

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



COVID 19 HASTALIĞININ YAPAY ZEKA YÖNTEMLERİ
KULLANILARAK TEŞHİS EDİLMESİ

Damla KÜRŞAT

Yüksek Lisans Tezi

BİYOTEKNOLOJİ ANABİLİM DALI

ŞUBAT 2023

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Biyoteknoloji Anabilim Dalı

Yüksek Lisans Tezi

**COVID 19 HASTALIĞININ YAPAY ZEKA YÖNTEMLERİ
KULLANILARAK TEŞHİS EDİLMESİ**

Tez Yazarı
Damla KÜRŞAT

Danışman
Doç. Dr. Zafer ÇAMBAY

İkinci Danışman
Dr. Öğr. Üyesi Muhammed YILDIRIM

ŞUBAT 2023
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Biyoteknoloji Anabilim Dalı

Yüksek Lisans Tezi

Başlığı: Covid 19 Hastalığının Yapay Zeka Yöntemleri Kullanılarak Teşhis Edilmesi

Yazarı: Damla KÜRŞAT

İlk Teslim Tarihi: 02.01.2023

Savunma Tarihi: 02.02.2023

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

| | <i>İmza</i> | |
|-----------|---|-----------|
| Danışman: | Doç. Dr. Zafer ÇAMBAY Fırat Üniversitesi, Sağlık Hizmetleri Meslek Yüksekokulu | Onayladım |
| Başkan: | Dr. Öğr. Üyesi Neslihan KELEŞTEMUR Fırat Üniversitesi, Sağlık Hizmetleri Meslek Yüksek Okulu | Onayladım |
| Üye: | Dr. Öğr. Üyesi Harun BİNGÖL Malatya Turgut Özal Üniversitesi, Mühendislik Fakültesi | Onayladım |

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “ Covid 19 Hastalığının Yapay Zeka Yöntemleri Kullanılarak Teşhis Edilmesi ” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

02.02.2023

Damla KÜRŞAT



ÖNSÖZ

Biyoteknoloji, birçok endüstri ve mühendislik alanında olduğu gibi tıbbi alanlarda da büyük öneme sahiptir. Dünyanın şimdiye dek gördüğü en büyük salgın hastalıklardan olan COVID-19 hastalığının, teşhisi, kontrol altına alınması ve tedavisinde yine biyoteknolojiye başvuruldu.

COVID-19, birçok ülkedeki insanın ölümüne sebep olan bir salgın hastalıktır. Hastalığın kolay bulaş yolu (damlacık, solunum) olması nedeni ile kısa sürede milyonlarca insandan insana bulaştı. COVID-19 hastalığının teşhisinde PCR, bilgisayarlı tomografi (BT) ve antikör testleri gibi birçok yöntem kullanıldı. COVID-19'da virüsün ÜSYE (üst solunum yolu enfeksiyonu)'ye sebep olması ve akciğer tutulumu göstermesi dolayısıyla toraks BT ile teşhis konuldu.

Çalışmamızda da amaç COVID-19 pnömonisinin akciğer görüntüsünün yapay zeka yöntemleriyle teşhisine bakılarak uzman olmayan sağlık kuruluşlarında tanıyı koymak ve ayrıca uzman olan yerlerde uzmanın işini kolaylaştırmaktır.

Yüksek lisans öğrenimim boyunca bilgi, beceri ve bakış açısıyla bana sürekli yol gösteren, danışman hocam sayın Doç. Dr. Zafer ÇAMBAY'a gönülden teşekkür eder, sonsuz saygılarımı sunarım. Tez konumun seçiminde yardımcı olan, yaptığım çalışma süresince değerli bilgi ve birikimlerini esirgemeyip paylaşan, ikinci danışman hocam sayın Dr. Öğr. Üyesi Muhammed YILDIRIM'a teşekkürü bir borç bilir, saygılarımı sunarım.

Damla KÜRŞAT
ELAZIĞ, 2023

İÇİNDEKİLER

| | Sayfa |
|--|-----------|
| ÖNSÖZ..... | iv |
| İÇİNDEKİLER | v |
| ÖZET | vii |
| ABSTRACT..... | viii |
| ŞEKİLLER LİSTESİ | ix |
| TABLolar LİSTESİ | xi |
| SİMGELER VE KISALTMALAR..... | xii |
| 1. GİRİŞ | 1 |
| 1.1. COVİD-19 bulaşma ve Klinik | 3 |
| 1.2. Zatürre (Pnomokok Pnömonosi) | 4 |
| 2. İLGİLİ ÇALIŞMALAR | 5 |
| 3. MATERYAL VE METOT..... | 10 |
| 3.1. Derin Öğrenme ve Evrişimsel Sinir Ağları | 10 |
| 3.2. Evrişimsel Sinir Ağları Mimarileri | 12 |
| 3.2.1. Alexnet | 12 |
| 3.2.2. LeNet | 12 |
| 3.2.3. VGG | 13 |
| 3.2.4. ResNet | 13 |
| 3.2.5. Xception | 14 |
| 3.2.6. GoogleNet..... | 14 |
| 3.2.7. DenseNet | 15 |
| 3.2.8. MobileNet..... | 15 |
| 3.2.9. EfficientNet | 16 |
| 3.2.10. ShuffleNetV2..... | 17 |
| 3.2.11. NasNet Mobile..... | 18 |
| 3.3. Önerilen Model | 19 |
| 3.4. Veri Seti | 20 |
| 3.5. Çalışmada kullanılan mimariler ve ön hazırlık | 21 |
| 4. BULGULAR VE TARTIŞMA | 23 |
| 4.1. ESA mimarilerinin ve önerilen modelin sonuçları | 24 |
| 4.2. Alexnet mimarisinde elde edilen sonuçlar | 24 |
| 4.3. DenseNet201 mimarisinde elde edilen sonuçlar | 26 |
| 4.4. GoogleNet mimarisinde elde edilen sonuçlar | 28 |
| 4.5. MobileNetV3 mimarisinde elde edilen sonuçlar | 30 |
| 4.6. Resnet101 mimarisinde elde edilen sonuçlar | 32 |
| 4.7. Vgg19 mimarisinde elde edilen sonuçlar | 34 |
| 4.8. Xception mimarisinde elde edilen sonuçlar | 36 |
| 4.9. Efficientnetb0 mimarisinde elde edilen sonuçlar | 37 |
| 4.10. ShuffleNet mimarisinde elde edilen sonuçlar | 39 |
| 4.11. NasNet Mobile mimarisinde elde edilen sonuçlar | 41 |
| 4.12. Önerilen modelde elde edilen sonuçlar | 43 |

| | |
|-------------------------|-----------|
| 5. SONUÇLAR..... | 48 |
| ÖNERİLER | 49 |
| KAYNAKLAR..... | 50 |
| ÖZGEÇMİŞ | |



ÖZET

Covid 19 Hastalığının Yapay Zeka Yöntemleri Kullanılarak Teşhis Edilmesi

Damla KÜRŞAT

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Biyoteknoloji Anabilim Dalı

Şubat 2023, Sayfa: xii + 53

COVID-19'la birlikte yapay zeka ve özellikle makine öğrenme işlemleri için yeni bir süreç başlamıştır. Koronavirüs salgınının bu kadar yaygın ve ölümcül olmasından dolayı bilgisayar destekli sistemler kullanılarak koronavirüsün tespit edilmesi büyük bir önem arz etmektedir. Yapılan bu tez çalışmasında ESA tabanlı hibrit bir model geliştirilmiştir. Koronavirüs hastalığını tespit etmek için geliştirilen modelde Resnet101 ve Densenet201 mimarileri taban olarak kullanılmıştır. Resnet101 ve Densenet201 mimarilerinin fc1000 katmanlarından özellik haritaları elde edilmiştir. Resnet101 ve Densenet201 mimarilerinden elde edilen her bir özellik haritasının boyutu 3075 x 1000'dir. Resnet101 ve Densenet201 mimarileri kullanılarak elde edilen bu özellik haritaları daha sonra birleştirilmiştir. Birleştirilen özellik haritasının boyutu 3075 x 2000 olmuştur. Bu sayede aynı görüntünün farklı özellikleri bir araya getirilmiştir. Bu da geliştirilen modelin başarımını artıracaktır. Önerilen hibrit modelin son aşamasında birleştirilen özellik haritaları SVM sınıflandırıcısında sınıflandırılmıştır. Yapılan bu tez çalışmasında önerilen modelin başarımını test edebilmek için literatürde kabul görmüş önceden eğitilmiş farklı ESA mimarileri kullanılmıştır. Sonuç olarak önerilen hibrit model literatürde kabul görmüş ESA mimarilerinden daha başarılı olmuştur. Önerilen hibrit model %98.2 oranında bir doğruluk değeri elde etmiştir. Önerilen modelde elde edilen sonuçlar önerilen modelin uzman olmayan yerlerde ön teşhis için kullanılabileceğini ve uzman olan yerlerde ise önerilen modelin uzmanların iş yükünü hafifleteceği ve maliyetleri azaltacağı kanaatine varılmıştır.

Anahtar Kelimeler: Biyoteknoloji, ESA, COVID-19, Yapay Zeka, Zatiirre

ABSTRACT

Diagnosing Covid 19 Disease Using Artificial Intelligence Methods

Damla KÜRŞAT

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences

Department of Biotechnology

February 2023, Pages: xii + 53

A new process has started with Covid 19 for artificial intelligence and especially machine learning processes. Since the coronavirus epidemic is so widespread and deadly, it is of great importance to detect the coronavirus using computer-aided systems. In this thesis, a CNN-based hybrid model has been developed. Resnet101 and Densenet201 architectures were used as the base in the model developed to detect the coronavirus disease. Feature maps were obtained from the fc1000 layers of the Resnet101 and Densenet201 architectures. The size of each feature map obtained from the Resnet101 and Densenet201 architectures is 3075 x 1000. These feature maps obtained using the Resnet101 and Densenet201 architectures were then combined. The size of the combined feature map was 3075 x 2000. In this way, different features of the same image are brought together. This will increase the performance of the developed model. In the last step of the proposed hybrid model, the combined feature maps are classified in the SVM classifier. In this thesis study, different pre-trained CNN architectures accepted in the literature were used to test the performance of the proposed model. As a result, the proposed hybrid model has been more successful than the CNN architectures accepted in the literature. The proposed hybrid model achieved an accuracy of 98.2%. It is obvious that the results obtained in the proposed model can be used for pre-diagnosis in non-experts, and that the proposed model will alleviate the workload of experts and reduce costs in specialists.

Keywords: Biotechnology, Covid-19, CNN, Artificial Intelligence, Pneumonia

ŞEKİLLER LİSTESİ

| | Sayfa |
|--|-------|
| Şekil.1.1.SARS-CoV-2 genel görünümü..... | 2 |
| Şekil 1.2. İnsandaki koronavirüslerinin hayvan kökenleri..... | 3 |
| Şekil 3.1. Yapay zekâ ve alt kümeleri..... | 10 |
| Şekil 3.2. ESA mimarilerinin temel yapısı..... | 11 |
| Şekil 3.3. AlexNet mimarisi..... | 12 |
| Şekil 3.4. LeNet mimarisi..... | 13 |
| Şekil 3.5. VGG16 mimarisi..... | 13 |
| Şekil 3.6. Resnet50 artık blok gösterim..... | 14 |
| Şekil 3.7. GoogleNet başlangıç katmanı..... | 15 |
| Şekil 3.8. Büyüme oranı $k = 3$ olan 4 katmanlı yoğun blok..... | 15 |
| Şekil 3.9. MobileNetV3 genel yapısı..... | 16 |
| Şekil 3.10. Efficientnetb0 mimarisinin genel yapısı..... | 17 |
| Şekil 3.11. ShuffleNet V2 temel birimleri: (a) temel birim, (b) uzamsal alt örnekleme için temel birim [70]..... | 18 |
| Şekil 3.12. Önerilen modelin blok diyagramı..... | 19 |
| Şekil 3.13. Veri setinden örnekler..... | 21 |
| Şekil 3.14. Karışıklık matrisi örneği..... | 22 |
| Şekil 4.1. AlexNet mimarisinde elde edilen doğruluk ve kayıp eğrileri..... | 24 |
| Şekil 4.2. Alexnet mimarisinde elde edilen karışıklık matrisi..... | 25 |
| Şekil 4.3. DenseNet201 mimarisinde elde edilen doğruluk ve kayıp eğrileri..... | 26 |
| Şekil 4.4. DenseNet201 mimarisinde elde edilen karışıklık matrisi..... | 27 |
| Şekil 4.5. GoogleNet mimarisinde elde edilen doğruluk ve kayıp eğrileri..... | 28 |
| Şekil 4.6. GoogleNet mimarisinde elde edilen karışıklık matrisi..... | 29 |
| Şekil 4.7. MobileNetV3 mimarisinde elde edilen doğruluk ve kayıp eğrileri..... | 30 |
| Şekil 4.8. MobileNetV3 mimarisinde elde edilen karışıklık matrisi..... | 31 |
| Şekil 4.9. Resnet101 mimarisinde elde edilen doğruluk ve kayıp eğrileri..... | 32 |
| Şekil 4.10. Resnet101 mimarisinde elde edilen karışıklık matrisi..... | 33 |
| Şekil 4.11. Vgg19 mimarisinde elde edilen doğruluk ve kayıp eğrileri..... | 34 |
| Şekil 4.12. Vgg19 mimarisinde elde edilen karışıklık matrisi..... | 35 |
| Şekil 4.13. Xception mimarisinde elde edilen doğruluk ve kayıp eğrileri..... | 36 |
| Şekil 4.14. Xception mimarisinde elde edilen karışıklık matrisi..... | 36 |

| | |
|--|----|
| Şekil 4.15. EfficientNetb0 mimarisinde elde edilen doğruluk ve kayıp eğriler..... | 38 |
| Şekil 4.16. EfficientNetb0 mimarisinde elde edilen karışıklık matrisi | 38 |
| Şekil 4.17. ShuffleNet mimarisinde elde edilen doğruluk ve kayıp eğrileri..... | 40 |
| Şekil 4.18. ShuffleNet mimarisinde elde edilen karışıklık matrisi | 40 |
| Şekil 4.19. NasNet Mobile mimarisinde elde edilen doğruluk ve kayıp eğrileri..... | 42 |
| Şekil 4.20. NasNet Mobile mimarisinde elde edilen karışıklık matrisi | 42 |
| Şekil 4.21. Önerilen modelde elde edilen karışıklık matrisi..... | 44 |
| Şekil 4.22. Önerilen modelde elde edilen AUC Eğrileri | 46 |
| Şekil 4.23. Modellerde elde edilen doğruluk değerleri..... | 47 |



TABLULAR LİSTESİ

| | Sayfa |
|---|-------|
| Tablo 4.1. AlexNet mimarisinde elde edilen performans metrikleri..... | 25 |
| Tablo 4.2. DenseNet201 mimarisinde elde edilen performans metrikleri..... | 28 |
| Tablo 4.3. GoogleNet mimarisinde elde edilen performans metrikleri..... | 30 |
| Tablo 4.4. MobileNetV3 mimarisinde elde edilen performans metrikleri..... | 32 |
| Tablo 4.5. Resnet101 mimarisinde elde edilen performans metrikleri..... | 33 |
| Tablo 4.6. Vgg19 mimarisinde elde edilen performans metrikleri..... | 35 |
| Tablo 4.7. Xception mimarisinde elde edilen performans metrikleri..... | 37 |
| Tablo 4.8. EfficientNetb0 mimarisinde elde edilen performans metrikleri..... | 39 |
| Tablo 4.9. ShuffleNet mimarisinde elde edilen performans metrikleri..... | 41 |
| Tablo 4.10. NasNet Mobile mimarisinde elde edilen performans metrikleri..... | 43 |
| Tablo 4.11. Önerilen modelde elde edilen performans metrikleri..... | 45 |

SİMGELER VE KISALTMALAR

Simgeler

% : Yüzde

Kısaltmalar

| | |
|------------|--|
| ARDS | : Akut Respiratuar Distres Sendromu |
| CADx | : Bilgisayar Destekli Teşhis |
| ESA | : Evrişimli Sinir Ağı |
| DİK | : Dissemine intravasküler koagulopati |
| DSÖ | : Dünya sağlık örgütü |
| ESA | : Evrişimsel Sinir Ağları |
| FN | : Yanlış Negatif |
| FP | : Yanlış Pozitif |
| HDCNN | : Konvüsyonel Sinir Ağı |
| KOAH | : Kronik obstrüktif akciğer hastalığı |
| LAMP | : İzotermal amplifikasyon |
| MERS-CoV | : Orta Doğu Solunum Sendromu |
| NHC | : Çin Ulusal Sağlık Komisyonu |
| PCR | : Polymerase Chain Reaction- Polimeraz Zincir Reaksiyonu |
| ReLU | : Doğrultulmuş Doğrusal Birim |
| RNA | : Ribonükleik asit |
| SARS-CoV | : Şiddetli Akut Solunum Sendromu |
| SARS-CoV-2 | : Akut Solunum Sendromu Koronavirüs-2 |
| TN | : Gerçek Negatif |
| TP | : Gerçek Pozitif |
| WHO | : Dünya Sağlık Örgütü |
| ÜSYE | : Üst Solunum Yolu Enfeksiyonu |

1. GİRİŞ

Biyoteknoloji, pek çok doğa biliminin yanı sıra mühendislik alanlarından da yararlanarak DNA teknolojisi ile bitki, hayvan ve mikroorganizma gibi canlıları yetiştirmek, geliştirmek, ihtiyacımız kadar üretilmeyen maddeleri üretmek amacıyla uygulanan teknolojilerin tümüdür. Özellikle kısa sürede ticari kar elde etmek istenen ürünler üzerinde uygulanmasıyla kendi talebini de yaratabilir. Teknolojinin pek çok alanını bünyesinde toplar. Bu nedenle de diğer alanlarla disiplinler bir çalışma içerisindedir. Canlıların tamamını ya da genetik bir parçasını kullanarak yeni bir canlı elde etmek, genetik yapıda istenilen değişiklik elde etmek amacıyla kullanılan yöntemlerin tümüdür. İnsanlar için önemli proteinlerin üretilmesi, bazı hormon, vitamin, antibiyotiklerin üretilmesi, yeni sebze ve meyve üretilmesi, yapay organ ve doku üretilmesi tıbbi bitkilerin yetiştirilmesi gibi pek çok alanda biyoteknoloji kullanılmaktadır [1].


Yeni bir koronavirüs tarafından koronavirüs hastalığı (COVID-19) olarak bilinen şiddetli Akut Solunum Sendromu Koronavirüs-2 (SARS-CoV-2) ortaya çıktı. SARS-CoV-2, genellikle insanlarda yayılan soğuk algınlığına neden olan diğer koronavirüslere benzemez. COVID-19, akut solunum yolu bulaşıcı bir hastalıktır esas olarak solunum yoluyla bulaşır. Bu yeni koronavirüsün neden olduğu ilk pnömoni vakası, 2019 yılı sonunda bildirilmiştir [2]. Koronavirüs hastalığı 2019 (COVID-19) pandemisi, dünya çapında benzeri görülmemiş bir sağlık krizidir. İnsandan insana bulaşıcı bir hastalık olan COVID-19'un neden olduğu şiddetli viral pnömoniye ve akut solunum yolu hastalığına yol açabilen SARS-CoV-2 adlı yeni bir koronavirüs tarafından oluşmuştur [2].

SARS-CoV-2 (COVID-19), tek sarmallı bir RNA virüsüdür, "Corona" adı, sivri uçlarının bir taca benzerliği nedeniyle verilen "Taç" anlamına gelen Latince bir kelimedir (Şekil 1.1) [2]. Koronavirüslerin, insanlarda ve hayvanlarda Şiddetli Akut Solunum Sendromu (SARS-CoV) ve Orta Doğu Solunum Sendromu (MERS-CoV) dahil olmak üzere çok sayıda sendroma neden olma geçmişi vardır. SARS-CoV ilk olarak 2002'de ortaya çıktı ve dünya çapında yayıldı. SARS-CoV'nin bulaşması, damlacık yoluyla, insandan insana temas yoluyla gerçekleşti. MERS-CoV, Eylül 2012'de Suudi Arabistan'da rapor edildi. Geriye dönük incelemelerde, bilinen ilk MERS vakası Nisan 2012'de Ürdün'de ortaya çıkmıştır [2, 3]. MERS-CoV, diğer koronavirüsler gibi, muhtemelen enfekte kişilerin öksürme veya hapşırma gibi solunum salgıları yoluyla yayılır. Bununla birlikte, MERS'in bulaşma yolu tam olarak anlaşılmamıştır [2].

