

Atf İçin: Daşgın, A., Adem, K. ve Kılıçarslan, S. (2023). Covid19 Yayılımını Azaltmak İçin Yüz Maskesinin Evrişimsel Sinir Ağı Modelleri ile Tespiti. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(3): 1511-1527.

To Cite: Daşgın, A., Adem, K. & Kılıçarslan, S. (2023). Detection of Face Mask with Convolutional Neural Network Models to Reduce Covid19 Spread. *Journal of the Institute of Science and Technology*, 13(3): 1511-1527.

Covid19 Yayılımını Azaltmak İçin Yüz Maskesinin Evrişimsel Sinir Ağı Modelleri ile Tespiti

Aslıhan DAŞGIN^{1*}, Kemal ADEM², Serhat KILIÇARSLAN³

Öne Çıkanlar:

- Covid-19
- Maske Tespiti
- Derin Öğrenme

Anahtar Kelimeler:

- Maske Tespiti
- Maskeli
- Maskesiz
- Derin Öğrenme
- Nesne Tespiti
- CNN
- Covid-19

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. DSÖ 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 ile toplamda 906 görüntü ile DenseNet121, EfficientNetV2M, NasNetMobile, InceptionV3, VGG19 ve InceptionResNetV2 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.

Detection Of Face Mask With Convolutional Neural Network Models To Reduce Covid19 Spread

Highlights:

- Covid-19
- Mask Detection
- Deep Learning

Keywords:

- Mask Detection
- Masked
- Unmasked
- Deep Learning
- Object Detection
- CNN
- Covid-19

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, VGG19 and InceptionResNetV2 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.

¹ Aslıhan DAŞGIN ([Orcid ID: 0000-0002-9303-3463](https://orcid.org/0000-0002-9303-3463)), Aksaray Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Bilişim Sistemleri Anabilim Dalı, Aksaray, Türkiye

² Kemal Adem ([Orcid ID: 0000-0002-3752-7354](https://orcid.org/0000-0002-3752-7354)), Sivas Bilim ve Teknoloji Üniversitesi, Bilgisayar Mühendisliği, Sivas, Türkiye

³ Serhat KILIÇARSLAN ([Orcid ID: 0000-0001-9483-4425](https://orcid.org/0000-0001-9483-4425)), Bandırma Onyedi Eylül Üniversitesi, Yazılım Mühendisliği Bölümü, Balıkesir, Türkiye

*Sorumlu Yazar/Corresponding Author: Aslıhan DAŞGIN, e-mail: aslihandsgn@gmail.com

GİRİŞ

İlk olarak 2019 Aralık'ta Çin'de görüldüğü açıklanan, 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, mesafe ve hijyen kurallarının önemli olduğu bilinmektedir. Bu tedbirlerden maske kullanımının etkililiği bilinmekle birlikte alışveriş merkezleri, konserler, sinemalar, tiyatrolar, hastaneler, okullar gibi kalabalık ortamlarda maske kullanımını zorunlu hale getirilmiştir. Bu durum bulaş açısından büyük öneme sahiptir. Ancak bu gibi ortamlarda insanların çoğu yasağa uymamakta ve denetimi çok zor olmaktadır.

İnsanlar tarafından gerçekleştirilmesi zor olan işlerde son zamanlarda derin öğrenme yöntemleriyle hazırlanan sistemlerin faydası görülmektedir. 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 modellerini kullanan gerçek zamanlı öğrenci takip sistemi (Cerit, 2020) tasarlanmıştır. Farklı sistemlere entegre edilerek kullanılacak yüksek doğruluk performansına sahip modellerle eğitilen maske tespiti çalışmaları gerçekleştirilmiştir (Aydemir ve Arslan, 2021). Bu konuda birçok çalışma yapıldığının (Akar, 2020; Jasim, 2022) görülmesinin yanı sıra, derin öğrenme modellerinden daha önceki çalışmalarda kullanılmamış olan modellerin yüksek doğrulukla maske tespiti yapabilmesi ve alana yeni katkılar sağlaması açısından çalışmamız önemlidir. Çalışmada InceptionV3, VGG19, DenseNet121, EfficientNetV2M, InceptionResNetV2 ve NasNetMobile derin öğrenme modelleri kullanılarak maske tespiti gerçekleştirilmiştir.

