



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

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK
DERİ LEZYON GÖRÜNTÜLERİNDEN MAYMUN ÇİÇEĞİ
HASTALIĞININ TESPİTİ

YÜKSEK LİSANS TEZİ

MUHAMMET TALHA ENGİN

DANIŞMAN
DOÇ. DR. KEMAL ADEM

AKSARAY 2023

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

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK
DERİ LEZYON GÖRÜNTÜLERİNDEN MAYMUN ÇİÇEĞİ
HASTALIĞININ TESPİTİ

YÜKSEK LİSANS TEZİ

MUHAMMET TALHA ENGİN

DANIŞMAN
DOÇ. DR. KEMAL ADEM

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 : Muhammet Talha
Soyadı : ENGİN
Bölümü : Yönetim Bilişim Sistemleri
İmza :

Teslim tarihi : 07/06/2023

TEZİN

Türkçe Adı : Derin Öğrenme Yöntemleri Kullanılarak Deri Lezyon Görüntülerinden Maymun Çiçeği Hastalığının Tespiti

İngilizce Adı : Detecting Monkeypox Disease from Skin Lesion Images Using Deep Learning Methods.

ETİK İLKELERE UYGUNLUK BEYANI

Tez yazma sürecinde bilimsel ve etik ilkelere uyduğumu, yararlandığım tüm kaynakları kaynak gösterme ilkelerine uygun olarak kaynakçada belirttiğimi ve bu bölümler dışındaki tüm ifadelerin şahsıma ait olduğunu beyan ederim.

Yazar Adı Soyadı: Muhammet Talha ENGİN

İmza:

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

Muhammet Talha ENGİN tarafından hazırlanan “Derin Öğrenme Yöntemleri Kullanılarak Deri Lezyon Görüntülerinden Maymun Çiçeği Hastalığının 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: Doç. Dr. Rahmi BAKİ

Yönetim Bilişim Sistemleri, Aksaray Üniversitesi

.....

Üye: Dr. Öğr. Cengiz COŞKUN

Bilgisayar Mühendisliği, Sivas Bilim ve Teknoloji Üniversitesi

.....

Tez Savunma Tarihi: 22/06/ 2023

TEŞEKKÜR

Çalışmam boyunca bana rehberlik eden ve desteklerini esirgemeyen danışman hocam Sayın Doç. Dr. Kemal ADEM'e minnettarlığımı ifade etmek isterim. Ayrıca, jüri üyelerine değerli görüşleri ve katkıları için teşekkür ederim. Her zaman yanımda olan eşim Saliha ŞUA ENGİN'e içtenlikle teşekkürlerimi sunarım ve aileme, sürekli destek ve yardımlarını esirgememeleri için minnettarım.

AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK
DERİ LEZYON GÖRÜNTÜLERİNDEN MAYMUN ÇİÇEĞİ
HASTALIĞININ TESPİTİ
(Yüksek Lisans Tezi)

Muhammet Talha ENGİN, Aksaray 2023

ÖZET

Maymun çiçeği hastalığı virüsü, COVID-19'dan kurtulmaya çalışırken yeni bir salgın tehdidi oluşturmaktadır. Maymun çiçeği hastalığı, COVID-19 kadar ölümcül ve bulaşıcı olmasa da her gün yeni hasta vakaları kaydedilerek küresel bir salgına dönüşme potansiyeli göstermektedir. Tıbbi görüntüleme alanında Derin Öğrenme teknikleri, bir kişinin hangi hastalığa sahip olduğunu tespit etme konusunda umut vericidir. Maymun çiçeği virüsü bulaşmış deri lezyon görüntüleri, hastalığın erken teşhisi için kullanılabilir. Ancak Dünya Sağlık Örgütü tarafından onaylanmış bir veritabanı mevcut değildir. Derin öğrenme modellerini eğitmek için doğru bir şekilde görüntü veri kümesi oluşturmak önemlidir. Bu çalışma, iki bölümden oluşmaktadır. İlk bölüm, Monkeypox Skin Image Dataset (MSID) veri kümesi ile eğitilmiş bir derin öğrenme modeli sunmaktadır. İkinci bölüm ise Monkeypox Skin Image Dataset (MSID), Monkeypox Master (MM) ve Monkeypox Orijinal Images (MOI) veri kümelerinden oluşturulan birleştirilmiş bir veri kümesi ile eğitilmiş bir derin öğrenme modeli sunmaktadır. Bu görüntüler, çeşitli açık kaynak ve çevrimiçi kaynaklardan toplanmış olup araştırma amaçlı kullanıma uygundur. Bu çalışmada, DenseNet201, InceptionResNetV2, InceptionV3, NASNetLarge ve Xception olmak üzere beş farklı derin öğrenme modeli, oluşturulan iki farklı veritabanında denenmiş ve karşılaştırılmıştır. Artırılmış veri kümeleri bu çalışmada kullanılarak, maymun çiçeği hastalığını %99,33 ve %98,52 doğruluk oranlarıyla sırayla MSID ve HİBRİD veri kümelerinde tanımlayabilen DenseNet201 modeli değerlendirilmiş ve önerilmiştir. Önerilen model, olası bir pandeminin önüne geçerek insan sağlığını korumaya yardımcı olarak insan sağlığının korunmasına katkıda bulunacaktır.

Bilim Kodu: 92418, 92432, 92431

Anahtar Kelimeler: Maymun Çiçeği Hastalığı, Virüs, Derin Öğrenme, DenseNet201

Sayfa Sayısı: 73

AKSARAY UNIVERSITY
GRADUATE SCHOOL OF SOCIAL SCIENCES
DETECTING MONKEYPOX DISEASE SKIN LESION IMAGES
USING DEEP LEARNING METHODS

(Master Thesis)

Muhammet Talha ENGİN, 2023

ABSTRACT

Monkeypox disease virus, while trying to recover from COVID-19, poses a new outbreak threat. Although Monkeypox disease is not as deadly and contagious as COVID-19, it has the potential to evolve into a global pandemic with new cases being reported daily. Deep Learning techniques in medical imaging offer promising prospects for identifying which disease a person has. Images of skin lesions infected with Monkeypox virus can be used for early detection of the disease. However, there is currently no approved database by the World Health Organization. It is crucial to create a proper image dataset to train deep learning models accurately. This study consists of two parts. The first part presents a deep learning model trained with the Monkeypox Skin Image Dataset (MSID). The second part presents a deep learning model trained with a combined dataset created from Monkeypox Skin Image Dataset (MSID), Monkeypox Master (MM), and Monkeypox Original Images (MOI) datasets. These images are collected from various open-source and online sources and suitable for research purposes. In this study, five different deep learning models, namely DenseNet201, InceptionResNetV2, InceptionV3, NASNetLarge, and Xception, are tested and compared on the two created databases. By utilizing augmented datasets, the DenseNet201 model is evaluated and recommended, achieving identification of monkeypox disease with an accuracy of 99.33% and 98.52% on the MSID and HYBRID datasets, respectively. The proposed model contributes to the preservation of human health by preventing a potential pandemic.

Science Code: 92431, 92432, 92418

Key Words: Monkeypox Disease, Virus, Deep Learning, DenseNet201

Number of Pages: 73

Advisor: Assoc. Prof. Dr. Kemal ADEM

İÇİNDEKİLER

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU	i
ETİK İLKELERE UYGUNLUK BEYANI	ii
JÜRİ ONAY SAYFASI	iii
TEŞEKKÜR	iv
ÖZET.....	v
ABSTRACT	vi
TABLO LİSTESİ.....	ix
ŞEKİLLER LİSTESİ.....	x
KISALTMA VE SİMGE LİSTESİ.....	xii
1. GİRİŞ.....	1
1.1. ARAŞTIRMANIN AMACI	2
1.2. ARAŞTIRMANIN KAPSAMI.....	3
1.3. ARAŞTIRMANIN ÖNEMİ	4
2. LİTERATÜR TARAMASI	6
3. KURAMSAL TEMELLER	10
3.1. MAYMUN ÇİÇEĞİ HASTALIĞI (MONKEYPOX)	10
3.1.1. Hastalığa Yakalanmamak için Alınması Gereken Önlemler	11
3.2. GÖRÜNTÜ KÜMELERİNDE NESNE TESPİTİ	12
4. MATERYAL VE YÖNTEM.....	14
4.1. VERİ SETLERİNİN OLUŞTURULMASI VE SINIFLANMASI	14
4.2. DERİN ÖĞRENME (MAKİNE ÖĞRENİMİ)	16
4.3. EVRİŞİMLİ SİNİR AĞLARI (CNN-CONVOLUTIONAL NEURAL NETWORK).....	17
4.3.1. Evrişim Katmanı	18
4.3.2. Havuzlama Katmanı.....	19
4.3.3. Aktivasyon Fonksiyonları (ReLU Katmanı)	19
4.3.4. Optimizasyon (Optimizer).....	21
4.3.5. Tam Bağlı Katman.....	22
4.4. ÇALIŞMADA TERCİH EDİLEN MODELLER	22
4.4.1. DenseNet201	22
4.4.2. NasNetLarge	23
4.4.3. InceptionV3	24
4.4.4. InceptionResNetV2	25
4.4.5. Xception	26
4.5. PERFORMANS METRİKLERİ.....	27

4.5.1.	Karışıklık Matrisi	27
4.5.2.	Doğruluk (Accuracy) Değeri	28
4.5.3.	Kesinlik Değeri	29
4.5.4.	Geri Çağırma (Recall) Değeri.....	29
4.5.5.	F1 Skor Değeri.....	30
4.6.	MODEL EĞİTİMİNDE KULLANILAN HİPER PARAMETRELER	30
4.6.1.	Eğitim (Training)	30
4.6.2.	Öğrenme Oranı (Learning Rate)	30
4.6.3.	Epoch.....	31
4.6.4.	Batches	31
5.	BULGULAR.....	33
5.1.	DENSENET201 MODELİ İLE GERÇEKLEŞTİRİLEN ANALİZ SONUÇLARI.....	35
5.2.	INCEPTIONRESNETV2 MODELİYLE GERÇEKLEŞTİRİLEN ANALİZ SONUÇLARI.....	37
5.3.	INCEPTIONV3 MODELİYLE GERÇEKLEŞTİRİLEN ANALİZ SONUÇLARI	39
5.4.	XCEPTION MODELİYLE GERÇEKLEŞTİRİLEN ANALİZ SONUÇLARI.....	41
5.5.	NASNETLARGE MODELİYLE GERÇEKLEŞTİRİLEN ANALİZ SONUÇLARI	44
5.6.	MODELLERİN PERFORMANS VE ÖZELLİK KARŞILAŞTIRMASI.....	46
6.	SONUÇ VE ÖNERİLER.....	49
7.	KAYNAKÇA.....	51
	EKLER	57
	AKSARAY ÜNİVERSİTESİ TEZ DEĞERLENDİRME FORMU	58

TABLO LİSTESİ

Tablo 1: Karışıklık Matrisi	28
Tablo 2: Derin Öğrenme Modellerinde Kullanılan Değişkenler	34
Tablo 3: DenseNet201 Modelinin Performans Değerlendirmesi	35
Tablo 4: DenseNet201 Modelinin Sınıflandırma Performans Analizi.....	36
Tablo 5: InceptionResNetV2 Modelinin Performans Değerlendirmesi	37
Tablo 6: InceptionResNetV2 Modelinin Sınıflandırma Performans Analizi	39
Tablo 7: InceptionV3 Modelinin Performans Değerlendirmesi	39
Tablo 8: InceptionV3 Modelinin Sınıflandırma Performans Analizi	41
Tablo 9: Xception Modelinin Performans Değerlendirmesi	41
Tablo 10: Xception Modelinin Sınıflandırma Performans Analizi.....	43
Tablo 11: NasNetLarge Modelinin Performans Değerlendirmesi	44
Tablo 12: NasNetLarge Modelinin Sınıflandırma Performans Analizi	45
Tablo 13: Modellerin Performans Karşılaştırması.....	46