Koronavirüsler soğuk algınlığından Orta Doğu Solunum Sendromu (MERS) ve Şiddetli Akut Solunum Sendromu (SARS) gibi solunum yetmezliği ile seyreden daha ciddi hastalıklara kadar geniş spektrumlu klinik tablolara yol açmaktadır [4]. SARS-CoV-2 virüsünün semptomlar başlamadan önce 2-14 gün arası kuluçka dönemi vardır. COVID-19 semptomları yüksek ateş, öksürük, dispne, kas ağrısı ve diaredir [5]. COVID-19 klinik seyri bireyler arası farklılıklar

gösterebilmektedir [6]. Özellikle diyabet, hipertansiyon, kronik obstrüktif akciğer hastalığı (KOA) gibi komorbiditesi olan hastalarda Akut Respiratuar Distres Sendromu (ARDS), metabolikasidoz, septik şok, dissemine intravasküler koagulopati (DİK) ve çoklu organ yetmezliğine bağlı ölümler gerçekleşebilmektedir [6].

Hastalığın erken tespiti, yayılmasını kontrol etmenin ve daha fazla sağlık, sosyal ve ekonomik zararı önlemenin anahtarı olmuştur. Ana tanı yöntemleri, serolojik / antijen testleri ve RT-PCR (ters transkripsiyon-polimeraz zincir reaksiyonu) gibi moleküler analizlerden oluşur. Pandeminin başlangıcında, viral enfeksiyona yanıt olarak üretilen antikorları (immunoglobulin-M ve immunoglobulin-G) hızlı ve düşük maliyetli bir şekilde hedeflemesi nedeniyle lateral-flow testine dayalı serolojik testler yaygın olarak kullanılıyordu [7, 8]. Bununla birlikte, anti-COVID-19 aşularının ortaya çıkmasından sonra, virüs enfeksiyonu yerine aşıya yanıt olarak üretilen antikorları tespit edebildiği için bu test artık uygun görülmemektedir. RT-PCR testi, viral RNA enfeksiyonunun ilk günlerinde yüksek özgüllük ve duyarlılıkla tespit edilebildiği ve güvenilir bir sonuç sağladığı için altın standart teşhis yöntemidir [9, 10]. Diğer moleküler testler de kullanılmaktadır, 1 saat içinde hedef genin sekiz adede kadar dizisini tanıyabilen modern ve hassas bir nükleik amplifikasyon yöntemi olan döngü aracılı izotermal amplifikasyon (LAMP) yöntemi örnek verilebilir [10]. Ancak bu yöntemler zahmetli, pahalı ve uzman profesyoneller ve laboratuvar altyapısı gerektirerek artan taleplere cevap vermeyi zorlaştırıyor. Şu anda, yanal akış yöntemini kullanan antijen testleri, hasta başı teşhis için en yaygın şekilde kullanılmaktadır [11]. Salgın ve pandemik durumlarda, teşhis testlerine olan talebin çok artabileceği durumlarda, testlerin üretilmesi için gereken malzeme eksikliğini önlemek için farklı stratejiler kullanılarak cihazlar geliştirilmelidir. Örneğin, omikron varyantının günlük vakaları zirveye ulaştığında, yanal akış testleri için yüksek bir talep vardı ve sonuç olarak birçok ülke, altın nanopartiküller gibi kaynakların eksikliği olasılığı konusunda tetikte kaldı [12].




Şekil.1.1.SARS-CoV-2 genel görünümü [13].

1.1. COVID-19 bulaşma ve Klinik

COVID-19 ile enfekte hastaların çoğunun, virüs içeren yüzey, enfekte hastalar veya virüs taşıyıcıları ile temas öyküsü vardı. Ayrıca, enfekte hastalarda ateş, öksürük, yorgunluk ve şiddetli vakalarda nefes darlığı gibi soğuk algınlığına ile ortak semptomlar görülür. Enfekte hastalarda en sık görülen komplikasyon pnömoni olup hastaların solunum bozuklukları izledi ve nadiren şoklar bulundu [2, 14].

COVID-19 ile enfekte olmuş hastalarda bulunan bazı semptomlar; ishal, hemoptizi, baş ağrısı, balgam üretimi, myalgia (kas ağrısı), öksürük, ateş olarak sıralanabilir. COVID-19 genellikle enfekte bir kişiyle fiziksel temas (kişiden kişiye), damlacık yoluyla bulaşır veya daha az olasılıkla ağızdan bulaşır [15]. Bildirilen sonuçlar, insandan insana bulaşmanın kanıtını sağladı. Ayrıca araştırmacılar, enfekte hastaların dışkı örneklerinde, gastrointestinal sistem, tükürük ve idrarında da SARS-CoV-2 tespit ettiler [14]. ACE2 (Anjiyotensin dönüştürücü enzim 2) bir bağışıklık sistemlerinin önemli bir parçası ve SARS-CoV-2 konakçı hücreleri ACE2 reseptörleri yoluyla enfekte ederek COVID-19'a neden olur [16]. Bu nedenle enfekte olan bireyler SARS-CoV-2, hastalığın ilerlemesi sonucunda bağışıklık sistemi bozukluklarıyla karşı karşıyadır [2]. Develer ve yarasalar başta olmak üzere birçok hayvan türünde yaygın olarak bulunmaktadır. Alfa, beta, gama ve delta olmak üzere dört koronavirüs alt grubu bulunmaktadır [15]. Alfacoronavirus: yarasa, insan, domuz; Betacoronavirus: kemirgenler, yarasa, insan; Gammacoronavirus: kuş, deniz memeli hayvanları; Deltacoronavirus: bülbül, ispinoz ve ardıç kuşunda tanımlanmıştır (Şekil 1.2.) [17, 18].



Şekil 1.2. İnsandaki koronavirüslerinin hayvan kökenleri [19].

Tüm yaş gruplarındaki insanlara SARS-CoV-2 bulaşabilir. Çin Ulusal Sağlık Komisyonu'na (NHC) göre, ölümlerin yaklaşık %80'i 60 yaşın üzerindeki hastalarda rapor

edilirken, bunların %75'i diyabet ve kardiyovasküler hastalıklar dahil olmak üzere önceden sağlık sorunları yaşayan insanlardır. 27 Ocak 2020 tarihinde yayınlanan DSÖ Durum Raporu No.7 doğrultusunda, Çin dışında tespit edilen vakaların medyan yaşı 45'tir (2-74 yaş). Yaşlı insanlar, özellikle önceden sağlık sorunları olan astım, diyabet veya kalp hastalığı gibi hastalığı olanların COVID-19'dan ölme olasılığı daha yüksektir [20, 21].

1.2. Zatürre (Pnomokok Pnömonosi)

Etkeni pnömokoktur. Gram pozitif kapsüllü diplokoktur. Pnömokokların neden olduğu akciğer dokusunun kırmızılık, şişkinlik, ısı ve ağrıyla baş gösteren cerahat toplanmasına pnömokok pnömonisi denir. Birçok etken pnömoneye sebep olabileceği gibi pnömokoklarında birden çok serotipi tespit edilmiştir. Her serotip farklı şekil ve farklı hastalık şiddetinde oluşur. Pnömokoklar sağlıklı insanların normal boğaz florasında bulunur bu nedenle bulaşma önem taşımaz. En önemli bulaşma yolu solunum yoludur [22].

Patogenez ve klinik belirtileri, normal boğaz florasında bulunan pnömokoklar üst solunum yolunda yerleşip çoğalırlar. Bağışıklığı düşüren hazırlayıcı faktörler hastalığın oluşmasında önem taşır. Bu faktörler ise; yeterli beslenmeme, aşırı alkol tüketimi, geçirilen ÜSYE, aspirasyon, soğuk algınlığı, kafa travmaları vs. Zatürre hastalığı daha çok yoksul ve kalabalık toplumlarda çocuk ve yaşlılarda daha fazla görülür. Hastalık soğuk algınlığı ve yüksek ateşle başlar, göğüs, baş, karın ağrısı, huzursuzluk ve sayıklama ile kendini gösterir. Sonraki gün öksürük başlar, başlarda kuru olan öksürük pürülan ve paslı balgama dönüşür. Son olarak solunum güçlüğü, siyanoz ve bulantı-kusma eklenir [22].

Klinik tanı, ateş, göğüs ağrısı, öksürük, hırıltılı solunum kanlı ve paslı balgamla konulabilir. Laboratuvar çalışmalarında lökositoz vardır. Nazofarenks sekresyon kültüründe patojen etken tespiti ile kesin tanı konulur. Röntgen grafisi de teşhis konulmasında önemli rol oynar. En sık görülen komplikasyonları, perikardit, endokardit, otitis media, sinüzit, artrit, sepsis ve menenjittir [22].

Pnömoni (zatürre), insan akciğerlerindeki hava keseciklerini sıvı ve cerahatla dolduran bir enfeksiyondur. Bu hastalığa yakalanan hastanın göğsünde rahatsızlık, ağrı, nefes alma ve solunum güçlüğü yaşar. Fakat Covid zatürresi başlayan hastalarda oksijen düzeyleri düşsede nefessiz kalmazlar. Daha sonra nefes almak zorlaşmaya başladığında ise oksijen düzeyleri aşırı düşmüş oluyor ve röntgenlerinden pnömoni orta ve ağır düzeye kadar ilerlemiş olduğu anlaşılıyor [22].

2. İLGİLİ ÇALIŞMALAR

Koronavirus hastalığı, Çin'in Hubei eyaletinin Wuhan kentinde 2019'da etyolojisi bilinmeyen pnömoni vakaları şeklinde ortaya çıkan ve ardından pandemi şeklinde birçok ülkeye hızla yayılan bulaşıcı bir viral hastalıktır. Koronavirüs salgınından dünyada birçok kişi etkilenmiş ve birden fazla kişi ölmüştür. Koronavirüs hastalığının erken tespit edilmesi tedavi sürecinin daha erken başlamasına ve ölüm vakalarının minimuma indirgenmesine imkân tanıyacaktır. Bundan dolayı bilgisayar destekli sistemler kullanılarak COVID-19 virüsünün tespit edilmesi büyük bir önem arz etmektedir. Literatürde konuyla ilgili yapılmış çalışmalar mevcuttur.

Alakuş ve Türkoğlu yapmış oldukları çalışmada geliştirdikleri modeli 600 hastadan alınan 18 labaratuvar bulgusu kullanarak test etmişlerdir. Araştırmacılar yapmış oldukları çalışmada ESA mimarilerini kullanarak %87.35, YSA kullanarak %86.90, ESALSTM ağında %93.68 ve LSTM ağında %86.66 oranında bir doğruluk elde etmişlerdir. Araştırmacılar deneyler boyunca 10 kat çapraz doğruluma tekniğini kullanmışlardır. Araştırmacılar yapmış oldukları çalışmada farklı veri setleri kullanarak önermiş oldukları modeli test etmişlerdir [23].

Jain ve arkadaşları x-ray görüntüleri kullanarak eğitmiş oldukları modelde %97.77 oranında bir doğruluk değerine ulaşmışlardır. Yapılan çalışmada araştırmacılar veri setinde ki x-ray görüntülerine görüntü ön işleme adımlarını uygulamışlardır. Görüntü ön işleme adımlarından ilki görüntü boyutlandırma ve ikincisi ise veri çoğullamadır. Araştırmacılar uygulama sonuçlarını python ortamında elde etmişlerdir. Çalışmada Resnet18, Resnet50, Densenet121 ve Resnet101 kullanılan ESA mimarileridir. Yapılan bu çalışmada araştırmacılar 5 kat çapraz doğruluma tekniğini kullanmışlardır [24].

Azemin ve arkadaşlarının yaptıkları bu çalışmada; göğüs röntgeninden COVID-19'u saptamak için ResNet101 ESA mimarisine dayalı bir derin öğrenme (DL) yöntemi önerdiler. Bu çalışmada anlamlı nesnelere ayırt etmek için ön eğitim aşamasında binlerce göğüs röntgeni görüntüsü kullanıldı ve anormallikleri saptamak için yeniden eğitim aşamasında binlercesi daha kullanıldı. Bu yöntem yalnızca %71,9 doğruluk elde edilmişlerdir [25, 26].

Nishio ve arkadaşları yaptıkları çalışmada, COVID-19 pnömonisini, COVID-19 olmayan pnömoniyi ve sağlıklı akciğeri sınıflandırmak için bir Bilgisayar Destekli Teşhis (CADx) oluşturdu. Özelleştirilmiş bir veri seti üzerinde eğitim vermek için VGG16'yı benimsediler. Model eğitiminde üç tür veri artırma yönteminin kombinasyonu (çevirme, kaydırma ve döndürme vb. geleneksel yöntem, karıştırma ve Rastgele Görüntü Kırpma ve Yamalama-RICAP) uygulandı. CAD sistemi, 125 CXR görüntüsü içeren test setine göre %83,6 doğruluk sağladığını belirttiler [26, 27].

Khan ve arkadaşları yaptıkları çalışmada, göğüs röntgeni görüntülerinden COVID-19 enfeksiyonunu otomatik olarak saptayan CoroNet adlı derin bir ESA modeli sundu. Önerilen bu

model, Xception mimarisi üzerinde geliştirilmiştir ve özel bir ImageNet veri seti üzerinde eğitilmiştir. Model, %89,6'lık bir genel doğruluk elde etti [26, 28].

Wang ve arkadaşları yaptıkları çalışmada, insan-makine işbirliğine dayalı bir tasarım stratejisi kullanarak CXR görüntülerinden COVID-19'u tahmin edebilen COVID-Net adlı bir ESA modeli uyarladı. Modeli eğitmek ve değerlendirmek için bir kıyaslama veri seti kullanılır. Tanıtılan model, üç sınıf (COVID+, pnömoni ve normal vaka) tahmininde %93,3 doğruluk elde etti [26, 29].

Oh ve arkadaşları yaptıkları çalışmada göğüs x-ray görüntülerini sınıflandırmak için 502 adet görüntüden oluşan bir veri seti kullanmışlardır. Yapılan bu çalışmada araştırmacılar segmentasyon ve sınıflandırma yapmışlardır. Araştırmacıların önerdiği modelde segmentasyon adımında DenseNet mimarisi taban olarak kullanılırken, sınıflandırma aşamasında Resnet18 mimarisi taban olarak kullanılmıştır. Araştırmacılar ayrıca önerdikleri modelde Grad-Cam teknolojisini kullanarak göğüs x-ray görüntülerinin ısı haritalarını elde etmişlerdir. Göğüs x-ray görüntülerini sınıflandırmak için önerilen modelde elde edilen doğruluk değeri %88.9 olmuştur [30].

Aslan ve arkadaşları yaptıkları çalışmada ESA tabanlı mimarileri ve Bayesian Optimizasyon yöntemini taban olarak kullanıp hibrit bir model geliştirmişlerdir. Araştırmacılar yapmış oldukları bu çalışmada özellik çıkarımı için 8 farklı ESA mimarisi kullanmışlardır. Elde edilen özellik haritaları 4 farklı makine öğrenmesi sınıflandırıcısında kullanılmıştır. Yapılan çalışmada en yüksek doğruluk değeri Densenet201 mimarisi taban olarak kullanılıp özellik çıkarımı yapıldıktan sonra SVM sınıflandırıcısında elde edilmiştir. Bu yöntemde elde edilen doğruluk değeri %96.29 olmuştur [31].

Irmak yaptığı çalışmada 4 evreden oluşan göğüs x-ray görüntülerini kullanarak sınıflandırma işlemini gerçekleştirmiştir. COVID-19göğüs x-ray görüntülerinin sınıflandırılması için araştırmacı ESA tabanlı bir model geliştirmiştir. Giriş katmanında dahil 16 katmandan oluşan bu model göğüs x-ray görüntülerini sınıflandırmada %95.52 oranında bir doğruluk değeri elde etmiştir. Yapılan çalışmada önerilen model ayrıca literatürde kabul görmüş 4 farklı ESA mimarisi ile de karşılaştırılmıştır. Önerilen modelde elde edilen başarımleri önceden eğitilmiş ESA mimarilerinden daha iyi sonuçlar vermiştir [32].

Monshi ve arkadaşları göğüs x-ray görüntülerini sınıflandırmak için CovidXrayNet isminde bir model önermişlerdir. Araştırmacılar veri çoğullama ön işleme adımının ESA modellerinin başarımını artırdığı belirterek yapılan çalışmada öncelikle veri çoğullama işlemini gerçekleştirmişlerdir. Normal, zatürre ve COVID-19görüntülerinden oluşan veri seti üzerinde araştırmacıların önermiş olduğu model %95.82 oranında bir doğruluk değerine ulaşmıştır. Araştırmacıların önermiş olduğu model 30 adım çalıştırılmıştır. Önerilen model ayrıca literatürde

kabul gören farklı ESA mimarileri ile de karşılaştırılmıştır. Araştırmacılar önerilen modelin daha yüksek bir doğruluk değerine ulaştığını belirtmişlerdir [33].

Heidari ve arkadaşları Radyografik göğüs görüntülerinin, COVID-19'u daha doğru bir şekilde tespit etmek ve hastalık şiddetini değerlendirmek için kullanılabileceğini ifade etmişlerdir. 8474 göğüs x-ray görüntüsünden oluşan veri setinde, araştırmacıların önermiş olduğu model %94.1 doğruluk değerine ulaşmıştır. Yapılan çalışmada VGG16 mimarisi kullanılmıştır. Bu mimari literatürde sıklıkla kullanılan mimarilerden biridir [34].

Hira ve arkadaşı yapmış oldukları çalışmada göğüs x-ray görüntülerini kullanarak yapmış oldukları çalışmada 9 farklı önceden eğitilmiş ESA mimarisini kullanarak deneysel sonuçları elde etmişlerdir. Ayrıca araştırmalar ön işleme adımında boyutlandırma ve görüntü çoğullama yapmışlardır. Görüntü çoğullama işleminde modellerin doğruluk oranının arttığı gözlemlenmiştir. Araştırmacılar yapmış oldukları çalışmada 4 farklı veri seti kullanmışlardır [35].

Jia ve arkadaşları COVID-19 tespiti için göğüs x-ray görüntüleri ve bilgisayarlı tomografi görüntülerini kullanmışlardır. Araştırmacılar yapmış oldukları çalışmada Resnet ve Mobilenet mimarilerini dinamik kullanarak COVID-19 teşhisini amaçlamışlardır. Yapılan çalışmada %98.8 oranında bir doğruluk değerine ulaşılmıştır. Araştırmacılar yapmış oldukları çalışmada veri setindeki görüntülerin sınıflandırılması sürecinde 5 kat çapraz doğrulama tekniğini kullanmışlardır [36].

Dastider ve arkadaşları Akciğer ultrasonundan COVID-19 ciddiyet tahmini için entegre otomatik kodlayıcı tabanlı hibrit ESA-LSTM model geliştirmişlerdir. Geliştirilen modelde otomatik kodlayıcılar, ESA mimarilerinden biri olan Densenet201 ve LSTM ağları birlikte kullanılmıştır. Yapılan çalışmada önerilen modelin etkinliğini daha iyi açıklayabilmek için araştırmacılar 5 kat çapraz doğrulama tekniğinden faydalanmışlardır. Ayrıca yapılan çalışmada göğüs x-ray görüntülerinin ısı haritalarının elde edilmesi sürecinde Grad-Cam tekniğide kullanılmıştır. Araştırmacılar geliştirmiş oldukları modelin COVID-19 teşhisinde kullanılabileceğini ifade etmişlerdir [37].

Güngör tarafında yapılan çalışmada, DeOldify kütüphanesini kullanarak renklendirilen BT veri seti ile derin öğrenme tekniklerinden DenseNet121'i kullanarak Covid-19'u, COVID-19 olmayan vakalardan ayırt etmeye odaklanmışlardır. Çalışmanın sonunda %98'lik doğruluk elde edildiğini belirtmiştir [38].

Alshazly ve arkadaşları göğüs x-ray görüntülerinin sınıflandırılması sürecinde CovidResNet and CovidDenseNet olmak üzere 2 model geliştirdiklerini belirtmişlerdir. Geliştirilen model literatürde kabul gören farklı ESA mimarileri ile de karşılaştırılmıştır. Yapılan çalışmada geliştirilen modellerin önceden eğitilmiş modellerden daha başarılı oldukları belirtilmiştir. Geliştirilen modellerde sırasıyla %83.17 ve %83.89 oranında doğruluk değerlerine ulaşmıştır [39].

