



T.C.
AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI

COVID19 YAYILIMINI AZALTMAK İÇİN YÜZ MASKESİNİN
EVİRİŞİMSEL SİNİR AĞI MODELLERİ İLE TESPİTİ

YÜKSEK LİSANS TEZİ

ASLIHAN DAŞGIN

DANIŞMAN
DOÇ. DR. KEMAL ADEM

AKSARAY 2023

T.C.
AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI

COVID19 YAYILIMINI AZALTMAK İÇİN YÜZ MASKESİNİN
EVİRİŞİMSEL SİNİR AĞI MODELLERİ İLE TESPİTİ

YÜKSEK LİSANS TEZİ

ASLIHAN DAŞGIN

DANIŞMAN
DOÇ. DR. KEMAL ADEM
DR. ÖĞR. ÜYESİ SERHAT KILIÇARSLAN

AKSARAY 2023

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU

Bu tezin tüm hakları saklıdır. Kaynak göstermek koşuluyla tezin teslim tarihinden itibaren(...) ay sonra tezden fotokopi çekilebilir.

YAZARIN

Adı : Aslıhan

Soyadı : DAŞGIN

Bölümü : Yönetim Bilişim Sistemleri

İmza :

Teslim tarihi :

TEZİN

Türkçe Adı : Covid19 Yayılımını Azaltmak İçin Yüz Maskesinin Evrimsel Sinir Ağı Modelleri ile Tespiti

İngilizce Adı : Detection of Face Mask with Convolutional Neural Network Models to Reduce Covid19 Spread

ETİK İLKELERE UYGUNLUK BEYANI

Tez yazma sürecinde bilimsel ve etik ilkelere uyduđumu, yararlandıđım tüm kaynakları kaynak gösterme ilkelerine uygun olarak kaynakçada belirttiđimi ve bu bölümler dışındaki tüm ifadelerin şahsıma ait olduđunu beyan ederim.

Yazar Adı Soyadı: Aslıhan DAŞGIN

İmza:

T.C.
AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
JÜRİ ONAY SAYFASI

Aslıhan DAŞGIN tarafından hazırlanan “Covid19 Yayılımını Azaltmak İçin Yüz Maskesinin Evrişimsel Sinir Ağı Modelleri ile Tespiti” başlıklı tez çalışması aşağıdaki jüri tarafından oy birliği ile Aksaray Üniversitesi Yönetim Bilişim Sistemleri Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

İmza

Danışman : Doç. Dr. Kemal ADEM

Bilgisayar Mühendisliği, Sivas Bilim ve Teknoloji Üniversitesi

.....

Üye: Dr. Öğr. Üyesi Rahmi BAKİ

Yönetim Bilişim Sistemleri, Aksaray Üniversitesi

.....

Üye: Dr. Öğr. Üyesi Cemil KÖZKURT

Ulaştırma Mühendisliği, Bandırma Onyedli Eylöl Üniversitesi

.....

Tez Savunma Tarihi: 19 / 01 / 2023

Sosyal Bilimler Enstitüsü Yönetim Kurulu’nun tarih ve sayılı kararı ile onaylanmıştır.

Sosyal Bilimler Enstitüsü Müdürü

Doç. Dr. Sevilay USLU DİVANOĞLU

İmza

TEŞEKKÜR

Bu çalışmanın gerçekleşmesinde yardımlarını esirgemeyen ve yol gösteren danışman hocalarım Sayın Doç. Dr. Kemal ADEM'e ve Dr. Öğretim Üyesi Serhat Kılıçarslan'a, değerli fikirleri ile çalışmaya katkı sunan jüri üyelerine, her daim yanımda olan başta eşim Ramazan DAŞGIN ve oğlum Mehmet Eren DAŞGIN olmak üzere destek ve yardımlarını esirgemeyen tüm aileme teşekkür ederim.

AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
COVID19 YAYILIMINI AZALTMAK İÇİN YÜZ MASKESİNİN
EVRIŞİMSEL SİNİR AĞI MODELLERİ İLE TESPİTİ

(Yüksek Lisans Tezi)

Aslıhan DAŞGIN, Aksaray 2023

ÖZET

Son yıllarda hayatımızın gerçeği olan ve tüm dünya için pandemi haline gelen Covid-19'un gerekli tedbirlere sıkı şekilde uyulmadığı takdirde bulaşma oranı artmakta hatta varyantları bile ortaya çıkmaya başlamaktadır. Dünya Sağlık Örgütü tarafından yayınlanan ve alınması gerekli olan tedbirler alındıkça hastalıkla mücadele daha kolay hale gelebilmektedir. Tedbirlere uymanın zorluğu olsa da uymaya özen gösterildiği takdirde, hastalık ya daha hafif atlatılmakta ya da hastalığa kolayca yakalanılmamaktadır. Bu tedbirlerin en önemlilerinden birisi de kalabalık alanlarda maske kullanımına özen gösterilmesidir. Maske kullanımının önemi araştırmalarla desteklenmesinden sonra, bazı alışveriş merkezi, sağlık kuruluşları, okullar gibi kalabalık mekanlarda maske kullanımına yönelik denetimler başlamıştır. Ancak bu denetimleri bir insanın gerçekleştirmesi zor olduğundan günümüzde sıklıkla kullanılan derin öğrenme yöntemleriyle maske tespiti çalışmaları yapılmaya başlanmıştır. Bu tez çalışmasında, transfer öğrenme tabanlı modeller kullanılarak maske tespiti gerçekleştirilmesi amaçlanmaktadır. Kaggle web sitesinde bulunan veri seti üzerinde toplamda 906 görüntü ile DenseNet121, EfficientNetV2M, NasNetMobile, InceptionV3 ve VGG19 derin öğrenme modelleri kullanılmıştır. Deneysel değerlendirmeler sonucunda, en iyi başarı oranı olarak NasNetMobile modeliyle, %99.35 doğruluk, %99 kesinlik, %99 geri çağırma ve %99 f1 skorları elde edildiği görülmüştür.

Bilim Kodu: 92431, 92432, 92418

Anahtar Kelimeler: Maske Tespiti, Maskeli, Maskesiz, Derin Öğrenme, Nesne Tespiti, CNN, Covid-19

Sayfa Adedi: 66

Danışman: Doç. Dr. Kemal ADEM

İkinci Danışman: Dr. Öğr. Üyesi Serhat KILIÇARSLAN

AKSARAY UNIVERSITY
GRADUATE SCHOOL OF SOCIAL SCIENCES
DETECTION OF FACE MASK WITH CONVOLUTIONAL
NEURAL NETWORK MODELS TO REDUCE COVID19
SPREAD

(M.A. Thesis)

Ashhan DAŞGIN, Aksaray 2023

ABSTRACT

In recent years, Covid-19, which has become a reality of our lives and has become a pandemic for the whole world, increases the rate of infection and even variants of it begin to appear if the necessary precautions are not strictly followed. As the measures published by WHO and necessary to be taken are taken, the fight against the disease may become easier. Although it is difficult to comply with the measures, if care is taken to comply, the disease is either milder or the disease is not easily caught. One of the most important of these measures is to pay attention to the use of masks in crowded areas. After the importance of mask use was supported by research, inspections for the use of masks in crowded places such as some shopping malls, health institutions and schools began. However, since it is difficult for a human to perform these inspections, mask detection studies have begun to be carried out with deep learning methods, which are frequently used today. In this thesis, it is aimed to perform mask detection using transfer learning based models. DenseNet121, EfficientNetV2M, NasNetMobile, InceptionV3 and VGG19 deep learning models were used with a total of 906 images with the data set available on the Kaggle website. As a result of the experimental evaluations, it was seen that the best success rate was obtained with the NasNetMobile model, with 99.35% accuracy, 99% precision, 99% recall and 99% f1 scores.

Science Code: 92431, 92432, 92418

Key Words: Mask Detection, Masked, Unmasked, Deep Learning, Object Detection, CNN, Covid-19

Page Number: 66

Supervisor: Assoc. Prof. Dr. Kemal ADEM

Co-supervisor: Asst. Prof. Dr. Serhat KILIÇARSLAN

İÇİNDEKİLER

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU	İ
ETİK İLKELERE UYGUNLUK BEYANI.....	İİ
JÜRİ ONAY SAYFASI.....	İİİ
TEŞEKKÜR.....	İV
ÖZET.....	V
ABSTRACT	VI
TABLolar LİSTESİ.....	İX
ŞEKİLLER LİSTESİ.....	X
RESİMLER LİSTESİ.....	XI
SİMGELER VE KISALTMALAR LİSTESİ.....	XII
1. GİRİŞ.....	1
1.1. ARAŞTIRMANIN AMACI.....	3
1.2. ARAŞTIRMANIN KAPSAMI.....	4
1.3. ARAŞTIRMANIN ÖNEMİ.....	4
2. LİTERATÜR TARAMASI	5
3. KURAMSAL TEMELLER.....	10
3.1. COVID-19 SALGINI.....	10
3.1.1. <i>Bulaşma Yolları ve Alınan Önlemler</i>	11
3.2. NESNE TESPİTİ	13
4. MATERYAL VE YÖNTEM.....	14
4.1. VERİ SETİNİN OLUŞTURULMASI.....	14
4.2. DERİN ÖĞRENME	14
4.3. CNN (CONVOLUTIONAL NEURAL NETWORK-EVRİŞİMLİ SINIR	

AĞLARI)	16
4.3.1. <i>Evrişim Katmanı</i>	17
4.3.2. <i>ReLU (Düzeltilmiş Doğrusal Birim) Katmanı</i>	18
4.3.3. <i>Havuzlama Katmanı</i>	18
4.3.4. <i>Tam Bağlı Katman</i>	19
4.4. KULLANILAN MODELLER	19
4.4.1. <i>DenseNet121</i>	19
4.4.2. <i>EfficientNetV2M</i>	20
4.4.3. <i>NasNetMobile</i>	21
4.4.4. <i>InceptionV3</i>	22
4.4.5. <i>VGG19</i>	23
4.5. PERFORMANS METRİKLERİ.....	24
4.5.1. <i>Karışıklık Matrisi</i>	24
4.5.2. <i>Doğruluk (Accuracy)</i>	25
4.5.3. <i>Kesinlik (Precision)</i>	25
4.5.4. <i>Geri Çağırma (Recall)</i>	25
4.5.5. <i>F1 Skor</i>	26
4.6. MODEL EĞİTİMİNDE KULLANILAN KAVRAMLAR	26
4.6.1. <i>Training</i>	26
4.6.2. <i>Learning Rate</i>	26
4.6.3. <i>Epoch</i>	26
4.6.4. <i>Batches</i>	27
4.6.5. <i>Optimizasyon (Optimizer)</i>	27
4.7. TENSORFLOW	27
4.8. KERAS.....	27
5. BULGULAR	29
5.1. DENSENET121 MODELİYLE ELDE EDİLEN SONUÇLAR	30
5.2. EFFICIENTNETV2M MODELİYLE ELDE EDİLEN SONUÇLAR.....	32
5.3. NASNETMOBILE MODELİYLE ELDE EDİLEN SONUÇLAR	34
5.4. INCEPTIONV3 MODELİYLE ELDE EDİLEN SONUÇLAR	36
5.5. VGG19 MODELİYLE ELDE EDİLEN SONUÇLAR	38
5.6. KULLANILAN MODELLERİN KARŞILAŞTIRILMASI.....	40
6. SONUÇ VE ÖNERİLER.....	42
7. KAYNAKÇA	44
EKLER.....	50
AKSARAY ÜNİVERSİTESİ TEZ DEĞERLENDİRME FORMU	51

TABLÖLAR LİSTESİ

Tablo 1: ImageNet1K ile yapılan eğitim sonuçları (Tan & Le, 2021).....	21
Tablo 2: ImageNet21K önceden eğitilmiş ve ince ayarı yapılmış modeller (Tan & Le, 2021)	21
Tablo 3: Karışıklık Matrisi.....	24
Tablo 4: Modelleri Eğitiminde Kullanılan Parametreler	30
Tablo 5: DenseNet121 Modeli Ölçüm Parametre Sonuçları	30
Tablo 6: DenseNet121 Modeli Sınıflama Raporu	32
Tablo 7: EfficientNetV2M Modeli Ölçüm Parametre Sonuçları.....	32
Tablo 8: EfficientNetV2M Modeli Sınıflama Raporu	34
Tablo 9: NasNetMobile Modeli Ölçüm Parametre Sonuçları.....	34
Tablo 10: NasNetMobile Modeli Sınıflama Raporu.....	36
Tablo 11: InceptionV3 Modeli Ölçüm Parametre Sonuçları	36
Tablo 12: InceptionV3 Modeli Sınıflama Raporu	38
Tablo 13: VGG19 Modeli Ölçüm Parametre Sonuçları	38
Tablo 14: VGG19 Modeli Sınıflama Raporu.....	40
Tablo 15: Modellerin Doğruluk, Eğitim Süresi, Kesinlik, Geri Çağırma, F1-Skor, Kayıp Değerlerinin Karşılaştırılması	40

ŞEKİLLER LİSTESİ

Şekil 1: Derin Öğrenmenin Yapısı (Isaksson, 2018)	15
Şekil 2: Derin Öğrenme Türleri (Kaya & Önal, 2021)	15
Şekil 3: Evrişimli Sinir Ağı Genel Mimarisi (Akar, 2022).....	17
Şekil 4: Görüntünün Evrişimi ve Çıktının Elde Edilmesi.....	17
Şekil 5: Maksimum ve Ortalama Havuzlama Katmanı (Doğan, 2020)	18
Şekil 6: Değerlerin Tam Bağlı Katmanda Kullanılması İçin Düzleştirme İşlemi (Konca, 2020)	19
Şekil 7: DenseNet121 Mimarisi (Eryilmaz & Karacan, 2021)	20
Şekil 8: EfficientNetV2 Modellerinin Eğitim Verimlilikleri (Tan & Le, 2021).....	21
Şekil 9: NasNetMobile Mimarisi (Eryilmaz & Karacan, 2021)	22
Şekil 10: InceptionV3 Mimarisi (Ashames, 2020)	23
Şekil 11: VGG19 Mimarisi (Simonyan & Zisserman, 2014)	24
Şekil 12: Google Colab Jupyter Notebook Görünümü	29
Şekil 13: Klasör Halinde Veri Setinin Dağılımı	30
Şekil 14: DenseNet121 Modeli Eğitim Grafiği	31
Şekil 15: DenseNet121 Modeli Karışıklık Matrisi	31
Şekil 16: EfficientNetV2M Modeli Eğitim Grafiği	33
Şekil 17: EfficientNetV2M Modeli Karışıklık Matrisi	33
Şekil 18: NasNetMobile Modeli Eğitim Grafiği.....	35
Şekil 19: NasNetMobile Modeli Karışıklık Matrisi.....	35
Şekil 20: InceptionV3 Modeli Eğitim Grafiği	37
Şekil 21: InceptionV3 Modeli Karışıklık Matrisi	37
Şekil 22: VGG19 Modeli Eğitim Grafiği.....	39
Şekil 23: VGG19 Karışıklık Matrisi	39

RESİMLER LİSTESİ

Resim 1: Corana Virüs Yapısı (DSÖ, 2022).....	10
Resim 2: PCR Testi Numune Alma İşlemi (Euronews, 2022)	11
Resim 3: Covid-19 Tedbirleri ile İlgili Afişler (Sağlık Bakanlığı, 2022).....	12
Resim 4: Örnek Bir Nesne Tespiti (Géron, 2019)	13
Resim 5: Veri Setinden Maskeli ve Maskesiz Yüz Örnekleri	14

SİMGELER VE KISALTMALAR LİSTESİ

CNN	Convolutional Neural Network
DSÖ	Dünya Sağlık Örgütü
ReLU	Doğrultulmuş Doğrusal Aktivasyon Fonksiyonu
f	Aktivasyon fonksiyonu
TP/DP	Doğru Pozitif
TN/DN	Doğru Negatif
FP/YP	Yanlış Pozitif
FN/YN	Yanlış Negatif
PCR	Polimeraz Zincir Reaksiyonu
tf	tensorflow
NAS	Neural Architecture Search
FLOPS	Saniyede kayan nokta işlemlerinin

1. GİRİŞ

Salgın Hastalık aynı hastalığı taşıyan ve olağan dışı yüksek enfeksiyon oranı ile zaman ve mekana bağlı olmadan yayılan hastalıklar için kullanılan ifadedir (Tütüncü & Esen, 2021). Bu tanımın yazılması için günümüzde olduğu gibi geçmişte de bu şekilde hastalıkların yaşanmış olması gerekmektedir. Geçmişte de tüm dünyayı etkisi altına almış veya çeşitli bölgeleri kapsayan salgın hastalıkların yaşandığı bilinmektedir. Ülkemizde kolera, veba, verem, cüzzam gibi hastalıklar insanların yaşamlarını fazlasıyla etkilediği bilinmektedir (Cerit, 2020). Ülkemizin gerek jeopolitik konumu gerek doğal güzellik ve zenginlikleri düşünüldüğünde, salgınların farklı sebepler sonucunda ortaya çıkması ve yayılması kaçınılmazdır. Farklı sebeplerden kaynaklı meydana gelen savaşlar, ticari faaliyetler ve göçlerin yaşanması salgın hastalıkların en büyük sebebi haline gelmiş ve milyonlarca insanın ölümüyle sonuçlanmıştır (Özer, 2020).