ŞEKİLLER LİSTESİ

Şekil 1:Maymun Çiçeği Hastalığı Virüsü (DSÖ, 2022).....	10
Şekil 2: Nesne Algılama Senaryosu	13
Şekil 3: Maymun Çiçeği Hastalığı Olan Veri Seti Örnekleri	15
Şekil 4: Maymun Çiçeği Hastalığı Olmayan Veri Seti Örnekleri	15
Şekil 5: Derin Öğrenmenin Temel Mimarisi (Isaksson, 2018).....	16
Şekil 6: Derin Öğrenme Yaklaşımları (Kaya & Önal, 2021)	17
Şekil 7: Evrişimli Sinir Ağı Temel Yapısı	18
Şekil 8: Görüntünün Evrişim İşlemi ve Çıktı Oluşturma Süreci	18
Şekil 9: Havuzlama Katmanlarının Maksimum ve Ortalama Değerleri (Doğan, 2020).....	19
Şekil 10: Veri Aktarımı İçin Tam Bağlı Katmanda Veri Düzleştirme İşlemi	22
Şekil 11: DenseNet201 Mimarisi	23
Şekil 12 : NasNetLarge Mimarisi	24
Şekil 13: InceptionV3 Mimari Yapısı	24
Şekil 14: InceptionResNetV2 Mimarisi (Ashames, 2020)	26
Şekil 15: Colab Pro Jupyter Görünümü	33
Şekil 16: MSID Veri Kümesinin Dağılımı	34
Şekil 17: HİBRİD Veri Kümesinin Dağılımı	34
Şekil 18: DenseNet201 Modelinin Eğitim İlerlemesi Grafiği	35
Şekil 19: DenseNet201 Modelinin Karışıklık Matrisi Analizi	36
Şekil 20: InceptionResNetV2 Modelinin Eğitim İlerlemesi Grafiği	38
Şekil 21: InceptionResNetV2 Modelinin Karışıklık Matrisi Analizi.....	38
Şekil 22: InceptionV3 Modelinin Eğitim İlerlemesi Grafiği.....	40
Şekil 23: InceptionV3 Modelinin Karışıklık Matrisi Analizi	41
Şekil 24: Xception Modelinin Eğitim İlerlemesi Grafiği	42
Şekil 25: Xception Modelinin Karışıklık Matrisi Analizi	43
Şekil 26: NasNetLarge Modelinin Eğitim İlerlemesi Grafiği	44
Şekil 27: NasNetLarge Modelinin Karışıklık Matrisi Analizi.....	45



KISALTMA VE SİMGE LİSTESİ

DSÖ	World Health Organization (WHO)
ReLU	Doğrusal Düzeltme Etkinleştirme Fonksiyonu
f	Etkinleştirme Fonksiyonu
CNN	Convolutional Neural Network
TP/DP	Doğru Pozitif
FP/YP	Yanlış Pozitif
FN/YN	Yanlış Negatif
TN/DN	Doğru Negatif
NAS	Neural Architecture Search

1. GİRİŞ

Yüksek bir enfeksiyon hızıyla zaman ve mekândan bağımsız olarak yayılan bir hastalık salgını olarak tanımlanır (Tütüncü ve Esen, 2021). Tarihsel olarak, dünya çapında veya çeşitli bölgelere yayılan salgın hastalıkların var olduğu bilinmektedir. Kolera, veba, verem ve cüzzam gibi hastalıkların insan hayatını etkilediği iyi bilinmektedir (Cerit, 2020). Ülkemizin coğrafi konumu, doğal güzellikleri ve zenginlikleri, çeşitli nedenlerden dolayı salgın hastalıkların ortaya çıkması ve yayılması için uygun bir ortam oluşturmaktadır. Savaşlar, ticari faaliyetler ve göç gibi farklı sebeplerden kaynaklanan salgın hastalıklar, milyonlarca insanın ölümüne yol açmıştır (Özer, 2020).

Son yıllarda dünya genelinde yeni bir salgın hastalık olan Covid-19 ve Maymun Çiçeği Hastalığı ile karşı karşıyayız. Aralık 2019'da Çin'in Wuhan şehrinde görülmüş ve hızlı bir şekilde dünya geneline yayılmıştır. 11 Mart 2020 tarihinde Ülkemizde ise ilk vaka tespit edilmiştir. Covid-19 solunum yollarını hedef alan bir hastalıktır ve zaman içinde diğer salgın hastalıklardan daha tehlikeli hale gelmiştir (Güngör vd., 2021).

Maymun çiçeği (monkeypox), viral bir zoonotik hastalıktır ve çiçek hastalığına benzer döküntülere neden olur. Ancak çiçek hastalığına göre daha düşük bir yayılma hızı ve ölüm oranına sahiptir (Nalca A, 2005). Maymun çiçeği hastalığı ilk olarak 1958 yılında Danimarka'da yapılan maymun araştırmalarında tespit edilmiştir. Hastalık, Poxviridae ailesine ait bir virüs olan maymun çiçeği virüsü tarafından oluşturulur ve çiçek hastalığı ve çiçek hastalığı aşısı virüsüyle yakından ilişkilidir. Maymun çiçeği virüsü, Orthopoxvirüs cinsine ait bir zarflı, çift sarmallı DNA virüsüdür (Bunge EM, 2022).

Maymun çiçeği virüsü genellikle enfekte olan hayvana dokunma, deri ve mukoza lezyonu sıvısıyla temas etme, hayvanın salyası, hayvan tarafından ısırılma/tırmalanma, idrarı veya dışkısı gibi vücut sıvılarıyla temas veya hayvan ısırıkları yoluyla bulaşır. Bu tür invaziv maruziyetlerden sonra, bulaş yoluyla birlikte klinik belirtilerin değerlendirilmesi, sistemik hastalık gelişme riskinin daha yüksek olduğunu göstermektedir (Reynolds MG vd., 2006). Bununla birlikte, virüsün rezervuarı kesin olarak bilinmemektedir, ancak insan ve maymunların rastlantısal konakçılar olduğu ve kemirgenler aracılığıyla diğer hayvanlara bulaşabileceği düşünülmektedir (CDC, 2003).

Maymun çiçeği virüsü, damlacık yoluyla da bulaşabilir. Kişisel koruyucu ekipmanın olmadığı durumlarda, yakın mesafede yüz yüze temas halinde bulunulmasıyla damlacık

yoluyla bulaşma gerçekleşebilir. En az 3 saat boyunca 2 metreden daha yakın mesafede bulunma, bulaşma riskini artırabilir. İnsandan insana bulaşma potansiyeli, R0 (reprodüksiyon numarası) adı verilen bir modelleme yöntemiyle değerlendirilmiş ve maymun çiçeği virüsünün salgın potansiyeline sahip olduğu belirlenmiştir (Grant R vd. 2020). Dünya Sağlık Örgütü (DSÖ) 2022 yılında, Nijerya, Gana, Kongo, Kamerun gibi birçok Afrika ülkesini hastalık için endemik bölge ilan etmiş ve bu ülkelerde kısa süre içinde 1238 vaka ve 57 ölüm bildirilmiştir (WHO, 2022). Küresel maymun çiçeği salgını, 23 Temmuz 2022'de küresel düzeyde önemli olan bir halk sağlığı acil durum (PHEIC) ilan edildi (WHO, 2022).

İnsandan insana bulaşma düşük olmasına rağmen, 2022 yılında özellikle cinsel temas sırasında enfekte lezyonlarla doğrudan temas gibi faktörlerle endemik olmayan ülkelerde de maymun çiçeği vakaları bildirilmeye başlanmıştır (WHO, 2022). Dünya Sağlık Örgütü (DSÖ), çiçek hastalığının kontrol altına alınması ve aşılama programlarının sona ermesi nedeniyle maymun çiçeği vakalarında artış olabileceğini göz önünde bulundurarak hastalığı düzenli olarak izlemektedir. Hızla yayılarak ölümcül bir hal almasının en önemli nedeni, günümüz teknolojilerinin ilerlemesiyle insanlar arasındaki etkileşimin farklı yollarla artmasıdır (Aslan, 2021). Salgın döneminde, ulaşım ve iletişim kanallarının gelişimi, kontrol sürecini zorlaştırsa da, teknoloji farklı alanlarda olumlu bir şekilde kullanılmıştır. Sağlık hizmetlerinin planlanması ve salgının kontrol altına alınması konularında özellikle teknolojik gelişmeler önemli bir rol oynamıştır (Tütüncü & Esen, 2021).

Bu süreçte, salgın hastalıkların etkilerini en aza indirmek ve yayılmasını kontrol altına almak için tıp ve teknoloji alanında önemli ilerlemeler kaydedilmektedir. İlerleyen dönemlerde bu gelişmelerin devam ederek daha etkili salgın önleme ve tedavi stratejilerinin geliştirilmesine katkı sağlanması umulmaktadır. Derin öğrenme yöntemleri ile farklı alanlarda çok sayıda görüntü sınıflandırma ve nesne tespiti çalışması yapılmıştır (Adem, 2022; Adem, 2023; Yurdasev, 2023; Kılıçarslan, 2021; Hekim, 2020; Yılmaz, 2023).

1.1. Araştırmanın Amacı

Çalışmamızın hedefi, derin öğrenme yöntemlerinin kullanılarak deri lezyon görüntülerinden maymun çiçeği hastalığının tespit edilmesi için bir otomatik teşhis sistemini geliştirmektir. Maymun çiçeği hastalığı, virüs kaynaklı bir enfeksiyon olup deride karakteristik lezyonlara neden olabilir. Geleneksel teşhis yöntemleri genellikle uzmanlar tarafından yapılan görsel muayeneye dayanmaktadır, ancak bu süreç zaman alıcı ve hatalara açıktır.

Bu tezde, derin öğrenme yöntemlerinin kullanımıyla maymun çiçeği hastalığının tespitinde otomatik bir sistem geliştirilmesi hedeflenmektedir. Deri lezyon görüntülerinden anlamlı özelliklerin çıkarılması ve sınıflandırma modellerinin oluşturulması için derin öğrenme algoritmaları ve derin sinir ağları kullanılacaktır.

Ayrıca, tezde kullanılacak derin öğrenme modelinin eğitimi için büyük bir deri lezyon görüntü veri kümesi oluşturulması planlanmaktadır. Bu veri kümesi, farklı tiplerde maymun çiçeği lezyonları içerecek ve çeşitli klinik durumları temsil edecektir. Veri kümesinin oluşturulması ve etiketlenmesi, uzman dermatologlar tarafından doğrulanacak ve kalite kontrol süreçlerine tabi tutulacaktır.

Son olarak, geliştirilen otomatik teşhis sisteminin performansının değerlendirilmesi ve gerçek dünya verileriyle test edilmesi planlanmaktadır. Sistemin doğruluk, hassasiyet ve özgüllük gibi performans metrikleri kullanılarak değerlendirilecektir. Ayrıca, sistemin uzman dermatologların teşhis yeteneğiyle karşılaştırılması ve sonuçların istatistiksel analizlerle desteklenmesi hedeflenmektedir.

Bu tez, derin öğrenme yöntemlerinin tıbbi teşhis süreçlerindeki potansiyelini göstermek amacıyla maymun çiçeği hastalığının tespiti üzerinde odaklanmaktadır. Geliştirilen otomatik teşhis sistemi, erken teşhis ve doğru sınıflandırma sağlayarak hastaların tedavi sürecini iyileştirebilir ve sağlık uzmanlarının teşhis kararlarını destekleyebilir.