Naeem ve arkadaşları yapmış oldukları çalışmada, birleştirilmiş bir derin öğrenme ve çok seviyeli özellik çıkarma metodolojisi yardımıyla CT taraması ve göğüs röntgeninde otomatik bir COVID-19 tanımlaması sunduklarını belirtmişlerdir. Bu yöntemde araştırmacılar farklı özellik çıkarma tekniklerini kullanmışlardır. Son olarak, çıkarılan COVID-19 özelliklerini tespit etmek için ESA ağı boyunca Uzun Kısa Süreli Bellek (LSTM) kullanılmıştır. Yapılan çalışmada %98.94 ve %83.03 oranında doğruluk değerleri elde edilmiştir [40].

Muhammad ve arkadaşları göğüs x-ray görüntülerini kullanarak COVID-19 tespiti için ESA-BiLSTM tabanlı bir model önermişlerdir. Önerilen model 3 farklı veri seti üzerinde test edilmiştir. Araştırmacılar önerilen modelinin açıklama bilirliliği için PCA ve t-SNE özellik görselleştirmesinden yararlanmışlardır. Önerilen model farklı veri setleri üzerinde sırasıyla %97, %84 ve %98 doğruluk değerlerine ulaşmıştır. Yapılan bu çalışmada araştırmacılar önermiş oldukları modeli farklı ESA mimarileri ile karşılaştırmışlardır. Önerilen model çalışmada kullanılan ESA mimarilerinden daha iyi sonuçlar elde etmiştir [41].

Demir yaptığı bu çalışmada, Röntgen görüntülerinden COVID-19 vakalarını otomatik olarak tanımlayan derin LSTM'ye dayalı yeni bir yaklaşım önermiştir. Demir derin LSTM modelinin, transfer öğrenme ve derin öznitelik çıkarma yaklaşımlarının aksine sıfırdan öğrenilen bir mimari olduğunu ifade etmiştir. Ayrıca, araştırmacı ön işleme aşamasında önerilen modelin performansını artırmak için ham görüntülere Sobel gradyanı ve işaretçi kontrollü havza bölütleme işlemleri uygulamıştır. Demir önerilen modelin büyük veri setleriyle eğitildikten sonra, radyologlara ve uzmanlara yardımcı olmak için gerçek dünyadaki uygulamalarda kullanılabilirliğini belirtmiştir [42].

Kumar ve arkadaşları yaptıkları bu çalışmada, göğüs röntgeni kullanılarak COVID-19'un tespit edilmesi için ESA ve Tekrarlayan Sinir Ağı (RNN) mimarisini birleştiren Hibrit Konvolüsyonel Sinir Ağı (HDCNN) isminde yeni bir yaklaşım sunmuşlardır. Transfer öğrenme yaklaşımı ve Grad-CAM sorumlu görüntüleri görüntülemek için HDCNN ile birlikte kullanılmıştır. Bu çalışmada HDCNN, Inception-v3, ShuffleNet, SqueezeNet, VGG-19 ve DenseNet gibi diğer CNN'ler ile karşılaştırılmıştır. Sonuç olarak, HDCNN %98,20 doğruluk değeri elde etmiştir [43].

Saiful Islam ve arkadaşları tarafından yapılan çalışmada, göğüs röntgeni görüntülerinden COVID+ (yani COVID-19'lu hastalar), pnömoni ve normal vakaları tespit etmek için derin Evrişimli Sinir Ağı (ESA) tabanlı bir yaklaşım kullanılmıştır. Bu önerilen çalışmada VGG16, InceptionV3, DenseNet121, DenseNet201 ve InceptionResNetV2 dahil olmak üzere birkaç derin ESA modeli benimsenmiştir. Ampirik sonuçlar, DenseNet201'in sırasıyla %94,75, %96, %95 ve %95'lik doğruluk, geri çağırma, F1 puanı ve kesinlik ile genel olarak daha iyi performans sağladığını göstermişlerdir. Literatürde bulunan sonuçlarla dikkatli bir karşılaştırmadan sonra, daha yüksek güvenilirliğe sahip modeller geliştirdiklerini belirtmişlerdir [26].

Bilgisayar destekli bir veri ađı ve oluřturulan sistemlerle, sađlık alıřanlarına hastalık ile ilgili karar vermede teřhis ve hasta takibini sađlamak iin desteklemede yardımcı olabilmektedir. Bu alıřmada, COVID-19'u sađlıklı bireylerle, pnmoni hastalıđını ayırt edebilmek model oluřturup bilgisayar programları destekli tanı aracı meydana getirilmiř ve sađlık hizmetlerine yardımcı olmak iin sunulmuřtur.

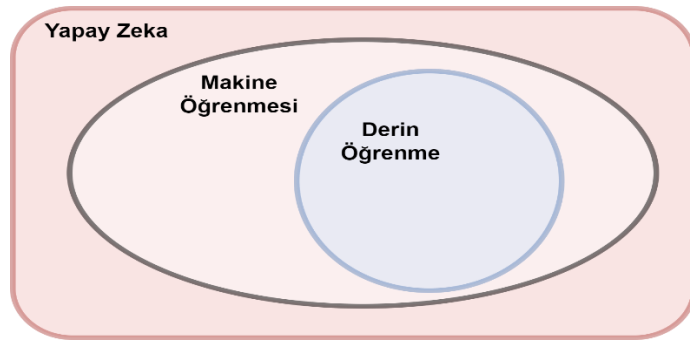


3. MATERYAL VE METOT

Bu bölümde Derin Öğrenme, Evrişimsel Sinir Ağları, çalışmada kullanılan veri seti ve önerilen model detaylı bir şekilde incelenmiştir.

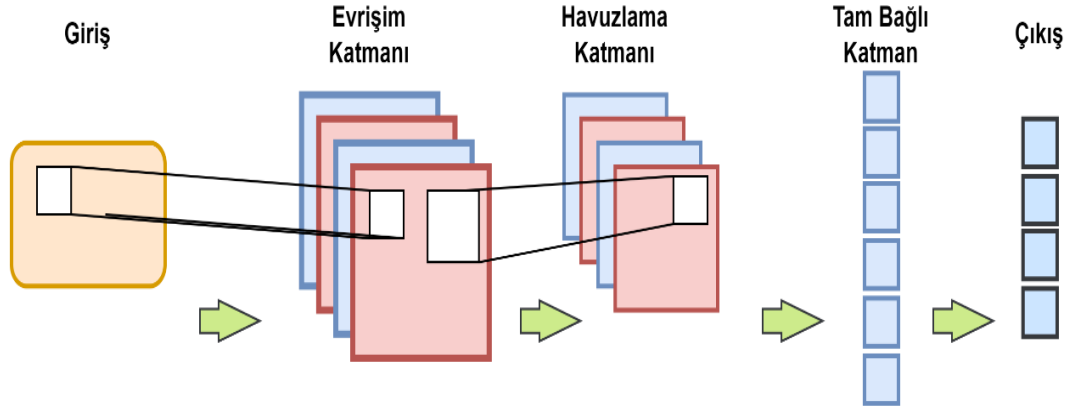
3.1. Derin Öğrenme ve Evrişimsel Sinir Ağları

Derin öğrenme en genel tabiri ile makine öğrenmesinin bir alt dalıdır. Makine öğrenmesi de yapay zekanın bir alt dalıdır. Yapay zeka ve alt kümeleri Şekil 3.1'de gösterilmektedir. Derin öğrenme mimarileri, hem verilerin işlenmesinde hem de verilerin hangi sınıfa dahil olduklarının belirlenmesi gibi karar alma süreçlerinde insan beyninin temel yapısından ve işleyişinden esinlenilerek geliştirilmiştir. Günümüzde derin öğrenme ile hava durumu analizi [44], bitki türlerinin tanımlanması [45], hastalık tespiti [46], yüz tanıma [47] gibi birçok problemin çözümü noktasında etkili sonuçlar üretebilmektedir. Derin öğrenmenin bu çok yönlülüğünden ötürü bilim dünyasının ilgisini çekmektedir. Bilim dünyasının en çok ilgilendiği konuların başında derin öğrenmenin bir alt dalı olan Evrişimsel Sinir Ağları (ESA) gelmektedir. ESA ağları görüntü işleme ve tanımda oldukça sık kullanılmaktadır. Genellikle modelin eğitimi esnasında işlediği veri, çok boyutlu ve büyük verilerdir. Gelişen teknoloji ile birlikte veri setlerinde tutulan yüksek miktarda ki bu verilerden özelliklerin manuel çıkarılması oldukça zahmetli ve uzun zaman alan bir işlemdir. ESA ağları sayesinde bu özellikler otomatik olarak çıkarılmaktadır. ESA ağları sayesinde özellik çıkarımı otomatik yapıldığından dolayı uzman bilgisine olan ihtiyaçta minimuma indirgenmiş olunur.



Şekil 3.1. Yapay zekâ ve alt kümeleri

ESA mimarileri genellikle çok katmanlı bir yapıya sahiptirler. Genellikle Şekil 3.2'de gösterildiği gibi evrişim katmanı, havuzlama katmanı ve tam bağlı katman olmak üzere 3 tür katmanı bünyesinde ihtiva etmektedir [48, 49].



Şekil 3.2. ESA mimarilerinin temel yapısı

ESA mimarilerdeki katman sayısının artışı genellikle modelin doğruluğu üzerinde pozitif bir etkiye sahip olsa da her zaman bu etkiyi göstermeyebilirler. Katman sayısındaki artış özellikle modelin eğitimi esnasında daha güçlü donanım ihtiyacını da beraberinde getirmektedir. Derin öğrenme, modelin eğitimi esnasında yapısı gereği oldukça fazla veriye ihtiyaç duymaktadır. Bu kadar büyük miktarda veriyi işlemek için güçlü donanıma sahip bilgisayarlar ya da iş istasyonları gereklidir. Günümüzde hem güçlü donanımlar üzerinde çok miktarda veriyi işleyip etkili sonuçlar alabilen hem de daha düşük donanımsal ekipmanların üzerinde oldukça az veri ile çalışarak etkili sonuçlar alabilen derin öğrenme mimarileri mevcuttur. Derin öğrenme mimarilerinde her mimarinin kendine göre avantaj ve dezavantajları mevcuttur. Bundan dolayı her geçen gün farklı mimariler geliştirilmektedir.

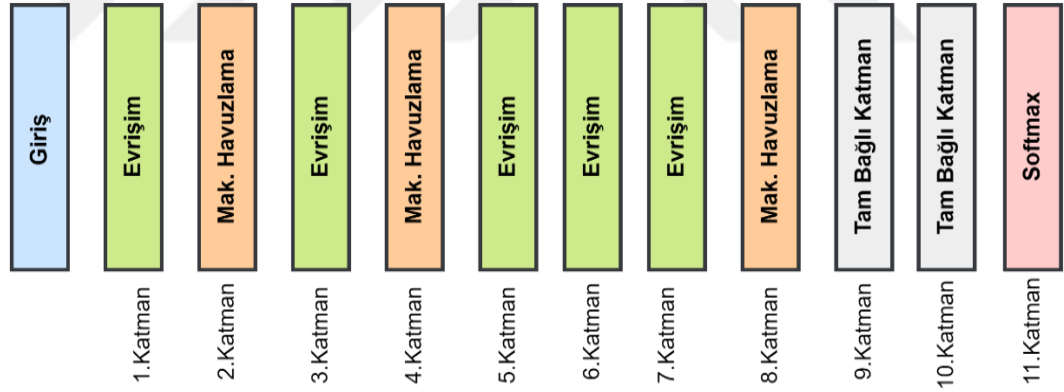
Şekil 3.2 incelendiğinde ESA mimarilerinin başlıca 3 katman üzerine kurulu olduğu görülmektedir. Bu katmanlardan ilki evrişim katmanıdır. Evrişim katmanı kendisine girdi olarak gelen görüntülere filtreler uygulayarak, görüntülerin özellik haritalarının elde edilmesini sağlamaktadırlar. Evrişim katmanında uygulanan filtreler ile ağın derinliği de artırılır ve bu sayede daha başarılı sonuçlar elde edilmesi amaçlanır [50, 51]. ESA ağlarında sıklıkla kullanılan bir diğer katman ise havuzlama katmanıdır. Havuzlama katmanı kendisine girdi olarak gelen özellik haritasının boyutunu düşürmektedir. Bu adımda önemli özellikler korunarak gereksiz özellikler elemine edilmektedir. Havuzlama katmanında ağırlık matrisleri kullanılmadığından dolayı, bu katmanda öğrenme gerçekleşmemektedir. Literatürde en yaygın kullanılan havuzlama türleri maksimum havuzlama ve ortalama havuzlamadır [52]. ESA mimarilerinde en sık kullanılan katmanlardan bir diğeri ise tam bağlı katmandır. Tam bağlı katman kendisine girdi olarak gelen özellik haritalarını sınıflandırma sürecine hazırlamaktadır. Kendisine girdi olarak gelen çok boyutlu özellik haritaları bu katmanda tek boyuta dönüştürülür ve sınıflandırıcıya girdi olarak verilir [53, 54].

3. 2. Evrişimsel Sinir Ağları Mimarileri

Literatürde kabul görmüş birçok ESA mimarisi mevcuttur. Bu bölümde literatürde kabul görmüş mimarilerden olan AlexNet, LeNet, VGG19, ResNet101, Xception, GoogleNet, DenseNet201, MobileNetV3, EfficientNet, ShuffleNet ve NasNet mimarileri incelenmiş ve bu mimariler hakkında bilgiler verilmiştir.

3.2.1. Alexnet

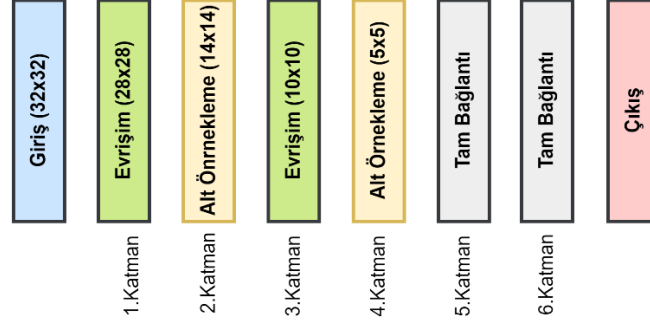
Alex Krishevsky ve bir grup arkadaşı tarafından geliştirilen ESA tabanlı bir mimaridir. Bu mimarinin özellikleri arasında 2012 yılında düzenlenen ImageNet (ILSVRC) yarışmasında diğer tüm bilinen mimarilerden ve geleneksel makine öğrenme yöntemlerinden daha yüksek başarımla birinci olmasıdır [55]. 1 milyon görüntünün işlenip sınıflandırıldığı bu yarışma ile bilinirliğini artırmış ve bilim dünyasının ilgisini çekmeyi başarmıştır [56]. 60 milyon toplam parametreye sahip olan AlexNet mimarisi, 227x227 boyutundaki görüntüler üzerinde çalışabilmektedir. Çok karmaşık bir yapıya sahip olmayan AlexNet mimarisi 11 katmandan oluşmaktadır. Evrişim, havuzlama ve tam bağlı katmanın haricinde sınıflandırma için softmax katmanını kullanmaktadır. Şekil 3.3'te AlexNet mimarisi gösterilmektedir.



Şekil 3.3. AlexNet mimarisi

3.2.2. LeNet

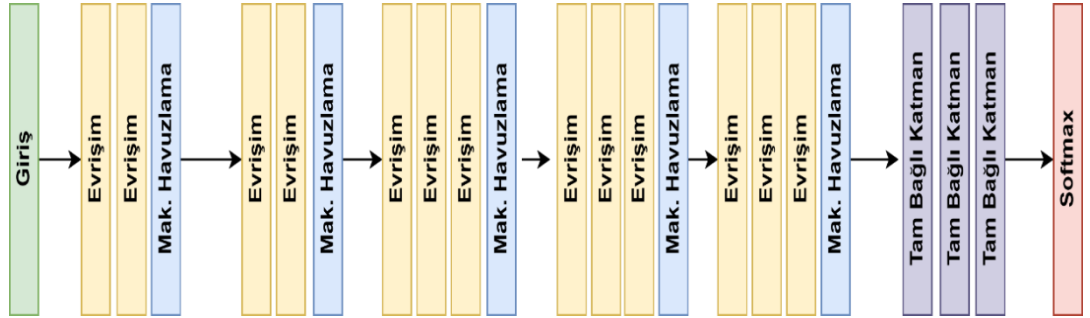
İlk olarak 1998 yılında sunulduğunda hesaplama ve bellek kapasitesi oldukça sınırlı olduğu için bu algoritmanın uygulanmasını zorlaştırmıştır [57]. 2010 yılında LeCun el yazısından oluşan rakamlardan oluşan bir veri seti üzerinde çalışmalar gerçekleştirmiştir. LeNet 2 evrişim, 2 alt örnekleme ve 2 tam bağlantı olmak üzere toplam 6 katmandan oluşmakta ve Şekil 3.4'te gösterilmektedir.



Şekil 3.4. LeNet mimarisi

3.2.3. VGG

Simonyan ve Zisserman tarafından önerilen ve 2014 yılında düzenlenen ILSVRC yarışmasında derece elde eden bu mimarinin temel katkısı sinir ağının derinleşmesiyle derin mimarilerin daha iyi tanımlama yaptığı ve sınıflandırma doğruluğunu arttırdığı gözlemlenmiştir [58]. VGG mimarisinin bilinen 3 versiyonu mevcuttur. Bu versiyonlar VGG11, VGG16 ve VGG19'dur. Bu mimariler sırası ile 11, 16 ve 19 katmandan oluşmaktadır [58]. Şekil 5'te görüleceği üzere VGG16 mimarisinin, ilk iki blokta 2 adet evrişim katmanı ardından, Doğrultulmuş Doğrusal Birim (ReLU) aktivasyon fonksiyonu ve maksimum havuzlama katmanı gelmektedir. Ayrıca yine Şekil 3.5'te görüleceği gibi diğer 3 blokta 3 adet evrişim katmanı ardından ReLU aktivasyon fonksiyonu ve maksimum havuzlama katmanı gelmektedir. Sonrasında tam bağlı katman ve softmax katmanı gelmektedir.




Şekil 3.5. VGG16 mimarisi

3.2.4. ResNet

Resnet mimarisi 2015 yılında önerilmiştir. He Kaiming ve arkadaşları tarafından önerilen bu mimari ILSVRC yarışmasını kazanarak bilim dünyasının ilgisini çekmeyi başarmıştır [59]. ResNet mimarisi, 224x224 boyutundaki görüntüleri girdi olarak kabul etmektedir. Bu mimari sayesinde bilinenin aksine ağın derinliği arttıkça doğruluk artmamış aksine azalmaya başlamıştır.

Bu da aşırı uyumun sağlandığı sonucuna varılmasına sebep olmuştur. Böylesi bir sorunu çözmek amacıyla artık blokları üst üste koyan bir yapay sinir ağı oluşturulmuştur. Şekil 3.6'da artık blok gösterilmektedir. Temsili a girişi çıkışa direkt olarak eklenmiştir. Bu durum kısa yol bağlantısı $f(a) + a$ olarak da bilinmektedir. Bu sayede mevcut yapısındaki derinliğe rağmen daha az hesapsal karmaşıklığı elde etmiştir. ResNet'in 50, 101 ve 151 şeklinde literatürde versiyonları mevcuttur.



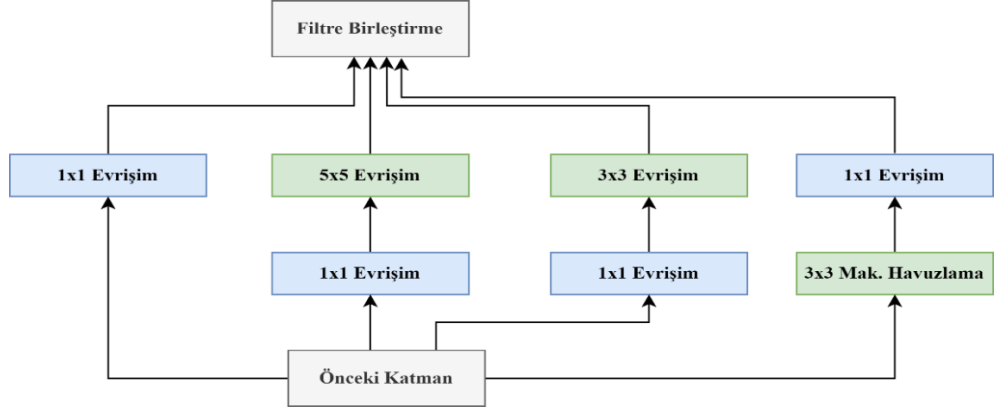
Şekil 3.6. Resnet50 artık blok gösterim

3.2.5. Xception

2017 yılında Francois Chollet tarafından önerilen bu mimari derinlemesine ayrılabilen evrişim katmanlarına sahiptir [60]. ILSVRC yarışmasında 350 milyon görüntü ve 17000 sınıf içeren veri kümesinde Inceptionv3'den daha yüksek bir performans sağlamıştır. Xception mimarisi ile Inceptionv3 mimarisi eşit sayıda parametreye sahiptir. Xception'ın performansındaki bu üstünlüğün sebebi parametrelerin daha verimli kullanıldığından ötürüdür.

