ÇANKIRI KARATEKİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ İLE COVID-19 HASTALIĞININ TEŞHİSİ

Gözde KAHRAMAN

ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ÇANKIRI
2021

Her hakkı saklıdır

TEZ ONAYI

Gözde KAHRAMAN tarafından hazırlanan "Bilgisayarlı Tomografi Görüntülerinden Derin Öğrenme ve Makine Öğrenmesi ile COVID-19 Hastalığının Teşhisi" adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Elektrik – Elektronik Mühendisliği Anabilim Dalı'nda Yüksek Lisans Tezi olarak kabul edilmiştir.

Danışman **:** Dr. Öğr. Üyesi Zafer CİVELEK
Çankırı Karatekin Üniversitesi
Elektrik Elektronik Mühendisliği

Jüri Üyeleri :

Başkan **:** Dr. Öğr. Üyesi Zafer CİVELEK
Çankırı Karatekin Üniversitesi
Elektrik Elektronik Mühendisliği

Üye **:** Dr. Öğr. Üyesi Mehmet GÜÇYETMEZ
Kırşehir Ahi Evran Üniversitesi
Elektrik Elektronik Mühendisliği

Üye **:** Dr. Öğr. Üyesi Mustafa TEKE
Çankırı Karatekin Üniversitesi
Elektrik Elektronik Mühendisliği

Yukarıdaki sonucu onaylarım

Prof. Dr. İbrahim ÇİFTÇİ
Enstitü Müdürü

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğine göre hazırlamış olduğum "Bilgisayarlı Tomografi Görüntülerinden Derin Öğrenme ve Makine Öğrenmesi ile COVID-19 Hastalığının Teşhisi" konulu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, tezin Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü'nden başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve bu çalışmanın Çankırı Karatekin Üniversitesi tarafından kullanılan "Bilimsel İntihal Tespit Programı"yla tarandığını, "intihal içermediğini" beyan ederim. Çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması halinde ortaya çıkacak tüm ahlaki ve hukuki sonuçlara razı olduğumu bildiririm. Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

Gözde KAHRAMAN

ÖZET

Yüksek Lisans Tezi

BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ İLE COVID-19 HASTALIĞININ TEŞHİSİ

Gözde KAHRAMAN

Çankırı Karatekin Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Zafer CİVELEK

COVID-19 hastalığı kısa süre içerisinde hızlı yayılım göstererek birçok insanın hastalanmasına ve ölmesine sebep olan bir salgın haline gelmiştir. COVID-19 hastalığının kontrol altına alınmasında ve bulaşmanın azaltılmasında hastalığın hızlı tespit edilmesi büyük önem taşımaktadır. COVID-19 hastalığının teşhisinin önemli bir parçasını akciğer görüntüleme işlemleri oluşturmaktadır. Bu çalışmada daha önce hiçbir çalışmada kullanılmamış Bilgisayarlı Tomografi cihazı akciğer görüntülerinden toplam 7200 görüntü içeren veri seti oluşturulmuştur. Bilgisayarlı Tomografi görüntüleri 2020 mart ve 2020 kasım ayları aralığındaki erişkin bütün hastalardan radyoloji doktoru ve radyoloji teknikerlerinin yardımıyla raporlandırılmış hasta verileri arasından seçilmiştir. Çalışmada ikili sınıflandırma metodu kullanılmıştır. Hastalığın teşhisi için Derin Öğrenme yöntemlerinden Evrişimli Sinir Ağları, Makine Öğrenmesi algoritmalarından Yapay Sinir Ağı (YSA), Destek Vektör Makinesi (SVM), K-En Yakın Komşu (KNN) algoritmalarında doğrulama ve test işlemleri gerçekleştirilmiştir. Çalışmalar sonucunda CNN mimarisi Xception modeli için eğitim aşamasında %99,77 doğruluk ve %97,78 test doğruluğu elde edilmiştir. YSA modeli için eğitim aşamasında %98,98 doğruluk ve %97,68 test doğruluğu elde edilmiştir. SVM modeliyle gerçekleştiren test işlemi %96,91 doğruluk elde etmiştir. KNN modelinde ise verilen K değerleri için en iyi %97,40 test doğruluğu elde edilmiştir.

2021, 59 sayfa

ANAHTAR KELİMELER: COVID-19, Derin Öğrenme, Makine Öğrenmesi, CNN, KNN, ANN, SVM, Bilgisayarlı Tomografi.

ABSTRACT

Master of Science Thesis

DEEP LEARNING FROM COMPUTERIZED TOMOGRAPHY IMAGES AND DIAGNOSIS OF COVID-19 WITH MACHINE LEARNING

Gözde KAHRAMAN

Çankırı Karatekin University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering

Supervisor: Assist. Prof. Dr. Zafer CİVELEK

COVID-19 disease has become an epidemic that spread rapidly in a short time and caused many people to get sick and die. Rapid detection of the disease is of great importance in controlling the Covid-19 disease and reducing the transmission. Lung imaging procedures constitute an important part of the diagnosis of COVID-19 disease. In this study, a data set containing a total of 7200 images was created from the lung images of the Computed Tomography device, which has not been used in any study before. Computed Tomography images were selected from patient data reported with the help of radiology doctors and radiology technicians from all adult patients between March 2020 and November 2020. The binary classification method was used in the study. For the diagnosis of the disease, validation and testing processes were carried out in Convolutional Neural Networks from Deep Learning methods, Artificial Neural Network (ANN) from Machine Learning algorithms, Support Vector Machine (SVM), K-Nearest Neighbor (KNN) algorithms. As a result of the studies, 99.77% accuracy and 97.78% test accuracy were obtained for the CNN architecture Xception model during the training phase. For the ANN model, 98.98% accuracy and 97.68% test accuracy were obtained during the training phase. The test process performed with the SVM model achieved 96.91% accuracy. In the KNN model, the best test accuracy of 97.40% was obtained for the given K values.

2021, 59 pages

KEY WORDS: COVID-19, Deep Learning, Machine Learning, CNN, KNN, ANN, SVM, Computed Tomography.

TEŞEKKÜR

Çalışmalarımda desteklerini esirgemeyen bilgilerini bana aktaran çok değerli danışman hocam Sayın Dr. Öğr. Üyesi Zafer CİVELEK'e emeği ve katkılarından dolayı teşekkürü bir borç bilirim.

Çankırı Özel Karatekin Hastanesi Müdürü Sayın Önder İZMİRLİOĞLU'na, Radyoloji Bölümü Uzman Doktoru Sayın Recep ER'e, Radyoloji Teknikeri Sayın Erkan KULOĞLU'na ve tüm Radyoloji bölümü çalışanlarına teşekkürlerimi ve saygılarımı sunarım.

Tez çalışmamın her aşamasında desteklerini esirgemeyen değerli babam Serdar KAHRAMAN'a ve arkadaşlarıma sevgi ve saygılarımı sunarım.

COVID-19 hastalığından dolayı kaybettiğimiz tüm insanlara ve erken yaşta aramızdan ayrılan annem Zeynep KAHRAMAN'a…

Gözde KAHRAMAN

Çankırı, 2021

İÇİNDEKİLER

ÖZET.....i

ABSTRACT.....ii

TEŞEKKÜR.....iii

SİMGELER DİZİNİ.....vi

ŞEKİLLER DİZİNİ.....vii

ÇİZELGELER DİZİNİ.....viii

İÇİNDEKİLER iv

ŞEKİLLER DİZİNİ vii

1. GİRİŞ ……1

1.1 Yapay Zeka……... 3

1.2 Makine Öğrenmesi……... 4

1.3 Derin Öğrenme……. 5

1.4 Tek Katmanlı Algılayıcılar…….. 6

1.5 Çok Katmanlı Algılayıcılar……..6

1.6 COVID-19 Hastalığının Teşhisi İçin Tıpta Kullanılan Görüntüleme Teknikleri……8

1.6.1 Röntgen x-ray görüntüleme……8

1.6.2 Bilgisayarlı tomografi…… ..9

2. KAYNAK ÖZETLERİ……...10

3. MATERYAL VE YÖNTEM……. 17

3.1 COVID-19 Hastalığının Teşhisi İçin Kullanılan Programlama Dilleri……. 18

3.1.1 COVID-19 Hastalığının teşhisi için kullanılan kütüphaneler…… 19

3.1.2 Tensorflow……...19

3.1.3 Keras…… 19

3.1.4 Numpy……..20

3.1.5 Pandas……..20

3.1.6 Scikit-learn…….. 20

3.1.7 Matplotlib…… 20

3.2 Evrişimli Sinir Ağları (CNN)……21

3.2.1 Evrişim katmanı……. 21

3.2.2 Havuzlama katmanı……23

3.2.3 Tam bağlı katman……...24

3.2.4 Doğruluk ve kayıp değerleri…….. 24

3.2.5 Evrişimli sinir ağlarında kullanılan temel aktivasyon fonksiyonları…… 25

3.2.6 Xception mimarisi……... 26

3.2.7 VGG-16 mimarisi……... 27

3.2.8 Resnet-50 mimarisi……28

3.2.9 DenseNet-201 mimarisi…….. 29

3.2.10 Inception-v3 mimarisi…… 30

3.2.11 Inceptionresnetv2 mimarisi……... 31

3.2.12 Yapay Sinir Ağları (YSA)……..32

3.2.13 K En Yakın Komşuluk Algoritması (KNN)……34

3.2.14 Destek Vektör Makinaları (SVM)……35

3.2.15 Performans Ölçütleri……... ..36

3.2.16 Karışıklık matrisi (Confusion matrix)……..36

4. BULGULAR……39

4.1 CNN Modellerinden Elde Edilen Bulgular…….. 39

4.2 YSA Modellinden Elde Edilen Bulgular……...43

4.3 KNN ve SVM Modelinden Elde Edilen Bulgular…… 44

5. SONUÇ VE TARTIŞMA……... 48

KAYNAKLAR……...50

EKLER……... 55

ÖZGEÇMİŞ……... 59

SİMGELER DİZİNİ

AUC	Eğrinin Altındaki Alan
BT	Bilgisayarlı Tomografi
CNN	Evrişimli Sinir Ağları
COVID-19	Koronavirüs-19 hastalığı
CT	Bilgisayarlı Tomografi
CPU	Merkezi İşlem Birimi
DL	Derin Öğrenme
DSÖ	Dünya Sağlık Örgütü
DNN	Derin Sinir Ağı
ELM	Ekstra Makine Öğrenmesi
GPU	Grafik İşlem Birimi
HTIL	İnsan Döngüsü Stratejisi
KNN	K En Yakın Komşuluk
ML	Makine Öğrenmesi
MAE	Ortalama Mutlak Hata
M-RNA	Mesajcı RNA
PCR	Polimeraz Zincir Reaksiyonu
POI	Enfeksiyon Yüzdesi
RNA	Ribonükleik Asit
ROC	Alınan Çalışma Özelliği
SVM	Destek Vektör Makinesi
TPU	Tensor İşlem Birimi
YSA	Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

Şekil 1.1 Yapay zekanın venn şeması ile gösterimi……..…..….....3
Şekil 1.2 İki giriş ve tek çıkıştan oluşan temel tek katmanlı algılayıcı modeli.....6
Şekil 1.3 Üç giriş ve tek çıkıştan oluşan temel çok katmanlı algılayıcı modeli.....7
Şekil 1.4 Örnek akciğer röntgen görüntüsü……...…….....……..8
Şekil 1.5 Örnek akciğer bilgisayarlı tomografi görüntüsü .……..…….….....9
Şekil 3.1 Veri setinden örnek görüntüler …….…….……....…….....17
Şekil 3.2 Veri setinin grafiksel gösterimi ……..…..…….....18
Şekil 3.3 CNN mimarisinin temel katmanları…….....…...…..…...….....21
Şekil 3.4 Konvülasyon işleminin temel gösterimi….....…….……....22
Şekil 3.5 Evrişim işleminin temel gösterimi……...…..……...…….....22
Şekil 3.6 Maksimum havuzlama……..…...……..…....…...……..…....23
Şekil 3.7 Düzleştirme işlemi ve tam bağlı katman…...….....24
Şekil 3.8 Aktivasyon fonksiyonlarının grafiksel gösterimi….…….....26
Şekil 3.9 Xception mimarisinin katmanları ……...…..…….…….....27
Şekil 3.10 VGG-16 mimarisinin katmanları ……..….....28
Şekil 3.11 Tüm resnet mimarilerinin katmanları……..…….....29
Şekil 3.12 Tüm densenet mimarilerinin katmanları……..…..….....30
Şekil 3.13 Inception-v3 mimarisinin katmanları …….....…….....31
Şekil 3.14 Inceptionresnet-v2'nin temel ağ mimarisi …….…….....32
Şekil 3.15 Yapay sinir ağı hücrelerinin bağlantılarının gösterimi……..….....33
Şekil 3.16 Yapay sinir ağları temel mimari örneği…….....…....33
Şekil 3.17 Karışıklık matrisi için performans ölçümleri…….....……...36
Şekil 4.1 CNN mimarilerinin karışıklık matrisleri …….……..…….....41
Şekil 4.2 CNN mimarilerinin roc grafikleri…….…….....42
Şekil 4.3 YSA modelinin roc grafiği……...……...….....….....43
Şekil 4.4 Tüm k değerleri için doğruluk grafiği…….….....45

ÇİZELGELER DİZİNİ

Çizelge 1.1 Dünya Sağlık Örgütü 16 Ağustos 2021 tarihinde dünya ülkelerinin doğrulanmış vaka ve ölüm sayıları……..…….....….....2

Çizelge 4.1 Tüm cnn modelleri için precision, recall ve f-score değeri……..…….....40

Çizelge 4.2 YSA modeli için precision, recall ve f-score değeri……..……...44

Çizelge 4.3 K=1 değeri için sonuç tablosu…….……..…45

Çizelge 4.4 K=3 değeri için sonuç tablosu……..…46

Çizelge 4.5 K=5 değeri için sonuç tablosu……..…….…….…....46

Çizelge 4.6 K=10 değeri için sonuç tablosu…….…...…….…….....…46

Çizelge 4.7 K=20 değeri için sonuç tablosu…….…….…….…….....47

Çizelge 4.8 K=50 değeri için sonuç tablosu…….…….…….....….47

Çizelge 4.9 K=100 değeri için sonuç tablosu…….……..……..……47

Çizelge 4.10 SVM için precision, recall ve f-score değerleri…….……...…….....48

1. GİRİŞ

Yeni Koronavirüs Hastalığı (COVID-19), ilk olarak 2019 yılı aralık ayı sonlarına doğru Çin'in Wuhan Eyaleti'nde ortaya çıkmıştır. Hastalık ilk olarak Wuhan Eyaletindeki deniz ürünleri ve hayvan pazarında bulunan bir grup kişide tespit edilmiştir. Bir grup hastada yapılan araştırmalar sonucunda solunum yolu şikayetleri görülmüş, nefes darlığı, ateş, öksürük gibi bulgular gözlemlenmiştir. Hastalık 13 Ocak 2020'de tanımlanmıştır. Salgın Wuhan eyaletinden, Hubei eyaletine oradan Çin Halk Cumhuriyeti'nin tüm eyaletlerine ve diğer tüm Dünya ülkelerine yayılmış, pandemi haline gelmiştir. COVID-19 insanlarda ya da hayvanlarda hastalığa neden olmaktadır. COVID-19 hastalığı şiddetli akut solunum yolu sendromu koronavirüsü 2 (SAR-CoV-2) virüsünden kaynaklanmaktadır. Virüs pozitif yönelimli ve tek iplikli RNA virüsüdür. Pozitif yönelimli RNA ve mRNA birbirlerine benzerler. Bu da konak hücre ribozomları tarafından doğrudan tanınmasını sağlar. COVID-19 hastalığının temel belirtileri arasında nefes darlığı, öksürük, ateş yer almaktadır. Hastalık şiddetlendikçe zatürre, ağır solunum yetmezliği, böbrek yetmezliği ve ölüm meydana gelebilmektedir. Hastalık hasta kişilerin solunum parçacıklarının sağlıklı kişiler tarafından solunması veya parçacıkların yüzeylere bulaşması sonucunda sağlıklı kişiler tarafından temas etmesiyle bulaşmaktadır (Yang *et al.* 2020, Brunese *et al.* 2020, Wang *et al* 2020). COVID-19 hastalığı sebebiyle Dünya Sağlık Örgütünün (DSÖ) 16 Ağustos 2021 tarihli verilerine bakıldığında dünya genelinde doğrulanmış 206.958.371 vaka ve 4.357.179 ölüm gerçekleştiği görülmektedir (https://covid19.who.int/, 2021).

Çizelge 1.1'deki verilerde de görüldüğü üzere hastalık başladığı günden beri giderek daha çok insana bulaşmakta ve ölümlere yol açmaktadır. Çok hızlı yayılım gösterdiği için hastalığın hızlı teşhisi sağlıklı kişilere bulaşma riskini azaltmaktadır. Günümüzde COVID-19 teşhisi için en çok Polimeraz Zincir Reaksiyonu (PCR) testi kullanılmaktadır (Boeckmans *et al.* 2021). PCR testinin yanı sıra hastalığın teşhisinde akciğerlerin görüntülenmesi için bilgisayarlı tomografi cihazı ve x-ray ışınlarıyla görüntüleme işlemleri de gerçekleştirilmektedir (Li and Xia 2020). Çizelge 1.1'de 16 Ağustos 2021 tarihinde DSÖ tarafından yayımlanan en çok doğrulanmış vaka sayısına sahip on iki

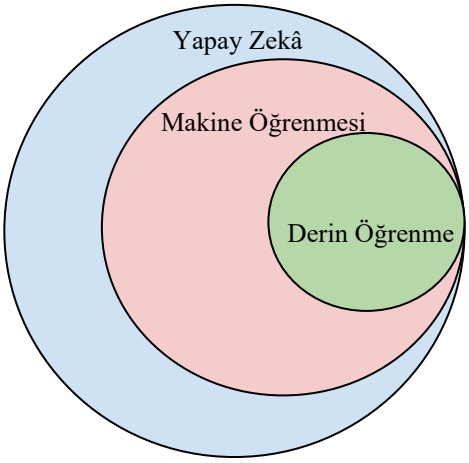
ülkenin vaka ve ölüm sayıları verilmiştir. Çalışmada yapay zeka uygulamaları ile COVID-19 hastalığının teşhisi gerçekleştirilmiştir.

Çizelge 1.1 Dünya Sağlık Örgütü 16 Ağustos 2021 tarihinde dünya ülkelerinin doğrulanmış vaka ve ölüm sayıları (https://covid19.who.int/, 2021).

