

T.C.
KASTAMONU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI



COVID-19 HASTALIĞININ SINIFLANDIRILMASINDA DERİN
ÖĞRENME MODELLERİNİN PERFORMANSLARININ
KARŞILAŞTIRILMASI

PERVİN SÜRGÜÇÖĞLU

YÜKSEK LİSANS TEZİ

DOÇ. DR. KEMAL AKYOL

NİSAN- 2023
KASTAMONU

TAAHHÜTNAME

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranıř ve akademik kurallar çerçevesinde elde edilerek sunulduđunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu alıřmada bana ait olmayan her türlü ifade ve bilginin kaynađına eksiksiz atıf yapıldıđını, bilimsel etiđe uygun olarak kaynak gösterildiđini bildirir ve taahhüt ederim.

Pervin SÜRGÜOĐLU

ÖZET

YÜKSEK LİSANS TEZİ

COVID-19 HASTALIĞININ SINIFLANDIRILMASINDA DERİN ÖĞRENME MODELLERİNİN PERFORMANSLARININ KARŞILAŞTIRILMASI

PERVİN SÜRGÜÇOĞLU

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI
DANIŞMAN:DOÇ. DR. KEMAL AKYOL

İlk olarak Aralık 2019'da Çin'in Wuhan kentinde ortaya çıkan yeni koronavirüs 2019 (Covid-2019) tüm ülkelerde hızla yayılarak pandemi haline geldi. Günlük yaşamda hem halk sağlığı hem de küresel ekonomi üzerinde çok yıkıcı bir etkiye neden olan bu salgın hastalığın daha fazla yayılmasını önlemek ve etkilenen hastaları hızla tedavi etmek için pozitif vakaları olabildiğince erken tespit etmek çok önemlidir. Covid-19 hastalığının tespitinde yapay zekâ temelli yardımcı teşhis araçları için radyoloji görüntüleme tekniklerine başvurulmaktadır. Akciğer X-ışını görüntüleri, Covid-19'u tespit etmenin olası yöntemlerinden biridir. Bu tez çalışmasında, Covid-19 tanısının olduğu iki farklı veriseti üzerinde önceden eğitilmiş derin öğrenme modelleri ile üç senaryo çerçevesinde deneysel çalışmalar gerçekleştirilmiştir. İlk veri seti iki sınıflı 1252 adet Covid-19 tanısı konmuş ve 1229 adet herhangi bir tanı konmamış bilgisayarlı tomografi görüntülerinden oluşmaktadır. İkinci veriseti, Covid-19, zatürre ve normal sınıfları içermekte olup her bir sınıfta 2313 X-ışını görüntüsü bulunmaktadır. İlk senaryodaki deneylerde orijinal önceden eğitilmiş derin öğrenme modelleri kullanılırken, ikinci senaryoda değiştirilmiş önceden eğitilmiş modeller kullanılmıştır. Son olarak, üçüncü senaryoda önceden eğitilmiş orijinal modellerden çıkarılan özellikler üzerinde geleneksel makine öğrenimi sınıflandırıcılarıyla deneyler yapıldı. Deneysel çalışmalarda, önceden eğitilmiş orijinal modellerin tam bağlı katmanlarında yapılan değişiklikler ile diğer senaryolara kıyasla daha yüksek doğruluklar elde edilmiş olup bu modeller içerisinde D_EfficientNetV2B0 iki sınıflı ve üç sınıflı verisetlerinde sırasıyla %98,99 ve %97,45 doğruluklar sunmuştur.

ANAHTAR KELİMELELER: Covid-19, yapay zekâ, derin öğrenme, öğrenme aktarımı, değiştirilmiş önceden eğitilmiş model

Nisan 2023, 64 Sayfa

ABSTRACT

MSC THESIS

COMPARISON OF THE PERFORMANCES OF DEEP LEARNING MODELS IN CLASSIFICATION OF COVID-19 DISEASE

PERVİN SÜRGÜÇOĞLU

KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE
DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
SUPERVISOR:ASSOC. PROF. DR. KEMAL AKYOL

The new coronavirus 2019 (Covid-2019), which first appeared in Wuhan, China in December 2019, spread rapidly in all countries and became a pandemic. It is very important to detect positive cases as early as possible in order to prevent the further spread of this epidemic, which has a devastating impact on both public health and the global economy in daily life, and to treat affected patients quickly. Radiology imaging techniques are used for artificial intelligence-based auxiliary diagnostic tools in the detection of Covid-19 disease. Lung X-ray images are one of the possible methods of detecting Covid-19. In this thesis, experimental studies were carried out within the framework of three scenarios with pre-trained deep learning models on two different datasets with Covid-19 diagnosis. The first dataset consists of two-classes computed tomography images of 1252 diagnosed with Covid-19 and 1229 undiagnosed. The second dataset includes Covid-19, pneumonia, and normal classes which have 2313 X-ray images in each class. In the first scenario, the original pre-trained deep learning models were used in the experiments, while in the second scenario, modified pre-trained models were used. Finally, experiments with traditional machine learning classifiers were conducted on the features extracted by original pre-trained models in the third scenario. In the experimental studies, higher accuracies were obtained with the changes made in the fully connected layers of the original pre-trained models compared to the other scenarios, and among these models, D_EfficientNetV2B0 provided 98,99% and 97,45% accuracies in two-class and three-class datasets, respectively.

KEYWORDS: Covid-19, artificial intelligence, deep learning, transfer learning, modified pre-trained model

April 2023, 64 Page

TEŞEKKÜR

Bu tez çalışmasında, bilgi ve tecrübeleri ile bana yol gösteren verdiği eğitim, yönlendirme ve pozitif yaklaşımıyla yardımlarını esirgemeyen danışmanım Doç. Dr. Kemal AKYOL'a teşekkürlerimi sunarım. Görüş ve bilgileriyle beni yönlendiren değerli hocalarım Doç. Dr. Salih GÖRGÜNOĞLU ve Doç. Dr. Abdulkadir KARACI'ya çok teşekkür ederim. Son olarak, eğitim hayatım boyunca her zaman bana destek olan hep benim yanımda olan kıymetli anneme ve babama teşekkürlerimi bir borç bilirim.

PERVİN SÜRGÜÇOĞLU

Kastamonu, 2023

İÇİNDEKİLER

	<u>Sayfa</u>
TEZ ONAYI	ii
TAAHHÜTNAME	iii
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ	xi
SİMGELER VE KISALTMALAR DİZİNİ	xii
1. GİRİŞ	1
1.1 Bulaşma Yöntemleri	2
1.2 Korunma Yöntemleri	2
1.3 Motivasyon	3
1.4 Katkı.....	3
2. LİTERATÜR ARAŞTIRMASI	4
3. YAPAY ZEKÂ	8
3.1 Makine Öğrenmesi.....	8
3.1.1 Denetimli Öğrenme.....	9
3.1.1.1 Destek vektör makineleri	10
3.1.1.2 Lojistik regresyon.....	10
3.1.1.3 K-En yakın komşu	11
3.1.1.4 Rastgele orman algoritması.....	12
3.1.2 Denetimsiz Öğrenme	12
3.1.3 Pekiştirmeli Öğrenme	12
3.2 Derin Öğrenme.....	13
3.2.1 Evrişimsel Sinir Ağları	14
3.2.2 Evrişim Katmanı	15
3.2.3 Aktivasyon Fonksiyonları.....	16
3.2.3.1 Rectified Linear Unit (ReLU)	16
3.2.3.2 Softmax	17
3.2.4 Havuzlama Katmanı	17
3.2.5 Toplu Normalleştirme Katmanı	18
3.2.6 Tam Bağlı Katman.....	19
3.2.7 Seyreltme Katmanı	19
3.3 Öğrenme Aktarımı ve Önceden Eğitilmiş Modeller	20
3.3.1 EfficientNetV2B0	20
3.3.2 MobileNetV2	21
3.3.3 ResNet.....	22
3.4 Performans Ölçümü	22
4. DENEYSEL ÇALIŞMALAR, ELDE EDİLEN SONUÇLAR VE TARTIŞMA	25
4.1 Deneysel Çalışma Ortamı	25
4.2 Deneysel Çalışmalar ve Önerilen Yaklaşım	25
4.3 Verisetleri.....	27

4.4	Model Eğitimi ve Testi	29
4.5	Deneysel Çalışma Senaryosu -1.....	32
4.5.1	Orijinal Önceden Eğitilmiş Modellerin İki Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar	32
4.5.2	Orijinal Önceden Eğitilmiş Modellerin Üç Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar	35
4.6	Deneysel Çalışma Senaryosu- 2.....	38
4.6.1	Değiştirilmiş Önceden Eğitilmiş Modellerin İki Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar	38
4.6.2	Değiştirilmiş Önceden Eğitilmiş Modellerin Üç Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar	41
4.7	Deneysel Çalışma Senaryosu- 3.....	44
4.7.1	Geleneksel Sınıflandırıcıların İki Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar.....	45
4.7.2	Geleneksel Sınıflandırıcıların Üç Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar.....	49
4.8	Elde Edilen Sonuçların Literatürdeki Çalışmalarla Karşılaştırılması.....	54
5.	SONUÇLAR VE ÖNERİLER.....	56
	KAYNAKLAR	57
	ÖZGEÇMİŞ.....	64

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1 Derin öğrenme, makine öğrenmesi ve yapay zekâ arasındaki ilişki.....	8
Şekil 3.2 Sınıflandırma ve regresyon	9
Şekil 3.3 Destek vektör makinesinin genel yapısı	10
Şekil 3.4 k-EYK algoritması	11
Şekil 3.5 Makine öğrenmesi ve derin öğrenme arasındaki farklılıklar	14
Şekil 3.6 Temel bir evrişimsel sinir ağı mimarisi	15
Şekil 3.7 Evrişimsel katman.....	16
Şekil 3.8 ReLU davranış fonksiyonu	17
Şekil 3.9 Havuzlama işlemleri	18
Şekil 3.10 Tam bağlı katman yapısı.....	19
Şekil 3.11 Normal sinir ağı (a) ve Seyreltme kullanılan sinir ağı (b)	20
Şekil 3.12 EfficientNet-B0 mimarisi.....	21
Şekil 3.13 MobileNetV2 mimarisi	21
Şekil 3.14 ResNet50 mimarisi	22
Şekil 3.15 Alıcı işlem karakteristiği eğrisi.....	24
Şekil 4.1 Önceden eğitilmiş orijinal modeller ile yapılan çalışmanın genel çerçevesi	26
Şekil 4.2 Değiştirilmiş önceden eğitilmiş modeller ile yapılan çalışmanın genel çerçevesi	27
Şekil 4.3 İki sınıflı veriseti: Covid-19 (a) ve hasta olmayanların (b) BT tarama görüntüleri	28
Şekil 4.4 Üç sınıflı veriseti: Covid-19, Normal ve Zatürre tanılı X-ışını görüntülerinden örnekler	29
Şekil 4.5 İki sınıflı verisetinde eğitim, doğrulama ve test kümeleri için ayrılan örnek sayıları	30
Şekil 4.6 Üç sınıflı verisetinde eğitim, doğrulama ve test kümeleri için ayrılan örnek sayıları	30
Şekil 4.7 Önceden eğitilmiş orijinal modellerin iki sınıflı veriseti üzerinde eğitimine ait doğruluk değerlerinin görselleştirilmesi	32
Şekil 4.8 İki sınıflı veriseti üzerinde orijinal önceden eğitilmiş modellerin karışıklık matrisleri	33
Şekil 4.9 İki sınıflı veriseti için orijinal önceden eğitilmiş modellerin AİK eğrileri	34
Şekil 4.10 Önceden eğitilmiş orijinal modellerin üç sınıflı veriseti üzerinde eğitimine ait doğruluk değerlerinin görselleştirilmesi	35
Şekil 4.11 Üç sınıflı veriseti üzerinde önceden eğitilmiş orijinal modellerin karışıklık matrisleri	36
Şekil 4.12 Üç sınıflı veriseti için orijinal önceden eğitilmiş modellerin AİK eğrileri	38
Şekil 4.13 Değiştirilmiş önceden eğitilmiş modellerin iki sınıflı veriseti üzerinde eğitimine ait doğruluk değerlerinin görselleştirilmesi.....	39
Şekil 4.14 İki sınıflı veriseti üzerinde değiştirilmiş önceden eğitilmiş modellerin karışıklık matrisleri	40

Şekil 4.15 İki sınıflı veriseti için değiştirilmiş önceden eğitilmiş modellerin AIK eğrileri	41
Şekil 4.16 Değiştirilmiş önceden eğitilmiş modellerin üç sınıflı veriseti üzerinde eğitimine ait doğruluk değerlerinin görselleştirilmesi.....	41
Şekil 4.17 Üç sınıflı veriseti üzerinde değiştirilmiş önceden eğitilmiş modellerin karışıklık matrisleri	43
Şekil 4.18 Üç sınıflı veriseti için değiştirilmiş önceden eğitilmiş modellerin AIK eğrileri	44
Şekil 4.19 İki sınıflı verisetinden orijinal ResNet50 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri	45
Şekil 4.20 İki sınıflı verisetinden orijinal ResNet50V2 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri	46
Şekil 4.21 İki sınıflı verisetinden orijinal MobileNetV2 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri	47
Şekil 4.22 İki sınıflı verisetinden orijinal EfficientNetV2B0 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri	48
Şekil 4.23 Üç sınıflı verisetinden orijinal ResNet50 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri	50
Şekil 4.24 Üç sınıflı verisetinden orijinal ResNet50V2 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri	51
Şekil 4.25 Üç sınıflı verisetinden orijinal MobileNetV2 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri	52
Şekil 4.26 Üç sınıflı verisetinden orijinal EfficientNetV2B0 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri.....	53

TABLolar DİZİNİ

	<u>Sayfa</u>
Tablo 3.1 Karışıklık matrisi	23
Tablo 4.1 Eklenen katmanların listesi.....	26
Tablo 4.2 İki sınıflı verisetindeki eğitim, doğrulama ve test kümelerindeki örnek sayıları	29
Tablo 4.3 Üç sınıflı verisetindeki eğitim, doğrulama ve test kümelerindeki örnek sayıları	30
Tablo 4.4 Derin öğrenme modellerinin eğitim parametreleri	31
Tablo 4.5 Orijinal önceden eğitilmiş modellerin iki sınıflı veriseti için performanslarının karşılaştırılması.....	34
Tablo 4.6 Orijinal önceden eğitilmiş modellerin üç sınıflı veriseti için performanslarının karşılaştırılması.....	37
Tablo 4.7 Değiştirilmiş önceden eğitilmiş modellerin iki sınıflı veriseti için performanslarının karşılaştırılması.....	40
Tablo 4.8 Değiştirilmiş önceden eğitilmiş modellerin üç sınıflı veriseti için performanslarının karşılaştırılması.....	43
Tablo 4.9 İki sınıflı verisetinde sınıflandırıcı algoritmaların sınıflandırma doğruluklarının karşılaştırılması	49
Tablo 4.10 Üç sınıflı verisetinde sınıflandırıcı algoritmaların ortalama sınıflandırma doğruluklarının karşılaştırılması	53
Tablo 4.11 İki ve üç sınıflı verisetleri üzerinde yapılmış çalışmalar	55

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

AİK	: Alıcı İşlem Karakteristiği
BT	: Bilgisayarlı Tomografi
COVID-19	: Yeni Koronavirüs Hastalığı
DSÖ	: Dünya Sağlık Örgütü
DVM	: Destek Vektör Makineleri
EAKA	: Eğri Altında Kalan Alan
ESA	: Evrişimli Sinir Ağları
GZ-PZR	: Gerçek Zamanlı Polimeraz Zincir Reaksiyonu
k-EYK	: K-En Yakın Komşu
LR	: Lojistik Regresyon
RO	: Rastgele Orman
SARS-CoV-2	: Şiddetli Akut Solunum Sendromu-Koronavirus-2

1. GİRİŞ

Covid-19, 31 Aralık 2019 yılının Çin'in Hubei eyaletinin Wuhan kentinde ortaya çıkan ve SARS-CoV-2 virüsünün neden olduğu ölüm de dahil olmak üzere hafif ile şiddetli solunum yolu hastalıklarına neden olan oldukça tehlikeli bir bulaşıcı hastalıktır. Çin'de ortaya çıkan bu virüs etrafa çok hızlı bir şekilde yayıldı ve birçok insanın hayatını olumsuz etkiledi. Covid-19, ev yaşamından iş yaşamına, eğitim alanından sosyal aktivitelerini gerçekleştirdikleri alanlara kadar birçok alanda insanları etkisi altına almıştır. Dünya Sağlık Örgütü (DSÖ) bu virüsün adını SARS-CoV-2 (Şiddetli Akut Solunum Sendromu-Koronavirus-2) olarak belirlemiş olup bu virüsün sebep olduğu hastalığı tanımlamak için Covid-19 terimini kullanmaktadır.

İnsanlarda farklı şekillerde etkilerini gösteren Covid-19 'un belli başlı belirtileri ateş, öksürük, baş ve boğaz ağrısı, halsizlik, kas ağrısı, tat veya kokuda kayıp, nefes darlığı, ishal, kırmızı veya tahriş olmuş gözlerdir (Singhal, 2020). Bu hastalığın teşhisi için uygulanan en yaygın test tekniği gerçek zamanlı polimeraz zincir reaksiyonudur (GZ-PZR, Reverse Transcriptase-Polymerase Chain Reaction, RT-PCR). Bilgisayarlı tomografi (BT) ve X-ışını gibi görüntüleme teknikleri, Covid-19 hastalığının erken teşhisinde ve tedavisinde çok önemli bir yer edinmiştir (Zu vd., 2020). %60-%70'lik düşük GZ-PZR duyarlılığı sebebiyle Covid-19 için negatif sonuçlar alınsa dahi radyolojik görüntüler incelenerek bu hastalığın semptomları saptanabilir (Kanne vd., 2020). BT bulguları semptomların başlamasından sonra uzun bir süre boyunca gözlenir ve hastalar genellikle ilk 2 gün içinde normal BT'ye sahip olur. Covid-19 hastalığına yakalanmış hastaların akciğer BT'si üzerine yapılan bir çalışmada semptomların başlamasından on gün sonra hastalığın gözlemlendiği bildirilmiştir (Pan vd., 2020).

Her geçen gün artan yeni vakalar, yoğun bakımda yatmakta olan hastalar ve ölümler bu yeni salgının tüm dünyayı ciddi bir şekilde tehdit ettiğinin önemli bir göstergesidir. Bu salgının yayılmasını kontrol altına alabilmek için hemen ve yüksek doğrulukta tarama yapabilen bir teknolojik aracın olması alan uzmanları için oldukça faydalı olacaktır. Covid-19 hastalığını önleyici en iyi tedbirler arasında aşı olmak, bulaşmanın

yüksek olduğu kalabalık ortamlarda maske takmak, insanlarla belli bir mesafeden iletişim kurmak, sık sık el yıkamak ve hasta insanlardan kaçınmak yer almaktadır (Koronavirüs, 2020).

1.1 Bulaşma Yöntemleri

İnsanlar arasında çok hızlı şekilde yayılabilen bir virüs olan Covid-19 birçok insana bulaşmıştır. Covid-19 esas olarak insanların birbirleriyle yakın temas halindeyken örneğin biriyle konuşma mesafesindeyken virüsün yayıldığını göstermektedir. Virüs; kişinin burnundan, ağzından, hapşırırken, konuşurken, şarkı söylerken veya kişi nefes alırken küçük tükürükler ya da sıvı parçacıkları halinde yayılabilmektedir. Bunun dışında bir kişi havadaki virüsü solunduğunda da bulaşabilir. Bu virüs ayrıca, iyi havalandırılmayan kalabalık mekânlarda veya insanların uzun zaman geçirdikleri yerlerde de yayılabilir. Bunun nedeni aerosollerin havada asılı kalabilmesidir. Dahası, virüs bulaşmış yüzeylere veya nesnelere dokunulması ve ardından göz, burun veya ağza temasta bulunulması da bu hastalığa yakalanma nedeni olabilir (World Health Organization, 2021).