3.2.6. GoogleNet


GoogleNet mimarisi 2014 yılında gerçekleştirilen ILSVRC yarışmanın kazanan mimarisidir. Christian Szegedy tarafından önerilen bu mimari ile hesapsal karmaşıklığı azaltmak amacıyla tasarlanmıştır [61]. GoogleNet 224x224 boyutundaki görüntüleri girdi olarak kabul etmektedir. GoogleNet, Şekil 3.7'de görüleceği gibi başlangıç katmanları yığını kullanarak en son teknoloji tanıma doğruluğunu geliştirmiştir. GoogleNet kendinden önceki tüm ağlardan daha fazla toplam katman içermektedir. Fakat GoogleNet'in kullandığı ağ parametre sayısı Alexnet ve VGG'den daha düşüktür. Alexnet'in 60 milyon VGG19'un ise 138 milyon toplam parametre sayısı varken GoogleNet'in toplam parametre sayısı sadece 7 milyondur.



Şekil 3.7. GoogleNet başlangıç katmanı

3.2.7. DenseNet

2017 yılında Gao Huang ve arkadaşları tarafından geliştirilen ve yoğun şekilde bağlı ESA katmanlarından oluşan bu mimarinin temel özelliği, her katmanın çıktıları, yoğun (dense) bir bloktaki tüm ardıl katmanlarla bağlı olması felsefesine dayanmaktadır [62]. DenseNet, temel olarak iki bitişik yoğun blok arasına yerleştirilmiş birkaç yoğun blok ve geçiş bloklarından oluşur. DenseNet 224x224 boyutundaki görüntüleri girdi olarak kabul etmektedir. Yoğun bir bloğun kavramsal diyagramı Şekil 8'de gösterilmektedir. Şekil 3.8'den de anlaşılacağı üzere son katman olan işlem katmanı kendinden önceki tüm katmanlardan özellik haritalarını içermektedir.

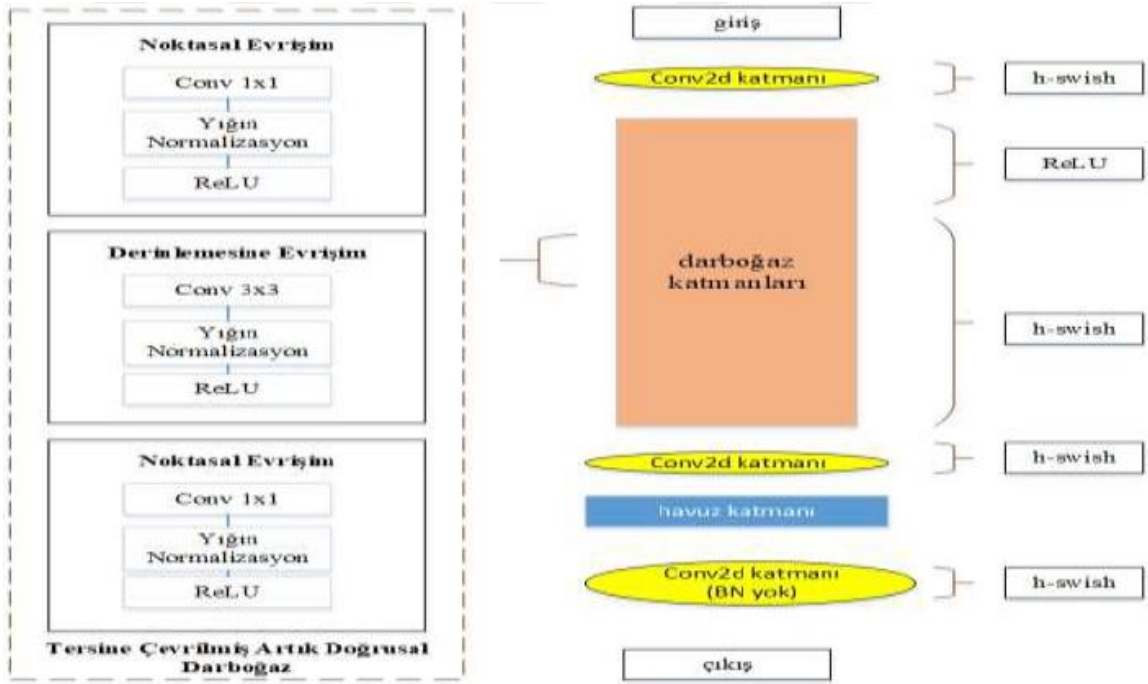


Şekil 3.8. Büyüme oranı $k = 3$ olan 4 katmanlı yoğun blok.

3.2.8. MobileNet

Son yıllarda teknolojinin hızlı bir şekilde artmasıyla beraber büyük veri kavramı ortaya çıkmaktadır. Veri tabanlarında yüksek boyutlarda tutulan verilerin işlenmesi ve bu verilerden anlamlı sonuçların çıkartılması büyük bir önem arz etmektedir [63]. Derin öğrenme mimarileri artan büyük miktardaki verileri işlerken hız ve maliyet kavramlarıyla karşı karşıya kalmaktadır. Bundan dolayı daha hızlı çalışabilen daha az karmaşık modellerin tasarımı büyük bir önem arz


etmektedir. MobileNet mimarisinde de daha düşük veri işleme yeteneğine sahip mobil ve derin öğrenme uygulamalarını gerçekleştirmek amaçlamışlardır. Howard ve arkadaşları tarafından 2017 yılında tanıtılan bu mimaride klasik evrişim işlemi kullanılmamıştır. Bu mimaride derinlemesine ayrılabilir evrişim tekniği tercih edilmiştir. Bu teknik sayesinde araştırmacılar modelin daha hızlı çalıştığını ifade etmişlerdir. Daha sonra MobileNet mimarisinde güncellemeler yapılarak farklı versiyonları geliştirilmiştir [64, 65]. Bu çalışmada MobileNetV3 versiyonu tercih edilmiştir. MobileNetV3 mimarisinin genel yapısı şekil 3.9 da sunulmuştur.



Şekil 3.9. MobileNetV3 genel yapısı [66]

3.2.9. EfficientNet

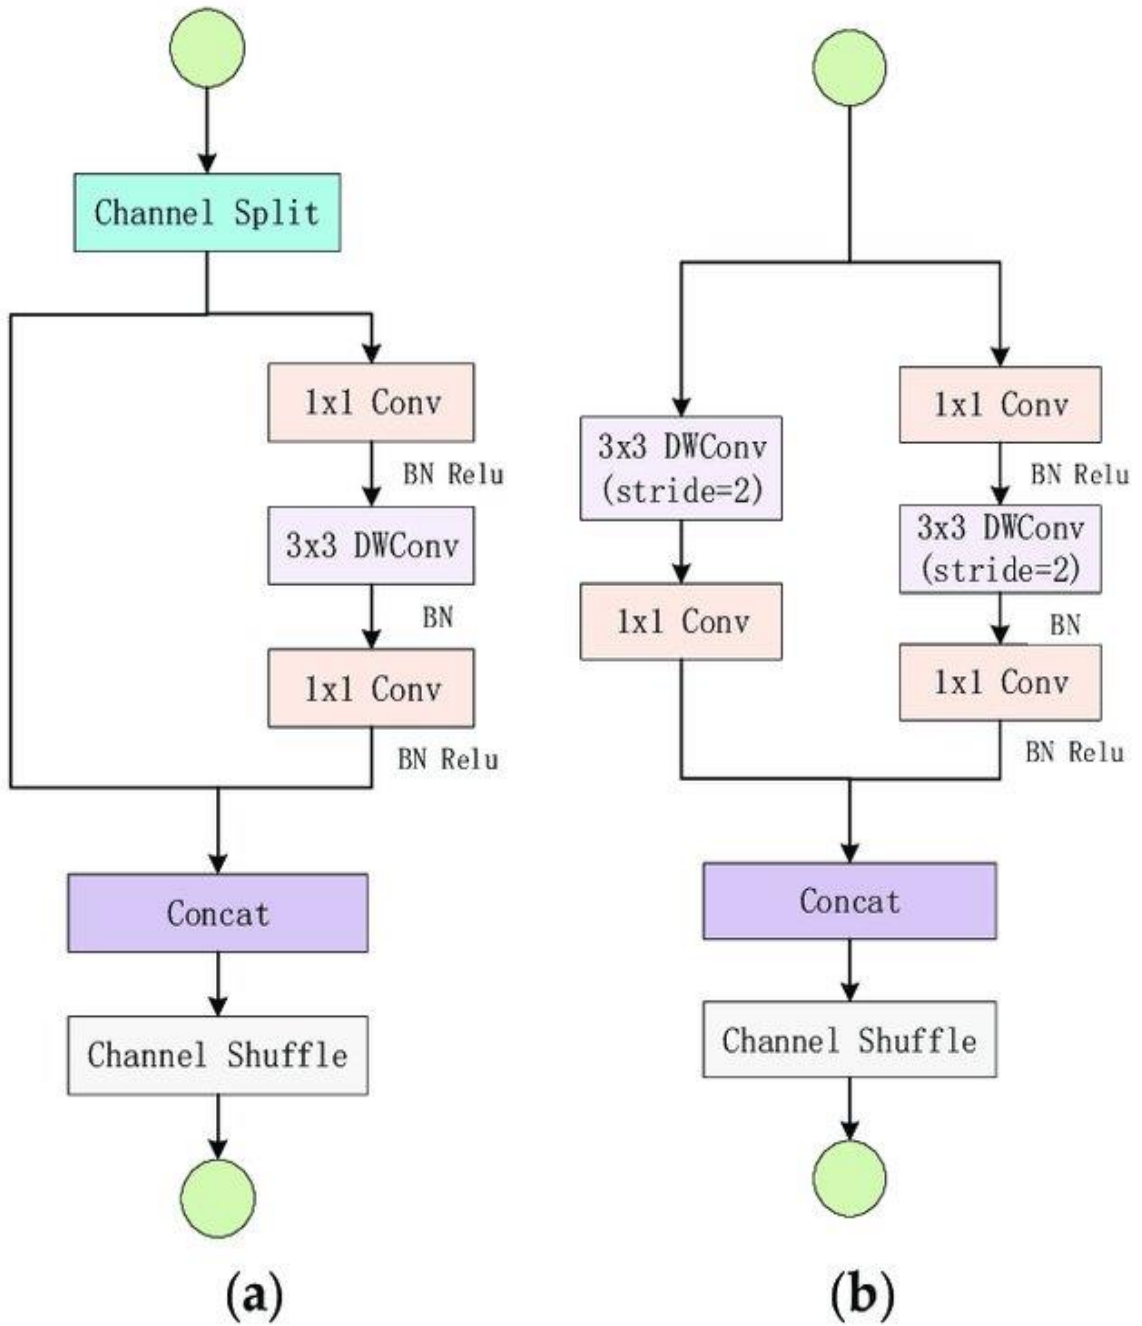
Tan ve Le tarafından önerilen EfficientNet mimarisinde, araştırmacılar daha iyi bir performans elde etmek amacıyla birleşik ölçeklendirme yöntemini kullanmışlardır. EfficientNet mimarisi kendisinden önce geliştirilmiş mimarilerden farklı olarak sadece derinlik kavramını ölçüt alınmayıp, genişlik ve çözünürlük faktörleri de sürece dahil edilmiştir. EfficientNet modelinde araştırmacılar bileşik bir katsayı kullanarak derinlik, genişlik ve çözünürlük boyutlarını eşit şekilde ölçeklediklerini belirtmişlerdir [67]. EfficientNet0 mimarisinin genel yapısı şekil 3.10 da verilmiştir.



Şekil 3.10. Efficientnetb0 mimarisinin genel yapısı [68]

3.2.10. ShuffleNetV2

Ma ve arkadaşları tarafından 2018 yılında geliştirilen ShuffleNetV2 mimarisi düşük hesaplama gücüne sahip mobil cihazlar için özel olarak geliştirilmiştir. Bu mimari çoğu ESA mimarisine kıyasla daha az parametre ve hesaplama maliyeti içermektedir [69]. ShuffleNetv2 mimarisinin temel birimleri şekil 3.11’de verilmiştir.



Şekil 3.11. ShuffleNet V2 temel birimleri: (a) temel birim, (b) uzamsal alt örnekleme için temel birim [70]

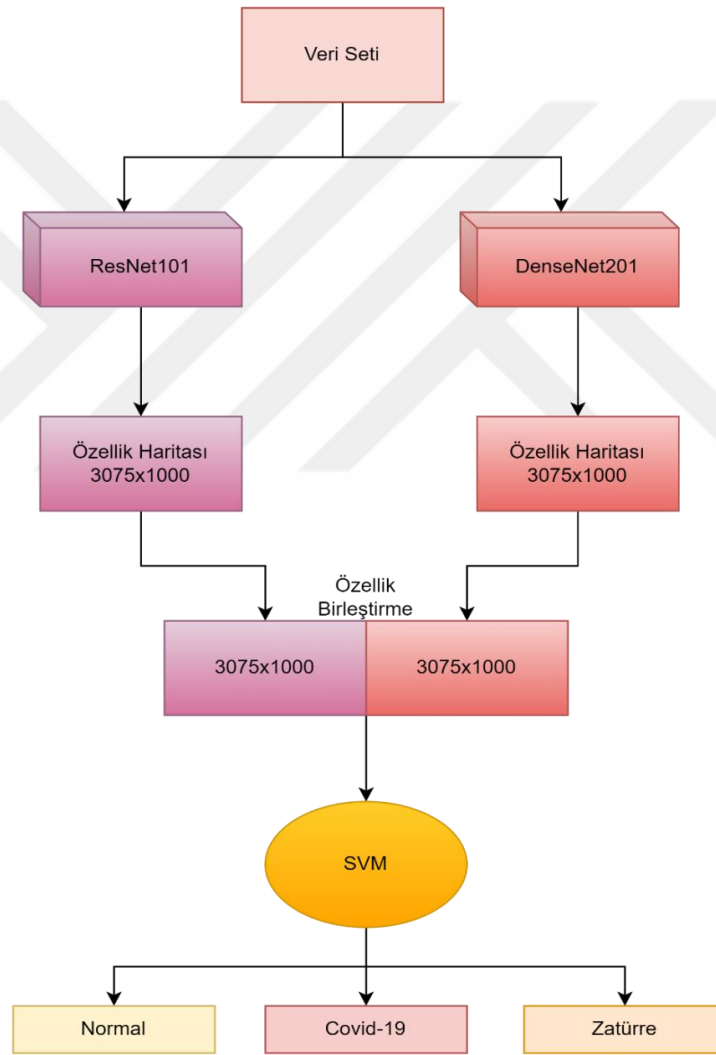
3.2.11. NasNet Mobile

NasNet mimarisi 2018 yılında Google Brain ekibinden Zoph ve arkadaşları tarafından önerilmiştir. NasNet modeli, daha küçük model boyutu ve daha düşük karmaşıklık ile son teknoloji sonuçlara ulaşır. NasNet mimarisi kendisinden önce geliştirilen mimarilere göre farklılıklar göstermektedir. NasNet mimarisinin genel kurulumu arama alanı, arama stratejisi ve performans tahmini bileşenlerinden oluşmaktadır. NasNet mimarisinde araştırmacılar, küçük bir

veri kümesinde bir mimari yapı bloğu aramayı ve ardından bloğu daha büyük bir veri kümesine aktarmayı önermektedir [71].

3.3. Önerilen Model

Bu kadar tehlikeli ve ölümcül olan COVID-19 salgınının bilgisayar destekli sistemler kullanılarak tespit edilmesi büyük bir önem arz etmektedir. Yapılan tez çalışmasında göğüs x-ray görüntülerinin sınıflandırılması için bilgisayar destekli yapay zekâ tabanlı bir model geliştirilmiştir. Geliştirilen modelin blok diyagramı şekil 3.12'deki gibidir.



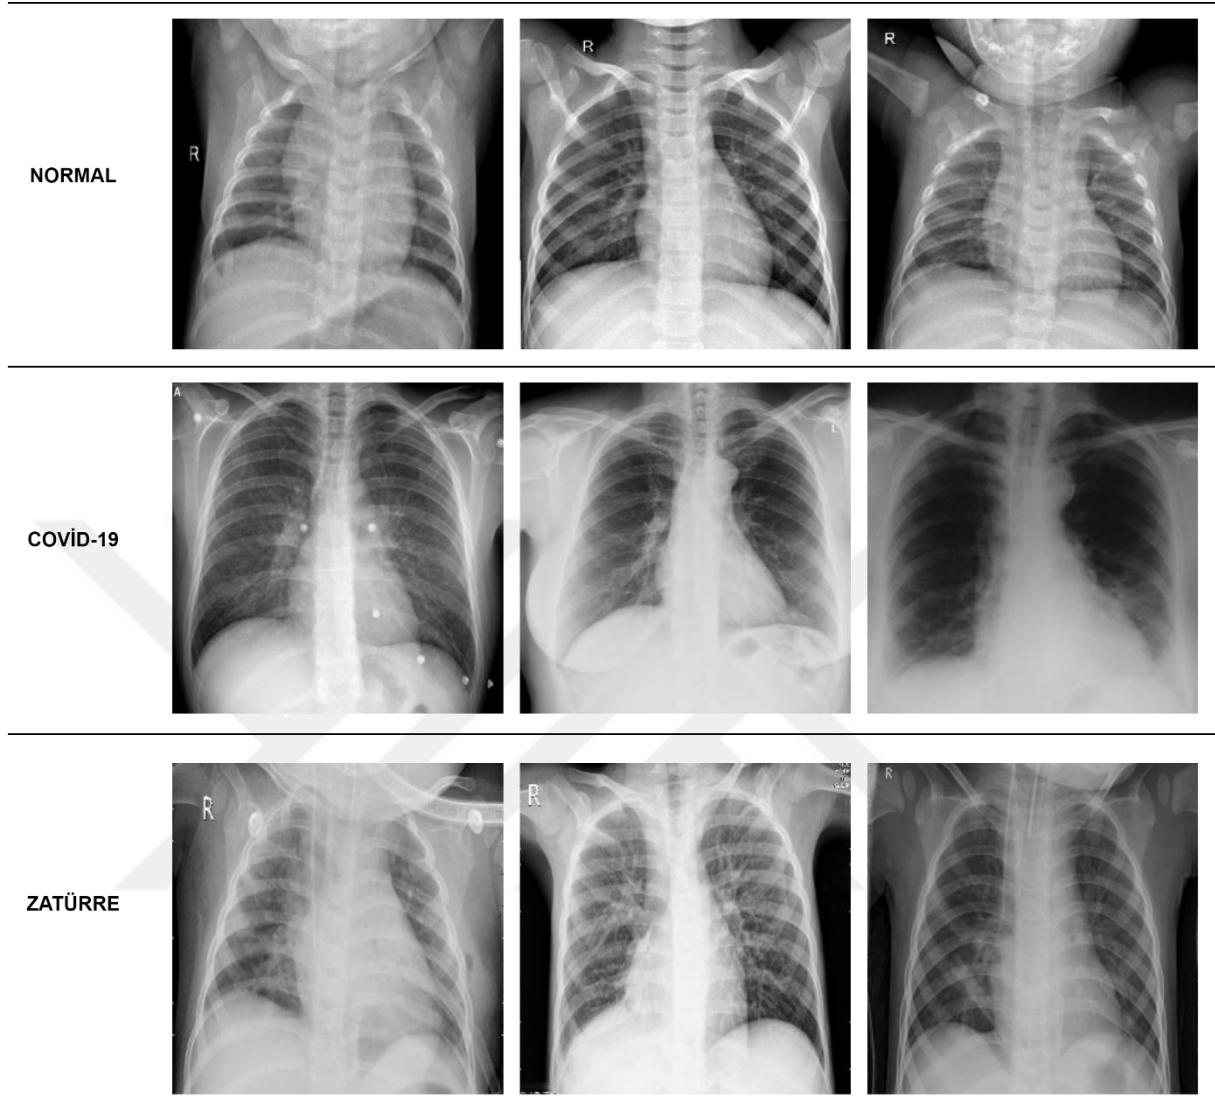
Şekil 3.12. Önerilen modelin blok diyagramı

Göğüs x-ray görüntülerinden oluşan veri setinde ki görüntüleri sınıflandırmak için geliştirilen hibrit modelde özellik çıkarımı için ESA mimarilerinden olan ResNet101 ve DenseNet201 mimarileri kullanılmıştır. Her bir mimaride elde edilen özellik haritasının boyutu

3075 x 1000 olmuştur. ResNet101 ve DenseNet201 mimarileri kullanılarak elde edilen bu özellik haritaları daha sonra birleştirilmiştir. Bu sayede aynı görüntünün farklı özellikleri bir araya getirilmiştir. Bu da geliştirilen modelin başarımını artıracaktır. Özellik birleştirme işleminden sonra elde edilen özellik haritasının boyutu 3075 x 2000 olmuştur. Geliştirilen modelin son adımında ise elde edilen özellik haritası SVM sınıflandırıcısında sınıflandırılmıştır.