Ülke Adı	**Doğrulanmış vaka sayısı**	**Doğrulanmış ölüm sayısı**
Amerika	36.385.257	615.747
Hindistan	32.225.513	431.642
Brezilya	20.350.142	568.788
Fransa	6.287.203	111.400
Türkiye	6.059.806	53.005
Rusya	4.940.245	115.871
İngiltere	4.448.855	127.675
İtalya	4.435.008	128.413
İspanya	4.710.009	82.538
Almanya	3.821.013	91.867
Arjantin	5.080.908	108.936
Kolombiya	4.864.629	123.356

1.1 Yapay Zeka

Yapay zeka temel olarak insanlar tarafından gerçekleştirilen düşünsel faaliyetlerin otonom hale getirilmesi işlemidir. Yapay zekanın teknolojik uygulamaları başka bilgisayar tabanlı sistemler ile birleşerek bilgisayarların etki alanlarını da arttırmaktadır. Yapay zekanın temel amacı makinaların daha akıllı ve etkin hale getirilmesidir. Yapay zeka çalışmaları ilk olarak 1884 yılında Bilim İnsanı Charles Babbagenin makinalara zeki davranışlar kazandırmak için çalışmalar yapmasıyla başladı. 1930'lu yıllara yaklaşıldığında makinalara zeki davranış kazandırma çalışmalarında karşılaşılan esas sorun işlemlerin belirli sıralamalarla gerçekleşmemesiydi. İkinci Dünya Savaşı devam ederken savaş sırasında Almanların kullandığı Enigma makinesinin şifrelerini çözebilmek için birçok bilim insanı çalışmalar yapmaktaydı. Bu çalışmalar sırasında Allan Mathinson Turingin prensipleri doğrultusunda oluşturduğu bilgisayar prototipi Healt Robinson Yapay zeka kavramının temelini oluşturmuştur. Yapay zeka makine öğrenmesi ve derin öğrenmeyi içinde barındıran geniş bir alanı temsil etmektedir. Şekil 1.1'de Yapay zekanın venn şeması ile gösterimi verilmiştir.



Şekil 1.1 Yapay zekanın venn şeması ile gösterimi

1.2 Makine Öğrenmesi

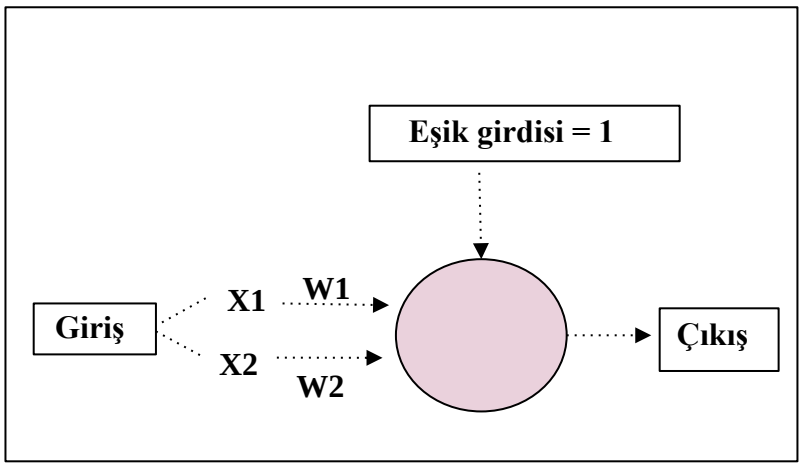
Makine öğrenmesi insanlar tarafından öğretilen kavramları yerine getiren bilgisayarların öğretilenlerin ilerisinde kendi kendilerine öğrenme işlemini gerçekleştirmesine dayanmaktadır. Bilgisayarların öğrenme işlemini gerçekleştirebilmesi için yeterince bilgiye sahip olmaları gerekir. Bilgilerin bilgisayarlara öğretilebilmesi için sistem ilk olarak bir örnek üzerinden verinin özelliklerini öğrenir. İlk örnekten sonra yeni gelen örnek ile bilgilerini bir miktar daha arttırır. Sisteme yeni örnekler geldikçe bilgilerini ve öğrenme işlemini veriler arasında bağıntılar kurarak ilerletir. Makine öğrenmesinde genel olarak büyük ve karmaşık veri setleri kullanılmaktadır. Makine öğrenmesinde sisteme ne kadar fazla örnekle eğitim sağlanırsa sistemin öğrenme oranı da o doğrultuda artar. Makine öğrenmesi teknikleri temelde üç guruba ayrılır; Denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme. Denetimli öğrenme de veriler sisteme verilmeden önce etiketlenirler. Etiketleme işlemi sayesinde sistem etiketlere göre verileri öğrenerek tahminler yapar. Denetimsiz öğrenmede veriler sisteme verilmeden önce herhangi bir etiketleme yapılmaz. Kümeleştirilen veriler gruplandırılırlar. Gruplar arasında çeşitli ilişkiler bulunur. Sistem kümeleştirilen veri grupları ile öğrenme ve test işlemlerini gerçekleştirir. Pekiştirmeye dayalı öğrenmede sistemler bilgileri sonuçlardan öğrenirler. Algoritmanın gerçekleştirdiği işlemler sonrasında işlemin doğruluğu için sistemden geri bildirim alır. Makine öğrenmesinin farklı birçok türü mevcuttur. Genel olarak değerlerin tahmininde regresyon ve zaman serisi algoritmaları, kümeleme ve sınıflandırma algoritmaları, hedef verinin tahmini algoritmaları kullanılmaktadır. Hedef verinin tahmini için veriler sınıflara ayrılırlar. Sınıflar ikili ya da çoklu olabilirler. Regresyon algoritmaları hafızasındaki veriler doğrultusunda yeni veriyi tahmin etmeye çalışırlar. Zaman serisi algoritmaları verilerin belirli bir süre içindeki değişimi doğrultusunda oluşan döngüselliği belirleyerek tahminler yaparlar. Kümeleme algoritmaları veriler arasındaki benzerlik oranlarına göre verileri gruplara ayırırlar. Sınıflandırma algoritmaları önceden etiketlenmiş verilerin hangi sınıfa ait olduğunu tahmin etmeye çalışırlar.

1.3 Derin Öğrenme

Derin öğrenme insanın öğrenme biçimini örnek alır. İnsanın sinir hücreleri ve hücreler arasındaki öğrenme bağlantısı yapay hale getirilerek makinelere insan beyni gibi öğrenme işlemini taklit ettirmeyi amaçlamaktadır. Derin öğrenme makine öğrenmesinin bir alt kümesidir. Derin öğrenmede birbirini takip eden katmanlarda veriler işlenirler. Derin öğrenme modellerindeki katman sayıları modelin derinliğini belirler. Derin öğrenmedeki katmanlı ağ yapısı sinir ağları ile öğrenme gerçekleştirir. Derin öğrenme algoritmaları yapısal olarak yapay sinir ağlarından daha karmaşıktır. Genel olarak öğrenme, hafızada depolama, veriler arasında bağıntı kurma işlemleri gerçekleştirilir. Derin öğrenmede sistem ağa girdi olarak verildikten sonra çeşitli katmanlardan geçer. Katmanlarda gerçekleştirilen işlemler sırasında bilgileri öğrenir, bu bilgiler sayesinde tahminler gerçekleştirir. Veriler katmalarda gerçekleştirilen işlemlerde katmanların ağırlıkları ile değiştirilirler. Ağın çıkışındaki verinin kontrolü için temelde beklenen sonuç ile ağın verdiği sonuç arasında kıyaslama gerçekleştirilir. İki sonuç arasında elde edilen farka kayıp fonksiyonu denilmektedir. Kayıp fonksiyonu beklenen sonuç ile ağın elde ettiği sonuç arasındaki fark doğrultusunda ağın doğruluk oranını hesaplar. Derin öğrenmede kayıp fonksiyonu sayesinde ağdaki kayıpları azaltmak için ağırlık matrisleri güncellenmesi gerçekleştirilir. Bu güncellenme işlemine geriye yayılım adı verilir. Makine öğrenmesinde verilerin özellikler manuel olarak çıkarılırken derin öğrenme modellerinde manuel olarak özellik çıkarımına ihtiyaç duyulmaz. Özellikler otomatik olarak çıkarılırlar. Makine öğrenmesi daha basit ve sade ağ yapısına sahipken derin öğrenme yüksek miktarlarda verilerle çalışarak çoklu işlemler gerçekleştiren karmaşık bir ağ yapısına sahiptir. Bundan dolayı yüksek hesaplama gücüne sahip donanımlara ihtiyaç duyar. Çeşitli derin öğrenme mimarileri mevcuttur. Evrişimli sinir ağları, tekrarlayan sinir ağları, uzun ve kısa hafızaya sahip sinir ağları, derin inanç ağları derin öğrenme mimarilerindendir. Derin öğrenme ile doğal dil işleme, görüntü-video işleme, biyomedikal sinyalleri ve görüntüleri işleme ve daha birçok alanda çalışmalar gerçekleştirilmektedir. Çalışma alanları yeni araştırmalar sayesinde giderek artmaktadır.

1.4 Tek Katmanlı Algılayıcılar

Tek katmanlı yapay sinir ağları giriş ve çıkış katmanlarından oluşur. Yapay sinir ağlarının bir veya daha fazla girişi ve çıkışı vardır. Her nöron birbirine bağlıdır. Her bağlantı bir ağırlık değerine sahiptir. Ağın içerisinde bir eşik değeri yer alır. Eşik değeri çıkış değerinin 0 değeri almasını engellemektedir. Eşik değeri tek katmanlı algılayıcılarda daima 1 değerini almaktadır. Çıkış değerine ulaşmak için giriş değerleri eşik değeri ile toplanır ve bir aktivasyon fonksiyonundan geçerler. Çıkış fonksiyonu bir doğrusal fonksiyondur. Şekil 1.2'de tek katmanlı algılayıcı modeli verilmiştir. Şekildeki x1ve x2 değerleri girişleri w1 ve w2 değerleri ise ağırlıklarını temsil etmektedir.

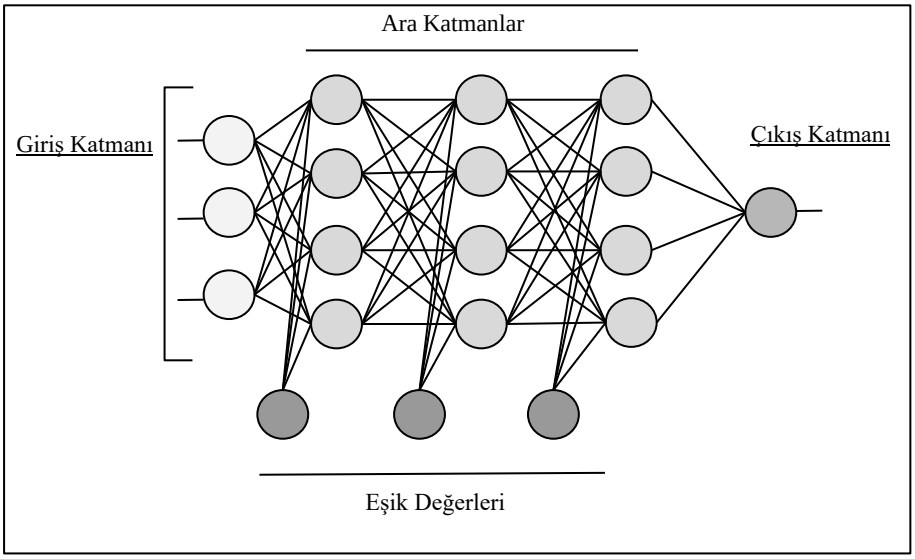


Şekil 1.2 İki giriş ve tek çıkıştan oluşan temel tek katmanlı algılayıcı modeli

1.5 Çok Katmanlı Algılayıcılar

Tek katmanlı algılayıcılarda giriş ve çıkış arasında doğrusal bir ilişki vardır. Doğrusal ilişkinin olmadığı durumlarda daha karmaşık öğrenme modelleri gereklidir. XOR problemi ile ilgili basit algılayıcının çözüm üretmediği görülmüş, bu problemi çözebilmek için Rumelhart ve arkadaşları çok katmanlı algılayıcı modelini geliştirmiştir (Rumelhart *et al.* 2013). Bu model sınıflandırma, tanıma problemlerinde oldukça

başarılıdır. Çok katmanlı algılayıcılar üç temel katmandan oluşmaktadır. Şekil 1.3'te çok katmanlı algılayıcı modeli verilmiştir.



Şekil 1.3 Üç giriş ve tek çıkıştan oluşan temel çok katmanlı algılayıcı modeli

Giriş Katmanı: Yapay sinir ağının dışardan gelen verilerin ağa alındığı kısımdır. Bir veya birden fazla veri girişi olabilmektedir. Giriş katmanındaki her proses elemanı ara katmandaki proses elemanlarına bağlıdır. Giriş katmanındaki tüm veriler ara katmana iletilir.

Ara katman: Giriş kısmından aktarılan veriler bu katmanda işlenirler. Ağda birden fazla ara katman yer alabilir. Ara katmandaki tüm veriler çıkış katmanına aktarılır.

Çıkış katmanı: Ara katmandan iletilen veriler işlenerek her giriş verisine karşılık bir çıkış verisi olacak şekilde belirlenir.

1.6 COVID-19 Hastalığının Teşhisi İçin Tıpta Kullanılan Görüntüleme Teknikleri

COVID-19 hastalığının akciğerlerdeki hastalık durumun görüntülenmesi ve hastalığın teşhis edilebilmesi için farklı görüntüleme teknikleri kullanılmaktadır. Görüntüleme işlemleri için temel olarak akciğer röntgen x-ray görüntüleme, bilgisayarlı tomografi cihazı ile görüntüleme temel olarak kullanılan yöntemlerdendir.

1.6.1 Röntgen x-ray görüntüleme

X-ray görüntüleme Wilhelm Conrad Röntgen'in 1985 yılında x-ışını buluşuyla kullanılmaya başlanmıştır. Röntgen x ışınları aracılığıyla vücudun bazı bölgelerinin görüntülenmesini sağlamaktadır. COVID-19 hastalığının teşhisinde akciğer röntgen görüntüleri kullanılmaktadır. Akciğer röntgeni COVID-19 hastaları veya hastalık şüphesi taşıyan kişilerin göğüs boşluğunun görüntülenmesi ve değerlendirilmesi için en sık kullanılan yöntemlerden biridir. Şekil 1.4'te örnek akciğer röntgen görüntüsü verilmiştir (Sümer *et al.* 2018).



Şekil 1.4 Örnek akciğer röntgen görüntüsü (Sümer *et al.* 2018)

1.6.2 Bilgisayarlı tomografi

Bilgisayarlı tomografi cihazı insan vücudunu z-ray ışınlarıyla tarayarak detaylı görüntüler elde eder. Dilim görüntüleme tekniklerini kullanarak görüntülerin katmanlar haline getirilip ayırt etmesi ile görüntülenmesini sağlamaktadır. Bu cihaz hastanın tam bir dairesel tarama ile farklı açılardan görüntülenmesini gerçekleştirmektedir. COVID-19 hastalığının teşhisinde akciğerlerin bilgisayarlı tomografi cihazıyla görüntülenmesi en sık kullanılan görüntüleme yöntemlerinden biridir. Şekil 1.5'te örnek akciğer bilgisayarlı tomografi görüntüsü verilmiştir (Savas 2015).



Şekil 1.5 Örnek akciğer bilgisayarlı tomografi görüntüsü (Savas 2015)

2. KAYNAK ÖZETLERİ

Fei Shan ve arkadaşları COVID-19 hastalığının teşhisi için göğüs bilgisayarlı tomografi görüntülerinden otomatik segmentasyon için derin öğrenme tabanlı sistem geliştirmişlerdir. Derin öğrenme tabanlı segmentasyonları için "VB Net" sinir ağını kullanmışlardır. Bilgisayarlı tomografi görüntüleri ile COVID-19 hastalığının enfeksiyon bölgelerini segmentlere ayırmak için 249 COVID-19 görüntüsü kullanarak eğitim gerçekleştirmişlerdir. Eğitim için bilgisayarlı tomografi görüntülerinin tanımlanması döngüsünde (HITL) stratejisini benimsemişlerdir. Derin öğrenme tabanlı sistemlerini zar benzerlik katsayısı, hacim, yüzde farklılıkları, enfeksiyon (POI), otomatik ve manuel segmentasyon sonuçları arasından hesaplamışlardır. Önerdikleri sistem, zar benzerlik katsayısı s'yi otomatik ve manual segmentasyonda sırasıyla %91,6 %10,0 olarak elde etmiştir. Otomatik ve manuel segmentasyon s ve tamamı için %0,3'lük bir ortalama POI tahmin hatası elde etmiştir. Doğrulama veri seti tam manuel tanımlama durumlarıyla karşılaştırıldığında genellikle 1 ile 5 saat zaman almaktadır. Önerdikleri döngü stratejisindeki 3 model güncelleme yinelemesiyle birlikte tanımlama süresini 4 dakikaya düşürmüştür. Veri setlerinde hastaların ön ve arka röntgen görüntülerinden vakalar yer almaktadır. Halka açık veri kümesinin kullanıldığı çalışmanın sonucunda %96,3 doğruluk ve 0,151 kayıp elde etmişlerdir. Dünya çapında farklı vakalardan oluşturdukları veri seti görüntülerinde çalışılan derin öğrenme modelini üç yanlış pozitif ve bir yanlış negatif vaka olarak tanımlamışlardır. COVID-19 hastalığının teşhis modelini otomatik hale getirmişlerdir (Shan *et al*. 2020).

Chuansheng Zheng ve arkadaşları bilgisayarlı tomografi görüntülerinden COVID-19 hastalığının teşhisi için otomatik derin öğrenmeye dayalı bir model geliştirmişlerdir. COVID-19'u tespit etmek için 3D CT hacimleri kullanmışlardır. Her vaka için akciğer bölgesi önceden eğitilmiş bir UNet kullanılarak bölümlere ayırılmış segmentli 3D akciğer bölgelerini COVID-19 vakalarının bulaşma olasılığını tahmin etmek için bir 3D derin sinir ağı ile beslemişlerdir.13 Aralık 2019'dan 23 Ocak 2020'ye kadar toplanan 499 CT hacmini eğitim için, 24 Ocak 2020 ile 6 Şubat 2020 arasında toplanan 131 CT hacimlerini test için kullanılmışlardır. Derin öğrenme algoritmaları 0,959 ROC AUC ve 0,976 PR

AUC doğruluk elde etmiştir. COVID-pozitif ve COVID-negatif olarak yapılan sınıflandırma algoritmaları 0,901 doğruluk sağlamıştır. Pozitif 0,840 tahmin değeri ve 0,982 negatif tahmin değeri elde etmişlerdir. Algoritmaları özel bir GPU kullanarak tek bir hastanın CT hacmini işlemek için 1,93 saniye süreye ihtiyaç duymuştur (Zheng *et al*. 2020).

Joseph Paul Cohen ve arkadaşları ön göğüs röntgeni görüntülerinden COVID-19 pnömonisinin teşhisi için skor tahmin modeli sunmuşlardır. Çalışmaları COVID-19 akciğer enfeksiyonlarının ve genel olarak zatürree hastalığının şiddetini ölçmeyi amaçlamıştır. Herkese açık bir COVID-19 veri tabanından alınan görüntüler üç uzman tarafından geriye dönük puanlanarak etiketlendirilip veri setlerini oluşturmuşlardır. Çalışmaları ön eğitimden elde edilen çıktıların bir alt küme üzerinde regresyon modeli eğitimi sonucunu coğrafi kapsam puanı (0-8 aralığı) 1,14 ortalama ile tahmin etmiştir. Mutlak hata (MAE) ve akciğer opasite skorları (0-6) 0,78 MAE sonuçlarını elde etmiştir (Cohen *et al*. 2020).

