır. Bellek ihtiyacında yapılan bu iyileştirme, ön bellek kontrollü koşan yazılımlar için yapılan gömülü donanım tasarımlarında aranan bir özelliktir [1-4, 62].

MobileNetV2 ağı, 52 evrişim katmanı ve 1 tam bağlantılı katman olmak üzere toplam 53 katmandan oluşmakta ve diğer mimarilere göre daha hafif bir yapı olarak değerlendirilmektedir [24]. Diğer ağlara göre bu ağların en ayırt edici özelliği, tersine çevrilmiş kalan (Inverted Residuals) ve doğrusal darboğaz (Linear Bottleneck) bloklarının beraber kullanılarak bellek ihtiyacını önemli ölçüde azaltmasıdır [17]. MobileNetV2 mimarisi; 3 evrişim katmanı, takip eden 16 tersine çevrilmiş kalan ağ ve dar boğaz blokları, 1 evrişim katmanı ve 1 adet tam bağlantılı katman içermektedir [24].




Şekil 4.3.MobileNetV2 mimarisi [74]

MobileNetV2 ağlarında tam evrişim katmanı çarpanlarına ayrılarak derinlemesine ayrılabilir evrişim ve noktasal ayrılabilir evrişim olmak üzere iki farklı katmana bölünmüştür. İlk katman olan derinlemesine evrişim ile görüntüdeki her kanala hafif filtreleme uygulanmaktadır. Noktasal evrişim katmanında 1x1 boyutunda evrişim uygulanarak giriş kanallarının doğrusal kombinasyonları hesaplanarak yeni özellikler çıkarılmaktadır. MobileNetV2 ağlarında 3x3 boyutlarında derinlemesine evrişim uygulanmakta olup geleneksel yaklaşımlarına göre hesaplama maliyeti 8-9 katına kadar azalmaktadır [1-4, 62].

4.4.2. DenseNet121


Yoğun bağlı evrişimli ağlarda tüm katmanlar birbirlerine bağlıdır. Her katman kendinden önceki katmanlara ait özellik haritalarının tamamını kullanmakla beraber kendi özellik haritasını da sonraki katmanlara aktarmaktadır [63]. Ağın uygulanabilir bir yapıda tutulabilmesi için özellik haritalarının birleştirilebilmesinde alt örnekleme yöntemi uygulanmakta olup bu sayede özellik harita sayıları yönetilebilir limitler içinde tutulmaktadır. Bu amaçla yoğun bloklar arasına yığın normalleştirme, evrişim ve ortaklama katmanları içeren geçiş blokları yerleştirilmektedir [3-4, 64].



Şekil 4.4.DenseNet121 yoğun bloklar ve geçiş katmanları arasındaki ilişki [64]

DenseNet ağına başlıca avantajları; kaybolan gradyan problemine iyileştirmelerde bulunması, güçlü bir özellik yayılımı sunması, çıkarılan özelliklerin tekrar kullanımını sağlaması ve toplam parametre sayısında diğer ağlara göre azaltılması şeklinde sıralanabilir [63].

DenseNet121 ağı ise 121 katmandan oluşmaktadır. Ağda kullanılan katmanlar oldukça dar yapıda olup 12 filtreden meydana gelmektedir. Katmanlardan geçerken kölektif bilgiye sınırlı miktarda yeni özellik haritası eklenmekte olup son katmandaki ağ tüm özellik haritalarını kullanarak sınıflandırma işlemini neticelendirmektedir [2-3, 63].




Şekil 4.5.DenseNet121 mimarisi [64]

4.4.3. Xception


Xception mimarisi, derinlemesine ayrılabilir katmanlar ve kalan bağlantıların doğrusal bir yığın formudur [65]. Bu ağlar derinlemesine ayrılabilir evrişim katmanı temeline dayanmaktadır. Ayrılabilir evrişim katmanları ile ağın hesaplama zamanı daha efektif hale getirilmektedir [2-3, 66]. Derinlemesine ayrılabilir evrişim katmanı; kanal bazlı derinlemesine evrişim ve noktasal evrişim olmak üzere iki alt bileşenden oluşmaktadır [67]. Xception ağlarında veriye ilk adımda noktasal evrişim, ikinci adımda ise derinlemesine evrişim işlemleri uygulanmaktadır [66]. Kalan bağlantılar ile kaybolan gradyan problemi giderilmiştir [67]. Xception mimarisi ilk ve son katman hariç birbiri ile kalan bağlantılar ile bağlı 36 evrişim katmanı içeren 14 modülden oluşmaktadır [65].

Xception ağları yapısal olarak Inception ağları ile benzer olup evrişim katmanındaki farklılıktan dolayı birbirlerinden ayrılmaktadırlar. Ayrıca Inception ağlarına göre ImageNet veri setinde yapılan çalışmada çok daha iyi performans sergilemiştir. Xception mimarisinde ilk adımda kanal bazlı evrişim ikinci adımda 1x1 evrişim uygulanırken Inception'da bu sıralama terstir. Inception ağlarında iki evrişim katmanından sonra RELU aktivasyonu uygulanarak doğrusal olmayan yapıya geçilirken Xception'da derinlemesine ayrılabilir evrişim ile bu sağlanmaktadır [2-3, 65].



Şekil 4.7. InceptionResNetV2 mimarisi [72]

Literatürde yer alan ve en sık kullanılan ESA modellerinin ImageNet veri setindeki Top-1 ve Top-5 Accuracy performansları Şekil 4.8 ve Şekil 4.9’da yer verilmiştir [78]. Şekildeki daire büyüklükleri modellerin parametre sayısını yani karmaşıklığı anlamına gelmektedir. G-Flops eksenini ise 1 milyar flopsa(Saniyede kayan nokta işlemi) eşit olup hesaplama karmaşıklığını ifade etmektedir. Çalışmada kullanılan modeller kırmızı kutu içine alınmıştır.