- Derin Öğrenme Yöntemleri Kullanılarak Deri Lezyon Görüntülerinden Maymun Çiçeği Hastalığının Tespiti çalışmasında “Monkeypox Skin Image Dataset” ve “Monkeypox Skin Image Dataset”, “Monkeypox Master” ve “Monkeypox Orijinal İmages” veri setlerinden oluşan hibrid veri setlerini kullanarak maymun çiçeği hastalığının deri üzerinde oluşturduğu lezyon görüntüleri görüntü işleme, Colab Pro, Python ve Keras’tan yararlanılarak tespit etmek,

- Bu çalışmada, hastalığın tespitinde DenseNet201, InceptionResNetV2, InceptionV3, NASNetLarge ve Xception gibi derin öğrenme modelleri kullanılacak ve doğru sonuçların başarıları karşılaştırılarak en iyi hastalık tespit modeli belirlenecektir.

1.2. Araştırmanın Kapsamı

Bu araştırma, maymun çiçeği hastalığının deri üzerinde oluşturduğu lezyonları tespit etmek amacıyla derin öğrenme yöntemlerini kullanmayı hedeflemektedir. Bu amaçla, "Monkeypox Skin Image Dataset", "Monkeypox Skin Image Dataset", "Monkeypox Master" ve

"Monkeypox Orijinal İmages" gibi veri setleri kullanılmıştır. Bu veri setleri, hastalığın deri lezyonlarını içeren görüntülerden oluşmaktadır.

Araştırma sürecinde, görüntü işleme teknikleri kullanılarak görüntüler önceden işlenir ve ön işleme aşamalarından geçirilir. Daha sonra, Colab Pro, Python ve Keras gibi araçlar kullanılarak derin öğrenme modelleri oluşturulur ve eğitilir.

Çalışmada, DenseNet201, InceptionResNetV2, InceptionV3, NASNetLarge ve Xception gibi derin öğrenme modelleri kullanılmaktadır. Bu modeller, farklı derin öğrenme mimarilerine sahip olup, maymun çiçeği hastalığının deri lezyonlarını tespit etmek amacıyla önceden eğitilmiş ağırlıklarla özelleştirilmiştir.

Araştırmanın amacı, farklı derin öğrenme modellerini kullanarak maymun çiçeği hastalığının deri lezyonlarını doğru bir şekilde tespit etmek ve bu modellerin başarılarını karşılaştırmaktır. Sonuçlar, doğruluk oranları ve diğer performans metrikleri kullanılarak değerlendirilir. En yüksek performansı gösteren model, maymun çiçeği hastalığının deri lezyonlarını tespit etmek için önerilen model olarak belirlenebilir.

Bu araştırma, maymun çiçeği hastalığının erken teşhisi ve tedavisi için önemli bir adım olabilir ve derin öğrenme tekniklerinin tıbbi teşhis alanında potansiyelini göstermektedir.

1.3. Araştırmanın Önemi

Bu araştırma, maymun çiçeği hastalığının deri üzerinde oluşturduğu lezyonların derin öğrenme yöntemleriyle tespit edilmesini hedeflemektedir. Maymun çiçeği hastalığı, bulaşıcı bir hastalıktır ve ciddi sağlık sorunlarına neden olabilen bir virüs tarafından tetiklenir. Hastalığın erken teşhisi ve tedavisi, hastaların daha hızlı bir şekilde uygun müdahale almasını sağlayarak iyileşme şanslarını artırabilir ve hastalığın yayılmasını kontrol altına alabilir.

Deri lezyonları, maymun çiçeği hastalığının karakteristik belirtilerinden biridir. Bu nedenle, deri lezyonlarının doğru ve hızlı bir şekilde tespit edilmesi, hastalığın teşhis sürecini kolaylaştırabilir. Geleneksel teşhis yöntemleri, deneyim ve uzmanlık gerektirebilir ve zaman alabilirken, derin öğrenme yöntemleri ile otomatik tespit ve teşhis yapmak daha hızlı ve etkili bir yaklaşım sunar.

Bu araştırmanın önemi, derin öğrenme modellerinin kullanımıyla maymun çiçeği hastalığının deri lezyonlarının hızlı ve doğru bir şekilde tespit edilebilmesinin sağlanmasıdır. Derin öğrenme modelleri, büyük miktarda veriyi analiz ederek örüntüleri ve karakteristikleri

tanıyabilir, böylece maymun çiçeği hastalığının deri lezyonlarını diğer deri rahatsızlıklarından ayırt edebilir.

Bu çalışma, hastalığın erken teşhisi ve tedavisi için önemli bir katkı sunmaktadır. Derin öğrenme tekniklerinin kullanılmasıyla, hastalığın teşhisi daha hızlı ve doğru bir şekilde yapılabilecek, tedavi süreci daha etkili bir şekilde yönlendirilebilecek ve hastaların sağlık sonuçları iyileştirilebilecektir. Ayrıca, erken teşhisin sağladığı bilgiler kullanılarak hastalığın yayılmasını kontrol altına almak için önlemler alınabilir ve halk sağlığına yönelik tedbirler etkin bir şekilde planlanabilir.

Sonuç olarak, maymun çiçeği hastalığının deri lezyonlarının derin öğrenme yöntemleriyle tespit edilmesi çalışması, hastalığın erken teşhisi ve tedavisi için önemli bir adımdır. Bu çalışma, yapay zekâ teknolojilerinin tıp alanında kullanımının artmasıyla birlikte, teşhis ve tedavi süreçlerinde yeni bir yaklaşım sunarak sağlık hizmetlerine değerli bir katkı sağlamaktadır.

2. LİTERATÜR TARAMASI

Günümüzde, derin öğrenme alanı büyük bir önem kazanmıştır ve çeşitli çalışmalar bu alanda gerçekleştirilmiştir. Bu çalışmaların analizi ve değerlendirmesi, mevcut bilgi birikimini anlamamızı ve bu alanda açıklanan sonuçlardan yararlanmamızı sağlayacaktır. Bu bölümde, maymun çiçeği hastalığının derin öğrenme yöntemleri kullanarak tespiti ile ilgili önceden yapılmış araştırmaların genel bir değerlendirmesini sunacağız. İlgili literatürü tararken, görüntü işleme kullanılan ve benzer çalışmalarda elde edilen sonuçlara ulaşarak çalışmamıza yol göstermesini amaçladık.

Chiranjibi, S. ve Tej B. S. (2022) önceden eğitilmiş 13 farklı derin öğrenme modelini kullanarak maymun çiçeği hastalığı görüntüleri üzerinde yapmış olduğu çalışmada Precision: 85.44%; Recall: 85.47%; F1-score: 85.40%; ve Accuracy: 87.13 başarı oranlarını elde etmiştir. Ayrıca çalışmasını kısıtlı veriler üzerinde gerçekleştirdiği veri kümesi arttırılarak performansın daha da iyileştirileceğini ifade etmiştir.

Shams N.A. vd. (2022) 3 farklı eğitilmiş model ile “Monkeypox Skin Lesion Dataset (MSLD)” 102 maymun çiçeği deri lezyon ve 126’sı diğer veri kümesinde yapmış oldukları büyütme sonrası 1428 ve 1764 görüntüden oluşan veri kümesinde yaptıkları çalışmada ResNet50, VGG16 ve InceptionV3 modelini kullanarak ResNet50 ile (%82,96±4,57) en yüksek güvenilirlik oranı elde edilmiştir. Derin öğrenme destekli geliştirdiği mobil uygulama ile maymun çiçeği hastalığını tespit edilme potansiyeli olabileceğini ortaya koymuştur.

Şahin, V.H. vd. (2022) pozitif ve negatif olarak sınıflandırılan veriler TensorFlow kullanılarak eğitildi. TensorFlow Lite modeli daha sonra maymun çiçeği tespiti için TensorFlow Lite kitaplığı ile birlikte mobil uygulamaya yerleştirildi. Sunulan sistem, vücut lezyonları olan kişilerin hızlı bir şekilde ön tanı koymasını sağlar. Böylece, maymun çiçeği ile enfekte olmuş kişiler, kesin bir teşhis için bir uzmana görünmeleri için hızlı hareket etmeye teşvik edilebilir. Test sonuçlarına göre sistem görüntüleri %91,11 doğrulukla sınıflandırabileceği görülmüştür.

Md, M.A. vd. (2022), ML modeli geliştirmek için genel kullanıma açık bir Maymun çiçeği veri seti mevcut olmadığından çalışmada ticari amaçlar dahil olmak üzere herhangi bir kısıtlama olmayan birçok açık kaynaklı ve çevrimiçi platformdan elde edilen görüntülerle "Maymun Çiçeği2022" adlı yeni bir veri seti sunmuştur. Çalışma birinci çalışma ve İkinci çalışma olmak üzere iki ayrı çalışmayı içeren bir modifiye edilmiş VGG16 modeli önermektedir. Yapılan keşifsel hesaplamalar, önerilen modelin Maymun çiçeği hastalarını

yüksek doğruluk oranlarıyla tespit edebileceğini göstermektedir. Birinci Çalışma için doğruluk oranı $97 \pm 1,8$ (AUC = 97,2) ve İkinci Çalışma için doğruluk oranı $88 \pm 0,8$ (AUC = 0,867) olarak hesaplanmıştır. Ayrıca, modelin tahminlerini ve özellik çıkarmayı açıklarken, Maymun çiçeği virüsünün başlangıcını karakterize eden belirli özelliklere daha derin bir içgörü sağlamak için Yerel Açıklanabilir Model-Bağımsız Açıklamaları (LIME) kullanmıştır. Bu çalışmada, Maymun çiçeği hastalığının teşhisi için ML tabanlı bir yaklaşımın potansiyelini göstermiş olup daha fazla araştırma ve veri setinin oluşturulması gerektiğini vurgulamıştır.

Md., E. H. vd. insan maymun çiçeği hastalığının görüntü tabanlı sınıflandırmasını gerçekleştirmek için derin transfer öğrenme tabanlı yöntemleri, bir konvolüsyonel blok dikkat modülü (CBAM) ile entegre etmeyi denemiş. VGG19, Xception, DenseNet121, EfficientNetB3 ve MobileNetV2 gibi beş derin öğrenme modelini, entegre kanal ve mekansal dikkat mekanizmalarıyla birlikte uygulamış ve aralarında karşılaştırmalı bir analiz gerçekleştirmiştir. Xception-CBAM-Dense katmanlardan oluşan bir mimari, diğer modellere göre insan maymun çiçeği ve diğer hastalıkları sınıflandırmada daha iyi bir performans sergilemiş ve doğrulama doğruluğu %83.89 olarak belirlenmiştir.

Altun, M. vd. (2023) çalışmasında MobileNetV3-s, EfficientNetV2, ResNET50, Vgg19, DenseNet121 ve Xception modelleri üzerinde uygulamış olup değerlendirme ve karşılaştırma için AUC, doğruluk, duyarlılık, kayıp ve F1-skor metrikleri kullanılmıştır. Optimizasyonu yapılmış hibrit MobileNetV3-s modeli, ortalama 0.98 F1-skor, 0.99 AUC, 0.96 doğruluk ve 0.97 duyarlılık elde ederek en iyi sonucu sağlamıştır. Bu çalışmada, evrişimli sinir ağları, hiperparametrelerin optimizasyonu ve özelleştirilmiş bir hibrit fonksiyon transfer öğrenme modeli ile birlikte kullanılarak özelleştirilmiş bir CNN modeli geliştirildiğinde etkileyici sonuçlar elde etmiştir.

Pacal, I. (2023) göğüs röntgeni görüntülerinden otomatik COVID-19 Teşhisi için Görü transformatörüne dayalı bir yaklaşım adlı çalışmasında derin öğrenmenin CNN tabanlı yaklaşımları gibi daha önceki tekniklerinden ziyade en güncel ve çok daha popüler bir mimarisi olan transformatör yöntemine dayalı bir teşhis sistemi önerdi. Bu sistem, görü transformatör modelleri temelli bir yaklaşım ve yeni bir veri seti olan COVID-QU-Ex üzerinde COVID-19 hastalığının daha efektif bir teşhisini içermektedir. Yaptığı deneysel çalışmasında, görü transformatör modellerinin CNN modellerinden daha başarılı olduğu gözlemlendiğini ifade ederek, ViT-L16 modeli %96'nın üzerinde test doğruluğu ve F1-skoru sunarak, literatürde benzer çalışmalara kıyasla çok daha yüksek bir başarımlı gösterdiğini ifade

etmiştir.