Ophir Gozes ve arkadaşları COVID-19 hastalığının teşhisi için çok sayıda uluslararası Bilgisayarlı Tomografi görüntülerinden veri seti oluşturmuşlardır. 2B ve 3B derin öğrenme modellerini kullanarak, mevcut yapay zeka modellerini değiştirip uyarlayan, klinik anlayışla birleştiren bir sistem sunmuşlardır. COVID-19 torasik bilgisayarlı tomografi özelliklerinin saptanarak sistemin performansını analiz edip 3D cilt incelemesi kullanmışlardır. Her hastada hastalığın zaman içindeki evrimini değerlendirerek "Corona skoru" oluşturmak amacıyla geriye dönük deney gerçekleştirmişlerdir. Veri setleri 157 uluslararası hastadan oluşan bir test setini içermektedir. Çalışmaları sonucunda torasik bilgisayarlı tomografi çalışmaları başına koronavirüs ve koronavirüs olmayan vakalar için sınıflandırma sonuçları 0,996 AUC (%95CI: 0.989-1.00) doğruluk elde etmiştir. Çin vakalarında olası çalışma noktası %98,2 duyarlılık, %92,2 özgüllük elde etmiştir (Gozes *et al.* 2020).

D. Javor ve arkadaşları COVID-19 hastalığının teşhisi için basitleştirilmiş bir derin öğrenmeden türetilen makine öğrenimi sınıflandırıcısı geliştirmiştir. Açık kaynaklı 418

hastanın 6868 bilgisayarlı tomografi akciğer görüntülerinden oluşan veri setini eğitim ve doğrulama alt kümelerine ayırmışlardır. 90 hastanın oluşturduğu bağımsız test veri kümesinde %95,6 Area Under The Curve (AUC) genel doğruluk elde etmişlerdir (Javor *et al.* 2020).

Govardhan Jain ve arkadaşları COVID-19 hastalığının hızlı teşhisi için mevcut kaynaklarını ve gelişmiş derin öğrenme tekniklerini kullanarak dört aşamalı derin ağ model tasarımı gerçekleştirmişlerdir. Toplam 1832 x-ray görüntüsünü sağlıklı, bakteri kaynaklı ve diğer virüs kaynaklı olmak üzere sınıflandırmışlardır. Çalışma sonucunda %97,77 sınıflandırma doğruluğu, COVID-19 hastalık teşhisi için %97,14 doğruluk elde etmişlerdir (Jain *et al.* 2020).

Shuo Wang ve arkadaşları COVID-19 hastalığının akciğer bilgisayarlı tomografi görüntülerinden teşhisi için yedi farklı şehirden 5372 görüntü içeren veri seti oluşturmuşlardır. Dört harici doğrulama setinde işlemler gerçekleştirmiş, viral zatürreden %86 AUC diğer zatürreden %87 AUC elde edilmiştir. Sistemleri hastaları yüksek ve düşük risk gruplarına göre ayırmayı başarmıştır (Wang *et al.* 2020).

Y.Pathak ve arkadaşları COVID-19 enfekte hastalarının teşhisi için CNN mimari modelini kullanarak % 96,22 eğitim ve %93,1 test doğruluk oranı elde etmiştir (Gilanie *et al.* 2021).

Zhua Tao ve arkadaşları önceki çalışmalarda kullanılan toplu veri kümelerini ve sağlık kuruluşundan aldıkları yeni görüntüleri birleştirerek veri seti oluşturmuş, farklı derin CNN ağlarında eğitim ve test gerçekleştirmiştir (Zhou *et al.* 2021).

M.Türkoğlu hastalık teşhisi için akciğer bilgisayarlı tomografi görüntülerini ELM tabanlı Derin sinir ağı (ELM-DNN) yöntemini önermiş, CNN ile CT görüntülerinden derin

özellik çıkarımı gerçekleştirmiştir. Hastalığın teşhisinde önerdiği model %98,28 başarıya ulaşmıştır (Turkoglu 2021).

Lu Huang ve arkadaşları COVID-19 hastalığının teşhisi için akciğer bilgisayarlı tomografi görüntülerini hastaların laboratuvar ve klinik tablolarına göre hafif, orta, şiddetli ve kritik olarak sınıflandırmıştır. Çalışma ticari bir yazılım ve takip bilgisayarlı tomografi görüntüleri ile karşılaştırılmasını yapmışlardır (Huang *et al.* 2020).

Shervin Minaee ve arkadaşları çalışmalarında halka açık veri setlerinden 5000 göğüs röntgeni görüntüsünden veri seti oluşturmuşlardır. COVID-19 hastalığını tanımlamak için ResNet18, ResNet50, SqueezeNet ve DenseNet-121 dahil olmak üzere dört popüler konvolüsyonel sinir ağını eğitmek için 200 radyogramdan oluşan bir alt kümede transfer öğrenimi kullanmışlardır. Çalışmaları sonucunda ağlarının çoğu %98 (±%3) duyarlılık oranı elde etmiş, özgüllük oranı yaklaşık %90'a ulaşmıştır *(*Minaee *et al.* 2020).

Song Ying ve arkadaşları COVID-19 hastalığının teşhisi için Çin'in iki şehrindeki hastanelerden COVID-19 tanısı almış 88 hasta, bakteri pnömonisi almış 101 hasta ve sağlıklı 86 kişinin bilgisayarlı tomografi görüntülerinden veri seti oluşturmuşlardır. Hastalığın teşhisi için derin öğrenme yöntemleri ile bilgisayarlı tomografi tanı sistemi geliştirmişlerdir. Çalışmaları sonucunda 0,99 AUC ve 0,93 hassasiyet elde etmişlerdir (Ct 2021).

Halgurd S. Maghdid ve arkadaşları birçok kaynaktan x-ışınları ve CT tarama görüntüleriyle veri seti oluşturmayı amaçlamışlardır. Çalışmalarında veri setlerine Evrişim sinir ağı (CNN) ve modifiye edilerek önceden eğitilmiş AlexNet modeli uygulamışlardır. Çalışılan modellerde %98'e kadar doğruluk ve modifiye edilmiş CNN kullanılarak %94,1 doğruluk sağlamışlardır (Maghdid *et al.* 2020).

Xuehai He ve arkadaşları çalışmalarında sinerjik olarak bütünleştiren bir transfer öğrenme Self-Trans yaklaşımı ile kendi kendine denetimli öğrenme yöntemi

önermektedirler. Self-Trans yaklaşımları 0,85 F1 score ve AUC değerlerini elde etmiştir (He *et al.* 2020).

Ezz El-Din Hemdan ve arkadaşları x-ray görüntüleri ile COVIDX-Net, değiştirilmiş Görsel Geometri Grup Ağı (VGG19) ve Google MobileNet'in ikinci sürümü gibi yedi farklı derin evrişimli sinir ağı modeli ile çalıştırmalarını gerçekleştirmişlerdir. VGG19 ve yoğun evrişim ağı (DenseNet) modelleri, normal ve COVID-19 için sırasıyla 0,89 ve 0,91 f1 değerlerini elde etmiştir (Hemdan *et al.* 2020).

Amine Amyar ve arkadaşları COVID-19 hastalığının teşhisine yardımcı olmak için otomatik bir sınıflandırma segmentasyon aracı sunmuşlardır. Bilgisayarlı tomografi görüntülerinden segmentteki lezyonlar ile pnömoni şiddetinin değerlendirilmesini amaçlamışlardır. Mimarileri üç çözülmüş özellik gösterimi için ortak bir kodlayıcıdan oluşmaktadır. Veri setleri 449 COVID-19, 425 normal, 98 akciğer kanseri ve 397 farklı patoloji türlerinden oluşturulmuştur. Çalışmaları sonucunda segmentasyon için 0,88'den yüksek katsayı ve ROC eğrisi altındaki alan için %97'den yüksek sınıflandırma elde etmişlerdir (Amyar *et al.* 2020).

Muhammad Farooq ve arkadaşı açık erişimli veri setleriyle önceden eğitilmiş CNN mimarisinin ResNet-50 modelinde ince ayar yapmak için 3 farklı adım kullanmış, bu adımlara COVID-ResNet adını vermişlerdir. Çalışmaları tüm sınıflarda %96,23 doğruluk elde etmiştir (Farooq and Hafeez 2020).

Xiaowei Xu ve arkadaşları derin öğrenme teknikleri kullanılarak akciğer bilgisayarlı tomografi görüntüleri aracılığıyla IAVP, sağlıklı vakalar ve COVID-19 tanısı almış vakalardan veri seti oluşturmuşlardır. Veri setlerinde kullandıkları CT görüntülerini Zhejiang'daki belirlenen üç hastaneden oluşturmuşlardır. Veri setleri toplamda 618 CT örneği içermektedir. Çalışmaları tüm bilgisayarlı tomografi görüntü vakaları açısından %86,7 genel doğruluk oranının elde etmiştir (Xiaowei and Jiang 2020).

Md Zahangir Alom ve arkadaşları COVID-19 hastalığının tespiti için transfer öğrenim ile Inception Rezidüel Tekrarlayan evrişimli sinir ağı yaklaşımını önermişlerdir. COVID-19 bulaşmış bölgeleri segmentlere ayırmak için NABLA-N ağ modelini kullanmışlardır. Algılama modelleri, x-ray görüntülerinden yaklaşık %84,67 test doğruluğu ve CT görüntülerinde %98,78 doğruluk elde etmiştir. Çalışmaları sonucunda 1,00 üstün hassasiyet (%95 güven aralığı (GA) 0,95, 1,00) ve F1 puanı 0,97 değerleri elde etmişlerdir (Alom *et al.* 2020).

Aayush Jaiswala ve arkadaşları sınırlı görüntü içeren veri setleri nedeniyle makalelerinde önceden eğitilmiş derin öğrenmeyi kullanmışlardır Teşhis almış hastaları sınıflandırmak için DenseNet201 tabanlı derin transfer öğrenimi (DTL) önermektedirler. Önerdikleri DTL modelinin COVID-19 hastalığının teşhisi üzerindeki performansını değerlendirmek için yaptıkları deneyler sonucunda DTL tabanlı COVID-19 sınıflandırmasının rekabetçi yaklaşımlardan daha iyi performans gösterdiğini elde etmişlerdir (Jaiswal *et al.* 2020).

Eduardo Luza ve arkadaşları göğüs röntgenlerinden COVID-19 hastalığının teşhisi için EfficientNet mimarisini kullanıp çalışmalarını genişletmişlerdir. 13569 göğüs röntgeninden oluşan veri setlerinde sınıflandırmalar yapmışlardır. Çalışmaları sonucunda %93,9 genel doğruluk %96,8 ve %100 pozitif tahmin elde etmişlerdir (Luz *et al.* 2020).

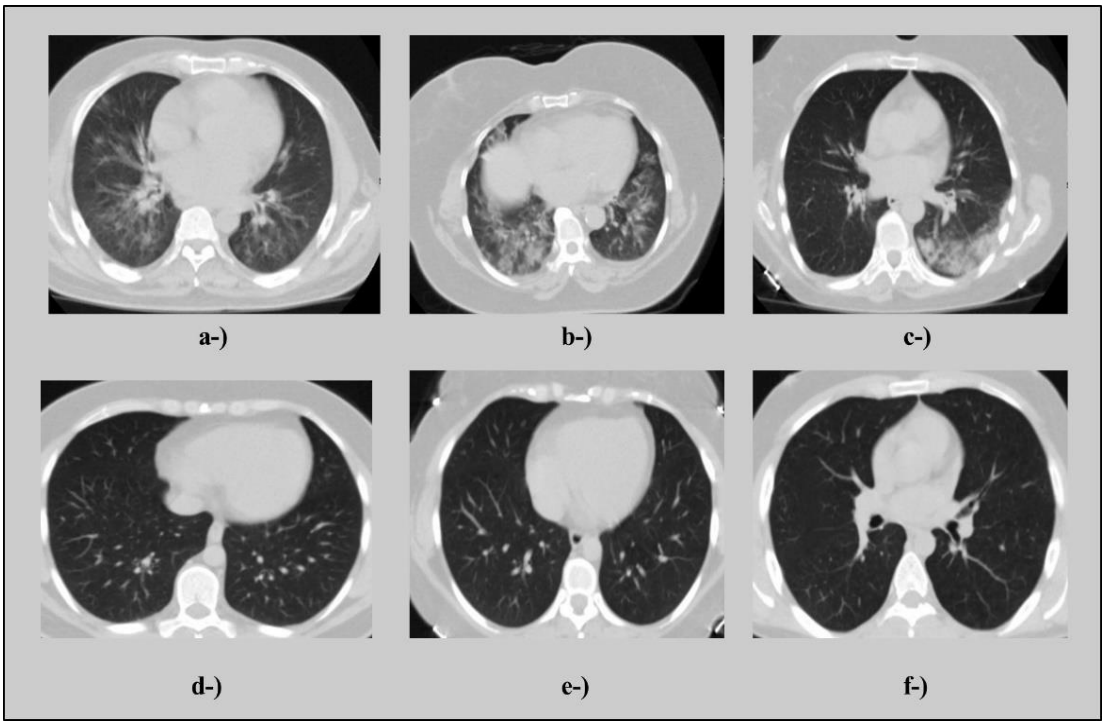
Resul Bütüner ve arkadaşı yapay zeka ve makine öğrenmesi teknikleri ile farklı akciğer tomografilerinden oluşan çok sınıflı veri setlerinde COVID-19 hastalığını teşhis etmeyi amaçlamışlardır. Hastalığın teşhisi için evrişimli sinir ağları ve derin sinir ağları ile makine öğrenmesi algoritması olan k-en yakın komşuluk yöntemlerini kullanmışlardır (Bütüner and Calp 2020).

Shaoping Hu ve arkadaşları COVID-19 hastalığının bilgisayarlı tomografi görüntülerinden teşhisi için zayıf denetimli bir derin öğrenme stratejisi önermişlerdir. Akciğer bilgisayarlı tomografi görüntülerini manuel olarak teşhislerine göre etiketleyerek

sınıflandırmışlardır. CNN mimarilerinden Resnet ve Inception'ı kullanmışlardır. Deneysel bulguları yüksek doğruluk ve AUC elde etmiştir (Hu e*t al*. 2020).

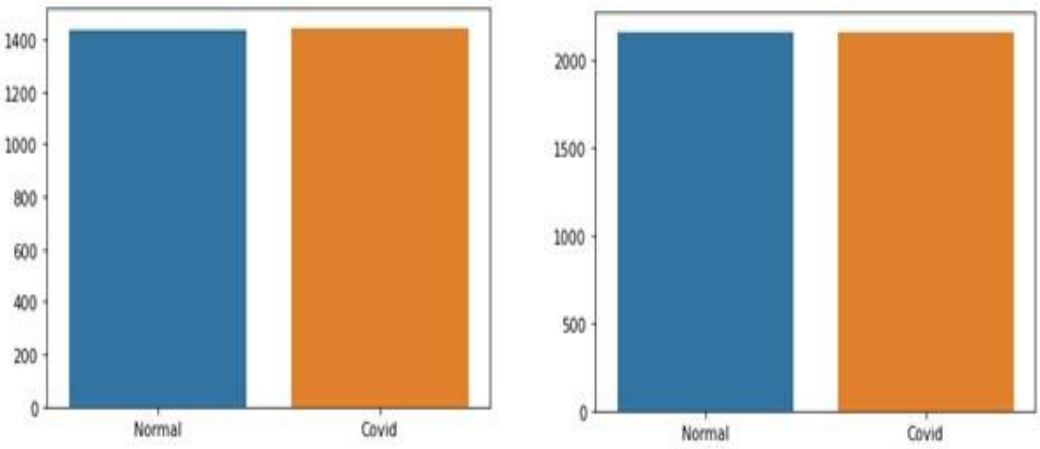
3. MATERYAL VE YÖNTEM

COVID-19 hastalığının yapay zeka ile teşhisi için özel bir hastanenin radyoloji bölümünden radyoloji doktorları yardımıyla tanı almış özgün 7200 akciğer bilgisayarlı tomografi cihazı görüntüsü ile veri seti oluşturulmuştur. Veri setinde yer alan vakalar 2020 mart ve 2020 kasım ayları arasında seçilen erişkin hastaların görüntülerinden düzenlenmiştir. Şekil 3.1'de veri setinde yer alan etiketlenmiş görüntülerden örnekler verilmiştir. Şekil 3.2'de veri setinin grafiksel gösterimi verilmiştir.



Şekil 3.1 Veri setinden örnek görüntüler (a),(b),(c) sağlıklı akciğer görüntüleri (d),(e),(f) covid-19 hastalık tanısı almış akciğer görüntüleri

Veri setindeki toplam görüntü verisinin %60'ı (4320 görüntü) eğitim için %40'ı (2880 görüntü) test işlemleri için kullanılmıştır. Çalışmada iki ayrı sınıf oluşturulmuştur. Bu sınıflardan birincisini kesin COVID-19 tanısı almış görüntüler, ikincisini ise sağlıklı görüntüler oluşturmaktadır. Test görüntü verileri pozitif ve negatif görüntülerden rastgele seçilerek oluşturulmuştur. Şekil 3.2' de veri setinin grafiksel gösterimi yer almaktadır.



(a) (b)

Şekil 3.2 Veri setinin grafiksel gösterimi (a) Covid-19 tanısı almış sağlıklı görüntülerin eğitim veri setinin grafiksel gösterimi (b) Covid-19 tanısı almış sağlıklı görüntülerin test veri setinin grafiksel gösterimi

3.1 COVID-19 Hastalığının Teşhisi İçin Kullanılan Programlama Dilleri

COVID-19 hastalığının teşhisi için çalışmada kullanılan Python yüksek seviyeye sahip nesne yönelimli bir programlama dilidir. Açık kaynaklıdır, basit söz dizilimlerine sahiptir. Derin öğrenme ve makine öğrenmesi yöntemlerinde en çok kullanılan programlama dili Pythondur. COVID-19 hastalığının teşhisi için derin öğrenme ve makine öğrenmesi algoritmalarında Python program dili kullanılmıştır. Yapay zeka uygulamaları büyük veri kümelerine sahiptir. Veri kümelerinin işlenmesi için GPU desteği gerekmektedir. Bu çalışmada programlamalar Google Colaboratory ile gerçekleştirilmiştir. Google Colaboratory ücretsiz olarak Tesla K80 GPU ile Keras, TensorFlow kütüphanelerini kullanarak derin öğrenme uygulamaları gerçekleştirmeyi sağlamaktadır.