1.2 Korunma Yöntemleri

Covid-19 virüsünden korunmak için sağlıklı bireylerin halka açık alanlara çıktıkları zaman ağızlarını maske ile kapatmaları gerekmektedir. Alerjik durumlarda öksürük hapşırma gibi durumlarda kalabalık ortamlara girdiklerinde maske takmaları çok önemlidir. El temizliğine dikkat etmek sık sık ellerin yıkanması ve özellikle ellerin yıkanmadığı durumlarda ağız, burun, göz ile temastan kaçınılması gerekmektedir. Hasta olan insanlarla temastan mümkün olduğunca kaçınılmalıdır. Kalabalık ortamlarda mümkün olduğunca belli bir mesafeden iletişim kurulması çok önemlidir. Bu hastalıktan korunmadaki amaç yeni olgu ve ölümlerin önüne geçmek ve bu sayede virüsün yayılmasını önleyerek kontrol altına almaktır. Korunma önlemlerine uyulmadığında çok fazla sayıda insana bu virüs hızlı ve kolay bir şekilde bulaşır. Dahası, bu hastalığı kontrol altına almak çok güç olabilir ve sınırlı sayıdaki sağlık çalışanları ve kurumlar zor durumda kalabilirler (Batirel, 2020).

1.3 Motivasyon

Covid-19 virüsünün etkilerini azaltmak için erken tanı çok önemlidir. Bu çerçevede Covid-19 salgının ortaya çıkmasından bu yana birçok derin öğrenme tabanlı çalışmanın yapıldığı görülmektedir. Covid-19 hastalığının ülkemizdeki etkilerinin gün geçtikçe artmasıyla birlikte BT ve X-ışını görüntülerinin kullanıldığı derin öğrenme tabanlı modeller diğer tanı yöntemlerinden daha hızlı ve daha az maliyetlidir. Bu çerçevede, bu tez çalışmasında BT ve X-ışını görüntülerinden Covid-19 hastalığının tespitini yüksek başarıyla gerçekleştiren derin öğrenme modellerinin tasarımı motivasyonu ile deneysel çalışmalar gerçekleştirilmiştir.

1.4 Katkı

Covid-19 hastalığının erken tespiti ve bu sayede zamanında tedavi ile bu hastalığın ilerlemesini önlemek çok önemlidir. Covid-19 virüsünün hızlı bir şekilde tespit edilmesi hasta vaka sayılarını ve ölümleri azaltacaktır. Bu çalışmanın temel katkısı bu hastalığın tespitinde yüksek başarı sunan derin öğrenme temelli özgün bir modeli tasarlamaktır. Bu çerçevede, önceden eğitilmiş derin öğrenme modellerinin tam bağlı katmanlarına yapılan eklemeler ile iki farklı veri seti üzerinde performans incelemeleri yapılmış ve karşılaştırmalı olarak analiz edilmiştir. Bu tez çalışmasının başlıca katkıları şu şekildedir:

1. Bu çalışma, Covid-19 hastalığının tespiti için hem X-ışını hem de BT görüntüleri üzerinde değiştirilmiş önceden eğitilmiş modellerin katkısını göstermek için kapsamlı bir deneysel çalışma çerçevesi sunar.
2. Önceden eğitilmiş derin öğrenme modelleri ile görüntülerden çıkartılan derin özellikler üzerinde birçok çalışmada kullanılmakta olan geleneksel sınıflandırıcılar ile makine öğrenimi deneyimi gerçekleştirir.
3. Orijinal önceden eğitilmiş modellerin tam bağlı katmanlarına yapılan eklemeler ile tanı başarısını iyileştirdiğini çeşitli model metriklerine dayalı olarak gösterir.

2. LİTERATÜR ARAŞTIRMASI

Tüm dünyayı etkileyen Covid-19 hastalığının tespiti üzerine bu alanda birçok çalışma yapılmış olup her geçen gün bu çalışmalar daha da artmaktadır.

İsmael ve Şengür, Covid-19 ve normal göğüs röntgeni görüntülerini sınıflandırmak için ResNet50, ResNet18, ResNet101, VGG16 ve VGG19 gibi önceden eğitilmiş modelleri kullanmışlardır. Çalışmalarında 180 Covid-19 ve 200 normal akciğer röntgeni görüntülerini kullanmışlar ve ResNet50 modeli ile %92,6 doğruluk elde etmişlerdir. Ayrıca, bu derin öğrenme modelleri ile çıkarttıkları özellikler üzerinde Destek Vektör Makineleri (DVM) sınıflandırıcısı ile %94,7 doğruluk elde etmişlerdir (Ismael ve Şengür, 2021).

Hemdan vd., Covid-19 hastalığı tespiti için 25 adet Covid-19 ve 50 adet normal X-ray görüntüsünden oluşan iki sınıflı bir veri seti üzerinde derin öğrenme modelleri ile çalışmışlar ve yedi evrimsel sinir ağı modelinden oluşan bir CovidX-Net modeli önermişlerdir. VGG-19 ve DenseNet-201 gibi yedi farklı derin evrimsel sinir ağı modelini uygulamışlardır. Deneysel çalışma sonucunda VGG-19 modelinde en yüksek %91 oranı başarı elde etmişlerdir (Hemdan vd., 2020).

Zheng vd., Covid-19 hastalığının tespiti için 630 adet üç boyutlu bilgisayarlı tomografi görüntülerini içeren iki sınıflı bir veri seti üzerinde %90,08 doğruluk sunan üç boyutlu derin evrimsel sinir ağı DeCoVNet modelini önermişlerdir (Zheng vd., 2020).

Shah vd., Covid-19 ve Covid-19 olmayan akciğer görüntülerini ayırt etmek için farklı derin öğrenme modelleriyle çalışmışlar ve kendi geliştirdikleri CTnet-10 adını verdikleri model ile %82,10 doğruluk elde etmişlerdir (Shah vd., 2021).

Serte ve Demirel, Covid-19 ve normal BT görüntülerini sınıflandırmak için üç boyutlu BT taramasının her BT görüntüsünde Resnet-18 ve Resnet-50 derin öğrenme modelleri tasarlamışlar ve %96 ve %98 doğruluklar elde etmişlerdir (Serte ve Demirel, 2021).

Yang vd., Covid-19 hastalığı olan bireyler ile sağlıklı bireyleri ayırt etmek için kullandıkları DenseNet derin öğrenme modeli ile %98 doğruluk elde etmişlerdir (Yang vd., 2020).

Jaiswal vd., Covid-19 pozitif ve Covid-19 negatif sınıflandırması yapabilmek için iki sınıflı bir veriseti üzerinde eğittikleri bir derin öğrenme modeli ile %97 doğruluk elde etmişlerdir (Jaiswal vd., 2021).

Ahamed vd., Covid-19 hastalığının tespiti için iki sınıflı, üç sınıflı ve dört sınıflı verisetleri üzerinde deneysel çalışmalar yapmışlardır. Yazarlar, ResNet50V2 modeli ile iki sınıflı verisetinde %98,95 doğruluk, üç sınıflı verisetinde %97,27 doğruluk ve dört sınıflı verisetinde %96,45 doğruluk elde etmişlerdir (Ahamed vd., 2021).

Apostolopoulos vd., önceden eğitilmiş derin öğrenme VGG19, MobileNetV2, Xception ve Inception modelleri ile deneysel çalışmalar yapmışlardır. Yazarlar çalışmalarında 224 adet Covid-19, 504 adet normal ve 700 adet zatürre görüntüsü olmak üzere üç sınıf içeren veriseti kullanmışlar ve MobileNetV2 modeli ile %99,18 doğruluk elde etmişlerdir (Apostolopoulos vd., 2020).

Albahli vd., Covid-19 hastalığının tespiti için 6057 zatürre, 590 Covid-19 ve 881 sağlıklı akciğer X-ışını görüntülerini içeren bir veriseti oluşturmuşlardır. Yazarlar, derin öğrenme aktarımına dayalı olarak DenseNet, InceptionV3 ve Inception-ResNeV4 modellerini kullanmışlar ve bu modeller ile sırasıyla %92; %83,47 ve %85,57 sınıflandırma doğruluğu elde etmişlerdir (Albahli vd., 2021).

Foto, Covid-19 hastalığını tespiti için üç sınıflı veriseti üzerinde segmentasyon gerçekleştirdikten sonra öğrenme aktarımına dayalı olarak VGG-16, ResNet50, DenseNet-121 ve InceptionV3 gibi modelleri ile deneysel çalışmalar yapmıştır. Yazar, çalışmasında %96,7 doğruluk oranı ile en yüksek başarıyı VGG-16 modelinin sunduğunu bildirmiştir (Foto, 2022).

Luz vd., Covid-19, normal ve zatürre olmak üzere farklı çözünürlüklerdeki X-ışını görüntüleri içeren üç sınıflı bir veriseti üzerinde EfficientNet modelini kullanarak %93,9 doğruluk elde ettiklerini bildirmişlerdir (Luz vd., 2021).

İbrahim, çalışmasında göğüs röntgenlerinden Covid-19, zatürre ve akciğer kanseri tespiti için VGG19-ESA, ResNet152v2, ResNet152V2+Geçitli Tekrarlayan Birim ve ResNet152V2+ Çift Yönlü GRU olmak üzere dört mimarinin performansını ele almıştır. Yazar, deneysel çalışmalar çerçevesinde VGG19-ESA modelinin diğerlerinden daha iyi performans gösterdiğini rapor etmiştir (İbrahim vd., 2021).

Rahimzadeh ve Attar, 180 Covid-19 ve 6054 zatürre tanısı konmuş hastaların görüntüleri ve tanı konulmamış kontrol grubundaki 8851 insanın görüntüsünü içeren iki açık kaynak veriseti üzerinde Xception ve ResNet50V2 adlı iki önceden eğitilmiş derin öğrenme modelini birleştirmişlerdir. Xception ve ResNet50V2 birleştirilmiş derin sinir ağı ile %91,4 doğruluk oranı elde etmişlerdir (Rahimzadeh ve Attar, 2020).

Narin vd., Covid-19, viral zatürre, bakteriyel zatürre tanısı konmuş ve ayrıca normal bireylerden oluşan bir veriseti üzerinde ResNet50 modeli ile %99,7 doğruluk elde etmişlerdir (Narin vd., 2020).

Nour vd., Covid-19 hastalığının tespiti için X-ışını görüntülerinden özellik çıkartmak için yeni bir Evrişimsel Sinir Ağı (ESA) modeli tasarlamışlardır. Çıkarttıkları özellikler üzerinde k-en yakın komşu, karar ağacı ve destek vektör makinaları ile sınıflandırma gerçekleştirmişlerdir. Bu sınıflandırıcıların parametrelerini Bayes optimizasyon algoritması ile optimize etmişler ve DVM ile %98,97 sınıflandırma başarısı elde etmişlerdir (Nour vd., 2020).

Pathak vd., BT görüntülerinden Covid-19 enfekte olmuş insanların tespiti için derin öğrenme aktarımına dayalı yaptıkları çalışmada ResNet50 mimarisi ile %93,01 doğruluk elde etmişlerdir (Pathak vd., 2020).

Song vd., Covid-19 hastalığını tespit etmek için derin öğrenmeye dayalı bir BT tanı sistemi geliştirmişlerdir. VGG16, DenseNet, ResNet ile DRE-Net adını verdikleri ResNet50 temelli yeni bir mimari önermişlerdir. Yazarlar çalışmalarında önerdikleri modelin %86 doğruluk oranı sunduğunu bildirmişlerdir (Song vd., 2021).

Özyurt vd., BT görüntülerinden Covid-19 hastalığını tespit etmek için önerdikleri çalışmalarında yapay sinir ağı ve derin sinir ağı modelleri sırasıyla %94,10 ve %95,84 sınıflandırma doğruluk oranına ulaşmışlardır (Özyurt vd., 2021).



3. YAPAY ZEKÂ

McCarty, yapay zekâ terimini zeki makineler özellikle de zeki bilgisayar programları yapma bilimi ve mühendisliği olarak tanımlamıştır. Bir bilgisayar sisteminin insan zekasına özgü özelliklerini sergilemesi yapay zekâ olarak tanımlanabilir. Yapay zekâ akıllı davranış sergilemeye dayalı bir davranıştır. İnsanın daha kolay bir yaşam sürmesine yardımcı olacak değerli bilgiler sunmak ve bu doğrultuda teknolojik araçlar üretmektir. Yapay zekâ, insanların yaptıklarını her geçen gün daha verimli, daha hızlı ve daha düşük bir maliyetle yapmaktadır. Sağlık alanında yapay zekâ uygulamaları, süreçlerde maliyetlerin azaltılması, kalitenin artırılması, insan kaynaklı hataların azaltılması ve performansın artırılması amacıyla kullanılmaktadır (Akalin ve Veranyurt, 2021). Şekil 3.1, derin öğrenme, makine öğrenmesi ve yapay zekâ arasındaki ilişkiyi sunar.



Şekil 3.1 Derin öğrenme, makine öğrenmesi ve yapay zekâ arasındaki ilişki

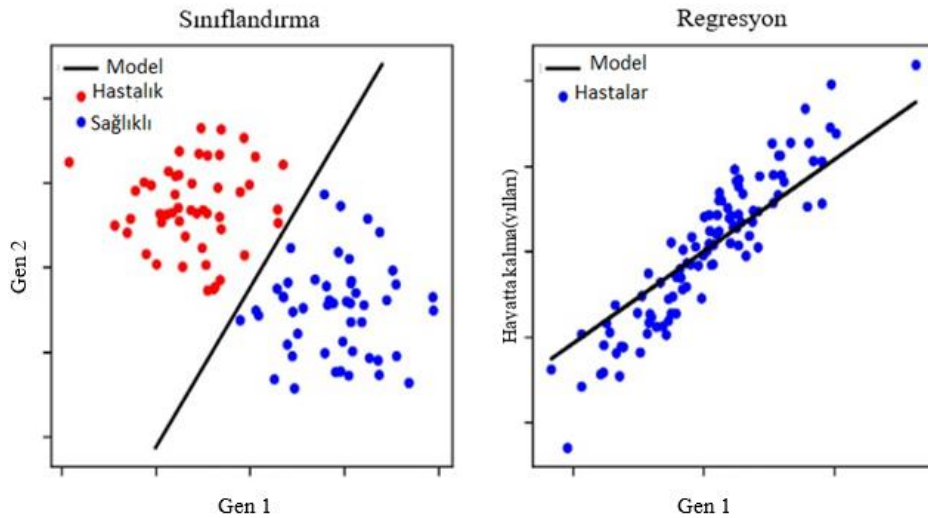
3.1 Makine Öğrenmesi

Makine öğrenmesi, tasarlanan modeller ile veri analitiği, örüntü tanıma ve tahmin sistemi sunan bir yaklaşımdır. Ayrıca gizli olan örüntüleri keşfetmeye yardımcı olur (Ahuja ve Angra, 2017). Makine öğrenmesi ile verilerden istatistiksel çıkarımlar veya tahminler yapılabilir. Makine öğrenmesi ile geçmiş bilgilere dayalı olarak çıkarımlar yapılabilir ve sağlık çalışanları ve araştırmacıların oldukça çok yararlandığı çalışma alanıdır (Dua ve Bais, 2014). Veriler üzerinde tahmin, doğal dil işleme, el yazısı tanıma, konuşma tanıma, yüz tanıma, tıbbi teşhis tahmini, hava tahmini gibi problemlere makine öğrenmesi yaklaşımları uygulanabilmektedir (Nacar ve Erdebilli,

2021). Makine öğrenmesi yaklaşımları denetimli, denetimsiz ve pekiştirmeli öğrenme olmak üzere üç başlıkta incelenebilir.

3.1.1 Denetimli Öğrenme


Denetimli öğrenme yaklaşımında amaç, girdi verileri için tahminde bulunabilmemizi sağlayan etiketli eğitim verilerinden öğrenmeye dayalı bir model tasarlamaktır (Raschka, 2015). Denetimli öğrenme, sisteme eğitim veriseti ve test verisetinin yüklenmesi, verisetinde her bir veri için gerekli etiketlenmenin yapılması ve bu sayede girdi veriseti ile çıktı arasında ilişki kurulması mantığına dayanır. Sonuçları bilinen bir veriseti üzerinde gerçekleştirilen eğitim ile sonuçları bilinmeyen verisetine yönelik tahminler yapabilmektir (Aydın ve Özkul, 2015). Diğer bir deyişle, etiketlenen eğitim verilerine dayalı olarak hangi girdinin hangi çıktı ile eşleşeceğinin öğrenilmesi ve sonrasında hiç görmediği bir veri üzerinde doğru tahminler sunan bir öğrenme şeklidir. Denetimli öğrenme konuları regresyon ve sınıflandırma olarak iki alt grupta incelenmektedir. Regresyon, nicel değişkenlerin tahmin ve kestirimi için kullanılan bir denetimli öğrenmedir. Sınıflandırma ise nitel değişkenlerin modellenmesi ve tahmin edilmesi için kullanılan denetimli öğrenme yaklaşımıdır. Şekil 3.2’de sınıflandırma ve regresyon görselleri sunulmuştur.



Şekil 3.2 Sınıflandırma ve regresyon (URL-1, 2017)

3.1.1.1 Destek vektör makineleri

Vapnik tarafından geliştirilen Destek Vektör Makineleri (DVM) algoritmasında farklı sınıflardaki verileri birbirinden ayırmak için en uygun karar sınırları ya da hiper düzlemler tespit edilir. Bu algoritma, istatistiksel öğrenme içerisinde yer alan yapısal risk azaltma prensibine sahip genelleme yeteneği çok iyi olan bir sınıflandırıcıdır (Widodo ve Yang, 2007). DVM hem regresyon hem de sınıflandırma için kullanılan denetimli makine öğrenimi algoritmasıdır. DVM'nin probleme göre parametrelerinin ve çekirdek fonksiyonlarının değiştirilebilmesi avantajlarından biridir. DVM özellikle çok sınıflı sınıflandırıcı uygulamalarında kendini kanıtlamış bir yöntemdir ve çok büyük boyutlu az sayıda veri içeren veri kümelerinde de başarılıdır. Bu algoritma, metin sınıflandırma, görüntü sınıflandırma ve biyoinformatik alanlarında kullanılmaktadır (Joachims, 1999). DVM genel yapısı Şekil 3.3'te gösterilmiştir.



Şekil 3.3 Destek vektör makinesinin genel yapısı (Sevli, 2019)

3.1.1.2 Lojistik regresyon


Lojistik Regresyon (LR), sonucu belirleyen bir veya daha fazla bağımsız değişken bulunan veri kümesini incelemek için kullanılan istatistiksel bir yöntemdir (Bulut ve Yörük, 2017). LR, ikili değişken (0-1, var-yok, evet-hayır) durumlarında odds oranına dayalı olarak sonucun olasılığını tahmin eder. Denklem 3.1'de verildiği üzere odds değeri, P incelenen olayın olasılığı olmak üzere, incelenen bir olayın olasılığının diğer olayların olasılığına oranı Odds değerini verir (Hosmer ve Lemeshow, 2000).

$$Odds = p/(1 - p) \quad (3.1)$$

Tahmin, bir ya da daha fazla sayısal ve kategorik değer kullanımına dayanır. Genellikle tıp alanındaki problemler için LR modellerindeki bağımsız değişkenler hastalığın olup olmadığını belirleyen faktörlerdir. Bu çerçevede, hastalığa neden olan faktörlerle mücadelede LR önemli bir rol almaktadır (Başer vd., 2021).

3.1.1.3 K-En yakın komşu

K-En Yakın Komşu (k-EYK) algoritması, sınıflandırma ve regresyon için kullanılan istatistiksel denetimli öğrenme tekniğidir. Şekil 3.4, k-EYK algoritmasını temsilen sunar. Bu algoritmanın optimum sonuç üretmesi için en uygun uzaklık matrisinin hesaplanmasına ve optimal sınıflandırmayı sağlayacak komşu sayısına (k hiper parametresine) ihtiyaç vardır. Örneğin w_1 , w_2 ve w_3 olmak üzere üç tane sınıf olduğu varsayılın ve sınıfı bilinmeyen bir x_u örneğinin sınıflandırılmasında $k=5$ değeri için en yakın 5 komşu incelendiğinde 4 tane komşunun w_1 sınıfında olduğu, 1 komşunun ise w_3 sınıfında olduğu görülmektedir. Bu durumda, baskın olan sınıf w_1 olduğu için x_u örneği bu sınıfa dahil olur.