Derin öğrenme yöntemleri kullanılarak gerçek zamanlı maske tespiti ve denetimi amacıyla gerçekleştirilen çalışmalarda çeşitli modeller geliştirilmiştir (Susanto ve ark., 2020; Nagrath ve ark., 2021; Kaur ve ark., 2022). Çalışmaların büyük çoğunluğu, önceden eğitilmiş bir modelin ince-ayarlar yöntemiyle yeni bir veri setine uyarlanması yoluyla gerçekleştirilmiştir (Bozkurt, 2022). Bu modeller, genellikle VGG16, VGG19, ResNet, DenseNet, MobileNetV2 ve InceptionV3 gibi popüler mimarileri içermektedir. Maske tespiti için kullanılan özellikle popüler yöntemler arasında Çok Görevli Kademeli Evrişimli Sinir Ağı (MTCNN), Viola Jones algoritması, SSD ve YOLOV4 bulunmaktadır. Bu çalışmaların çoğu, farklı veri setleri ve kullanım senaryoları üzerinde test edilerek yüksek doğruluk oranları elde edilmiştir. Bu çalışmalar, derin öğrenme yöntemlerinin gerçek zamanlı maske tespiti ve denetimindeki yüksek performansını göstermektedir. Bununla birlikte, bu modellerin gerçek dünya uygulamalarında nasıl performans göstereceği hala araştırma konusudur. Ayrıca, veri seti boyutu, model karmaşıklığı ve donanım gereksinimleri gibi faktörlerin de göz önünde bulundurulması gerekmektedir. Literatürde yer alan çalışmalarda, maske tespitiyle ilgili farklı derin öğrenme modellerini kullanan birçok çalışma mevcuttur. Militante ve Dionisio (2020) tasarladıkları çalışmada, RasperryPi'de gerçek zamanlı bir yüz maskesi tespitini gerçekleştirecek alarm sistemi geliştirmeyi amaçlayan ve maske tespiti için VGG16 modelini kullandıklarını bildirmişlerdir. Çalışma sonunda tasarladıkları model ile birlikte VGG-16 %96 doğruluk elde etmişlerdir (Militante ve Dionisio, 2020). Maskelerin algılanması amacıyla Harriat Christa ve ark., (2021), yüz algılanmasında Çok Görevli Kademeli Evrişimli Sinir Ağı (MTCNN) ve Viola Jones algoritmasını, ayrıca maske tespitinde derin öğrenme yöntemlerinden MobileNetV2 kullanılmıştır. Deneysel değerlendirme sonucunda MobileNetV2 ile %99'luk doğruluk ve %99'luk F1-skoru elde edilmiştir (Harriat Christa ve ark., 2021). İnsansız hava aracı kullanılarak elde edilen video görüntülerinden insanların maske takıp takmadığını kontrol üzerine çalışmasında Akar (2022), bu kontrolü derin öğrenme tabanlı yöntemler ile gerçekleştirmiştir. İki farklı insansız hava

aracıyla hem kapalı hemde açık yerlerde gerçek zamanlı maske denetiminde başarılı olan YoloV4, VGG16, VGG19, ResNet101, ResNet152 ve MobileNetV1 uygulamış ve gerçek zamanlı uygulamalara en uygun sonuçların YoloV4 modeli ile elde edildiğini bildirmiştir (Akar, 2022). Goyal ve ark., (2022) tarafından yapılan çalışmada, durağan veya gerçek zamanlı tüm videolarda maske algılama modeli sunmak üzerine DenseNet-121, MobileNetV2, VGG19, InceptionV3 ve önerdikleri bir CNN modeli kullandıklarını bildirdiler. Deneysel çalışma sonucunda önerdikleri modelle %98'lik 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). Jasim (2022) tarafından yapılan çalışmada, güvenlik kamerası aracılığıyla maskenin takılıp-takılmadığını tespit edebilmek amacıyla derin öğrenme yöntemlerinden SSD ve MobilNetV2 tercih edilmiştir. Deneysel değerlendirmelerde en iyi başarımların MobilNetV2 ile %99.72 doğruluk ve %100 F1-skoru elde edilerek uygulamanın yüksek güvenilirlikte çalıştığını bildirmiştir (Jasim, 2022).

Yazar Adı	Yılı	Veri Seti	Yöntem	Doğruluk
Militante ve Dionisio	2020	25000	VGG16	%96
Harriat Christa ve ark.	2021	1376	MobileNetV2	%99
Akar	2022	1510	YoloV4	
Goyal vd.	2022	4000	Önerdikleri bir CNN modeli	%98
Jasim	2022	2173	MobilNetV2	%99.72

Bu çalışmada, maske tespiti için daha önce literatürde kullanılmayan derin öğrenme modelleri kullanılmıştır. Ayrıca kullanılan InceptionV3, VGG19, DenseNet121, EfficientNetV2M, NasNetMobile ve InceptionResNetV2 derin öğrenme modelleri ile gerçekleştirilen maske tespit çalışmalarının sonuçları karşılaştırılarak performans sonuçlarının iyi olduğu gözlemlenmiştir. Ek olarak, literatürde maske tespiti üzerine hibrit bir yöntem önerilmesi ilk olmaktadır. Literatürde, yaygın olarak maske tespiti için kullanılan transfer öğrenme yöntemleri ön eğitilmiş ağırlıklar kullanılarak gerçekleştirilmiştir. Bu çalışmada, diğer çalışmalardan farklı olarak ön eğitilmiş bir derin öğrenme mimarisi kullanılmamasıdır. Böylece önerilen transfer öğrenme yöntemleri, ön eğitilmiş mimarilerden daha iyi başarı verdiği gözlemlenmiştir. Ek olarak, ağırlık başarısını arttırabilmek üzere, eğitim aşamasında kullanılan veri kümesine ölçeklendirme, döndürme, kaydırma, yansılama ve burkma gibi özellikler kullanılarak veri seti genişletilmiştir.