3.1.1 COVID-19 Hastalığının teşhisi için kullanılan kütüphaneler

Veri setinde iki sınıfa ayrılarak etiketlendirilmiş akciğer bilgisayarlı tomografi görüntülerinin bilgisayarda işlenebilmesi için Python dilinde çeşitli kütüphanelere ihtiyaç duyulmaktadır. COVID-19 hastalığının teşhisi için derin öğrenme ve makine öğrenmesi uygulamalarında temel olarak TensorFlow, Keras, NumPy, Pandas, Skict-Learn ve Matplotlib kütüphaneleri kullanılmıştır.

3.1.2 Tensorflow

TensorFlow kütüphanesi Google Brain ekibi tarafından geliştirilmiştir. 2015 yılından itibaren makine öğrenmesindeki hesaplamaların gerçekleştirilmesi için ücretsiz ve açık kaynaklı olarak kullanılan makine öğrenme kütüphanesidir. TensorFlow yapay zeka ve makine öğrenmesi çalışmalarında soyutlama açısından büyük avantaja sahiptir. Birden fazla GPU, CPU ve TPU ile çalışabilir.

3.1.3 Keras

Google mühendisi François Chollet tarafından inşa edilmiştir. Derin öğrenme için geliştirilmiş bir Python kütüphanesidir. Açık kaynaklıdır. Sinir ağı modellerinin tasarlanması konusunda kolay kullanıma sahiptir. Evrişimli sinir ağları modellerinin görsel mimarilerini analiz etmede de oldukça başarılıdır. Yeni işlemlerde ve sınıf tanımlamalarında kullanımı kolaydır.

3.1.4 Numpy

Python programlama dilinde çok boyutlu dizi ve matrislerle çalışmayı kolaylaştıran ileri düzeyde matematiksel işlemlerin gerçekleştirildiği bir kütüphanedir. Açık kaynaklı ve numeriktir. Sisteme verilen verilerin işlenmeden önce hazırlanmasını gerçekleştirir.

3.1.5 Pandas

Açık kaynaklı bir kütüphanedir. Veri analizlerini hızlı bir biçimde gerçekleştirir. Sisteme verilen veri analizleri için büyük önem taşır. Verilerin ön işlemelerini yaparak sisteme uygun biçime dönüşmesini sağlar.

3.1.6 Scikit-learn

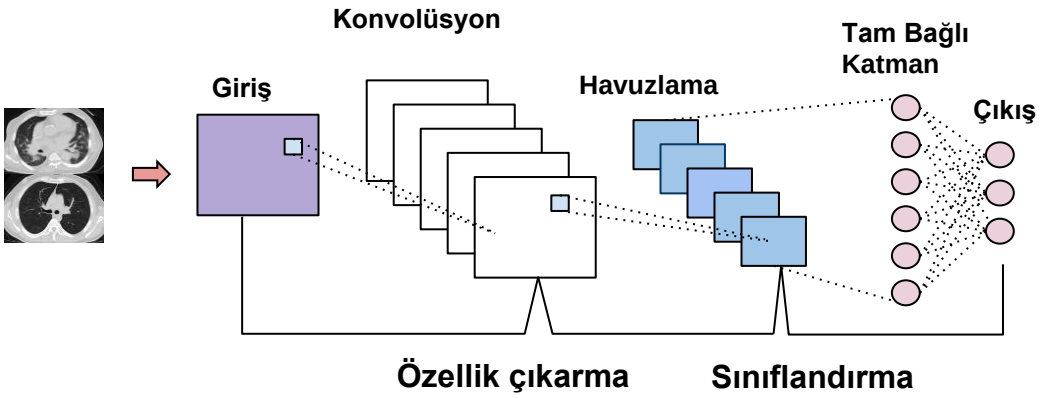
Python programlama dilinde kullanılan ücretsiz bir yazılımdır. Makine öğrenmesi kütüphanesidir. Özellikle sınıflandırma problemlerinde aktif olarak kullanılmaktadır. Pythonun diğer sayısal kütüphaneleriyle uyum içinde çalışabilir.

3.1.7 Matplotlib

Sistem verilerinin görselleştirilmesi için kullanılan Python kütüphanesidir. Ücretsiz ve kolaydır. İki boyutlu çizimlerin yapılmasına olanak sağlar. Çizilen figürlerin tümünün kontrol edilmesine imkân tanır.

3.2 Evrişimli Sinir Ağları (CNN)

Evrişimli Sinir Ağları (CNN), çok katmanlı algılayıcıların düzenlenmiş hali olan bir sinir ağı sınıfıdır. İlk olarak 1960 yılında Hubel ve Wisel tarafından önerilmiştir (Hubel and Wiesel 1962). CNN'ler geleneksel sinir ağlarındaki karmaşıklığı çoklu olarak azaltmışlardır. CNN ağları daha az ön işleme gereksinimi duyduğu için oldukça avantajlıdır. Görüntü tanıma, görüntü sınıflandırma, doğal dil işleme gibi daha farklı birçok alanda uygulamaları mevcuttur (Liu *et al.* 2015, Qian *et al.* 2018). CNN ağları temelde üç ana bölümden oluşur bunlar; Evrişim katmanı, havuzlama katmanı, tamamen bağlı katmandır. Şekil 3.3'te temel CNN mimarisi verilmiştir.

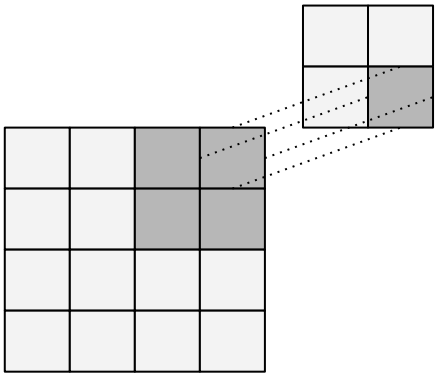


Şekil 3.3 CNN mimarisinin temel katmanları

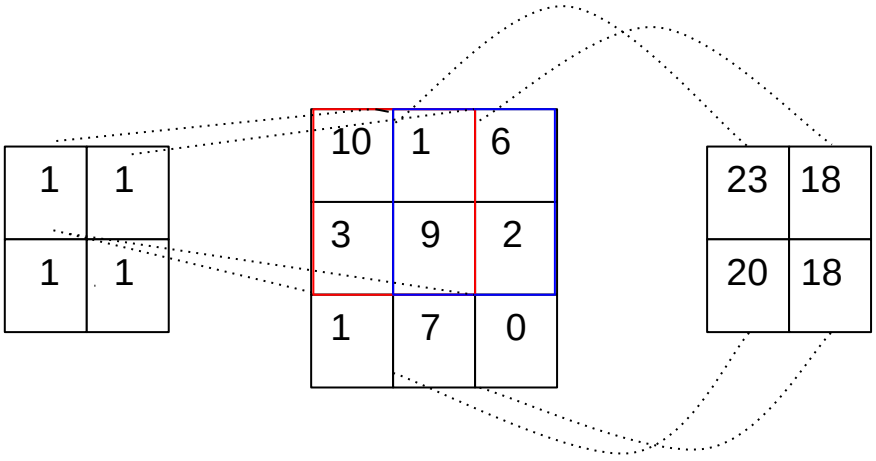
3.2.1 Evrişim katmanı

Giriş katmanı (input) CNN ağlarının girişinden gelen yeni görüntülerin işlenmemiş ham piksel değerlerinin yer aldığı kısımdır. Girişten gelen veriler CNN'in evrişim katmanına aktarılır. Evrişim katmanı konvolüsyon işleminin uygulandığı en temel katmandır (Wei *et al.* 2020). Girişten gelen görüntüler algılanır, görüntülerin özellikleri çıkarılarak haritalanır. Görüntülerin özelliklerinin çıkarılması için görüntüye belirli sayıda filtre uygulanması gerekir. Filtreler görüntülerin üzerinde hareket ettirilerek matris

çarpımlarını gerçekleştirir. Çarpımlardan elde edilen değerler toplanır ve sonuç değeri ortaya çıkarılır. Şekil 3.4'te konvülasyon işleminin temel gösterimi Şekil 3.5'te evrişim işleminin temel gösterimi verilmiştir.



Şekil 3.4 Konvülasyon işleminin temel gösterimi



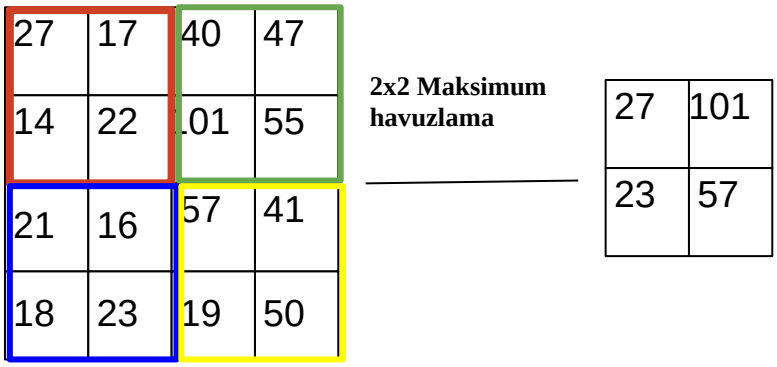
Şekil 3.5 Evrişim işleminin temel gösterimi

Şekil 3.5'te 3x3'lük matris ve 2x2'lik filtrede konvolüsyon işlemi gerçekleştirildiğinde filtre matrisin sol üst köşesinden başlamak üzere sırayla konumlandırılır. İki matris değerleri birbiriyle çarpılarak tüm sonuçlar toplanır. Örneğin 3x3'lük matrisin sol üst köşesinden başlayarak 2x2'lik filtreyle konvolüsyon işlemleri sırasıyla 10.1+1.1+3.1+9.1=23 değerlerinin çarpımı ve toplamlarıyla gerçekleştirildiğinde çıkış

matrisinin sol üst köşe birimi 23 olarak elde edilir. Bu işlemler sağa doğru basamak basamak tekrarlanır. Sırasıyla tüm işlemler gerçekleştirildiğinde 3x3 matrisinden 2x2'lik bir çıkış matrisi elde edilir.

3.2.2 Havuzlama katmanı

Görüntü evrişim katmanından sonra havuzlama katmanına aktarılır. Bu katmanda temel amaç ağdaki parametre sayısının azaltılmasıdır. Parametrelerin azaltılması ağdaki uyumsuzluk kontrolünü de sağlamaktadır. Farklı havuzlama işlemleri mevcuttur. Genel olarak maksimum havuzlama ve ortalama havuzlama kullanılmaktadır. Şekil 3.6'da havuzlama katmanın örneklemesine yer verilmiştir.

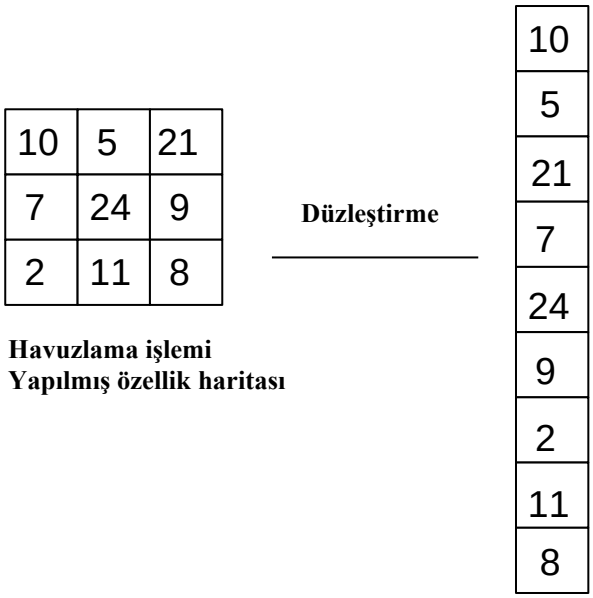


Şekil 3.6 Maksimum havuzlama

Şekil 3.6'da 4x4'lük matrise maksimum havuzlama işlemi uygulandığında filtre kapsadığı alandaki en büyük değeri almıştır. Bu işlem yeterli bilgiyi içeren daha küçük parametrelere sahip olunmasını sağlar.

3.2.3 Tam bağlı katman

Tam bağlı katmanda, kendisinden önceki katmandan gelen nöronlar flatten kısmında birbirlerine tamamen bağlanırlar. Konvolüsyon ve havuzlama katmanından sonra elde edilen matrisin kullanılabilmesi için matrise düzleştirme işlemi yapılır. Düzleştirme işlemi sonucunda tam bağlı katmanın giriş verileri hazır hale gelir. Gizli katmanlardan gelen katsayılar üzerinde işlemler gerçekleştirilir. Katsayı işlemlerinden sonra veriler seçilen yoğunluk fonksiyonu ile bağdaştırılırlar ve çıkış değeri üretirler. Ağın çıkış katmanı sonuç değerlerinin etiketlendiği kısımdır. Şekil 3.7'de düzleştirme işlemi ve tam bağlı katman yer almaktadır.



Şekil 3.7 Düzleştirme işlemi ve tam bağlı katman

3.2.4 Doğruluk ve kayıp değerleri

Herhangi bir CNN ağına verilen veri setine test işleminden hemen önce eğitim işlemi gerçekleştirilir. Ağın verilen verileri ne kadar oranda öğrendiği onun doğruluk değerinin

bir göstergesidir. Eğitim işlemi gerçekleştirilirken tekrarlayan öğrenme işlemi bazı kayıplara yol açar. Eğitim süresince oluşan kayıpların ortalaması kayıp değerini verir.

3.2.5 Evrişimli sinir ağlarında kullanılan temel aktivasyon fonksiyonları

Doğrusal olmayan özelliklerin doğrusallaştırılması için aktivasyon fonksiyonları kullanılır. Çok dereceli fonksiyonlar doğrusal değildir. Yapay sinir ağı mimarilerinde ağırlıklar geri yayılım yaparak hata değerini hesaplar. Aktivasyon fonksiyonu bir nöronun aktif olup olmadığına da karar verir. Aşağıda yaygın olarak kullanılan fonksiyonlar hakkında bilgiler verilmiştir. Şekil 3.8'de Aktivasyon fonksiyonlarının grafiksel gösterimi verişmiştir (Avenash and Viswanath 2019).

Basamak (Step) fonksiyonu: Eşik değeriyle birlikte 0 ya da 1 olarak çıkış değeri üretir

Sigmoid Fonksiyonu: 0 ve 1 aralığında çıkış değerleri üretir.

Tanh Fonksiyonu: -1 ve 1 aralığında çıkış değeri üretir. Doğrusal bir fonksiyon değildir.

Relu Fonksiyonu: Negatif giriş değerleri 0 değeri alır. Pozitif giriş değerleri aynı değerle çıkış değerini oluşturur. Doğrusal bir fonksiyon değildir.

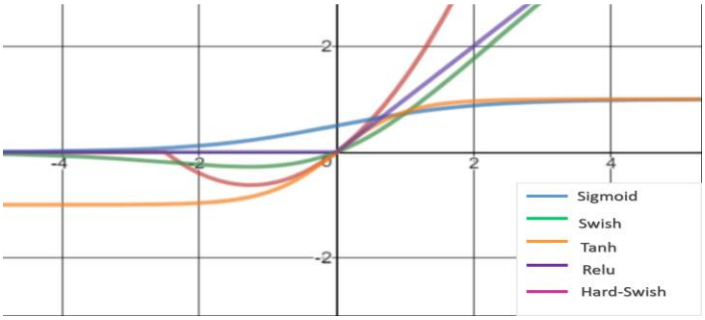
Softmax Fonksiyonu: Her giriş değerinin hangi sınıfa ait olabileceği olasılığıyla 0 ve 1 değerleri arasında çıkış değerleri üretir.

Softplus Fonksiyonu: 0 ve $+\infty$ değerleri arasında türevlenebilen çıkış fonksiyonu üretir.

ELU Fonksiyonu: Üstel doğrusal birimler ve negatif değerler hariç Relu fonksiyonuyla benzer özelliklere sahiptir. Negatif girdilerde alfa parametresini alır.

PRELU Fonksiyonu: Negatif giriş verileri için giriş verileri ekstra alfa sabiti ile çarpılır. Çarpım sonucu elde edilen değer ile çıkış üretilir.

Swish Fonksiyonu: Giriş verileri ile sigmoid fonksiyonunun çarpılması sonucunda çıkış verileri üretir.

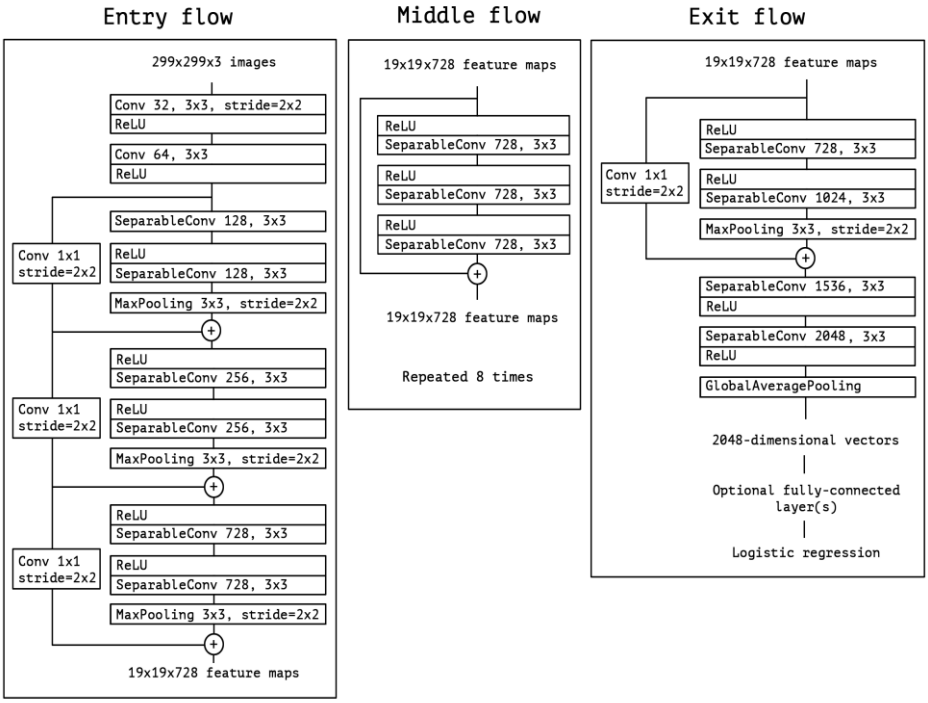


Şekil 3.8 Aktivasyon fonksiyonlarının grafiksel gösterimi (Avenash and Viswanath 2019)

Çalışmada CNN mimarisinin Xception, InceptionResnetV2, VGG-16, Resnet-50, Inception-V3, DenseNet-201 modellerinde eğitim ve test işlemleri gerçekleştirilmiştir. COVID-19 tanısı almış akciğer görüntüleri ‘1’ sağlıklı akciğer görüntüleri ’0’ olarak etiketlenmiştir.