Şekil 4.9.Kullanılan ESA modellerinin ImageNet Top-5 Accuracy performansları [78]

4.5. Önerilen Yaklaşım

Tez kapsamında yapılan çalışma 3 fazdan oluşmaktadır. İlk fazda ESA modelleri transfer öğrenimi ile aldıkları başlangıç ağırlıkları ile ön eğitilmiş hale getirilmiştir. Sıfırdan eğitime başlamak yerine atılan bu iyileştirme sonrasında modeller probleme ait X-Ray veri setinde

eğitilmiştir. Bu adıma müteakip görüntüler COVID-19 pozitif ve negatif şeklinde sınıflandırılmıştır.

İkinci fazla ise çoklu sınıflandırma hedeflenmiş olup modellerin ikili sınıflandırmayla benzer eğitim aşamasından sonra veriyi COVID-19, Akciğer Opasitesi, Normal ve Viral Pnömoni etiketlerine göre sınıflandırması incelenmiştir.




Şekil 4.10.ESA modellerinin ikili ve sınıflandırma blokları

Topluluk öğrenmesi adımı için kullanılan temel modellerin ikili ve çoklu sınıflandırma işlemlerine ait tüm akış Şekil 4.10'da gösterilmiştir.

Modellerin çıkış katmanında performansı artırmak ve tez kapsamındaki problem tanımına ait sınıf etiketlerine uyumluluk göstermek için yeni katmanlar eklenmiştir. Bu katmanların gösterimine Şekil 4.11'de yer verilmiştir. Modele eklenen bu katmanlar; 4x4 boyutunda ortaklama katmanı, tam bağlantılı ağlar için düzleştirme katmanı, 256 nöronlu ve ReLU aktivasyon fonksiyonuna sahip gizli katmanları içeren tam bağlantılı katman, performansı artırmak ve aşırı öğrenmenin önüne geçmek için 0,5 oranında seyreltme(Dropout), 128 nöronlu ve ReLU aktivasyon fonksiyonuna sahip tam bağlantılı katman, 0,5 oranında

seyreltme, sınıf etiketlerine ait nöronları içeren son katman şeklindedir. Son katmanda ikili sınıflandırma için sigmoid, çoklu sınıflandırma için softmax aktivasyon fonksiyonları kullanılmıştır.




Şekil 4.11.ESA modellerine eklenen yeni çıkış katmanları

Modeller katmanlar üzerinde yapılan değişiklikler sonunda yeni parametrelere göre derlenip kullanıma hazır hale getirilmiştir. Modellerde ikili sınıflandırma için ikili kategorik çapraz entropi (Binary Categorical Cross Entropy), çoklu sınıflandırma için ise kategorik çapraz entropi (Categorical Cross Entropy) kayıp/yitim fonksiyonu kullanılmıştır. Optimizasyon yöntemleri arasında en iyi sonuç veren adadelta optimizasyon yaklaşımı tercih edilmiştir.

Modeller uygulanırken CPU, GPU ve TPU gibi mevcut kaynakların sınırlı olması nedeniyle Keras kütüphanesine ait erken durdurma (early stopping) mekanizması kullanılmıştır. Bu mekanizma modeldeki doğrulama kaybı (validation loss) değerini gözlemlemektedir. Eğer model satüre olup doğrulama kaybında bir değişiklik gerçekleşmezse en iyi sonucu veren ağırlıklar kayıt edilerek model sonlandırılmaktadır. Çalışma kapsamında doğrulama kaybı gözlemleme değeri 15 olarak alınmıştır. Tüm modellerin eğitim sürecinde döngü(Epoch) sayısı 100 şeklinde belirlenmiştir. Veriler 32'lik paketler (Batch Size) halinde modellere verilmiştir.


Eğitim ve validasyon işlemleri tamamlanan evrişimsel modeller ve bu modellere ait ağırlıklar kayıt edilerek son adım olan topluluk öğrenmesine aktarılmıştır. İlgili çalışma kapsamında ağırlıksız model ortalaması topluluk öğrenmesi yöntemi kullanılarak eğitilen modellerin çıkış katmanlarına ait ağırlıkların ortalaması alınarak birleştirilmiştir. Elde edilen

birleştirilmiş modelde optimizasyon modeli olarak hem adam hem de adadelta optimizasyon yöntemi denenmiş olup adadelta ile daha iyi sonuçlar elde edilmiştir.




Şekil 4.12.Çalışmada izlenen topluluk öğrenmesi yaklaşımı

Son fazda ise birbirlerine göre avantajları olan birleştirilmiş modeller kullanılarak ikili ve çoklu sınıflandırma yapılmış olup sonuçlar analiz edilmiştir. Model birleştirme süreci Şekil 4.12’de gösterildiği gibi çıkış katmanlarının ortalaması alınarak yapılmıştır.



Şekil 4.13.İkili sınıflandırma için önerilen hibrit model mimarisi



Şekil 4.14.Çoklu sınıflandırma için önerilen hibrit model mimarisi

Şekil 4.13 ve 4.14’de yer alan görsellerde DenseNet121 bloğu temsili olarak gösterilmiştir. Genel mimaride kullanılan topluluk öğrenmesinin çekirdek modelleri aynı olup bu modeller; DenseNet121, MobileNetV2, Xception ve InceptionResNetV2’dir.