Makalenin geri kalanında, ikinci bölümde çalışmada kullanılan veri kümesi ve yöntemler verilmiştir. Üçüncü bölümde, deneysel değerlendirme sonuçları ve tartışma verilmiştir. Son bölümde, sonuçlar ve gelecekte yapılacak çalışma sunulmuştur.

[MATERYAL VE METOT]

COVID Face Mask Detection veri kümesi

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


Çalışmamızda Kaggle sitesinde “COVID Face Mask Detection Dataset” ismiyle yayınlanan eğitim ve test 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. Ayrıca, ağırlık başarısını

arttırabilmek üzere, eğitim aşamasında kullanılan veri kümesine ölçeklendirme, döndürme, kaydırma, yansılama ve burkma gibi özellikler kullanılarak veri seti genişletilmiştir. Çalışmada kullanılan veri kümesinde ön işlem adımı olarak, insan yüzlerinin haricinde bulunan gürültülü alanlar veri kümesinden çıkartılmıştır. Böylelikle, maske tespiti için kullanılacak görüntülerdeki gereksiz alanlar sınıflandırma işleminin dışına alınmıştır. Gürültülerin temizleme sürecinin ardından orijinal görüntüye göre yeni görüntülerde boyut, derinlik gibi farklılıkların oluşmasına sebep olmuştur. Transfer öğrenme yöntemlerini doğru bir şekilde kullanılabilmesi için veri kümesi tekrardan boyutlandırma işlemine tabi tutularak 224 x 224 boyutuna dönüştürülmüştür. Elde edilen görüntüler ile deneysel değerlendirmeler gerçekleştirilmiştir.

Bu çalışmada, DenseNet121, EfficientNetMobile, NasNetMobile, InceptionV3, VGG19 ve InceptionResNetV2 derin öğrenme modelleriyle maske tespiti gerçekleştirilerek performansları karşılaştırılmıştır.

DenseNet121

Her katmanı diğer her katmanlara bağlayan ve katmanlar arasında yoğun bağlantıları nedeniyle DenseNet adını alan bu mimari Huang ve ark. (2016) tarafından önerilmiştir. DenseNet modelinin derinlikleri birbirinden farklı çeşitleri bulunmaktadır. Derinliği 121 olduğunda versiyonu DenseNet121 olarak adlandırılmaktadır ve modelin yapı taşı evrişim katmanlarından oluşan dense bloklardır (Güngör ve ark., 2021). DenseNet121 mimarisi bünyesinde 121 adet evrişim katmanından ve 1000 nöronluk tam bağlantılı katman meydana gelmektedir (Şekil 1).



Şekil 1. DenseNet121 Mimarisi (Eryılmaz ve Karacan, 2021)

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

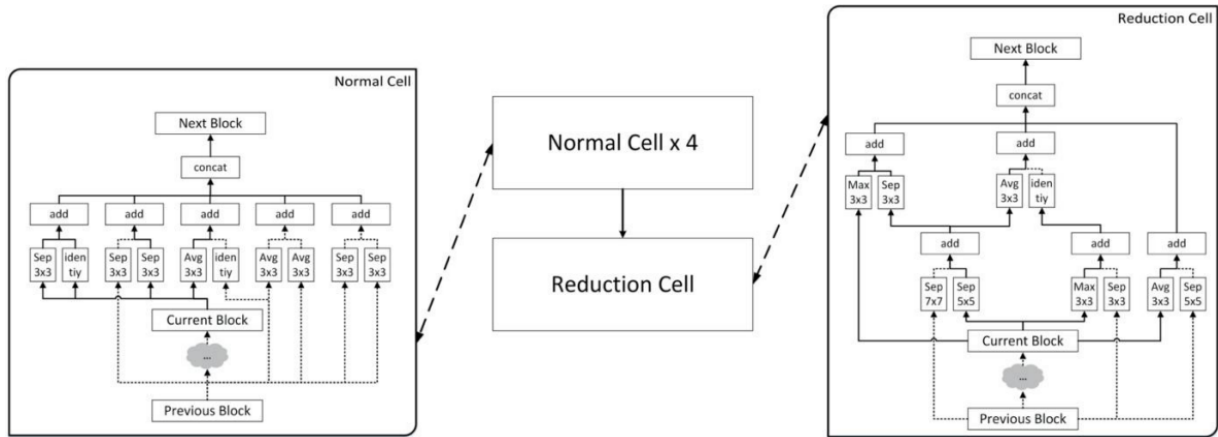
kayan nokta işlemlerinin (FLOPS) kullanımıyla ölçülen verimlilik ve doğruluk optimize edilmiştir (Hoang ve Jo, 2021).