3.2.6 Xception mimarisi

Evrişimli Sinir Ağları modellerinden olan Xception François Chollet tarafından önerilmiştir. Verilerin özellik çıkarılması işlemleri için basit evrişimli katman yığınlarına sahiptir. Üst üste yığılanmış maksimum havuzlama katmanları içerir. Her katmanın içerisinde evrişim ve maksimum havuzlama blokları yer alır. Az parametreye gereksinim duyar. Mimari konvolüsyonları birbirinden ayırarak elde eder. Üç temel katmandan meydana gelir. Giriş akışı (Entry flow), Orta akış (Middle flow), Çıkış akışı (Exit flow) (Rahimzadeh and Attar 2020). Şekil 3.9’da Xception Mimarisinin Katmanları yer almaktadır (Chollet 2014).



Şekil 3.9 Xception mimarisinin katmanları (Google 2014)

3.2.7 VGG-16 mimarisi

İlk olarak 2014 yılında Simonyan ve Zisserman tarafından 'Very Deep Convolutional Networks for Large Scale Image Recognition' makalesinde yer almıştır. İçeriğinde 3x3'lük filtreler ve evrişim katmanları yer almaktadır. Maksimum havuzlama blokları evirişim katmanlarının arasında yer alır, aktivasyon işlemleri harita boyutlarını küçültmektedir. Ağın son kısmında iki yoğun katman bulunur. Yoğun katmanlar 4096 nörondan oluşurlar. Mimarinin en sonunda ise 1000 nörondan oluşan son katman yer almaktadır. Şekil 3.10'da VGG-16 Mimarisinin Katmanları verilmiştir (Simonyan and Zisserman 2015).

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 **LRN**	conv3-64 **conv3-64**	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 **conv3-128**	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 **conv1-256**	conv3-256 conv3-256 **conv3-256**	conv3-256 conv3-256 conv3-256 **conv3-256**
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 **conv1-512**	conv3-512 conv3-512 **conv3-512**	conv3-512 conv3-512 conv3-512 **conv3-512**
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 **conv1-512**	conv3-512 conv3-512 **conv3-512**	conv3-512 conv3-512 conv3-512 **conv3-512**
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Şekil 3.10 VGG-16 mimarisinin katmanları (Simonyan and Zisserman 2015)

3.2.8 Resnet-50 mimarisi

ResNet mimarisi ilk olarak 2015 yılında He Kaiming, Sun Jian ve Microsoft Research Asia tarafından önerilmiştir. ResNet 50 modeli derin ağlar için dar boğaz yapısına sahiptir. Ağda 1x1'lik boyutsallık azaltıcı evrişim işleminin ardından 3x3'lük evrişim işlemi ve son olarak 1x1'lik boyutsallık yer alır. Resnet-50 modelinde parametre sayıları azaltılarak hesaplama yükü hafifletilmiş, derin modeller genişletilmiştir. Bu sayede mimarinin hata oranında büyük miktarda azalma gerçekleşmiştir. Şekil 3.11'de tüm Resnet Mimarilerinin Katmanları yer almaktadır (Kaiming and Zhang 2015).

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2_x	56×56	3×3 max pool, stride 2				
		$\begin{bmatrix} 3\times3, 64 \\ 3\times3, 64 \end{bmatrix}\times2$	$\begin{bmatrix} 3\times3, 64 \\ 3\times3, 64 \end{bmatrix}\times3$	$\begin{bmatrix} 1\times1, 64 \\ 3\times3, 64 \\ 1\times1, 256 \end{bmatrix}\times3$	$\begin{bmatrix} 1\times1, 64 \\ 3\times3, 64 \\ 1\times1, 256 \end{bmatrix}\times3$	$\begin{bmatrix} 1\times1, 64 \\ 3\times3, 64 \\ 1\times1, 256 \end{bmatrix}\times3$
conv3_x	28×28	$\begin{bmatrix} 3\times3, 128 \\ 3\times3, 128 \end{bmatrix}\times2$	$\begin{bmatrix} 3\times3, 128 \\ 3\times3, 128 \end{bmatrix}\times4$	$\begin{bmatrix} 1\times1, 128 \\ 3\times3, 128 \\ 1\times1, 512 \end{bmatrix}\times4$	$\begin{bmatrix} 1\times1, 128 \\ 3\times3, 128 \\ 1\times1, 512 \end{bmatrix}\times4$	$\begin{bmatrix} 1\times1, 128 \\ 3\times3, 128 \\ 1\times1, 512 \end{bmatrix}\times8$
conv4_x	14×14	$\begin{bmatrix} 3\times3, 256 \\ 3\times3, 256 \end{bmatrix}\times2$	$\begin{bmatrix} 3\times3, 256 \\ 3\times3, 256 \end{bmatrix}\times6$	$\begin{bmatrix} 1\times1, 256 \\ 3\times3, 256 \\ 1\times1, 1024 \end{bmatrix}\times6$	$\begin{bmatrix} 1\times1, 256 \\ 3\times3, 256 \\ 1\times1, 1024 \end{bmatrix}\times23$	$\begin{bmatrix} 1\times1, 256 \\ 3\times3, 256 \\ 1\times1, 1024 \end{bmatrix}\times36$
conv5_x	7×7	$\begin{bmatrix} 3\times3, 512 \\ 3\times3, 512 \end{bmatrix}\times2$	$\begin{bmatrix} 3\times3, 512 \\ 3\times3, 512 \end{bmatrix}\times3$	$\begin{bmatrix} 1\times1, 512 \\ 3\times3, 512 \\ 1\times1, 2048 \end{bmatrix}\times3$	$\begin{bmatrix} 1\times1, 512 \\ 3\times3, 512 \\ 1\times1, 2048 \end{bmatrix}\times3$	$\begin{bmatrix} 1\times1, 512 \\ 3\times3, 512 \\ 1\times1, 2048 \end{bmatrix}\times3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Şekil 3.11 Tüm resnet mimarilerinin katmanları (Kaiming and Zhang 2015)

3.2.9 DenseNet-201 mimarisi

Evrişimli Sinir Ağı modelleri arasında yer alan DenseNet-201 içerisinde 201 katman barındırmaktadır. Mimaride özellik yayılımı sağlanarak kullanılmış olan özelliklerin tekrar kullanılmasına olanak sağlanmıştır. Özellik yayılımı parametre sayısını da azaltmaktadır. Ağın girişinde 7x7'lik konvolüsyon blokları ve maksimum havuzlama katmanı yer almaktadır. Ağda her yoğunluk (Dense) bloğunun sonrasında geçiş bloğu (Transition) mevcuttur. Geçiş bloğunda 1x1lik konvolüsyon katmanı ve 2x2'lik ortalama havuzlama katmanı, 4 adet yoğunluk ve geçiş bloğu bulunmaktadır. Sınıflandırma katmanında ise 7x7'lik ortalama havuzlama ve tam bağlı katman yer alır. Şekil 3.12'de tüm Densenet Mimarilerinin Katmanları yer almaktadır (Huang and Weinberger 2018).

Layers	Output Size	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264
Convolution	112 × 112	7 × 7 conv, stride 2			
Pooling	56 × 56	3 × 3 max pool, stride 2			
Dense Block (1)	56 × 56	[1 × 1 conv, 3 × 3 conv] × 6	[1 × 1 conv, 3 × 3 conv] × 6	[1 × 1 conv, 3 × 3 conv] × 6	[1 × 1 conv, 3 × 3 conv] × 6
Transition Layer (1)	56 × 56	1 × 1 conv			
	28 × 28	2 × 2 average pool, stride 2			
Dense Block (2)	28 × 28	[1 × 1 conv, 3 × 3 conv] × 12	[1 × 1 conv, 3 × 3 conv] × 12	[1 × 1 conv, 3 × 3 conv] × 12	[1 × 1 conv, 3 × 3 conv] × 12
Transition Layer (2)	28 × 28	1 × 1 conv			
	14 × 14	2 × 2 average pool, stride 2			
Dense Block (3)	14 × 14	[1 × 1 conv, 3 × 3 conv] × 24	[1 × 1 conv, 3 × 3 conv] × 32	[1 × 1 conv, 3 × 3 conv] × 48	[1 × 1 conv, 3 × 3 conv] × 64
Transition Layer (3)	14 × 14	1 × 1 conv			
	7 × 7	2 × 2 average pool, stride 2			
Dense Block (4)	7 × 7	[1 × 1 conv, 3 × 3 conv] × 16	[1 × 1 conv, 3 × 3 conv] × 32	[1 × 1 conv, 3 × 3 conv] × 32	[1 × 1 conv, 3 × 3 conv] × 48
Classification Layer	1 × 1	7 × 7 global average pool			
		1000D fully-connected, softmax			

Şekil 3.12 Tüm densenet mimarilerinin katmanları (Huang and Weinberger 2018)

3.2.10 Inception-v3 mimarisi

Mimari ilk olarak Szegedy ve arkadaşları tarafından 'Rethinking the Inception Architecture for Computer Vision' makalesinde önerilmiştir. Yapısında çok sayıda konvolüsyon ve maksimum havuzlama katmanı yer almaktadır. Ağ 48 katman derinliğine sahiptir. Faktörleştirilmiş evrişimler ağın parametre sayısını azaltarak ağın verimliliğini kontrol eder. Ağda simetrik olmayan kovolüsyon işlemleri vardır. Havuzlama işlemleriyle birlikte Izgara boyutunu küçültme işlemleri de yapılır. Bu işlemler dar boğazlarla mücadele edilmesini sağlar. Şekil 3.13'te Inception-V3 Mimarisinin katmanları yer almaktadır (Szegedy *et al.* 2016).

type	patch size/stride or remarks	input size
conv	3×3/2	299×299×3
conv	3×3/1	149×149×32
conv padded	3×3/1	147×147×32
pool	3×3/2	147×147×64
conv	3×3/1	73×73×64
conv	3×3/2	71×71×80
conv	3×3/1	35×35×192
3×Inception	As in figure 5	35×35×288
5×Inception	As in figure 6	17×17×768
2×Inception	As in figure 7	8×8×1280
pool	8 × 8	8 × 8 × 2048
linear	logits	1 × 1 × 2048
softmax	classifier	1 × 1 × 1000

Şekil 3.13 Inception-v3 mimarisinin katmanları (Szegedy *et al.* 2016)

3.2.11 Inceptionresnetv2 mimarisi

Inceptionresnetv2 mimarisi temellerini Inception-v3 ve Resnet mimarilerinden oluşturmuştur. Inception ve resnet mimarilerine göre daha düşük hesaplama maliyetine sahiptir. Inceptionresnetv2 mimarisi inception mimarisini artık bağlantılar sayesinde birleştirmiştir. Mimaride 164 katman yer almaktadır. Evrişim filtreleri artık bağlantılarla birleşir bu eğitim süresinin azalmasını sağlamanın yanında derin ağ bozulmalarını da önler. Şekil 3.14'te Inception-Resnet-v2'nin temel ağ mimarisi yer almaktadır (Alruwaili *et al*. 2021).

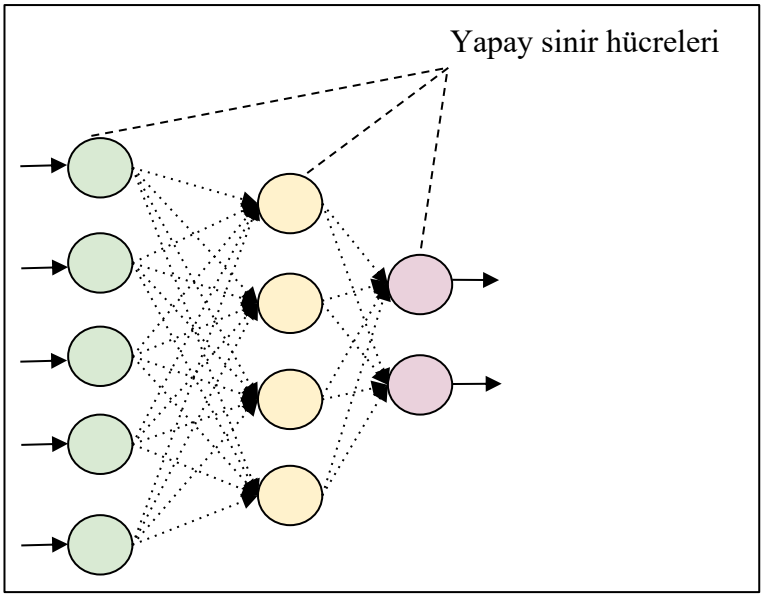
Layer	Patch size	Input size
Conv	3 × 3	224 × 224 × 3
Conv	3 × 3	111 × 111 × 32
Filter contact	3 × 3 pool + 3 × 3 conv	109 × 109 × 64
Filter contact	1 × 1 conv, 3 × 3 conv+ 1 × 1 conv, 7 × 1 conv, 1 × 7 conv, 3 × 3 conv	54 × 54 × 160
Filter contact	3 × 3 conv + max pool	52 × 52 × 128
Inception-ResNet-A × 10	–	26 × 26 × 256
Reduction-A	–	26 × 26 × 256
Inception-ResNet-B × 20	–	13 × 13 × 768
Reduction-B	–	13 × 13 × 768
Inception-ResNet-C × 10	–	6 × 6 × 1534
Average pooling	6 × 6	6 × 6 × 1534
Dropout	Keep = 0.5	1 × 1 × 1534
Fc	1534 × 1000	1534
Fc	1000 × 3	1000
Softmax	Classifier (3 classes)	500

Şekil 3.14 Inceptionresnet-v2'nin temel ağ mimarisi (Alruwaili et *al.* 2021)

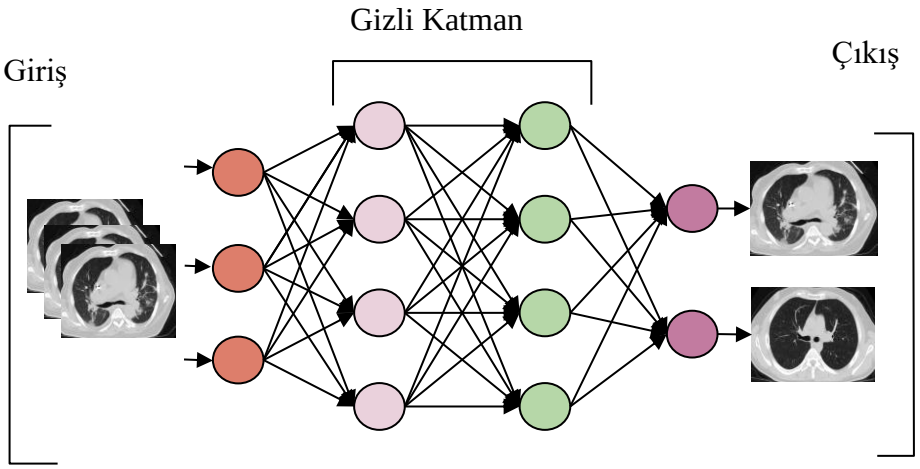
3.2.12 Yapay Sinir Ağları (YSA)

Yapay Sinir ağları insan beyninin öğrenme yetisinden esinlenerek geliştirilmiş hesaplama sistemlerinin modellenmesidir. İnsan beyninde birbirlerine sinapslarla bağlı çok sayıda sinir hücresi (nöron) bulunur. Yapay sinir ağları da insandaki sinaps ve nöron bağlantılarının yapay biçimde oluşturulması sonucu ortaya çıkmıştır (Abiodun *et al.* 2018). Yapay sinir ağlarındaki nöronlar birbirlerine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden meydana gelmektedir (Öztemel 2008). Yapay sinir hücrelerinin arasındaki bağlantıların her biri ayrı bir değere sahiptir. Bağlantı değerleri öğrenilen bilgileri içerirler. Yapay sinir hücrelerinin birbirine bağlanmasıyla elde edilen ağa yapay sinir ağı denmektedir. Yapay sinir ağları üç katmandan meydana gelir giriş katmanı, ara katman ve çıkış katmanı. Giriş katmanında giriş verileri ağa dahil edilir, buradaki her giriş verisi ara katmana aktarılır. Ara katman girişten gelen yeni verilerin işlendiği katmandır, Ağın yapısına göre ara katman sayısı değişebilmektedir. Çıkış katmanında her giriş değeri için yeni bir çıkış değeri üretilir. Yapay sinir ağları her giriş değeri için bir çıkış değeri belirler (Dongare *et al.* 2012). Şekil 3.15'te yapay sinir ağlarına

temel mimari örneği verilmiştir. Şekil 3.16'da bir yapay sinir ağının hücrelerinin birbirine bağlanma biçimi verilmiştir.



Şekil 3.15 Yapay sinir ağı hücrelerinin bağlantılarının gösterimi



Şekil 3.16 Yapay sinir ağları temel mimari örneği

3.2.13 K En Yakın Komşuluk Algoritması (KNN)

K en yakın komşuluk bir sınıflandırma algoritmasıdır. Gözetimli öğrenme algoritmalarındandır. KNN algoritması birçok veri setine karşı dirençli öğrenmelerindendir. İlk olarak 1967 yılında T.M. Cıver ve P. E. Hart tarafından önerilmiştir. Sınıflandırma ve regresyon problemlerinin çözümünde tercih edilmektedir (Shaban *et al.* 2020). KNN algoritmasında ilk olarak bir k değeri belirlenir. Bu k değeri verilen noktaya göre bulunan en yakın komşu sayısını ifade eder. Bu durumda k değerine göre en yakın k değeri kadar komşuya göre sınıflandırılma gerçekleştirilir. Veri setine dahil olacak yeni verinin uzaklığı mevcut verilere göre tek tek hesaplanır. Algoritma uzaklık hesaplamalarının bütün verilerini hafızasında saklar. Veri büyüklüğüne göre bellek ihtiyacı da artar. Aradaki uzaklığın hesaplanması için genel olarak Öklid, Manhattan, Minkowski uzaklıkları kullanılmaktadır. Minkowski uzaklığı öklid uzay düzleminde tanımlı bir diziyi temsil eder. Q = (x1, x2,…xm) ve P=(y1,y2,…ym) olmak üzere eşitlik 1 değerine göre hesaplanır. Minkowski ölçütünde P=2 olması özel durumu, öklid uzaklığının P=1 olması özel durumu ve Manhattan uzaklığını n→∞ özel durum uzaklığını verir.

Formül 1 2 ve 3'te p ve q iki farklı noktası için özellik vektörleri P = (x1, x2,…xm) ve Q=(y1,y2,…ym) ile temsil edilmektedir. N değeri özellik uzayının boyutunu temsil etmektedir. Uzaklık hesaplamasından sonra öznitelik değerlerine göre veri yeni sınıfına atanır. İki değer arasındaki uzaklık hesaplandıktan sonra sıralama gerçekleştirilir, alınan değer hangi sınıfa uygunsa o sınıfa atanır.