Şekil 3.4 k-EYK algoritması (Çavuşoğlu ve Kaçar, 2019)

3.1.1.4 Rastgele orman algoritması

2001 yılında Breiman tarafından önerilen Rastgele Orman (RO) algoritması, karar ağacı sınıflandırıcı temelli bir topluluk sınıflandırıcı algoritmadır. RO algoritması, tüm değişkenler arasından en iyi dalı kullanarak her bir düğümü dallara ayırmak yerine her bir düğümde rastgele olarak seçilen değişkenler arasından en iyisini kullanarak her bir düğümü dallara ayırır. Her bir veriseti orijinal verisetinden yer değiştirmeli olarak üretilir. Sonra rastgele özellik seçimi kullanılarak ağaçlar geliştirilir (Breiman, 2001). Bu algoritma, yüksek sınıflandırma doğruluğuna sahiptir, aykırı değerleri ve gürültüyü çok iyi tolere eder (Liu vd., 2012). RO algoritması, hem regresyon hem de sınıflandırma görevlerini yüksek doğrulukla gerçekleştirebildiğinden veri bilimcileri tarafından tercih edilen bir yöntemdir. Büyük verisetleri ile verimli bir şekilde çalışan RO algoritması hızlıdır, aşırı uyuma dayanıklıdır ve belirlenen sayıda ağaç ile çalışabilme özellikleri bulunmaktadır (Breiman, 2001).

3.1.2 Denetimsiz Öğrenme

Denetimsiz öğrenme sınıflandırılmamış ve etiketi olmayan veriler üzerinde öğrenme yaklaşımıdır. Diğer bir deyişle, kendi kendine öğrenmenin gerçekleştiği denetimsiz öğrenme yönteminde sadece girdi verileri bulunur, bu verilere dayalı öğrenme gerçekleştirilir ve çıktı verileri keşfedilir. Amaç, verilerdeki gizli örüntülerin keşfedilmesidir. Kümeleme olarak da bilinen bu öğrenme yaklaşımında veriler ayrılırken benzerlik derecesine göre gruplandırma yapılır (Şapcı ve Pektaş, 2021).

3.1.3 Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, hedefe ulaşabilmek için ne yapılması gerektiğini öğrenen bir yaklaşımdır. Bir etmenin deneme yanılma yoluyla bilinmeyen öğrenmesi yöntemidir. Etmen, pekiştirmeli öğrenmede karşılaşılan durumlara gösterdiği tepkilerin sonucunda ödül alır ve bu ödülü en yüksek değere ulaştırmaya çalışır (Mnih vd., 2015).

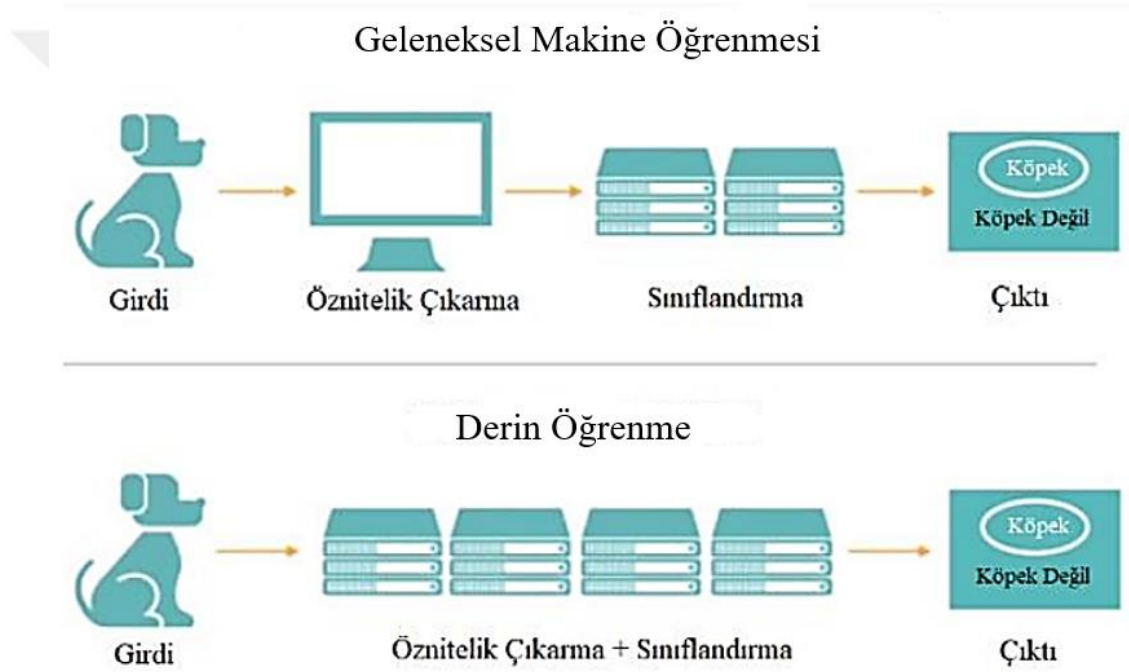
3.2 Derin Öğrenme

Yapay sinir ağlarından daha da karmaşık bir yapı içeren derin öğrenme mimarileri doğrusal olmayan problemlere birden çok katman kullanarak çözümler sunan ve makineler tarafından dünyayı algılamak ve anlamak için kullanılan bir yöntemdir. Derin öğrenme, genellikle görüntüleri sınıflandırmada video analizlerinde ve doğal dil öğrenme gibi alanlarda kullanılmaktadır (İnik ve Ülker, 2017). Derin öğrenme, insan beyninin veri işleme ve karar vermede kullanılmak üzere kalıplar oluşturma konusundaki çalışmalarını taklit eden bir yapay zekâ işlevidir. Derin sinirsel öğrenme veya derin sinir ağı olarak bilinir (Salman vd., 2020).

Derin öğrenme yöntemleri kullanılarak önceden oluşturulmuş bir matematiksel modele dayalı öznitelik çıkarıcıya ihtiyaç duymadan analiz ve genelleme yapılabilmektedir. Derin öğrenme genellikle yapay sinir ağları üzerinde geliştirilir ve katmanlarından yararlanır ve bir sonraki katman bir önceki katmanın çıktısını girdi olarak alır (İnik ve Ülker, 2017). Derin öğrenme, tıbbi görüntülerde kalıpları doğru bir şekilde analiz ederek, tanımlayarak ve sınıflandırarak otomatik hastalık teşhisi ve yönetiminde çığır açmıştır. Bu başarının nedeni, derin öğrenme tekniklerinin el yapımı özelliklere dayanmaması diğer bir deyişle bu modellerin özellikleri veriden otomatik olarak çıkartmasıdır (Shen vd., 2017).

Tıp alanında klinisyenler için yardımcı bir araç olan otomatik tanı sistemlerinde makine öğrenimi yöntemlerinin uygulanması son zamanlarda popülerlik kazanmıştır (Litjens vd., 2017). Yapay zekânın oldukça ilgi gören bir araştırma alanı olan derin öğrenme, beklenen sonuçlara ulaşmak için manuel özellik çıkarımına gerek kalmadan girdi verilerini kullanarak uçtan uca modellerin oluşturulmasını sağlar (Krizhevsky vd., 2017). Derin öğrenme teknikleri, cilt kanseri sınıflandırması, beyin hastalığı sınıflandırması, zatürre tespiti, retinal fundus görüntü segmentasyonu ve akciğer segmentasyonu gibi birçok çalışmada başarıyla uygulanmıştır. Covid-19 salgınının hızlı yükselişi bu alandaki uzmanlık ihtiyacını ortaya çıkartmasının yanı sıra yapay zekâ tekniklerine dayalı otomatik algılama sistemlerine olan ilgiyi artırmıştır.

Makine öğrenmesinde eğitim daha hızlıyken, derin öğrenme yoğun hesaplamalara ihtiyaç duyar. Derin öğrenme, makine öğrenmesi yönteminin daha gelişmiş şeklidir. Şekil 3.5’de derin öğrenme ve makine öğrenmesi süreçleri sunulmuştur. Derin öğrenme, derin sinir ağlarını ifade eden bir makine öğrenmesi yöntemidir. Temel farkı veri içerisinden kendi kendine öğrenerek yeni özellikler oluşturmaktır. Geleneksel makine öğrenmesinde girdi görüntüsünü temsil edecek olan özellikler el yapımı tekniklere başvurulurken, derin öğrenme mimarilerinde bu özellikler veya özellik haritaları mimarideki katmanlardan otomatik olarak çıkarılır (Şeker vd., 2017).

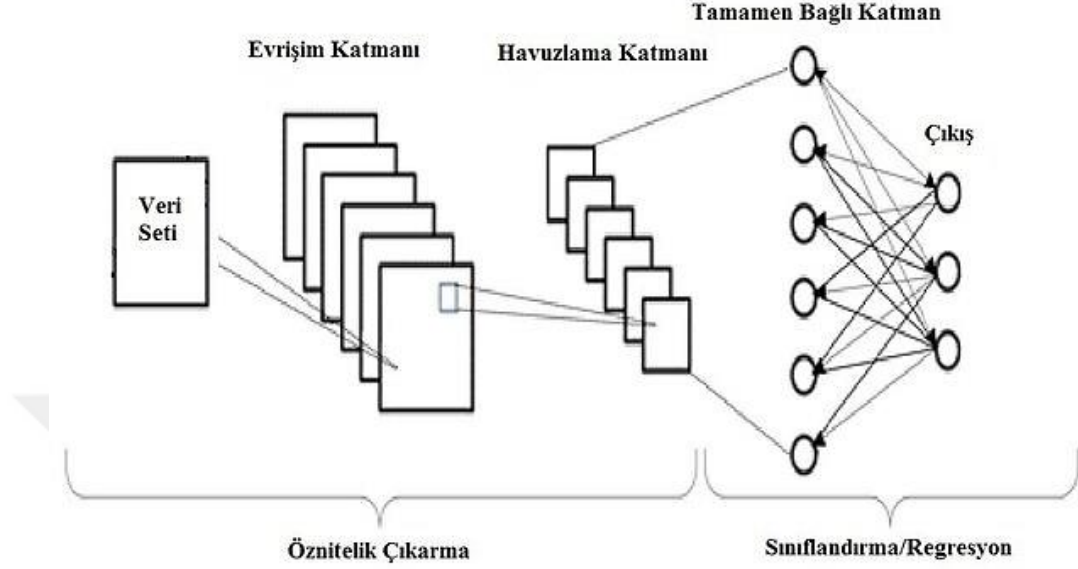


Şekil 3.5 Makine öğrenmesi ve derin öğrenme arasındaki farklılıklar (Erhandı, 2020)

3.2.1 Evrişimsel Sinir Ağları

Evrişimsel sinir ağları, görüntüleri sınıflandırmak, analiz etmek ve tıbbi görüntüler üzerinden tespitler yapmak için sundukları yüksek performansları nedeniyle en çok tercih edilen bir derin öğrenme modelidir. Derin evrişimsel sinir ağları, giriş görüntülerinden düşük seviye ve yüksek seviye özellikleri otomatik olarak çıkarabilir (Alzubaidi vd., 2020). Görüntülerden özellikleri çıkarabilmek için ESA mimarilerinde, çok fazla evrişimsel katman, havuzlama katmanı, tam bağlı katman, aktivasyon katmanı, sınıflandırıcı katman gibi ek katmanlarda bulunur. Şekil 3.6,

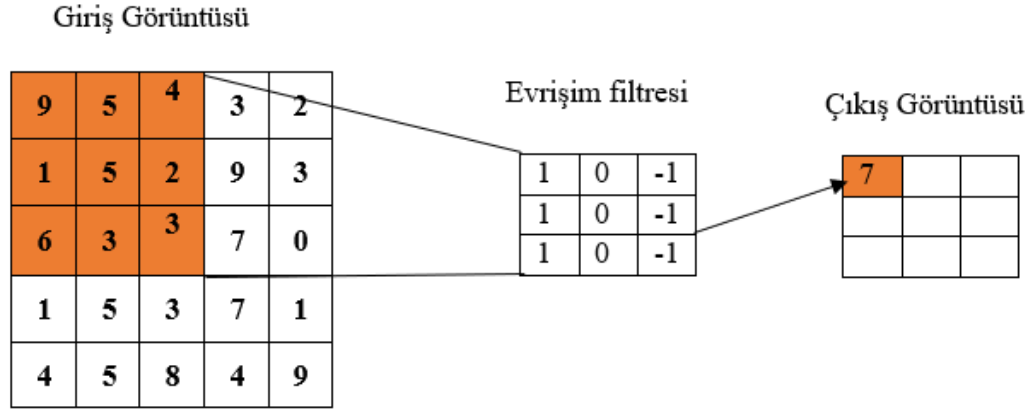
temel bir evrişimsel sinir ağı mimarisini sunar. Sonraki bölümler, bu tez çalışmasında kullanılan katmanlar hakkında bilgiler sunar.



Şekil 3.6 Temel bir evrişimsel sinir ağı mimarisini (Talu ve Nimet, 2022)

3.2.2 Evrişim Katmanı

Evrişim katmanı, görüntülerin özniteliklerinin ortaya çıkartıldığı temel bir evrişimsel sinir ağı katmanıdır. Bir evrişimsel sinir ağının temel yapı taşı olan evrişim katmanı yapay sinir ağlarında bulunmayan bir katmandır. Sayısal görüntüler piksel matrisleri biçimindedir. Evrişimsel sinir ağlarında bir görüntünün piksel matrisinden özellikler bu evrişim işlemlerinin yapıldığı katmanlar ile çıkarılmaktadır. Evrişim işlemi görüntü üzerinde bir filtrenin gezdirilmesi ile gerçekleşmektedir. Ağın her bir eğitim turu sonunda bu filtrelerin üzerindeki ağırlık değerleri güncellenir ve filtrelerde öğrenme işlemi gerçekleşir. Filtreleme işlemi bir görüntünün sol üst kısmından başlayıp filtrenin sağa kaydırılması suretiyle gerçekleşir. Filtre uygulamada ağırlık matrisi ile girdi matrisinin filtre ile örtüşen kısmındaki değerler birbirleriyle çarpılır. İlk satır işlemi bittikten sonra ikinciye geçilir ve bu işlemler tekrar edilir. Tüm işlemler yapıldıktan sonra çıktı matrisi oluşturulur. Yapılan bu işlemle görüntüyü temsil eden özellikler belirlenmiş olur. Görüntü tek bir özellikten oluşmadığından dolayı görüntüde birden fazla filtre uygulanması gerekebilir bundan dolayı da evrişimsel sinir ağı algoritmalarında çok sayıda evrişimli katman bulunur (İnik ve Ülker, 2017). Şekil 3.7'de evrişim filtresinin uygulanması ile elde edilen yeni değer gösterilmektedir.



Şekil 3.7 Evrişimsel katman (Türkoğlu vd., 2021)

3.2.3 Aktivasyon Fonksiyonları


Aktivasyon fonksiyonu, yapay sinir hücresinin girdi verilerine dayalı elde edilen sonuç değeri bir işlemde geçirerek buna karşılık gelen net çıktı sonuçlarını elde eder. Aktivasyon için genellikle doğrusal olmayan fonksiyonlar kullanılır (Öztürk ve Şahin, 2018). Her bir nörondaki girdiler nöronlardaki ağırlıklarla çarpılır ve elde edilen sonuçlar toplanır. Daha sonra bu değer, yapay sinir ağlarında bir nöronun önemli bir bileşeni olan aktivasyon fonksiyonu kullanılarak doğrusal olmayan bir değere dönüştürülür (Jang vd., 2020; Kayhan, 2022).

3.2.3.1 Rectified Linear Unit (ReLU)

Denklem 3.2’de eşitliği verilen ReLU, güçlü biyolojik ve matematiksel temeli olan bir aktivasyon fonksiyonudur. Derin sinir ağlarının eğitiminde değerleri 0’da eşikleyerek çalışır. Burada, $x < 0$ olduğunda 0 verir ve $x \geq 0$ olduğunda doğrusal bir fonksiyon verir (Agarap, 2018).

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

Bu fonksiyon, ağda bulunan tüm nöronları aynı anda aktive etmemesi özelliğine sahiptir ve bu özelliği nedeniyle ara katmanlarda sıkça yer almaktadır. ReLU aktivasyon fonksiyonu sayesinde bir hücre negatif değer üretirse o hücre aktive edilmeyecektir (Doğan ve Türkoğlu, 2018). Şekil 3.8, ReLU fonksiyonunun işlevinin grafiksel gösterimini sunar.



Şekil 3.8 ReLU davranış fonksiyonu (Agarap, 2018)

3.2.3.2 Softmax

Softmax aktivasyon fonksiyonu, girdi verilerinin her bir sınıfa ait olma derecesini gösteren çıktılar üretir ve sınıflandırma problemlerinde sıklıkla kullanılır. Bu çıktılar 0 ve 1 arasında yer alır ve 1'e en yakın olan değer ağırlık tahminidir (Dağlı ve Öztürk, 2021). Çoklu sınıflandırma problemlerinde kullanılan Softmax aktivasyon fonksiyonu, sinir ağının ham çıktılarının bir vektörünü alır ve bir olasılık puanları vektörü döndürür. Esasen girdi sınıfları üzerinde bir olasılık dağılımına dönüştürür. N sınıflı çok sınıflı bir sınıflandırma probleminde, i sınıfına ait belirli bir girdiye karşılık gelen olasılık değeri ve diğer sınıflarında olasılık değerlerinin olduğu N giriş uzunluğunda bir çıktı vektörü döndürür (URL-2, 2022). Denklem 3.3'te Softmax fonksiyonu eşitliği verilmiştir.

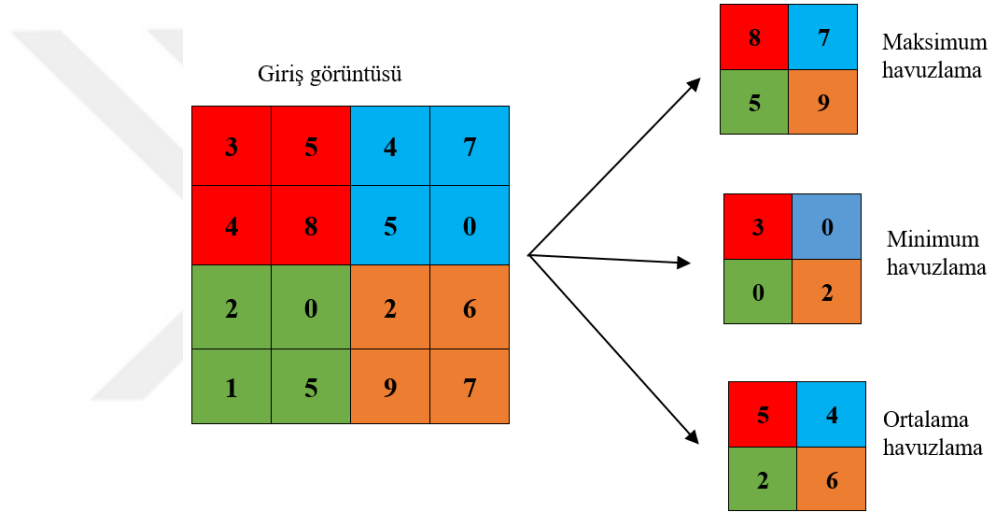
$$\text{softmax}(z)_i = \frac{e^{z_i}}{\sum_{j=1}^N e^{z_j}} \quad (3.3)$$

Burada z, sinir ağının ham çıktılarının vektörüdür. e, 2,718'in değerini ifade eder. Softmax çıkış vektörü, softmax (z)'deki i'inci giriş, i sınıfına ait test girişinin tahmin edilen olasılığını verir.

3.2.4 Havuzlama Katmanı

Evrişim katmanında elde edilen özellik haritaları havuzlama katmanına gönderilir. Bu katmanda parametre sayılarının azaltılması hedeflenir. Evrişimsel katmandan elde edilen matrisin yükseklik ve genişliğini küçülterek karmaşıklığın önüne geçmek için havuzlama katmanı kullanılır (Hinton vd., 2012). Diğer bir deyişle, ağ parametrelerini

ve dolayısıyla hesaplama yükünü azaltmak için kullanılır. Görüntüdeki belirli bir bölgedeki pikseller üzerinde maksimum, ortalama veya minimum değerlerin elde edilmesi için gezdirilen filtreler yardımıyla havuzlama işlemi uygulanır (Bozkurt ve Yağanoğlu, 2021; Hinton vd., 2012; Türkoğlu vd., 2021). Şekil 3.9’da 2x2 boyutunda filtrenin uygulandığı maksimum, minimum ve ortalama havuzlama işlemleri gösterilmektedir. Maksimum havuzlama işleminde ilgili 2x2’lik piksel alanındaki maksimum piksel değeri, minimum havuzlama işleminde ilgili 2x2’lik piksel alanındaki minimum piksel değeri ve ortalama havuzlamada bu alandaki piksel değerlerinin ortalaması alınarak yeni değer elde edilir.