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), parametre boyutu ve bellek erişim yükü açısından EfficientNet'teki bulunan modelin son aşamasında kullanılmamaktadır. Ayrıca 3x3 gibi küçük bir çekirdek boyutu tercih ettiği ve bu tercihin de azaltılmış alıcı alanı gerektirdiğinden fazladan katman eklenmesi gerçekleştirilir (Tan ve Le, 2021; Yavuz, 2020).

NasNetMobile

ImageNet veri tabanı kullanılarak önceden eğitilen bu model NasNet mimarisinin mobil ortamlar için olan türevlerinden birisidir (Herdian ve ark., 2019). Neural Architecture Search (Nöral Mimari Arama)'ün kısaltması olan NasNet, temel hücreleri barındıran, takviye eğitimiyle iyileştirilen ve ayrılabilir evrişim ve ortaklama gibi basit bloklardan oluşan bir CNN mimarisidir. NasNet temelli mimariler de ağlarının kapasitesine göre bu basit blokların tekrarlanması mantığına göre oluşmaktadır (Eryılmaz ve Karacan, 2021). Mimari 913 katmana sahip yapısı ve 224x224 giriş görüntü boyutu bulunmaktadır (Kaçmaz, 2020).

Mimari 769 katman ve 224x224 giriş boyutuna sahip olan NasNetMobile, 5,4 milyon kapasite ve 564 milyon çarpma kapasiteye sahip 12 hücreden oluşur (Şekil 2). Bu yaklaşımda evrişimli ağın genel konfigürasyonu el ile önceden belirlenir. Her biri aynı mimari ve farklı ağırlıklara sahip çok sayıda çoğaltılmış erişimli birimden oluşur. Herhangi bir ölçüğe ait görüntüler için basit şekilde ölçeklenebilir bir mimarinin oluşturulması için bir özellik eşlenirse, evrişimli birimin aynı boyuta sahip özellik haritasını döndürme rolü bulunmaktadır. Ayrıca, özellik haritasındaki yüksekliğin ve genişliğin iki katı olan özellik haritasının döndürülmesi şeklinde iki önemli rolü bulunmaktadır (Ba Alawi ve Qasem, 2021).



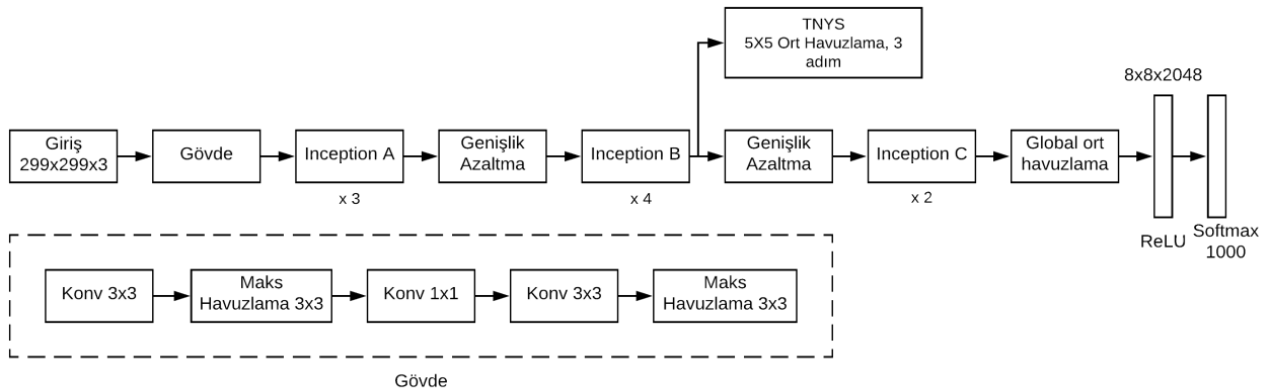
Şekil 2. NasNetMobile Mimarisi (Eryılmaz ve Karacan, 2021)

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).



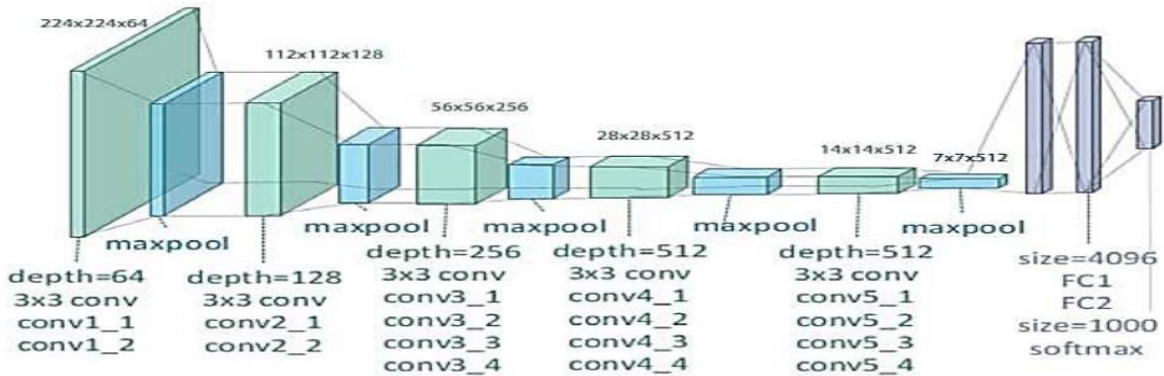
Şekil 3. InceptionV3 Mimarisi (Ashames, 2020)