Çizelge 4.6.Modellere ait parametre bilgisi

Model	Giriş Veri Boyutu	Eğitilebilir Parametre Sayısı	Sabit Parametre Sayısı	Toplam Parametre Sayısı
DenseNet121	224x224x3	8,043,970	83,648	8,127,618
MobileNetv2	224x224x3	3,576,130	34,112	3,610,242
Xception	299x299x3	22,945,642	54,528	23,000,170
InceptionResNetV2	299x299x3	54,710,946	60,544	54,771,490
Hibrit Model	256x256x3	59,276,688	232,832	89,509,520

Hibrit model ve bu modeli oluşturan alt modeller: giriş veri boyutu, eğitilebilir, sabit parametre ve toplam parametre sayısına göre Çizelge 4.6.’da karşılaştırılmıştır.

5. BULGULAR

Veri seti üzerinde yapılan çalışmada iki farklı sınıflandırma yaklaşımı izlenerek akciğer X-Ray görüntülerini evrişimsel sinir ağları ile analiz ederek COVID-19 tespiti yapılmaya çalışılmıştır. İlk yaklaşımda X-Ray görüntüleri COVID-19 pozitif ve negatif sınıf etiketiyle ikili, ikinci yaklaşımda ise Normal, COVID-19, Akciğer Opasitesi ve Viral Pnömoni etiketleri dikkate alınarak çoklu sınıflandırma yapılmıştır. Önerilen çalışmada ön eğitilmiş modeller transfer öğrenimi ile aldıkları başlangıç ağırlıklarını kullanarak ikili ve çoklu sınıflandırma için tek tek eğitilmiştir. Eğitimi tamamlanan modeller ve ağırlıklar topluluk derin öğrenmesinde birleştirilmek üzere kayıt edilmiştir. Bireysel modellerin daha yüksek performansta sonuç verebilmesi için çıkış katmanlarında çeşitli eklemeler yapılmıştır. Alt modellerin eğitim işlemi tamamlandıktan sonra son aşamada ağırlıksız model ortalaması yaklaşımı ile birleştirme yapılmıştır. Bu yöntemin modele ek bir parametre gerektirmemesi nedeniyle sadece çıkış katman ağırlıklarının ortalaması alınmıştır. Final model oluşturulduktan sonra test kümesi kullanılarak sonuçlar elde edilmiştir.

Çizelge 5.1.İkili sınıflandırma sonuçları


Model	Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	Özgüllük (Specificity)	Hassaslık (Sensitivity)	AUC	MSE
DenseNet121	0,9862	0,9541	0,9648	0,9997	0,9887	0,9933	0,0105
MobileNetV2	0,9884	0,9728	0,9578	1,0	0,9901	0,9944	0,0095
Xception	0,9799	0,9471	0,9324	0,9985	0,9789	0,9864	0,0165
InceptionResNetV2	0,9591	0,8788	0,8776	0,9900	0,9409	0,9588	0,0372
Hibrit Model	0,9900	0,9737	0,9666	1,0	0,9980	0,9974	0,0108

İkili sınıflandırma sonuçlarına ait Çizelge 5.1 incelendiğinde alt modellerden en başarılı performansı MobileNetV2 ağı sergilemiştir. Yanlış negatif yani gerçekte hasta olup model tarafından hasta olarak sınıflandırılmayan durumları inceleyen duyarlılık metriği incelendiğinde hibrit model ve MobileNetV2 mimarisi en başarılı sonuçları ortaya koymuştur.


Çizelge 5.2.Çoklu sınıflandırma sonuçları

Model	Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Recall)	Özgüllük (Specificity)	Hassaslık (Sensitivity)	AUC	MSE
DenseNet121	0,9317	0,9336	0,9308	0,9980	0,9906	0,9883	0,0275
MobileNetV2	0,9216	0,9249	0,9171	0,9983	0,9929	0,9878	0,0302
Xception	0,9152	0,9128	0,9978	0,9975	0,9858	0,9832	0,0338
InceptionResNetV2	0,8909	0,8959	0,8883	0,9910	0,9679	0,9690	0,0453
Hibrit Model	0,9398	0,9437	0,9312	0,9987	0,9979	0,9918	0,0249


Çizelge 5.2’de yer alan çoklu sınıflandırma sonuçlarına göre alt modellerden en başarılı sınıflandırma performansını DenseNet121 mimarisi göstermiştir. Diğer metrikler incelendiğinde, ortalama ortalama hata karesi(MSE) ve doğru pozitif, yanlış pozitif arasındaki korelasyonu(AUC) en yüksek hibrit model ve DenseNet121 mimarilerinde elde edilmiştir.



Şekil 5.1.Hibrit modele ait ESA modellerinin çoklu sınıflandırma performansları



Şekil 5.2. Hibrit modele ait ESA modellerinin ikili sınıflandırma performansları



Şekil 5.3. Alt modellerin çoklu ve ikili sınıflandırma hata matrisleri

Alt modellere ait performans grafikleri Şekil 5.1 ve 5.2’de yer verilmiş olup iki sınıflandırma yaklaşımı için hata matris bilgileri Şekil 5.3’de bulunmaktadır.

Analiz sonuçlarına göre topluluk öğrenmesi yaklaşımının iki sınıflandırma yönteminde de daha iyi sonuçlar verdiği gözlemlenmiştir. İkili sınıflandırma için oluşturulan final model, kendini oluşturan alt modellere göre küçük bir oranda artış sağlamıştır. Fakat önerilen çözümün alt modellerin tüm avantajlarını koruyarak gelecekteki veri setlerinde de yüksek doğruluk oranında ikili sınıflandırma yapacağı değerlendirilmektedir. Çoklu öğrenmede ise alt modellere göre çok daha iyi genelleştirme sağlanmış olup final model doğruluk oranı bu modellerden yüksek çıkmıştır.