Dünya geneli üzerinde son yıllarda yeni bir salgın hastalık Covid-19 ile karşı karşıya kalınmış bulunmaktadır. Aralık 2019 tarihinde ilk çıkışı Çin'in Hubei Eyaleti Wuhan Kentinden tüm dünyaya yayılmaya başlamış ve ülkemizde de 11 Mart 2020 yılında ilk vaka görülmesiyle başlamıştır. Covid-19 salgını solunum yollarına zarar veren bir hastalık olduğu bilinmekte olup, zamanla birçok salgından daha tehlikeli hale gelmiştir (Güngör vd., 2021). Tüm dünyada hızlı bir şekilde yayılarak ölümcül hale gelmesindeki en önemli etken günümüz teknolojilerinin ilerlemesinden kaynaklı olarak insanlar arası etkileşimin farklı yollarla artması olarak görülebilir (Aslan, 2021). Farklı ulaşım ve iletişim kanallarının gelişmesi salgının seyrini zorlaştırır da bu dönemde teknolojiye farklı alanlarda olumlu yönde faydalanılmıştır. Özellikle sağlık hizmetlerinin planlanmasında ve salgını kontrol altına alma gibi konularda teknolojik bir değişim yaşanmıştır (Tütüncü & Esen, 2021).

Covid-19 öksürme, hapşırma, esneme ve kişilerin birbirleriyle teması sonucu bulaşma oranı artmaktadır (Akar, 2022). Bundan dolayı hastalığın; yayılımının durdurulabilmesi için birçok önlem alınması gerekmektedir. (Cerit, 2020).

Karantinanın ilk günlerinden beri üzerinde sıklıkla durulan temizlik, maske ve mesafe tedbirleri bulaştan korunmak için sıkı şekilde bunlara uyulmalıdır (DSÖ, 2022). Bulaşma sürecinin genellikle öksürük vasıtasıyla solunum, el veya mukozal temasla bulaştığı düşünüldüğünde bu tedbirlerin gerekliliği fazlasıyla dikkat edilmelidir (Güngör vd., 2021). Hastayla veya hastanın dokunmuş olabileceği yüzeylere temas sonrası el, yüz temizliği önem

arz etmektedir. Ayrıca; havada bulunabilecek virüs damlacıklarına ve insanlarla iletişimde olası virüs bulaşmasına karşı maske kullanımı önemlidir. Bu kurallar çeşitli araştırmalar sonucunda çıkmış olup Dünya Sağlık Örgütü (DSÖ) tarafından salgının ilk dönemlerinden başlayarak uyulması gerektiği konusunda tüm dünyaya uyarılarda bulunulmuştur. Tüm uyarılara rağmen belirli bir süre sonra bu tedbirlere uyumun azaldığı ve bunun sonucunda bulaşın artışa geçtiği görülmüştür. Yaşanan bu gelişmeler kuralların denetlenmesi konusunda teknolojinin devreye girmesini kaçınılmaz hale getirmiştir (Jasim, 2022).

Son yıllarda öne çıkan yapay zekâ, derin öğrenme, nesne tanıma, görüntü işleme gibi kavramlar sağlık, güvenlik, ticaret, ulaşım, iletişim gibi birçok alanda ciddi adımlar atılmasını sağlayarak hayatı birçok alanda kolaylaştırmıştır. Derin öğrenme görüntü işleme (Güngör vd.,2021), konuşma tanıma (Kutucu,2020), e-ticaret (Santur,2020), pazarlama (Özer Çizer, 2022), robot öğrenimi gibi birçok alanda kullanıldığı gözlemlenmektedir (Cerit, 2020). Covid-19'un tanısı, tespiti (Özdemir & Pala, 2020; Şener Cömert &Kıral, 2020), salgınla ilgili verilerin analizi (Karcıoğlu, 2020), salgında alınan tedbirlerin tespit ve kontrolü (Erdem, 2020; Aydemir& Arslan, 2021) gibi konularda derin öğrenmeden faydalanılmıştır (Loey vd., 2021). Enfeksiyon oranlarının anlaşılması, hasta bireylerin izlenmesi ve ileri düzey hastalar için tıbbi x-ray göğüs röntgenlerinden Covid-19 tespiti gibi birçok çalışma yaygın araştırma konusu olmuştur (Bozkurt, 2021; Özbay & Altunbey Özbay, 2021). Salgın döneminin en önemli tedbiri haline gelen maske konusunda da kalabalık alanlarda maske kullanımının denetimini içeren derin öğrenme kullanılarak birçok çalışma literatürde gözlemlenmektedir (Cerit, 2020; Sanjaya & Rakhmavan, 2020; Baluprithviraj vd., 2021).

Virüs bulaşının önlenmesinde %68 oranında koruyuculuğa sahip olan maske kullanımı, hava yoluyla bulaşabilen virüslerin etkinliğini bozarak hastalık bulaşını engellemektedir (Milante & Dionisio, 2020). Pandemi dönemi öncesinde Güney Kore, Çin gibi hava kirliliğinin fazla olduğu ülkelerde hava kirliliğinden korunmak için, yoğun bakım gibi hastalık çeşitliliğinin fazla olduğu birimlerde sağlık çalışanları hastaların muayenesinde, bazı ülkelerde ise insanların kimliğini gizlemesi gibi çeşitli sebeplerden dolayı maske kullanıldığı bilinmektedir (Harriat Christa vd., 2021). Ancak pandemi döneminde bulaşın seyrini azaltmak için maske kullanımı özellikle alışveriş merkezleri, ibadet yerleri, hastaneler, okullar gibi insan yoğunluğunun olduğu yerlerde zorunlu hale getirilmiştir. Bu durum gittikçe normal karşılanır olmasına rağmen bir süre sonra maske kuralları ihlal edilmeye başlanmıştır (Baluprithviraj vd., 2021). Maske kullanım ihlali sürecini izlemek ve düzenlemek ise bazı yaptırımlara rağmen gittikçe zorlaşmıştır (Sanjaya & Adi Rakhmawan, 2020). İşte bu süreçte derin

öğrenmenin ilgi alanı olan nesne tanıma konusu devreye girmiştir. Çeşitli bölgelerde maske kullanımının denetiminde kamera sistemi kurularak derin öğrenme yöntemleri sayesinde maske tespiti işlemleri gerçekleştirilmiştir. Çin gibi bazı ülkelerde ise hem maske hem mesafe konusunda drone kullanarak maske- mesafe tespit işlemleri gerçekleştirmişlerdir (Snyder & Husari, 2021; europolitika.com, 2020).

Bu dönemde halka açık yerlerde maske kullanımının tespiti amacıyla derin öğrenme modelleriyle eğitilmiş otonom sistemler (Akar, 2022) geliştirilmiştir. Ayrıca öğrencilerin güvenliğini sağlamak için yine farklı derin öğrenme modelleri kullanılan gerçek zamanlı öğrenci takip sistemi (Cerit, 2020) tasarlanmıştır. Farklı sistemlere entegre edilerek kullanılabilecek yüksek doğruluk oranlarına sahip modellerle eğitilen maske tespiti çalışmaları gerçekleştirilmiştir (Aydemir & Arslan, 2021).

1.1. Araştırmanın Amacı

İlk olarak 2019 Aralık'ta Çin'de görüldüğü açıklanan ve Ocak 2020 itibariyle hızla tüm dünyaya yayılan ve pandemi haline gelen Covid-19 virüsünün, öksürük, ateş, solunum yetersizliği, koku kaybı gibi belirtiler gösteren ve solunum yoluyla bulaşan bir virüs olduğu bilinmektedir (Akar, 2022). Dünya Sağlık Örgütü (2022) tarafından bulaşma yolları, belirtileri, yayılma hızı tanımlanan virüse karşı maske, mesafe ve hijyen kurallarının önemli olduğu bilinmektedir. Özellikle maske kullanımı konusunda tedbirlerin kontrolü için kullanılan ve önerilen birçok sistem olduğu ve derin öğrenme, makine öğrenmesi gibi konuların ön plana geldiği çalışmalar literatürde gözlemlenmektedir (Bozkurt, 2021; Erdem, 2020; Aydemir& Arslan, 2021). Bu çalışmalar maskeyi farklı doğruluk oranlarında tespit edebilmektedirler. Maske tespitinde doğruluk oranı ne kadar yüksekse kullanılabilir sistemlere entegre etmek ve denetlemenin güvenilirliği o kadar yüksek olmaktadır. Bizim de bu çalışmada amacımız;

-Maske tespiti çalışmasında “Covid-19 Facemask Detection” veri setini kullanarak maske takılıp takılmadığını görüntü işleme, tensorflow ve Keras'tan faydalananarak tespit etmek,

-Derin öğrenme modellerinden olan EfficientNetV2M, NasNetMobile, InceptionV3, DenseNet121 ve VGG19'u maske tespitinde kullanmak ve doğru maske tespitindeki başarılarını karşılaştırarak en iyi maske tespit modelini bulmaktır.

1.2. Araştırmanın Kapsamı

Çalışmanın kapsamında belirtmiş olduğumuz amaçları gerçekleştirmek için Kaggle sitesinde bulunan “Covid-19 facemask detection” veri setini kullanarak, derin öğrenme modelleriyle eğitim gerçekleştirilmiştir. Eğitim için kullanılan veri seti daha önce düzenlendikten sonra kullanıma açılan bir veri setidir. Kullanılan modellerle maske var-maske yok şeklinde sınıflandırma gerçekleştirilerek modellerin ne kadar doğru şekilde bu ayrımı yapabildiği karşılaştırılmıştır.

1.3. Araştırmanın Önemi

2020 yılının ilk yarısında tüm dünya ülkeleri için bir gerçek haline gelen Covid-19 virüsünden korunabilmek, yayılım hızını azaltmak için DSÖ tarafından bir takım uyulması gereken tedbirler yayınlandı: maske, mesafe, hijyen. Bu tedbirlerden maske kullanımının etkililiği bilinmekle birlikte alışveriş merkezleri, konserler, sinema, tiyatro, hastane, okul gibi kalabalık ortamlarda maske kullanımı zorunlu hale getirilmiş ve bu durum bulaş açısından büyük öneme sahiptir. Ancak bu gibi ortamlarda insanların çoğu yasağa uymamakta ve bunun da denetimi çok zor olmaktadır. Bu şekilde insanlar tarafından gerçekleştirilmesi zor olan işlerde son zamanda derin öğrenme yöntemleriyle hazırlanan sistemlerin faydası görülmektedir. Hazırlanan bu sistemlerin yüksek güvenlikte çalışması gerekmektedir ki doğru şekilde tespit işlemleri gerçekleştirilebilsin. Literatür tarandığında bu konuda birçok çalışma yapıldığının (Akar, 2020; Jasim, 2022) görülmesinin yanı sıra, InceptionV3, VGG19, DenseNet121 ve daha önce kullanılmamış EfficientNetV2M ve NasNetMobile derin öğrenme modellerinin yüksek doğrulukla maske tespiti yapabilmesi ve alana yeni katkılar sağlaması açısından çalışmamız önemlidir.

2. LİTERATÜR TARAMASI

Tüm dünyayı etkisi altına alan Covid-19 virüsü ilk ortaya çıkmasıyla birlikte Covid-19 ile ilgili farklı alanlarda çalışmalar yapılmaya başlanmıştır. Hastalık teşhisi, bulaşın ilerlemesiyle ilgili çalışmalar, alınması gereken tedbirlerle ilgili ilgili de yapay zeka, derin öğrenme gibi teknolojilerin yardımıyla birçok çalışma gerçekleştirilmiştir (Özdemir & Pala, 2020; Bozkurt,2021).

İnsansız hava aracı kullanılarak elde edilen video görüntülerinden insanların maske takıp takmadığını kontrol ettiği çalışmada Akar (2022), bu kontrolü derin öğrenme tabanlı yöntemler ile gerçekleştirmiştir. İki farklı insansız hava aracıyla hem kapalı hem açık yerlerde gerçek zamanlı maske denetiminde başarılı olan derin öğrenme yöntemlerinden YoloV4, VGG16, VGG19, ResNet101, ResNet152 ve MobileNetV1 uygulamış ve gerçek zamanlı uygulamalara en uygun sonuçların YoloV4 modeli ile elde etmiştir (Akar, 2022).

Jasim (2022) tarafından yapılan çalışmada, güvenlik kamerası aracılığıyla maskenin takılıp-takılmadığını tespit edebilmek amacıyla derin öğrenme yöntemlerinden SSD, MobilNetV2 tercih edilmiştir. Deneysel değerlendirmelerde en iyi başarı sonucunun MobilNetV2 ile %99,72 doğruluk ve %100 f1 skoru elde edilerek uygulamanın yüksek güvenilirlikte çalıştığını bildirmiştir. (Jasim, 2022).

Gerçek zamanlı olarak hem öğrenci takibi yapan hem de maske tespiti gerçekleştirilen çalışmada Cerit (2020), okula giden öğrenciler için bir takip sistemi geliştirmiştir. RFID sistemin kullanıldığı bu çalışmada maske takılıp takılmadığının kontrolünde SSD mimarisi ile çalışılmıştır. Deneysel değerlendirmelerin sonucunda SSD modeliyle maske tespitinde %91,9, yüz tespitinde ise %89,6 başarı elde edildiğini bildirmiştir. (Cerit, 2020).

Maske takan insanların tespitinde hibrit makine öğrenmesi yöntemlerini kullanarak iki aşamadan oluşan yeni bir yaklaşım önerdikleri çalışmalarında Wang vd. (2021), yöntemin ilk kısmını maske bölgesinin tespiti için Faster- RCNN ve InceptionV2 modellerini kullanmıştır. İkinci kısımda ise gerçek yüz maskelerini doğrulanması için Faster-RCNN-ResNet50, Faster-RCNN-InceptionV2, SSD-InceptionV2, SSD-InceptionV1, PaddlePaddle ve önerilen modeller kullanılmıştır. Önerdikleri derin öğrenme yaklaşımıyla basit sahnelerde %97,32'lik bir doğruluk elde ederken, karmaşık sahneler için doğruluğun %91,13 olduğu, doğru maske %99,87'lik, yanlış maske_çene %99,93'lük ve yanlış maske_ağız_çene %97,47'lik doğruluk yüzdeleriyle tespit edildiği görülmüştür (Wang vd., 2021).

Sanjaya & Adi Rakhmawan (2020), Endonezya’da bulunan 25 şehirden farklı kaynaklardan topladıkları görüntülerle çalıştıkları modelde MobileNetV2 yöntemini kullanarak makine öğrenmesi algoritması geliştirmişlerdir. Veri setinde verilerin elde edildiği şehirlerin veri mevcudiyetine göre seçildiği çalışmada yüz maskesi takan ve takmayan kişilerin %96,85 doğrulukla tespit edildiği görülmektedir (Sanjaya & Adi Rakhmawan, 2020).