Mimari 48 katman derinliği olan, 1x1, 3x3, 5x5 evrişim ile birleştirilen inception modüllerinin kullanıldığı ve VGGNet'e göre de daha verimli olduğu bilinmektedir. Şekil 3'de 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 amaç, ağın genişliğinin ve derinliğinin en iyi seviyelere getirerek yüksek bilgi akışı sağlamak olmuştur (Szegegy ve ark., 2015).

VGG19

VGG19 modeli, Oxford Üniversitesi Görsel Geometrik Grubu tarafından önerilen VGG modelinin 19 katmanlı olan versiyonudur (Simonyan ve 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 modellerindedir (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 4'de yer almaktadır (Başaran ve ark., 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 4. VGG19 Mimarisi (Simonyan ve Zisserman, 2014)

Bu çalışmada, maske tespitinin gerçekleştirilmesi için derin öğrenme algoritmalarından başarı oranları yüksek olan, DenseNet121, EfficientNetMobile, NasNetMobile, InceptionV3, InceptionResNetV2 ve VGG19 modelleri kullanılmıştır. Kullanılan modeller için Çizelge 1’de görülen değerler deneme yanılma yöntemiyle seçilerek deneysel değerlendirmeler yapılmıştır. Deneysel değerlendirmeler Python-keras ve tensorflow kütüphaneleri kullanılarak gerçekleştirilmiştir.

Çizelge 1. Modellerin Eğitiminde Kullanılan Parametreler

Parametreler	Değerler
Öğrenme oranı	0.00001
Tur sayısı	10
Yığın boyutu	32


BULGULAR VE TARTIŞMA

Çalışmada derin öğrenme modelleri ile deneysel analizler gerçekleştirilmiştir. Bu bölümde, COVID Face Mask Detection veri kümesi üzerinden maske tespit işlemini gerçekleştirebilmek için InceptionV3, VGG19, DenseNet121, EfficientNetV2M, InceptionResNetV2 ve NasNetMobile modelleri kullanılarak elde edilen deneysel sonuçlar sunulmuştur. Çalışmada kullanılan derin öğrenme modellerinin deneysel sonuçları Çizelge 2-7’de verilmiştir. Ayrıca, eğitim sonunda ortaya çıkan karmaşıklık matrisleri Şekil 5, Şekil 7, Şekil 9, Şekil 11, Şekil 13 ve Şekil 15’te, eğitim grafikleri ise Şekil 6, Şekil 8, Şekil 10, Şekil 12, Şekil 14 ve Şekil 16’da yer almaktadır.

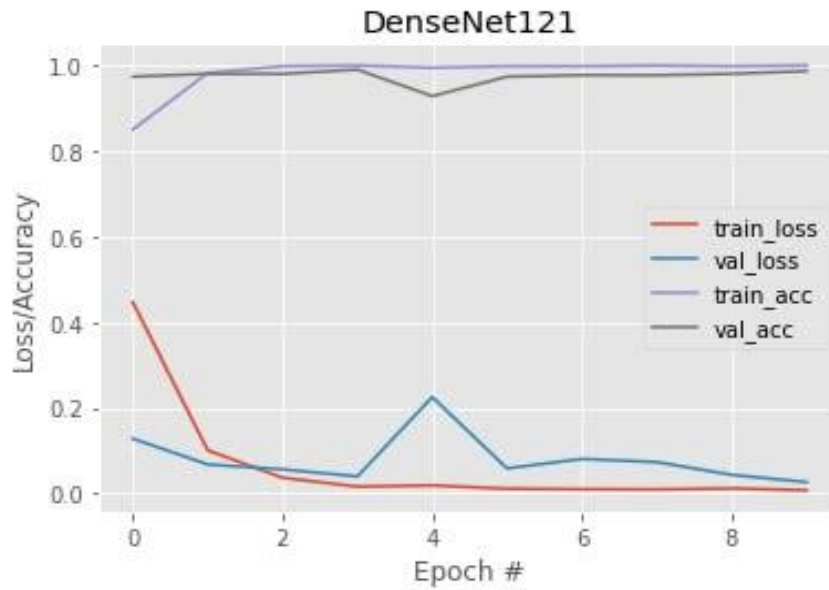
DenseNet121 modeliyle gerçekleştirilen eğitim sonucunda eğitim ve test verilerinin maskeli ve maskesiz olarak sınıflandırılmasıyla ilgili elde edilen kesinlik, geri çağırma ve f1-skor değerleri Çizelge 2’de yer almaktadır.