Akyel, C. (2023) Xception ile histopatolojik görüntülerden oral kanser teşhisi adlı çalışmasında mevcut literatürden farklı olarak Xception modeli ön eğitilmiş ve ardışık algoritmayla birlikte modifiye edilmiş şekilde kullanmıştır. Normal ve oral skuamöz hücreli kanserler şeklinde iki sınıfında bulunduğu eğitim aşamasında sırasıyla %98.70 eğitim başarısı, %97.20 zar doğruluğu, %96.50 hassasiyet ve %97 duyarlılık elde etmiştir. Elde ettiği bu değerler literatürde yer alan diğer bazı çalışmalarla karşılaştırılmıştır. Çalışmasında Xception modelinin Clahe ile birlikte oral kanser sınıflandırmasında uygun bir seçenek olduğu ve teşhis sürecinde yararlı olabileceği görülmüştür.

Diker, A. (2023) derin öğrenme yöntemlerini kullanarak beyin felcinin otomatik olarak sınıflandırılması adlı çalışmasında beyin felci sınıflandırmasında derin öğrenme tekniklerinin performans karşılaştırmasını sunmaktadır. EfficientNetB0, MobileNet-V2, ResNet18 ve VGG-16 gibi farklı derin öğrenme algoritmalarının performansı sırasıyla karşılaştırılmıştır. EfficientNetB0, MobileNet-V2, ResNet18 ve VGG-16 derin öğrenme modellerine ait sırasıyla 84.6%, 87.4%, 80.9% ve 92.6% doğruluk değerleri elde etmiştir.

Çeçen, Ş. ve Özer, A. B. (2023) patolojik meme kanseri görüntülerinin YOLOv5 algoritması ile sınıflandırılması adlı çalışmasında meme dokusundan alınan biyopsilere ait patolojik görüntüler yapay zekanın bir alt dalı olan derin öğrenme yöntemi ile incelenmiştir. Meme kanseri türünün sınıflandırılması üzerine çalışılmıştır. Derin Öğrenme modeli olarak YOLOv5 algoritması kullanılmıştır. Deneyler sonucunda doğruluk parametresinde %95,3 oranında yüksek başarı ile tümörün sınıflandırılması sağlanmıştır.

Tüfekçi, P. ve Gezici, B. (2023) derin öğrenme ile göğüs röntgeni görüntülerinden COVID-19 ve viral pnömoni tespiti adlı çalışmasında göğüs röntgeni görüntülerinden, COVID-19 ve viral pnömoni hastalıklarını ayırt etmeye çalışan, yüksek doğruluklu ve güvenilir bir model oluşturulmaya çalışılmıştır. Bu amaçla, derin öğrenme algoritmalarından olan Evrişimli Sinir Ağlarının AlexNet ve GoogleNet özel mimarilerinin, doğrudan orijinal halleri ve transfer öğrenmeyle geliştirilmiş halleri uygulanarak, geniş kapsamlı bir modelleme çalışması yapılmıştır. Modelleme sürecinde, kullanılan veri seti (COVID-19 Radiography Database) popüler bir veri seti olup, 3 sınıflı ve her sınıfta farklı sayıda örnek bulunduran dengesiz bir veri setidir. Bu veri setine, veri azaltma ve arttırma yöntemleri uygulanarak, her sınıfta eşit sayıda örnek içeren dengeli 2 yeni veri seti oluşturmuştur. Orijinal veri seti ve yeni oluşturulan veri setleri, 80-20 oranında eğitim ve test veri setine bölünerek ve aynı zamanda

3, 5 ve 10 kez apraz doęrulamaya gre blnerek, model performansları llmřtr ve en iyi performansa sahip model bulunmaya alıřmıřtır. Sonu olarak, en iyi model, veri arttırma yntemiyle dengeli hale getirilmiř veri setinin, 10 kez apraz doęrulamaya gre blnerek, transfer ęrenme ile geliřtirilmiř AlexNet mimarisinin uygulandıęı model olarak, % 99.90 doęruluk bařarısı ile tespit etmiřtir.



3. KURAMSAL TEMELLER


3.1. Maymun Çiçeği Hastalığı (Monkeypox)

Maymun çiçeği hastalığı, Orthopoxviridae ailesinden bir DNA virüsü olan maymun çiçeği virüsü (Monkeypox virus) tarafından neden olunan bir enfeksiyon hastalığıdır (Bunge EM, 2022). İnsanlarda çiçek hastalığına benzer semptomlara yol açar. Maymun çiçeği virüsü, doğal olarak vahşi hayvanlar arasında, özellikle ormanlarda yaşayan kemirgenler ve primatlar arasında dolaşır (CDC, 2003). İnsanlara, bu hayvanlarla temas sonucu veya maymun çiçeği hastalığına sahip insanlarla yakın temas sonucu bulaşabilir.

Maymun çiçeği hastalığı, özellikle Afrika'da ve Orta ve Batı Afrika ülkelerinde görülmektedir. İnsanlar arasında yayılabilen bir hastalıktır (WHO, 2022). Semptomlar genellikle ateş, baş ağrısı, kas ağrıları, halsizlik ve genel bir huzursuzluk hissi ile başlar. Daha sonra ciltte karakteristik kabarcıklar, kabuklanmalar veya ülserasyonlar ortaya çıkar. Hastalık genellikle hafif seyreder, ancak bazı vakalarda ciddi komplikasyonlara yol açabilir (WHO, 2022).

Maymun çiçeği hastalığının tedavisi semptomatik destek tedavisiyle sağlanır. Ateşin düşürülmesi, ağrı kesicilerin kullanılması ve lezyonların enfeksiyon riskini azaltmak için hijyen önlemlerinin uygulanması gibi yöntemler kullanılır. Aşılar, maymun çiçeği hastalığından korunmak için etkili bir yol olarak kullanılmaktadır (WHO, 2022).

Maymun çiçeği hastalığı genellikle insanlar arasında sınırlı sayıda vaka ile sınırlıdır. Ancak, bazı durumlarda salgınlara yol açabilir. Bu nedenle, hastalığın erken teşhisi, enfekte kişilerin izolasyonu ve enfeksiyonun yayılmasının önlenmesi için önemlidir.



Şekil 1:Maymun Çiçeği Hastalığı Virüsü (DSÖ, 2022)

Maymun çiçeği hastalığı enfeksiyonu genellikle iki döneme ayrılır:

İnvazyon Dönemi: Enfeksiyonun ilk dönemi olan invazyon dönemi, genellikle enfeksiyondan

sonraki 0-5 gün içinde ortaya çıkar. Bu dönemde, ateş, yoğun baş ağrısı, lenf bezlerinin şişmesi (lenfadenopati), sırt ağrısı, kas ağrıları ve şiddetli halsizlik gibi belirtiler görülür. Lenfadenopati, maymun çiçeği virüsü enfeksiyonunu diğer hastalıklardan (suçiçeği, kızamık, çiçek hastalığı gibi) ayıran önemli bir özelliktir.

Deri Döküntüsü Dönemi: İkinci dönem olan deri döküntüsü dönemi, genellikle ateşin başlamasından sonraki 1-3 gün içinde ortaya çıkar. Deri döküntüleri genellikle yüz ve ekstremitelerde yoğunlaşma eğilimindedir. Özellikle yüzde başlayan döküntüler (vakaların %95'inde) ve avuç içleri ile ayak tabanlarını etkiler (vakaların %75'inde). Ayrıca, oral mukozalar (vakaların %70'inde), genital bölge (%30) ve göz konjonktivası ile birlikte kornea da (%20) etkilenebilir. Döküntüler, başlangıçta düz lezyonlar olan maküllerden başlayarak, hafifçe kabarık sert lezyonlara (papüller), berrak sıvı ile dolu lezyonlara (veziküller), sarımsı sıvı ile dolu lezyonlara (püstüller) ve son olarak kuruyup dökülen kabuklara doğru değişim gösterir (CDC, WHO, 2022).

Maymun çiçeği hastalığı genellikle kendiliğinden düzelir ve semptomları genellikle 2 ila 4 hafta sürebilir. Şiddetli vakalar genellikle çocuklar arasında daha sık görülür. Maymun çiçeği virüsüne bağlı vaka ölüm oranı genel popülasyonda %0 ile %11 arasında değişirken, küçük çocuklar arasında daha yüksek olabilir.

3.1.1. Hastalığa Yakalanmamak için Alınması Gereken Önlemler

- Maymun çiçeği virüsünün bulaşabileceği hayvanlarla temas etmekten kaçının. Maymun çiçeği vakalarının olduğu bölgelerde hasta veya ölü hayvanlarla temas etmekten kaçınmak önemlidir.
- Hasta hayvanlarla temas etmiş olan kontamine malzemelerden uzak durun. Bu malzemeler enfeksiyonun bulaşmasına katkıda bulunabilir. Hasta hayvanlarla temas etmiş yüzeyleri, giysileri veya eşyaları temizlemek ve dezenfekte etmek gerekebilir.
- Enfekte hastaları, diğer insanlardan izole edin. Maymun çiçeği hastalarının enfeksiyonu yayma riskini azaltmak için izolasyon önlemleri alınmalıdır. Hasta kişilerin diğer insanlarla yakın teması sınırlandırılmalı ve gerekli koruyucu önlemler alınmalıdır.
- Enfekte hayvanlar veya insanlarla temas sonrasında iyi el hijyenine dikkat edin. Ellerinizi sık sık sabun ve suyla yıkamak, özellikle enfekte hayvan veya insanlarla temas sonrasında önemlidir. Alkol bazlı el dezenfektanları da kullanılabilir.

- Maymun çiçeği hastalarıyla temas halindeyken kişisel koruyucu ekipman (örneğin eldiven, maske) kullanın. Bu önlemler enfeksiyonun bulaşma riskini azaltmaya yardımcı olabilir. Özellikle sağlık çalışanları ve bakım verenler, kişisel koruyucu ekipman kullanarak enfeksiyonun yayılmasını engellemek için önemli bir rol oynar.

Bu önlemler, maymun çiçeği virüsü enfeksiyonunu önlemek ve yayılmasını engellemek için temel koruyucu önlemlerdir. Sağlık otoritelerinin ve yerel sağlık kuruluşlarının önerilerini dikkate almak ve güncel bilgilere başvurmak önemlidir.

3.2. Görüntü Kümelerinde Nesne Tespiti

Nesne tespiti, bir görüntüde bulunan birden fazla ögenin algılanması ve etiketlenmesi işlemidir (Alqadiri, 2022). Bu, bilgisayarların görsel görüntüleri okuyarak içerdikleri nesneleri algılayıp tanımlayabilme yeteneklerini ifade eder (Alkhder, 2021). Nesne tespiti çalışmalarındaki hedef, bir görüntünün içerisinde bulunan nesnelerin varlığını tespit ederek, bu nesnelerin konumlarını ve sınıflarını belirleyebilen bir sistem oluşturmaktır. Bu işlem genellikle hayali dikdörtgen sınırlayıcılar kullanılarak görüntüyü taramak suretiyle gerçekleştirilir (Resim 4'te gösterildiği gibi).

Son zamanlarda, bilgisayarla görme ve görsel algılama gibi alanlar, bilgisayar teknolojilerinin gelişimiyle birlikte artan ilgi görmektedir. Nesne tespiti, günlük yaşamımızda iş yerlerinde veya kişisel amaçlarla kullanılan bir ihtiyaç haline gelmiştir. Ayrıca, tarımsal işlemler, güvenlik amaçlı, tıbbi görüntüleme, otomatik sürüş teknolojileri, yüz tanıma sistemleri, nesneleri takip etme ve izleme uygulamaları gibi çeşitli alanlarda da yoğun bir şekilde kullanılmaktadır (Alkhder, 2021). Nesnelerin doğru bir şekilde tespit edilmesi ve sınıflandırılması, daha akıllı ve etkili sistemlerin geliştirilmesine katkı sağlamaktadır. Ayrıca, nesne tespiti, veri analitiği, nesneler arası ilişkilerin anlaşılması, içerik yönetimi gibi alanlarda da büyük önem taşımaktadır. Nesne tespiti, daha akıllı ve etkili sistemlerin oluşturulmasına ve çeşitli uygulamaların geliştirilmesine katkı sağlamaktadır.