3.4. Veri Seti

Yapılan çalışmada COVID-19göğüs x-ray görüntülerinin sınıflandırılabilmesi için public “Covid-1919-chest-xray-dataset” veri seti kullanılmıştır [72]. Bu veri seti 3 sınıftan oluşmaktadır. Bu veri setinde COVID-19, zatürre ve normal sınıflar mevcuttur. Yani bir hastanın x-ray görüntüsü 3 farklı şekilde COVID-19, zatürre ve normal şeklinde yorumlanmıştır. Veri setindeki x-ray görüntülerine örnekler şekil 3.13’ de verilmiştir.



Şekil 3.13. Veri setinden örnekler

Çalışmada kullanılan veri setinde 2616 normal, 1025 COVID-19 ve 3726 adet zatürre görüntüsü mevcuttur. İlgili veri setinde en az görüntü COVID-19 sınıfına aittir. Bundan dolayı yapılan tez çalışmasında dengeli bir veri seti ile çalışmak için her bir sınıftan rastgele 1025 görüntü seçilerek çalışılmıştır.

3.5. Çalışmada kullanılan mimariler ve ön hazırlık

Yapılan tez çalışmasında literatürde kabul gören önceden eğitilmiş 10 farklı ESA mimarisi kullanılmıştır. Bu mimariler AlexNet, VGG19, ResNet101, Xception, GoogleNet, DenseNet201, MobileNetV3, EfficientNet, ShuffleNet ve NasNet tür. Veri setindeki veriler kullanılarak ESA mimarileri eğitilirken, veri setinde ki x-ray görüntülerinin %80'ni modellerin

eđitim s¼recinde, geriye kalan %20'si ise eđitilen modellerin test edilmesi s¼recinde kullanılmıřtır. T¼m mimarilerde aynı eđitim verileri ve aynı test verileri kullanılmıřtır. Ayrıca alıřmada kullanılan ESA mimarileri aynı parametreler kullanılarak eđitilmiřtir. Optimizer olarak SGDM tercih edilmiř, eđitim 5 epoch s¼rm¼ř ve toplamda 765 adımda tamamlanmıřtır.

alıřmada kullanılan 10 farklı ESA mimarisinin bařarımlarının test edilmesi iin farklı performans deđerlendirme metrikleri kullanılmıřtır. Bu metrikler literat¼rde kabul g¼ren ve bilimsel alıřmalarda sıklıkla kullanılan metriklerdir. Bu metriklerin ođu karıřıklık matrisi kullanılarak hesaplanmaktadır. řekil 3.14'de ¼rnek bir karıřıklık matrisi verilmiřtir.

| | | |
|---|----|----|
| | X | Y |
| X | TP | FP |
| Y | FN | TN |

řekil 3.14. Karıřıklık matrisi ¼rneđi

Gerek Pozitif (TP) deđeri X sınıfına ait olan g¼r¼nt¼lerin gerek pozitif olarak dođru tahmin edildiđini g¼stermektedir. Yanlıř Pozitif ise (FP) gerekte X sınıfına ait olan g¼r¼nt¼lerin Y olarak yanlıř tahmin edilmesini g¼stermektedir. Yanlıř negatif (FN) ise gerekte Y sınıfına ait olan g¼r¼nt¼lerin, X sınıfındaymıř gibi yanlıř tahmin edilmesini ifade etmektedir. Son olarak gerek negatif (TN) ise gerekte Y sınıfına ait olan g¼r¼nt¼lerin Y diye dođru tahmin edilmesini g¼stermektedir. Yapılan alıřmada modellerin performanslarını karıřılařtırmak iin farklı performans deđerlendirme parametreleri kullanılmıřtır. Bu parametreler Denklem 1-4 te verilmiřtir.

$$\text{Dođruluk (Accuracy)} = (TP + TN) / (TP + TN + FP + FN) \quad (\text{Eq.1.})$$

$$\text{Duyarlılık (Sensitivity)} = TP / (TP + FN) \quad (\text{Eq.2.})$$

$$\text{¼zg¼ll¼k (Specificity)} = TN / (FP + TN) \quad (\text{Eq.3.})$$

$$\text{F1-Score} = 2TP / (2TP + FP + FN) \quad (\text{Eq.4.})$$

4. BULGULAR VE TARTIŞMA

COVID-19, tüm dünyada insanların yaşamlarını alt üst etti. Bilinen ilk vaka Aralık 2019'da Çin'in Hubei eyaletine bağlı Wuhan şehrinde tespit edilmişti. Daha sonra yavaş yavaş dünyanın her yerine yayıldı. 15 Kasım 2021 itibarıyla etkilenen ve ölen vaka sayısı sırasıyla 254.050.589 ve 5.115.804'tür. COVID-19 semptomları bir hastadan diğerine göre değişir ancak ateş, öksürük ve nefes darlığının enfekte insanlar arasında en yaygın özellikler olduğu bulunmuştur. Solunum damlacıkları yoluyla virüs, enfekte olanlardan altı fit uzakta olanlara yayılabilir. Dünya, küresel ekonomide büyük bir bozulma ile karşı karşıya kaldı. Dünya Bankası'na göre, bu küresel ekonomik çöküşten kurtulmak 80 yıl alacak [26].

COVID-19, RT-PCR testi, göğüs röntgeni görüntü analizi ve CT taramaları dahil olmak üzere çeşitli teknikler kullanılarak tespit edilebilir. RT-PCR, COVID-19 saptamanın etkili bir yoludur, ancak örnek toplama zaman alır ve her yerde bulunmayabilecek özel kitler gerektirir. Bu test güvenilir sonuçlar verebilir, ancak laboratuvar olanaklarına göre her vakanın işlenmesi ortalama altı ila sekiz saat sürebilir. COVID-19'u teşhis etmenin başka bir yolu, göğüs BT taraması görüntülerinin analizidir. BT taramalarından aşırı radyasyona maruz kalan kişilerde yüksek kanser riski vardır. COVID-19 nedeniyle, BT taramalarının sayısı önemli ölçüde arttı. Bu, radyasyona aşırı maruz kalmayı ve sonuç olarak radyograflarda kanser geliştirme olasılığını artırır. Bunun yanı sıra pahalıdır, çalışması için klinik uzmanlık gerektirir ve bir ülkenin az gelişmiş bölgesinde bulunmayabilir. Bununla birlikte, göğüs röntgeni testleri ucuzdur ve BT taramasına kıyasla düşük radyasyon riski taşır. Dünya Sağlık Örgütü (WHO), akciğer röntgeni görüntülerini COVID-19 tanısında çok etkili bir yöntem olarak görüyor [26].


Covid-19 görüntülerinin bilgisayar destekli sistemler tarafından teşhis edilip sınıflandırılması büyük bir önem arz etmektedir. Bilgisayar destekli sistemler sayesinde uzmanların iş yükü hafifleyecek ve bu sistemler uzman olmayan yerlerde de ön teşhis işlemi için kullanılabilir. Yapılan bu tez çalışmasında da COVID-19 x-ray görüntüleri kullanılarak otomatik teşhis yapan bilgisayar destekli bir sistem tasarlamak amaçlanmıştır. Bu bölümde literatürde kabul görmüş ESA mimarileri ile COVID-19 veri seti üzerinde sonuçlar elde edilmiş ve bu mimarilerde elde edilen sonuçlar tartışılmıştır. Çalışmada kullanılan tüm ESA mimarilerinde sonuçlar karşılaştırılabilmesi için aynı eğitim parametreleri kullanılmıştır. Korona virüs salgını 2019 yılından beri tüm dünyayı etkisi altına aldığından dolayı literatürde konuyla ilgili yapılmış birçok çalışma mevcuttur. Bununla birlikte COVID-19'un erken bulaşması ve ölüm oranlarının yüksek olmasından dolayı çalışmalar devam etmektedir.

4.1. ESA mimarilerinin ve önerilen modelin sonuçları

Yapılan tez çalışmasında göğüs x-ray görüntüleri kullanılarak hastalık teşhisi yapılmıştır. Çalışmada kullanılan veri setinde Normal, COVID-19 ve Zatürre olmak üzere üç farklı sınıf mevcuttur. Üç farklı sınıftan oluşan bu veri setinde ki göğüs x-ray görüntülerini sınıflandırmak için literatürde kabul görmüş AlexNet, VGG19, ResNet101, Xception, GoogleNet, DenseNet201, MobileNetV3, EfficientNet, ShuffleNet ve NasNet mimarileri ve geliştirilen modelden sonuçlar elde edilmiştir. Bu modellerde elde edilen doğruluk ve kayıp eğrileri ayrı ayrı incelenmiştir. Daha sonra ilgili modellerin karışıklık matrisleri sunulmuş ve bu karışıklık matrisleri tartışılmıştır. Ayrıca bu modellerin başarımları hesaplanmış ve yorumlanmıştır.

4.2. Alexnet mimarisinde elde edilen sonuçlar

Yapılan tez çalışmasında veri setindeki görüntüler ilk olarak önceden eğitilmiş Alexnet mimarisinde sınıflandırılmıştır. Alexnet mimarisinde elde edilen doğruluk ve kayıp eğrileri şekil 4.1'de verilmiştir.



Şekil 4.1. AlexNet mimarisinde elde edilen doğruluk ve kayıp eğrileri

AlexNet mimarisi kullanılarak elde edilen karışıklık matrisi şekil 4.2 de verilmiştir.

| | | | | |
|----------|---------------|----------|---------|-------------|
| Alexnet | Normal | Covid-19 | Zatürre | |
| Normal | 203 | 2 | 0 | Doğru Sınıf |
| Covid-19 | 2 | 202 | 1 | |
| Zatürre | 4 | 4 | 197 | |
| | Tahmini Sınıf | | | |

Şekil 4.2. Alexnet mimarisinde elde edilen karışıklık matrisi

Şekil 4.2 incelendiğinde AlexNet mimarisi test için kullanılan 615 adet göğüs x-ray görüntüsünden 602 tanesini doğru tahmin ederken, geriye kalan 13 görüntüyü ise yanlış tahmin etmiştir. AlexNet mimarisi test için kullanılan 205 göğüs x-ray Normal görüntüsünden 203 tanesini doğru tahmin ederken, 2 görüntüyü ise COVID-19 olarak yanlış tahmin etmiştir. Bu mimarinin bu sınıfta elde ettiği doğruluk değeri %99.02 olmuştur. AlexNet mimarisi COVID-19 sınıfında ise 205 test görüntüsünün 202 tanesini doğru tahmin ederken, 3 görüntüyü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 2 göğüs x-ray görüntüsü model tarafından Normal şeklinde tahmin edilirken, 1 göğüs x-ray görüntüsü ise zatürre şeklinde tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %98.53 şeklinde gerçekleşmiştir. Son olarak AlexNet mimarisi Zatürre sınıfına ait 205 göğüs x-ray görüntüsünden 197 tanesini doğru tahmin ederken, 8 tanesini ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 4 tanesini Normal, 4 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %96.09'dur. AlexNet mimarisinin en başarılı olduğu sınıf Normal, en başarısız olduğu sınıf ise Zatürre olmuştur. AlexNet mimarisinin ortalama doğruluk değeri %97.89'dur. AlexNet mimarisinde elde edilen performans metrikleri Tablo 4.1'de sunulmuştur.


Tablo 4.1. AlexNet mimarisinde elde edilen performans metrikleri

| AlexNet | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|----------|-------------|---------------|-------------|-------------|
| Normal | 99.02 | 97.12 | 99.50 | 98.06 |
| Covid-19 | 98.53 | 97.11 | 99.26 | 97.82 |
| Zatürre | 96.09 | 99.49 | 98.08 | 97.76 |

Tablo 4.1 incelendiğinde AlexNet mimarisinin en yüksek F1-Score değerini %98.06 ile Normal sınıfta elde ederken, en düşük F1-Score değerini ise %97.76 ile Zatürre sınıfında elde etmiştir. AlexNet mimarisinin COVID-19 sınıfında elde ettiği F1-Score değeri ise %97.82 olmuştur.

4.3. DenseNet201 mimarisinde elde edilen sonuçlar

Yapılan tez çalışmasında veri setindeki görüntülerin sınıflandırılması için kullanılan ikinci mimari ise DenseNet201'dir. DenseNet201 mimarisinde elde edilen doğruluk ve kayıp eğrileri şekil 4.3' te verilmiştir.



Şekil 4.3. DenseNet201 mimarisinde elde edilen doğruluk ve kayıp eğrileri

DenseNet201 mimarisi kullanılarak elde edilen karışıklık matrisi şekil 4.4' de verilmiştir.

| DenseNet201 | Normal | Covid-19 | Zatürre | |
|-------------|---------------|----------|---------|-------------|
| Normal | 205 | 0 | 0 | Doğru Sınıf |
| Covid-19 | 2 | 202 | 1 | |
| Zatürre | 12 | 2 | 191 | |
| | Tahmini Sınıf | | | |

Şekil 4.4. DenseNet201 mimarisinde elde edilen karışıklık matrisi

Şekil 4.4 incelendiğinde DenseNet201 mimarisi test için kullanılan 615 adet göğüs x-ray görüntüsünden 598 tanesini doğru tahmin ederken, geriye kalan 17 görüntüyü ise yanlış tahmin etmiştir. DenseNet201 mimarisi test için kullanılan 205 göğüs x-ray Normal görüntüsünün tamamını doğru tahmin etmiştir. DenseNet201 mimarisinin bu sınıfta yanlış tahmin ettiği görüntü bulunmamaktadır. Bu mimarinin Normal sınıfında elde ettiği doğruluk değeri %100'dür. DenseNet201 mimarisi COVID-19 sınıfında ise 205 test görüntüsünün 202 tanesini doğru tahmin ederken, 3 görüntüyü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 2 göğüs x-ray görüntüsü model tarafından Normal şeklinde tahmin edilirken, 1 göğüs x-ray görüntüsü ise Zatürre şeklinde tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %98.53 şeklinde gerçekleşmiştir. Son olarak DenseNet201 mimarisi Zatürre sınıfına ait 205 göğüs x-ray görüntüsünden 191 tanesini doğru tahmin ederken, 14 tanesini ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 12 tanesini Normal, 2 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %93.17'dir. DenseNet201 mimarisinin en başarılı olduğu sınıf Normal, en başarısız olduğu sınıf ise Zatürre olmuştur. DenseNet201 mimarisinin ortalama doğruluk değeri %97.24'tür. DenseNet201 mimarisinde elde edilen performans metrikleri Tablo 4.2'te sunulmuştur.


Tablo 4.2. DenseNet201 mimarisinde elde edilen performans metrikleri

| DenseNet201 | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|-------------|-------------|---------------|-------------|-------------|
| Normal | 100 | 93.60 | 100 | 96.69 |
| Covid-19 | 98.53 | 99.01 | 99.27 | 98.77 |
| Zatürre | 93.17 | 99.47 | 96.69 | 96.22 |

Tablo 4.2 incelendiğinde DenseNet201 mimarisinin en yüksek F1-Score değerini %98.77 ile COVID-19sınıfında elde ederken, en düşük F1-Score değerini ise %96.22 ile Zatürre sınıfında elde etmiştir. DenseNet201 mimarisinin Normal sınıfında elde ettiği F1-Score değeri ise %96.69 olmuştur.

4.4. GoogleNet mimarisinde elde edilen sonuçlar

Yapılan tez çalışmasında veri setindeki görüntülerin sınıflandırılması için kullanılan üçüncü mimari ise GoogleNet'tir. GoogleNet mimarisinde elde edilen doğruluk ve kayıp eğrileri şekil 4.5'te verilmiştir.



Şekil 4.5. GoogleNet mimarisinde elde edilen doğruluk ve kayıp eğrileri

GoogleNet mimarisi kullanılarak elde edilen karışıklık matrisi şekil 4.6'da verilmiştir.

| GoogleNet | Normal | Covid-19 | Zatürre | |
|-----------|---------------|----------|---------|-------------|
| Normal | 205 | 0 | 0 | Doğru Sınıf |
| Covid-19 | 2 | 199 | 4 | |
| Zatürre | 15 | 3 | 187 | |
| | Tahmini Sınıf | | | |

Şekil 4.6. GoogleNet mimarisinde elde edilen karışıklık matrisi

Şekil 4.6 incelendiğinde GoogleNet mimarisi test için kullanılan 615 adet göğüs x-ray görüntüsünden 591 tanesini doğru tahmin ederken, geriye kalan 24 görüntüyü ise yanlış tahmin etmiştir. GoogleNet mimarisi test için kullanılan 205 göğüs x-ray Normal görüntüsünün tamamını doğru tahmin etmiştir. GoogleNet mimarisinin bu sınıfta yanlış tahmin ettiği görüntü bulunmamaktadır. Bu mimarinin Normal sınıfında elde ettiği doğruluk değeri %100'dür. GoogleNet mimarisi COVID-19 sınıfında ise 205 test görüntüsünün 199 tanesini doğru tahmin ederken, 6 görüntüyü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 2 göğüs x-ray görüntüsü model tarafından Normal şeklinde tahmin edilirken, 4 göğüs x-ray görüntüsü ise Zatürre şeklinde tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %95.67 şeklinde gerçekleşmiştir. Son olarak GoogleNet mimarisi Zatürre sınıfına ait 205 göğüs x-ray görüntüsünden 187 tanesini doğru tahmin ederken, 18 tanesini ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 15 tanesini Normal, 3 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %93.17'dir. GoogleNet mimarisinin en başarılı olduğu sınıf Normal, en başarısız olduğu sınıf ise Zatürre olmuştur. GoogleNet mimarisinin ortalama doğruluk değeri %96.10'dur. GoogleNet mimarisinde elde edilen performans metrikleri Tablo 4.3'te sunulmuştur.


Tablo 4.3. GoogleNet mimarisinde elde edilen performans metrikleri

| GoogleNet | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|-----------|-------------|---------------|-------------|-------------|
| Normal | 100 | 92.34 | 100 | 96.01 |
| Covid-19 | 97.07 | 98.51 | 98.54 | 97.78 |
| Zatürre | 91.21 | 97.90 | 95.75 | 94.44 |

Tablo 4.3 incelendiğinde GoogleNet mimarisinin en yüksek F1-Score değerini %97.78 ile COVID-19 sınıfında elde ederken, en düşük F1-Score değerini ise %94.44 ile Zatürre sınıfında elde etmiştir. GoogleNet mimarisinin Normal sınıfında elde ettiği F1-Score değeri ise %97.78 olmuştur.

4.5. MobileNetV3 mimarisinde elde edilen sonuçlar

Veri setindeki göğüs x-ray görüntülerinin sınıflandırılması için kullanılan dördüncü mimari ise MobileNetV3'dir. MobileNetV3 mimarisinde elde edilen doğruluk ve kayıp eğrileri şekil 4.7'de verilmiştir.



Şekil 4.7. MobileNetV3 mimarisinde elde edilen doğruluk ve kayıp eğrileri

MobileNetV3 mimarisi kullanılarak elde edilen karışıklık matrisi şekil 4.8'de verilmiştir.

| MobileNetV2 | Normal | Covid-19 | Zatürre | |
|---------------|--------|----------|---------|-------------|
| Normal | 205 | 0 | 0 | Doğru Sınıf |
| Covid-19 | 1 | 199 | 5 | |
| Zatürre | 12 | 3 | 190 | |
| Tahmini Sınıf | | | | |

Şekil 4.8. MobileNetV3 mimarisinde elde edilen karışıklık matrisi

Şekil 4.8 incelendiğinde MobileNetV3 mimarisi test için kullanılan 615 adet göğüs x-ray görüntüsünden 594 tanesini doğru tahmin ederken, geriye kalan 21 görüntüyü ise yanlış tahmin etmiştir. MobileNetV3 mimarisi test için kullanılan 205 göğüs x-ray Normal görüntüsünün tamamını doğru tahmin etmiştir. MobileNetV3 mimarisinin bu sınıfta yanlış tahmin ettiği görüntü bulunmamaktadır. Bu mimarinin Normal sınıfında elde ettiği doğruluk değeri %100'dür. MobileNetV3 mimarisi COVID-19 sınıfında ise 205 test görüntüsünün 199 tanesini doğru tahmin ederken, 6 görüntüyü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 1 göğüs x-ray görüntüsü model tarafından Normal şeklinde tahmin edilirken, 5 göğüs x-ray görüntüsü ise Zatürre şeklinde tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %97.07'dir. Son olarak MobileNetV3 mimarisi Zatürre sınıfına ait 205 göğüs x-ray görüntüsünden 190 tanesini doğru tahmin ederken, 15 tanesini ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 12 tanesini Normal, 3 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %92.68'dir. MobileNetV3 mimarisinin en başarılı olduğu sınıf Normal, en başarısız olduğu sınıf ise Zatürre olmuştur. MobileNetV3 mimarisinin ortalama doğruluk değeri %96.59'dur. MobileNetV3 mimarisinde elde edilen performans metrikleri Tablo 4.4'te sunulmuştur.