Öklid uzaklığı

$$dist\ (P,Q) = \sqrt{\sum_{i=1}^{n}(x_i - y_i)^2} \qquad (1)$$

Minkowski uzaklığı

$$dist\ (P,Q) = (\sum_{i=1}^{n}(|x_i - y_i|)^q)^{\frac{1}{q}} \quad (2)$$

Manhattan uzaklığı

$$dist\ (P,Q) = \sum_{i=1}^{n}|x_i - y_i| \quad (3)$$

3.2.14 Destek Vektör Makinaları (SVM)

Destek vektör makinaları genel olarak sınıflandırılma problemlerinde kullanılan istatiksel öğrenme teorisine dayalı gözetimli öğrenme algoritmasıdır. İki veya daha fazla sınıf içeren veri kümelerinde sınıflandırma destek vektör makineleriyle yapılabilir. İlk olarak 1963 yılında Vladimir Vapnik ve Alexey Chervonenkis tarafından temelleri atılmıştır. Sınıflandırma problemlerinde temel amaç gelecek yeni verinin hangi sınıfa ait olduğunun tahmin edilmesidir. Sınıflar arasındaki ayrımın yapılabilmesi için sınıflar arasına bir doğru çizilir. Buna karar sınırı denilmektedir. Sınıflar arasında kalan bölgeye margin adı verilir. Marginin genişliğiyle doğru orantılı olarak sınıflar birbirinden ayrışırlar. Karar sınıfına yakın değerlere destek denilmektedir. Destek değerlinin yerleri en iyi durumu ve karar sınırlarını da etkiler. Destek vektör makinaları hiçbir parametre kabul etmeyen sınıflayıcılardandır. Doğrusal ve doğrusal olmayan destek vektör makinaları vardır. Karmaşık karar sınırlarını gayet iyi biçimde modelleyip fazla değişkenlerle çalışabilirler.

Eğer $yi = 1 \qquad wt * x\,i + b \geq 1$ (4)

Eğer $yi = -1 \qquad wt * x\,i + b \leq 1$ (5)

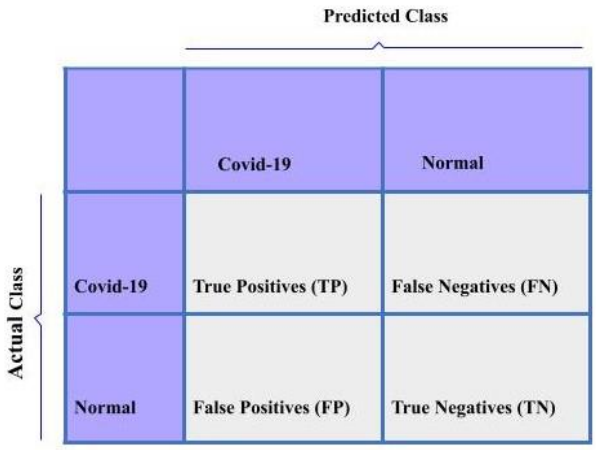
Formül 4 ve 5'te w ağırlık vektörünü, x girdi vektörünü b ise sapmayı temsil etmektedir. Yeni elde edilen değer 1'den küçük ve eşitse 1. sınıfa, birden büyük ve eşitse 2.sınıfa daha yakın olur.

3.2.15 Performans Ölçütleri

Eğitim işlemi gerçekleştirilen ikili sınıflandırılmış veri setlerinde hastalık teşhisinin gerçekleştirilmesi için kullanılan modellerin sonuçları istatiksel ölçümlerle değerlendirilmiştir. İstatiksel ölçüm ve sonuçları için Karşıklık Matrsi (Confusion Matrix), Doğruluk (Accuracy), Hassasiyet (Precision), Geri Çağırma (Recall), F-skoru (F-score) ve Alıcı Çalışma Özellikleri Eğrisi (Receiver Operating Characteristics Curve) parametreleri kullanılmıştır.

3.2.16 Karışıklık matrisi (Confusion matrix)

Çalışmada kullanılan modellerin sonuçlarının istatiksel olarak yorumlanabilmesi, tahmin edilen değerlerin doğruluk ve hatalarını çapraz olarak değerlendirmek için kullanılmaktadır. Şekil 3.17'de Karışıklık matrisi parametreleri yer almaktadır.



Şekil 3.17 Karışıklık matrisi için performans ölçümleri

Gerçek Pozitifler (True Positives): COVID-19 tanısı almış verilerin COVID-19 olarak doğru tahmin edilmesidir.

Gerçek Negatifler (True Negatives): Sağlıklı tanısı almış verilerin sağlıklı olarak doğru tahmin edilmesidir.

Yanlış Pozitifler (False Positives): COVID-19 olarak tahmin edilen verilerin aslında sağlıklı veriler olması sonucunda yanlış tahmin edilmesidir.

Yanlış Negatifler (False Negatives): Sağlıklı olarak tahmin edilen verilerin aslında COVID-19 verileri olması sonucunda yanlış tahmin edilmesidir.

a-) Doğruluk (Accuracy): Modelde tüm doğru tahmin edilen Gerçek Pozitiflerle (TP) Gerçek Negatif (TN) değerlerinin toplamının tüm veri sayısına yani Gerçek Pozitifler (TP), Gerçek Negatifler (TN), Yanlış Pozitifler (FP), Yanlış Negatifler (FN) tümünün değerlerinin toplamına oranıdır.

$$Accuracy = ((TP + TN))/((TP + FP + FN + TN)) \quad (6)$$

b-) Hassasiyet (Precision): Doğru tahmin COVID-19 tanısı almış verilerin (TP) yanlış tahmin edilen COVID-19 verileri (FP) ve doğru tahmin edilen COVID-19 verilerinin (TP) toplamına oranıyla ifade edilir.

$$Precision = ((TP))/((TP + FP)) \quad (7)$$

c-) Geri Çağırma (Recall): Doğru tahmin edilen COVID-19 tanısı almış verilerin (TP) Sağlıklı tanısı almış verinin COVID-19 tanısı almış veri (FN) olarak yanlış tahmin edilmesi ile doğru tahmin edilen COVID-19 verisinin (TP) toplamlarına oranı.

$$Recall = ((TP))/((TP + FN)) \quad (8)$$

d-) F-Skoru (F-Score): Recall ve Precision değerlerinin harmonik ortalamasıdır. Sınıflandırmanın performansının doğruluğunu gösterir.

$$F\text{-}Score = 2\ x\ ((Precision\ x\ Recall))/((Precision + Recall)) \quad (9)$$

e-) Alıcı Çalışma Özellikleri Eğrisi (Receiver Operating Characteristics Curve):
ROC bir olasılık eğrisidir. Eğrinin x koordinatı False Positives (FP), y koordinatı True Positives (TP)' i temsil eder. Eğrinin altında kalan alana Area Under The Curve (AUC) adı verilmektedir. AUC parametrelerin ayrıştırılmış ölçü ve değerini göstermektedir. AUC modelin performansının özetinin yer aldığı kısımdır, kapsadığı alanın büyüklüğü kullanılan modellerin sınıf ayrımları ile doğru orantılı olarak iyileşmektedir.

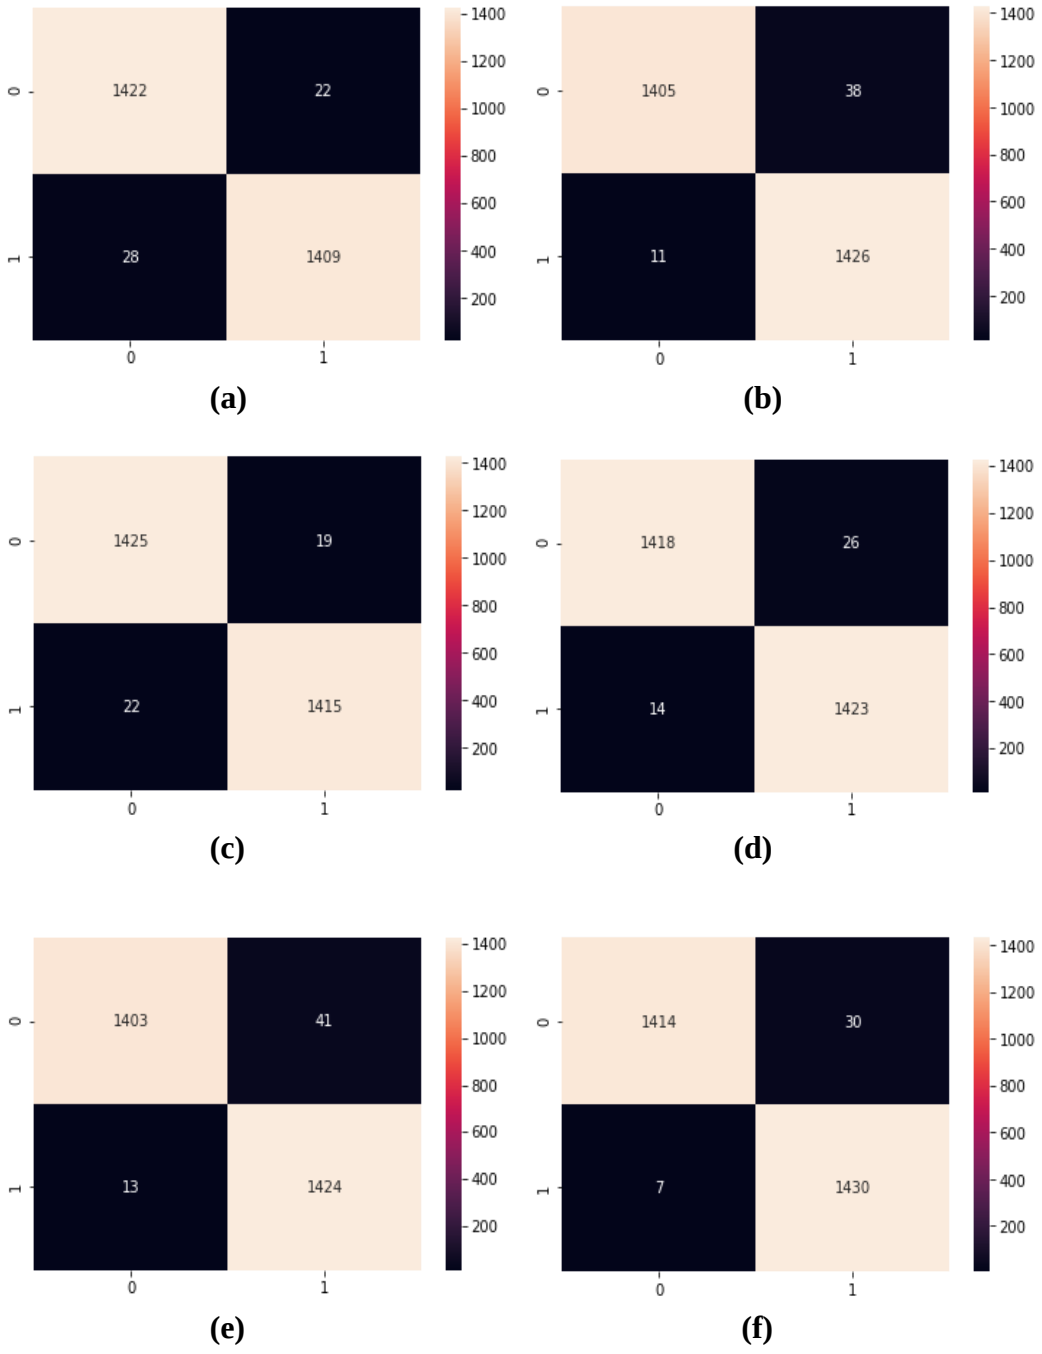
4. BULGULAR

4.1 CNN Modellerinden Elde Edilen Bulgular

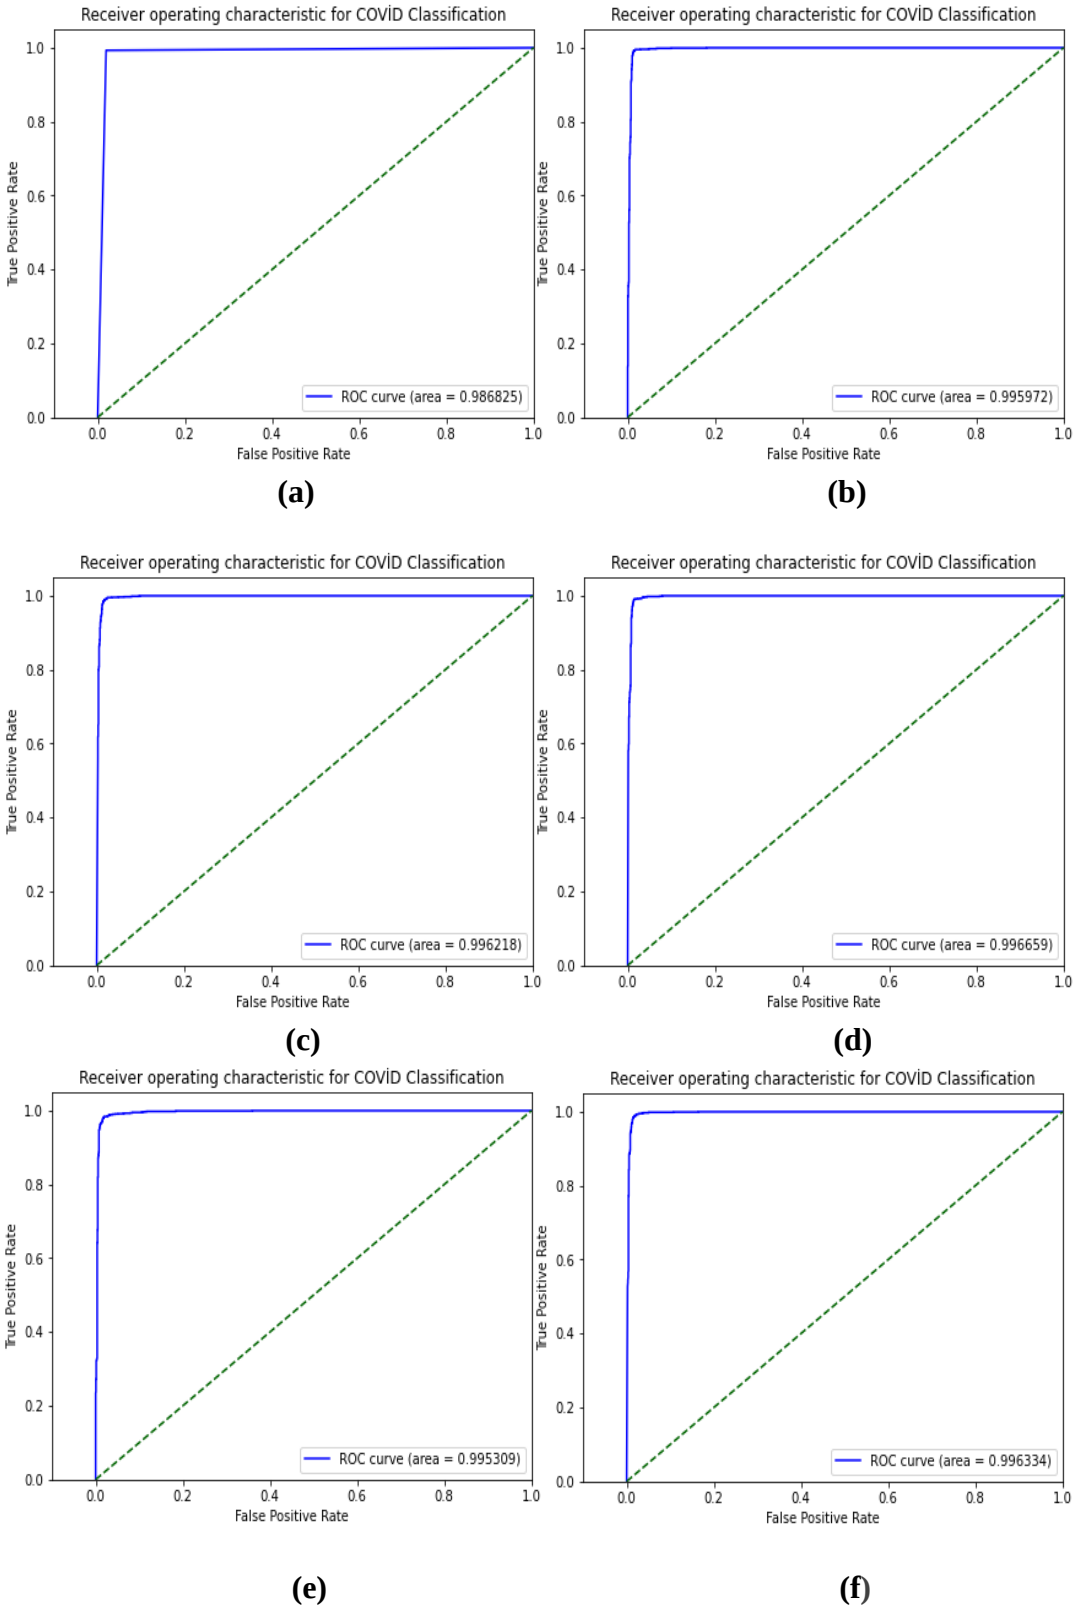
COVID-19 hastalığının teşhisi için altı farklı CNN mimarisi ile eğitim ve test işlemleri gerçekleştirilmiştir. Çalışmada CNN mimarilerinde eğitim için Adam optimizeri, iç katmanlarda relu fonksiyonu, çıkış katmanlarında sigmoid fonksiyonu kullanılmıştır. Eğitim işlemleri 30 epokluk iterasyonlarda gerçekleştirilmiştir. Xception modelinde %99,60 eğitim doğruluğu, %98,58 test doğruluğu, %99,71 AUC elde edilmiştir. DenseNet201 modelinde %99,44 eğitim doğruluğu, %98,61 test doğruluğu, %99,61 AUC elde edilmiştir. VGG16 modelinde %98,58 eğitim doğruluğu, %98,26 test doğruluğu, %99,73 AUC elde edilmiştir. ResNet50 modelinde %99,44 eğitim doğruluğu, %98,72 test doğruluğu, %99,60 AUC elde edilmiştir.InceptionResnetv2 modelinde %99,05 eğitim doğruluğu, %98,30 test doğruluğu, %99,66 AUC elde edilmiştir. Inceptionv3 modelinde %99,19 eğitim doğruluğu, %98,13 test doğruluğu, %99,52 AUC elde edilmiştir. Çizelge 4.1'de tüm CNN modelleri için Precision, Recall ve F-score değerleri verilmiştir. Ek-1'de tüm modellerin eğitim ve doğruluk kayıp grafikleri yer almaktadır. Şekil 4.1'de tüm modellerin karışıklık matrisleri ve Şekil 4.2'de tüm CNN modellerinin ROC grafikleri yer almaktadır.