Çizelge 5.3. Mevcut çalışma ve diğer çalışmaların karşılaştırılması

Referans Makale	Model	Veri Seti	Doğruluk Oranı
[11]	COVID-NET	13,800 Akciğer X-Ray Görüntüsü (8,066 Normal, 5,538 Pnömoni, 183 COVID-19)	İkili sınıflandırma: %92,6. Çoklu sınıflandırma: %83,5.
[12]	DarkCovidNet	1,127 Akciğer X-Ray Görüntüsü (500 Normal, 500 Pnömoni, 127 COVID-19)	İkili sınıflandırma: %98,08. Çoklu Sınıflandırma: %87,02.
[17]	COVIDX-Net (VGG19, DenseNet201, InceptionV3, ResNetV2, InceptionResNetV2, Xception, MobileNetV2)	50 Akciğer X-Ray Görüntüsü (25 COVID-19)	İkili Sınıflandırma: %90.
[23]	Hibrid CNN (Xception ve ResNet50V2)	15,085 Akciğer X-Ray Görüntüsü (180 COVID-19, 6,054 Pnömoni, 8,851 Normal)	İkili Sınıflandırma: %99,50. Çoklu Sınıflandırma: %91,4.
[31]	ResNet18, InceptionV3, MobileNetV2	Akciğer X-Ray Görüntüsü (1,778 COVID-19, 1,530 Normal, 1,718 Diğer Pnömoni)	Çoklu Sınıflandırma X-Ray MobileNetV2: %87. X-Ray ResNet18: %90. X-Ray InceptionV3: %92.
[32]	CVDNet	2,905 Akciğer X-Ray Görüntüsü (219 COVID-19, 1,341 Normal, 1,345 Viral Pnömoni)	İkili Sınıflandırma: %97,20. Çoklu Sınıflandırma: %96,69.
[33]	Ensemble Deep Learning (InceptionV3, DenseNet121, Xception)	10,000 Akciğer X-Ray Görüntüsü (2,022 Diğer Pnömoni, 2,161 COVID-19, 5,563 Normal)	İkili Sınıflandırma: %98,33 Çoklu Sınıflandırma: %92,36
[34]	Ensemble Deep Learning (MobileNet, InceptionV3)	4,200 Akciğer X-Ray Görüntüsü (1,050 COVID-19, 1,050 Bakteriye Pnömoni, 1,050 Viral Pnömoni, 1,050 Normal)	Çoklu Sınıflandırma: %96,49
[75]	Ensemble Deep Learning (Farklı ağırlıklarla DenseNet161)	11,197 Akciğer X-Ray Görüntüsü (7,217 Normal ve Diğer Pnömoniler, 5,451 Pnömoni, 1,056 COVID-19)	Çoklu Sınıflandırma: %91,2
[76]	Ensemble Deep Learning (MobileNet, InceptionV3, Xception, DenseNet121, DenseNet201)	1,622 Akciğer X-Ray Görüntüsü (408 COVID-19, 408 Bakteriye Pnömoni, 408 Viral Pnömoni, 408 Normal)	Çoklu Sınıflandırma: %89,21
[77]	Ensemble Deep Learning (COVID-NET farklı örneklemeleri)	15,477 Akciğer X-Ray Görüntüsü (6,053 Pnömoni, 8,851 Normal, 573 COVID-19)	İkili Sınıflandırma: 96 %
#	Önerilen Çözüm	21,165 Akciğer X-Ray Görüntüsü (3,616 COVID-19, 6,012 Akciğer Opasitesi, 10,192 Sağlıklı, 1,1345 Viral Pnömoni)	İkili Sınıflandırma: %99,00 Çoklu Sınıflandırma: %93,98

Önerilen çalışma ve benzer çalışmalar Çizelge 5.3’de karşılaştırılmıştır. Literatürde yer alan en büyük koronavirüs veri setlerinden birisi kullanılmıştır. Tez çalışması kapsamında kullanılan veri seti diğer çalışmalara göre çok daha zengin olup çalışma odağı olan COVID-19 görüntü sayısı açısından en fazla veriye sahip settir. İkili sınıflandırma için önerilen hibrit mimari benzer çalışmalara göre en iyi performansı göstermiştir. Hibrit mimarinin çoklu sınıflandırma performansı ise veri seti büyüklükleri dikkate alındığında başarılı performanslar arasındadır.



6. SONUÇLAR VE TARTIŞMA

İlgili çalışma kapsamında akciğer X-Ray görüntüleri kullanılarak COVID-19 teşhisi için ikili ve çoklu sınıflandırma yapabilen bir çözüm ortaya konmuştur. Pandeminin yeni ortaya çıkması, kişisel bilgilerin korunması gibi yasal düzenlemeler nedeniyle açık kaynaklarda bulunan sınırlı sayıda veriye rağmen diğer çalışmalara göre büyük bir veri seti ile modeller geliştirilmiştir. Çalışmadaki esas amaç ortaya konan çözümün ileride karşılaşılabilecek çeşitli büyüklükteki veri setlerinde de etkili sonuç üretmesi olarak belirlenmiştir. Bu doğrultuda bilgisayarlı görü ve görüntü işleme problemlerinde yüksek performans sergileyen DenseNet121, MobileNetV2, Xception ve InceptionResNetV2 modellerini temel alan hibrit bir model inşa edilmiştir. Tercih edilen modellerin eğitim aşamalarına sıfırdan başlamak yerine başlangıç ağırlıkları ImageNet veri setinden transfer öğrenimi yaklaşımı ile aktarılmıştır.