Şekil 3.9 Havuzlama işlemleri (Türkoğlu vd., 2021)

3.2.5 Toplu Normalleştirme Katmanı

Toplu Normalleştirme Katmanı (Batch Normalization), sinir ağlarının performansını ve genelleştirme kapasitesini arttırmak için uygulanan bir tekniktir. Toplu normalleştirmede asıl amaç ağ eğitimini optimize etmektir. Toplu normalleştirme, bir ağın herhangi bir katmanının diğer katmanlardan bağımsız olarak biraz daha fazla öğrenmesini sağlar (Serwa, 2017). Evrişim katmanlarında kullanılan toplu normalleştirme evrişimsel sinir ağını daha düzenli hale getirerek eğitim esnasında optimize olmasını sağlar. Toplu normalleştirme aynı zamanda evrişimsel sinir ağının eğitim süresini azaltabilmekte ve modelin daha iyi bir performans göstermesini sağlayabilmektedir (Kaya ve Önal, 2021).

3.2.6 Tam Bağlı Katman

Tam bağlı (Fully Connected) katman, evrimsel sinir ağı mimarisinin sınıflandırma kısmında yer alır ve bu katmandan birden fazla bulunur. Bu nedenle sınıflandırma safhasında çok katmanlı algılayıcı rol alır. Tam bağlı katmanda, önceki katmandaki her bir nöron bir sonraki katmandaki her bir nörona bağlanır ve her bir değer bir değer belirlenmiş bir sınıfa ne kadar uyduğunu tahmin etmeye yardımcı olur. Şekil 3.10'da görüldüğü üzere tüm nöronlar bir dizi şeklinde görünür. Tam bağlı katmanlardan sonra gelen katman sınıflandırma katmanıdır. Bu katman, bir giriş verisi için kaç tane sınıf tanımlanmışsa aynı sayıda çıktı üretir (Talan ve Aktürk, 2022). Diğer bir deyişle, tam bağlı katmanlardan sonra gelen sınıflandırma katmanı sınıflandırma yapılan öge sayısı kadar sonuç üretir. Bu sonuçların her biri bir sınıfı temsil eder. Son katman olarak bilinen sınıflandırıcı katmanı için farklı türde sınıflandırıcılar kullanılmakla birlikte genellikle Softmax sınıflandırıcısı tercih edilir (Ciresan vd., 2011).




Şekil 3.10 Tam bağlı katman yapısı (Doğan ve Türkoğlu, 2019)

3.2.7 Seyreltme Katmanı

Çok katmanlı yapay sinir ağlarında sinir ağı eğitilirken aşırı öğrenme adı verilen ağın ezberlemesi olayı gerçekleşebilir. Seyreltme (Dropout) katmanı, aşırı öğrenmeyi önler ve böylece ağın performansını artırır (Hinton vd., 2012). Şekil 3.11'de sunulan şekilde seyreltme katmanına sahip bir ağ yapısı verilmiştir. Seyreltme işlemi yapılmış olan sağdaki şekilde bazı düğümler rastgele olarak ortadan kaldırılmış görülmektedir. Bu

katman, genellikle evrişim katmanlarının fonksiyonelliği için bir engel oluşturmaması amacıyla tam bağlantılı katmanlar arasında yer alır (Srivastava vd., 2014).



Şekil 3.11 Normal sinir ağı (a) ve Seyreltme kullanılan sinir ağı (b) (Barın, 2021)

3.3 Öğrenme Aktarımı ve Önceden Eğitilmiş Modeller


Öğrenme aktarımı (Transfer Learning), bir başka problemi çözmek için büyük bir veriseti üzerinde önceden eğitilmiş bir modelde ince ayar yapılarak kullanılması yaklaşımıdır. Ağ derinliğinin artması da zor hesaplamaları ve fazla veri ihtiyacını ortaya çıkarır. Sınırlı sayıda veri ile bir ESA eğitimi için öğrenme aktarımı yönteminden yararlanır. Derin öğrenme araştırmacıları tarafından oluşturulmuş ve oldukça çok örnek görüntü üzerinde eğitilmiş ESA modelleri bulunmaktadır. Bu tez çalışmasında ResNet50, ResNet50V2, MobileNetV2 ve EfficientNetV2B0 modelleri kullanılmış olup bu bölümün devamındaki alt başlıklarda bu modeller hakkında bilgiler bulunmaktadır.

3.3.1 EfficientNetV2B0

Tan ve Le tarafından öne sürülen EfficientNetB0, ESA'nda model ölçeklendirme için kullanılan yeni ve kolay bir yaklaşımdır (Tan ve Le, 2019). Şekil 3.12, ölçeklendirmeyi ve genelleştirmeyi kolaylaştıran EfficientNetB0 mimarisini sunar. İlk ortaya çıktığı zamanlarda, EfficientNet mimarisinin B0'dan B7'ye kadar mimari tasarımları yapılmıştır. Model numarası büyüdükçe parametre sayısı artmaktadır. Bu mimarilerin yanı sıra güncel bir mimari olan EfficientNetV2B0, diğer gelişmiş modellerden farklı olarak modeli küçültmeye çalışırken; derinlik, genişlik ve çözünürlük açısından

3.3.3 ResNet

ResNet (Residual Network, Derin Artık Ağı) mimarisi, 2015 yılında düzenlenen ImageNet yarışmasında %3,6 hata oranıyla yarışmanın kazananı olmuştur. ResNet insandan daha iyi görsel tanıma yapabildiğini göstermiştir (Doğan ve Türkoğlu, 2019). ESA'larının performans kaybı problemini çözmek için tasarlanmış olan bu modelde ağ derinliği arttıkça bir bozulma sorunu ortaya çıkar. ResNet mimarisi parametre sayılarını azaltarak hesaplama yükünü hafifletmeyi ve modeli genişletmeyi hedefler (Kavuncu, 2018). Diğer ESA modellerine kıyasla ResNet daha çok katman içermektedir. Giriş görüntüsü 224x224x3 boyutundadır. ResNet'in 34,50,101 ve 152 gibi katmandan oluşan farklı mimarileri vardır. ResNet50 mimarisi, katman sayısı arttıkça eğitim başarısı artar yanlıgısını ortadan kaldırmak için çıkarılan bir mimaridir. ResNet50 modelinin mimarisi Şekil 3.14'te görülmektedir. Bu deneysel çalışmada ResNet50 ve ResNet50V2 ESA mimarileri ile çalışılmıştır.



Şekil 3.14 ResNet50 mimarisi (Li ve Lima, 2021)

3.4 Performans Ölçümü

Sınıflandırma algoritmalarının performanslarının değerlendirilmesi için sınıfların gerçek değerleri ve bir model tarafından elde edilen değerleri karışıklık matrisi formunda ele alınır (Polat vd., 2017). Bir makine öğrenmesi modelinin gerçekten pozitif olan sınıflardan doğru tahmin ettiklerinin sayısı Doğru Pozitif (DP), gerçekten negatif olan sınıflardan doğru tahmin ettiklerinin sayısı Doğru Negatif (DN) olarak ifade edilir. Gerçek negatif olan örneklerden, yanlış sınıflandırılanların sayısı Yanlış Pozitif (YP), gerçek pozitif olan örneklerden yanlış sınıflandırılanların sayısı da Yanlış Negatif (YN) olarak nitelendirilir. Diğer bir deyişle, burada DP ve DN modelin doğru tahminlerini ifade ederken, YP ve YN modelin yanlış tahminlerini ifade eder. Bu matris temelli hesaplamaların yapıldığı Doğruluk, Duyarlılık, Özgüllük ve Kesinlik performans ölçütleri sırasıyla Denklem 3.4-3.7'de verilmiştir.

Tablo 3.1 Karışıklık matrisi

		Tahminler	
		<i>Pozitif</i>	<i>Negatif</i>
Gerçekler	<i>Pozitif</i>	DP	YN
	<i>Negatif</i>	YP	DN

Doğruluk, doğru sınıflandırılan örneklerin tüm örneklere oranını veren genel bir sınıflandırma performansı ölçütüdür. Hasta olanların hasta, sağlıklı olanların sağlıklı olarak tahmin edildiği örneklerin toplamının tüm örnek sayısına oranı ile elde edilen bir ölçüttür. Duyarlılık, gerçekte pozitif olan örneklerden ne kadarının doğru sınıflandırıldığına ölçümüdür. Özgüllük, negatif sınıftaki örneklerden ne kadarının doğru sınıflandırıldığına ölçümüdür. Son olarak, kesinlik, modelin pozitif sınıfa atanan örneklerden ne kadarının doğru sınıflandırıldığına ölçümüdür. Bu değerlendirme metrikleri birçok sınıflandırma çalışmasında rol verilmiş olan oldukça önemli metriklerdir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+DN+YN}, \quad (3.4)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3.5)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (3.6)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP}, \quad (3.7)$$

Çok sınıflı verisetleri üzerinde yapılan deneysel çalışmalarda modelin performansını ölçmek için ortalama başarı dikkate alınır. Bu çerçevede, verisetindeki her bir sınıf için Denklem 3.4-3.7, arasında verilen performans metrikleri ölçülür ve elde edilen değerlerin ortalaması alınarak ilgili metrik ölçümünde ortalama değer elde edilmiş olur. Denklem 3.8-3.11, üç sınıflı veriseti üzerinde yapılan deneysel çalışmalarda bir modelin performans ölçümü için dikkate alınan metrikleri sırasıyla sunar.

Her bir sınıf s için;


$$\text{Ortalama Doğruluk} = \frac{1}{\text{sınıf sayısı}} \sum_{s=1}^{\text{sınıf sayısı}} \text{Doğruluk}(s) \quad (3.8)$$

$$\text{Ortalama Duyarlılık} = \frac{1}{\text{sınıf sayısı}} \sum_{s=1}^{\text{sınıf sayısı}} \text{Duyarlılık}(s) \quad (3.9)$$

$$\text{Ortalama Özgüllük} = \frac{1}{\text{sınıf sayısı}} \sum_{s=1}^{\text{sınıf sayısı}} \text{Özgüllük}(s) \quad (3.10)$$

$$\text{Ortalama Kesinlik} = \frac{1}{\text{sınıf sayısı}} \sum_{s=1}^{\text{sınıf sayısı}} \text{Kesinlik}(s) \quad (3.11)$$

En yaygın kullanılan performans ölçütlerinden biri de alıcı işlem karakteristiği (AİK) eğrisidir. Bu eğride bulunan x eksenini YP oranını; y eksenini DP oranını vermektedir. Eğri altında kalan alan (EAKA), AİK eğrisinin altında kalan alanı ifade eder. Bu alanın büyüklüğü bir modelin verilen sınıfları ayırt edebilme başarısını gösterir. İdeal değeri 1'dir. İşlem karakteristik eğrisi $Y=X$ fonksiyonuna yaklaştıkça başarısız bir test ortaya çıkar. AİK eğrisi grafiği Şekil 3.15'de verilmiştir. Bu şekildeki (0,0) ile (1,1) noktalarını birleştiren köşegen çizgi referans çizgisi olarak kabul edilir. En iyi tanı, doğru pozitif oranı yüksek ve yanlış pozitiflik oranı düşük olanıdır. Mükemmel çok yakın bir tanı hemen hemen (0,0)'dan (0,1)'e ve sonra yatayda (1,1)'den geçen bir işlem karakteristik eğrisine sahip olmalıdır (Tomak ve Yüksel, 2009).



Şekil 3.15 Alıcı işlem karakteristiği eğrisi (Tomak ve Yüksel, 2009)

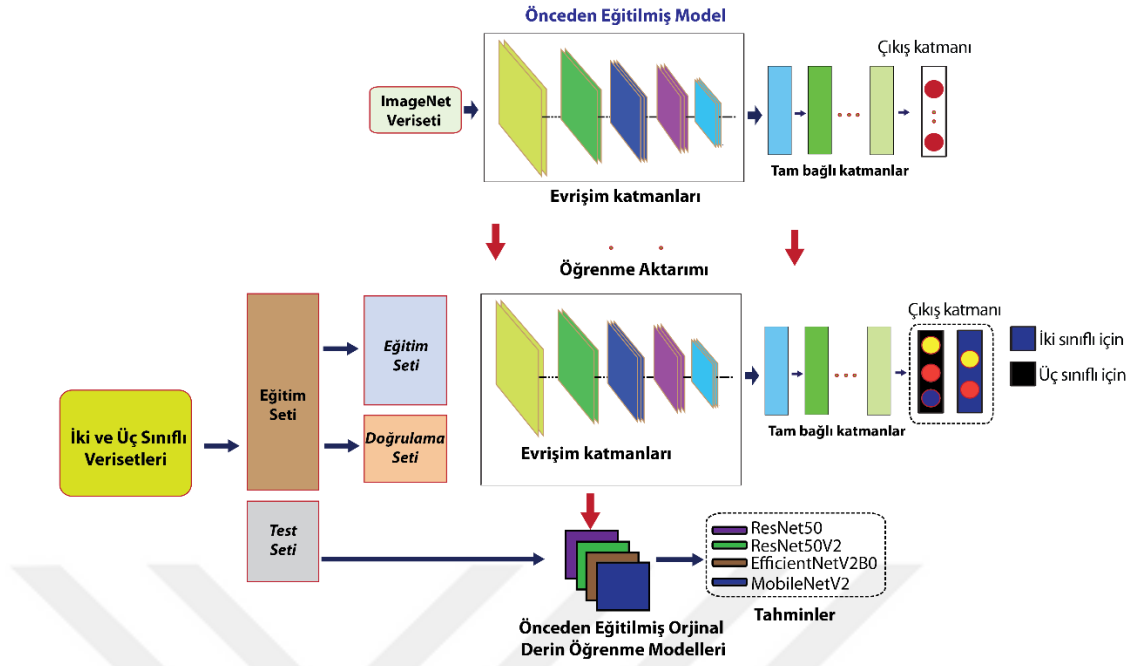
4. DENEYSEL ÇALIŞMALAR, ELDE EDİLEN SONUÇLAR VE TARTIŞMA

4.1 Deneysel Çalışma Ortamı

Bu çalışmada derin öğrenme tabanlı deneysel çalışmaları gerçekleştirmek için Google Araştırma tarafından sunulan Google Colab Pro (Google Colaboratory Pro) hizmeti kullanılmıştır. Etkileşimli bir bulut hizmeti olan Google Colab Pro, yapay zekâ ve derin öğrenme üzerinde çalışmalar yapan araştırmacıların sıklıkla başvurduğu bir programlama ortamıdır. Deneysel çalışmaların yapıldığı Google Colab Pro, Intel(R) Core (TM) 2.11 GHz işlemci, Nvidia A100- SXM4- 40 GB grafik işlemci birimi ve 16 GB RAM sistem özelliklerine sahiptir.

4.2 Deneysel Çalışmalar ve Önerilen Yaklaşım

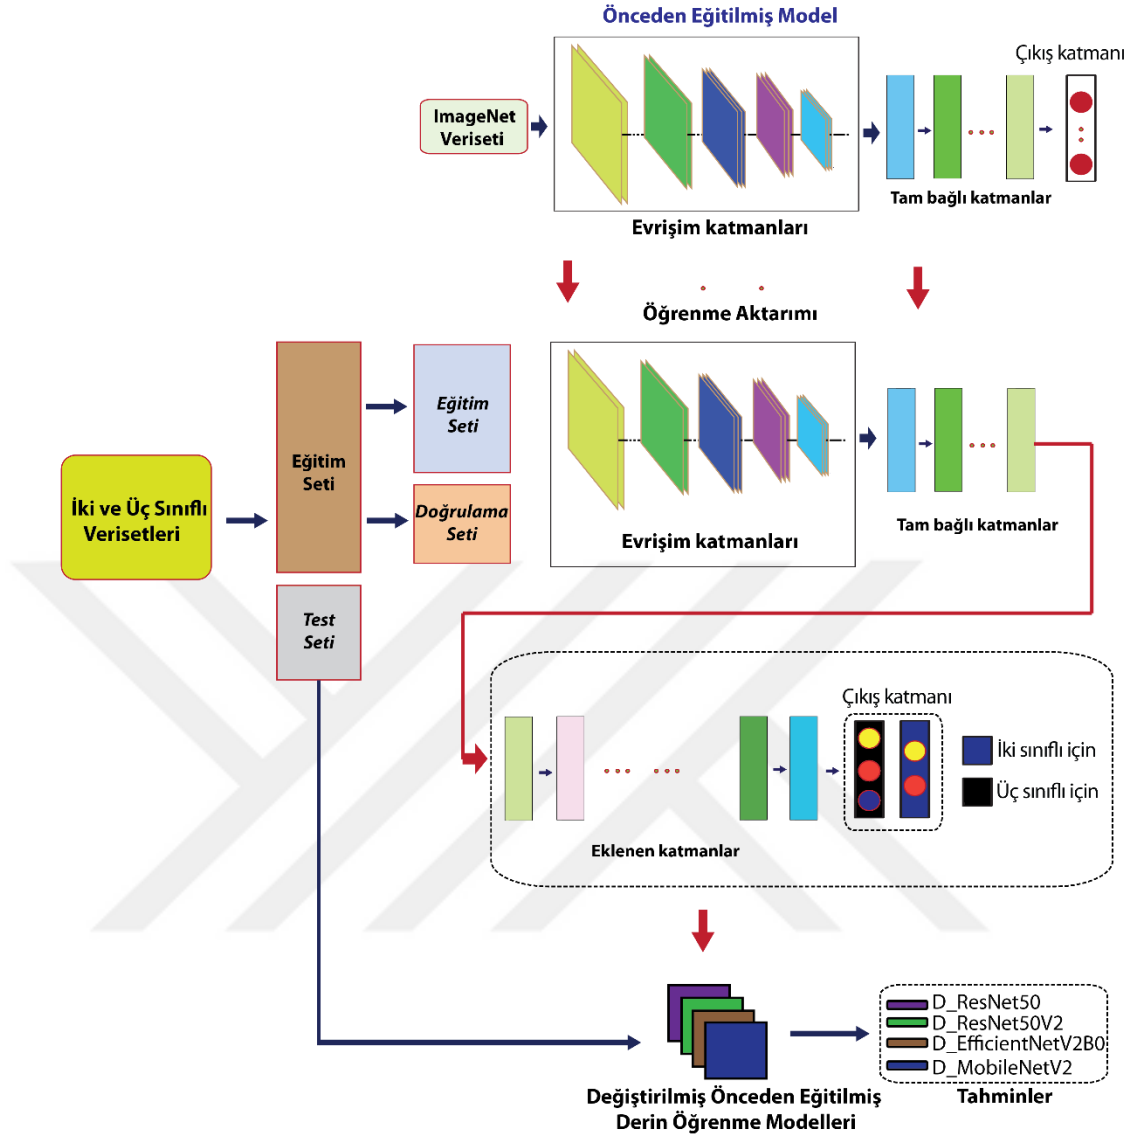
Bu tez çalışması Covid-19 hastalığının tespiti için bireylerin akciğer BT ve X-ışını görüntüleri üzerinde derin öğrenme temelli modellerin karşılaştırmasını içerir. Çok yönlü deneysel çalışmalar ile öncelikle Şekil 4.1’de sunulan grafiksel özeti verilen iş akışı çerçevesinde ResNet50, ResNet50V2, MobileNetV2 ve EfficientNetV2B0 önceden eğitilmiş modellerinin eğitimi ve testi gerçekleştirilmiştir (Senaryo-1). Sonrasında, Şekil 4.2’de görüldüğü üzere bu tez çalışmasında önerilen yaklaşım çerçevesinde orijinal önceden eğitilmiş modellerin tam bağlı katmanlarına küresel ortalama havuzlama katmanı, tam bağlı katmanlar, ReLU aktivasyon fonksiyonu ve seyreltme katmanı Tablo 4.1’de listelenen sırasıyla eklenerek bu modellerin eğitimi ve testi gerçekleştirilmiştir (Senaryo-2). Değiştirilmiş olan önceden eğitilmiş modellerin orijinal önceden eğitilmiş modellerle karşılaştırmasının daha anlaşılır olması ve bu modelleri doğru ifade edebilmek için “D_” ile orijinal önceden eğitilmiş modelin adı birleştirilmiştir. Burada, değiştirilmiş kelimesinin baş harfi D harfi olduğu için bu harf tercih edilmiştir. Örneğin, ResNet50 önceden eğitilmiş modeli ile yapılan çalışma için bu modelin tam bağlı katmanlarında yapılan değişikliği ifade etmek için D_ResNet50 ifadesi kullanılmıştır. Diğer değiştirilmiş önceden eğitilmiş modeller içinde aynı yapı geçerlidir. Orijinal ve tam bağlı katmanlarında yapılan değişikliklerle eğitilen tüm modellerin son katmanlarında Softmax aktivasyon fonksiyonu bulunmaktadır.