Çizelge 4.1 Tüm cnn modelleri için precision, recall ve f-score değerleri

MODEL	PRECISION (%)	RECALL(%)	F-SCORE (%)	AUC (%)
VGG16	98,46	98,05	98,25	99,59
InceptionResNetv2	97,40	99,23	98,31	99,66
DenseNet201	98,20	99,02	98,61	98,68
ResNet50	97,94	99,51	98,72	99,62
Inceptionv3	97,20	99,09	98,13	99,53
Xception	98,38	98,37	98,37	99,63



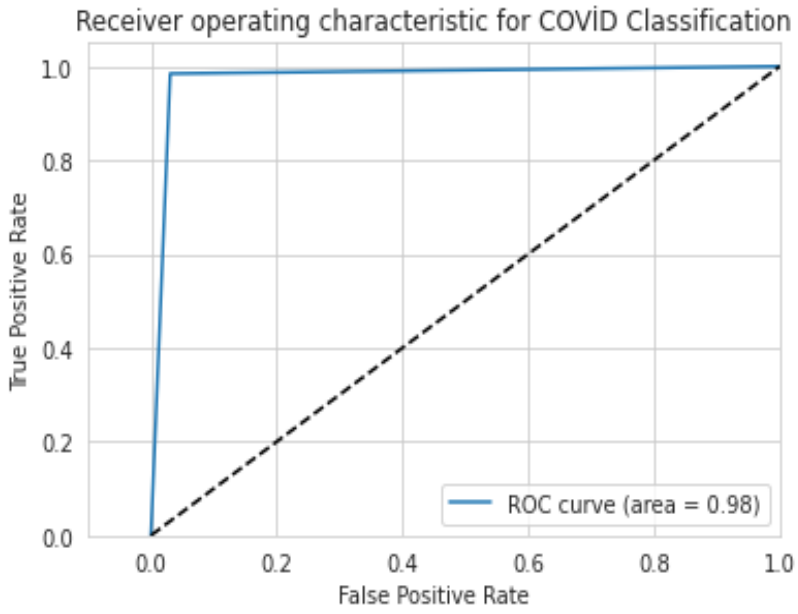
Şekil 4.1 CNN mimarilerinin karışıklık matrisleri 0 etiketi sağlıklı akciğer görüntülerini 1 etiketi covid-19 tanısı almış akciğer görüntülerini temsil etmektedir. a-) Xception, b-) Densenet201, c-) Vgg-16, d-) Resnet-50, e-) Inceptionresnetv2 ve f-) Inception-v3 mimarilerinin karışıklık matrisleri



Şekil 4.2 CNN mimarilerinin karışıklık matrisleri roc grafikleri a-) Xception, b-) Densenet201, c-) Vgg-16, d-) Resnet-50, e-) Inceptionresnetv2 ve d-) Inceptionv3 mimarilerinin roc grafikleri

4.2 YSA Modellinden Elde Edilen Bulgular

Çok katmanlı algılayıcı modeli (Multilayer Perceptron) ile COVID-19 hastalığının teşhisi için 30 epokluk iterasyonlarda eğitim gerçekleştirilmiştir. İç katmanlarda relu, çıkış katmanında sigmoid fonksiyonu kullanılmıştır. Eğitim sonucunda %98,98 doğruluk, test sonucunda %97,68 doğruluk ve %98,0 AUC elde edilmiştir. Çizelge 4.2'de YSA modelinin Precision, Recall ve F-score değerleri verilmiştir. Şekil 4.3'te YSA modelinin ROC grafiği yer almaktadır.



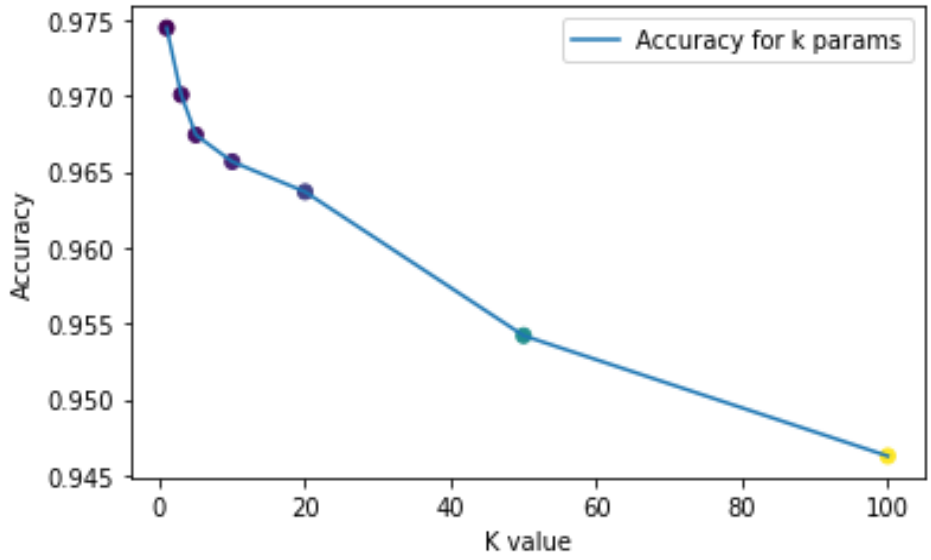
Şekil 4.3 YSA modelinin roc grafiği

Çizelge 4.2 YSA modeli için precision, recall ve f-score değerleri

SINIF	PRECISION(%)	RECALL (%)	F-SCORE (%)	AUC (%)
Normal	98	97	98	98
COVID-19	97	98	97	98

4.3 KNN ve SVM Modelinden Elde Edilen Bulgular

COVID-19 hastalığının teşhisi için kullanılan makine öğrenmelerinden KNN algoritmasında k için 7 farklı değer verilmiştir. k=1 değeri için %97,44, k = 3 değeri için %97, k=5 değeri için %96,74, k=10 değeri için %96,56 ve k=20 değeri için %96,36, k=50 değeri için %95,4 ve k=100 değeri için %94,6 test doğruluğu elde edilmiştir. K değeri arttıkça doğruluk sayısı azalmıştır. Şekil 4.4'te tüm k değerleri için doğruluk grafiği yer almaktadır. Çizelge 4.3'te k=1 değeri için Precision, Recall, F1-score değerleri yer almaktadır. Çizelge 4.4'te k=3 değeri için Precision, Recall, F1-score değerleri yer almaktadır. Çizelge 4.5'te k=5 değeri için Precision, Recall, F1-score değerleri yer almaktadır. Çizelge 4.6'da k=10 değeri için Precision, Recall, F1-score değerleri yer almaktadır. Çizelge 4.7'de k=20 değeri için Precision, Recall, F1-score değerleri yer almaktadır. Çizelge 4.8'de k=50 değeri için Precision, Recall, F1-score değerleri yer almaktadır. Çizelge 4.9'da k=100 değeri için Precision, Recall, F1-score değerleri yer almaktadır.



Şekil 4.4 Tüm k değerleri için doğruluk grafiği

Çizelge 4.3 K=1 değeri için sonuç tablosu

K = 1	PRECISION	RECALL	F1-SCORE
COVID	0,95	0,98	0,96
NORMAL	0,99	0,97	0,97

Çizelge 4.4 K=3 değeri için sonuç tablosu

K = 3	PRECISION	RECALL	F1-SCORE
COVID	0,94	0,98	0,96
NORMAL	0,99	0,97	0,97

Çizelge 4.5 K=5 değeri için sonuç tablosu

K = 5	PRECISION	RECALL	F1-SCORE
COVID	0,93	0,98	0,95
NORMAL	0,99	0,96	0,98

Çizelge 4.6 K=10 değeri için sonuç tablosu

K = 10	PRECISION	RECALL	F1-SCORE
COVID	0,92	0,98	0,95
NORMAL	0,99	0,96	0,97

Çizelge 4.7 K=20 değeri için sonuç tablosu

K = 20	PRECISION	RECALL	F1-SCORE
COVID	0,92	0,97	0,95
NORMAL	0,99	0,96	0,97

Çizelge 4.8 K=50 değeri için sonuç tablosu

K = 50	PRECISION	RECALL	F1-SCORE
COVID	0,90	0,97	0,93
NORMAL	0,99	0,94	0,96

Çizelge 4.9 K=100 değeri için sonuç tablosu

K = 100	PRECISION	RECALL	F1-SCORE
COVID	0,89	0,96	0,92
NORMAL	0,98	0,94	0,96

SVM modeliyle gerçekleştiren test işlemi %96,91 doğruluk elde etmiştir. Çizelge 4.10'da SVM modeli için Precision, Recall ve F-score değerleri yer almaktadır.

Çizelge 4.10 SVM için precision, recall ve f-score değerleri

SINIF	PRECISION (%)	RECALL (%)	F-SCORE (%)
NORMAL	97	98	98
COVID-19	96	95	95

5. SONUÇ VE TARTIŞMA

COVID-19 hastalığını teşhisinde kullanılan derin öğrenme mimarilerimden CNN'in 6 farklı modelinde gerçekleştirilen eğitim ve test işlemleri için farklı sonuçlar elde edilmiştir. Xception mimarisinden elde edilen test doğruluğu %98,58 elde edilmiştir. Şekil 4.1'de modellerin karışıklık matrisleri verilmiştir. 0 etiketi almış görüntüler sağlıklı verileri temsil ederken 1 olarak etiketlenirken görüntüler COVID-19 hastalığını temsil etmektedir. Veri setinden test işleminde kullanılan 2880 test verisinin 1440'ı sağlıklı 1440'ı COVID-19 tanısı almış verilerden oluşturulmuştur. Xception modelinin karışıklık matrisine bakıldığında 1425 sağlıklı görüntü doğru olarak tahmin edilirken, 1415 COVID-19 tanısı almış görüntü doğru olarak tahmin edilmiştir. Model %98,58'lik test doğruluğu elde edilmiştir. DenseNet201 modelinin karışıklık matrisine bakıldığında 1418 sağlıklı görüntü doğru olarak tahmin edilirken, 1423 COVID-19 tanısı almış görüntü doğru olarak tahmin edilmiştir. Model %98,61'lik test doğruluğu elde edilmiştir. VGG16 modelinin karışıklık matrisine bakıldığında 1422 sağlıklı görüntü doğru olarak tahmin edilirken, 1409 COVID-19 tanısı almış görüntü doğru olarak tahmin edilmiştir. Model %98,26'lık test doğruluğu elde edilmiştir. Resnet50 modelinin karışıklık matrisine bakıldığında 1414 sağlıklı görüntü doğru olarak tahmin edilirken, 1430 COVID-19 tanısı almış görüntü doğru olarak tahmin edilmiştir. Model %98,72'lik test doğruluğu elde edilmiştir. InceptionResNetV2 modelinin karışıklık matrisine bakıldığında 1403 sağlıklı görüntü doğru olarak tahmin edilirken, 1424 COVID-19 tanısı almış görüntü doğru olarak tahmin edilmiştir. Model %98,30'luk test doğruluğu elde edilmiştir. Inceptionv3 modelinin karışıklık matrisine bakıldığında 1405 sağlıklı görüntü doğru olarak tahmin edilirken, 1426 COVID-19 tanısı almış görüntü doğru olarak tahmin edilmiştir. Model %98,13'lük test doğruluğu elde edilmiştir. Tüm modellerin sonuçları değerlendirildiğinde en yüksek başarı oranı %98,75'lik test doğruluğu ile Resnet50 modeline aitken en düşük test doğruluğu %9813'lük test doğruluğu ile Inception modeline aittir. YSA modelinde gerçekleştirilen test işlemi %97,68 doğruluk elde etmiştir. Makine öğrenmesi olan KNN modeli k=1 değerinde en yüksek başarı oranı olarak %97,44'ü elde etmiştir. Şekil 4.4'te k değerlerinin grafiğini bakıldığında k değeri arttıkça doğruluk oranında düşüş gerçekleştirilmiştir. SVM modelinin test işleminde %96,91 doğruluk elde edilmiştir. Tüm test işlemi sonuçları değerlendirildiğinde COVID-19 hastalığının teşhisi için en iyi

sonucu derin öğrenme modellerinden Resnet50 elde ederken en düşük sonucu makine öğrenmelerinden SVM elde etmiştir. CNN mimarilerinin sınıflandırma problemlerindeki başarısı çalışma sonuçlarında da görülmektedir. Hastalık teşhisi için sınıflandırma metodu ile CNN modellerinde farklı yöntemler ve farklı modeller denenerek modellerden daha iyi sonuçlar elde edilebilir. Veri setindeki görüntü miktarları arttırılarak daha yüksek sonuçlar elde edilebilir. Sonuç olarak derin öğrenmenin COVID-19 ve diğer hastalıkların teşhisi için sağlık sistemlerine ve insanlığa büyük katkılar sağlayacağı görülebilmektedir.

KAYNAKLAR

Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., Arshad, H. 2018. State of the art in artificial neural network applications. Heliyon, 4(11), e00938.

Alom, M. Z., Rahman, M. S., Nasrin, M. S., Taha, T. M., Asari, V. K. 2020. COVID_ MTNet : COVID-19 Detection with Multi-Task Deep Learning Approaches. Arxiv, 2004, 03747.

Alruwaili, M., Shehab, A., El-ghany, S. 2021. COVID-19 Diagnosis Using an Enhanced Inception-ResNetV2 Deep Learning Model in CXR Images. Journal of Healthcare Engineering, 2021, 34-41.

Amyar, A., Modzelewski, R., Li, H., Ruan, S. 2020. Multi-task deep learning based CT imaging analysis for COVID-19 pneumonia : Classification and segmentation. Computers in Biology and Medicine, 126, 104037.

Avenash, R., Viswanath, P. 2019. In Proceedings of the 14th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications VISIGRAPP, 413-420.

Boeckmans, J., Cartuyvels, R., Hilkens, P., Bruckers, L., Magerman, K., Waumans, L., Raymaekers, M. 2021. Follow-up testing of borderline SARS-CoV-2 patients by rRT-PCR allows early diagnosis of COVID-19. Diagnostic Microbiology Infectious Disease, Journal Pre-proof, 100(2), 115350.

Brunese, L., Mercaldo, F., Reginelli, A., Santone, A. 2020. Explainable Deep Learning for Pulmonary Disease and Coronavirus COVID-19 Detection from X-rays. Computer Methods and Programs in Biomedicine, 96, 105608.

Bütüner, R., Calp, M. H. 2020. EasyChair Preprint COVID-19 Detection from Lung Tomography Images Using Deep Learning and Machine Learning Methods,2020 EasyChair, 4097.

Chollet, F. 2017. Xception: Deep learning with depthwise separable convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition, 1251-1258.

Cohen, J. P., Dao, L., Roth, K., Morrison, P., Bengio, Y., Abbasi, F., Shen, B., Mahsa, H. K., Ghassemi, M., Li, H., Duong, T.Q. 2020. Predicting COVID-19 Pneumonia

Severity on Chest X-ray With Deep Learning Cureus, 12(7), 9448.

COVID 19 WHO 16 ağustos 2021 verileri. Web sitesi. https://covid19.who.int/2021. Erişim tarihi 16.08.2021.

Dixit, A., Mani, A., Bansal, R. 2021. CoV2-Detect-Net: Design of COVID-19 prediction model based on hybrid DE-PSO with SVM using Chest X-ray images. Information Sciences, 676-692.

Dongare, A. D., Kharde, R. R., Kachare, A. D. 2012. Introduction to Artificial Neural Network (ANN) Methods. International Journal of Engineering and Innovative Technology (IJEIT), 2(1), 189–194.

Farooq, M., Hafeez, A. 2020. COVID-ResNet:A Deep Learning Framework for Screening of COVID 19 from Radiographs.Arxiv, 2003, 14395.

Gilanie, G., Bajwa, U. I., Waraich, M. M., Asghar, M., Kousar, R., Kashif, A., Aslam, R. S., Qasim, M. M., Rafique, H. 2021. Coronavirus (COVID-19) Detection from Chest Radiology Images using Convolutional Neural Networks.Biomedical Signal Processing and Control, 66, 02490.

Gozes, O., Frid-Adar, M., Greenspan, H., Browning, P. D., Zhang, H., Ji, W., Bernheim, A., Siegel, E. 2020. Rapid AI Development Cycle for the Coronavirus (COVID-19) Pandemic : Initial Results for Automated Detection Patient Monitoring using Deep Learning CT Image Analysis.Arxiv, 2003, 05037.

He, K., Zhang, X., Ren, S., Sun, J. 2015. Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778.

He, X., Yang, X., Zhang, S., Zhao, J., Zhang, Y., Xing, E., Xie, P. 2020. Sample-Efficient Deep Learning for COVID-19 Diagnosis Based on CT Scans. Medrxiv, 04, 13, 20063941.

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, 2003, 11055.

Hu, S., Gao, Y., Niu, Z., Jiang, Y., Li, L., Xiao, X.,Wang, M., Fang, E.F., Smith, W. M., Xia, J., Ye, H., Yang, G.2020. Weakly Supervised Deep Learning for COVID-19 Infection Detection and Classification From CT Images. IEE Access, 8, 118869–118883.

Huang, G., Liu, Z., Maaten, L. V., Weinberger, K.Q. 2017.Densely Connected Convolutional Networks. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 4700-4708.

Huang, L., Han, R., Ai, T., Yu, P., Kang, H., Tao, Q., Xia, L. 2020. Serial Quantitative Chest CT Assessment of COVID-19 :A Deep Learning Apporach. Radiology: Cardiothoracic İmaging, 2(2) ,200075.

Hubel, D. H., Wiesel, T. N. 1962. And functıonal archıteture in the cat's vısual cortex from the neurophysiolojy laboratory,Department of Pharmacology central nervous system is the great diversity of its cell types and inter- receptive fields of a more complex type (Part I), 106–154.

Jain, G., Mittal, D., Thakur, D., Mittal, M. K. 2020. A deep learning approach to detect Covid-19 coronavirus with X-Ray images. Science Direct, 40(4), 1391–1405.

Jaiswal, A., Gianchandani, N., Singh, D. Kumar, V., Kaur, M. 2020. Classification of the COVID-19 infected patients using DenseNet201 based deep transfer learning. Journal of Biomolecular Structure and Dynamics, 1–8.

Javor, D., Kaplan, H., Kaplan, A., Puchner, S. B., Krestan, C., Baltzer, P. 2020. Deep learning analysis provides accurate COVID-19 diagnosis on chest computed tomography. European Journal of Radiology, 133, 109402.

Li, Y., Xia, L. 2020. Coronavirus disease. 2019. (COVID-19): Role of chest CT in diagnosis and management. American Journal of Roentgenology, 214(6), 1280–1286.

Liu, T., Fang, S., Zhao, Y., Wang, P., Zhang, J. 2015. Implementation of Training Convolutional Neural Networks. Arxiv, 1506, 01195.

Luz, E., Silva, P., Silva, R., Silva, L., Guimarães, J., Miozzo, G., Moreira, G., Menotti, D. 2021. Towards an effective and efficient deep learning model for COVID-19 patterns detection in X-ray images. Arxiv, 1-14.

Maghdid, H. S., Asaad, A. T., Ghafoor, K. Z., Sadiq, A. S., Mirjalili, S., Khan, M. K. 2020. Diagnosing COVID-19 pneumonia from x-ray and ct images using deep learning and transfer learning algorithms. Arxiv, 11734, 117340E.

Mahdy, L. N., Ezzat, K. A., Elmousalami, H., Ella, H. A., Hassanien, A. E. 2020. Automatic X-ray COVID-19 Lung Image Classification System based on Multi-Level Thresholding and Support Vector Machine.MedRxiv, 2020-03, 1–8.

Minaee, S., Kafieh, R., Sonka, M., Yazdani, S., Soufi, G.J. 2020. Deep-COVID : Predicting COVID-19 from chest X-ray images using deep transfer learning.Medical Image Analysis, 65, 101797.