Hibrit modelde kullanılan alt modellerin eğitimi birbirlerinden bağımsız olarak gerçekleştirilmiştir. Eğitimi tamamlanan modellere ait model ve ağırlıklar birleştirme adımı için kayıt edilmiştir. Alt modellere ait performans metrikleri incelendiğinde ikili sınıflandırma için en başarılı model 0.9884 doğruluk oranıyla MobileNetV2 çıkmıştır. Hasta olup model tarafından hasta değil olarak işaretlenenlerin oranını ifade eden diğer önemli metrik olan duyarlılık incelendiğinde ise DenseNet121 ve MobileNetV2 modelleri sırası ile 0.9648 ve 0.9578 oranlarında sonuçlanmıştır. Çoklu sınıflandırma sonuçları analiz edildiğinde ise en başarılı performansı 0.9317 doğruluk oranı ile DenseNet121 modeli göstermiştir. Duyarlılık metriğinde de Xception mimarisi oldukça başarılı olup 0.9978 değerini ulaşmıştır. Çalışmanın çıkış motivasyonu olan birbirine göre farklı avantajlara sahip ağların birleştirilmesi hedefine ulaşmıştır. İkili ve çoklu sınıflandırmada en yüksek sınıflandırma oranı hibrit modellerle elde edilmiştir.

Modellerin birleştirilmesi sürecinde ağırlıksız model ortalaması topluluk öğrenmesi yaklaşımı kullanılarak dört evrimsel sinir ağının avantajları bir araya getirilmiş ve daha iyi genelleştirme sonuçları elde edilmiştir. İkili sınıflandırma için ortaya konan final modelde alt modellere göre az da olsa artış elde edilmiş olup sonuç model %99 doğruluk oranı, çoklu sınıflandırma da ise daha yüksek bir artış sağlanmış olup %93,98 doğruluk oranı ile sınıflandırma yapılmıştır. Bu sonuçlar kendini ispatlamış ve yüksek performansta çalışan

ESA modellerinin üstüne kurulan hibrit mimarinin gelecekte karşılaşılabileceği veri setlerinde de umut verici performans sergileyebileceğini göstermektedir.

Bu çalışma kapsamında karşılaşılan başlıca zorluklar: veri setinin yeterli büyüklükte olmaması, dengeli bir dağılım göstermemesi, diğer pnömoni türlerine ait az veri içermesi ve bulut tabanlı makine öğrenme platformlarının uzun süren analizlerde çalışmayı istemsiz sonlandırma eğilimi şeklinde sıralanmaktadır. Ayrıca iki hibrit modelde de en yüksek parametre sayısına sahip ama en düşük performans sergileyen InceptionResNetV2 modelinin çıkarılarak farklı bir model konması faydalı olacaktır. Böylece hibrit modellerin karmaşıklığı azalacaktır. Mevcut çalışmanın PCR testi ile korele X-Ray görüntülerinin eklenerek geliştirilmesi X-Ray görüntülerinin makine öğrenmesi yaklaşımları ile yorumlanmasının kabulünü ve kullanılabilirliğini destekleyecektir.

Parametre sayısı en düşük olan MobileNetV2 ağı ikili sınıflandırmada en başarılı, çoklu sınıflandırmada ise ikinci en yüksek performansı sergilemiştir. Bu sonuçlara göre salgının zirve yaptığı dönemlerde geliştirilecek mobil çözümler ile hastalık teşhisi ve izolasyon kararı için asker, polis, memurlar gibi destek personelleri kullanılabilir. Bu sayede doktorlar üzerindeki yük hafifletilmiş ve salgın daha hızlı kontrol altına alınacaktır.

Gelecekte yapılacak çalışmalarda; standart olmayan ve her cihazın farklı özelliklerde görüntü üretme problemine, diğer pnömonilere ait daha çok görüntünün veri setlerine dahil edilmesine, görüntülere ait özellikler ile diğer klinik belirtilerin beraber modellerde kullanılmasına, modeller tarafından atlanabilen küçük nüfuz bölgelerinin tespiti için çok iyi segmentasyon modellerine ve çok daha büyük veri setlerine odaklanılmalıdır. Ayrıca büyük potansiyel barındıran mobil çözümler için federe mimariler geliştirilmesi sahada virüs ile mücadelede etkinliği artıracaktır. Daha başarılı hibrit modellerin üretilmesi için diğer topluluk öğrenmesi metotlarının incelenmesi gelecek çalışmalarda isabetli bir tercih olacaktır.