Tablo 4.4. MobileNetV3 mimarisinde elde edilen performans metrikleri

| MobileNetV2 | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|-------------|-------------|---------------|-------------|-------------|
| Normal | 100 | 94.03 | 100 | 96.62 |
| Covid-19 | 97.07 | 98.51 | 98.54 | 97.78 |
| Zatürre | 92.68 | 97.43 | 96.42 | 95.00 |

Tablo 4.4 incelendiğinde MobileNetV3 mimarisinin en yüksek F1-Score değerini %97.78 ile COVID-19sınıfında elde ederken, en düşük F1-Score değerini ise %95.00 ile Zatürre sınıfında elde etmiştir. MobileNetV3 mimarisinin Normal sınıfında elde ettiği F1-Score değeri ise %96.62 olmuştur.

4.6. Resnet101 mimarisinde elde edilen sonuçlar

Göğüs x-ray görüntülerinin sınıflandırılması için kullanılan beşinci ESA mimarisi ise Resnet101'dir. Resnet101 mimarisinde elde edilen doğruluk ve kayıp eğrileri şekil 4.9 te verilmiştir.



Şekil 4.9. Resnet101 mimarisinde elde edilen doğruluk ve kayıp eğrileri

Resnet101 mimarisi kullanılarak elde edilen karışıklık matrisi şekil 4.10'da verilmiştir.

| Resnet101 | Normal | Covid-19 | Zatürre | |
|-----------|---------------|----------|---------|-------------|
| Normal | 204 | 1 | 0 | Doğru Sınıf |
| Covid-19 | 1 | 204 | 0 | |
| Zatürre | 12 | 2 | 191 | |
| | Tahmini Sınıf | | | |

Şekil 4.10. Resnet101 mimarisinde elde edilen karışıklık matrisi

Şekil 4.10 incelendiğinde Resnet101 mimarisi test için kullanılan 615 adet göğüs x-ray görüntüsünden 599 tanesini doğru tahmin ederken, geriye kalan 16 görüntüyü ise yanlış tahmin etmiştir. Resnet101 mimarisi test için kullanılan 205 göğüs x-ray Normal görüntüsünden 204 tanesini doğru tahmin ederken, 1 görüntüyü ise COVID-19 olarak tahmin etmiştir. Bu mimarinin Normal sınıfında elde ettiği doğruluk değeri %99.51'dir. Resnet101 mimarisi COVID-19 sınıfında ise 205 test görüntüsünün 204 tanesini doğru tahmin ederken, 1 görüntüyü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 1 göğüs x-ray görüntüsü model tarafından Normal sınıfındaymış gibi tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %99.51'dir. Son olarak Resnet101 mimarisi Zatürre sınıfına ait 205 göğüs x-ray görüntüsünden 191 tanesini doğru tahmin ederken, 14 tanesini ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 12 tanesini Normal, 2 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %93.17'dir. Resnet101 mimarisinin en başarılı olduğu sınıflar Normal ve Covid-19, en başarısız olduğu sınıf ise Zatürre sınıfıdır. Resnet101 mimarisinin ortalama doğruluk değeri %97.40'dır. Resnet101 mimarisinde elde edilen performans metrikleri Tablo 4.5'te sunulmuştur.

Tablo 4.5. Resnet101 mimarisinde elde edilen performans metrikleri

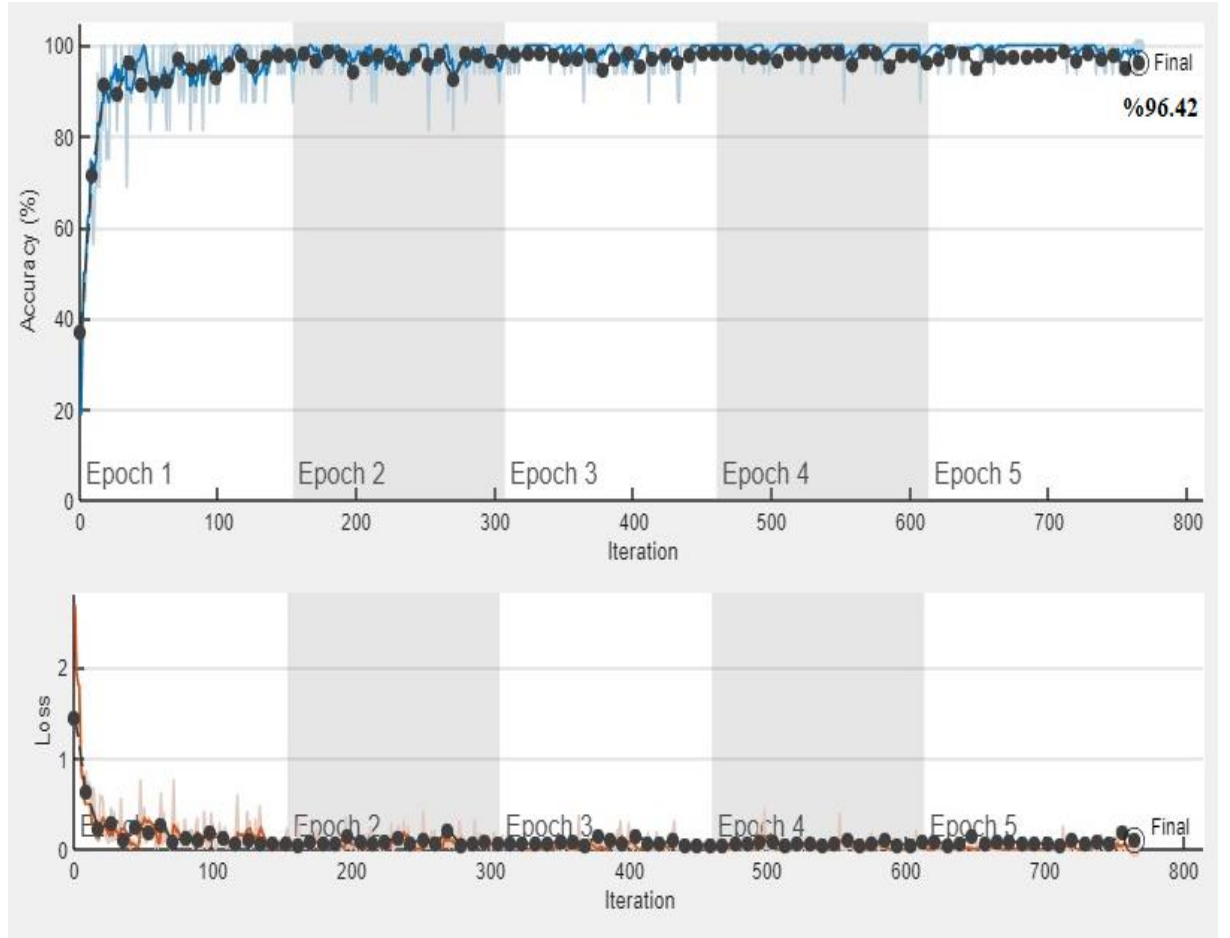
| Resnet101 | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|-----------|-------------|---------------|-------------|-------------|
| Normal | 99.51 | 94.00 | 99.74 | 96.68 |
| Covid-19 | 99.51 | 98.55 | 99.75 | 99.02 |
| Zatürre | 100 | 93.17 | 100 | 96.46 |

Tablo 4.5 incelendiğinde ResNet101 mimarisinin en yüksek F1-Score değerini %99.02 ile COVID-19sınıfında elde ederken, en düşük F1-Score değerini ise %96.46 ile Zatürre sınıfında

elde etmiştir. ResNet101 mimarisinin Normal sınıfında elde ettiği F1-Score değeri ise %96.68 olmuştur.

4.7. Vgg19 mimarisinde elde edilen sonuçlar

Göğüs x-ray görüntülerinin sınıflandırılması için kullanılan önceden eğitilmiş altıncı ESA mimarisi ise Vgg19'dur. Vgg19 mimarisinde elde edilen doğruluk ve kayıp eğrileri Şekil 4.11'de verilmiştir.



Şekil 4.11. Vgg19 mimarisinde elde edilen doğruluk ve kayıp eğrileri

Vgg19 mimarisi kullanılarak elde edilen karışıklık matrisi şekil 4.12'de verilmiştir.

| Vgg19 | Normal | Covid-19 | Zatürre | |
|---------------|--------|----------|---------|-------------|
| Normal | 203 | 2 | 0 | Doğru Sınıf |
| Covid-19 | 3 | 200 | 2 | |
| Zatürre | 11 | 4 | 190 | |
| Tahmini Sınıf | | | | |

Şekil 4.12. Vgg19 mimarisinde elde edilen karışıklık matrisi

Şekil 4.12 incelendiğinde Vgg19 mimarisi test için kullanılan 615 adet göğüs x-ray görüntüsünden 593 tanesini doğru tahmin ederken, geriye kalan 22 görüntüyü ise yanlış tahmin etmiştir. Vgg19 mimarisi test için kullanılan 205 göğüs x-ray Normal görüntüsünden 203 tanesini doğru tahmin ederken, 2 görüntüyü ise COVID-19 olarak tahmin etmiştir. Bu mimarinin Normal sınıfında elde ettiği doğruluk değeri %99.02'dir. Vgg19 mimarisi COVID-19 sınıfında ise 205 test görüntüsünün 200 tanesini doğru tahmin ederken, 5 görüntüyü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 3 göğüs x-ray görüntüsü model tarafından Normal ve 2 görüntü Zatürre sınıfındaymış gibi tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %97.56'dır. Son olarak Vgg19 mimarisi Zatürre sınıfına ait 205 göğüs x-ray görüntüsünden 190 tanesini doğru tahmin ederken, 15 tanesini ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 11 tanesini Normal, 4 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %92.68'dir. Vgg19 mimarisinin en başarılı olduğu sınıf Normal, en başarısız olduğu sınıf ise Zatürre sınıfıdır. Vgg19 mimarisinin ortalama doğruluk değeri %96.42'dir. Vgg19 mimarisinde elde edilen performans metrikleri Tablo 6'da sunulmuştur.

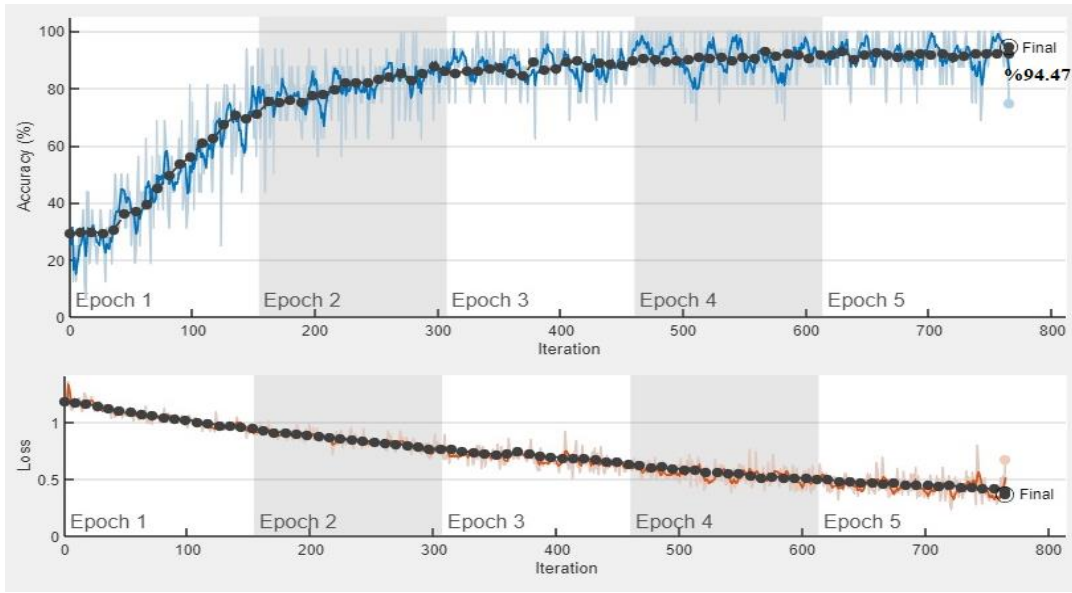
Tablo 4.6. Vgg19 mimarisinde elde edilen performans metrikleri

| Vgg19 | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|-----------------|-------------|---------------|-------------|-------------|
| Normal | 99.02 | 93.54 | 99.49 | 96.20 |
| Covid-19 | 97.56 | 97.08 | 98.77 | 97.32 |
| Zatürre | 92.68 | 98.95 | 96.45 | 95.71 |

Tablo 4.6 incelendiğinde Vgg19 mimarisinin en yüksek F1-Score değerini %97.32 ile COVID-19 sınıfında elde ederken, en düşük F1-Score değerini ise %95.71 ile Zatürre sınıfında elde etmiştir. Vgg19 mimarisinin Normal sınıfında elde ettiği F1-Score değeri ise %96.20 olmuştur.

4.8. Xception mimarisinde elde edilen sonuçlar

Göğüs x-ray görüntülerinin sınıflandırılması için kullanılan bir başka ESA mimarisi ise Xception mimarisidir. Xception mimarisinde elde edilen doğruluk ve kayıp eğrileri şekil 4.13'te verilmiştir.



Şekil 4.13. Xception mimarisinde elde edilen doğruluk ve kayıp eğrileri

Xception mimarisi kullanılarak elde edilen karışıklık matrisi şekil 4.14' de verilmiştir.

| Xception | Normal | Covid-19 | Zatürre | |
|----------|---------------|----------|---------|-------------|
| Normal | 201 | 0 | 4 | Doğru Sınıf |
| Covid-19 | 4 | 191 | 10 | |
| Zatürre | 13 | 3 | 189 | |
| | Tahmini Sınıf | | | |

Şekil 4.14. Xception mimarisinde elde edilen karışıklık matrisi

Şekil 4.14 incelendiğinde Xception mimarisi test için kullanılan 615 adet göğüs x-ray görüntüsünden 581 tanesini doğru tahmin ederken, geriye kalan 34 görüntüyü ise yanlış tahmin etmiştir. Xception mimarisi test için kullanılan 205 göğüs x-ray Normal görüntüsünden 201 tanesini doğru tahmin ederken, 4 görüntüyü ise Zatürre olarak tahmin etmiştir. Bu mimarinin Normal sınıfında elde ettiği doğruluk değeri %98.04'dür. Xception mimarisi COVID-19 sınıfında ise 205 test görüntüsünün 191 tanesini doğru tahmin ederken, 14 görüntüyü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 4 göğüs x-ray görüntüsü model tarafından Normal ve 10 görüntü Zatürre sınıfındaymış gibi tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %93.17'dir. Son olarak Xception mimarisi Zatürre sınıfına ait 205 göğüs x-ray görüntüsünden 189 tanesini doğru tahmin ederken, 16 görüntüyü ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 13 tanesini Normal, 3 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %92.19'dur. Xception mimarisinin en başarılı olduğu sınıf Normal, en başarısız olduğu sınıf ise Zatürre sınıfıdır. Xception mimarisinin ortalama doğruluk değeri %94.47'dir. Xception mimarisinde elde edilen performans metrikleri Tablo 4.7'te sunulmuştur.


Tablo 4.7. Xception mimarisinde elde edilen performans metrikleri

| Xception | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|-----------------|--------------------|----------------------|--------------------|--------------------|
| Normal | 98.04 | 92.20 | 98.99 | 95.03 |
| Covid-19 | 93.17 | 98.45 | 96.67 | 95.73 |
| Zatürre | 92.19 | 93.10 | 96.11 | 92.64 |

Tablo 4.7 incelendiğinde Xception mimarisinin en yüksek F1-Score değerini %95.73 ile COVID-19sınıfında elde ederken, en düşük F1-Score değerini ise %92.64 ile Zatürre sınıfında elde etmiştir. Xception mimarisinin Normal sınıfında elde ettiği F1-Score değeri ise %95.03 olmuştur.

4.9. Efficientnetb0 mimarisinde elde edilen sonuçlar

Göğüs x-ray görüntülerinin sınıflandırılması için kullanılan bir diğer ESA mimarisi ise EfficientNetb0 mimarisidir. EfficientNetb0 mimarisinde elde edilen doğruluk ve kayıp eğrileri şekil 4.15' te verilmiştir.



Şekil 4.15. EfficientNetb0 mimarisinde elde edilen doğruluk ve kayıp eğriler

EfficientNetb0 mimarisi kullanılarak elde edilen karışıklık matrisi şekil 4.16'da verilmiştir.

| EfficientNetb0 | Normal | Covid-19 | Zatürre | |
|----------------|---------------|----------|---------|-------------|
| Normal | 204 | 0 | 1 | Doğru Sınıf |
| Covid-19 | 6 | 191 | 8 | |
| Zatürre | 33 | 1 | 171 | |
| | Tahmini Sınıf | | | |

Şekil 4.16. EfficientNetb0 mimarisinde elde edilen karışıklık matrisi

Şekil 4.16 incelendiğinde EfficientNetb0 mimarisi test için kullanılan 615 adet göğüs x-ray görüntüsünden 566 tanesini doğru tahmin ederken, geriye kalan 49 görüntüyü ise yanlış

tahmin etmiştir. EfficientNetb0 mimarisi test için kullanılan 205 göğüs x-ray Normal görüntüsünden 204 tanesini doğru tahmin ederken, 1 görüntüyü ise Zatürre olarak tahmin etmiştir. Bu mimarinin Normal sınıfında elde ettiği doğruluk değeri %99.51'dir. EfficientNetb0 mimarisi COVID-19 sınıfında ise 205 test görüntüsünün 191 tanesini doğru tahmin ederken, 14 görüntüyü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 6 göğüs x-ray görüntüsü model tarafından Normal ve 8 görüntü Zatürre sınıfındaymış gibi tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %93.17'dir. Son olarak EfficientNetb0 mimarisi Zatürre sınıfına ait 205 göğüs x-ray görüntüsünden 171 tanesini doğru tahmin ederken, 34 görüntüyü ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 33 tanesini Normal, 1 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %83.41'dir. EfficientNetb0 mimarisinin en başarılı olduğu sınıf Normal, en başarısız olduğu sınıf ise Zatürre sınıfıdır. EfficientNetb0 mimarisinin ortalama doğruluk değeri %92.03'tür. EfficientNetb0 mimarisinde elde edilen performans metrikleri Tablo 4.8'te sunulmuştur.


Tablo 4.8. EfficientNetb0 mimarisinde elde edilen performans metrikleri

| EfficientNetb0 | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|----------------|-------------|---------------|-------------|-------------|
| Normal | 99.51 | 83.95 | 99.73 | 91.07 |
| Covid-19 | 93.17 | 99.47 | 96.69 | 96.22 |
| Zatürre | 83.41 | 95.00 | 92.18 | 88.83 |

Tablo 4.8 incelendiğinde EfficientNetb0 mimarisinin en yüksek F1-Score değerini %96.22 ile COVID-19 sınıfında elde ederken, en düşük F1-Score değerini ise %88.83 ile Zatürre sınıfında elde etmiştir. EfficientNetb0 mimarisinin Normal sınıfında elde ettiği F1-Score değeri ise %91.07 olmuştur.

4.10. ShuffleNet mimarisinde elde edilen sonuçlar

Göğüs x-ray görüntülerinin sınıflandırılması için bu tez çalışmasında kullanılan bir diğer ESA mimarisi ise ShuffleNet mimarisidir. ShuffleNet mimarisinde elde edilen doğruluk ve kayıp eğrileri şekil 4.17'de verilmiştir.