Çizelge 2. 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



Şekil 5. DenseNet Modeli Karmaşıklık Matrisi



Şekil 6. DenseNet Modeli Eğitim Grafiği

Çizelge 2’te 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 %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. DenseNet121 modeliyle elde edilen karmaşıklık matrisi ve eğitim aşamasında oluşan doğruluk/kayıp grafiği Şekil 5 ve 6 da verilmektedir.

Şekil 5’te DenseNet121 modeliyle eğitim sonunda oluşan 153 maskeli, 153 maskesiz test verisine ait karmaşıklık matrisi yer almaktadır. Matrise göre DenseNet121 modelinin, 153 maskesiz görüntüsünün 153’ünün maskesiz olarak sınıflandırdığı ve 153 maskeli görüntünün 149’unun maskeli ve 4’ünün maskesiz olarak sınıflandırdığı görülmektedir. Modelin maskesiz görüntüleri ayırt etmede başarılı olurken, maskeli görüntülerde az da olsa hatanın olduğu görülmektedir. DenseNet121 modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerine göre değişimi Şekil 6’da yer almaktadır. Şekildeki grafikten 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.


EfficientNetV2M modeliyle gerçekleştirilen eğitim sonucunda eğitim ve test verilerinin maskeli ve maskesiz olarak sınıflandırılmasıyla ilgili elde edilen kesinlik, geri çağırma ve f1-skor değerleri Çizelge 3’de yer almaktadır.

Çizelge 3. 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

Çizelge 3’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. EfficientNetV2M modeliyle elde edilen karmaşıklık matrisi ve eğitim aşamasında oluşan doğruluk/kayıp grafiği Şekil 7 ve 8 de verilmektedir.




Şekil 7. EfficientNetV2M Modeli Karmaşıklık Matrisi




Şekil 8. EfficientNetV2M Modeli Eğitim Grafiği

Şekil 7'de EfficientNetV2M modeliyle eğitim sonunda oluşan, 153 maskeli, 153 maskesiz test verilerine ait karmaşıklık 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. EfficientNetV2M modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerine göre değişimin yer aldığı Şekil 8'de yer alan grafikten 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.

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



Şekil 9. NasNetMobile Modeli Karmaşıklık Matrisi



Şekil 10. NasNetMobile Modeli Eğitim Grafiği

Çizelge 4. 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

Çizelge 4'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 %100, geri çağırma değeri %99 ve f1-skor değerinin ise %99 olduğu, maskeli (1) veriler için ise kesinlik değeri %99, geri çağırma değeri %100 ve f1-skor değerinin ise %99 olduğu

görülmektedir. NasNetMobile modeliyle elde edilen karmaşıklık matrisi ve eğitim aşamasında oluşan doğruluk/kayıp grafiği Şekil 9 ve 10 da verilmektedir.


Şekil 9'da NasNetMobile modeliyle eğitim sonunda oluşan, 153 maskeli, 153 maskesiz test verilerine ait karmaşıklık matrisi yer almaktadır. Matrise göre NasNetMobile modelinin, 153 maskesiz görüntüsünün 152'sinin maskesiz ve 1'inin maskeli olarak sınıflandırdığı ve 153 maskeli görüntüsünün 152'sinin maskeli ve 1'inin maskesiz olarak sınıflandırdığı görülmektedir. Modelin maskesiz görüntüleri ve maskeli görüntüleri ayırt etmede çok az hatanın olduğu görülmektedir. NasNetMobile modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerine göre değişimin yer aldığı Şekil 10'da yer alan grafikten 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.

InceptionV3 Modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerinin maskeli ve maskesiz olarak sınıflandırılmasıyla ilgili elde edilen kesinlik, geri çağırma ve f1-skor değerleri Çizelge 5'de yer almaktadır.


Çizelge 5. 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

Çizelge 5'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 %99 ve f1-skor değerinin ise %99 olduğu görülmektedir. InceptionV3 modeliyle elde edilen karmaşıklık matrisi ve eğitim aşamasında oluşan doğruluk/kayıp grafiği Şekil 9 ve 10 da verilmektedir.



Şekil 11. InceptionV3 Modeli Karmaşıklık Matrisi



Şekil 12. InceptionV3 Modeli Eğitim Grafiği


Şekil 11’de InceptionV3 modeliyle eğitim sonunda oluşan, 153 maskeli, 153 maskesiz test verilerine ait karmaşıklık 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. InceptionV3 modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerine göre değişimin yer aldığı Şekil 12’de yer alan grafikten anlaşılacağı 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.

VGG19 modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerinin maskeli ve maskesiz olarak sınıflandırılmasıyla ilgili elde edilen kesinlik, geri çağırma ve f1-skor değerleri Çizelge 6’da yer almaktadır.