KAYNAKLAR

1. Allam, Z. (2020). *Surveying the Covid-19 Pandemic and Its Implications: Urban Health, Data Technology and Political Economy* (First Edition). Amsterdam: Elsevier Science, 1–7.
2. Qu, J., Cao, B., and Chen, R. (2021). *COVID-19: The Essentials of prevention and treatment* (First Issue). Amsterdam: Elsevier Science, 1-6.
3. Karthik, R., Menaka, R., and M, H. (February, 2021). Learning distinctive filters for COVID-19 detection from chest X-ray using shuffled residual CNN. *Applied soft computing*, 99, 106744.
4. Alam, N.-A.-A., Ahsan, M., Based, M. A., Haider, J., and Kowalski, M. (February, 2021). COVID-19 Detection from Chest X-ray Images Using Feature Fusion and Deep Learning. *Sensors*, 21(4), 1480.
5. Monshi, M. M. A., Poon, J., Chung, V., and Monshi, F. M. (June, 2021). CovidXrayNet: Optimizing data augmentation and CNN hyperparameters for improved COVID-19 detection from CXR. *Computers in Biology and Medicine*, 133, 104375.
6. Yang, J., Zheng, Y., Gou, X., Pu, K., Chen, Z., Guo, Q., Ji, R., Wang, H., Wang, Y., and Zhou, Y. (2020). Prevalence of comorbidities and its effects in patients infected with SARS-CoV-2: a systematic review and meta-analysis. *International journal of infectious diseases: IJID : official publication of the International Society for Infectious Diseases*, Vol. 94, 91–95.
7. Lybarger, K., Ostendorf, M., Thompson, M., and Yetisgen, M. (2021). Extracting COVID-19 Diagnoses and Symptoms from Clinical Text: A New Annotated Corpus and Neural Event Extraction Framework. *Journal of Biomedical Informatics*, 117(13), 103761.
8. İnternet: WHO Coronavirus (COVID-19) Dashboard. URL: <https://covid19.who.int/>. Son Erişim Tarihi: 12.09.2021.
9. Bouchareb, Y., Khaniabadi, P. M., Kindi, F. A., Dhuhli, H. A., Shiri, I., Zaidi, H., and Rahmim, A. (2021). Artificial intelligence-driven assessment of radiological images for COVID-19. *Computers in Biology and Medicine*, 136, 104665.
10. Huang, P., Liu, T., Huang, L., Liu, H., Lei, M., Xu, W., . . . Liu, B. (2020). Use of Chest CT in Combination with Negative RT-PCR Assay for the 2019 Novel Coronavirus but High Clinical Suspicion. *Radiology*, 295(1), 22-23.
11. Wang, L., Lin, Z. Q., and Wong, A. (2020). COVID-Net: A tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images. *Scientific Reports*, 10(1), 19549.
12. Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yıldırım, O., and Acharya, U. R. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine*, 121, 103792.

13. Wang, D., Hu, B., Hu, C., Zhu, F., Liu, X., Zhang, J., . . . Peng, Z. (2020). Clinical Characteristics of 138 Hospitalized Patients With 2019 Novel Coronavirus–Infected Pneumonia in Wuhan, China. *Jama*, 323(11), 1061.
14. Oh, Y., Park, S., and Ye, J. C. (2020). Deep Learning COVID-19 Features on CXR Using Limited Training Data Sets. *IEEE Transactions on Medical Imaging*, 39(8), 2688-2700.
15. Wang, Z., Xiao, Y., Li, Y., Zhang, J., Lu, F., Hou, M., and Liu, X. (2021). Automatically discriminating and localizing COVID-19 from community-acquired pneumonia on chest X-rays. *Pattern Recognition*, 110, 107613.
16. Horry, M. J., Chakraborty, S., Paul, M., Ulhaq, A., Pradhan, B., Saha, M., and Shukla, N. (2020). COVID-19 Detection Through Transfer Learning Using Multimodal Imaging Data. *IEEE Access*, 8, 149808-149824.
17. Hemdan, E. E., Shouman, A. M., Karar, M. E. (2020). COVIDX-Net: A Framework of Deep Learning Classifiers to Diagnose COVID-19 in X-Ray Images. *ArXiv*, abs/2003.11055.
18. Rubin, G. D., Ryerson, C. J., Haramati, L. B., Sverzellati, N., Kanne, J. P., Raoof, S., . . . Leung, A. N. (2020). The Role of Chest Imaging in Patient Management during the COVID-19 Pandemic: A Multinational Consensus Statement from the Fleischner Society. *Radiology*, 296(1), 172-180.
19. Arru, C., Ebrahimian, S., Falaschi, Z., Hansen, J. V., Pasche, A., Lyhne, M. D., Zimmermann, M., Durlak, F., Mitschke, M., Carriero, A., Nielsen-Kudsk, J. E., Kalra, M. K., and Saba, L. (2021). Comparison of deep learning, radiomics and subjective assessment of chest CT findings in SARS-CoV-2 pneumonia. *Clinical imaging*, 80, 58–66.
20. Narin, A., Kaya, C., and Pamuk, Z. (2021). Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks. *Pattern Analysis and Applications*, 24, 1207-1220.
21. Abbas, A., Abdelsamea, M. M., and Gaber, M. M. (2020). Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network, *Applied Intelligence*, 51, 854-864.
22. Gao, T., and Wang, G. (2020). Chest X-ray image analysis and classification for COVID-19 pneumonia detection using Deep CNN. medRxiv preprint medRxiv 2020.08.20178913.
23. Rahimzadeh, M., and Attar, A. (2020). A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2. *Informatics in Medicine Unlocked*, 19, 100360.