Snyder & Husari (2021), insan algılaması, insan yüzü algılaması ve bir mobil robot (Thor) tarafından maske takan insan tespiti yapılabilmesi amacıyla, insan deneklerin tespitinde ResNet-50 ile Özellik Piramit Ağı (MT-CNN)’nı, deneklerin maskeli-maskesiz olarak ayrılması için ise evrimsel sinir ağı sınıflandırıcısı kullanmışlardır. Çalışma sonunda elde edilen yaklaşım ile %99,2’lik bir geri çağırma oranı ile %81,3 doğruluk oranında maske algılaması gerçekleştirilmiştir (Snyder & Husari, 2021).

Maskenin takılıp takılmadığının tespiti amacıyla gerçekleştirilen çalışmada Negi vd. (2020) özel bir CNN modeli eğitmişlerdir 15 epoch ile eğitilen modelde %100 eğitim doğruluğu ve %98,9 doğrulama doğruluğu elde edilmiştir (Negi vd., 2020).

RaspberryPi’de gerçek zamanlı bir yüz maskesi tespiti alarm sistemi geliştirmeyi amaçlayan Militante & Dionisio (2020), çalışmada tasarladıkları bir maske sınıflandırıcı ile VGG16 modelini kullanmışlardır. Çalışma sonunda tasarladıkları model ve birlikte VGG-16 modeli ile %96 doğruluk elde etmişlerdir (Militante & Dionisio, 2020).

Yine yüz maskesi takan- takmayan tespiti yapmak ve fiziksel mesafeyi kontrol etmek amacıyla Militante & Dionisio (2020) bir alarm sistemi tasarlamışlardır. Derin öğrenme teknikleri kullandıkları çalışmada yüz maskesi tespitinde bir VGG16 modeli geliştirmişlerdir. Geliştirilen model ile %97’lik bir doğruluk oranı elde edilmiştir (Militante & Dionisio, 2020).

Covid-19 ile mücadele sürecinde yüz maskesinin tespiti için yaptıkları çalışmada Loey vd. (2021), iki bileşenden oluşan bir model önermişlerdir. Modelin ilk bileşeninde ResNet-50 derin transfer modeline dayanan özellik çıkarma işlemi, ikinci bileşende ise yüz maskesi tespiti için YOLOV2 modeli kullanılmıştır. Deneysel değerlendirmeler sonunda iki bileşenden oluşan modelleriyle %81’lik ortalama kesinlik yüzdesi elde edilmiştir (Loey vd., 2021).

Loey vd. (2021), yüz maskesi tespit amacıyla yapılan bir diğer çalışmalarında, derin öğrenme ve klasik makine öğrenmesi modellerini hibrit bir şekilde kullanmışlardır. Özellik çıkarımı için ResNet-50 modeli, maske tespiti için destek vektör makinesi (SVM), karar ağaçları ve topluluk algoritmaları gibi makine öğrenimi algoritmaları kullanılmıştır. Deneysel

değerlendirmelerde SVM'de %99,64, RMFD'de %64, SMFD'de %99,49 ve LFW sınıflandırıcısında ise %100 test doğruluğu elde edilmiştir (Loey vd., 2021).

Mehedi Shamrat vd. (2021), maske algılaması gerçekleştirmesi amacıyla Max havuzlama, ortalama havuzlama ve MobilNetV2 mimarileri de dahil üç derin öğrenme yöntemi kullanmışlardır. Deneysel değerlendirmeler sonunda Max havuzlamada %96,49 eğitim doğruluğu, %98,67 doğrulama doğruluğu ve ortalama havuzlamada %95,19 eğitim doğruluğu, %96,23 doğrulama doğruluğu elde edilmiştir (Mehedi Shamrat vd., 2021).

Maske algılaması gerçekleştirmek amacıyla Saleh vd. (2021), Çok Katmalı Algılayıcı Model (MLP) kullanmışlardır. Deneysel değerlendirmeler sonunda eğitim için 6.7379 saniye ve tahmin için 0.0023 saniye zaman sonunda MLP ile %90,58 doğruluk elde edilmiştir. (Saleh vd., 2021).

Maskelerin algılanması amacıyla Harriat Christa vd. (2021), yüz algılanmasında Çok Görevli Kademeli Evrişimli Sinir Ağı (MTCNN) ve Viola Jones algoritmasını, maske tespitinde derin öğrenme yöntemlerinden MobileNetV2 kullanılmıştır. Deneysel değerlendirme sonunda MobileNetV2 ile 0.99 doğruluk ve 0.99 f1 puanı elde edilmiştir (Harriat Christa vd., 2021).

Bir insanın maske takıp takmadığını denetlemek amacıyla Baluprithviraj vd. (2021), mobil uygulama üzerinden uyarı mesajı gönderen, yapay zeka destekli kameralar ve RaspberryPi'yi kullanmışlardır. Önerilen sistemde yüz tanıma sistemi için SSD modeli, yüz maskesi tespiti için ise CNN modelini kullanılmıştır. Deneysel değerlendirmelerle yapılan çalışma sonunda gece-gündüz çalışarak insanlar yüz maskesi taktığı zaman kapıyı açan bir cihaz ve evde insanlar bulunmadığı zaman eve birilerinin girip girmediğinin haberini veren bir mobil geliştirmişlerdir. (Baluprithviraj vd., 2021).

Maske tespitinde kullanılmak üzere bir veri seti geliştirilmek amacıyla Kumar vd. (2021), 50.000'den fazla sıkı sınırlayıcı kutuya sahip 52.635 görüntüden oluşan yeni bir veri seti önermişlerdir. Elde ettikleri veri seti üzerinde YOLO algoritmasının sekiz çeşidinin kullanarak yaptıkları deneysel çalışma sonunda, en iyi performansın %71,69 mAP değeriyle YOLOV4 algoritmasıyla elde edildiği belirtilmiştir (Kumar vd., 2021).

Yüz maskesi algılama yazılım modeli geliştirmek amacıyla Zhang (2021), derin Evrişimli Sinir Ağı (DCNN) ve VGG19 ağ mimarisi kullanılmıştır. Deneysel çalışma sonunda DCNN maske algılamasında kullanılan yazılım ile %98 doğruluk elde edilirken, maske modeli performansında %98,7'lik doğruluk elde edildiği bildirilmiştir (Zhang, 2021).

Wakchaure vd. (2022), mobil cihazlar için maske tanımlama uygulaması sunmak amacıyla, Google Cloud ML API kullanarak hem algılama çerçevesi oluşturmuş hem de makine öğrenimi gerçekleştirmişlerdir. Bulut teknolojisinin çalışması incelenmesinin yanında maske takanları içeren temiz bir veri setinin ortaya konulduğu çalışmada, yüz bölgesinin algılanmasında Viola Jones algoritması ve maskeli yüz bölgesinin belirlenmesinde YOLOV3 algoritması kullanılmıştır. Deneysel değerlendirmeler sonunda önerdikleri yöntemde maskeli insan tespitinde %100, maskesiz insan tespitinde %90 doğruluk ile iyi performans elde ettiklerini bildirmişlerdir (Wakchaure vd., 2022).

Maske tespiti, pozisyonu, maske tipinin sınıflandırılması ve kimliğin tanınması amacıyla “Spartan yüz tespiti ve Yüz tanıma sistemi” önerdikleri çalışmada Song vd. (2022), özelliklerin sınıflandırılmasında CNN, AlexNet, VGG16 modellerini, yüz tanıma hattı olarak FaceNet’i kullanmışlardır. Deneysel çalışma sonunda modellerden ortalama %97 doğruluk elde edilmiş ve modeller birbiriyle birleştirilerek gerçek zamanlı videolarda kullanılabileceği belirtilmiştir (Song vd., 2022).

Goyal vd. (2022), durağan veya gerçek zamanlı tüm videolarda maske algılama modeli sunmak amacıyla DenseNet-121, MobileNetV2, VGG19, InceptionV3 ve önerdikleri bir CNN modeli kullanmışlar. Deneysel çalışma sonunda önerdikleri modelle %98 bir doğruluk elde etmişler ve önerilen modelin işlem süresi ve doğruluk değerleri bakımından DenseNet-121, MobileNetV2, VGG19 ve InceptionV3 modellerine göre daha iyi performans gösterdiğini belirtmişlerdir (Goyal vd., 2022).

Maske takmayan kişilerin belirlenmesi sürecini otomatikleştirmek amacıyla yaptıkları çalışmada Jignesh Chowdary vd. (2020), InceptionV3’te bazı değişiklikler yaparak bir transfer öğrenme modeli önermişlerdir. Deneysel çalışmalar sonunda model, eğitim sırasında %99.9, test sırasında ise %100 doğruluk elde etmişler ve yakın zamanda önerilen diğer yaklaşımlardan daha iyi performans gösterdiğini belirtmişlerdir (Jignesh Chowdary vd., 2020).

Ullah vd. (2022), yüz maskesi takmayan insanları tespit etmek ve yüz maskesi kullanırken kişileri tanıyabilen bir sistem geliştirmek amacıyla, büyük ölçekli ve çeşitli birleşik maske algılama ve maskeli yüz tanıma veri seti geliştirmişler ve yeni bir DeepMasknet çerçevesi önermişlerdir. Deneysel çalışmalar sonunda yüz maskesi tespitinde %100, maskeli yüz tanımda %93.33 doğruluk elde etmişler ve modelin çağdaş tekniklere göre üstün olduğunu belirtmişlerdir (Ullah vd., 2022).


Literatürde yer alan maske tespitiyle ilgili çalışmalardan da anlaşılaçağı üzere birçok farklı derin öğrenme modelleri kullanılmıştır (Güngör vd., 2021; Sanjaya & Rakhmawan, 2021). Ancak ya kullanılan derin öğrenme modellerinin yapısı değıştirilerek kullanılmış (Zhang, 2021; Bozkurt, 2021) ya da bazı modeller hiç kullanılmamıştır. Bu çalışma da literatürdeki bu boşluğı doldurarak InceptionV3, VGG19, DenseNet121, EfficientNetV2M ve NasNetMobile derin öğrenme modellerini maske tespitinde kullanarak bu konudaki başarılarının karşılaştırmasını gerçekleştirmektedir.



3. KURAMSAL TEMELLER

3.1. Covid-19 Salgını

Covid-19, yüzeyleri çıkıntılı büyük, polimorfik küre şeklinde olan parçacıklar olup yapısı itibariyle SARS-COV-2 ailesinden bir virüs olduğu ifade edilmektedir (Resim 1). Tam genetik dizilimi açıklanan bu virüsü yarasalardan bulaşmış olabileceği düşünülmüştür. (Cerit, 2020). Yeni koronavirüs olarak bilinen Covid-19 hastalığının, Çin Halk Cumhuriyeti'nin yabani hayvanları satan Pazar bulunan Wuhan kentinde ilk olarak Aralık 2019'da ortaya çıktığı bilinmektedir ve vahşi hayvan tüketen kişi veya kişilerden yayıldığı düşünülmektedir (Akar, 2022). İnsandan insana bulaştığı kanıtlanan bu virüs Çin'den sonra tüm dünyaya yayılmış ve Ocak 2020 itibariyle tüm dünyayı etkisine almıştır. DSÖ'nün yayınladığı rapora göre Aralık 2022 itibariyle 645.100.674 kişi bu hastalığa yakalanırken toplam 6.633.463 kişinin ölümüne sebep olduğu görülmektedir (DSÖ, 2022). Bu da virüsün ne kadar büyük bir pandemi haline gelerek kayıplar yaşattığını açıkça göstermektedir.



Resim 1: Corana Virüs Yapısı (DSÖ, 2022)

Virüsün sebep olduğu Covid-19 hastalığının belirtileri kuru öksürük, ateş, yorgunluk, baş ve boğaz ağrısı, tat ve koku kaybı, ishal şeklinde görülebilmektedir. Hastalık ilerlediğinde ise solunum güçlüğü, nefes darlığı, göğüste ağrı, konuşmada ve harekette kayıplar da görülmektedir (Güngör vd., 2021). Bu belirtilerden birkaç tanesini taşıyan bir kişinin en yakın sağlık kuruluşuna başvurması gerekmektedir. Ülkemiz şartlarında bulaşın ilk zamanlarında hastalığı taşıdıklarını düşünen kişiler için hastalığa özel ALO 184 hattı tanımlanmış olup insanlar bu hattı arayarak da sağlık ekipleri aracılığıyla bir sağlık kuruluşuna ulaşabilmektedir (Cerit, 2020). Sağlık birimine başvuran kişilerde hastalığın varlığının tespiti için Polimeraz Zincir Reaksiyonu (PCR) test kitleri kullanılmaktadır. Bu testler hastalığın ilk safhalarında olunmasına rağmen burun ve boğaz yolundan bir pamuklu çubukla örnek alınarak

gerçekleştirilmektedir (Resim 2). Testin başlangıç için laboratuvar ekipmanları açısından maliyetli olması, sarf malzemelerine fazla ihtiyaç duyulması, deneyimli elemanlar gerekmesinin yanında, hatalı sonuç ihtimali de dezavantajlarından (Akar, 2022). Hem hatalı sonuç ihtimaline karşı hem de hastanın ileri düzey belirtiler göstermesi durumunda ise göğüs tomografisi çekilerek de hastalığın varlığı kesinleşebilmektedir (Kansu, 2020).



Resim 2: PCR Testi Numune Alma İşlemi (Euronews, 2022)

3.1.1. Bulaşma Yolları ve Alınan Önlemler

Covid-19 genellikle hasta olan kişiden diğer kişilere hapsirme, öksürme, sarılma, esneme gibi yollarla ortama yayılan damlacıkları solunması ile bulaşan bir hastalıktır (Jasim, 2022). Ayrıca hasta bireylerin bu solunum damlacıkları ile kirlenmiş olan yerlere diğer insanların dokunduktan sonra elleri yıkanmadan yüz, göz, ağız, burun gibi uzuvlara dokunmaları ile de bulaş gerçekleşebilmektedir (Sağlık Bakanlığı, 2022).

İnsanların temasını en aza indirmek için ilk zamanlar dünya genelinde birçok ülke sınırlarını kapatmak, yurtiçinde veya yurt dışına olan uçuşların iptali, yüz yüze yapılan eğitimlerin iptali, sokağa çıkma yasakları gibi birçok sert tedbirler alınmıştır. Ancak bu tedbirlerin yetmediği ve bulaşın giderek arttığı görülmüştür. Uzmanların aşının en etkili yöntem olduğu ifade etmelerine rağmen, tüm dünyada yapılacak aşılanmanın dört yıldan fazla süreceği bilindiğinden virüse karşı en etkili yöntemlerin maske, mesafe ve hijyen olduğu görülmektedir (Aydemir & Arslan, 2021). Ülkemiz ve tüm dünyada bu yöntemlerin uygulanması için hastalığın ilk çıktığı günden itibaren çeşitli yollarla teşvik edilmeye çalışıldığı bilinmektedir. Bu konuda Resim 3’ te yer alan afişler gibi daha birçok afiş ve broşür ile sosyal medya üzerinden yapılan uyarılar yer almaktadır.



Resim 3: Covid-19 Tedbirleri ile İlgili Afişler (Sağlık Bakanlığı, 2022)

Tüm solunum yolları hastalıkları için de geçerli olan bu tedbirlerin detayları şu şekilde ele alınabilir (Sağlık Bakanlığı, 2022):

- Ellerin yıkanması en az 20 sn. olacak şekilde sabun ve su ile yapılmalı, bunların bulunmadığı yerlerde alkol içerikli el dezenfektanları kullanılmalı. Elleri yıkamadan her hangi bir uzvumuzla temas ettirilmemeli.
- Hasta olan insanlara yaklaşılmamalı, bazı hasta kişiler hastalık belirtisi göstermeyebildiğinden insanlarla mesafe en az 1 m olacak şekilde korunmalı ve insanlarla temas ettikten sonra veya insan yoğunluğunun fazla olduğu yerlerde bulunulduğunda eller sık sık temizlenmeli,
- İnsan yoğunluğunun fazla olduğu yerlerde bulunulacağına özellikle sağlık kuruluşlarında maske kullanımına önem verilmeli,
- Öksürme, hapsırma esnasında burnun ve ağzın mendille kapatılmasına dikkat edilmeli,
- Seyahatlerde de tüm tedbirlere dikkat edilmeli ve sonrasında 14 gün içinde herhangi bir solunum yoluyla ilgili belirti olursa hemen bir sağlık kuruluşuna başvurulmalıdır.