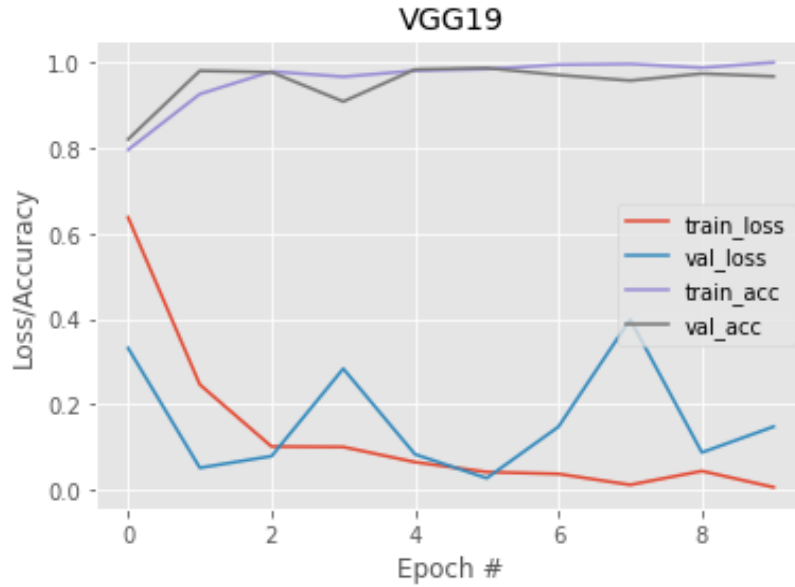
Çizelge 6. VGG19 Modeli Sınıflama Raporu

	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

Çizelge 6’da 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. VGG19 modeliyle elde edilen karmaşıklık matrisi ve eğitim aşamasında oluşan doğruluk/kayıp grafiği Şekil 9 ve 10 da verilmektedir.



Şekil 13. VGG19 Modeli Karmaşıklık Matrisi



Şekil 14. VGG19 Modeli Eğitim Grafiği


Şekil 13'te VGG19 modeliyle eğitim sonunda oluşan, 153 maskeli, 153 maskesiz test verilerine ait karmaşıklık 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. VGG19 modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerine göre değişimin yer aldığı Şekil 14'te yer alan grafikteki bilgilere göre, kaybın eğitim verileriyle test verileri arasında çok farklı olduğu, doğruluk değerlerinin ise eğitim verilerinde test verilerinden daha fazla olduğu anlaşılmaktadır. Değerlerin eğitim boyunca artış ve azalışlarının düzensiz gerçekleşmesine karşın eğitim sonunda kabul edilebilir doğruluk elde edildiği görülmektedir.

InceptionResNetV2 modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerinin maskeli ve maskesiz olarak sınıflandırılmasıyla ilgili elde edilen kesinlik, geri çağırma ve f1-skor değerleri Çizelge 7'de yer almaktadır.

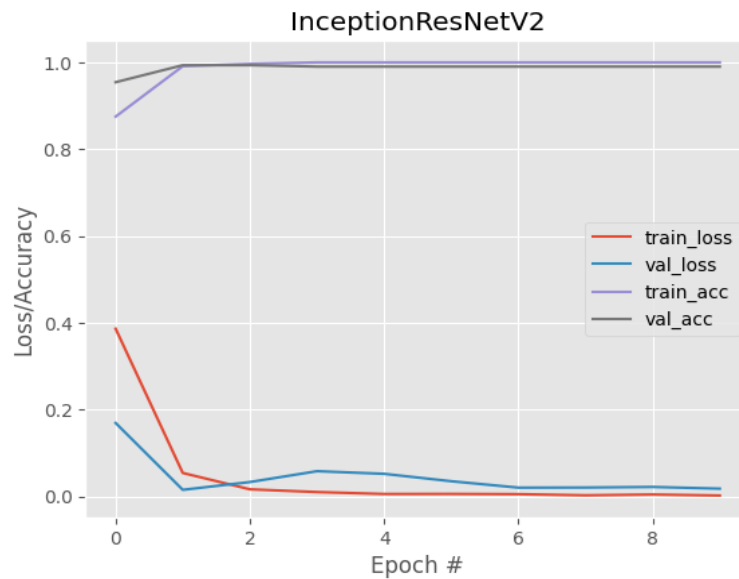
Çizelge 7. InceptionResNetV2 Modeli Sınıflama Raporu

	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

Çizelge 7’de görüldüğü gibi eğitim verileri için, kesinlik, geri çağırma ve f1-skor değerlerinde %99’luk oranlar 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. InceptionResNetV2 modeliyle elde edilen karmaşıklık matrisi ve eğitim aşamasında oluşan doğruluk/kayıp grafiği Şekil 9 ve 10 da verilmektedir.



Şekil 15. InceptionResNetV2 Modeli Karmaşıklık Matrisi



Şekil 16. InceptionResNetV2 Modeli Eğitim Grafiği

Şekil 15'te InceptionResNetV2 modeliyle eğitim sonunda oluşan, 153 maskeli, 153 maskesiz test verilerine ait karmaşıklık matrisi yer almaktadır. Matrise göre InceptionResNetV2 modelinin, 153 maskesiz görüntüsünün 153'ünün de 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 görüntüleri ayırt etmede çok az hata elde ettiği görülmektedir.