Şekil 4.17. ShuffleNet mimarisinde elde edilen doğruluk ve kayıp eğrileri

ShuffleNet mimarisi kullanılarak göğüs x-ray görüntüleri sınıflandırıldığında elde edilen karışıklık matrisi şekil 4.18’de verilmiştir.

| ShuffleNet | Normal | Covid-19 | Zatürre | |
|------------|---------------|----------|---------|-------------|
| Normal | 204 | 0 | 1 | Doğru Sınıf |
| Covid-19 | 2 | 198 | 5 | |
| Zatürre | 11 | 2 | 192 | |
| | Tahmini Sınıf | | | |

Şekil 4.18. ShuffleNet mimarisinde elde edilen karışıklık matrisi

Şekil 4.18 incelendiğinde ShuffleNet mimarisi test için kullanılan 615 adet göğüs x-ray görüntüsünden 594 tanesini doğru tahmin ederken, geriye kalan 21 göğüs x-ray görüntüsünü ise

yanlış tahmin etmiştir. ShuffleNet mimarisi test için kullanılan 205 göğüs x-ray Normal görüntüsünden 204 tanesini Normal diye doğru tahmin ederken, 1 görüntüyü ise Zatürre olarak yanlış tahmin etmiştir. Bu mimarinin Normal sınıfında elde ettiği doğruluk değeri %99.51'dir. ShuffleNet mimarisi COVID-19 sınıfında ise 205 test görüntüsünün 198 tanesini COVID-19 diye doğru tahmin ederken, 7 göğüs x-ray görüntüsünü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 2 göğüs x-ray görüntüsü model tarafından Normal ve 5 görüntü Zatürre sınıfındaymış gibi tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %96.58'dir. Son olarak ShuffleNet mimarisi Zatürre sınıfına ait 205 göğüs x-ray görüntüsünden 192 tanesini doğru tahmin ederken, 13 görüntüyü ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 11 tanesini Normal, 2 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %93.65'tir. ShuffleNet mimarisinin en başarılı olduğu sınıf Normal, en başarısız olduğu sınıf ise Zatürre sınıfıdır. ShuffleNet mimarisinin ortalama doğruluk değeri %96.59'dur. ShuffleNet mimarisinde elde edilen performans metrikleri Tablo 4.9'da sunulmuştur.

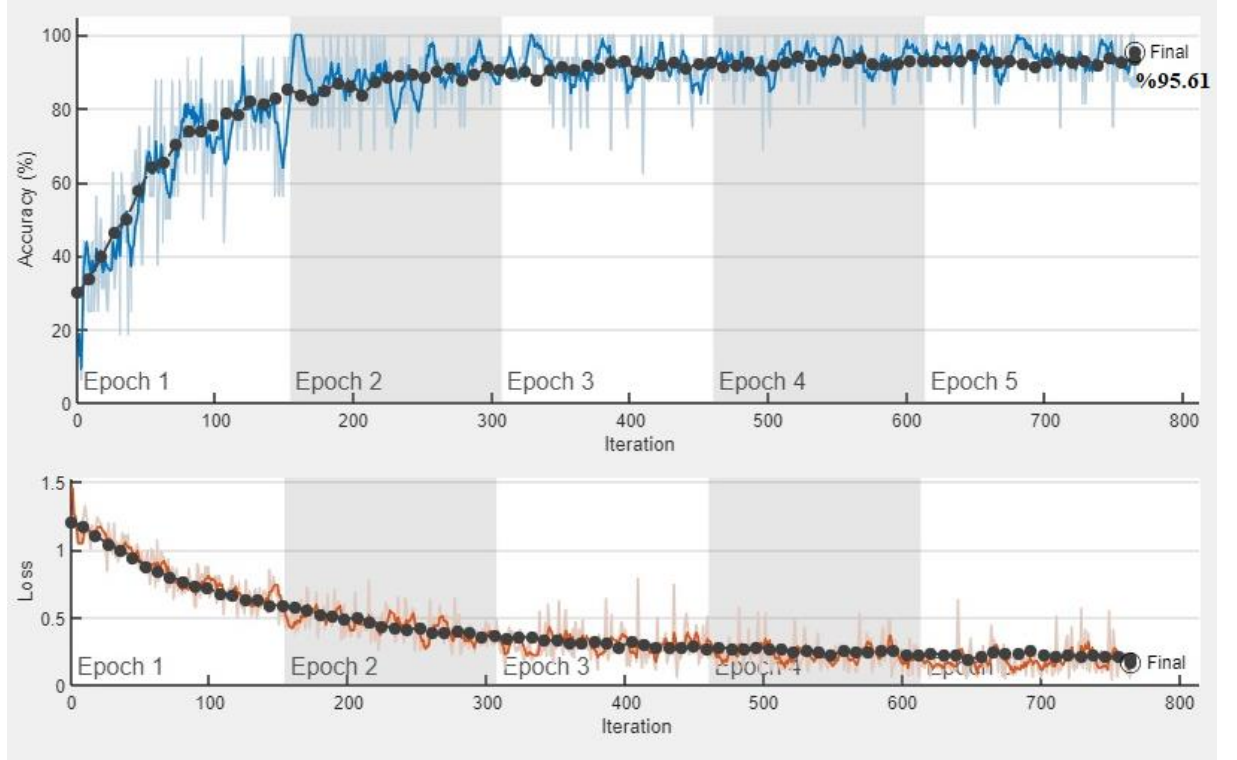
Tablo 4.9. ShuffleNet mimarisinde elde edilen performans metrikleri

| ShuffleNet | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|------------|-------------|---------------|-------------|-------------|
| Normal | 99.51 | 94.00 | 99.74 | 96.68 |
| Covid-19 | 96.58 | 99.00 | 98.31 | 97.77 |
| Zatürre | 93.65 | 96.96 | 96.88 | 95.28 |

Tablo 4.9 incelendiğinde ShuffleNet mimarisinin en yüksek F1-Score değerini %97.77 ile COVID-19 sınıfında elde ederken, en düşük F1-Score değerini ise %95.28 ile Zatürre sınıfında elde etmiştir. ShuffleNet mimarisinin Normal sınıfında elde ettiği F1-Score değeri ise %96.68 olmuştur.

4.11. NasNet Mobile mimarisinde elde edilen sonuçlar

Göğüs x-ray görüntülerinin sınıflandırılması için bu tez çalışmasında kullanılan önceden eğitilmiş bir diğer ESA mimarisi ise NasNet mimarisidir. NasNet Mobile mimarisinde elde edilen doğruluk ve kayıp eğrileri şekil 4.19'da verilmiştir.



Şekil 4.19. NasNet Mobile mimarisinde elde edilen doğruluk ve kayıp eğrileri

NasNet Mobile mimarisi kullanılarak elde edilen karışıklık matrisi şekil 4.20’de verilmiştir.

| NasNet Mobile | Normal | Covid-19 | Zatürre | |
|---------------|---------------|----------|---------|-------------|
| Normal | 203 | 0 | 2 | Doğru Sınıf |
| Covid-19 | 3 | 198 | 4 | |
| Zatürre | 15 | 3 | 187 | |
| | Tahmini Sınıf | | | |

Şekil 4.20. NasNet Mobile mimarisinde elde edilen karışıklık matrisi

Şekil 4.20 incelendiğinde NasNet Mobile mimarisi test için kullanılan 615 adet göğüs x-ray görüntüsünden 588 tanesini doğru tahmin ederken, geriye kalan 27 göğüs x-ray görüntüsünü

ise yanlış tahmin etmiştir. NasNet Mobile mimarisi test için kullanılan 205 göğüs x-ray Normal görüntüsünden 203 tanesini Normal diye doğru tahmin ederken, 2 göğüs x-ray görüntüsünü ise Zatürre olarak yanlış tahmin etmiştir. Bu mimarinin Normal sınıfında elde ettiği doğruluk değeri %99.02'dir. NasNet Mobile mimarisi COVID-19 sınıfında ise 205 test görüntüsünün 198 tanesini COVID-19 diye doğru tahmin ederken, 7 göğüs x-ray görüntüsünü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 3 göğüs x-ray görüntüsü model tarafından Normal ve 4 görüntü Zatürre sınıfındaymış gibi tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %96.58'dir. Son olarak NasNet Mobile mimarisi Zatürre sınıfına ait 205 göğüs x-ray görüntüsünden 187 tanesini doğru tahmin ederken, 18 görüntüyü ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 15 tanesini Normal, 3 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %91.21'dir. NasNet Mobile mimarisinin en başarılı olduğu sınıf Normal, en başarısız olduğu sınıf ise Zatürre sınıfıdır. NasNet Mobile mimarisinin ortalama doğruluk değeri %95.61'dir. NasNet Mobile mimarisinde elde edilen performans metrikleri Tablo 4.10'da sunulmuştur.

Tablo 4.10. NasNet Mobile mimarisinde elde edilen performans metrikleri

| NasNet Mobile | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|----------------------|--------------------|----------------------|--------------------|--------------------|
| Normal | 99.02 | 91.85 | 99.49 | 95.30 |
| Covid-19 | 96.58 | 98.50 | 98.30 | 97.53 |
| Zatürre | 91.21 | 96.89 | 95.73 | 93.96 |

Tablo 4.10 incelendiğinde NasNet mimarisinin en yüksek F1-Score değerini %97.53 ile COVID-19sınıfında elde ederken, en düşük F1-Score değerini ise %93.96 ile Zatürre sınıfında elde etmiştir. NasNet mimarisinin Normal sınıfında elde ettiği F1-Score değeri ise %95.30 olmuştur.

4.12. Önerilen modelde elde edilen sonuçlar

Göğüs x-ray görüntülerinin sınıflandırılması için yapılan bu tez çalışmasında hibrit bir model önerilmiştir. Önerilen bu yöntem literatürde kabul gören önceden eğitilmiş mimariler ile karşılaştırılmıştır. Önerilen modelde ResNet101 ve DenseNet201 mimarileri taban olarak kullanılmış ve veri setindeki x-ray görüntülerinin özellik haritaları elde edilmiştir. Daha sonra elde edilen özellik haritaları aynı görüntülerin farklı özelliklerini bir araya getirmek için birleştirilmiştir. Önerilen modelin son adımında birleştirilen özellik haritası SVM

sınıflandırıcısında sınıflandırılmıştır. Önerilen yöntemde elde edilen karışıklık matrisi şekil 4.21’de verilmiştir.

| Önerilen Yöntem | Normal | Covid-19 | Zatürre | |
|-----------------|--------|----------|---------|-------------|
| Normal | 1007 | 5 | 13 | Doğru Sınıf |
| Covid-19 | 6 | 1014 | 5 | |
| Zatürre | 22 | 4 | 999 | |
| Tahmini Sınıf | | | | |

Şekil 4.21. Önerilen modelde elde edilen karışıklık matrisi

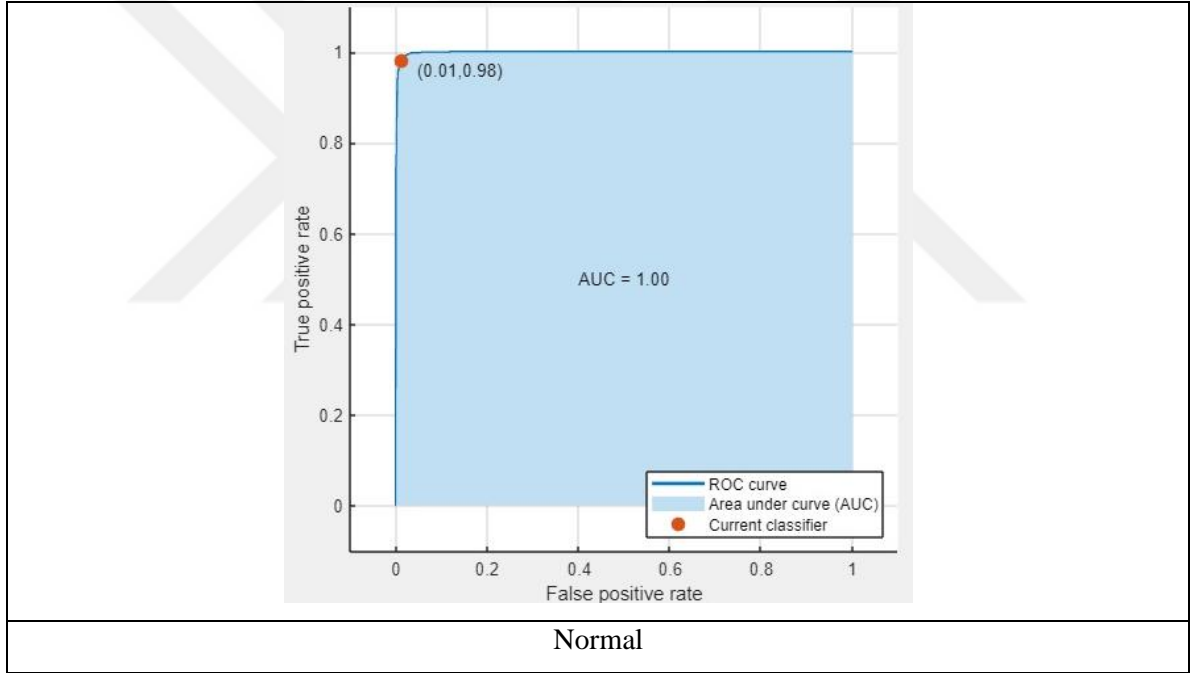
Şekil 4.21 incelendiğinde önerilen model 3075 adet göğüs x-ray görüntüsünden 3020 tanesini doğru tahmin ederken, geriye kalan 55 göğüs x-ray görüntüsünü ise yanlış tahmin etmiştir. Önerilen model 1025 göğüs x-ray Normal görüntüsünden 1007 tanesini Normal diye doğru tahmin ederken, 5 göğüs x-ray görüntüsünü COVID-19 ve 13 göğüs x-ray görüntüsünü ise Zatürre olarak yanlış tahmin etmiştir. Bu mimarinin Normal sınıfında elde ettiği doğruluk değeri %98.24’dir. Önerilen model COVID-19 sınıfında ise 1025 göğüs x-ray görüntüsünün 1014 tanesini COVID-19 diye doğru tahmin ederken, 11 göğüs x-ray görüntüsünü ise yanlış tahmin etmiştir. COVID-19 sınıfına ait 6 göğüs x-ray görüntüsü model tarafından Normal ve 5 görüntü Zatürre sınıfındaymış gibi tahmin edilmiştir. Modelin COVID-19 sınıfında elde ettiği doğruluk değeri %98.92’dir. Son olarak önerilen model Zatürre sınıfına ait 1025 göğüs x-ray görüntüsünden 999 tanesini doğru tahmin ederken, 26 görüntüyü ise yanlış tahmin etmiştir. Yanlış tahmin ettiği görüntülerden 22 tanesini Normal, 4 tanesini ise COVID-19 olarak tahmin etmiştir. Modelin Zatürre sınıfında elde ettiği doğruluk değeri ise %97.46’dir. Önerilen modelin en başarılı olduğu sınıf COVID-19, en başarısız olduğu sınıf ise Zatürre sınıfıdır. Göğüs x-ray görüntülerini sınıflandırmak için geliştirilen modelin ortalama doğruluk değeri %98.2’dir. Önerilen modelde elde edilen performans metrikleri Tablo 4.11’de sunulmuştur.

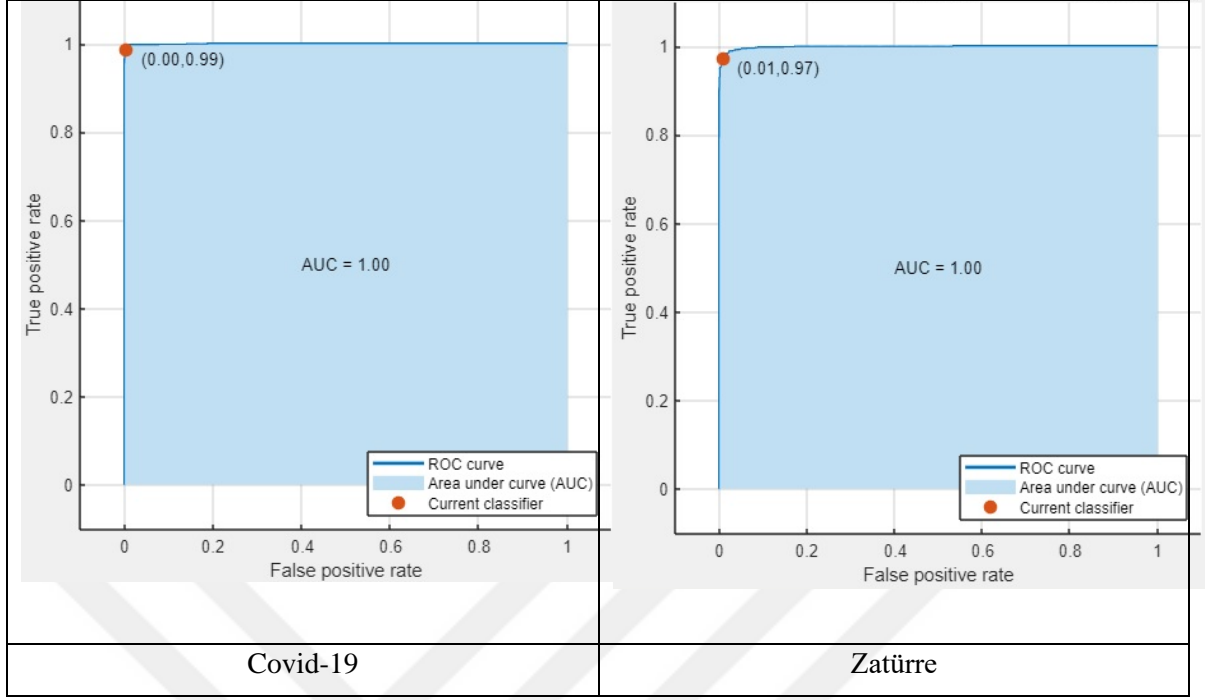
Tablo 4.11. Önerilen modelde elde edilen performans metrikleri

| Önerilen Model | Doğruluk(%) | Duyarlılık(%) | Özgüllük(%) | F1-Score(%) |
|----------------|-------------|---------------|-------------|-------------|
| Normal | 98.24 | 97.29 | 99.11 | 97.76 |
| Covid-19 | 98.92 | 99.12 | 99.46 | 99.02 |
| Zatürre | 97.46 | 98.23 | 98.73 | 97.84 |

Tablo 4.11 incelendiğinde önerilen modelin en yüksek F1-Score değerini %99.02 ile COVID-19sınıfında elde ederken, en düşük F1-Score değerini ise %97.76 ile Normal sınıfında elde etmiştir. Önerilen modelin Zatürre sınıfında elde ettiği F1-Score değeri ise %97.84 olmuştur.

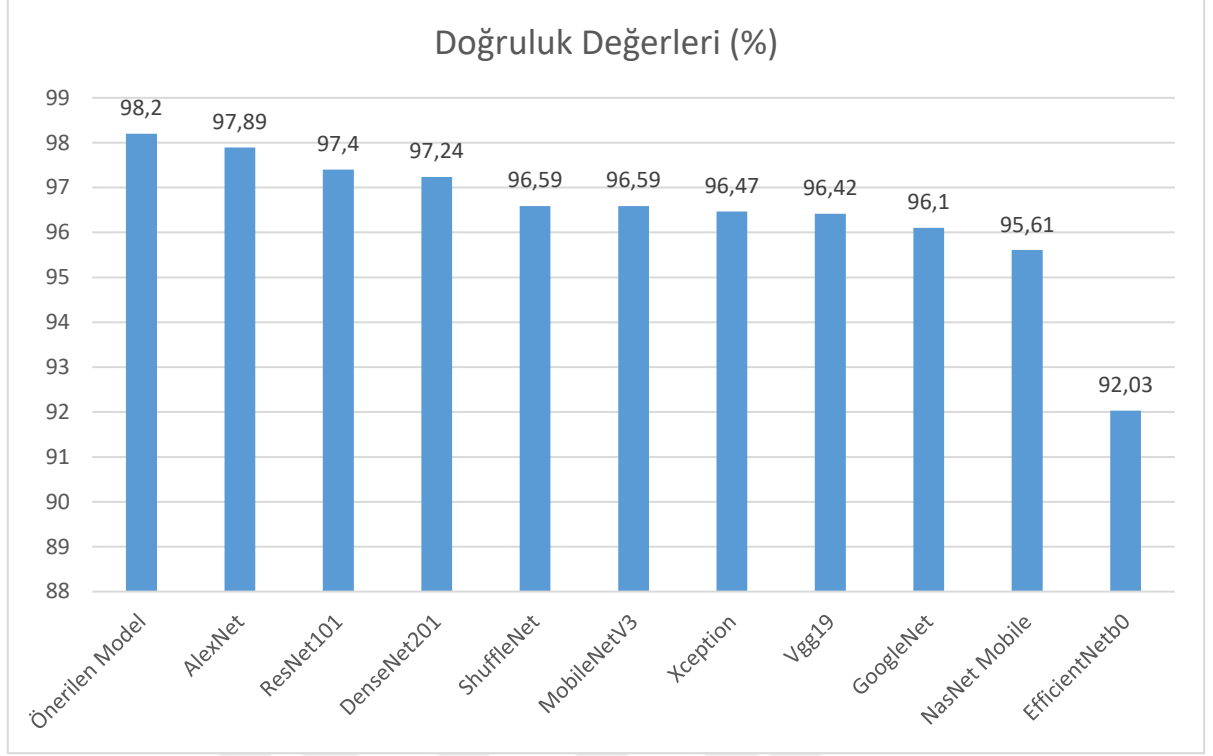
Önerilen modelde elde edilen AUC eğrileri şekil 4.22' te sunulmuştur.