Bilinen tedbirler uygulansa da hastalığın tam olarak önüne geçilemediği, tam bir aşılamayla hastalığın önüne geçilebileceği düşünülmektedir. Bazı ülkeler tarafından %90' a kadar etkili aşılar üretilmiştir (Alqadiri, 2022). Kasım 2021 itibariyle AstraZeneca, Biontech,

Sinopharm, Sinovac, COVAXIN gibi aşıların güvenlik ve etkililik açısından gerekli şartları sağladığı DSÖ tarafından değerlendirilmiştir (Akar, 2022).

3.2. Nesne Tespiti

Farklı teknolojilerin gelişmeleri sonucunda ortaya çıkan bilgisayarla görme, görsel görüntülerin algılanması gibi alanlar son zamanda sıklıkla ilgi görmeye başladı. İş ortamlarında veya kişisel amaçlı olarak kullanımı gittikçe artan nesne tespiti de günlük hayatımızda çeşitli ortamlarda kullanılması bir zorunluluk haline gelmeye başladı. Tıbbi görüntüleme, tarımsal işlemlerde, görüntü alınmasında, güvenlik ve istihbarat ile ilgili konularda sıklıkla kullanılmaya başlandığı görülmektedir (Alkhder, 2021).

Yalnızca bir görüntüye ait birden fazla ögenin algılanmasının ardından etiketlenmesi işlemine nesne tespiti denilmektedir (Alqadiri, 2022). Ayrıca bir bilgisayarın görsel olan görüntüleri okuması ve o görüntülerde bulunan nesnelerin algılanması ve tanımlanması yeteneği olarak da ifade edilebilir (Alkhder, 2021). Nesne tespitindeki amaç görüntülerin içinde bulunması gereken bir nesnenin var olduğunu sayarak, bu nesnelere ait konumların ve sınıfların tespit edilebilmesi ve bu işlemleri sağlayan sistemin oluşturulmasıdır. Bu işlemleri Resim 4'te görüldüğü gibi hayali dikdörtgen sınırlayıcıların görüntüyü taramasıyla gerçekleştirmektedir.



Resim 4: Örnek Bir Nesne Tespiti (Géron, 2019)


Nesne tespit işlemi istenilen nesnenin bulunmasıyla ilgilenen nesne yerleştirmesi ve ilgili nesneyi sınıflandırma görevini gerçekleştiren nesne sınıflandırması şeklinde iki bölümde çalışmasını sürdürür. Birden fazla nesnenin tanınması ve tanımlanmasından sorumlu olan nesne tespiti nesnenin bulunduğu yeri ve hangi sınıfa ait olduğunu da belirler (Alqadiri, 2022).

4. MATERİYAL VE YÖNTEM

4.1. Veri Setinin Oluşturulması

Bu çalışmada üzerinde çeşitli ön işlemler gerçekleştirilerek hazırlanmış ve test edilerek paylaşılmış hazır veri seti kullanılmıştır. Çeşitli konularda hazır birçok veri seti bulunan Kaggle sitesinde yüz maskesi denetimiyle ilgili yayınlanan veri setleri incelenmiş ve çalışmamıza uygun olanı seçilmiştir.

Çalışmamızda Kaggle sitesinde “COVID Face Mask Detection Dataset” ismiyle yayınlanan test, train ve validation klasörlerinin içinde maskeli ve maskesiz insan yüzleri resimleri bulunan veri seti kullanılmıştır. Veri setinde eğitim için 300 maskeli, 300 maskesiz, test için 153 maskeli, 153 maskesiz olmak üzere toplamda 906 maskeli ve maskesiz insan yüzü resimleri yer almaktadır. Veri setimizde yer alan görüntülerden örnekler Resim 5’te yer almaktadır.




Resim 5: Veri Setinden Maskeli ve Maskesiz Yüz Örnekleri

4.2. Derin Öğrenme

Yapay zeka ve makine öğreniminin alt dalı olarak bilinen derin öğrenme aslında iki teknolojinin birleşimi ve daha gelişmiş bir yapıya sahiptir. Ayrıca makine öğrenimine göre esneklik ve doğru modeller oluşturma konusunda önde olduğu bilinmektedir (Milante & Dionisio, 2020). Derin öğrenme yöntemleri karmaşık geniş veri kümelerinden anlamlı bilgiler ortaya çıkarılması için yaygın olarak kullanılmaktadır (Zhang, 2021).


Derin öğrenme, beyin nöronlarının yapısından ilham alınarak geliştirilmiştir (Milante & Dionisio, 2020). Makinelerin bir insan gibi işler yapabilmesi, kendilerinin öğrenmesi için teoriler ve yöntemler bulması ve bazı değişkenleri kullanarak geniş veri kümelerinden özellik

çıkarımı yolunu keşfetmeyi amaçlamaktadır (Jasim, 2022). Özellik çıkarımının yanında dönüştürme işleminin de yapılması için birden fazla doğrusal olmayan katmanlı bir yapıdan meydana gelmektedir. Yapısında bulunan her katman kendinden bir önceki katmanın çıktısını girdi olarak kullanmak suretiyle çalışır. Bu şekilde işlenmemiş olan veri kümesinden özellikler otomatik olarak çıkarılmış olur (Kaya & Önal, 2021). Derin öğrenmenin bu katmanlı yapısı Şekil 1’de yer almaktadır.



Şekil 1: Derin Öğrenmenin Yapısı (Isaksson, 2018)

Özellikle tıp ve tarım alanında hastalıkların tanımlanması, tespiti, meyve hastalıklarının tespiti gibi birçok alanda yaygın olarak derin öğrenme mimarileri kullanılmaktadır (Milante & Dionisio, 2020). Tüm bu alanlardaki işlemleri farklı özellikleri ve yapıları kullanarak gerçekleştiren derin öğrenme mimarileri denetimli ve denetimsiz olarak iki alana ayrılmaktadır (Şekil 2). Bu çalışmada denetimli derin öğrenme türlerinden olan CNN mimarisine sahip modeller kullanılmıştır.




Şekil 2: Derin Öğrenme Türleri (Kaya & Önal, 2021)

4.3. CNN (Convolutional Neural Network-Evrişimli Sinir Ağları)

LeCun, Bottou, Bengio ve Haffner'in 1998 yılında yaptıkları çalışmada hem evrişimli sinir ağlarının hem de evrişimli sinir ağlarının ilki olarak görülen LeNet modelini geliştirmişlerdir (Simonyon & Zisserman, 2015). İlk çıktığında LeNet ile posta kodlarının ve rakamların tanımlanması amacıyla görevleri gerçekleştirirken şimdi geldiği noktaya bakıldığında, milyarlarca parametrenin hesaplanıp verilerden anlam çıkararak sorunlara çözüm bulabilen bir model haline geldiği görülmektedir (Akar, 2022). Bilgisayarla görme, görüntü tabanlı uygulamalar gibi konularda çok ileri düzeylere ulaşan evrişimsel sinir ağları, yüz tanıma, nesne tanınması, görüntü sınıflandırma, sürücüsüz araç yapımı, hastalık tespiti, maske tespiti gibi alanlarda da yüksek başarılar elde edildiği için tercih edilmektedir (Akar, 2022; Militante & Dionisio, 2020).

Bir girdi görüntüsü alarak o görüntüde bulunan farklı nesnelerin ayırt edebilen evrişimsel sinir ağları (CNN ya da ConvNet) derin öğrenmenin en başarılı modellerinden olduğu bilinmektedir (Kaya & Önal, 2021). Aynı yapay sinir ağları mimarisinde olduğu gibi derin öğrenmenin mimarilerinden CNN'in girdi, birden çok gizli ve bir de çıktı katmanının yer aldığı çok katmanlı bir yapıya sahip olduğu bilinmektedir. Bir evrişimli sinir ağı incelendiğinde genel yapısının temel olarak bir evrişim katmanı, bir havuzlama katmanı ve bir de tam bağlı katman olmak üzere üç ana katmandan oluştuğu görülmektedir. İlk iki katmada girdi olarak alınan görüntüden özellik çıkarımı gerçekleştirilir ve tam bağlı katman, çıkan özellikleri çıktı katmanına eşler (Özbay & Altunbey Özbay, 2020). Bu katmanların yapısı Şekil 3'te yer almaktadır. Bu katmanların yapısı Şekil 3'te yer almaktadır. Tam bağlantılı katman, ilk katmanında yer alan nöronlar, kendinden sonraki katmana ait diğer nöronlara bağlanarak sınıflandırma işlemine hazırlık gerçekleştirmektedir (Harriat Christa vd., 2021). CNN'in derin öğrenme mimarisinden görüntünün kendisini girdi olarak alması açısından ayrılmaktadır ve görüntünün tümü yerine görüntü içinde bulunduğu etkili özelliklerle çalışır (Mehedi Shamrat vd., 2021).




Şekil 3: Evrişimli Sinir Ağı Genel Mimarisi (Akar, 2022)

4.3.1. Evrişim Katmanı

CNN mimarisinin temel yapısını oluşturan ve hesaplama işlemlerinin birçoğunun gerçekleştiği bu katmanda, ağda girdi olarak verilen görüntü üzerinde filtre veya çekirdek adında bir özellik algılayıcısı olarak görev yapan bir filtre ve özellik haritası bileşenleri yer almaktadır (Akar, 2022). Bu bileşenlerden CNN'in yapı taşı ve girdi olarak verilen görüntüden daha küçük olan filtreler, giriş görüntüsündeki özelliklerin varlığının özetlendiği özellik haritalarının oluşturulmasında kullanılır (Jasim, 2022).

Girdi görüntüsünü birleştirip sonucu bir sonraki katmana aktaran bu katman, belirli bir 2x2, 3x3 veya 5x5 gibi farklı boyutlarda olan filtreyi, tüm görüntü üzerinde dolaştıran bir dönüşüm işlemini gerçekleştirmektedir (Kaya & Önal, 2021). Bu işlemlerden de anlaşılacağı üzere evrişim katmanının temel amacı girdi olarak verilen görüntüden anlamlı verileri elde edileceği öznitelik haritasının elde edilmesidir (Özbay & Altunbey Özbay, 2020).

Şekil 4'te girdi olan görüntüye ait 5x5 boyutundaki matrise, 3x3 boyuta sahip evrişim filtresi uygulanması ve oluşan çıktının görüntüsü yer almaktadır. Filtrenin girdi görüntüsü üzerinde aşağı-yukarı, sağa-sola kaydırılması ile gerçekleşen bu işlem tüm görüntünün üzerine uygulanmaktadır (Türkoğlu vd., 2020).



Şekil 4: Görüntünün Evrişimi ve Çıktının Elde Edilmesi


4.3.2. ReLU (Düzeltilmiş Doğrusal Birim) Katmanı

Aktivasyon fonksiyonu, derin öğrenme modellerinde giriş olarak verilen verilere göre çıkış üretebilmek amacıyla kullanılmaktadır. Bu amaç için literatürde yaygın olarak doğrusal olmayan aktivasyon fonksiyonu ReLU kullanılmaktadır (Alqadiri, 2022). Öğrenmenin gerçekleşmesinde ihtiyaç duyulan, doğrusallığın gerekli olmadığı problemlerde de iyi bir performans gösteren bir aktivasyon fonksiyonu olan ReLU (Maas vd., 2013) matematiksel olarak Eşitlik 1'deki gibi tanımlanmaktadır (Harriat Christa vd., 2021).

$$f(x) = \max(0, x) \quad (1)$$

4.3.3. Havuzlama Katmanı

Evrişim katmanında olduğu gibi belirli filtreler tanımlanan bu katmanın kullanımı zorunlu olmadığından bazı modeller tarafından kullanılmamaktadır. Hesaplamaların hızlı şekilde gerçekleştirildiği havuzlama katmanında bir önceki katmandan gelen özellik haritaları gruptandırılmış yeni birer özellik haritalarının oluşturulması için işlenir (Jasim, 2022). Böylelikle bu katmanın temel amacı olan herhangi bir özellik kaybolmadan dizinin boyutunun bir sonraki katman için azaltılma işlemi gerçekleştirilmektedir. Ancak bu işlemler sonunda boyutta gerçekleştirilen bu azaltma bilgi kaybına neden olabilmektedir. Burada gerçekleşen bilgi kaybı kötü bir şeymiş gibi görünse de bu işlem diğer katmanlar için hesaplama yükünü azaltırken sistemde aşırı öğrenmenin gerçekleşmesini engellediğinden aslında bir avantaja dönüşmektedir (Kaya & Önal, 2021).



Şekil 5: Maksimum ve Ortalama Havuzlama Katmanı (Doğan, 2020)

Havuzlama katmanının Şekil 5'te yapısının yer aldığı iki çeşidi bulunmaktadır: Maksimum havuzlama ve Ortalama havuzlama


Maksimum havuzlama: Genelde daha iyi performans gösterdiğinden dolayı geliştiriciler

tarafından yığın olarak kullanılmaktadır. Bu katmanda filtrelerle tarama işlemi yapılırken çıktı işlemine gönderilecek değerler görüntüde yer alan piksellerin en yüksek değerine göre seçilmektedir (Akar, 2022).

Ortalama havuzlama: Filtrelerin gerçekleştirdiği tarama işlemi sırasında çıkış işlemine gönderilen değer seçili olan alanın ortalaması alınarak belirlenmekte ve bu işlem yeni dizideki tüm hücrelere uygulanmaktadır (Jasim, 2022).

4.3.4. Tam Bağlı Katman

Kendisinden önce olan katmanları birbirlerine bağlayarak sınıflandırma işlemini gerçekleştirebilmesi için değerleri birbirine bağlayarak tek boyutlu hale dönüştürmemizi sağlamaktadır (Akar, 2022). Şekil 6'da görülen düzleştirme işlemi gerçekleştirildikten sonra ağlarda kullanılan giriş verileri hazır hale gelir.



Şekil 6: Değerlerin Tam Bağlı Katmanda Kullanılması İçin Düzleştirme İşlemi (Konca, 2020)


4.4. Kullanılan Modeller

4.4.1. DenseNet121

Her katmanı diğer her katmanlara bağlayan ve katmanlar arasında yoğun bağlantıları nedeniyle DenseNet adını alan bu mimari Huang vd. (2016) tarafından önerilmiştir. DenseNet modelinin derinlikleri birbirinden farklı çeşitleri bulunmaktadır. Derinliği 121 olan çeşidi DenseNet121 olarak adlandırılmaktadır ve modelin yapı taşı evrişim katmanlarından oluşan dense bloklardır (Güngör vd., 2021).

DenseNet121 mimarisi bünyesinde 121 adet evrişim katmanından ve 1000 nöronluk tam bağlantılı katman meydana gelmektedir (Şekil 7). Ayrıca doğrusal olmamanın artırılması için

ReLU aktivasyon fonksiyonunu kullanmaktadır (Bozkurt, 2021).



Şekil 7: DenseNet121 Mimarisi (Eryılmaz & Karacan, 2021)

4.4.2. EfficientNetV2M

EfficientNet, Google Araştırma Ekibi tarafından 2019 yılında geliştirilen ve doğruluk, verimlilik gibi konularda kayda değer iyileştirmeler sağlayan bir CNN modelidir. Diğer CNN modellerinin aksine doğruluğu artırma konusunda katman sayısı, derinlik ya da çözünürlüğü ayrı ayrı değiştirmek yerine, belirlenen bir oran ile hepsine birden değişikliğe gitmektedir (Yavuz, 2020). EfficientNet saniyede kayan nokta işlemlerinin (FLOPS) kullanımıyla ölçülen verimlilik ve doğruluk optimize edilmiştir (Hoang & Jo, 2021).