Şekil 2: Nesne Algılama Senaryosu

Nesne tespiti, iki aşamadan oluşan bir süreçtir: nesne yerleştirme ve nesne sınıflandırma. Bu süreç, belirli bir nesnenin bulunması ve ilgili nesnenin sınıflandırılması görevini gerçekleştirir. Ayrıca birden fazla nesnenin tanınması ve tanımlanması da nesne tespiti tarafından sağlanır (Alqadiri, 2022). Nesne tespiti, bir nesnenin konumunu belirleyerek onu tanımlar ve hangi sınıfa ait olduğunu da tespit eder.

Nesne yerleştirme, bir görüntüde belirli bir nesnenin varlığını tespit etme sürecidir. Nesnenin konumunu sınırlayıcı bir kutu (genellikle dikdörtgen) kullanarak belirler. Bu kutu, nesnenin sınırlarını belirlemek için kullanılır ve nesnenin bulunduğu bölgeyi işaretler.

Nesne sınıflandırma ise belirlenen nesnenin hangi sınıfa ait olduğunu tespit etme görevidir. Bu aşamada, verilen görüntüdeki nesne, önceden tanımlanmış bir dizi sınıf arasından doğru şekilde sınıflandırılır. Bu genellikle derin öğrenme teknikleriyle gerçekleştirilir, örnek olarak sinir ağları kullanılabilir.

Nesne tespiti, birçok uygulama alanında kullanılır. Otomatik sürüş sistemleri, güvenlik ve gözetim sistemleri, robotik, video analizi gibi alanlarda nesne tespiti önemli bir rol oynar. Ayrıca, nesne tespiti, nesneler arası ilişkilerin anlaşılması, içerik yönetimi, nesnelerin takibi ve izlenmesi gibi alanlarda da kullanılır.


4. MATERİYAL VE YÖNTEM

4.1. Veri Setlerinin Oluşturulması ve Sınıflandırılması


Araştırmamızın veri tabanı iki bölümden oluşmaktadır. Birinci bölüm Kaggle sitesinde Monkeypox Skin Image Dataset (MSID) veri kümesi kullanılmıştır. İkinci bölümde ise Kaggle sitesinde Monkeypox Skin Image Dataset (MSID), GitHub sitesinde Monkeypox Master (MM) ve yine Kaggle sitesinde Monkeypox Orijinal İmages (MOI) veri setlerinden harmanlanarak oluşan HİBRİD veri seti kullanılmıştır. Tüm görüntüler harmanlandıktan sonra Visipics uygulaması ile benzer olan görüntüler tespit edilerek çıkarılmıştır. Veri kümelerine renkleri ters çevirme ve kahverengi, gri skalaya dönüştürme ön işlemler gerçekleştirilerek her iki veri kümesinde de veri arttırımı aynı şekilde yapılmıştır. Yapılan işlemler sonucunda MSID kümesinde monkeypox tanısı olan 281 orijinal görüntü, 278 renkleri ters çevirme, 278 kahverengi skalaya çevirme ve 278 gri skalaya çevrilmiş görüntülerden oluşmaktadır. MSID kümesinde non monkeypox görüntüleri ise 247 orijinal görüntü, 245 renkleri ters çevirme, 245 kahverengi skalaya çevirme ve 245 gri skalaya çevrilmiş görüntülerden oluşmaktadır. HİBRİD veri kümesinde monkeypox tanısı olan 389 orijinal görüntü, 389 renkleri ters çevirme, 389 kahverengi skalaya çevirme ve 389 gri skalaya çevrilmiş görüntülerden oluşmaktadır. HİBRİD kümesinde non monkeypox görüntüleri ise 677 orijinal görüntü, 677 renkleri ters çevirme, 677 kahverengi skalaya çevirme ve 677 gri skalaya çevrilmiş görüntülerden oluşmaktadır. Bu veri kümeleri eğitim ve test dosyaları olarak ayrılırken %70 eğitim %30 test görüntü olarak python da oluşturulan kod ile rastgele bir şekilde gerçekleştirilmiştir. Ayrıca analizler gerçekleştirilirken rastgele döndürme işlemi (rotation_range), rastgele yaklaştırma (zoom_range), yatay yönde rastgele kaydırılması (width_shift_range), dikey yönde rastgele kaydırılması (height_shift_range), yatay kayma (shear_range), yatay yönde rastgele olarak simetrisini alma (horizontal_flip) ve görüntülerin dönüşümü sırasında oluşan ekstra alanları veya boşlukları doldurma (fill_mode) ön işlemleri uygulanmıştır.

Çalışmamız da MonkeypoxDataset3 ismiyle yayımlanan Monkeypox Skin Image Dataset (MSID) veri kümesi train ve validation klasörleri içinde Monkeypox ve Non Monkeypox görüntüleri bulunan veri kümesi kullanılmıştır. Veri setinde eğitim için 806 Monkeypox, 690 Non Monkeypox, test için 309 Monkeypox, 292 Non Monkeypox olmak üzere toplamda 2097 Monkeypox ve Non Monkeypox olan maymun çiçeği hastalığı bulunan/bulunmayan deri lezyon resimleri yer almaktadır. Ayrıca MonkeypoxDataset4 ismiyle yayımlanan

HİBRİD veri kümesi train ve validation klasörleri içinde Monkeypox ve Non Monkeypox görüntüleri bulunan veri kümesi kullanılmıştır. Veri kümesinde eğitim için 1088 Monkeypox, 1896 Non Monkeypox, test için 468 Monkeypox, 812 Non Monkeypox olmak üzere toplamda 4264 Monkeypox ve Non Monkeypox olan maymun çiçeği hastalığı bulunan/bulunmayan deri lezyon resimleri yer almaktadır.



Şekil 3: Maymun Çiçeği Hastalığı Olan Veri Seti Örnekleri



Şekil 4: Maymun Çiçeği Hastalığı Olmayan Veri Seti Örnekleri


Çalışmamızda veri kümelerinde bulunan resimler pythonda yazılan kod ile rast gele seçilerek ayrıştırılmıştır.

4.2. Derin Öğrenme (Makine Öğrenimi)

Derin öğrenme, yapay zekanın ve makine öğreniminin bir alt dalıdır ve daha gelişmiş bir yapıya sahiptir. Derin öğrenme, esneklik ve doğru modeller oluşturma konusunda makine öğrenimine göre önde gelir. Bu teknoloji, karmaşık ve büyük veri setlerinde anlamlı bilgi çıkarımı için sıkça tercih edilmektedir (Militante & Dionisio, 2020; Zhang, 2021)

Derin öğrenme, sinir sisteminin ana kontrol merkezi olan beynin nöronlarının yapısından ilham alınarak oluşturulmuştur (Militante & Dionisio, 2020). Amacı, insanın yüklendiği görevleri makinelerin yerine getirebilmesi, kendi kendine öğrenme yeteneği geliştirmesi ve geniş veri kümelerinden özellik çıkarımı yapabilmesi için teoriler ve yöntemler bulmaktır (Jasim, 2022). Derin öğrenme, özellik çıkarımının yanı sıra dönüşüm işlemlerini gerçekleştirebilmek için birden fazla doğrusal olmayan katmanlı bir yapıya sahiptir. Her katman, kendisinden önceki katman çıktılarına girdi olarak çalışır ve bu sayede işlenmemiş veri setinden otomatik olarak özellikler çıkarılır (Kaya & Önal, 2021). Şekil 1, derin öğrenme modellerinin temel katman tabanlı yapısını göstermektedir.


Böylece, derin öğrenme, yapay zeka ve makine öğreniminin birleşimiyle oluşturulan bir teknolojidir. Esnekliği ve doğru modeller oluşturma yeteneğiyle bilinir. Derin öğrenme, veri analizinde geniş veri kümelerinden anlamlı bilgiler çıkarabilmek için kullanılan karmaşık bir yapının içerisinde özellik çıkarımı ve dönüşüm işlemlerini gerçekleştirir.



Şekil 5: Derin Öğrenmenin Temel Mimarisi (Isaksson, 2018)

Derin öğrenme mimarileri, tarım ve tıp gibi alanlarda özellikle hastalıkların sınıflanması, tespiti gibi farklı alanlarda sıkça tercih edilmektedir (Militante & Dionisio, 2020). Bu alanlardaki işlemleri gerçekleştirmek için derin öğrenme mimarileri farklı özellikler ve

yapılar kullanmaktadır. Genellikle denetimli ve denetimsiz olmak üzere iki ana kategoriye ayrılan derin öğrenme mimarileri, çeşitli uygulama alanlarına göre farklı modelleri içermektedir (Şekil 2). Bu çalışmada, CNN (Convolutional Neural Network) mimarisine sahip modeller gibi denetimli derin öğrenme türleri tercih edilmiştir.



Şekil 6: Derin Öğrenme Yaklaşımları (Kaya & Önal, 2021)


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

1998 yılında Bottou, LeCun, Haffner ve Bengio tarafından yapılan çalışmada, evrişimli sinir ağlarının ve evrişimli sinir ağlarının ilk örneği olan LeNet modeli geliştirilmiştir (Simonyon & Zisserman, 2015). İlk başlarda sadece posta kodlarını ve rakamları tanımlamak için kullanılan LeNet modeli, günümüzde milyarlarca parametreyi hesaplayarak verilerden anlam çıkaran ve çeşitli sorunlara çözüm bulan bir model haline gelmiştir (Akar, 2022). Evrişimli sinir ağları, bilgisayarla görme, görüntü tabanlı uygulamalar ve diğer alanlarda önemli ilerlemeler kaydetmiştir. Yüz tanımlama, nesne tanımlama, görüntü kategorize edilmesi, otonom yapımı, hastalıkların tespiti gibi farklı bir çok alana büyük başarılar kazandırdığı gözlemlenmiştir (Akar, 2022; Militante & Dionisio, 2020).

Evrişimli sinir ağları (CNN veya ConvNet), bir girdi görüntüsü olarak içindeki farklı nesneleri ayırt edebilen derin öğrenme modellerinden biridir (Kaya & Önal, 2021). CNN, çok katmanlı bir yapıya sahip olan yapay sinir ağları mimarisine benzer. Evrişim katmanı, havuzlama katmanı ve tam bağlantılı katmandan oluşur. Evrişim katmanı ve havuzlama katmanı, girdi görüntüsünden özellikler çıkarırken, tam bağlantılı katman, elde edilen özellikleri sınıflandırma için çıktı katmanına ileterek işlemi tamamlar (Özbay & Altunbey Özbay, 2020). Şekil 3, bu katmanların yapısını görsel olarak göstermektedir.

Tam bağlantılı katman, ilk katmandaki nöronları, sonraki katmandaki nöronlara bağlayarak sınıflandırma işlemi hazırlıklarını yapar (Harriat C. vd., 2021). Derin öğrenme yapısından farklı olarak CNN, görüntülerin tamamı yerine etkili özellikleri kullanarak çalışması, onu

diğer yöntemlerden ayırır (Mehedi S. vd., 2021).




Şekil 7: Evrişimli Sinir Ağı Temel Yapısı

4.3.1. Evrişim Katmanı

CNN'nin temel mimarisini belirleyen ve büyük bir hesaplama işleminin gerçekleştiği, filtreler ve özellik haritaları olarak adlandırılan bileşenleri içerir (Akar, 2022). Bu katmandaki filtreler, girdi olarak verilen görüntü üzerinde özellikleri algılamak için kullanılır ve özellik haritalarının oluşturulmasında önemli bir rol oynar (Jasim, 2022).