InceptionResNetV2 modeliyle gerçekleştirdiğimiz eğitim sonucunda eğitim ve test verilerine göre değişimin yer aldığı Şekil 16'da yer alan grafikteki bilgilere göre, kayıp ve doğruluk değerlerinin eğitim verileriyle test verileri arasında farkın olmadığı anlaşılmaktadır. Değerlerin eğitim boyunca artış ve azalışlarının genel olarak düzenli gerçekleştiği görülmektedir. Kullanılan tüm derin öğrenme modellerinin performans karşılaştırılması Çizelge 8'de yer almaktadır.

Çizelge 8. Kullanılan Modelleri Karşılaştırılması

Model Adı	Doğruluk	Kesinlik	Geri Çağırma	F1-Skor	Kayıp Değeri
DenseNet121	0.9869	0.99	0.99	0.99	0.0262
EfficientNetV2M	0.9902	0.99	0.99	0.99	0.0324
NasNetMobile	0.9935	0.99	0.99	0.99	0.0108
InceptionV3	0.9935	0.99	0.99	0.99	0.0269
VGG19	0.9673	0.97	0.97	0.97	0.1483
InceptionResNetV2	0.9902	0.99	0.99	0.99	0.0179

Yapılan tüm deneylerde en iyi başarı oranının NasNetMobile ile edildiği görülmektedir. Kullanılan modeller arasında ikinci en iyi başarı oranı InceptionV3 modeliyle doğruluk %99.35, kesinlik, geri çağırma ve f1-skor değerleri %99 oranları elde edilmiştir.

SONUÇ

2019 sonunda ilk olarak Çin'de ortaya çıkarak 2020 yılının ilk yarısında tüm dünyaya yayılan Covid-19 virüsü sonunda uyulması gereken tedbirlerden maske, mesafe ve hijyen konusunda bulaşın ilk zamanlarından itibaren tüm dünyada 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. Çalışmada maske tespiti gerçekleştirmek için derin öğrenme modelleri kullanılmıştır. Deneysel değerlendirmeler sonucunda, en başarılı sonucun NasNetMobile modeliyle %99.35 doğruluk oranıyla gerçekleştiği görülmüştür. Gelecekteki 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.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

Yazar Katkısı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder.

KAYNAKLAR

- 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 Enstitüsü, Karaman.
- 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.
- Aydemir, F., & Arslan, S. (2021). COVID-19 Pandemi Sürecinde Çocukların El Yıkama Alışkanlığının Nesnelere 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.
- 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*, (24), 149-156.
- Bozkurt, F. (2022). A deep and handcrafted features-based framework for diagnosis of COVID-19 from chest x-ray images. *Concurrency and Computation: Practice and Experience*, 34(5), e6725.
- Cerit, B. (2020). Gerçek Zamanlı Öğrenci Takip Sistemi ve Derin Öğrenme Yaklaşımı ile Maske Tespiti. (Yüksek Lisans Tezi), Karabük Üniversitesi Mekatronik Mühendisliği Ana Bilim Dalı, Karabük.
- 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.
- DSÖ. (2022). Advice for the public on COVID-19 – World Health Organization. <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/advice-for-public> (Erişim tarihi: 26.12.2022)
- 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.
- 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.
- 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.
- 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>
- 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).
- Hoang, V.-T., & Jo, K.-H. (2021). Practical Analysis on Architecture of EfficientNet. 2021 14th International Conference on Human System Interaction (HSI), 1-4.

- Jasim, A. A. (2022). Gerçek Zamanlı Yüz Maskesi Algılama Uyarı Sistemi. (Yüksek Lisans Tezi), Kırşehir Ahi Evran Üniversitesi İleri Teknolojiler Ana Bilim Dalı, Kırşehir.
- Kaçmaz, R. N. (2020). Mining Colonoscopy Images For Abnormality Detection. (Doktora Tezi), Abdullah Gül Üniversitesi Elektrik ve Bilgisayar Mühendisliği Ana Bilim Dalı, Kayseri.
- Kaur, G., Sinha, R., Tiwari, P. K., Yadav, S. K., Pandey, P., Raj, R., ... & Rakhra, M. (2022). Face mask recognition system using CNN model. *Neuroscience Informatics*, 2(3), 100035.
- 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.
- Nagrath, P., Jain, R., Madan, A., Arora, R., Kataria, P., & Hemanth, J. (2021). SSDMNV2: A real time DNN-based face mask detection system using single shot multibox detector and MobileNetV2. *Sustainable cities and society*, 66, 102692.
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv 1409.1556.
- Susanto, S., Putra, F. A., Analia, R., & Suciningtyas, I. K. L. N. (2020, October). The face mask detection for preventing the spread of COVID-19 at Politeknik Negeri Batam. In 2020 3rd International conference on applied engineering (ICAE) (pp. 1-5). IEEE.
- 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.
- Tan, M., & Le, Q. V. (2021). EfficientNetV2: Smaller Models and Faster Training (arXiv:2104.00298). arXiv. <http://arxiv.org/abs/2104.00298>
- 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.