Şekil 4.22. Önerilen modelde elde edilen AUC Eğrileri

Yapılan bu tez çalışmasında göğüs x-ray görüntülerinin sınıflandırılması için 10 tane önceden eğitilmiş ESA mimarisi kullanılmış ve ayrıca bir model önerilmiştir. Çalışmada kullanılan önceden eğitilmiş 10 ESA mimarisi ve önerilen modelde elde edilen doğruluk değerleri Şekil 4.23'te karşılaştırılmıştır.



Şekil 4.23. Modellerde elde edilen doğruluk değerleri

Şekil 4.23 incelendiğinde en yüksek doğruluk değerinin %98.2 ile önerilen modelde elde edildiği görülmektedir. Önerilen modeli sırasıyla %97.89 ile AlexNet, %97.4 ile ResNet101, %97.24 ile DenseNet201, %96.59 ile ShuffleNet ve MobileNetV3, %96.47 ile Xception, %96.42 ile Vgg19, %96.1 ile GoogleNet, %95.61 ile NasNet Mobile ve %92.03 ile EfficientNetb0 mimarileri takip etmiştir.

5. SONUÇLAR

2019 yılının Aralık ayının başlarında tüm dünyayı etkisi altına alan COVID-19 virüsü kısa bir sürede pandemiye dönüşmüştür. COVID-19 yaygın bir şekilde kendini ateş, kuru öksürük, kas ağrısı, boğaz ağrısı, göğüs ağrısı gibi semptomlarla göstermektedir. COVID-19 hastalığının teşhisinde x-ray ve Computed Tomography (CT), COVID-19 teşhisini koymada en önemli yöntemlerdir. COVID-19 teşhisinde Polymerasechainreaction (PCR) testi yaygın bir şekilde kullanılmaktadır. Ancak PCR testinin temin edilmesi oldukça zorlu bir süreç olmakla birlikte bu test yönteminin güvenilirliği, x-ray ve CT'ye göre daha düşüktür. CT ve x-ray görüntüleme yöntemleri kendi içinde karşılaştırıldığında ise, X-ray görüntüleme tekniği daha uygun maliyetli olduğundan daha yaygın bir şekilde kullanılmaktadır. Buna ek olarak x-ray ile CT kıyaslandığında x-ray ile daha kısa sürede görüntüleme yapabilmektedir. Tüm dünyayı etkisi altına alan ve ölüm oranı oldukça yüksek olan COVID-19 virüsünün erken tespit edilmesi oldukça önemlidir. Erken teşhis tedavinin daha erken başlamasına ve ölümlerin azalmasına imkan tanıyacaktır. Yapılan bu tez çalışmasında hem hastalığın daha erken teşhis edilebilmesi hem de uzmanların iş yükünün hafifletilebilmesi için yapay zeka tabanlı hibrit bir model geliştirilmiştir. Geliştirilen bilgisayar destekli bu model sayesinde COVID-19 hastalığının tespit edilmesi daha kısa bir sürede gerçekleşecektir. Geliştirilen bilgisayar destekli bu sistem sayesinde hem uzmanların iş yükü hafifleyecek hem de uzmanların yapacağı hataların önüne geçilecektir. Ayrıca önerilen model uzman olmayan yerlerde de kullanılabilir. Yapılan tez çalışmasında geliştirilen hibrit model literatürde kabul gören önceden eğitilmiş ESA mimarileri ile kıyaslandığında önerilen modelin daha başarılı olduğu görülmektedir. COVID-19 hastalığının bilgisayar destekli sistemler tarafından daha kısa bir sürede tespit edilebilmesi için geliştirilen model %98.2 oranında yüksek bir doğruluk değeri elde etmiştir. Bu değer önerilen modelin COVID-19 tespitinde kullanılabileceğini göstermektedir.

ÖNERİLER

COVID-19, RT-PCR testi, göğüs röntgeni görüntü analizi ve CT taramaları dahil olmak üzere çeşitli teknikler kullanılarak tespit edilebilir. RT-PCR, COVID-19 saptamanın etkili bir yoludur, ancak örnek toplama zaman alır ve her yerde bulunmayabilecek özel kitler gerektirir. COVID-19'u teşhis etmenin başka bir yolu, göğüs BT taraması görüntülerinin analizidir. BT taramalarından aşırı radyasyona maruz kalan kişilerde yüksek kanser riski vardır. Bununla birlikte, göğüs röntgeni testleri ucuzdur ve BT taramasına kıyasla düşük radyasyon riski taşır.

COVID-19 görüntülerinin bilgisayar destekli sistemler tarafından teşhis edilip sınıflandırılması büyük bir önem arz etmektedir. Bilgisayar destekli sistemler sayesinde uzmanların iş yükü hafifleyecek ve bu sistemler uzman olmayan yerlerde de ön teşhis işlemi için kullanılabilir. COVID-19 x-ray görüntüleri kullanılarak otomatik teşhis yapan bilgisayar destekli bir sistem tasarlamayı önermekteyiz.

KAYNAKLAR

- [1] <https://tr.wikipedia.org/wiki/Biyoteknoloji> (Erişim tarihi: 06.07.2021).
- [2] Baloch, S., Baloch, M.A., Zheng, T., Pei, X. (2020). The Coronavirus Disease 2019 (COVID-19) Pandemic, *The Tohoku Journal of Experimental Medicine*, 250 (4), pp. 271-278.
- [3] Hijawi, B., Abdallat, M., Sayaydeh, A., Alqasrawi, S., Haddadin, A., Jaarour, N., Alsheikh, S., Alsanouri, T. (2013). Novel coronavirus infections in Jordan, April 2012: epidemiological findings from a retrospective investigation, *Eastern Mediterranean Health Journal*, 19(1), pp. 12-18.
- [4] Velavan, T.P., ve Meyer, C.G. (2020). The COVID-19 epidemic, *Tropical Medicine and International*, 25, pp. 278-280.
- [5] Huang, C., Wang, Y., Li, X., Ren, L., Zhao, J., Hu, Y., Zhang, L., Fan, G., Xu, J., Gu, X., Cheng, Z., Yu, T., Xia, J., Wei, Y., Wu, W., Xie, X., Yin, W., Li, H., Liu, M., Xiao, Y., Gao, H., Guo, L., Xie, J., Wang, G., Jiang, R., Gao, Z., Jin, Q., Wang, J., Cao, B. (2020). Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China, *The Lancet*, 395, pp. 497-506.
- [6] Saruhan, M. (2020). COVID-19 Vakalarında Biyokimyasal Testlerin Değerlendirilm, *Ege Klinik Tıp Dergisi*, 58, ss.12-15.
- [7] Khan, P., Aufdembrink, L.M., Engelhart, A.E. (2020). Isothermal SARS-CoV-2 diagnostics: tools for enabling distributed pandemic testing as a means of supporting safe reopenings, *ACS Synthetic Biology*, 9, pp. 2861-2880.
- [8] Peeling, R.W., Wedderburn, C.J., Garcia, P.J., Boeras, D., Fongwen, N., Nkengasong, J., Sall, A., Tanuri, A., Heymann, D.L. (2020). Serology testing in the COVID-19 pandemic response, *Lancet Infectious Diseases*, 20, e245-e249.
- [9] Gupta, N., Augustine, S., Narayan, T., O'Riordan, A., Das, A., Kumar, D., Luong, J.H.T., Malhotra, B.D. (2021). Point-of-Care PCR Assays for COVID-19 Detection, *Biosensors*, 2021, p. 141.
- [10] Yan, C., Cui, J., Huang, L., Du, B., Chen, L., Xue, G., Li S., Zhang, W., Zhao, L., Sun, Y., Yao, H., Li, N., Zhao, H., Feng, Y., Liu, S., Zhang, Q., Liu, D., Yuan, J. (2020). Rapid and visual detection of 2019 novel coronavirus (SARS-CoV-2) by a reverse transcription loop-mediated isothermal amplification assay, *Clinical Microbiology and Infection*, 26 (6), pp. 773-779.
- [11] Peeling, R.W., Olliaro, P.L., Boeras, D.I., Fongwen, N. (2021) Scaling up COVID-19 rapid antigen tests: promises and challenges, *Lancet Infectious Diseases*, 21, e290-e295.
- [12] Sampaio, I., KusimotoTakeuti, N.N., Gusson, B., Rafael, T., Zucolotto, M.V. (2023). Capacitive immunosensor for COVID-19 diagnosis, *Microelectronic Engineering*, 111912, pp. 267-268.
- [13] <https://www.cdc.gov/dotw/covid-19/index.html> (Erişim tarihi:27.12.2022).
- [14] Du, Z., Wang, L., Cauchemez, S. (2020.) Risk for transportation of 2019 novel coronavirus disease from Wuhan to other cities in China. *Emerging Infectious Diseases*, 26(5), pp. 1049-1052.
- [15] WHO (2020). *World Health Organization Coronavirus Disease 2019 (COVID-19) - Situation Report 72*, 10.1001/jama.2020.2633.
- [16] Turner, A.J., Hiscox, J.A., Hooper, N.M. (2004). ACE2: from vasopeptidase to SARS virus receptor, *Trends in Pharmacological Sciences*, 25, pp. 291-294.
- [17] Al-Tawfiq, J.A. 2013 Middle East respiratory syndrome- coronavirus infection: an overview, *Journal Infect Public Health*, 6, pp. 319-22.
- [18] Holmes, K.V. ve Dominguez, S.R. (2013). The new age of virus discovery: genomic analysis of a novel human betacoronavirus isolated from a fatal case of pneumonia, *MBio*, 4(1), e54812.
- [19] Cui, J., Li, F., Shi, ZL., (2019). Origin and evolution of pathogenic coronaviruses, *Nature Reviews Microbiology*, 17, pp. 181- 192.
- [20] Wang, W., Tang, J., Wei, F. (2020) Updated understanding of the outbreak of 2019 novel coronavirus (2019-nCoV) in Wuhan, China, *Journal of Medical Virology*, 92, pp. 441-447.

- [21] Wilder-Smith, A. ve Freedman, D.O. (2020) Isolation, quarantine, social distancing and community containment: pivotal role for old-style public health measures in the novel coronavirus (2019-nCoV) outbreak, *Journal of Travel Medicine*, pp. 1-4.
- [22] Kurban, M. (2009). *Enfeksiyon hastalıkları ders kitabı*. Devlet kitapları, İkinci baskı, İstanbul.
- [23] Alakus, T.B. ve Turkoglu, I. (2020). Comparison of deep learning approaches to predict COVID-19infection, *Chaos, Solitons & Fractals*, 140, pp. 110120.
- [24] Jain, G., Mittal, D., Thakur, D., Mittal, M.K. (2020). A deep learning approach to detect COVID-19coronavirus with X-ray images, *Biocybernetics and biomedical engineering*, 40(4), pp. 1391-1405.
- [25] Azemin, M.Z.C., Hassan, R., Tamrin, M.I.M, Ali, M.A.M. (2020). COVID-19deep learning prediction model using publicly available radiologist-adjudicated chest X-ray images as training data: Preliminary findings, *International Journal of Biomedical Imaging*, 2020, pp. 1–7.
- [26] Saiful Islam, M., Das, S.J., Riajul Alam Khan M., Momen, S., Mohammed, N. (2023). Detection of COVID-19and Pneumonia Using Deep Convolutional Neural Network, *Computer Systems Science and Engineering*, 44(1), pp. 519-534.
- [27] Nishio, M. Noguchi, S. Matsuo H., Murakami, T. (2020). Automatic classification between COVID-19pneumonia, non-COVID-19pneumonia, and the healthy on chest X-ray image, *Combination of data augmentation methods, Scientific Reports*, 10(1), pp. 1–6.
- [28] Khan, A.I., Shah J.L., Bhat, M.M. (2020). Coronet: A deep neural network for detection and diagnosis of COVID19 from chest X-ray images, *Computer Methods and Programs in Biomedicine*, vol. 196, no. 18, pp. 9, 2020
- [29] Wang, L. Lin Z.Q., Wong, A. (2020). COVID-Net: A tailored deep convolutional neural network design for detection of COVID-19cases from chest X-ray images, *Scientific Reports*, 10(1), pp. 1–12.
- [30]. Oh, Y., Park, S., Ye, J.C. (2020). Deep learning COVID-19features on CXR using limited training data sets, *IEEE transactions on medical imaging*, 39(8), pp. 2688-2700.
- [31] Aslan, M.F., Sabanci, K., Durdu, A., Unlersen, M.F. (2022). COVID-19diagnosis using state-of-the-art CNN architecture features and Bayesian Optimization, *Computers in Biology and Medicine*, 105244.
- [32] Irmak, E. (2021). COVID-19 disease severity assessment using CNN model, *IET image processing*, 15(8), pp. 1814-1824.
- [33] Monshi, M.M.A., Poon, J., Chung, V., Monshi, F.M. (2021). CovidXrayNet: Optimizing data augmentation and CNN hyperparameters for improved COVID-19detection from CXR, *Computers in biology and medicine*, 133, 104375.
- [34] Heidari, M., Mirniaharikandehi, S., Khuzani, A.Z., Danala, G., Qiu, Y., Zheng, B. (2020). Improving the performance of CNN to predict the likelihood of COVID-19using chest X-ray images with preprocessing algorithms. *International journal of medical informatics*, 144, p.104284.
- [35] Hira, S., Bai, A., Hira, S. (2021). An automatic approach based on CNN architecture to detect COVID-19disease from chest X-ray images, *Applied Intelligence*, 51(5), pp. 2864-2889.
- [36] Jia, G., Lam, H. K., Xu, Y. (2021). Classification of COVID-19chest X-Ray and CT images using a type of dynamic CNN modification method, *Computers in biology and medicine*, 134, p.104425.
- [37] Dastider, A.G., Sadik, F., Fattah, S.A. (2021). An integrated autoencoder-based hybrid CNN-LSTM model for COVID-19severity prediction from lung ultrasound, *Computers in Biology and Medicine*, 132, p.104296.
- [38] GÜNGÖR, S. (2021). *Derin Öğrenme Yöntemleri Kullanarak Bilgisayarlı Tomografi Görüntülerinden Covid-19'un Tespit Edilmesi*, Yüksek lisans Tezi, , Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- [39] Alshazly, H., Linse, C., Abdalla, M., Barth, E., Martinetz, T. (2021). COVID-Nets: deep CNN architectures for detecting COVID-19using chest CT scans, *Peer Journal Computer Science*, 7, e655.

- [40] Naeem, H., ve Bin-Salem, A.A. (2021). A CNN-LSTM network with multi-level feature extraction-based approach for automated detection of coronavirus from CT scan and X-ray images, *Applied Soft Computing*, 113, p.107918.
- [41] Muhammad, U., Hoque, M. Z., Oussalah, M., Keskinarkaus, A., Seppänen, T., Sarder, P. (2022). SAM: Self-augmentation mechanism for COVID-19 detection using chest X-ray images, *Knowledge-Based Systems*, 241, p. 108207.
- [42] Demir, F. (2021). DeepCoroNet: A deep LSTM approach for automated detection of COVID-19 cases from chest X-ray images, *Applied Soft Computing*, 103, p. 107160.
- [43] Kumar, M., Shakya, D., Kurup, V., Suksatan, W. (2022). COVID-19 prediction through X-ray images using transfer learning-based hybrid deep learning approach, *Materials Today: Proceedings*, 51, pp. 2520-2524.
- [44] Zhao, B., Li, X., Lu, X., Wang, Z. (2018). A CNN-RNN architecture for multi-label weather recognition. *Neurocomputing*, 322, pp. 47-57.
- [45] Bingol, H. (2022). Derin Öğrenme Modellerinde Komşuluk Bileşen Analizi Yöntemi Kullanarak Çiçek Görüntülerinin Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), pp. 439-447.
- [46] Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U.B., Yildirim, O., Acharya, U.R. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images, *Computers in biology and medicine*, 121, p.103792.
- [47] Cengil, E., ve Cinars, A. (2017). Comparison Of Hog (Histogram of Oriented Gradients) and Haar Cascade Algorithms with a Convolutional Neural Network Based Face Detection Approaches, *International journal of advance research, ideas and innovations in technology*, 3(5), pp. 244-255.
- [48] Yamashita, R., Nishio, M., Do, R. K. G., Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology, *Insights into imaging*, 9(4), pp. 611-629.
- [49] Kattenborn, T., Leitloff, J., Schiefer, F., Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing, *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, pp. 24-49.
- [50] Yan, K., Huang, S., Song, Y., Liu, W., Fan, N. (2017). Face recognition based on convolution neural network, *In 2017 36th Chinese Control Conference (CCC)*, (pp. 4077-4081). IEEE.
- [512] Pang, Y., Sun, M., Jiang, X., Li, X. (2017). Convolution in convolution for network in network, *IEEE transactions on neural networks and learning systems*, 29(5), pp. 1587-1597.
- [52] Dias, C. A., Bueno, J., Borges, E. N., Botelho, S. S., Dimuro, G. P., Lucca, G., Drews Junior, P.L.J. (2018). Using the Choquet integral in the pooling layer in deep learning networks. *In North american fuzzy information processing society annual conference*, (pp. 144-154). Springer, Cham.
- [53] Zhou, S., ve Wu, J.N. (2015). Compression of fully-connected layer in neural network by kronecker product, *arXiv preprint arXiv*, 1507.05775.
- [54] Yamashita, R., Nishio, M., Do, R K.G., Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology, *Insights into imaging*, 9(4), pp. 611-629.
- [55] Alom, M.Z., Taha, T.M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Asari, V.K. (2018). The history began from AlexNet: A comprehensive survey on deep learning approaches, *arXiv preprint arXiv*, 1803.01164.
- [56] Krizhevsky, A., Sutskever, I., Hinton, G.E. (2012). Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 25.
- [57] LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86(11), pp. 2278-2324.
- [58] Simonyan, K., ve Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv*, 1409.1556.
- [59] He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).

- [60] Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions, *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1251-1258).
- [61] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. (2015). Going deeper with convolutions. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- [63] Thudumu, S., Branch, P., Jin, J., Singh, J.J. (2020). A comprehensive survey of anomaly detection techniques for high dimensional big data. *Journal of Big Data*, 7(1), pp. 1-30.
- [64] Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications, *arXiv preprint arXiv:1704.04861*.
- [65] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.C. (2018). MobileNetv2: Inverted residuals and linear bottlenecks. *Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition*.
- [66] Cengil, E., (2022). *İki Boyutlu Sağlık, Tarım Ve İş Güvenliği İmgeleri Üzerinde Sınıflandırma Ve Nesne Tespiti*, Yüksek lisans, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- [67] Tan, M. ve Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. *Paper presented at the International Conference on Machine Learning*.
- [68] Alhichri, H., Alswayed, A.S., Bazi, Y., Ammour, N., Alajlan, N. A. (2021). Classification of Remote Sensing Images Using EfficientNet-B3 CNN Model With Attention, *in IEEE Access*, 9, pp. 14078-14094.
- [69] Ma, N., Zhang, X., Zheng, H. T., Sun, J. (2018). Shufflenet v2: Practical guidelines for efficient cnn architecture design. *In Proceedings of the European conference on computer vision (ECCV)* (pp.116-131).
- [70] Liu, H., Yao, D., Yang, J., Li, X. (2019). Lightweight Convolutional Neural Network and Its Application in Rolling Bearing Fault Diagnosis under Variable Working Conditions, *Sensors*, 19(22), p.4827.
- [71] Zoph, B., Vasudevan, V., Shlens, J., Le, Q. (2018). Learning transferable architectures for scalable image recognition. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*
- [72] <https://www.kaggle.com/datasets/francismon/curated-covid19-chest-xray-dataset> (Erişim tarihi: 20.08.2022).