Şekil 4.1 Önceden eğitilmiş orijinal modeller ile yapılan çalışmanın genel çerçevesi

Tablo 4.1 Eklenen katmanların listesi

Katman	Açıklama
GlobalAveragePooling2D	Global ortalama havuzlama
Dense (512, activation="relu")	Tam bağlı katman
BatchNormalization ()	Toplu normalleştirme katmanı
Dropout (0,3)	Seyreltme
Dense (256, activation="relu")	Tam bağlı katman
BatchNormalization ()	Toplu normalleştirme katmanı
Dropout (0,2)	Seyreltme
Dense (128, activation="relu")	Tam bağlı katman
BatchNormalization ()	Toplu normalleştirme katmanı
Dropout (0,2)	Seyreltme
Dense (64, activation="relu")	Tam bağlı katman
BatchNormalization ()	Toplu normalleştirme katmanı
Dropout (0,2)	Seyreltme




Şekil 4.2 Değiştirilmiş önceden eğitilmiş modeller ile yapılan çalışmanın genel çerçevesi

Ayrıca, önerilen yaklaşımın tanı başarısını karşılaştırmak adına Senaryo 3'te DVM, LR, k-EYK ve RO makine öğrenmesi algoritmaları temelli deneysel çalışmalara da yer verilmiştir. Her bir senaryoda tasarlanan modellerin performansları sınıflandırma performansı metriklerine dayalı olarak incelenmiştir.

4.3 Verisetleri


Deneysel çalışmalarda iki farklı veriseti kullanılmıştır. Her iki veriseti birçok araştırmacının faydalandığı halka açık bir veri tabanı olan Kaggle web sitesinden alınmıştır. Brezilya, Sao Paulo'daki hastanelerindeki hastaların BT tarama görüntülerini içeren iki sınıflı verisetinde toplamda 2481 görüntü vardır (Soares ve

Angelov, 2020). Bu veriseti, Covid-19 pozitif hastalara ait 1252 BT taraması ve Covid-19 olmayan hastalara ait 1229 BT taraması içermekte olup Şekil 4.3'te her iki sınıf için örnek görüntüler verilmiştir.



Şekil 4.3 İki sınıflı veriseti: Covid-19 (a) ve hasta olmayanların (b) BT tarama görüntüleri

Üç sınıflı olan ikinci verisetinde 6939 adet akciğer görüntüsü bulunmaktadır. Bu görüntülerden 2313 tanesi Covid-19 ve 2313 tanesi zatürre olarak etiketlenmiş olup kalan 2313 akciğer görüntüsü herhangi bir tanının konulmadığı normal hastaların akciğer görüntüleridir. Bu verisetindeki görüntüler farklı kaynaklardan toplanarak bir araya getirilmiştir (Asraf, 2020). Şekil 4.4'te bu verisetindeki üç sınıf için örnek görüntüler verilmiştir.



Normal

Covid-19

Zatürre


Şekil 4.4 Üç sınıflı veriseti: Covid-19, Normal ve Zatürre tanılı X-ışını görüntülerinden örnekler

4.4 Model Eğitimi ve Testi

Deneyisel çalışmalar için her iki veriseti de eğitim ve test için %80 ve %20 oranında bölünmüştür. Bunlardan ilki eğitim seti olarak ve kalan kısmı da test seti olarak kullanılmıştır. Ayrıca, eğitim setindeki örneklerin %20'si de her bir modelin eğitimi için gerekli olan doğrulama seti olarak ayrılmıştır. Her iki veri setine ait bilgiler Tablo 4.2'de ve Tablo 4.3'de verilmiş ve ayrıca Şekil 4.5 ve Şekil 4.6'da grafiksel olarak gösterilmiştir.

Tablo 4.2 İki sınıflı veri setindeki eğitim, doğrulama ve test kümelerindeki örnek sayıları


Veriseti	Normal	Covid-19
Eğitim seti	786	800
Doğrulama seti	197	201
Test seti	246	251
Toplam	1229	1252



Şekil 4.5 İki sınıflı verisetinde eğitim, doğrulama ve test kümeleri için ayrılan örnek sayıları

Tablo 4.3 Üç sınıflı verisetindeki eğitim, doğrulama ve test kümelerindeki örnek sayıları

Veriseti	Normal	Covid-19	Zatürre
Eğitim seti	1480	1481	1480
Doğrulama seti	370	370	370
Test seti	463	462	463
Toplam	2313	2313	2313



Şekil 4.6 Üç sınıflı verisetinde eğitim, doğrulama ve test kümeleri için ayrılan örnek sayıları

Bu tez çalışmasında, öncelikle her bir ESA mimarisi için her iki verisetindeki görüntüler yeniden boyutlandırılmış ve üç senaryo çerçevesinde deneysel çalışmalar yapılmıştır. İlk senaryoda orijinal önceden eğitilmiş ResNet50, ResNet50V2, MobileNetV2, EfficientNetV2B0 modellerinin eğitimi ve testi gerçekleştirilirken ikinci senaryoda bu modellerin tam bağı katmanlarında yapılan değişiklikler temelli

deneysel çalışmalar yapılmıştır. Model tasarlanırken mini-topluluk boyutu parametresi olarak belirlenen değer modelin aynı anda kaç veriyi işleyeceğini ifade etmektedir. Epoch sayısı modelin kaç iterasyon çalışacağını belirlediği bir hiper parametredir. Tüm modellerin eğitimi için epoch sayısı 100 olarak belirlenmiştir ve RMSProp optimizasyon yöntemi kullanılmıştır. Tieleman ve Hinton tarafından tanıtılan RMSProp, öğrenme oranını katlanmış gradyanların üstel olarak azalan ortalamasına göre ölçeklendiren uyarlanabilir bir öğrenme oranı yöntemidir (Tieleman ve Hinton, 2012). Her iki senaryo için tüm derin öğrenme modellerinin eğitim parametre bilgileri Tablo 4.4'te sunulmuş olup bu modellerin eğitim sürecine ait doğruluk grafikleri ilgili şekillerde gösterilmiştir. Genel bir ifadeyle, derin öğrenme modellerinin eğitim süreçlerini gösteren şekillerdeki mavi ile belirtilen eğri eğitim setindeki doğruluğu (train accuracy), turuncu renk ile gösterilen eğri ise doğrulama setindeki (validation accuracy) doğruluğu vermektedir. Bazı turlarda modellerin özellikle doğrulama setinde sundukları doğruluklarda iniş çıkışlar olması modelin katmanlarındaki parametrelerin güncellenmesine dayalı olağan bir süreçtir.

Tablo 4.4 Derin öğrenme modellerinin eğitim parametreleri

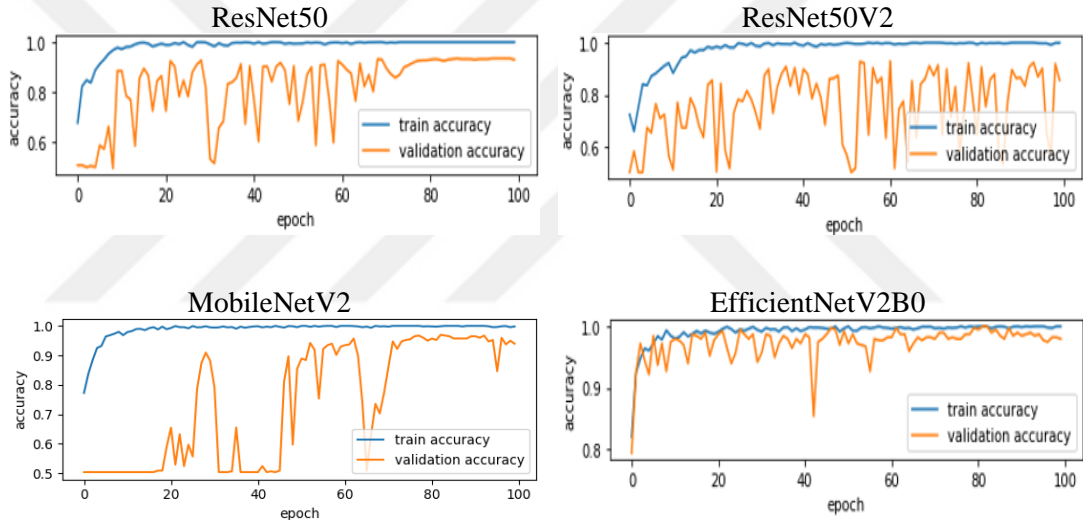
Parametre	Değer
Öğrenme oranı	0,001
Çıkış katmanındaki aktivasyon fonksiyonu	Softmax
Topluluk boyutu	32
Optimizasyon algoritması	RMSprop
Devir sayısı (epoch number)	100
Katmanlarda eğitim	Evet
Hata (Kayıp)	2 sınıf için <i>binary crossentropy</i> 3 sınıf için <i>categorical crossentropy</i>

Üçüncü senaryoda orijinal derin öğrenme modellerinden çıkartılan derin özellikler üzerinde DVM, LR, k-EYK ve RO makine öğrenmesi algoritmaları ile sınıflandırmalar gerçekleştirilmiştir. Her iki veriseti üzerinde gerçekleştirilen deneysel çalışmalar çerçevesinde test setlerinde modellerin karışıklık matrisleri ve performans ölçümleri ilgili şekil ve tablolarda sunulmuştur.


4.5 Deneysel Çalışma Senaryosu -1

4.5.1 Orijinal Önceden Eğitilmiş Modellerin İki Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar

Bu çalışmada kullanılan orijinal derin öğrenme modellerinin eğitim ve doğrulama setlerinde elde edilen doğruluk grafikleri Şekil 4.7’de verilmiştir. Bu grafiklerden, özellikle EfficientNetV2B0 modelinin eğitim ve doğrulama setlerindeki başarılarının 1’e yaklaştığı ve dolayısıyla eğitimin başarılı olduğu ifade edilebilir. İki sınıflı veriseti için bu modellerin test setindeki sınıflandırma performanslarını gösteren karışıklık matrisleri Şekil 4.8’de verilmiştir.



Şekil 4.7 Önceden eğitilmiş orijinal modellerin iki sınıflı veriseti üzerinde eğitimine ait doğruluk değerlerinin görselleştirilmesi



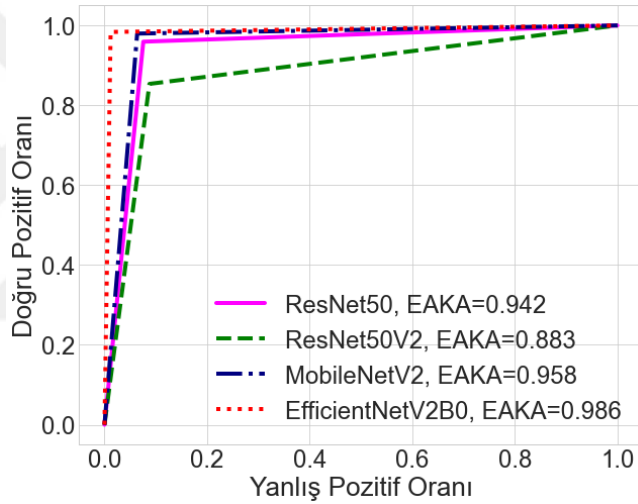
Şekil 4.8 İki sınıflı veriseti üzerinde orijinal önceden eğitilmiş modellerin karışıklık matrisleri

Senaryo 1 çerçevesinde iki sınıflı veriseti üzerinde yapılan sınıflandırma çalışmasında önceden eğitilmiş orijinal modellerin performanslarını gösteren doğruluk, duyarlılık, özgüllük ve kesinlik değerleri Tablo 4.5'te sunulmuştur. EfficientNetV2B0 modeli Covid-19 sınıfından 248 örneği doğru sınıflandırırken 3 örneği yanlış sınıflandırmıştır. Diğer yandan bu model, normal sınıfından 242 örneği doğru ve 4 örneği yanlış sınıflandırmıştır. Diğer modellerden ResNet50, %94,16 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 232 örneği doğru sınıflandırırken 19 örneği yanlış sınıflandırmıştır. Bu model, normal sınıfından 236 örneği doğru ve 10 örneği yanlış sınıflandırmıştır. ResNet50V2, %88,33 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 229 örneği doğru sınıflandırırken 22 örneği yanlış sınıflandırmıştır. Bu model, normal sınıfından 210 örneği doğru ve 36 örneği yanlış sınıflandırmıştır. MobileNetV2, %95,77 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 235 örneği doğru sınıflandırırken 16 örneği yanlış sınıflandırmıştır. Bu model, normal

sınıfından 241 örneği doğru ve 5 örneği yanlış sınıflandırmıştır. Bu sonuçlara göre, en yüksek doğruluğu %98,59 ile EfficientNetV2B0 en düşük doğruluğu ise %88,33 ile ResNet50V2 modeli sunmuştur.

Tablo 4.5 Orijinal önceden eğitilmiş modellerin iki sınıflı veriseti için performanslarının karşılaştırılması

Model	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
ResNet50	94,16	95,93	92,43	92,55
ResNet50V2	88,33	85,37	91,24	90,52
EfficientNetV2B0	98,59	98,37	98,8	98,78
MobileNetV2	95,77	97,97	93,63	93,77

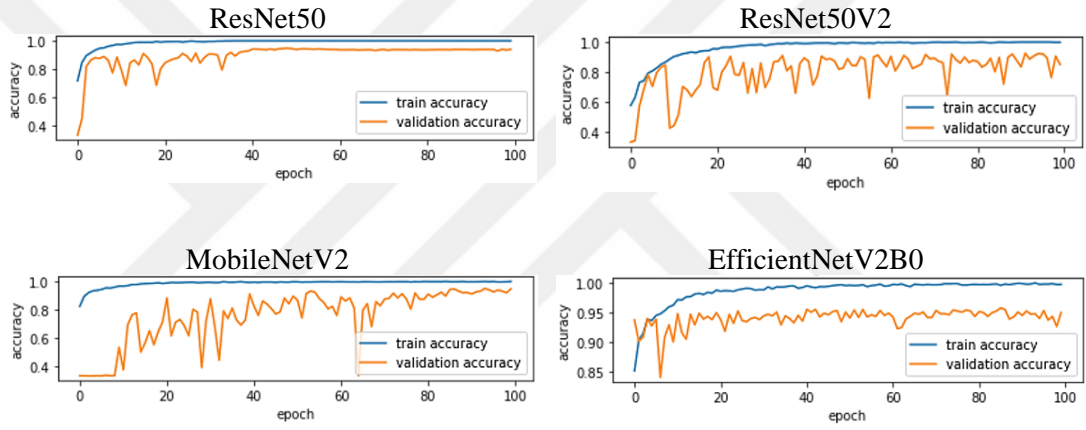


Şekil 4.9 İki sınıflı veriseti için orijinal önceden eğitilmiş modellerin AİK eğrileri


Bu derin öğrenme modellerinin Covid-19 durumunu ne kadar doğru bir şekilde ayırdığını ölçebilmek için ayrıca AİK ile değerlendirilmiştir. Şekil 4.9, ResNet50, ResNet50V2, EfficientNetV2B0 ve MobileNetV2 modellerinin AİK eğrilerini sunar. AİK eğrisi altında kalan alanın büyüklüğü derin öğrenme modelinin ayırt etme başarısını göstermektedir. AİK eğrisi altında kalan alan değeri ile (EAKA: 0,986) EfficientNetV2B0 modeli Covid-19 hastalığının tespitinde diğer modellere kıyasla daha başarılı olduğu ifade edilebilir.

4.5.2 Orijinal Önceden Eğitilmiş Modellerin Üç Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar

Senaryo 1 çerçevesinde üç sınıflı veriseti üzerinde önceden eğitilmiş orijinal modellerin eğitim ve doğrulama setlerinde elde edilen doğruluk grafikleri Şekil 4.10'da sunulmuştur. Bu grafiklerden, özellikle ResNet50 ve MobileNetV2 modellerinin eğitim ve doğrulama setlerindeki başarılarının 1'e yakın olduğu ve dolayısıyla eğitimin başarılı olduğu ifade edilebilir. Üç sınıflı veriseti için bu modellerin test setindeki sınıflandırma performanslarını gösteren karışıklık matrisleri Şekil 4.11'de verilmiştir.



Şekil 4.10 Önceden eğitilmiş orijinal modellerin üç sınıflı veriseti üzerinde eğitimine ait doğruluk değerlerinin görselleştirilmesi



Şekil 4.11 Üç sınıflı veriseti üzerinde önceden eğitilmiş orijinal modellerin karışıklık matrisleri

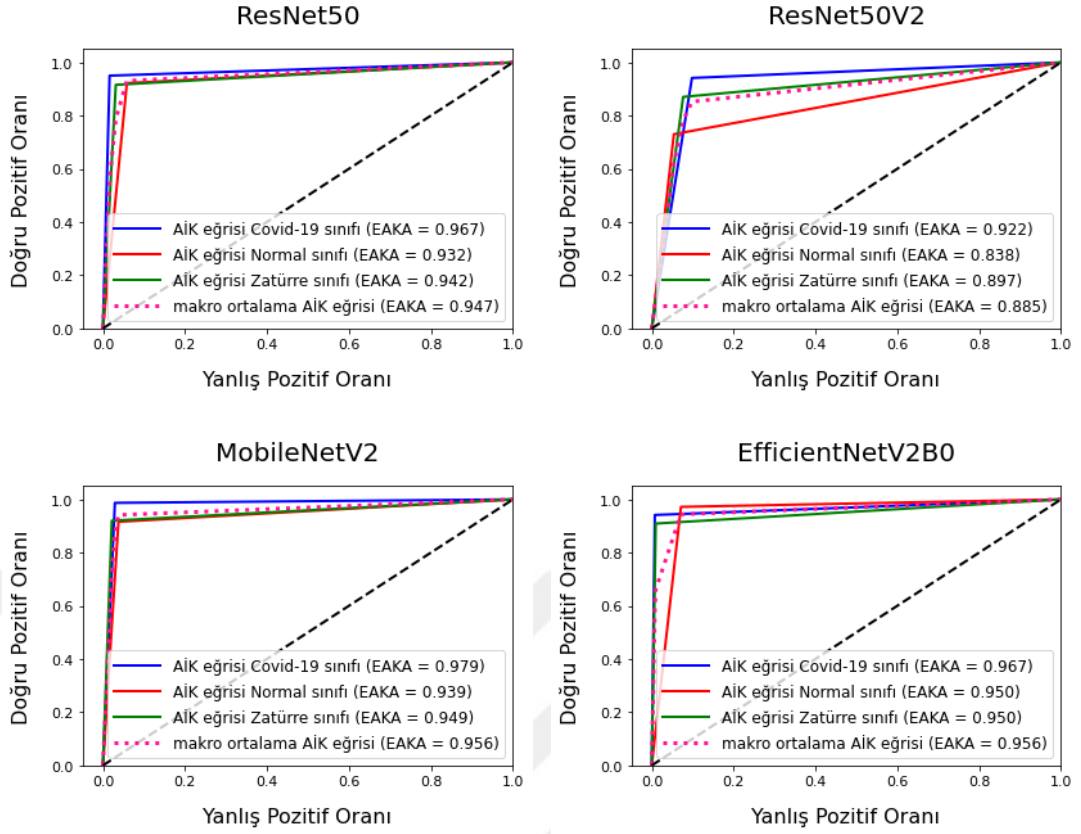
Senaryo 1 çerçevesinde üç sınıflı veriseti üzerinde yapılan sınıflandırma çalışmasında önceden eğitilmiş orijinal modellerin performanslarını gösteren doğruluk, duyarlılık, özgüllük ve kesinlik değerleri Tablo 4.6’da sunulmuştur. EfficientNetV2B0 modeli Covid-19 sınıfından 435 örneği doğru sınıflandırırken 27 örneği yanlış sınıflandırmıştır. Yanlış sınıflandırdığı görüntülerden 24 tanesini normal ve 3 tanesini zatürre olarak sınıflandırmıştır. Diğer yandan bu model, normal sınıfından 450 örneği doğru ve 13 örneği yanlış sınıflandırırken, zatürre sınıfından 421 örneği doğru 42 örneği yanlış sınıflandırmıştır. Diğer modellerden ResNet50, %95,29 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 439 örneği doğru sınıflandırırken 23 örneği yanlış sınıflandırmıştır. Yanlış sınıflandırdığı görüntülerden 19 tanesini normal ve 4 tanesini zatürre olarak sınıflandırmıştır. Diğer yandan bu model, normal sınıfından 427 örneği doğru ve 36 örneği yanlış sınıflandırırken, zatürre sınıfından 424 örneği doğru 39 örneği yanlış sınıflandırmıştır. MobileNetV2, %96,06 doğruluk oranı sunmuştur.