Bu katmanda, girdi görüntüsü ile daha küçük boyutlarda olan filtreler kullanılarak dönüşüm işlemi gerçekleştirilir. Filtreler, genellikle 2x2, 3x3 veya 5x5 boyutunda olabilir ve tüm görüntü üzerinde kaydırma işlemi yapar (Kaya & Önal, 2021). Bu işlemler sonucunda öznitelik haritaları elde edilir, yani girdi görüntüsündeki önemli bilgiler özetlenir (Özbay & A. Özbay, 2020).


Girdi olarak verilen 5x5 boyutunda bir matris görüntüsüne ve 3x3 boyutunda bir evrişim filtresi uygulanmasıyla elde edilen çıktı görüntüsü Şekil 4'te göstermektedir. Bu filtre, görüntü üzerinde kaydırılarak uygulanır ve bu işlem tüm görüntü üzerinde gerçekleştirilir (Türkoğlu vd., 2020).



Şekil 8: Görüntünün Evrişim İşlemi ve Çıktı Oluşturma Süreci

4.3.2. Havuzlama Katmanı

Havuzlama katmanı, bazı modellerde kullanılmayabilecek olan bir katmandır, çünkü kullanımı zorunlu değildir. Havuzlama katmanında hesaplamalar hızlı bir şekilde gerçekleştirilir ve önceki katmandan gelen özellik niteliklerini gruplandırılır, böylece yeni özellik haritaları oluşturulur (Jasim, 2022). Bu katmanın amacı, özellik kaybı olmadan boyutun sonraki katman için azaltılmasıdır. Ancak, süreç içerisindeki azaltma işlemi bilgi kaybına neden olabilir. Bilgi kaybı dezavantajlı olarak görünse de aslında gerçekleşen işlem, sonraki katmanlar için hesaplama yükünü azaltarak fazladan öğrenmenin engellenmesine yardımcı olur (Kaya & Önal, 2021). Bu nedenle, bilgi kaybı, sistemin avantajına dönüşebilen bir özelliktir.



Şekil 9: Havuzlama Katmanlarının Maksimum ve Ortalama Değerleri (Doğan, 2020)

Havuzlama katmanı, iki farklı yapıya sahip olan maksimum havuzlama katmanı ve ortalama havuzlama katmanı olarak ikiye ayrılmıştır, bu yapılar Şekil 5'te gösterilmiştir. Maksimum havuzlama genellikle daha iyi performans gösterdiği için yaygın olarak tercih edilen bir yöntemdir. Bu katmanda, filtrelerin taradığı bölgede yer alan piksellerin en yüksek değeri çıktı olarak seçilir (Akar, 2022).

Öte yandan, ortalama havuzlama yönteminde ise tarama işlemi sırasında seçili bölgedeki değerlerin ortalaması alınarak çıktı olarak belirlenir ve bu işlemler yeni dizideki diğer hücrelere de gerçekleştirilir (Jasim, 2022).

4.3.3. Aktivasyon Fonksiyonları (ReLU Katmanı)

Aktivasyon fonksiyonu tercihi, kullanılan yapay sinir ağı modeline ve çözülmek istenen probleme bağlıdır. Her bir aktivasyon fonksiyonunun farklı avantajları ve özellikleri vardır. İşte bazı durumlar için tercih edilen aktivasyon fonksiyonları:

Sigmoid fonksiyonu genellikle çıktı katmanında kullanılır. Özellikle ikili sınıflandırma problemlerinde tercih edilebilir. Sigmoid fonksiyonu çıktıyı 0 ile 1 arasında bir olasılık değeri olarak yorumlamamıza izin verir.

Tanh fonksiyonu, sigmoid fonksiyonuna benzer ancak çıktıyı -1 ile 1 arasında sınırlar. Ortak kullanım alanları, aralığı -1 ile 1 olan çıktılara ihtiyaç duyulan ikili sınıflandırma problemleri veya simetrik aktivasyon fonksiyonlarının gerektiği durumlardır.

ReLU (Rectified Linear Unit), derin öğrenme modellerinde yaygın olarak kullanılan bir aktivasyon fonksiyonudur. Hızlı hesaplama ve modelin daha hızlı öğrenme yeteneği gibi avantajları vardır. Ancak ReLU fonksiyonunun negatif girdi değerlerini sıfır olarak kabul etmesi, bazı durumlarda aşırı aktivasyon sorununa neden olabilir.

Leaky ReLU, ReLU fonksiyonunun bir genişletmesidir. Negatif girdi değerlerinde sızıntı yaparak negatif değerleri korur. Bu, aşırı aktivasyon sorununu hafifletmeye yardımcı olabilir.

Softmax fonksiyonu, çok sınıflı sınıflandırma problemlerinde kullanılır. Çoklu çıkışlardaki değerleri olasılık dağılımına dönüştürerek sınıflar arasındaki olasılıkları karşılaştırmamıza olanak tanır.

Hangi aktivasyon fonksiyonunun tercih edileceği, veri setinin özelliklerine, problemin doğasına ve modelin performansına bağlıdır. Deneyler yaparak ve modelinizi optimize ederek en uygun aktivasyon fonksiyonunu seçebilirsiniz (K. He, 2015).

Derin öğrenme modellerinde genel olarak girdi verilerine dayalı olarak çıktı üretmek için aktivasyon fonksiyonları kullanılır. ReLU, literatürde yaygın olarak kullanılan doğrusal olmayan bir aktivasyon fonksiyonudur (Alqadiri, 2022). ReLU, öğrenmenin gerçekleştiği süreçte doğrusallığın gereksinim duyulmadığı problemlerde iyi bir performans sergileyen bir fonksiyondur (Maas., 2013). ReLU fonksiyonu matematiksel olarak Eşitlik 1'de tanımlanmıştır (Harriat C. vd., 2021).

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

Burada x , giriş değerini temsil eder ve fonksiyonun çıktısı 0'dan büyükse x değerini, 0'dan küçükse 0'ı alır. Bu şekilde, ReLU fonksiyonu negatif değerleri sıfır olarak dönüştürürken, pozitif değerleri de aynı şekilde aktarır.

ReLU (Rectified Linear Unit), yapay sinir ağlarında tercih edilen bir aktivasyon fonksiyonudur ve çeşitli avantajları vardır:

- **Hızlı Hesaplama:** ReLU, sigmoid veya tanh gibi diğer aktivasyon fonksiyonlarına

kıyasla hesaplama açısından daha hızlıdır. Bu, büyük veri setleri veya derin sinir ağları gibi hesaplama yoğun uygulamalarda önemli bir avantaj sağlar.

- **Doğrusallık:** ReLU, pozitif girdi değerlerinde doğrusal bir ilişki sergiler. Doğrusal bir fonksiyon olması, modelin daha iyi öğrenme yeteneği sağlar ve ağırlıkların güncellenmesini kolaylaştırır.
- **Azalma Sorunu Yok:** ReLU fonksiyonu, pozitif girdi değerleri için doğrusal bir çıktı üretirken, negatif girdi değerlerinde sıfır çıktısı verir. Bu, ağırların eğitim sırasında gradiyentin doğru şekilde iletilmesini sağlar ve gradiyentin azalma sorununu (vanishing gradient problem) önler.
- **Sparse Activation:** ReLU, negatif girdi değerlerini sıfır olarak atar. Bu nedenle, bir sinir hücresi genellikle yalnızca birkaç aktivasyonu tetikler. Bu, ağırların daha düzenli ve daha az bağımlı bir şekilde çalışmasını sağlar ve aşırı uyum (overfitting) riskini azaltır.

Ancak, negatif girdi değerlerinde tamamen sıfır çıktısı vermesi, bazı durumlarda dead neuron problemine (ölü nöron problemine) yol açabilir (Goodfellow, I., 2016). Bu durumda, Leaky ReLU gibi modifikasyonlar kullanılabilir. ReLU, bu avantajları nedeniyle derin öğrenme modellerinde yaygın olarak tercih edilen bir aktivasyon fonksiyonu olduğundan çalışmamızda bu fonksiyonu tercih ettik.

4.3.4. Optimizasyon (Optimizer)

Optimizasyon, muayyen kısıtlamalar ve parametreler altında maliyet veya kayıp fonksiyonunu en iyi şekilde minimize veya maximize etme sürecidir. Derin öğrenme uygulamalarında, öğrenme sürecinin temelinde bir optimizasyon problemi olduğu bilinmektedir. Bu problemin çözümünde, doğrusal olmayan ilişkilerin keşfedilmesi ve en uygun değer belirlenmesi için çeşitli optimizasyon yöntemleri kullanılmaktadır.

Derin öğrenme modellerinde performansı ve hızı etkileyen çeşitli optimizasyon algoritmaları bulunmaktadır. Bu algoritmalar arasında stokastik gradyan inişi (stochastic gradient descent), adadelta, adagrad, adamax, adam gibi algoritmalar sıkça tercih edilmektedir (Atcılı, 2020). Bu algoritmalar, farklı optimizasyon stratejileri ve güncelleme kuralları kullanarak modelin kayıp fonksiyonunu minimize etmeyi hedefler.


Çalışmamızda, derin öğrenme konularında son zamanlarda sıklıkla kullanılan ve iyi sonuçlar veren Adam optimizasyon algoritması tercih edilmiştir. Adam, adaptif moment tahmini

yöntemini kullanarak gradient tabanlı optimizasyonu gerçekleştirir. Bu algoritma, kayıp fonksiyonunun minimumuna hızlı bir şekilde yaklaşabilme yeteneği ve parametre güncellemelerinde adaptif özellikleri ile bilinir.

Bu nedenle, çalışmanızda Adam optimizasyon algoritmasının kullanılması, derin öğrenme modelinizin performansını ve hızını artırmada etkili bir seçimdir.

4.3.5. Tam Bağlı Katman

Bu katmanda sınıflandırma işlemini gerçekleştirebilmek için önceki katmanların çıktılarını birbirine bağlamak ve elde edilen değerleri birbirine bağlayarak tek boyutlu bir diziye dönüştürmek amacıyla düzleştirme işlemi uygulanır (Akar, 2022). Şekil 6'da gösterilen düzleştirme işlemi, kullanılan ağlarda giriş verilerini uygun hale getirir.



Şekil 10: Veri Aktarımı İçin Tam Bağlı Katmanda Veri Düzleştirme İşlemi

4.4. Çalışmada Tercih Edilen Modeller


4.4.1. DenseNet201

DenseNet201, derin öğrenme modellerinden biridir ve 201 katmanlı yoğun bağlantılı bloklardan oluşan bir sinir ağıdır. Bu model, görüntü sınıflandırma, nesne tespiti ve segmentasyon gibi görevlerde kullanılmak üzere önceden eğitilmiş bir model olarak sunulmuştur. DenseNet201, evrimsel sinir ağı (CNN) mimarisi üzerine inşa edilmiştir ve yoğun bağlantılı bloklarıyla dikkat çeker. Yoğun bağlantılı bloklar, ağın derinliğini artırmak ve özelliklerin daha iyi paylaşılmasını sağlamak amacıyla tasarlanmıştır.

Bu mimari yapı, Huang ve arkadaşları tarafından bilgi aktarımını sağlamak amacıyla geliştirilmiştir. Her katman için önceki katmanların çıktıları, girdi değeri olarak kullanılır.

DenseNet, kaybolan gradyan sorununu önemli ölçüde azaltmaya yardımcı olan bir ağ mimarisidir. Bu işlemi gerçekleştirebilmek için DenseNet, azaltılmış parametre sayısına sahiptir (Çetiner, H.). DenseNet201 ise 7x7 evrişim filtresi ve ardından 3x3 MaxPool ile başlayan bir ilk katman, aralarında 3 ortalama havuz katmanı olan 196 evrişim katmanı ve 1 çıkış katmanından oluşan toplamda 201 katmana sahiptir (Bingöl H., 2022). DenseNet201 mimarisine $224 \times 224 \times 3$ boyutunda bir girdi verilmektedir. Bu modelde, her bir yoğun bağlantılı blok, önceki bloktaki tüm katmanların çıktılarıyla birleştirilerek oluşturulur (X. Yu. Vd., 2019). Bu yoğun bağlantılar, bilgi akışını kolaylaştırır ve ağın daha derin katmanlarda daha iyi özellikler öğrenmesine olanak tanır.