24. Ardakani, A. A., Kanafi, A. R., Acharya, U. R., Khadem, N., and Mohammadi, A. (2020). Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks. *Computers in Biology and Medicine*, 121, 103795.
25. Brunese, L., Mercaldo, F., Reginelli, A., and Santone, A. (2020). Explainable Deep Learning for Pulmonary Disease and Coronavirus COVID-19 Detection from X-rays. *Computer Methods and Programs in Biomedicine*, 196, 105608.
26. Hassantabar, S., Ahmadi, M., and Sharifi, A. (2020). Diagnosis and detection of infected tissue of COVID-19 patients based on lung x-ray image using convolutional neural network approaches. *Chaos, Solitons & Fractals*, 140, 110170.
27. Jain, R., Gupta, M., Taneja, S., and Hemanth, D. J. (2020). Deep learning based detection and analysis of COVID-19 on chest X-ray images. *Applied Intelligence*, 51(3), 1690-1700.
28. Aslan, M. F., Unlarsen, M. F., Sabanci, K., and Durdu, A. (2021). CNN-based transfer learning-BiLSTM network: A novel approach for COVID-19 infection detection. *Applied soft computing*, 98, 106912.
29. Pereira, R. M., Bertolini, D., Teixeira, L. O., Silla, C. N., and Costa, Y. M. (2020). COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios. *Computer Methods and Programs in Biomedicine*, 194, 105532.
30. Feki, I., Ammar, S., Kessentini, Y., and Muhammad, K. (2021). Federated learning for COVID-19 screening from Chest X-ray images. *Applied Soft Computing*, 106, 107330.
31. Benmalek, E., Elmhamdi, J., and Jilbab, A. (2021). Comparing CT scan and chest X-ray imaging for COVID-19 diagnosis. *Biomedical Engineering Advances*, 1, 100003.
32. Ouchicha, C., Ammor, O., and Meknassi, M. (2020). CVDNet: A novel deep learning architecture for detection of coronavirus (Covid-19) from chest x-ray images. *Chaos, Solitons & Fractals*, 140, 110245.
33. Bhardwaj, P., and Kaur, A. (2021). A novel and efficient deep learning approach for COVID -19 detection using X-ray imaging modality. *International Journal of Imaging Systems and Technology*, 31(2), 1-17.
34. Ahmad, F., Farooq, A., and Ghani, M. U. (2021). Deep Ensemble Model for Classification of Novel Coronavirus in Chest X-Ray Images. *Computational Intelligence and Neuroscience*, 2021, 1-17.
35. Ankile, L.H., Heggland, M.F., Krage, K. (2020). Deep Convolutional Neural Networks: A survey of the foundations, selected improvements, and some current applications. arXiv preprint arXiv:2011.12960.
36. Arora, D., Garg, M., and Gupta, M. (2020). *Diving deep in Deep Convolutional Neural*

- Network*. 2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN), Greater Noida, India, 749-75.1
37. Pukale, D. D., Bhirud, S. G., and Katkar, V. D. (2017). *Content-based image retrieval using deep convolution neural network*. 2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA), Pune, India, 1-5.
 38. Aloysius, N., and Geetha, M. (2017). *A review on deep convolutional neural networks*. 2017 International Conference on Communication and Signal Processing (ICCSP), 0588-0592.
 39. Gulcu, A., and Kus, Z. (2020). Hyper-Parameter Selection in Convolutional Neural Networks Using Microcanonical Optimization Algorithm. *IEEE Access*, 8, 52528-52540.
 40. Sun, S., Cao, Z., Zhu, H., and Zhao, J. (2020). A Survey of Optimization Methods from a Machine Learning Perspective. *IEEE Transactions on Cybernetics*, 50(8), 3668–3681.
 41. Vani, S., and Rao, T. V. (2019). *An experimental approach towards the performance assessment of VARIOUS OPTIMIZERS on convolutional neural network*. 2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI), Tirunelveli, India, 331-336.
 42. Arunsuriyasak, P., Boonme, P., and Phasukkit, P. (2019). *Investigation of deep Learning optimizer for water pipe Leaking Detection*. 2019 16th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON), Pattaya, Thailand, 85-88.
 43. Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., and Liu, C. (2018). A Survey on Deep Transfer Learning, *International Conference on Artificial Neural Networks*, Island of Rhodes, Greece, 270-279.
 44. Yamashita, R., Nishio, M., Do, R. K., and Togashi, K. (2018). Convolutional neural NETWORKS: An overview and application in radiology. *Insights into Imaging*, 9(4), 611–629.
 45. Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., and He, Q. (2021). A Comprehensive Survey on Transfer Learning. *Proceedings of the IEEE*, 109, 43-76.
 46. Wan, Z., Yang, R., Huang, M., Zeng, N., and Liu, X. (2021). A review on transfer learning in EEG signal analysis. *Neurocomputing*, 421, 1–14.
 47. Weiss, K., Khoshgoftaar, T.M. and Wang, D. A survey of transfer learning. *J Big Data*, 3, 9.
 48. Amin-Naji, M., Aghagolzadeh, A., and Ezoji, M. (2019). Ensemble of CNN for multi-focus image fusion. *Information Fusion*, 51, 201–214.

49. Yang, Y., Lv, H., Chen, N., Wu, Y., Zheng, J., and Zheng, Z. (2021). Local minima found in the subparameter space can be effective for ensembles of deep convolutional neural networks. *Pattern Recognition*, 109, 107582.
50. Ganaie, m. A., Hu, M., Tanveer, M., Suganthan, P. N., (2021). Ensemble deep learning: A review. *arXiv, abs/2104.02395*.
51. İnternet: BIMCV. URL: <https://bimcv.cipf.es/bimcv-projects/bimcv-covid19/#1590858128006-9e640421-6711>. Son Erişim Tarihi: 12.09.2021.
52. İnternet: COVID-19 Image Repository. URL: <https://github.com/ml-workgroup/covid-19-image-repository/tree/master/png>. Son Erişilme Tarihi: 11.05.2021.
53. İnternet: COVID-19 Database. URL: <https://www.sirm.org/category/senza-categoria/covid-19/>. Son Erişilme Tarihi: 11.05.2021.
54. İnternet: European Society of Radiology URL: <https://www.eurorad.org/> Son Erişilme Tarihi: 11.05.2021.
55. İnternet: IEEE8023 COVID Chestxray Dataset URL: <https://github.com/ieee8023/covid-chestxray-dataset>. Son Erişilme Tarihi: 11.05.2021.
56. İnternet: COVID-19 Chest X-Ray Image Repository URL: https://figshare.com/articles/dataset/COVID-19_Chest_X-Ray_Image_Repository/12580328 Son Erişilme Tarihi: 11.05.2021.
57. İnternet: COVID-CXNet URL: <https://github.com/armiro/COVID-CXNet> Son Erişilme Tarihi: 11.05.2021.
58. İnternet: RSNA Pneumonia Detection Challenge URL: <https://www.kaggle.com/c/rsna-pneumonia-detection-challenge/data> Son Erişilme Tarihi: 11.05.2021.
59. İnternet: Chest X-Ray Images (Pneumonia) URL: <https://www.kaggle.com/c/rsna-pneumonia-detection-challenge/data> Son Erişilme Tarihi: 11.05.2021.
60. İnternet: Tensorflow. URL: <https://www.tensorflow.org/>. Son Erişilme Tarihi: 14.05.2021.
61. İnternet: Keras. URL: <https://keras.io/about/>. Son Erişilme Tarihi: 14.05.2021.
62. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L. (2018). *MobileNetV2: Inverted Residuals and Linear Bottlenecks*. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 4510-4520
63. Huang, G., Liu, Z., Maaten, L. V., and Weinberger, K. Q. (2017). *Densely Connected Convolutional Networks*. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, USA, 2261-2269.
64. Wang, S., and Zhang, Y. (2020). DenseNet-201-Based Deep Neural Network with