Bu model Covid-19 sınıfından 456 örneği doğru sınıflandırırken 6 örneği yanlış sınıflandırmıştır. Yanlış sınıflandırdığı görüntülerden 5 tanesini normal ve 1 tanesini zatürre olarak sınıflandırmıştır. Diğer yandan bu model, normal sınıfından 424 örneği doğru ve 39 örneği yanlış sınıflandırırken, zatürre sınıfından 426 örneği doğru 37 örneği yanlış sınıflandırmıştır. ResNet50V2, %89,82 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 435 örneği doğru sınıflandırırken 27 örneği yanlış sınıflandırmıştır. Yanlış sınıflandırdığı görüntülerden 22 tanesini normal ve 5 tanesini zatürre olarak sınıflandırmıştır. Diğer yandan bu model, normal sınıfından 338 örneği doğru ve 125 örneği yanlış sınıflandırırken, zatürre sınıfından 403 örneği doğru 60 örneği yanlış sınıflandırmıştır. Bu sonuçlara göre, en yüksek doğruluğu %96,06 ile EfficientNetV2B0 ve MobileNetV2 modelleri en düşük doğruluğu ise %89,82 ile ResNet50V2 modeli sunmuştur.

Tablo 4.6 Orijinal önceden eğitilmiş modellerin üç sınıflı veriseti için performanslarının karşılaştırılması

Model	Ortalama Doğruluk	Ortalama Duyarlılık	Ortalama Özgüllük	Ortalama Kesinlik
ResNet50	95,29	92,94	96,47	93,02
ResNet50V2	89,82	84,73	92,36	84,94
EfficientNetV2B0	96,06	94,09	97,05	94,51
MobileNetV2	96,06	94,10	97,05	94,10

Senaryo 1 çerçevesinde orijinal önceden eğitilmiş modellerin üç sınıflı veriseti üzerindeki performansları ayrıca AİK ile değerlendirilmiştir. Şekil 4.12, ResNet50, ResNet50V2, EfficientNetV2B0 ve MobileNetV2 modellerinin AİK eğrilerini sunar. AİK eğrisi altında kalan alanın büyüklüğü modelin sınıfları ayırt etme başarısını göstermektedir. Bu şekilde görüldüğü üzere AİK eğrisi altında kalan alan değeri ile (makro ortalama EAKA: 0,956) MobileNetV2 ve EfficientNetV2B0 modellerinin diğer modellere kıyasla daha başarılı olduğu ifade edilebilir.

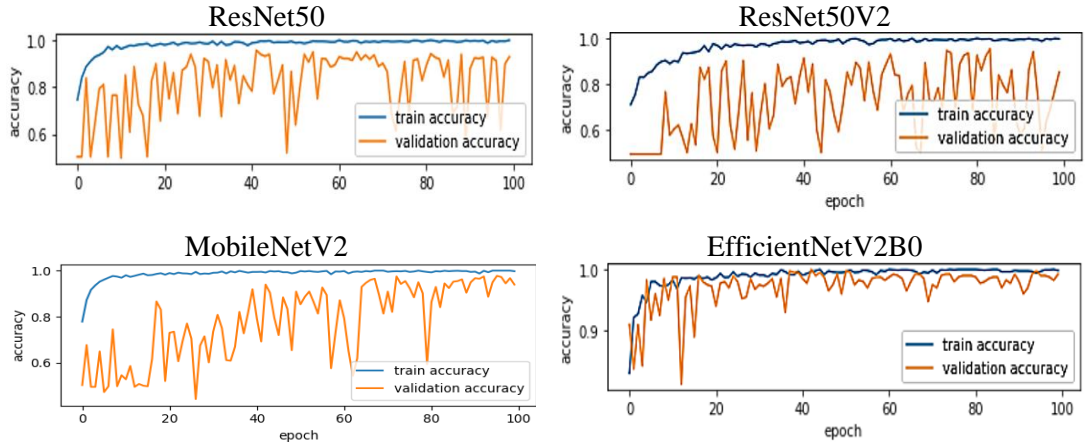


Şekil 4.12 Üç sınıflı veriseti için orijinal önceden eğitilmiş modellerin AİK eğrileri

4.6 Deneysel Çalışma Senaryosu- 2

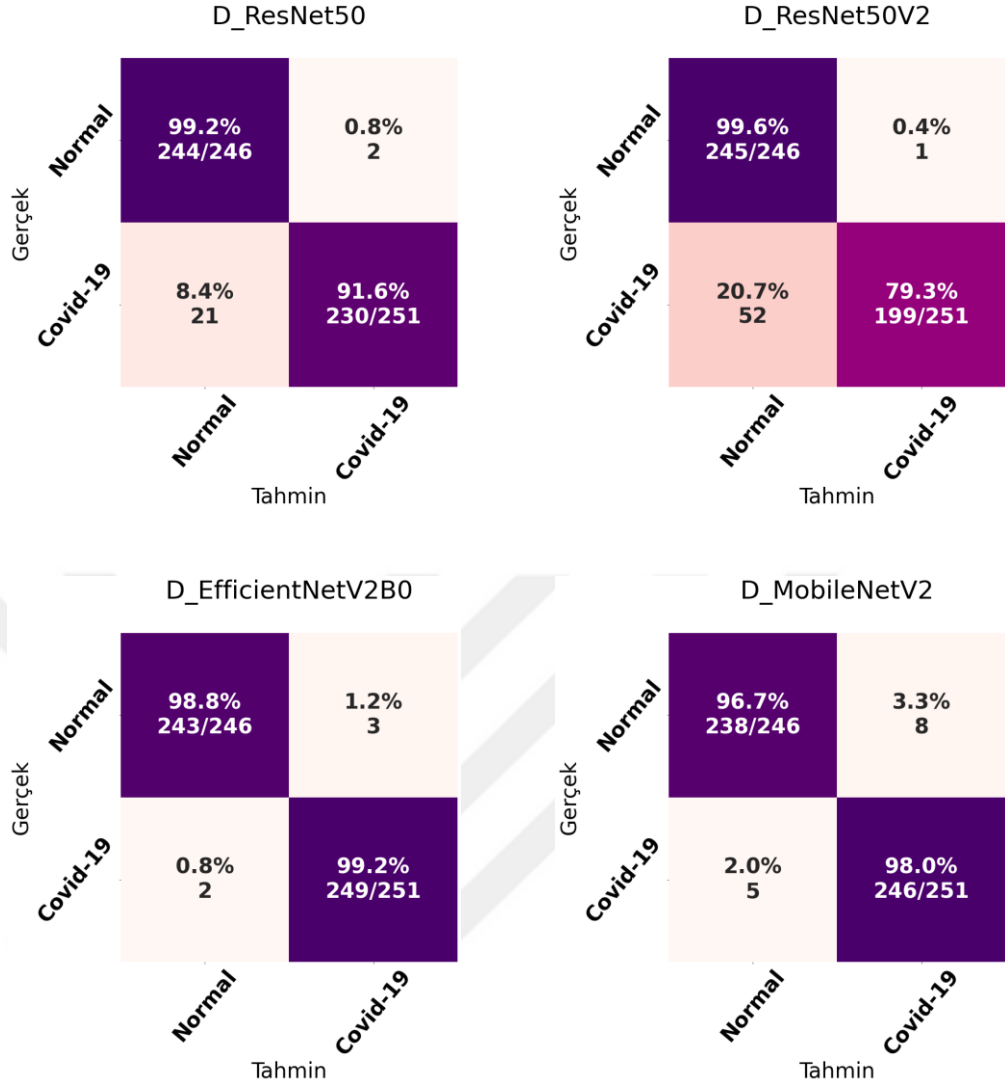
4.6.1 Değiştirilmiş Önceden Eğitilmiş Modellerin İki Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar

Senaryo 2 çerçevesinde tam bağlı katmanlarında yapılan değişiklikler temelli önceden eğitilmiş modellerin eğitim ve doğrulama setlerinde elde edilen doğruluk grafikleri Şekil 4.13'te verilmiştir. Bu grafiklerden, özellikle EfficientNetV2B0 modelinin eğitim ve doğrulama setlerindeki başarılarının oldukça iyi olduğu ifade edilebilir. Son turlardaki gösterdiği performans ile MobileNetV2 modelinin EfficientNetV2B0 modelini takip ettiği ifade edilebilir. İki sınıflı veriseti için bu modellerin test setindeki sınıflandırma performanslarını gösteren karışıklık matrisleri Şekil 4.14'te verilmiştir.



Şekil 4.13 Değiştirilmiş önceden eğitilmiş modellerin iki sınıflı veriseti üzerinde eğitimine ait doğruluk değerlerinin görselleştirilmesi

Senaryo 2 çerçevesinde iki sınıflı veriseti üzerinde yapılan sınıflandırma çalışmasında önceden eğitilmiş orijinal modellerin performanslarını gösteren doğruluk, duyarlılık, özgüllük ve kesinlik değerleri Tablo 4.7’de sunulmuştur. D_EfficientNetV2B0 modeli Covid-19 sınıfından 249 örneği doğru sınıflandırırken 2 örneği yanlış sınıflandırmıştır. Diğer yandan bu model, normal sınıfından 243 örneği doğru ve 3 örneği yanlış sınıflandırmıştır. Diğer modellerden D_MobileNetV2, %97,38 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 246 örneği doğru sınıflandırırken 5 örneği yanlış sınıflandırmıştır. Bu model, normal sınıfından 238 örneği doğru ve 8 örneği yanlış sınıflandırmıştır. D_ResNet50, %95,37 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 230 örneği doğru sınıflandırırken 21 örneği yanlış sınıflandırmıştır. Bu model, normal sınıfından 244 örneği doğru ve 2 örneği yanlış sınıflandırmıştır. D_ResNet50V2, %89,34 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 199 örneği doğru sınıflandırırken 52 örneği yanlış sınıflandırmıştır. Bu model, normal sınıfından 245 örneği doğru ve 1 örneği yanlış sınıflandırmıştır. Bu sonuçlara göre, en yüksek doğruluğu %98,99 ile D_EfficientNetV2B0 en düşük doğruluğu ise %89,34 ile D_ResNet50V2 modeli sunmuştur.



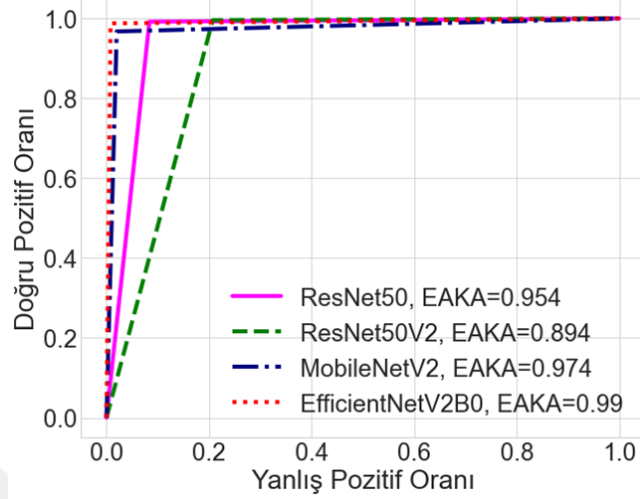
Şekil 4.14 İki sınıflı veriseti üzerinde değiştirilmiş önceden eğitilmiş modellerin karışıklık matrisleri

Tablo 4.7 Değiştirilmiş önceden eğitilmiş modellerin iki sınıflı veriseti için performanslarının karşılaştırılması

Model	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
D_ResNet50	95,37	99,19	91,63	92,08
D_ResNet50V2	89,34	99,59	79,28	82,49
D_EfficientNetV2B0	98,99	98,78	99,2	99,18
D_MobileNetV2	97,38	96,75	98,01	97,94

Senaryo 2 çerçevesinde değiştirilmiş önceden eğitilmiş modellerin performansları ayrıca AİK ile değerlendirilmiştir. Şekil 4.15, D_ResNet50, D_ResNet50V2, D_EfficientNetV2B0 ve D_MobileNetV2 modellerinin AİK eğrilerini sunar. Bu şekilde görüldüğü üzere, AİK eğrisi altında kalan alan değeri ile (EAKA: 0,99) Covid-

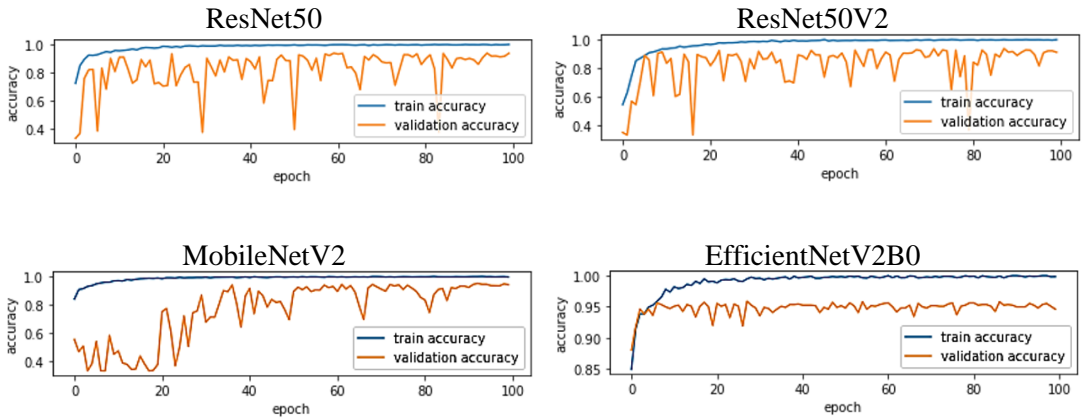
19 hastalığının tespitinde D_EfficientNetV2B0 modelinin diğer modellere kıyasla daha başarılı olduğu ifade edilebilir.



Şekil 4.15 İki sınıflı veriseti için değiştirilmiş önceden eğitilmiş modellerin AİK eğrileri


4.6.2 Değiştirilmiş Önceden Eğitilmiş Modellerin Üç Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar

Senaryo 2 çerçevesinde üç sınıflı veriseti üzerinde değiştirilmiş önceden eğitilmiş modellerin eğitim ve doğrulama setlerinde elde edilen doğruluk grafikleri Şekil 4.16’da sunulmuştur. Bu grafiklerden, tüm modellerin eğitim ve doğrulama setlerindeki başarılarının iyi olduğu ifade edilebilir. Üç sınıflı veriseti için bu modellerin test setindeki sınıflandırma performanslarını gösteren karışıklık matrisleri Şekil 4.17’de verilmiştir.



Şekil 4.16 Değiştirilmiş önceden eğitilmiş modellerin üç sınıflı veriseti üzerinde eğitimine ait doğruluk değerlerinin görselleştirilmesi

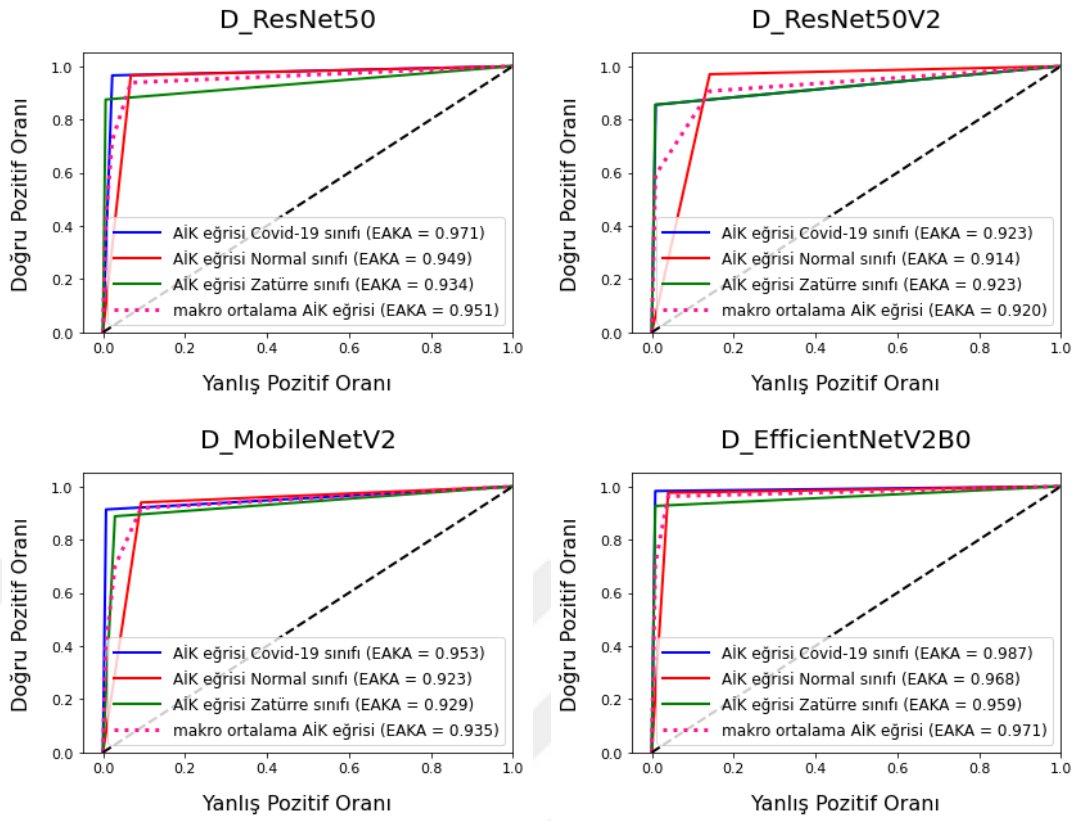
Senaryo 2 çerçevesinde üç sınıflı veriseti üzerinde yapılan sınıflandırma çalışmasında değiştirilmiş önceden eğitilmiş modellerin performanslarını gösteren doğruluk, duyarlılık, özgüllük ve kesinlik değerleri Tablo 4.8'de sunulmuştur. D_EfficientNetV2B0 modeli Covid-19 sınıfından 454 örneği doğru sınıflandırırken 8 örneği yanlış sınıflandırmıştır. Yanlış sınıflandırdığı görüntülerden 7 tanesini normal ve 1 tanesini zatürre olarak sınıflandırmıştır. Diğer yandan bu model, normal sınıfından 452 örneği doğru ve 11 örneği yanlış sınıflandırırken, zatürre sınıfından 429 örneği doğru 34 örneği yanlış sınıflandırmıştır. Diğer modellerden D_MobileNetV2, %94,24 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 422 örneği doğru sınıflandırırken 40 örneği yanlış sınıflandırmıştır. Yanlış sınıflandırdığı görüntülerden 35 tanesini normal ve 5 tanesini zatürre olarak sınıflandırmıştır. Diğer yandan bu model, normal sınıfından 435 örneği doğru ve 28 örneği yanlış sınıflandırırken, zatürre sınıfından 411 örneği doğru 52 örneği yanlış sınıflandırmıştır. D_ResNet50, %95,68 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 446 örneği doğru sınıflandırırken 16 örneği yanlış sınıflandırmıştır. Yanlış sınıflandırdığı görüntülerden 15 tanesini normal ve 1 tanesini zatürre olarak sınıflandırmıştır. Diğer yandan bu model, normal sınıfından 447 örneği doğru ve 16 örneği yanlış sınıflandırırken, zatürre sınıfından 405 örneği doğru 58 örneği yanlış sınıflandırmıştır. D_ResNet50V2, %92,89 doğruluk oranı sunmuştur. Bu model Covid-19 sınıfından 395 örneği doğru sınıflandırırken 67 örneği yanlış sınıflandırmıştır. Yanlış sınıflandırdığı görüntülerden 66 tanesini normal ve 1 tanesini zatürre olarak sınıflandırmıştır. Diğer yandan bu model, normal sınıfından 449 örneği doğru ve 14 örneği yanlış sınıflandırırken, zatürre sınıfından 396 örneği doğru 67 örneği yanlış sınıflandırmıştır. Bu sonuçlara göre, en yüksek doğruluğu %97,45 ile D_EfficientNetV2B0 en düşük doğruluğu ise %92,89 ile D_ResNet50V2 modeli sunmuştur.