DenseNet201, ImageNet veri kümesi üzerinde eğitilmiştir ve genel olarak genel görüntü sınıflandırma görevlerinde yüksek başarı elde etmiştir. Aynı zamanda, transfer öğrenme yöntemleriyle farklı görevlerde de kullanılabilir. DenseNet201 modeli, derin öğrenme alanında güçlü bir model olarak kabul edilir ve genellikle karmaşık ve çok sınıflı veri setlerinde kullanılır.



Şekil 11: DenseNet201 Mimarisi


4.4.2. NasNetLarge

NasNetLarge modeli, "Learning Transferable Architectures for Scalable Image Recognition" başlıklı makalede Zoph et al. (2018) tarafından tanıtılmıştır. Bu çalışma, Neural Architecture Search (NAS) adı verilen bir yapay zeka algoritması kullanılarak özelleştirilmiş bir evrişimli sinir ağı (CNN) mimarisinin otomatik olarak tasarlanması üzerine yapılan araştırmaları içermektedir.

NasNetLarge modeli, NASNet algoritmasıyla oluşturulan bir ağ yapısına dayanır ve büyük ölçekli görüntü sınıflandırma görevleri için optimize edilmiştir. Model, TensorFlow kütüphanesi kullanılarak Google tarafından geliştirilmiştir. Ayrıca, makalede modelin eğitimi sırasında kullanılan veri kümesi ve eğitim süreci ayrıntılı bir şekilde açıklanmaktadır.

NasNetLarge modeli genellikle görüntü sınıflandırma, nesne tanıma ve benzeri görevler için

Transfer Öğrenme yöntemiyle kullanılmaktadır. Önceden eğitilmiş ağırlıklar kullanılarak farklı veri setleri ve görevler için ince ayar yapılabilir (Zoph, B. vd., 2018).




Şekil 12 : NasNetLarge Mimarisi

4.4.3. InceptionV3

Inception modeli, ImageNet veri kümesi üzerinde yüksek sınıflandırma doğruluğunu elde eden ve ILSVRC 2014 yarışmasında birinci olan bir CNN mimarisidir. Bu model, görüntü sınıflandırması alanında önemli bir başarı elde etmiştir ve hata oranında diğer yarışma katılımcılarına kıyasla önemli bir düşüş sağlamıştır. Özellikle 2014 yılında tanıtılan VGG derin öğrenme modeline göre daha düşük bir hata oranına sahiptir (Bozkurt, 2021).

Inception modelinde elde edilen bu başarılar, doğruluğun artırılması ve modelin karmaşıklığının düşürülmesi gereken alanları göstermiştir. Bu iyileştirmeleri gerçekleştirirken, Inception modelinin farklı versiyonları geliştirilmiştir ve InceptionV3 modeli bu versiyonlardan biridir. InceptionV3 modeli, temelini orijinal Inception modelinden alarak doğruluğun daha da artırılmasını sağlamayı amaçlamıştır (Ashames, 2020).



Şekil 13: InceptionV3 Mimari Yapısı

InceptionV3 modeli, 48 katman derinliğine sahip ve 1x1, 3x3, 5x5 boyutlarındaki evrişimlerin birleştirildiği inception modüllerini kullanan bir modeldir. Bu modelin VGGNet'e kıyasla daha verimli olduğu bilinmektedir. InceptionV3 modelinin mimarisi Şekil 9'da gösterilmektedir.

InceptionV3, 5x5 veya 7x7 boyutlarında evrişimler için iki/üç adet 3x3 boyutlarında filtre kullanılmaktadır. Bu sayede parametre sayısı azaldığından eğitim sürecinde hızın arttığı gözlemlenmiştir (Bozkurt, 2021). Modelin derinliği arttıkça genişliğinin de arttığı bilinmektedir. Bu nedenle InceptionV3 modelinde, ağın genişliği ve derinliği en uygun seviyelere getirilerek yüksek bilgi akışı sağlanması amaçlanmıştır (Szegedy vd., 2015).

Sonuç olarak, InceptionV3 modeli 48 katman derinliği olan ve farklı boyutlardaki evrişimlerin birleştirildiği inception modüllerini kullanan bir modeldir. Bu modelde evrişimlerde filtrelerin boyutları ve sayıları optimize edilerek parametre sayısı azaltılmış ve yüksek bilgi akışı sağlanmıştır. Bu sayede InceptionV3 modeli, VGGNet'e göre daha verimli bir yapıya sahiptir.

4.4.4. InceptionResNetV2

InceptionResNetV2, Google tarafından geliştirilen bir derin öğrenme modelidir. Christian Szegedy, Sergey Ioffe, Vincent Vanhoucke ve Alex Alemi tarafından 2016 yılında yayınlanan "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning" makalesinde ayrıntılı olarak tanıtılmıştır (Christian S. vd., 2016).


Bu model, Inception mimarisini ve residual (artıklık) bağlantılarını birleştiren bir yapıya sahiptir. Inception mimarisi, farklı boyutlarda evrişim işlemlerini birleştiren "inception" modüllerini kullanarak bilgi akışını optimize etmeyi amaçlar. Bu sayede, model farklı ölçeklerdeki özellikleri algılamak için daha etkili bir yapıya sahip olur. Ayrıca, residual bağlantıları modelin daha derin ve daha etkili öğrenme yapmasını sağlar.

InceptionResNetV2 modeli, 48 katman derinliğe sahiptir ve 1x1, 3x3, 5x5 boyutlarında evrişim işlemlerini içeren inception modüllerini kullanır. Bu modüller, farklı filtre boyutlarını bir araya getirerek çeşitli özellikleri algılamayı mümkün kılar. Ayrıca, daha az parametre içermesi ve 3x3 boyutunda filtrelerin tercih edilmesi, eğitim hızını artırır ve modelin daha etkili bir şekilde öğrenmesini sağlar.

InceptionResNetV2 modeli genellikle görüntü sınıflandırma, nesne tespiti ve yüz tanıma gibi görsel işleme görevlerinde kullanılır. Özellikle ImageNet gibi büyük veri setleri üzerinde

eğitilen bu model, çeşitli görüntü özelliklerini algılama ve sınıflandırma konusunda yüksek başarı elde eder. Ayrıca, transfer öğrenme yöntemleriyle farklı görsel işleme problemlerinde kullanılarak etkileyici sonuçlar elde edilebilir.

InceptionResNetV2 modeli, derin öğrenme alanında önemli bir gelişme olup birçok uygulama alanında başarılı sonuçlar vermiştir.



Şekil 14: InceptionResNetV2 Mimarisi (Ashames, 2020)

Ayrıca, Google AI Blog'un 2016 yılında yayımlanan "Inceptionism: Going Deeper into Neural Networks" başlıklı yazısında da InceptionResNetV2 modeline değinilmektedir (Google AI Blog, 2016). Bu yazıda, Inceptionism konsepti ve derin sinir ağları üzerindeki etkisi üzerine bilgiler verilmektedir.

"InceptionResNetV2" modeli hakkında daha teknik detaylar için, François Chollet ve diğerleri tarafından hazırlanan Keras Dokümantasyonu'ndaki "Applications-InceptionResNetV2" bölümüne başvurabilirsiniz (François C. Vd. 2021).

4.4.5. Xception

Xception modeli, François Chollet tarafından 2017 yılında yayınlanan "Xception: Deep Learning with Depthwise Separable Convolutions" başlıklı makalede tanıtılan bir derin öğrenme modelidir.

Xception, evrişim tabanlı bir sinir ağıdır ve Inception mimarisi temel alınarak geliştirilmiştir. Makalede, geleneksel evrişim işleminden farklı bir yapı olan derinlik-yapılandırılmış evrişimler (depthwise separable convolutions) kullanılarak modelin öğrenme kapasitesi ve hesaplama verimliliği artırılmıştır.

Derinlik-yapılandırılmış evrişimler, geleneksel evrişim işleminden farklı olarak iki aşamalı bir yaklaşım sunar. İlk aşamada, girdi kanalları üzerinde evrişim işlemi uygulanır ve ardından kanal seviyesindeki evrişimler ayrı ayrı işlenir. Bu yapı, parametre sayısını azaltırken ağır öğrenme yeteneğini korur ve hesaplama maliyetini düşürür.

Xception modeli, özellikle görüntü sınıflandırma ve görsel işleme görevlerinde etkili sonuçlar elde etmiştir. Derinlik-yapılandırılmış evrişimlerin kullanımı sayesinde daha iyi öğrenme performansı elde edilirken daha az hesaplama kaynağına ihtiyaç duyulur.

Xception modeli, Keras kütüphanesinde "xception" olarak adlandırılan bir modül olarak bulunmaktadır. Keras, bu modelin kullanımını kolaylaştıran ve özelleştirmeyi destekleyen bir araç sağlar. Xception modeli, önceden eğitilmiş ağırlıklarla birlikte kullanılarak transfer öğrenme yöntemleriyle farklı görüntü işleme problemlerinde kullanılabilir (Keras.io, 2022).

Xception, derin öğrenme alanında önemli bir ilerleme olmuş ve derinlik-yapılandırılmış evrişimlerin kullanımı sayesinde etkili bir model haline gelmiştir. Yüksek sınıflandırma doğruluğu ve hesaplama verimliliği, Xception'ın farklı uygulama alanlarında tercih edilmesini sağlamıştır.

4.5. Performans Metrikleri

Bir modelin performansını değerlendirmek için bir dizi performans ölçütü kullanılır. Bu ölçütler arasında doğruluk, kesinlik, geri çağırma ve F1-skor en popüler olanlardır (Zhang, 2021).

4.5.1. Karışıklık Matrisi

Karışıklık matrisi, makine öğrenmesi veya sınıflandırma problemlerinde kullanılan bir algoritmadır ve modellerin eğitimi sırasında kullanılan algoritmaların performansını tablo şeklinde görsel hale getirir. Bu matris, gerçek etiketlere sahip veri setiyle algoritmanın tahmin ettiği değerler arasındaki karşılaştırmayı sağlar. Gerçek ve tahmin edilen değerlerin doğrulukla belirlenebilmesi için veri setindeki etiketlerin bilinmesi gerekmektedir. Karışıklık matrisi, hata analizi yapmak, modelin sınıflandırma başarısını değerlendirmek ve performans ölçütlerini elde etmek için kullanılır. (Akar, 2022).

Tablo 1: Karışıklık Matrisi

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

Tablo 1'de yer alan karışıklık matrisinde kullanılan ölçütler şu şekilde ifade edilir:

Doğru Pozitif (TP): Derin öğrenme modelinin pozitif olarak doğru tahmin ettiği sonuç sayısıdır.

Yanlış Pozitif (FP): Gerçekte negatif olan verileri modelin yanlış bir şekilde pozitif olarak tahmin ettiği sonuç sayısıdır.

Doğru Negatif (TN): Gerçekte negatif olan verileri modelin doğru bir şekilde negatif olarak tahmin ettiği sonuç sayısıdır.

Yanlış Negatif (FN): Gerçekte pozitif olan verileri modelin yanlış bir şekilde negatif olarak tahmin ettiği sonuç sayısıdır (Güngör vd., 2021).

Bu ölçütler, karışıklık matrisindeki hataların tespit edilmesi ve modelin sınıflandırma performansının değerlendirilmesi için kullanılır. Doğru pozitif ve doğru negatif değerleri, modelin doğru tahmin ettiği sonuçları temsil ederken, yanlış pozitif ve yanlış negatif değerleri ise modelin hatalı tahmin ettiği sonuçları temsil eder. Bu ölçütler, modelin hassasiyeti, özgüllüğü, doğruluk oranı, geri çağırma ve F1-skor gibi performans metriklerinin hesaplanmasında kullanılır.