EfficientNetV2, kendinden önce olan tekniklere kıyasla daha iyi parametre verimliliği ile daha hızlı eğitim sağlayan görüntü sınıflandırması gerçekleştirmektedir. Model boyutu ve eğitim hızının ortak olarak optimize edilmesinde Sinir Mimarisi Araması (Neural Architecture Search-NAS) kullanan model, parametre boyutu ve bellek erişim yükü açısından EfficientNet'teki bulunan modelin son aşamasında kullanılmamaktadır. Ayrıca 3x3 gibi küçük bir çekirdek boyu tercih ettiği ve bu tercihin de azaltılmış alıcı alanı gerektirdiğinden fazladan katman eklenmesi gerçekleştirilir (Tan & Le, 2021; Yavuz, 2020).

EfficientNetV2 model ailesi üyeleri olan EfficientNetV2-S, EfficientNetV2-M, EfficientNetV2-L modellerinin farkları ImageNet1K ve ImageNet21K veri setleriyle gerçekleştirilen eğitim şekillendirilmiştir. DeneySEL sonuçlar Tablo 1 ve Tablo 2'de yer almaktadır.


Tablo 1: ImageNet1K ile yapılan eğitim sonuçları (Tan & Le, 2021)

ImageNet1K	Top1 Acc.	Params	FLOPs
EffNetV2-S	83.9%	21.5M	8.4B
EffNetV2-M	85.2%	54.1M	24.7B
EffNetV2-L	85.7%	119.5M	56.3B

Tablo 2: ImageNet21K önceden eğitilmiş ve ince ayarı yapılmış modeller (Tan & Le, 2021)

ImageNet21K	Finetuned ImageNet1K
EffNetV2-S	top1=84.9%
EffNetV2-M	top1=86.2%
EffNetV2-L	top1=86.9%

EfficientNetV2 ailesinin diğer üyelerinin de Şekil 8’de görüldüğü gibi ImageNet ile gerçekleştirilen eğitim sonuçlarına göre, farklı eğitim süreleri ile farklı doğruluk oranları elde edilmiştir. EfficientV2-M için tablolar ve şekil birlikte ele alındığında modelin kısa sürede yüksek doğruluk elde ettiği görülmektedir.




Şekil 8: EfficientNetV2 Modellerinin Eğitim Verimlilikleri (Tan & Le, 2021)

4.4.3. NasNetMobile

ImageNet veri tabanı kullanılarak önceden eğitilen bu model NasNet mimarisinin mobil ortamlar için olan türevlerinden birisidir (Herdian vd., 2019). Neural Architecture Search (Nöral Mimari Arama)’ün kısaltması olan NasNet, temel hücreleri barındıran, takviye eğitimiyle iyileştirilen ayrılabilir evrişim ve ortaklama gibi basit bloklardan oluşan ve ölçeklenebilen bir CNN mimarisidir. NasNet temelli mimariler de ağlarının kapasitesine göre

bu basit blokların tekrarlanması mantığına göre oluşmaktadır (Eryılmaz & Karacan, 2021). 913 katmana sahip yapısı ve 224x224 giriş görüntü boyutu bulunmaktadır (Kaçmaz, 2020). 769 katman ve 224x224 giriş boyutuna sahip olan NasNetMobile, 5,4 milyon kapasite ve 564 milyon çarpma kapasiteye sahip 12 hücreden oluşur (Şekil 9). Bu yaklaşımda evrişimli ağıın genel konfigürasyonu el ile önceden belirlenir. Her biri aynı mimari ve farklı ağırlıklara sahip çok sayıda çoğaltılmış erişimli birimden oluşur. Herhangi bir ölçeğe ait görüntüler için basit şekilde ölçeklenebilir bir mimarinin oluşturulması için bir özellik eşlenirse, evrişimli birimin, aynı boyuta sahip özellik haritasını döndürme ve özellik haritasındaki yüksekliğin ve genişliğin iki katı olan özellik haritasının döndürülmesi şeklinde iki önemli rolü bulunmaktadır (Ba Alawi & Qasem, 2021).




Şekil 9: NasNetMobile Mimarisi (Eryılmaz & Karacan, 2021)

4.4.4. InceptionV3

ImageNet veri seti üzerinde en yüksek sınıflandırma ve en az hata oranı elde eden Inception modeli ILSVRC 2014 yarışmasında görüntü sınıflandırmasında birinci olmuş bir CNN mimarisidir. Aynı yarışmanın diğer senelerdeki galiplerine göre hata oranında önemli düşüş görülmüş ve aynı yarışmanın 2014 yılı ikincisi olan VGG modeline göre de hata oranı daha az olduğu bilinmektedir (Bozkurt, 2021).

Yüksek başarılar elde edilen bu modelde doğruluğun artırılması ve karmaşıklığın azaltılması gereken bazı yerlerin olduğu görülmüştür. Bu iyileştirmeler gerçekleştirilirken Inception modelinin farklı versiyonları çıkmış olup InceptionV3 modeli de bunlardan birisidir. Inception modelinin ilk versiyonunu temel alan bu model doğruluğun artırılmasını sağlamıştır (Ashames, 2020).




Şekil 10: InceptionV3 Mimarisi (Ashames, 2020)

48 katman derinliği olan, 1x1, 3x3, 5x5 evrişim ile birleştirilen inception modüllerinin kullanıldığı bu model VGGNet'e göre de daha verimli olduğu bilinmektedir. Şekil 10'da mimarisi yer alan InceptionV3 modelinde, 5x5 veya 7x7 boyutlarına sahip evrişimlerde iki veya üç adet 3x3 boyutunda filtre kullanılmakta ve parametre sayısının azalmasından kaynaklı olarak eğitimin hızının arttığı gözlemlenmiştir (Bozkurt, 2021). Ağın derinliğinin artmasıyla genişliğinin arttığı bilindiğinden InceptionV3'te de amaç, ağın genişliğinin ve derinliğinin en iyi seviyelere getirerek yüksek bilgi akışı sağlamak olmuştur (Szegedy vd., 2015).

4.4.5. VGG19

VGG19 modeli, Oxford Üniversitesi Görsel Geometrik Grubu tarafından önerilen VGG modelinin 19 katmanlı olan versiyonudur (Simonyan & Zisserman, 2014). Oxford Üniversitesi'nden Simonyan ve Zisserman tarafından önerilen, ImageNet'in düzenlemiş olduğu ILSVRC 2014 yarışmasında ImageNet veri setiyle eğitilen ve sınıflandırma alanında %9'luk bir hata oranı elde eden VGG19 modeli, 16 evrişim ve 3 tam bağlı katman içerir (Başaran, 2020). ImageNet veri setinin yanında çok çeşitli veri kümelerinde ve görevlerde de başarılı bir model olduğundan, günümüzün de popüler görüntü tanıma modellerindendir (Alqadiri, 2022).

Temel mimarisinde 5 adet havuzlama katmanı dahil olmak üzere 24 ana katman yanında tam bağlı katman, ReLU katmanı, dropout katmanı ve softmax katmanı ile birlikte toplamda 47 katmandan meydana gelen VGG19 mimarisi Şekil 11'de yer almaktadır. (Başaran vd., 2020). Giriş için görüntü boyutunun 224x224 piksel olduğu modelin evrişim katmanında kullanılan kaydırma penceresi boyutu 3x3'lük bir alana sahiptir ve model yaklaşık 144 milyon parametre içermektedir (Bozkurt, 2021).



Şekil 11: VGG19 Mimarisi (Simonyan & Zisserman, 2014)

4.5. Performans Metrikleri

Bir modelin performansının değerlendirilmesinde bazı performans ölçütlerinin elde edilmesi gerekmektedir. Bu ölçütlerin en popülerleri doğruluk, kesinlik, geri çağırma ve F1-skordur (Zhang, 2021).

4.5.1. Karışıklık Matrisi

Modellerin eğitiminde kullanılan algoritmaların gösterdiği performansları tablo şeklinde görsel hale getiren, makine öğrenmesi veya sınıflandırma problemleri için hata ya da karışıklık matrisi olarak adlandırılan bir algoritmadır. Karışıklık matrisi oluşturulurken veri setine ait gerçek etiketler ve algoritmanın etiketlediği verilerin bilinmesi önemlidir. Böylece bu matris üzerinden gerçek ve tespit edilen değerlerin karşılaştırılması rahatlıkla gerçekleştirilecektir (Akar, 2022).

Tablo 3: Karışıklık Matrisi

		Tespit	
		Negatif	Pozitif
Gerçek	Negatif	Doğru Negatif (TN)	Yanlış Pozitif (FP)
	Pozitif	Yanlış Negatif (FN)	Doğru Pozitif (TP)

Tablo 3'te karışıklık matrisinde yer alan ölçütlerde kullanılan değerler aşağıdaki gibi ifade edilmektedir (Güngör vd., 2021):

Doğru-pozitif (TP): Derin öğrenme modelinin pozitif olan tahminleri doğru bir şekilde

tahmin ettiği sonuçlardır.

Yanlış-Pozitif (FP): Gerçekte pozitif olan tahminlerin model tarafından yanlış tahmin edildiği sonuçlardır.

Doğru-Negatif (TN): Gerçekte negatif olan tahminlerin model tarafından doğru tahmin edildiği sonuçlardır.

Yanlış-Negatif (FN): Gerçekte negatif olan tahminlerin model tarafından yanlış tahmin edildiği sonuçlardır.

4.5.2. Doğruluk (Accuracy)

Tüm veri seti üzerinde yapılan doğru sınıflandırılmış olan verilerin sayısını ifade eder. Eğer veri setinde yer alan sınıflarda verilerin dağılımı dengeli değilse doğruluk tek başına performansın belirlenmesinde kullanılamaz .

Doğruluk hesaplaması Eşitlik 2’de yer almaktadır (Degadwala vd., 2021).

$$\text{doğruluk} = \frac{TN+TP}{TN+TP+FP+FN} \quad (2)$$

4.5.3. Kesinlik (Precision)

İyi bir sınıflandırmada kesinlik değerinin yüksek olması yani en yüksek sınırı olan 1 ya da 1’e yakın olması sınıf tahminin yapılmasında pozitif olarak bulunan değerlerden gerçekte de pozitif sınıfta olanlarının gösterdiğini ifade etmektedir. Eşitlik 3’te yer alan denklemden de anlaşılacağı üzere yanlış-pozitif değerinin 0 veya 0’a yakın olması gerekir ki kesinlik değeri en yüksek değerini alabilsin.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (3)$$

4.5.4. Geri Çağırma (Recall)

Sınıflandırıcı modelin, tüm pozitif olan örnekleri iyi tanımlanabildiğiyle ilgili bilgiyi geri çağırma (recall) verir (Zhang, 2021). Eşitlik 4’te yer alan formülüne bakıldığında kesinlik değerinde olduğu gibi 1 veya 1’e yakın olması beklenen geri çağırma değerinde de pay ve paydanın eşit olması yani yanlış- negatif sayısının 0 veya 0’a yakın olması gerektiği görülmektedir.

$$\text{Geri Çağırma} = \frac{TP}{TP+FN} \quad (4)$$

4.5.5. F1 Skor

Kesinlik ve geri çağırma değerlerinin hesaplanmasıyla elde edilen F1-skor testin doğruluğunun ölçüsünü verir (Zhang, 2021). Yine diğer ölçütlerde olduğu gibi 1 veya 1'e yakın olması başarılı bir model olduğu anlamına gelir. F1-skoru değerinin en yükseklerde olması içinse yanlış-negatif ve yanlış-pozitif değerinin 0 olması gerekmektedir (Eşitlik 5).

$$F1 - skor = 2 * \frac{kesinlik * geri \text{ çağırma}}{kesinlik + geri \text{ çağırma}} \quad (5)$$

4.6. Model Eğitiminde Kullanılan Kavramlar

4.6.1. Training

Model eğitiminde amaç, veri özellikleri ile denetimli öğrenme veya denetimsiz öğrenme arasında bulunan ilişkinin en iyi matematiksel temsilini oluşturmaktır. Eğitim sonunda elde edilen performans oluşturulan uygulamanın ve eğitim verilerinin kalitesine bağlıdır (c3.ai, 2022).

4.6.2. Learning Rate

Tahminleme sürecinden hataların olmaması için kullanılan öğrenme oranı (Learning Rate), eğitim için kullanılan model ağının yapılandırılmasında önemli bir faktördür. Modelin en az kayba ulaşarak minimum hata elde etmesi ve öğrenmenin işleminin hızlı bir şekilde gerçekleşmesini sağlamak için önemlidir. Learning Rate değerinin ne çok büyük bir değer ne de çok küçük bir değer seçilmemesi gerekmektedir. Büyük değer için, eğitim gerçekleşse de güvenilirlik düşerken, küçük değer seçimi, modeli gecikmeli fazla ayrıntılı bir eğitimle karşı karşıya getirmiş olur (Alkhder, 2021). Standart oranı 0.0001 olduğundan bizim çalışmamız için de bu şekilde kullanılmıştır.

4.6.3. Epoch

Modelin öğrenmesinin en üst seviyeye çıkarılması veya optimize edilmesi için veri kümelerinde yer alan görüntülerin birçok kez işlenmesinde gerekli olan tanımlı bir sayıdır. Eğitim sonunda modelin istenilen doğruluğa ulaşması için bu değer uygun yükseklikte seçilmesi gerekmektedir ki, yüksek bir epoch seçimi fazla öğrenmeye yol açarken, düşük bir epoch seçimi de yetersiz öğrenme gerçekleşmesine sebep olabilmektedir (Çarkacı, 2018).

4.6.4. Batches

Modelin sinir ağından veri kümesinin tümünün birden geçmesi zor olduğundan batch değeri ile veri seti daha küçük parçalara bölünerek eğitim işleminin gerçekleştirilmesi sağlanmaktadır (Alkhder, 2021). Bu tez çalışması için batch değeri 32 olarak belirlenmiştir.

4.6.5. Optimizasyon (Optimizer)

Optimizasyon belirli kısıtlamalara ve parametrelere tabi bir maliyet-kayıp fonksiyonunu maksimize etmek anlamına gelmektedir. Derin öğrenme uygulamaları için de öğrenme sürecinin aslında bir optimizasyon problemi olduğu bilinmektedir. Doğrusal olmayan bu problemlerin çözümünde en uygun değerin bulunmasında optimizasyon yöntemleri kullanılmaktadır. Performans ve hız bakımından farklılık gösteren bu algoritmalarından stochastic gradient descent, adagrad, adadelata, adam, adamax algoritmalarının yaygın olarak kullanıldığı bilinmektedir (Atcılı, 2020). Bizim çalışmamızda da iyi sonuçları hızlı bir şekilde veren ve derin öğrenme konularında son zamanlarda sıklıkla kullanılan Adam optimizasyon algoritması kullanılmıştır.

4.7. Tensorflow

Büyük ölçekli makine öğrenimi için uygun olduğu bilinen ve Google Brain ekibinin geliştirmiş olduğu Tensorflow güçlü bir sayısal bilgi işlem kitaplığıdır. Açık kaynaklı ve ücretsiz kullanıma sahip olan bu kütüphane Google Fotoğraflar, Google Arama, Google Cloud gibi birçok Google hizmetini destekler. Görüntü sınıflandırma, doğal dil işleme, öneri sistemleri gibi sayısız projelerde kullanılan Tensorflow son zamanların en çok kullanılan kitaplığıdır (Cerit, 2020; Singh vd., 2021; Géron, 2019).

Python üzerinden kullanılan bu kütüphane bir ortamda eğitilerek istenilen diğer ortamlarda da çalıştırılabilir (Géron, 2019). Bizim de çalışmamızda kullandığımız ve tensorflow tarafından kullanılan bazı komutlar; görüntü işleme işlemlerinde tf.image, veri yükleme ve ön işleme konularında tf.data, tf.io, Keras kütüphanesinin kullanımı için tf.keras şeklinde olmakla birlikte farklı özellikler için farklı komutlar da mevcuttur.