Şekil 4.17 Üç sınıflı veriseti üzerinde değiştirilmiş önceden eğitilmiş modellerin karışıklık matrisleri

Tablo 4.8 Değiştirilmiş önceden eğitilmiş modellerin üç sınıflı veriseti için performanslarının karşılaştırılması

Model	Ortalama Doğruluk	Ortalama Duyarlılık	Ortalama Özgüllük	Ortalama Kesinlik
D_ResNet50	95,68	93,52	96,76	93,9
D_ResNet50V2	92,89	89,33	94,67	91,07
D_EfficientNetV2B0	97,45	96,18	98,09	96,29
D_MobileNetV2	94,24	91,35	95,68	91,90



Şekil 4.18 Üç sınıflı veriseti için değiştirilmiş önceden eğitilmiş modellerin AİK eğrileri

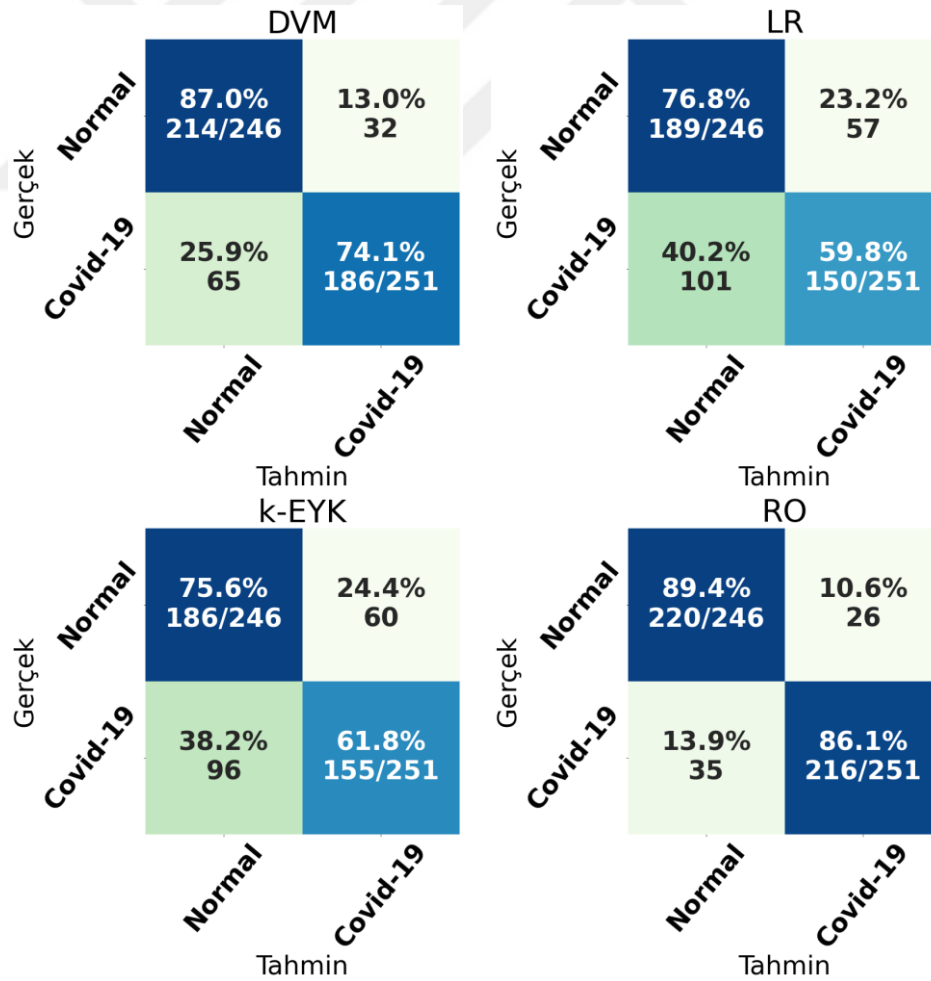
Senaryo 2 çerçevesinde değiştirilmiş önceden eğitilmiş modellerin üç sınıflı veriseti üzerindeki performansları ayrıca AİK ile değerlendirilmiştir. Şekil 4.18, D_ResNet50, D_ResNet50V2, D_EfficientNetV2B0 ve D_MobileNetV2 modellerinin AİK eğrilerini sunar. AİK eğrisi altında kalan alanın büyüklüğü modelin sınıfları ayırt etme başarısını göstermektedir. Bu şekilde görüldüğü üzere AİK eğrisi altında kalan alan değeri ile (makro ortalama EAKA: 0,971) D_EfficientNetV2B0 modelinin diğer modellere kıyasla daha başarılı olduğu ifade edilebilir.

4.7 Deneysel Çalışma Senaryosu- 3

Bu çalışmada Senaryo 2’de önerilen yaklaşımın performansını karşılaştırmak ve değerlendirmek adına ayrıca Senaryo 3 çerçevesinde DVM, LR, k-EYK ve RO sınıflandırıcıları ile de deneysel çalışmalar gerçekleştirilmiştir. Bunun için orijinal önceden eğitilmiş mimarileri ile çıkartılan 1000 boyutlu özellikler üzerinde bu sınıflandırıcıların eğitimi ve testi gerçekleştirilmiştir.


4.7.1 Geleneksel Sınıflandırıcıların İki Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar

Şekil 4.19’da ResNet50 ESA modeli ile çıkarılmış olan derin özellikler üzerinde eğitilen geleneksel sınıflandırıcı algoritmaların test setlerinde sundukları karışıklık matrisleri verilmiştir. Buna göre, DVM sınıflandırıcısı 251 Covid-19 örneğinden 186 tanesini doğru sınıflandırırken normal sınıftaki 246 örnekten 214 tanesini doğru sınıflandırmıştır. Diğer yandan, LR sınıflandırıcısı 150 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş olan 189 örneği doğru sınıflandırmıştır. k-EYK sınıflandırıcısı 155 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş olan 186 örneği doğru sınıflandırmıştır. Son olarak, RO sınıflandırıcısı 216 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş olan 220 örneği doğru sınıflandırmıştır.



Şekil 4.19 İki sınıflı verisetinden orijinal ResNet50 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri


Şekil 4.20’de ResNet50V2 ESA modeli ile çıkarılmış olan derin özellikler üzerinde eğitilen geleneksel sınıflandırıcı algoritmaların test setlerinde sundukları karışıklık matrisleri verilmiştir. Buna göre, DVM sınıflandırıcısı 251 Covid-19 örneğinden 56 tanesini doğru sınıflandırırken normal sınıftaki 246 örnekten 235 tanesini doğru sınıflandırmıştır. Diğer yandan, LR sınıflandırıcısı sadece 57 Covid-19 örneğini doğru sınıflandırabilirken normal tanısı konmuş olan 234 örneği doğru sınıflandırmıştır. k-EYK sınıflandırıcısı sadece 66 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş olan 224 örneği doğru sınıflandırmıştır. Son olarak, RO sınıflandırıcısı 61 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş olan 227 örneği doğru sınıflandırmıştır.



Şekil 4.20 İki sınıflı verisetinden orijinal ResNet50V2 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri

Şekil 4.21’de, MobileNetV2 ESA modeli ile çıkarılmış olan derin özellikler üzerinde eğitilen geleneksel sınıflandırıcı algoritmaların test setlerinde karışıklık matrisleri


verilmiştir. Buna göre, DVM sınıflandırıcısı 251 Covid-19 örneğinden 167 tanesini doğru sınıflandırırken normal sınıftaki 246 örnekten 208 tanesini doğru sınıflandırmıştır. Diğer yandan, LR sınıflandırıcısı 175 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş olan 183 örneği doğru sınıflandırmıştır. k-EYK sınıflandırıcısı 165 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş olan 181 örneği doğru sınıflandırmıştır. Son olarak, RO sınıflandırıcısı 211 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş olan 217 örneği doğru sınıflandırmıştır.



Şekil 4.21 İki sınıflı verisetinden orijinal MobileNetV2 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri

Şekil 4.22’de, EfficientNetV2B0 ESA modeli ile çıkarılmış olan derin özellikler üzerinde eğitilen geleneksel sınıflandırıcı algoritmaların test setlerinde sundukları karışıklık matrisleri verilmiştir. DVM sınıflandırıcısı 251 Covid-19 örneğinden 169 tanesini doğru sınıflandırırken normal sınıftaki 246 örnekten 206 tanesini doğru

sınıflandırmıştır. Diğer yandan, LR sınıflandırıcısı 153 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş 177 örneği doğru sınıflandırmıştır. k-EYK sınıflandırıcısı 171 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş 185 örneği doğru sınıflandırmıştır. Son olarak, RO sınıflandırıcısı 216 Covid-19 örneğini doğru sınıflandırırken normal tanısı konmuş 222 örneği doğru sınıflandırmıştır.



Şekil 4.22 İki sınıflı verisetinden orijinal EfficientNetV2B0 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri

Tablo 4.9’da bu sınıflandırıcıların derin özellikler üzerinde elde ettikleri doğruluk değerleri sunulmuştur. Burada görüldüğü üzere ResNet50V2 ESA ile çıkartılan özellikler hariç diğer modellerde en iyi başarıyı RO sınıflandırıcısı vermiştir. RO sınıflandırıcısı, ResNet50 özellikleri üzerinde %87,73; EfficientNetV2B0 özellikleri üzerinde %88,1; MobileNetV2 özellikleri üzerinde %85,31 ve ResNet50V2 özellikleri üzerinde 57,9 doğruluk oranı sunmuştur. ResNet50V2 özellikleri üzerinde diğer tüm


sınıflandırıcılar RO sınıflandırıcısından biraz daha iyi sonuç vermiştir. Bu sonuçlara göre, makine öğrenmesi sınıflandırıcıları içerisinde en yüksek doğruluğu %88,1 ile RO sınıflandırıcısı EfficientNetV2B0 özellikleri üzerinde elde etmiştir.

Tablo 4.9 İki sınıflı verisetinde sınıflandırıcı algoritmaların sınıflandırma doğruluklarının karşılaştırılması

	ResNet50	EfficientNetV2B0	MobileNetV2	ResNet50V2
DVM	80,48	75,5	75,45	58,55
LR	68,21	66,4	72,03	58,59
k-EYK	68,61	71,6	69,62	58,35
RO	87,73	88,1	85,31	57,9

4.7.2 Geleneksel Sınıflandırıcıların Üç Sınıflı Veriseti Üzerinde Eğitimi ve Elde Edilen Sonuçlar

Şekil 4.23'te üç sınıflı verisetinden ResNet50 ESA modeli ile çıkarılmış olan derin özellikler üzerinde eğitilen geleneksel sınıflandırıcı algoritmaların test setlerinde sundukları karışıklık matrisleri verilmiştir. Buna göre, DVM sınıflandırıcısı 462 Covid-19 örneğinden 307 tanesini doğru sınıflandırırken 463 normal sınıftaki örnekten 377 tanesini ve zatürre sınıfındaki 463 örnekten 387 tanesini doğru sınıflandırmıştır. LR sınıflandırıcısı 462 Covid-19 örneğinden 324 tanesini doğru sınıflandırırken normal sınıftaki 463 örnekten 329 tanesini ve zatürre sınıfındaki 463 örnekten 394 tanesini doğru sınıflandırmıştır. k-EYK sınıflandırıcısı 462 Covid-19 örneğinden 329 tanesini doğru sınıflandırırken normal sınıftaki 463 örnekten 301 tanesini ve zatürre sınıfındaki 463 örnekten 383 tanesini doğru sınıflandırmıştır. RO sınıflandırıcısı 462 Covid-19 örneğinden 423 tanesini doğru sınıflandırırken normal sınıftaki 463 örnekten 408 tanesini ve zatürre sınıfındaki 463 örnekten 415 tanesini doğru sınıflandırmıştır.



Şekil 4.23 Üç sınıflı verisetinden orijinal ResNet50 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri

Şekil 4.24’de üç sınıflı verisetinden ResNet50V2 ESA modeli ile çıkarılmış olan derin özellikler üzerinde eğitilen geleneksel sınıflandırıcı algoritmaların test setlerinde sundukları karışıklık matrisleri verilmiştir. Buna göre, DVM sınıflandırıcısı 462 Covid-19 örneğinden 340 tanesini doğru sınıflandırırken 463 normal sınıftaki örnekten 88 tanesini ve zatürre sınıfındaki 463 örnekten 367 tanesini doğru sınıflandırmıştır. LR sınıflandırıcısı 462 Covid-19 örneğinden 339 tanesini doğru sınıflandırırken normal sınıftaki 463 örnekten 91 tanesini ve zatürre sınıfındaki 463 örnekten 364 tanesini doğru sınıflandırmıştır. k-EYK sınıflandırıcısı 462 Covid-19 örneğinden 210 tanesini doğru sınıflandırırken normal sınıftaki 463 örnekten 234 tanesini ve zatürre sınıfındaki 463 örnekten 345 tanesini doğru sınıflandırmıştır. RO sınıflandırıcısı 462 Covid-19 örneğinden 330 tanesini doğru sınıflandırırken normal sınıftaki 463 örnekten 122 tanesini ve zatürre sınıfındaki 463 örnekten 356 tanesini doğru sınıflandırmıştır.




Şekil 4.24 Üç sınıflı verisetinden orijinal ResNet50V2 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri

Şekil 4.25’de üç sınıflı verisetinden MobileNetV2 ESA modeli ile çıkarılmış olan derin özellikler üzerinde eğitilen geleneksel sınıflandırıcı algoritmaların test setlerinde sundukları karışıklık matrisleri verilmiştir. Buna göre, DVM sınıflandırıcısı 462 Covid-19 örneğinden 359 tanesini doğru sınıflandırırken normal sınıftaki 463 örnekten 364 tanesini ve zatürre sınıfındaki 463 örnekten 379 tanesini doğru sınıflandırmıştır. LR sınıflandırıcısı 462 Covid-19 örneğinden 332 tanesini doğru sınıflandırırken 463 normal sınıftaki örnekten 295 tanesini ve zatürre sınıfındaki 463 örnekten 355 tanesini doğru sınıflandırmıştır. k-EYK sınıflandırıcısı 462 Covid-19 örneğinden 346 tanesini doğru sınıflandırırken normal sınıftaki 463 örnekten 328 tanesini ve zatürre sınıfındaki 463 örnekten 343 tanesini doğru sınıflandırmıştır. RO sınıflandırıcısı 462 Covid-19 örneğinden 417 tanesini doğru sınıflandırırken normal sınıftaki 463 örnekten 385 tanesini ve zatürre sınıfındaki 463 örnekten 413 tanesini doğru sınıflandırmıştır.



Şekil 4.25 Üç sınıflı verisetinden orijinal MobileNetV2 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri

Şekil 4.26’da EfficientNetV2B0 ESA modeli ile çıkarılmış olan özellikler üzerinde eğitilen geleneksel sınıflandırıcı algoritmaların test setlerinde sundukları karışıklık matrisleri verilmiştir. DVM sınıflandırıcısı 462 Covid-19 örneğinden 379 tanesini doğru sınıflandırırken 463 normal sınıftaki örnekten 378 tanesini ve zatürre sınıfındaki 463 örnekten 396 tanesini doğru sınıflandırmıştır. LR sınıflandırıcısı 462 Covid-19 örneğinden 359 tanesini doğru sınıflandırırken 463 normal sınıftaki örnekten 279 tanesini ve zatürre sınıfındaki 463 örnekten 389 tanesini doğru sınıflandırmıştır. K-EYK sınıflandırıcısı 462 Covid-19 örneğinden 364 tanesini doğru sınıflandırırken 463 normal sınıftaki örnekten 345 tanesini ve zatürre sınıfındaki 463 örnekten 392 tanesini doğru sınıflandırmıştır. RO sınıflandırıcısı 462 Covid-19 örneğinden 427 tanesini doğru sınıflandırırken normal sınıftaki 463 örnekten 421 tanesini ve zatürre sınıfındaki 463 örnekten 405 tanesini doğru sınıflandırmıştır.



Şekil 4.26 Üç sınıflı verisetinden orijinal EfficientNetV2B0 modeli ile çıkarılan özellikler üzerinde geleneksel makine öğrenmesi algoritmalarının karışıklık matrisleri

Tablo 4.10’da sınıflandırıcıların doğruluk değerleri sunulmuştur. Burada görüldüğü üzere tüm derin öğrenme modelleri ile çıkartılan derin özellikler üzerinde en iyi başarıyı RO sınıflandırıcısı vermiştir. RO sınıflandırıcısı, ResNet50 özellikleri üzerinde %93,18; EfficientNetV2B0 özellikleri üzerinde %93,52; MobileNetV2 özellikleri üzerinde %91,69 ve ResNet50V2 özellikleri üzerinde 72,14 doğruluk sunmuştur. Buna göre, RO en yüksek doğruluğu EfficientNetV2B0 özellikleri üzerinde, en düşük doğruluğu ise ResNet50V2 özellikleri üzerinde elde etmiştir.

Tablo 4.10 Üç sınıflı verisetinde sınıflandırıcı algoritmaların ortalama sınıflandırma doğruluklarının karşılaştırılması

	ResNet50	EfficientNetV2B0	MobileNetV2	ResNet50V2
DVM	84,77	88,71	86,26	71,52
LR	83,62	82,66	80,50	71,47
k-EYK	81,99	86,22	82,31	71,23
RO	93,18	93,52	91,69	72,14

Sonuç olarak, bu tez çalışmasında her iki veriseti üzerinde gerçekleştirilen deneysel çalışmalar değiştirilmiş önceden eğitilmiş modellerin önceden eğitilmiş orijinal modellerden ve ayrıca Senaryo 3 çerçevesinde elde edilen derin özellikler üzerinde eğitilen geleneksel sınıflandırıcılardan daha başarılı olduğunu bize göstermiştir.

4.8 Elde Edilen Sonuçların Literatürdeki Çalışmalarla Karşılaştırılması

Covid-19 hastalığının tespiti için şu ana kadar birçok çalışmalar yapılmıştır. Literatürde iki sınıflı (Covid-19, normal) ve üç sınıflı (Covid-19, normal, zatürre) problemler için yapılmış derin öğrenme tabanlı çalışmalar mevcuttur. Bu çerçevede, Covid-19 hastalığının tespiti için yapılmış çalışmaların özeti Tablo 4.11'de sunulmuştur. Bu tabloda görüleceği üzere, ilk altı çalışma iki sınıflı verisetleri üzerinde, sonraki çalışmalar ise üç sınıflı verisetleri üzerinde yapılmış çalışmalardır. Bu çalışmalarda derin öğrenme tabanlı yaklaşımlar ile oldukça başarılı sonuçlar elde edildiği görülmektedir. İki sınıflı verisetleri üzerinde yapılmış olan çalışmalardan Ahamed vd., ResNet50 mimarisini kullanarak X-ışını görüntüleri içeren bir veriseti üzerinde %98,95, BT görüntüleri içeren bir veriseti üzerinde %99,99 doğruluk oranı elde etmişlerdir (Ahamed vd., 2021). Apostolopoulos vd. X-ışını görüntüleri içeren bir veriseti üzerinde MobileNetV2 modeli ile %99,18 doğruluk oranı elde etmişlerdir (Apostolopoulos vd., 2020). Hemdan vd. yaptıkları çalışmada X-ışını görüntüleri içeren bir veriseti üzerinde VGG-19 modeli ile %91 doğruluk oranı elde etmişlerdir (Hemdan vd., 2020). İsmael ve Şengür X-ışını görüntüleri içeren bir veriseti üzerinde ResNet50 modeli ile en yüksek %94,7 doğruluk oranı elde etmişlerdir (İsmael ve Şengür, 2021). Özyurt vd. yaptıkları çalışmada BT görüntüleri içeren bir veriseti üzerinde derin sinir ağları ile %95,84 doğruluk oranını elde etmişlerdir (Özyurt vd., 2021). Zheng vd. BT görüntüleri içeren bir veriseti üzerinde üç boyutlu derin ESA DeCoVNet modeli ile %90,08 doğruluk oranı elde etmişlerdir (Zheng vd., 2020). Bu tez çalışmasında D_EfficientNetV2B0 modeli ile BT görüntüleri içeren iki sınıflı verisetinde %98,99 doğruluk oranı elde edilmiştir.