- Composite Learning Factor and Precomputation for Multiple Sclerosis Classification. *ACM Transactions on Multimedia Computing, Communications, and Applications*, 16(2s), 1-19.
65. Chollet, F. (2017). *Xception: Deep Learning with Depthwise Separable Convolutions*. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, USA, 1800-1807
 66. Rismiyati, Endah, S. N., Khadijah, and Shiddiq, I. N. (2020). *Xception Architecture Transfer Learning for Garbage Classification*. 2020 4th International Conference on Informatics and Computational Sciences (ICICoS), Semarang, Indonesia, 1-4.
 67. Wu, X., Liu, R., Yang, H., and Chen, Z. (2020). *An Xception Based Convolutional Neural Network for Scene Image Classification with Transfer Learning*. 2020 2nd International Conference on Information Technology and Computer Application (ITCA), Guangzhou, China, 262-267.
 68. Srinivasan, K., Garg, L., Datta, D., A. Alaboudi, A., Z. Jhanjhi, N., Agarwal, R., and George Thomas, A. (2021). Performance comparison of deep cnn models for detecting driver's distraction. *Computers, Materials & Continua*, 68(3), 4109–4124.
 69. Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. (2017). *Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning*. Proceedings of the AAAI Conference on Artificial Intelligence, 31(1), 4278-4284.
 70. He, K., Zhang, X., Ren, S., and Sun, J. (2016). *Deep Residual Learning for Image Recognition*. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 770-778.
 71. Konig, J., Jenkins, M. D., Barrie, P., Mannion, M., and Morison, G. (2019). *A Convolutional Neural Network for Pavement Surface Crack Segmentation Using Residual Connections and Attention Gating*. 2019 IEEE International Conference on Image Processing (ICIP), Taipei, Taiwan, 1460-1464.
 72. Goh, G.B., Siegel, C., Vishnu, A., Hodas, N.O., and Baker, N. (2017). Chemception: A Deep Neural Network with Minimal Chemistry Knowledge Matches the Performance of Expert-developed QSAR/QSPR Models. *ArXiv*, arXiv:1706.06689.
 73. Khan, A., Sohail, A., Zahoor, U., and Qureshi, A. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 1 - 62.
 74. Seidaliyeva, U., Akhmetov, D., Ilipbayeva, L., and Matson, E. T. (2020). Real-Time and Accurate Drone Detection in a Video with a Static Background. *Sensors (Basel, Switzerland)*, 20(14), 3856.
 75. Afifi, A., Hafsa, N. E., Ali, M. A., Alhumam, A., and Alsalman, S. (2021). An ensemble of global and local-attention Based convolutional neural networks FOR COVID-19

- diagnosis on chest x-ray images. *Symmetry*, 13(1), 113.
76. Saha, O., Tasnim, J., Raihan, M. T., Mahmud, T., Ahmmed, I., and Fattah, S. A. (2020). *A multi-model BASED Ensembling approach to Detect COVID-19 from chest x-ray images*. 2020 IEEE REGION 10 CONFERENCE (TENCON), Osaka, Japan, 591-595.
 77. 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, 6539-6549.
 78. Bianco, S., Cadène, R., Celona, L., and Napoletano, P. (2018). Benchmark Analysis of Representative Deep Neural Network Architectures. *IEEE Access*, 6, 64270-64277.








EKLER

EK-1.Evrimsel sinir ağlarının günümüz modern mimarilerine zamansal gelişimi [73].



EK-2.Topluluk öğrenmesiyle birleştirilmiş hibrit modele ait özet bilgi.

```

Model: "ensemble"
-----
-----
Layer (type)                Output Shape              Param #   Connected to
=====
-----
input_1 (InputLayer)        [(None, 256, 256, 3)] 0
-----
-----
DenseNet121 (Functional)    (None, 4)                8127748   input_1[0][0]
-----
-----
MobileNet (Functional)      (None, 4)                3610372   input_1[0][0]
-----
-----
Xception (Functional)       (None, 4)                23000300  input_1[0][0]
-----
-----
InceptionResNetV2 (Functional) (None, 4)                54771620  input_1[0][0]
-----
-----
average (Average)           (None, 4)                0          DenseNet121[0][0]
                                           MobileNet[0][0]
                                           Xception[0][0]
                                           InceptionResNetV2[0][0]
=====
=====
Total params: 89,510,040
Trainable params: 89,277,208
Non-trainable params: 232,832
-----
-----

```



GAZİLİ OLMAK AYRICALIKTIR...