4.8. Keras

Kullanımının kolaylığı, esnek olması, güzel tasarımlarının olması sayesinde çok kullanılır hale gelen ve Tensorflow üzerinde de faaliyet gösteren Python üzerinde yazılmış olan bir derin öğrenme API'sidir (Singh vd., 2021). Her türlü sinir ağının eğitilmesine,

oluřturulmasında, deęerlendirilmesine olanak veren bu API Franois Chollet'in bir arařtırma projesinin parası olarak geliřtirilmiř ve Mart 2015 'te aık kaynaklı olarak yayınlanmıřtır (Geron, 2019).


Tensorflow kütüphanesini destekleyen Keras sayesinde resim iřleme ve metin iřleme teknikleriyle alıřmak ok daha kolay hale gelmiřtir. Keras'ın kendi sitesinde de eęitim yapılacak modellerde kullanılabilir tensorflow destekli kodlar yer almaktadır (Keras.io, 2022).



5. BULGULAR

Derin öğrenme model ve mimarilerinin veri setinde bulunan büyük boyutlu resimlerin işlenebilmesi için donanımsal olarak güçlü makinelere ihtiyaç vardır. Bu çalışmada elimizde güçlü bir makinenin bulunmaması, modellerin çalıştırılması için gerekli olan bazı kütüphanelerin kurulumunda yaşanacak hatalardan uzak durulması ve işlemlerin kendi sisteminde sunulan GPU desteği sayesinde daha pratik bir şekilde gerçekleştiriliyor olmasından dolayı Google Colab kullanılmıştır.

Bu çalışmada yüz maskesi takılıp takılmadığının tespitinin gerçekleştirilmesi için Python programlama dili kullanılarak, Google Colab üzerinde yer alan Jupyter not defterleri aracılığıyla kodların çalıştırılması gerçekleştirilmiştir (Şekil 12).




Şekil 12: Google Colab Jupyter Notebook Görünümü

Kullanılan modellerin eğitimi için gerekli görüntüler birçok veri setinin yer aldığı Kaggle'dan temin edilmiştir. Maskeli ve maskesiz insan yüzlerine ait görüntüler üzerindeki eğitim öncesi gerçekleştirilmesi gereken görüntülerin boyutlarının 224x224 boyutuna getirilmesi gibi ön işlemler, model eğitiminden önce Python kodları aracılığıyla düzenlenmiştir. Görüntüler test ve train dosyaları şeklinde hazır dosyalanmış şekilde ele alınmıştır.

Kaggle sitesindeki “COVID Face Mask Detection Dataset” isimli veri seti kullanılmıştır. Veri seti içerisinde maskeli ve maskesiz olmak üzere iki sınıflı olan çalışmamızda, eğitim için 300 adet maskeli, 300 adet maskesiz olmak üzere toplamda 600 adet görüntü ile test için 153 adet maskeli, 153 adet maskesiz toplamda 306 adet görüntü bulunmaktadır (Şekil 13).

Verilerimizin dağılımına bakıldığında ise görüntülerin yaklaşık %30'unun test için, %70'ininse eğitim için kullanıldığı görülmektedir.



Şekil 13: Klasör Halinde Veri Setinin Dağılımı

Derin öğrenme modellerimizin nesne tespitini doğru şekilde gerçekleştirebilmesi için bazı değerler kullanılmaktadır. Kullandığımız modellerle eğitimleri gerçekleştirirken kullandığımız bu parametreler Tablo 4'te yer almaktadır.

Tablo 4: Modelleri Eğitiminde Kullanılan Parametreler

Parametreler	Değerler
Initial Learn Rate	0.00001
Epochs	10
Batch Size	32


Tabloda yer alan değerler yapılan çalışma sonucu incelendiğinde epoch sayısı 10, batch size 32 ve başlangıç öğrenme oranı 0.00001 alındığında daha başarılı sonuçların ortaya çıktığı görülmüştür.

5.1. DenseNet121 Modeliyle Elde Edilen Sonuçlar

Tablo 5: DenseNet121 Modeli Ölçüm Parametre Sonuçları

Doğruluk (Accuracy) Değeri	Kayıp (Loss) Değeri	Eğitim İçin Geçen Süre
0.9869	0.0262	1 saat 21 dk 49.19 sn

Tablo 5'te görüldüğü gibi, DenseNet121 modelinde gerçekleştirilen eğitimle 1 saat 21 dakika 49.19 saniye içerisinde 0.0262 oranlık bir kayıpla %98.69 oranında doğruluk elde edilmiştir. Bu sonuç da modelimizin maskeli maskesiz tespitinde yaklaşık bir buçuk saatlik sürede gerçekleşen eğitimin sonunda başarı oranının iyi düzeyde olduğu görülmektedir. Bu değerlerin eğitim ve test verilerine göre değişiminin yer aldığı Şekil 14'ten de anlaşılacağı üzere, eğitim verilerinde test verilerine göre kaybın daha az olduğu, doğruluk değerinin ise daha fazla olduğu görülmektedir. Değerlerin eğitim boyunca artış ve azalışlarında dalgalanmalar olsa da düzenli bir şekilde gerçekleştiği görülmektedir.



Şekil 14: DenseNet121 Modeli Eğitim Grafiği

Şekil 15'te DenseNet121 modeliyle eğitim sonunda oluşan 153 maskeli, 153 maskesiz test verilerine ait karışıklık matrisi yer almaktadır. Matrise göre DenseNet121 modelinin, 153 maskesiz görüntüsünün 153'ünün maskesiz olarak sınıflandığı ve 153 maskeli görüntünün 149'unun maskeli ve 4'ünün maskesiz olarak sınıflandığı görülmektedir. Modelin maskesiz görüntüleri ayırt etmede başarılı olurken, maskeli görüntülerde az da olsa hatanın olduğu görülmektedir.



Şekil 15: DenseNet121 Modeli Karışıklık Matrisi

DenseNet121 modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerinin maskeli ve maskesiz olarak sınıflandırılmasıyla ilgili elde edilen kesinlik, geri çağırma ve f1-skor değerleri Tablo 6'da yer almaktadır.

Tablo 6: DenseNet121 Modeli Sınıflama Raporu

	Precision (Kesinlik)	Recall (Geri Çağırma)	F1-score	Support
0	0.97	1.00	0.99	153
1	1.00	0.97	0.99	153
Macro avg	0.99	0.99	0.99	306
Weighted avg	0.99	0.99	0.99	306


Tablo 6’da görüldüğü gibi eğitim verileri için, kesinlik, geri çağırma, f1-skor değerlerinin hepsinde %97’lik bir oran elde edilmiştir. Test verileri için bu sonuçlar maskesiz (0) görüntüler için kesinlik değeri %97, geri çağırma değeri %100 ve f1-skor değerinin ise %99 olduğu, maskeli (1) veriler için ise kesinlik değeri %100, geri çağırma değeri %97 ve f1-skor değerinin ise %99 olduğu görülmektedir.

5.2. EfficientNetV2M Modeliyle Elde Edilen Sonuçlar

Tablo 7: EfficientNetV2M Modeli Ölçüm Parametre Sonuçları

Doğruluk (Accuracy) Değeri	Kayıp (Loss) Değeri	Eğitim İçin Geçen Süre
0.9902	0.0324	2 saat 21 dk 52.33 sn

Tablo 7’de görüldüğü gibi, EfficientNetV2M modelinde gerçekleştirilen eğitimle 2 saat 21 dakika 52.33 saniye içerisinde 0.0330 kayıp ve %99.02 doğruluk oranları elde edilmiştir. Bu sonuç da modelimizin maskeli maskesiz tespitinde 2 saati geçen bir sürede gerçekleşen eğitim sonucunda başarı oranının gayet yüksek olduğu görülmektedir. Bu değerlerin eğitim ve test verilerine göre değişiminin yer aldığı Şekil 16’dan da anlaşılacağı üzere, eğitim verilerinde test verilerine göre kaybın daha az olduğu, ancak doğruluk değerlerinin eşit olduğu görülmektedir. Değerlerin eğitim boyunca genel olarak artış ve azalışlarının düzenli bir şekilde gerçekleştiği anlaşılmaktadır.



Şekil 16: EfficientNetV2M Modeli Eğitim Grafiği

Şekil 17’de EfficientNetV2M modeliyle eğitim sonunda oluşan, 153 maskeli, 153 maskesiz test verilerine ait karışıklık matrisi yer almaktadır. Matrise göre EfficientNetV2M modelinin, 153 maskesiz görüntüsünün 153’ünün maskesiz olarak sınıflandırdığı ve 153 maskeli görüntünün 150’sinin maskeli ve 3’ünün maskesiz olarak sınıflandırdığı görülmektedir. Modelin maskesiz görüntüleri ayırt etmede başarılı olurken, maskeli görüntülerde az da olsa hatalı tespit olduğu görülmektedir.



Şekil 17: EfficientNetV2M Modeli Karışıklık Matrisi

EfficientNetV2M modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerinin maskeli ve maskesiz olarak sınıflandırılmasıyla ilgili elde edilen kesinlik, geri çağırma ve f1-skor değerleri Tablo 8’de yer almaktadır.

Tablo 8: EfficientNetV2M Modeli Sınıflama Raporu

	Precision (Kesinlik)	Recall (Geri Çağırma)	F1-score	Support
0	0.98	1.00	0.99	153
1	1.00	0.98	0.99	153
Macro avg	0.99	0.99	0.99	306
Weighted avg	0.99	0.99	0.99	306


Tablo 8’de görüldüğü gibi eğitim verileri için, kesinlik, geri çağırma, f1-skor değerlerinin hepsinde %99’luk bir oran elde edilmiştir. Test verileri için bu sonuçlar maskesiz (0) görüntüler için kesinlik değeri %98, geri çağırma değeri %100 ve f1-skor değerinin ise %99 olduğu, maskeli (1) veriler için ise kesinlik değeri %100, geri çağırma değeri %98 ve f1-skor değerinin ise %99 olduğu görülmektedir.

5.3. NasNetMobile Modeliyle Elde Edilen Sonuçlar

Tablo 9: NasNetMobile Modeli Ölçüm Parametre Sonuçları

Doğruluk (Accuracy) Değeri	Kayıp (Loss) Değeri	Eğitim İçin Geçen Süre
0.9935	0.0108	41 dk 57.92 sn

Tablo 9’da görüldüğü gibi, NasNetMobile modelinde gerçekleştirilen eğitimle 41 dakika 57.92 saniye içerisinde 0.0547 kayıp ve %99.35 doğruluk oranları elde edilmiştir. Bu sonuç da modelimizin maskeli maskesiz tespitinde çok kısa sürede gerçekleşen eğitim sonucunda başarı oranı kabul edilebilir düzeyde yüksek elde edilmiştir. Bu değerlerin eğitim ve test verilerine göre değişiminin yer aldığı Şekil 18’den de anlaşılacağı üzere, eğitim verilerinde test verilerine göre kaybın daha az olduğu, doğruluk değerlerinin ise daha fazla olmakla birlikte, düzenli bir şekilde artış azalış gerçekleştiği görülmektedir.



Şekil 18: NasNetMobile Modeli Eğitim Grafığı

Şekil 19’da NasNetMobile modeliyle eğitim sonunda oluşan, 153 maskeli, 153 maskesiz test verilerine ait karışıklık matrisi yer almaktadır. Matrise göre NasNetMobile modelinin, 153 maskesiz görüntüsünün 152’sinin maskesiz ve 1’inin maskeli olarak sınıflandırdığı ve 153 maskeli görüntünün 152’sinin maskeli ve 1’inin maskesiz olarak sınıflandırdığı görülmektedir. Modelin maskesiz görüntüleri ve maskeli görüntüleri ayırt etmede çok az hatanın olduğu görülmektedir.



Şekil 19: NasNetMobile Modeli Karışıklık Matrisi

NasNetMobile modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerinin maskeli ve maskesiz olarak sınıflandırılmasıyla ilgili elde edilen kesinlik, geri çağırma ve f1-skor değerleri Tablo 10’da yer almaktadır.

Tablo 10: NasNetMobile Modeli Sınıflama Raporu

	Precision (Kesinlik)	Recall (Geri Çağırma)	F1-score	Support
0	1.00	0.99	0.99	153
1	0.99	1.00	0.99	153
Macro avg	0.99	0.99	0.99	306
Weighted avg	0.99	0.99	0.99	306


Tablo 10’da görüldüğü gibi eğitim verileri için, kesinlik, geri çağırma, f1-skor değerlerinin hepsinde %99’luk bir oran elde edilmiştir. Test verileri için bu sonuçlar maskesiz (0) görüntüler için kesinlik değeri %100, geri çağırma değeri ve f1-skor değerinin %99 olduğu, maskeli (1) veriler için ise kesinlik değeri %99, geri çağırma değeri %100 ve f1-skor değerinin ise %99 olduğu görülmektedir.

5.4. InceptionV3 Modeliyle Elde Edilen Sonuçlar

Tablo 11: InceptionV3 Modeli Ölçüm Parametre Sonuçları

Doğruluk (Accuracy) Değeri	Kayıp (Loss) Değeri	Eğitim İçin Geçen Süre
0.9935	0.0269	52 dk 29.89 sn

Tablo 11’de görüldüğü gibi, InceptionV3 modelinde gerçekleştirilen eğitimle 52 dk 29.89 sn içerisinde 0.0250 kayıp ve %99.35 doğruluk oranları elde edilmiştir. Bu sonuç da modelimizin maskeli maskesiz tespitinde yaklaşık 1 saat gibi sürede gerçekleşen eğitim sonucunda başarı oranının neredeyse %100’e yakın olduğu görülmektedir. Bu değerlerin eğitim ve test verilerine göre değişiminin yer aldığı Şekil 20’den de anlaşılabacağı üzere, eğitim ve test verilerinin kayıp değerlerinin hemen hemen eşit olduğu, doğruluk değerlerinin ise eşit değerlere sahip olduğu görülmektedir. Değerlerin eğitim boyunca artış ve azalışlarının ise çalışılan diğer modellere göre daha düzenli bir şekilde gerçekleştiği anlaşılmaktadır.



Şekil 20: InceptionV3 Modeli Eğitim Grafiği

Şekil 21’de InceptionV3 modeliyle eğitim sonunda oluşan, 153 maskeli, 153 maskesiz test verilerine ait karışıklık matrisi yer almaktadır. Matrise göre InceptionV3 modelinin, 153 maskesiz görüntüsünün 153’ünün de maskesiz olarak sınıflandırdığı ve 153 maskeli görüntünün 151’inin maskeli ve 2’sinin maskesiz olarak sınıflandırdığı görülmektedir. Modelin maskesiz görüntüleri ayırt etmede başarılı olurken maskeli görüntüleri ayırt etmede çok az hatanın olduğu görülmektedir.



Şekil 21: InceptionV3 Modeli Karışıklık Matrisi

InceptionV3 Modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerinin maskeli ve maskesiz olarak sınıflandırılmasıyla ilgili elde edilen kesinlik, geri çağırma ve f1-skor değerleri Tablo 12’de yer almaktadır.

Tablo 12: InceptionV3 Modeli Sınıflama Raporu

	Precision (Kesinlik)	Recall (Geri Çağırma)	F1-score	Support
0	0.99	1.00	0.99	153
1	1.00	0.99	0.99	153
Macro avg	0.99	0.99	0.99	306
Weighted avg	0.99	0.99	0.99	306


Tablo 12’de görüldüğü gibi eğitim verileri için, kesinlik, geri çağırma, f1-skor değerlerinin hepsinde %99’luk bir oran elde edilmiştir. Test verileri için bu sonuçlar maskesiz (0) görüntüler için kesinlik değeri %99, geri çağırma değeri %100 ve f1-skor değerinin ise %99 olduğu, maskeli (1) veriler için ise kesinlik değeri %100, geri çağırma değeri ve f1-skor değerinin %99 olduğu görülmektedir.