Üç sınıflı verisetleri üzerinde ise Ahamed vd. çalışmalarında ResNet50 modeli ile X-ışını görüntüleri içeren bir veriseti üzerinde %97,27, BT görüntüleri içeren bir veriseti üzerinde %99,01 doğruluk oranı elde etmişlerdir (Ahamed vd., 2021). Albahli vd. X-

ışını görüntüleri içeren bir veriseti üzerinde ESA modelleri ile çalışmışlar ve DenseNet modeli ile %92 doğruluk oranı elde etmişlerdir (Albahli vd., 2021). Luz vd. X-ışını görüntüleri içeren bir veriseti üzerinde EfficientNet modeli kullanarak %93,9 doğruluk oranı elde etmişlerdir (Luz vd., 2021). Narin vd. X-ışını görüntüleri içeren bir veriseti üzerinde ESA modelleri ile yaptıkları deneysel çalışmalar sonucunda ResNet50 modeli ile %99,7 doğruluk elde etmişlerdir (Narin vd., 2020). Rahimzadeh ve Attar X-ışını görüntüleri içeren bir veriseti üzerinde yaptıkları çalışmada Xception ve ResNet50V2 adlı iki modeli birleştirmişler ve %91,4 doğruluk oranı elde etmişlerdir (Rahimzadeh ve Attar, 2020). Bu tez çalışmasında D_EfficientNetV2B0 modeli ile X-ışını görüntüleri içeren üç sınıflı verisetinde %97,45 doğruluk elde edilmiştir.

Tablo 4.11 İki ve üç sınıflı verisetleri üzerinde yapılmış çalışmalar

Sınıf sayısı	Çalışma	ESA Modeli	Veriseti	Görüntü	Doğruluk %	
2 sınıf	Ahamed vd.	ResNet50V2	Diğer	BT	99,99	
				X-ışını	98,95	
	Apostolopoulos vd.	MobileNetV2	Diğer	X-ışını	99,18	
	Hemdan vd..	VGG-19	Diğer	X-ışını	91,00	
	İsmael ve Şengür	ResNet50	Diğer	X-ışını	94,7	
	Özyurt vd.	Derin sinir ağları	Diğer	BT	95,84	
	Zheng vd.	DeCoVNet	Diğer	BT	90,08	
	Bu çalışma		D_ResNet50			95,37
			D_ResNet50V2			89,34
			D_EfficientNetV2B0		BT	98,99
		D_MobileNetV2			97,38	
3 Sınıf	Ahamed vd.	ResNet50V2	Diğer	BT	99,01	
				X-ışını	97,24	
	Albahli vd.	DenseNet	Diğer	X-ışını	92,0	
	Luz vd.	EfficientNet	Diğer	X-ışını	93,9	
	Narin vd.	ResNet50	Diğer	X-ışını	99,7	
	Rahimzadeh ve Attar	Xception+ResNet50V2	Diğer	X-ışını	91,4	
	Bu çalışma		D_ResNet50			95,68
			D_ResNet50V2			92,89
			D_EfficientNetV2B0		X-ışını	97,45
			D_MobileNetV2			96,24

Not: Yazarların çalışmalarına atıflar bu tablonun yukarısında verildiği için ve burada tekrar atıf yapıldığında fazla satır oluşmasına neden olacağı için ayrıca burada atıf verilmemiştir.

5. SONUÇLAR VE ÖNERİLER

Covid-19 birçok insanın ölümüyle sonuçlanan, şiddetli solunum sistemi enfeksiyonuna neden olan ve çok hızlı bir şekilde yayılan bir hastalıktır. Tüm dünyayı etkisi altına alan bu hastalığa yakalanmış pozitif vakaların hızlı bir şekilde erkenden tespit edilmesi kaçınılmazdır. Bu hastalığın tespitinde kullanılan GZ-PZR kiti oldukça maliyetlidir ve bu kitlerin olmadığı ülkeler vardır. Bunun yanı sıra deneyimli personel eksikliği gibi nedenler radyolojik görüntüleme üzerinde bilgisayar destekli çalışmaların önemini ortaya koymuştur. Bu tez çalışmasında BT ve X-ışını görüntülerinden Covid-19 hastalığını tespit etmek için ResNet50, ResNet50V2, MobileNetV2, EfficientNetV2B0 önceden eğitilmiş derin öğrenme modellerinin tam bağlı katmanlarında değişiklikleri içeren bir yaklaşım önerilmiştir. Önerilen yaklaşımın performansını değerlendirmek için üç senaryo çerçevesinde deneyler gerçekleştirilmiştir. İlk senaryo, iki sınıflı veriseti ve üç sınıflı veriseti üzerinde önceden eğitilmiş orijinal modellerin deneysel çalışmalarını içerir. İkinci senaryo, değiştirilmiş önceden eğitilmiş derin öğrenme modellerinin deneysel çalışmalarını içerir. Üçüncü senaryo, orijinal önceden eğitilmiş derin öğrenme modellerinden çıkartılan derin özellikler üzerinde DVM, LR, k-EYK ve RO makine öğrenmesi algoritmalarının deneysel çalışmalarını içerir. Tasarlanan modellerin performansları önerilen yaklaşımın orijinal önceden eğitilmiş modellere kıyasla daha başarılı olduğunu bize göstermektedir. İki sınıflı verisetinde %98,99 ve üç sınıflı verisetinde %97,45 doğruluklar ile D_EfficientNetV2B0 modeli en iyi performansı göstermiştir. Bu çerçevede, Covid-19 tanısını yüksek başarıyla tespit etmek için bu tez çalışmasında önerilen yaklaşımın içinde yer aldığı uzman sistem veya karar destek sistemleri tasarlanabilir ve tıp alanlarında alan uzmanlarının kullanımına sunulabilir. Dahası, Covid-19 hastalığının yanı sıra başka hastalıkların tespiti için de bu tez çalışmasında önerilen yaklaşımın içinde yer aldığı kapsamlı deneysel çalışmalar yapılabilir ve bu bağlamda yüksek başarı sunan bir modele sahip uzman sistemler veya karar destek sistemleri ile alan uzmanlarına destek sağlanabilir.

KAYNAKLAR

- Agarap, A. F. (2018). Deep learning using rectified linear units (relu). *arXiv preprint arXiv:1803.08375*.
- Ahamed, K. U., Islam, M., Uddin, A., Akhter, A., Paul, B. K., Yousuf, M. A., ... & Moni, M. A. (2021). A deep learning approach using effective preprocessing techniques to detect COVID-19 from chest CT-scan and X-ray images. *Computers in biology and medicine*, 139, 105014.
- Ahuja, S & Angra, S., (2017). Machine learning and its Applications: A Review. *In 2017 International Conference on Big Data Analytics and Computational Intelligence (ICBDAC)* (pp. 57-60). IEEE.
- Akalın, B., & Veranyurt, Ü. (2021) Sağlık hizmetleri ve yönetiminde yapay zekâ. *Acta Infologica*, 5(1), 231-240.
- Albahli, S., Ayub, N., & Shiraz, M. (2021). Coronavirus disease (COVID-19) detection using X-ray images and enhanced DenseNet. *Applied Soft Computing*, 110, 107645.
- Alzubaidi, L., Fadhel, M. A., Al-Shamma, O., Zhang, J., Santamaría, J., Duan, Y., & Olewi, S. R. (2020). Towards a better understanding of transfer learning for medical imaging: a case study. *Applied Sciences*, 10(13), 4523.
- Apostolopoulos, I. D., Aznaouridis, S. I., & Tzani, M. A. (2020). Extracting possibly representative COVID-19 biomarkers from X-ray images with deep learning approach and image data related to pulmonary diseases. *Journal of Medical and Biological Engineering*, 40, 462-469.
- Asraf, A.(2020).COVID19_Pneumonia_Normal_Chest_Xray_PA_Dataset. Kaggle: <https://www.kaggle.com/datasets/amanullahasraf/covid19-pneumonia-normal-chest-xray-pa-dataset?select=pneumonia>, Erişim tarihi :12/10/2022
- Aydın, S., & Özkul, A. E. (2015) Veri madenciliği ve Anadolu Üniversitesi uzaktan eğitim sisteminde bir uygulama. *Journal of Research in Education and Teaching*, 4(3), 36-44
- Barın, S. (2021). Deri lezyonlarının derin öğrenme yöntemleri ile segmentasyonu. Yüksek Lisans Tezi. *Afyon Kocatepe Üniversitesi/ Fen Bilimleri Enstitüsü*. Afyonkarahisar.
- Başer, B. Ö., Yangın, M., & Sarıdaş, E. S (2021). Makine Öğrenimi Teknikleriyle Diyabet Kullanımının Sınıflandırılması . *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 25(1), 112-120.
- Batirel, A. (2020). SARS-CoV-2: Bulaşma ve Korunma. *Southern Clinics of Istanbul Eurasia*, 31, 1-7.

- Bozkurt, F. & Yağanoğlu, M. (2021). Derin Evrişimli Sinir Ağları Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti. *Veri Bilimi*, 4(2), 1-8.
- Breiman L., C. A. (2001). Random forests, machine learning. *Kluwer Academic Publishers*, 45(1), 5-32.
- Bulut, E., & Yörük, E. (2017). Mediatized populisms Digital populism: Trolls and political polarization of Twitter in Turkey. *International Journal of Communication*, 11, 25.
- Ciresan, D. C., Meier, U., Masci, J., Gambardella, L. M., & Schmidhuber, J. (2011). Flexible, high performance convolutional neural networks for image classification. *In Proceedings of the Twenty-Second international joint conference on Artificial Intelligence-Volume Volume Two*(pp. 1237-1242). Switzerland.
- Çavuşoğlu, Ü., & Kaçar, S. (2019). Anormal trafik tespiti için veri madenciliği algoritmalarının performans analizi. *Academic Platform-Journal of Engineering and Science*, 7(2), 205-216.
- Dağlı, İ., & Öztürk, A. (2021). Görüntü Sınıflandırmada Derin Öğrenme Yöntemlerinin Karşılaştırılması. *Konya Mühendislik Bilimleri Dergisi*, 9(4), 872-888.
- Doğan, F., & Türkoğlu, İ. (2018). Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.
- Doğan, F., & Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- Dua, P., & Bais, S. (2014). Supervised learning methods for fraud detection in healthcare insurance. *Machine learning in healthcare informatics*, 56, 261-285.
- Erhandı, B. (2020). Derin öğrenme ile metin özetleme. Yüksek Lisans Tezi. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*. Sakarya.
- Foto, Ö. (2022). Transfer öğrenme modelleri ile akciğer X-ray görüntülerinden COVID-19 tespiti. Yüksek Lisans Tezi. *Aksaray Üniversitesi Sosyal Bilimler Enstitüsü*. Aksaray.
- Hemdan, E. E. D., Shouman, M. A., & Karar, M. E. (2020) Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images. *arXiv preprint arXiv:2003.11055*.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint*, *arXiv:1207.0580*.

- Hosmer, D.W. and Lemeshow, S.,(2000) Applied Logistic Regression, *Wiley Series In Probability And Statistics*, Canada, 8,49-50,143,156.
- İbrahim, D. M., Elshennawy, N. M., & Sarhan, A. M. (2021). Deep-chest: Multi-classification deep learning model for diagnosing COVID-19, pneumonia, and lung cancer chest diseases. *Computers in biology and medicine*, 132, 104348.
- İnik Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- İsmael, A. M., & Şengür, A. (2021). Deep learning approaches for COVID-19 detection based on chest X-ray images. *Expert Systems with Applications*, 164, 114054.
- Jaiswal, A. Gianchandani, N., Singh,D., Kumar, V., & Kaur, M. (2021).Classification of the COVID-19 infected patients using DenseNet201 based deep transfer learning. *Journal of Biomolecular Structure and Dynamics*, 39(15), 5682-5689.
- Jang, J., Cho, H., Kim, J., Lee, J. ve Yang, S. (2020). Deep neural networks with a set of node-wise varying activation functions. *Neural Networks: The Official Journal of The International Network Society*, 126(93), 118-131.
- Joachims, T. (1999). Transductive Inference for Text Classification using Support Vector Machines. *Proc. of the Sixteenth International Conference on Machine Learning*, 200-209.
- Kanne, J. P., Little, B. P., Chung, J. H., Elicker, B. M., & Ketai, L. H. (2020). Essentials for radiologists on COVID-19: an update radiology scientific expert panel. *Radiology*, 296(2), E113-E114.
- Kavuncu, S. K. (2018). Makine öğrenmesi ve derin öğrenme: Nesne tanıma uygulaması. Yüksek Lisans Tezi. *Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü*. Kırıkkale.
- Kaya, B. & Önal, M.(2021). COVID-19 Tespiti için Akciğer BT Görüntülerinin Bölütlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 28, 1296-1303.
- Koronavirüs. (2020). Cleveland Clinic: <https://my.clevelandclinic.org/health/diseases/21214-coronavirus-covid-19> Erişim Tarihi: 5/17/2022 .
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Li, B., & Lima, D. (2021). Facial expression recognition via ResNet-50. *International Journal of Cognitive Computing in Engineering*, 2, 57-64.
- Litjens, G., Kooi, T., Bejnordi, BE, Setio, AAA, Ciompi, F., Ghafoorian, M., ... & Sánchez, CI (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.

- Liu, M., & Zhu, M. (2018). Mobile Video Object Detection with Temporally-Aware Feature Maps. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*(pp.5686–5695).
- Liu, Y., Wang, Y., & Zhang, J. (2012). New Machine Learning Algorithm: Random Forest. *In Information Computing and Applications: Third International Conference. ICICA 2012, Chengde, China, September 14-16, 2012. Proceedings 3 7473* (pp. 246-252) Springer Berlin Heidelberg.
- Luz, E., Silva, P., Silva, R., Silva, L., Guimarães, J., Miozzo, G., ... & Menotti, D. (2021). Towards an effective and efficient deep learning model for COVID-19 patterns detection in X-ray images. *Research on Biomedical Engineering*, 38, 1-14.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., ... & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533.
- Nacar, E. N., & Erdebilli, B. (2021). Makine Öğrenmesi Algoritmaları ile Satış Tahmini. *Endüstri Mühendisliği*, 32(2), 307-320.
- Narin, A., Kaya, C., & Pamuk, Z. (2020). Automatic detection of coronavirus disease using X-ray images and deep convolutional neural networks. *arXiv preprint arXiv:2003.10849*.
- Nour, M., Cömert, Z., & Polat, K (2020). A novel medical diagnosis model for COVID-19 infection detection based on deep features and Bayesian optimization. *Applied Soft Computing*, 97, 106580.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Özyurt, F., Tuncer, T., & Subasi, A. (2021). An automated COVID-19 detection based on fused dynamic exemplar pyramid feature extraction and hybrid feature selection using deep learning. *Computers in Biology and Medicine*, 132, 104356.
- Pan, F., Ye, T., Sun, P., Gui, S., Liang, B., Li, L., ... & Zheng, C. (2020). Time course of lung changes on chest CT during recovery from 2019 novel coronavirus (COVID-19) pneumonia. *Radiology*, 295(3), 715-721.
- Pathak, Y., Shukla, P. K., Tiwari, A., Stalin, S., & Singh, S (2020). Deep Transfer Learning Based Classification Model for COVID-19, Disease. *Irbm*, 43(2), 87-92.
- Polat, H., Danaei Mehr, H., & Cetin, A. (2017). Diagnosis of chronic kidney disease based on support vector machine by feature selection methods. *Journal of medical systems*, 41, 1-11.
- Rahimzadeh, M., & 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.
- Raschka, S. (2015). *Python machine learning*. Packt publishing ltd.
- Salman, F. M., Abu-Naser, S. S., Alajrami, E., Abu-Nasser, B. S., & Alashqar, B. A. (2020). Covid-19 detection using artificial intelligence. *International Journal of Academic Engineering Research (IJAER)*, 4, 18-25.
- Seidaliyeva, U., Akhmetov, D., Ilipbayeva, L., & Matson, E. T. (2020). Real-time and accurate drone detection in a video with a static background. *Sensors (Basel)*, 20(14), 3856.
- Serte, S., & Demirel, H. (2021). Deep learning for diagnosis of COVID-19 using 3D CT scans. *Computers in biology and medicine*, 132, 104306.
- Serwa, A. (2017). Studying the effect of activation function on classification accuracy using deep artificial neural networks. *Journal of Remote Sensing & GIS*, 6(03), 1-6.
- Sevli, O. (2019). Göğüs kanseri teşhisinde farklı makine öğrenmesi tekniklerinin performans karşılaştırması. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 176-185.
- Shah, V., Keniya, R., Shridharani, A., Punjabi, M., Shah, J., & Mehendale, N. (2021). Diagnosis of COVID-19 using CT scan images and deep learning techniques. *Emergency radiology*, 28, 497-505.
- Shen, D., Wu, G., & Suk, H. I. (2017). Deep learning in medical image analysis. *Annual review of biomedical engineering*, 19, 221-248.
- Singhal, T. (2020). A review of coronavirus disease-2019 (COVID-19). *The indian journal of pediatrics*, 87(4), 281-286.
- Soares E., P.A. (2020). SARS-COV-2Ct-ScanDataset Kaggle: <https://www.kaggle.com/datasets/plameneduardo/sarscov2-ctscan-dataset> Erişim Tarihi: 5/10/2022.
- Song, Y., Zheng, S., Li, L., Zhang, X., Zhang, X., Huang, Z., ... & Yang, Y. (2021). Deep learning enables accurate diagnosis of novel coronavirus (COVID-19) with CT images. *IEEE/ACM transactions on computational biology and bioinformatics*, 18(6), 2775-2780.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Şafak, E. & Barışçı, N. (2022). Hafif Evrişimsel Sinir Ağları Kullanılarak Sahte Yüz Görüntülerinin Tespiti. *El-Cezeri*, 9(4), 1282-1289.

- Şapıcı, B., & Pektaş, Ş. T. (2021). Makine Öğrenmesi Aracılığı ile Kullanıcı Deneyimi Bilgilerinin Erken Mimari Tasarım Süreçleriyle Bütünleştirilmesi. *Algorithm Classification Overview. Journal of Computational Design*, 2(1), 67-94.
- Şeker, A, Diri, B.& Balık, H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Journal of Engineering Sciences*, 3(3), 47–64.
- Talan,T., & Aktürk C. (2022). *Bilgisayar Bilimlerinde Teorik Ve Uygulamalı Araştırmalar*. İstanbul: Efe Akademi Yayınları.
- Talu, T., & Nimet, H. (2022, May 12-13). *GELISIM-UWE 2022: 6th International Conference on Economics and Finance: Evaluation of the Consequences of Regional Inequalities in World Income Distribution in Economic, Social, and Health Fields: Hybrid Conference*. İstanbul: Book of Abstracts.
- Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. *In International conference on machine learning* (pp, 6105-6114).
- Tieleman, T., & Hinton, G. (2012). Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. *COURSERA: Neural networks for machine learning*, 4(2), 26-31.
- Tomak, L., & Yüksel, B. E. K. (2009). İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması. *Journal of Experimental and Clinical Medicine*, 27(2).
- Türkoğlu, M., Hanbay, K., Sivrikaya, I. S., & Hanbay, D. (2021). Derin Evrimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 334-345.
- URL-1. Introduction to Machine Learning: <https://aldro61.github.io/microbiome-summer-school-2017/sections/basics/#type-of-learning-problems> Erişim Tarihi: 01/02/2023.
- URL-2. Softmax Activation Function: Everything You Need to Know, <https://www.pinecone.io/learn/softmax-activation/> Erişim tarihi: 10/10/2022.
- URL-3. EfficientNet: Improving Accuracy and Efficiency through AutoML and Model Scaling, <https://ai.googleblog.com/2019/05/efficientnet-improving-accuracy-and.html>, Erişim tarihi: 29/05/2019.
- Widodo, A., & Yang, B. S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical Systems and Signal Processing*, 21(6), 2560-2574.
- World Health Organization*. (2021, Aralık 23). Coronavirus disease (COVID-19): How is it transmitted?: <https://www.who.int/news-room/qa-detail/qahow-is-covid-19-transmitted>. Erişim Tarihi: 12/08/2021.

- Yang, S., Jiang, L., Cao, Z., Wang, L., Cao, J., Feng, R., ... & Shan, F. (2020). Deep learning for detecting corona virus disease 2019 (COVID-19) on high-resolution computed tomography. *Annals of translational medicine*, 8(7), 450.
- Zheng, C., Deng, X., Fu, Q., Zhou, Q., Feng, J., Ma, H., ... & Wang, X. (2020). Overview of the 2019 coronavirus disease (COVID-19). *IEEE Transactions on Medical Imaging* *Journal of Zhejiang University-SCIENCE B*, 21(5), 343-360.
- Zu, Z. Y., Jiang, M. D., Xu, P. P., Chen, W., Ni, Q. Q., Lu, G. M., & Zhang, L. J. (2020). Coronavirus disease 2019 (COVID-19): a perspective from China. *Radiology*, 296(2), E15-E25.