Öztemel, E. 2003. Yapay Sinir Ağlari. Papatya Yayıncılık, İstanbul.

Qian, S., Liu, H., Liu, C., Wu, S., Wong, H.S. 2018. Adaptive activation functions in convolutional neural networks. Neurocomputing, 272, 204–212.

Rahimzadeh, M., Attar, A. 2020. a New Modified Deep Convolutional Neural Network for Detecting Covid-19 From X-Ray Images.ArXiv, 2004, 08052.

Rumelhart, D. E., Hinton, G. E., Williams, R. J. 2013. Learning Internal Representations by Error Propagation. Readings in Cognitive Science: A Perspective from Psychology and Artificial Intelligence, 399–421.

Savas, R. 2015. Akciğer Kanserinde PET/BT. Türk Radyoloji Seminerleri, *2*(3),326–339.

Shaban, W. M., Rabie, A. H., Saleh, A. I., & Abo-Elsoud, M. A. 2020. A new COVID-19 Patients Detection Strategy (CPDS) based on hybrid feature selection and enhanced KNN classifier. Knowledge-Based Systems, 205, 106270.

Shan, F., Gao, Y., Wang, J., Shi, W., Shi, N., Han, M., Xues, Z., Shen, D., Shi, Y. 2020. Lung Infection Quantification of COVID-19 in CT Images with Deep Learning. Arxiv, 2003, 04655.

Simonyan, K., Zisserman, A. 2015. Very deep convolutional networks for large-scale image recognition.Arxiv, 1409, 1556.

Song, Y., Zheng, S., Li, L., Zhang, X., Zhang, X., Huang, Z., Chen, J., Wang, R., Zhao, H., Zha, Y., Shen, J., Chong, Y., Yang, Y. 2021. Deep learning Enables Accurate Diagnosis of Novel Coronavirus (COVID-19) with CT images. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 14(8), 1-8.

Streiner, D. L., Cairney, J. 2007.What's under the ROC? An introduction to reciever operating characteristic curves. The Canadian Journal of Psychiatry, 52(2), 121–128.

Sümer, E., Engin, M., Ağıldere, M., Oğul, H. 2018. Monitoring Nodule Progression in Chest X-ray Images. Pamukkale University Journal of Engineering Sciences, 24(5), 934–941.

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. 2016. Rethinking the Inception Architecture for Computer Vision. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2818–2826.

Turkoglu, M. 2021. COVID-19 Detection System Using Chest CT Images and Multiple Kernels-Extreme Learning Machine Based on Deep Neural Network.IRBM, 1–8.

Wang, L., Lin, Z. Q., Wong, A. 2020. COVID-Net: a tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images. Scientific Reports, 10(1), 1–12.

Wang, S., Zha, Y., Li, W., Wu, Q., Li, X., Niu, M., Wang, M., Qiu, X., Li, H., Yu, H., Gong, W., Bai, Y., Li, L., Zhu, Y., Wang, L., Tian, J. 2020. A fully automatic deep learning system for COVID-19 diagnostic and prognostic analysis. European Respiratory Journal, 56(2), 2000775.

Wei, L., Cai, J., Nguyen, V., Chu, J., Wen, K. 2020. P-SFA: Probability based Sigmoid Function Approximation for Low-complexity Hardware Implementation. Microprocessors and Microsystems, 76, 103105.

Xu, X., Jiang, X., Ma, C., Du, P., Li, X., Lv, S., Yu, L., Ni, Q., Chen, Y., Su, J., Lang, G., Li, Y., Zhao, H., Liu, J., Xu, K., Ruan, L., Sheng, J., Qiu, Y., Li, L. 2019. A Deep Learning System to Screen Novel Coronavirus Disease 2019 Pneumonia. Engineering, 6 (10), 1122–1129.

Yang, X., Yu, Y., Xu, J., Shu, H., Xia, J., Liu, H., Wu, Y., Zhang, Lu.,Yu, Z., Fang, M., Yu, T., Wang, Y., Pan, S., Zou, X., Yuan, S., Shang, Y. 2020. Clinical course and outcomes of critically ill patients with SARS-CoV-2 pneumonia in Wuhan, China: a single-centered, retrospective, observational study. The Lancet Respiratory Medicine, 8(5), 475–481.

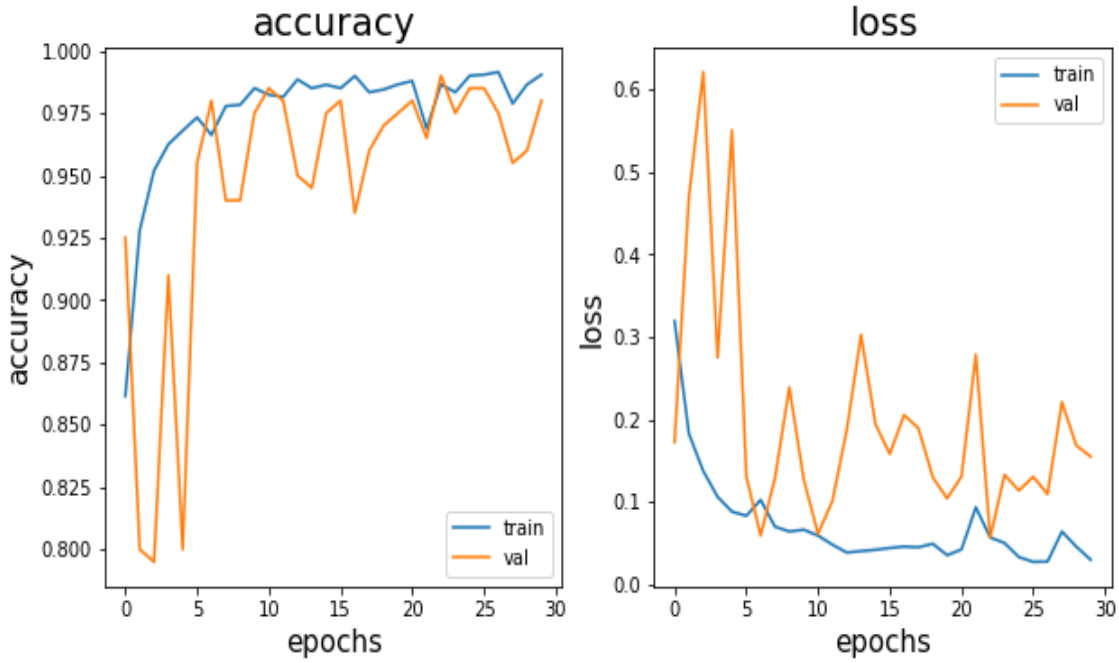
Zheng, C., Deng, X., Fu, Q., Zhou, Q., Feng, J., Ma, H., Liu, W., Wang, X. 2020. Deep Learning-based Detection for COVID-19 from Chest CT using Weak Label. IEEE Transactions on Medical Imaging, 1–13.

Zhou, T., Lu, H., Yang, Z., Qiu, S., Huo, B., Dong, Y. 2021. The ensemble deep learning model for novel COVID-19 on CT images. Applied Soft Computing, 98, 106885.

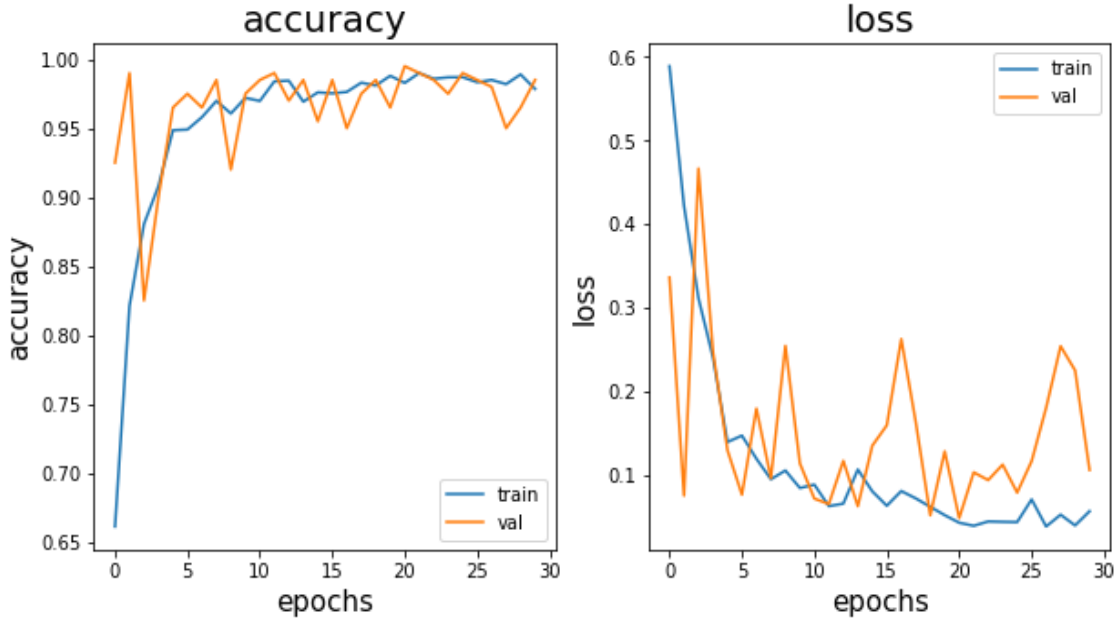
EKLER

EK-1 Tüm CNN modelleri için eğitim doğruluk ve kayıp grafikleri

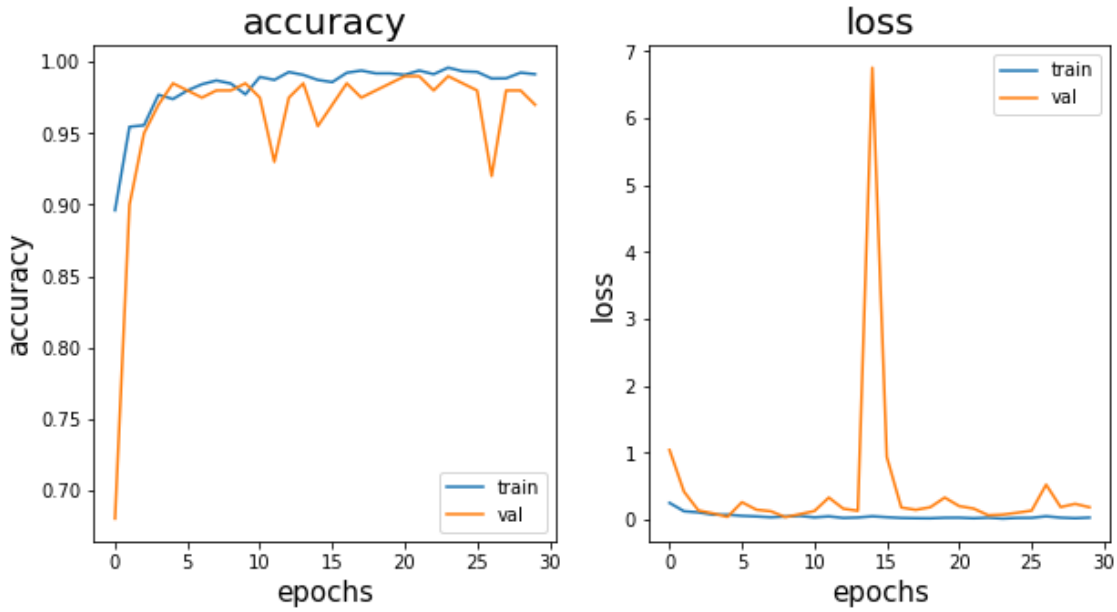
EK- 1


accuracy
loss
train
val
epochs
accuracy
loss

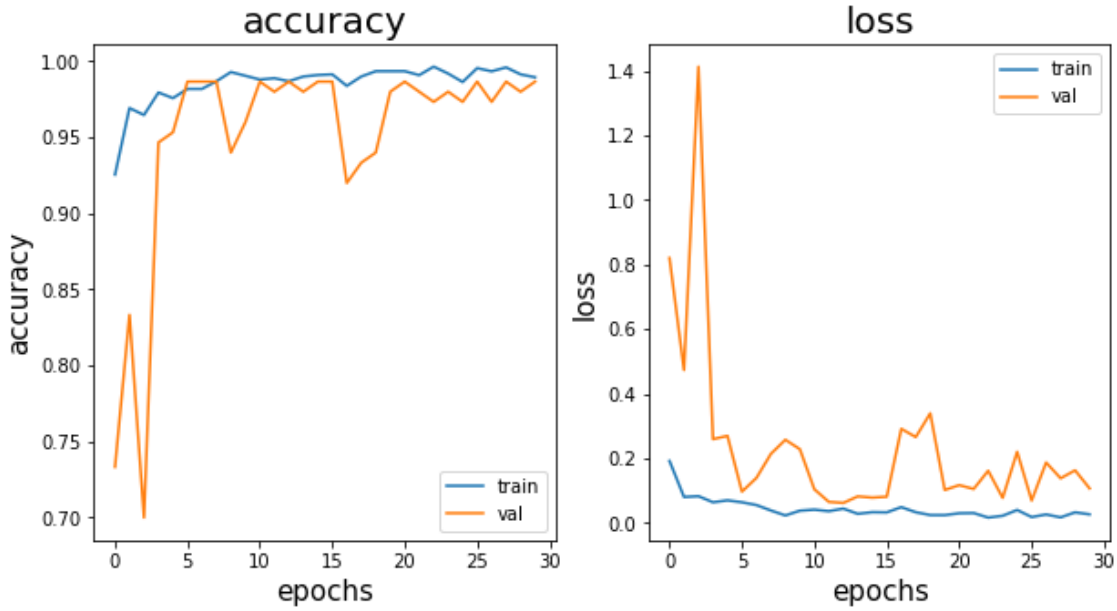
(a)


accuracy
loss
train
val
epochs
accuracy
loss

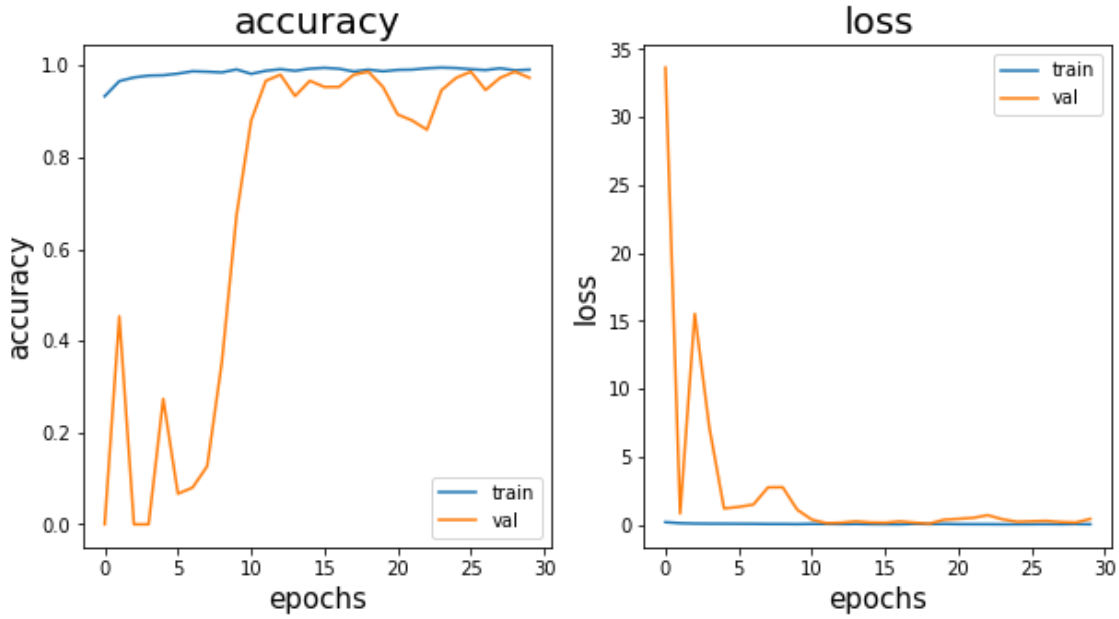
(b)


accuracy
loss
train
val
epochs
accuracy
loss

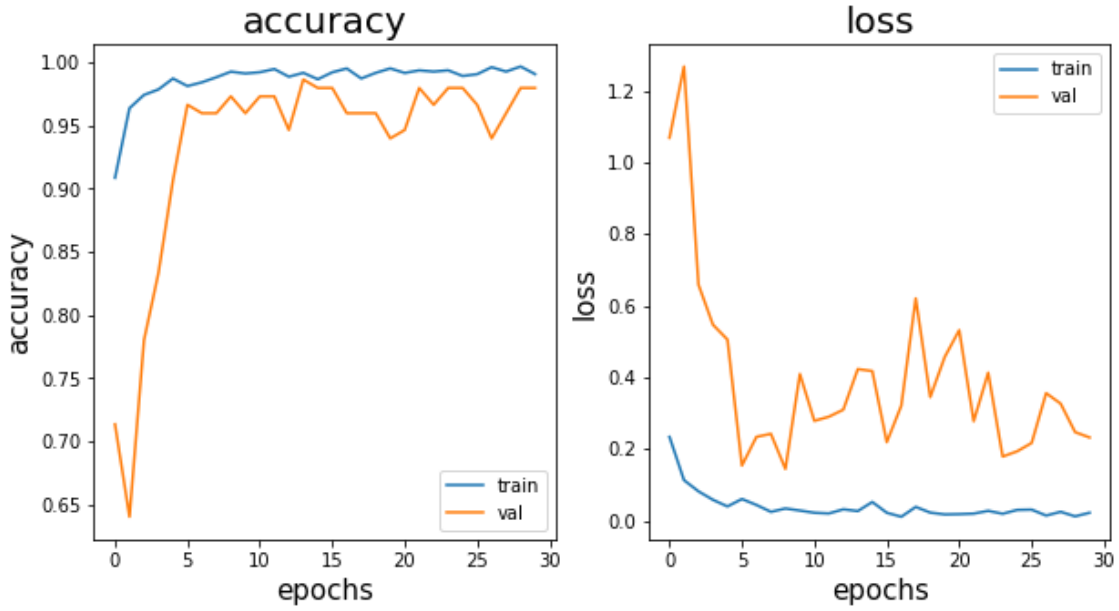
(c)


accuracy
loss
train
val
epochs
accuracy
loss

(d)



(e)



(f)

Şekil 1.1 Tüm CNN modelleri için eğitim doğrulama ve kayıp grafikleri a-) Inception-v3 b-) Vgg-16 c-) Inceptionresnetv2 d-) Densenet-201 e-) Resnet-50 f-) Xception mimarilerinin doğruluk ve kayıp grafikleri

ÖZGEÇMİŞ

Adı Soyadı	: Gözde KAHRAMAN
Eğitim Durumu	
Önlisans	: Çankırı Karatekin Üniversitesi Meslek Yüksek Okulu Endüstriyel Otomasyon Bölümü (2008-2010)
Lisans	: Erzincan Binali Yıldırım Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği (2013-2017)
Yüksek Lisans	: Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği ABD (2019-2021)