5.5. VGG19 Modeliyle Elde Edilen Sonuçlar

Tablo 13: VGG19 Modeli Ölçüm Parametre Sonuçları

Doğruluk (Accuracy) Değeri	Kayıp (Loss) Değeri	Eğitim İçin Geçen Süre
0.9673	0.1483	4 saat 14 dk 46.52 sn

Tablo 13’te görüldüğü gibi, VGG19 modelinde gerçekleştirilen eğitimle 2 saat 51 dk 59.97 sn içerisinde 0.1483 oranlık bir kayıpla %96.73 oranında doğruluk elde edilmiştir. Bu sonuç da modelimizin maskeli maskesiz tespitinde 4 saati geçen bir sürede gerçekleşen eğitim sonucunda başarı oranının kabul edilebilir fakat kaybın fazla olduğu görülmektedir. Bu değerlerin eğitim ve test verilerine göre değişiminin yer aldığı Şekil 22’den de anlaşılabileceği üzere, kaybın eğitim verileriyle test verileri arasında çok farklı olduğu, doğruluk değerlerinin ise eğitim verilerinde test verilerinden daha fazla olduğu görülmektedir. Değerlerin eğitim boyunca artış ve azalışlarının düzensiz gerçekleşmesine karşın eğitim sonunda kabul edilebilir doğruluk elde edildiği görülmektedir.



Şekil 22: VGG19 Modeli Eğitim Grafiği

Şekil 23'te VGG19 modeliyle eğitim sonunda oluşan, 153 maskeli, 153 maskesiz test verilerine ait karışıklık matrisi yer almaktadır. Matrise göre VGG19 modelinin, 153 maskesiz görüntüsünün 152'sinin maskesiz ve 1'inin maskeli olarak sınıflandırdığı ve 153 maskeli görüntünün 144'ünün maskeli ve 9'unun maskesiz olarak sınıflandırdığı görülmektedir. Modelin maskesiz görüntüleri ayırt etmede çok az hatayla başarılı olurken, maskeli görüntüleri ayırt etmede yüksek hata elde ettiği görülmektedir.



Şekil 23: VGG19 Karışıklık Matrisi

VGG19 modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerinin maskeli ve maskesiz olarak sınıflandırılmasıyla ilgili elde edilen kesinlik, geri çağırma ve f1-skor değerleri Tablo 14'te yer almaktadır.

Tablo 14: VGG19 Modeli Sınıflama Raporu

	Precision (Kesinlik)	Recall (Geri Çağırma)	F1-score	Support
0	0.94	0.99	0.97	153
1	0.99	0.94	0.97	153
Macro avg	0.97	0.97	0.97	306
Weighted avg	0.97	0.97	0.97	306

Tablo 14’te görüldüğü gibi eğitim verileri için, kesinlik, geri çağırma ve f1-skor değerlerinde %97’lik oranlar elde edilmiştir. Test verileri için bu sonuçlar maskesiz (0) görüntüler için kesinlik değeri %94, geri çağırma değeri %99 ve f1-skor değerinin ise %97 olduğu, maskeli (1) veriler için ise kesinlik değeri %99, geri çağırma değeri %94 ve f1-skor değerinin ise %97 olduğu görülmektedir.

5.6. Kullanılan Modellerin Karşılaştırılması

Tablo 15: Modellerin Doğruluk, Eğitim Süresi, Kesinlik, Geri Çağırma, F1-Skor, Kayıp Değerlerinin Karşılaştırılması

Model Adı	Doğruluk	Kesinlik	Geri Çağırma	F1-Skor	Kayıp Değeri	Eğitim Süresi
DenseNet121	0.9869	0.99	0.99	0.99	0.0262	1 saat 21 dk 49.19 sn
EfficientNetV2M	0.9902	0.99	0.99	0.99	0.0324	2 saat 21 dk 52.53 sn
NasNetMobile	0.9935	0.99	0.99	0.99	0.0108	41 dk 57.92 sn
InceptionV3	0.9935	0.99	0.99	0.99	0.0269	52 dk 29.89 sn
VGG19	0.9673	0.97	0.97	0.97	0.1483	4 saat 14 dk 46.52 sn

Çalışmamızda kullandığımız modellerin Tablo 15’te yer alan eğitim süreleri incelendiğinde, NasNetMobile modelinin 41 dakika 57.92 saniye ile en az eğitim süresine sahipken, 4 saat 14 dakika 46.52 saniye ile en uzun eğitim süresinin VGG19 modeline ait olduğu görülmektedir. InceptionV3 modelinde 52 dakika 29.89 saniye olan eğitim süresi DenseNet121 modelinde 1 saat 21 dakika 49.19 saniye iken, EfficientNetV2M modelinde 2 saat 21 dakika 52.53 saniye olduğu görülmektedir. Kullanılan modelleri eğitim süresine göre sıralayacak olursak en az süreliden en fazlasına doğru; NasNetMobile, InceptionV3, DenseNet121, EfficientNetV2M ve VGG19 şeklinde olmaktadır.

Tablo 15’te yer alan doğruluk oranlarına göre kullanılan modeller değerlendirildiğinde en yüksek doğrulukların %99.35’lik oranla NasNetMobile ve InceptionV3 modelleriyle elde edilmişken, en düşük doğruluğun ise %96.73’lük oranla VGG19 modeline ait olduğu

gözlemlenmiştir. Ayrıca DenseNet121 ve EfficientNetV2M modellerinin doğruluk oranlarının ise sırasıyla %98.69 ve 99.02 olduğu görülmektedir. Doğruluk oranları aynı olan iki modelin kayıp oranlarına bakıldığında 0.0108 oranla daha az kayıp elde ettiğinden dolayı NasNetMobile modelinin daha başarılı olduğu söylenebilir. Bu sonuçlar değerlendirildiğinde en başarılı modelden en az başarılı modele doğru sıralanışın NasNetMobile, InceptionV3, EfficientNetV2M, DenseNet121, VGG19 olduğu söylenebilir.

Tablo 15'te yer alan kesinlik, geri çağırma, f1-skor ve kayıp değerleri açısından kullanılan modeller değerlendirildiğinde; InceptionV3, EfficientV2M, NasNetMobile ve DenseNet121 modellerinde %99 oranı ile kesinlik, geri çağırma, f1-skor değerlerinin eşit ve VGG19'a göre daha yüksek çıktığı görülmektedir. VGG19 modelinde kesinlik, geri çağırma ve f1-skor değerleri %97 elde edilmiştir. Modeller kayıp değeri en az, 0.0108 oranıyla NasNetMobile ile elde edilirken, en çok kayıp değeri 0.1483 oranı ile VGG19 ile elde edilmiştir.

6. SONUÇ VE ÖNERİLER

2019 sonunda ilk olarak Çin’de ortaya çıkarak 2020 yılının ilk yarısında tüm dünyaya yayılan Covid-19 virüsü hayatımızın bir gerçeği haline gelmiştir. Yayılmaya başladığından itibaren başta DSÖ tüm dünya ülkelerini kapsayacak şekilde virüsün yayılmasını yavaşlatmak amacıyla birçok tedbir ve kurallar yayınlamışlardır. Ülkemiz sınırları için düşünüldüğünde ise yayılımın azalması, bulaşın artmaması için Sağlık Bakanlığı da birçok tedbir yayınlamışlardır. Bu tedbirler hastalık için kalıcı çareler bulunana kadar devam ettirilmek zorunda kalmıştır. Hastalığın tam olarak seyri, bulaşma şekli, verdiği zararlar anlaşılması için birçok çalışma gerçekleştirilmiştir. Bu çalışmalar teknolojinin de ilerlemiş olmasıyla birlikte derin öğrenme çalışmaları dahil edilerek bu konuya ilişkin bir sürü çalışma yapılmıştır. Başlangıçta hastalığın tespiti konularında yapılmaya başlayan çalışmalar, sonradan hastalığın bulaşmasında en önemli önleyici tedbir olan maske, mesafe ve hijyen konusu da eklenerek devam etmiştir.

Özellikle ülkemizde maske, mesafe ve hijyen konusunda bulaşın ilk zamanlarından itibaren çok dikkat edilmeye çalışılmıştır. Kalabalık alanlara maskesiz girmenin yasaklanmasıyla birlikte hem ülkemiz hem de diğer dünya ülkelerinde bu konunun denetlenmesiyle ilgili çalışmalar başlamıştır. Derin öğrenme konusunun bu konuda sıklıkla kullanıldığı tüm dünyada var olan maske-mesafe-hijyen tespiti gibi konulardaki örnekleri görülmektedir. Maske tespiti konusunda farklı derin öğrenme modelleri kullanılarak birçok çalışma gerçekleştirildiği, bazılarının ise gerçek zamanlı sistemlerde kullanıldığı bilinmektedir.

Bu tez çalışmasındaki amacımız daha önce kullanıldığı çalışmalarda yüksek başarılar elde edilmiş olan ve daha önce kullanılmayan bazı derin öğrenme modelleriyle yüksek doğrulukla maske tespiti gerçekleştirmektir. DenseNet121, EfficientNetV2M, NasNetMobile, InceptionV3 ve VGG19 modellerini kullandığımız çalışmada maskeli maskesiz şeklinde iki sınıfa ait verilerin yer aldığı veri setiyle çalışılmıştır. Toplamda 906 görüntümüzün yer aldığı veri setimizde verilerin yaklaşık %30’u test ve %70’i eğitim için kullanılmıştır. Veri setimiz üzerinde seçtiğimiz modellerin eğitimi Google Colab’ın sunduğu Jupyter Notebook kullanılarak Python diliyle gerçekleştirilmiştir. Eğitim sonuçları doğruluk, eğitim süresi, kesinlik, geri çağırma ve f1-skor değerleri çevresinde incelenmiştir. Maske tespitinin gerçekleştirilmesi için yapılan çalışmanın sonucunda DenseNet121 modelinde %98.69 doğruluk, %99 kesinlik, geri çağırma ve f1 skor, EfficientNetV2M modelinde %99.02 doğruluk, %99 kesinlik, geri çağırma ve f1 skor, NasNetMobile modelinde %99.35 doğruluk,

%99 kesinlik, geri çağırma ve f1 skor, InceptionV3 modelinde %99.35 doğruluk, %99 kesinlik, geri çağırma ve f1 skor ve VGG19 modelinde ise %96.73 doğruluk, %97 kesinlik, geri çağırma ve f1 skor elde edilmiştir. Bu sonuçlar değerlendirildiğinde maske tespiti konusunda çalışmış olduğumuz modeller içinden en başarılı sonuçların en az kayıp ve en yüksek doğruluk oranıyla NasNetMobile modeli ile alındığı görülmektedir.

Covid-19 maske tespiti konusunda kullandığımız modellerle yaptığımız sınıflandırma işlemlerinde yüksek doğruluk sonuçları elde edildiği görülmüştür. Derin öğrenme yöntemleri kullanılarak insanların maske takıp takmadığı konusunda bilgi verilebilmektedir. Kullanılan yöntemler maske kullanımının zorunlu olduğu kalabalık ortamlar için denetimi gerçekleştiren kişilerin iş yükünü hafifletmesi ve kolaylaştırması açısından önem arz etmektedir. Gerçekleştirmiş olduğumuz tez çalışmasının bazı sınırlılıkları vardır. Kullanılan veri setindeki görüntü sayısının derin öğrenme modelleri için önemi göz önüne alındığında veri setimizdeki örneklem görüntü toplamının çok zaman alıcı olduğundan hazır veri seti kullanılması gerekmesi ve paylaşılan hazır olan veri setlerinin ise yetersizliği açısından sınırlılığa sahiptir. Ayrıca gerekli donanımların sağlanmasının zorluğu dolayısıyla gerçek sistemlerde modellerin çalışmasının denemesinin zorluğu da başka bir sınırlılık olmaktadır.

Gelecekte yapılacak çalışmalarda, daha geniş, özenle hazırlanmış veri setleri kullanılarak daha farklı derin öğrenme modelleriyle çalışılması ve yeterli donanım kullanarak bu modellerin kullanılabilirliğinin de test edilebilmesi için gerçek zamanlı sistemlerin kullanılması düşünülmektedir.

7. KAYNAKÇA

- Akar, M. (2022). *Covid-19' A Karşı İnsansız Hava Aracı ile Derin Öğrenme Tabanlı Maske Tespiti*. (Yüksek Lisans Tezi), Karamanoğlu Mehmet Bey Üniversitesi Fen Bilimleri Fakültesi, Karaman.
- Alkhder, H. (2021). *Face Mask Detection*. (Yüksek Lisans Tezi), Başakşehir Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalı, İstanbul.
- Alqadiri, Y. (2022). *Face Mask Detection Using Deep Learning Methods*. (Yüksek Lisans Tezi), Bahçeşehir Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalı, İstanbul.
- Ashames, M. M. A. (2020). *Derin öğrenme yöntemleri kullanılarak osteoporozun belirlenmesi*. (Yüksek Lisans Tezi), Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Konya.
- Aslan, S. (2021). Covid-19 Salgınının Küreselleşmeye Ve Ulus Devletlere Etkisi. *Elektronik Sosyal Bilimler Dergisi*, 20 (80), 1735-1752.
- Atcılı, A. (2020). Yapay Sinir Ağlarında Kullanılan Optimizasyon Algoritmaları. *Machine Learning Türkiye*. 30.12.2022 tarihinde <https://medium.com/machine-learning-t%C3%BCrkiye/yapay-sinir-a%C4%9Flar%C4%B1nda-kullan%C4%B1lan-optimizasyon-algoritmalar%C4%B1-3e87cd738cb5> sayfasından erişilmiştir.
- Aydemir, F., & Arslan, S. (2021). *COVID-19 Pandemi Sürecinde Çocukların El Yıkama Alışkanlığının Nesnelerin İnterneti Tabanlı Sistem ile İzlenmesi*. Mühendislik Bilimleri ve Araştırmaları Dergisi, 3 (2), 161-168.
- Ba Alawi, A. E., & Qasem, A. M. (2021). *Lightweight CNN-based Models for Masked Face Recognition*. 2021 International Congress of Advanced Technology and Engineering (ICOTEN), 1-5. <https://doi.org/10.1109/ICOTEN52080.2021.9493424>
- Baluprithviraj, K. N., Bharathi, K. R., Chendhuran, S., & Lokeshwaran, P. (2021). *Artificial Intelligence based Smart Door with Face Mask Detection*. 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS), 543-548. <https://doi.org/10.1109/ICAIS50930.2021.9395807>
- Başaran, E. (2020). *Timpanik Membran Görüntü Analizi ve Yapay Zeka Kullanılarak Sanal Otitis Media Tanı Sisteminin Geliştirilmesi*. (Doktora Tezi), Karabük Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalı, Karabük.
- Başaran, E., Cömert, Z., Sengur, A., Budak, Ü., Celik, Y., & Toğaçar, M. (2020). *Normal ve Kronik Hastalıklı Orta Kulak İmgelerinin Evrimsel Sinir Ağları Yöntemiyle Tespit Edilmesi*. Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 13(1), Art. 1.

- Bozkurt, F. (2021). *Derin Öğrenme Tekniklerini Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti*. Avrupa Bilim ve Teknoloji Dergisi , Ejosat Özel Sayı 2021 (ARACONF) , 149-156 .
- c3.ai. (2022). *Model Training*. 29.12.2022 tarihinde <https://c3.ai/glossary/data-science/model-training/> sayfasından erişilmiştir.
- Cerit, B. (2020). *Gerçek Zamanlı Öğrenci Takip Sistemi ve Derin Öğrenme Yaklaşımı İle Maske Tespiti*. (Yüksek Lisans Tezi), Karabük Üniversitesi Mekatronik Mühendisliği Ana Bilim Dalı, Karabük.
- Çarkacı, N. (2018). *Derin Öğrenme Uygulamalarında En Sık kullanılan Hiper-parametreler*. 30.12.2022 tarihinde <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4> sayfasından erişilmiştir.
- Degadwala, S., Vyas, D., Chakraborty, U., Dider, A. R., & Biswas, H. (2021). *Yolo-v4 Deep Learning Model for Medical Face Mask Detection*. 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS), 209-213. <https://doi.org/10.1109/ICAIS50930.2021.9395857>
- Doğan, Ö. (2020). *CNN (Convolutional Neural Networks) Nedir?*. 28.12.2022 tarihinde <https://teknoloji.org/cnn-convolutional-neural-networks-nedir/> sayfasından erişilmiştir.
- DSÖ. (2022). *Advice for the public on COVID-19 – World Health Organization*. 26.12.2022 tarihinde <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/advice-for-public> sayfasından erişilmiştir.
- Erdem, İ. (2020). *Koronavirüse (Covid-19) karşı Türkiye'nin karantina ve tedbir politikaları*. Turkish Studies, 15(4), 377-388.
- Eryılmaz, F., & Karacan, H. (2021). *Akciğer X-Ray Görüntülerinden COVID-19 Tespitinde Hafif ve Geleneksel Evrimsel Sinir Ağ Mimarilerinin Karşılaştırılması*. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, ICAIAME 2021, 26-39.
- Euronews. (2022). *Everything you need to know about the UK's new 90-minute coronavirus test | Euronews answers*. 26.12.2022 tarihinde <https://www.euronews.com/my-europe/2020/08/03/everything-you-need-to-know-about-the-uk-s-new-90-minute-coronavirus-test-euronews-answers> sayasından erişilmiştir.
- Europolitika.com (2020). *Pandemik Teknolojiler*. 03.01.2023 tarihinde <https://www.europolitika.com/pandemik-teknolojiler/> sayfasından erişilmiştir.
- Géron, A. (2019). *14. Deep Computer Vision Using Convolutional Neural Networks*. 26.12.2022 tarihinde <https://learning.oreilly.com/library/view/hands-on-machine-learning/9781492032632/ch14.html> sayfasından erişilmiştir.
- Goyal, H., Sidana, K., Singh, C., Jain, A., & Jindal, S. (2022). *A real time face mask*

detection system using convolutional neural network. Multimedia Tools and Applications, 81(11), 14999-15015. <https://doi.org/10.1007/s11042-022-12166-x>

Güngör, S., Kaya, M., & Alhajj, R. (2021). *Renklendirilmiş BT Görüntülerinden Covid-19 Tespiti İçin Derin Öğrenmeye Dayalı Bir Yöntem*. Computer Science, 5th International Artificial Intelligence and Data Processing symposium, 391-399. <https://doi.org/10.53070/bbd.990750>

Harriat Christa, G., J, J., K, A., & Sagayam, K. M. (2021). *CNN-based Mask Detection System Using OpenCV and MobileNetV2*. 2021 3rd International Conference on Signal Processing and Communication (ICPS), 115-119. <https://doi.org/10.1109/ICSPC51351.2021.9451688>

Herdian, Putra, G., & -. (2019). *Classification of C2C e-Commerce Product Images using Deep Learning Algorithm*. International Journal of Advanced Computer Science and Applications, 10(9). <https://doi.org/10.14569/IJACSA.2019.0100925>

Hoang, V.-T., & Jo, K.-H. (2021). *Practical Analysis on Architecture of EfficientNet*. 2021 14th International Conference on Human System Interaction (HSI), 1-4. <https://doi.org/10.1109/HSI52170.2021.9538782>

Isaksson, M. (2018). *Create a drawing of a feed-forward neural network*. 03.01.2023 tarihinde <https://github.com/martisak/dotnets> sayfasından erişilmiştir.

Jasim, A. A. (2022). *Gerçek Zamanlı Yüz Maskesi Algılama Uyarı Sistemi*. (Yüksek Lisans Tezi), Kırşehir Ahi Evran Üniversitesi İleri Teknolojiler Ana Bilim Dalı, Kırşehir.

Jignesh Chowdary, G., Pun, N. S., Sonbhadra, S. K., & Agarwal, S. (2020, December). Face mask detection using transfer learning of inceptionv3. In International Conference on Big Data Analytics (pp. 81-90). Springer, Cham.

Kaçmaz, R. N. (2020). *Mining Colonoscopy Images For Abnormality Detection*. (Doktora Tezi), Abdullah Gül Üniversitesi Elektrik ve Bilgisayar Mühendisliği Ana Bilim Dalı, Kayseri.

Kansu, A. (2020). *Covid 19 Pandemisinde Akciğer ve Göğüs Hastalıkları*. Medical Research Reports. 2020; 3(Özel Sayı): 11-16.

Karacıoğlu Ö. (2020). *COVID-19: Epidemiyolojik bilgilerimiz ve hastalığın dünyadaki gidişi*. Journal of ADEM. 2020; 1(1): 55-70.

Kaya, B., & Önal, M. (2021). *COVID-19 Tespiti için Akciğer BT Görüntülerinin Bölütlenmesi*. Avrupa Bilim ve Teknoloji Dergisi , Ejosat Özel Sayı 2021 (ICAENS) , 1296-1303 . <https://doi.org/10.31590/ejosat.1015061>

Keras.io. (2022). *Keras documentation: The Model class*. 29.12.2022 tarihinde <https://keras.io/api/models/model/> sayfasından erişilmiştir.

Konca, M. S. (2020). *Evrişimli Sinir Ağları (Convolutional Neural Networks—CNN)*.

29.12.2022 tarihinde <https://mustafaserdarkonca.medium.com/evri%C5%9Fimli-sinir-a%C4%9Flar%C4%B1-convolutional-neural-networks-cnn-74b3d4a567f9> sayfasından erişilmiştir.

- Kumar, A., Kalia, A., Verma, K., Sharma, A., & Kaushal, M. (2021). *Scaling up face masks detection with YOLO on a novel dataset*. Optik, 239, 166744. <https://doi.org/10.1016/j.ijleo.2021.166744>
- Kutucu, H. (2020). *Derin Öğrenme Algoritmaları Kullanarak Bir Konuşma Tanıma Uygulaması*. (Yüksek Lisans Tezi), Sakarya Uygulamalı Bilimler Üniversitesi Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, Sakarya.
- Loey, M., Manogaran, G., Taha, M. H. N., & Khalifa, N. E. M. (2021). *A hybrid deep transfer learning model with machine learning methods for face mask detection in the era of the COVID-19 pandemic*. Measurement, 167, 108288. <https://doi.org/10.1016/j.measurement.2020.108288>
- Loey, M., Manogaran, G., Taha, M. H. N., & Khalifa, N. E. M. (2021). *Fighting against COVID-19: A novel deep learning model based on YOLO-v2 with ResNet-50 for medical face mask detection*. Sustainable Cities and Society, 65, 102600. <https://doi.org/10.1016/j.scs.2020.102600>
- Maas, A. L., Hannun, A. Y., & Ng, A. Y. (2013, June). *Rectifier nonlinearities improve neural network acoustic models*. In *Proc. icml* (Vol. 30, No. 1, p. 3).
- Mehedi Shamrat, F. M. J., Chakraborty, S., Billah, Md. M., Jubair, Md. A., Islam, M. S., & Ranjan, R. (2021). *Face Mask Detection using Convolutional Neural Network (CNN) to reduce the spread of Covid-19*. 2021 5th International Conference on Trends in Electronics and Informatics (ICOEI), 1231-1237. <https://doi.org/10.1109/ICOEI51242.2021.9452836>
- Militante, S. V., & Dionisio, N. V. (2020). *Real-Time Facemask Recognition with Alarm System using Deep Learning*. 2020 11th IEEE Control and System Graduate Research Colloquium (ICSGR), 106-110. <https://doi.org/10.1109/ICSGRC49013.2020.9232610>
- Militante, S. V., & Dionisio, N. V. (2020). *Deep Learning Implementation of Facemask and Physical Distancing Detection with Alarm Systems*. 2020 Third International Conference on Vocational Education and Electrical Engineering (ICVEE), 1-5. <https://doi.org/10.1109/ICVEE50212.2020.9243183>
- Negi, A., Chauhan, P., Kumar, K., & Rajput, R. S. (2020). *Face Mask Detection Classifier and Model Pruning with Keras-Surgeon*. 2020 5th IEEE International Conference on Recent Advances and Innovations in Engineering (ICRAIE), 1-6. <https://doi.org/10.1109/ICRAIE51050.2020.9358337>
- Özbay, E., & Altunbey Özbay, F. (2020). *Derin Öğrenme ve Sınıflandırma Yaklaşımları ile BT görüntülerinden Covid-19 Tespiti*. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, c. 12, sayı. 2, ss. 211-219. <https://doi.org/10.24012/dumf.812810>

- Özdemir Ö. & Pala A. (2020). *Çocuklarda COVID-19 Enfeksiyonunun Tanısı, Tedavisi ve Korunma Yolları*. J Biotechnol & Strategic Health Res. 2020; 4: 14-21.
- Özer Çizer, E. (2022). Pazarlamada yapay zeka uygulamaları. Dijitalleşen Dünyada Birey, Toplum, Siyaset Kongresi Bildiri Kitabı. (s.16-32). İstanbul: Işık Üniversitesi Yayınları.
- Özer, İ. (2020). Türkiye Cumhuriyeti Sınırlarını Tehdit Eden Kolera Saldırıları ve Alınan Savunma Tedbirleri. Ordu Üniversitesi Sosyal Bilimler Enstitüsü Sosyal Bilimler Araştırmaları Dergisi , 10 (1) , 201-216.
- Sağlık Bakanlığı. (2022). *COVID-19 Nedir ?*. 26.12.2022 tarihinde <https://covid19.saglik.gov.tr/TR-66300/covid-19-nedir-.html> sayfasından erişilmiştir.
- Saleh, N. A. A., Ertunç, H. M., Saleh, R. A. A., & Rassam, M. A. (2021). *A Simple Mask Detection Model Based On A Multi-Layer Perception Neural Network*. 2021 International Conference of Technology, Science and Administration (ICTSA), 1-5. <https://doi.org/10.1109/ICTSA52017.2021.9406523>
- Sanjaya, S. A., & Adi Rakhmawan, S. (2020). *Face Mask Detection Using MobileNetV2 in The Era of COVID-19 Pandemic*. 2020 International Conference on Data Analytics for Business and Industry: Way Towards a Sustainable Economy (ICDABI), 1-5. <https://doi.org/10.1109/ICDABI51230.2020.9325631>
- Santur, Y. (2020). *Derin Öğrenme ve Aşağı Örnekleme Yaklaşımları Kullanılarak Duygu Sınıflandırma Performansının İyileştirilmesi*. Fırat Üniversitesi Mühendislik Bilimleri Dergisi , 32 (2) , 561-570 .
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv 1409.1556*.
- Singh, K. R., Kamble, S. D., Kalbande, S. M., & Fulzele, P. (2021). *A Review on COVID-19 Face Mask Detection using CNN*. Journal of Pharmaceutical Research International, 39-45. <https://doi.org/10.9734/jpri/2021/v33i35B31896>
- Snyder, S. E., & Husari, G. (2021). *Thor: A Deep Learning Approach for Face Mask Detection to Prevent the COVID-19 Pandemic*. SoutheastCon 2021, 1-8. <https://doi.org/10.1109/SoutheastCon45413.2021.9401874>
- Song, Z., Nguyen, K., Nguyen, T., Cho, C., & Gao, J. (2022). *Spartan Face Mask Detection and Facial Recognition System*. Healthcare, 10(1), Art. 1. <https://doi.org/10.3390/healthcare10010087>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). *Going deeper with convolutions*. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>

- Şener Cömert, S., Nesrin Kırıl, N. (2020) *Radiological Findings of COVID-19 Pneumonia*. South Clin Ist Euras. 2020; 31(1): 16-22.
- Tan, M., & Le, Q. V. (2021). *EfficientNetV2: Smaller Models and Faster Training* (arXiv:2104.00298). arXiv. <http://arxiv.org/abs/2104.00298>
- Türkoğlu, M., Hanbay, K., Saraç SiVriKaya, I., & Hanbay, D. (2020). *Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması*. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9(1), 334-345. <https://doi.org/10.17798/bitlisfen.562101>
- Tütüncü, D., & Esen, M. F. (2021). *Salgın hastalıkların yönetiminde Nesnelerin İnterneti (NİT) kullanımı: COVID-19 örneği*. Sağlık Akademisyenleri Dergisi , 8 (2) , 169-177.
- Ullah, N., Javed, A., Ghazanfar, M. A., Alsufyani, A., & Bourouis, S. (2022). A novel DeepMaskNet model for face mask detection and masked facial recognition. Journal of King Saud University-Computer and Information Sciences.
- Wakchaure, A., Kanawade, P., Jawale, M. A., William, P., & Pawar, A. B. (2022). *Face Mask Detection in Realtime Environment using Machine Learning based Google Cloud*. 2022 International Conference on Applied Artificial Intelligence and Computing (ICAAI), 557-561. <https://doi.org/10.1109/ICAAI53929.2022.9793201>
- Wang, B., Zhao, Y., & Chen, C. L. P. (2021). *Hybrid Transfer Learning and Broad Learning System for Wearing Mask Detection in the COVID-19 Era*. IEEE Transactions on Instrumentation and Measurement, 70, 1-12. <https://doi.org/10.1109/TIM.2021.3069844>
- Yavuz, M. (2020). *Derin Öğrenme Modellerinin Hücre Veri Seti Üzerinde Eğitilerek Kıyaslanması ve Mobil Ortama Uyarlanması*. (Yüksek Lisans Tezi), Sakarya Uygulamalı Bilimler Üniversitesi Biyomedikal Mühendisliği Ana Bilim Dalı, Sakarya.
- Zhang, E. (2021). *A Real-Time Deep Transfer Learning Model for Facial Mask Detection*. 2021 Integrated Communications Navigation and Surveillance Conference (ICNS), 1-7. <https://doi.org/10.1109/ICNS52807.2021.9441582>

EKLER



Aksaray Üniversitesi Tez Değerlendirme Formu		
Öğrencinin Adı Soyadı:		Evet
Kapak		
1	Tez Başlığı tutanaktaki başlıkla aynı mı?	
2	Kapakdaki ay ve yıl savunmaya girilen tarihle tutarlı mı?	
3	Kapak format kılavuzdaki kapak formatına uygun mu?	
4	Kapakta yazılan tüm yazılar doğru olarak verilmiş mi?	
İçindekiler		
5	Sayfa numaraları tam verilmiş mi?	
6	Şekil, Çizelge vb. listeleri verilmiş mi? Sıralaması doğru mu?	
7	Özet, Abstract, Giriş, Sonuçlar vb. bölümler var mı?	
8	Yazım hataları kontrolü yapıldı mı?	
Giriş		
9	Hazırlanan tezin önemini anlatıyor mu?	
10	İkinci ve Üçüncü dereceden başlık içermemeli kuralına uyuldu mu?	
Özet/Abstract		
11	Kılavuza uygun mu?	
12	Ay ve yıl savunmaya girilen tarihle tutarlı mı?	
13	Özet; tek sayfa, tek aralık, tek paragraf kuralına uygun olarak yazıldı mı?	
14	Bilim kodu, sayfa adedi, anahtar kelimeler ve tez danışmanı yazıldı mı?	
Kaynakça		
15	Kaynakların tamamına metin içinde atıf yapıldı mı?	
16	Kaynak formatı Kılavuzdaki kaynak formatına uygun olarak hazırlanmış mı?	
17	Atıf formatı kılavuzdaki atıf formatına uygun mu?	
Atıf Yöntemi APA 6 ☐ CMS ☐ İSNAD ☐		
Genel Değerlendirme		
18	Etik Beyan açıklaması okundu, uyuldu ve imzalandı mı?	
19	Kabul/Onay sayfası kılavuzdaki formata uygun olarak düzenlenmiş mi?	
20	Kabul /Onay sayfasında belirtilen oy birliği/oy çokluğu seçeneklerinden uygun olanı savunmayla tutarlı olacak şekilde belirlenmiş mi?	
21	Sayfa kenar boşluklar ve sayfa numaraları kılavuzdaki formatına uygun mu?	
22	Paragraf boşlukları ve metin satır aralığı kılavuza uygun olacak şekilde düzenlenmiş mi?	
23	Başlık yazımları kılavuzdaki başlık formatlarına uygun mu?	
24	Yazı tipi ve boyutu kılavuzdaki yazı tipi ve boyutu formatına uygun mu?	
25	Şekil, Çizelge vb. açıklama ve numaralandırmaları kılavuzdaki formata uygun olarak yazılmış mı?	

Bu tezin tarafımdan “Tez yazım kuralları” okunarak dikkatlice hazırlanmış olduğunu ve doğabilecek her türlü olumsuzluktan sorumlu olacağımı kabul ederim.

Öğrencinin imzası