4.5.2. Doğruluk (Accuracy) Değeri

Doğru sınıflandırılan verilerin sayısı, tüm veri seti üzerinde doğru şekilde tahmin edilen örneklerin toplam sayısını ifade eder. Ancak, veri setindeki sınıfların dağılımı dengesizse, doğruluk tek başına bir performans ölçütü olarak yeterli olmayabilir.

Eşitlik 2'de Doğruluk hesaplaması (Degadwala vd., 2021) belirtildiği gibi gerçek sınıf etiketleriyle modelin tahmin ettiği sınıf etiketlerinin eşleşme oranını ifade eder.

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

Doğruluk hesaplama yöntemi, doğru pozitif (TP), yanlış pozitif (FP), doğru negatif (TN) ve yanlış negatif (FN) değerlerini kullanarak gerçekleştirilir. Modelin doğru şekilde tahmin ettiği örneklerin sayısı, toplam örnek sayısına oranlanarak doğruluk elde edilir.

Ancak, doğruluk hesaplama yöntemi dengesiz veri setleri için uygun olmayabilir. Özellikle sınıflar arasında dengesizlik varsa, doğruluk tek başına performansı değerlendirmek için yeterli olmayabilir. Bu durumda, kesinlik, geri çağırma ve F1-skor gibi diğer performans ölçütlerinin kullanılması gerekebilir. Bu ölçütler, sınıf dağılımının dengesiz olduğu durumlarda performansı daha ayrıntılı bir şekilde değerlendirmeye yardımcı olur. Bu metrikler, TP, FP, TN ve FN değerlerini kullanarak hesaplanır ve modelin sınıflandırma performansını daha kapsamlı bir şekilde değerlendirir.

4.5.3. Kesinlik Değeri

Sınıflandırma işlemlerinde, kesinlik değerinin yüksek olması, pozitif olarak tahmin edilen değerlerin gerçekte de pozitif sınıfta olduğunu ifade etmektedir. Kesinlik, TP (doğru pozitif) değeri ile FP (yanlış pozitif) değeri arasındaki oranı temsil eder. Kesinlik değeri, 1'e yakın olduğunda, yanlış pozitif değerinin 0'a yakın olduğu anlamına gelir.

Eşitlik 3, kesinlik değerinin hesaplanmasını göstermektedir. Kesinlik, TP değerini TP ve FP değerlerinin toplamına böler. Yanlış pozitif değeri (FP) 0'a en yakın olduğunda, kesinlik değeri en yüksek değerini alır.

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

Bu durumda, sınıflandırma modelinin pozitif tahminlerde düşük bir hata yapma oranına sahip olduğu ve pozitif olarak tahmin ettiği verilerin çoğunlukla gerçekten pozitif olduğu söylenebilir. Yüksek bir kesinlik değeri, modelin doğru pozitif tahminler yapma yeteneğini vurgulayarak, modelin sınıflandırma performansının güvenilir olduğunu gösterir.

4.5.4. Geri Çağırma (Recall) Değeri

Geri çağırma değeri, sınıflandırıcının pozitif örnekleri doğru bir şekilde tanımlama yeteneğini ölçer (Zhang, 2021). Eşitlik 4'te belirtildiği gibi, geri çağırma değeri, paydanın (doğru pozitiflerin sayısı) paya (gerçek pozitiflerin toplam sayısı) bölünmesiyle elde edilir. Bu nedenle, geri çağırma değerinin 1 veya 1'e yakın olması, yanlış negatiflerin (gerçek pozitif olanlar arasında yanlışlıkla tahmin edilenler) 0 veya 0'a yakın olması gerektiğini gösterir. Yani, modelin pozitif örnekleri doğru bir şekilde tespit etme yeteneği yüksek olduğunu ifade

eder.

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

4.5.5. F1 Skor Değeri

F1-skoru, bir testin doğruluğunun ölçüsünü hesaplayarak, kesinlik ve geri çağırma değerlerini kullanır (Zhang, 2021). F1-skorunun 1'e yakın veya 1'e eşit olması başarılı bir modeli işaret eder. En yüksek F1-skorunu elde etmek için ise yanlış negatif ve yanlış pozitif değerlerinin minimum olarak sonuçlanması gerekmektedir (Eşitlik 5).

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

4.6. Model Eğitiminde Kullanılan Hiper Parametreler

4.6.1. Eğitim (Training)

Model eğitiminin temel hedefi, veri özelliklerini en iyi şekilde matematiksel bir temsil ile ilişkilendirmektir, bu da denetimli veya denetimsiz öğrenme arasındaki ilişkiyi kapsar. Eğitim sürecinin sonucunda elde edilen performans, uygulamanın kalitesi ve kullanılan eğitim verilerinin niteliği ile sıkı bir bağlantıya sahiptir. Bu nedenle, iyi bir performans elde etmek için yeterli ve temsilci bir veri seti kullanmak, uygun bir model seçmek ve eğitim sürecini dikkatlice yönetmek önemlidir. Eğitim verilerinin kalitesi, modelin genelleme yeteneğini etkilerken, uygulamanın kalitesi, modelin gerçek dünya senaryolarında ne kadar iyi performans gösterdiğini belirler. (c3.ai, 2022).

4.6.2. Öğrenme Oranı (Learning Rate)

Tahminleme sürecinde oluşan hataların minimize edilmesi için tercih edilen öğrenme oranı (Learning Rate), modelin ağıнын yapılandırılmasında önemli bir faktördür. Amacı, modelin en küçük hatayı elde ederek minimum hataya ulaşmasını ve öğrenmenin hızlı gerçekleşmesini sağlamaktır. Öğrenme oranı değeri, çok büyük veya çok küçük olmaması gereken bir değerdir.

Büyük bir değer seçilmesi durumunda, eğitim gerçekleşse de modelin güvenilirliği düşebilir. Çünkü yüksek bir öğrenme oranı, modelin hızlıca minimum hataya yaklaşmasını sağlar, ancak aşırı hızlı öğrenme nedeniyle istikrarsız bir model oluşabilir.

Öte yandan, küçük bir değer seçimi, modelin aşırı ayrıntılı bir eğitim süreciyle karşı karşıya

kalmasına neden olabilir(Alkhder, 2021). Bu durumda model, minimum hataya ulaşmak için çok daha uzun bir süre ve daha fazla veriye ihtiyaç duyabilir, bu da eğitim süresini uzatabilir.

Genellikle, standart olarak 0.0001 gibi küçük bir değer olan Learning Rate, birçok çalışmada kullanılmaktadır. Bu değer, çoğu durumda iyi sonuçlar verir ve stabil bir eğitim süreci sağlar. Ancak, her problem ve veri seti farklı olduğundan, öğrenme oranının dikkatli bir şekilde ayarlanması ve deneyler yapılması önemlidir.

4.6.3. Epoch

Modelin en yüksek düzeyde öğrenmesini sağlamak için veri setlerindeki görüntülerin tekrar tekrar işlenmesi gereken bir sayı olan epoch, önemli bir faktördür. Eğitim sürecinin sonunda modelin hedeflenen doğruluğa ulaşabilmesi için epoch değerinin uygun bir şekilde seçilmesi gerekmektedir.

Yüksek bir epoch seçimi, modelin fazla öğrenme yapmasına neden olabilir. Bu durumda model, eğitim veri setini ezberleyebilir ve genelleme yeteneği düşebilir (Çarkacı, 2018). Ayrıca, aşırı öğrenme sorunu ortaya çıkabilir, yani model eğitim verilerindeki hatalara aşırı tepki verir, ancak yeni verilerde başarılı olamaz.

Öte yandan, düşük bir epoch seçimi, yetersiz öğrenmeye yol açabilir. Model, yeterince eğitim verisiyle karşılaşmadığından dolayı istenilen performansı elde edemeyebilir.

Genellikle, epoch değerinin uygun bir şekilde belirlenmesi için deneme yanılma yöntemi kullanılır. Farklı epoch değerleri deneyerek eğitim sürecini izleyerek en iyi sonuçları elde etmek önemlidir. Her veri seti ve problem farklı olduğundan, epoch değerinin doğru şekilde seçilmesi, modelin optimal öğrenme ve performansını sağlamak için önemlidir.

4.6.4. Batches

Modelin sinir ağı tarafından tüm veri setinin aynı anda işlenmesi zor olduğu için, eğitim işlemini gerçekleştirmek için veri setinin daha küçük parçalara bölündüğü batch değeri kullanılır (Alkhder, 2021). Batch değeri, eğitim sırasında her adımda işlenecek örneklerin sayısını belirler.

Batch değeri, eğitim sürecinde bir adımda işlenecek veri miktarını kontrol etmek için kullanılır. Küçük bir batch değeri, daha az bellek kullanımı ve daha hızlı eğitim süreleri sağlayabilir, ancak dalgalanmalara neden olabilir ve modelin gradyan tahminlerinde daha fazla gürültüye sebep olabilir. Büyük bir batch değeri ise daha kararlı gradyan tahminleri

sağlayabilir, ancak daha fazla bellek kullanımına ve daha yavaş eğitim sürelerine neden olabilir.

Genellikle, batch değeri eğitim veri setinin boyutuna, kullanılan donanım kaynaklarına ve modele bağlı olarak belirlenir. Daha küçük veri setleri için genellikle küçük batch değerleri kullanılırken, daha büyük veri setleri için daha büyük batch değerleri tercih edilebilir.


Bu tez çalışmasında batch değeri 32 olarak belirlenmiştir, bu da her eğitim adımında 32 örneğin aynı anda işlendiği anlamına gelir. Bu değer, veri seti ve donanım kaynakları göz önüne alındığında uygun bir seçim olarak belirlenebilir.



5. BULGULAR

Bu çalışmada, büyük boyutlu resimlerin işlenmesi için güçlü donanıma ihtiyaç duyulmasına rağmen, mevcut bir güçlü makine bulunmaması nedeniyle Google Colab Pro kullanılmıştır. Google Colab Pro, gereken kütüphanelerin kurulumu ve GPU/TPU desteği gibi işlemleri daha kolay ve pratik hale getirerek, modellerin çalıştırılmasını sağlamaktadır.

Çalışmada maymun çiçeği hastalığının tespitinde Python dili kullanılmıştır. Bu işlemler Google Colab Pro'da bulunan Jupyter ile çalışılmıştır. Bu çalışmanın bir örneği Şekil 12'de görülebilir. Bu şekilde, Google Colab Pro ve Jupyter not defterleri kullanarak, modelin çalıştırılması ve sonuçların elde edilmesi kolaylıkla gerçekleştirilebilir.



Şekil 15: Colab Pro Jupyter Görünümü

Derin öğrenme modellerinin eğitiminde kullanılan veri setleri, Kaggle ve GitHub gibi kaynaklardan temin edilmiştir. Bu görüntüler, birçok veri setini içermektedir. Eğitim öncesi ön işlemler, Python kodları kullanılarak gerçekleştirilmiştir. Ön işlemler arasında, Maymun Çiçeği hastalığı olan ve olmayan insan deri lezyonlarına ait görüntülerin boyutlarının 224x224'e dönüştürülmesi gibi işlemler yer almaktadır. Görüntüler, eğitim ve doğrulama (validation) dosyaları olarak ayrılmış bir şekilde kullanılmıştır.

Çalışmamız da MonkeypoxDataset3 ismiyle yayımlanan Monkeypox Skin Image Dataset (MSID) veri kümesi train (eğitim) ve validation (test) dosyalarında Monkeypox ve Non Monkeypox veri kümesi kullanıldı. Veri setinde eğitim için 806 Monkeypox, 690 Non Monkeypox, test için 309 Monkeypox, 292 Non Monkeypox olmak üzere toplamda 2097 Monkeypox ve Non Monkeypox olan maymun çiçeği hastalığı bulunan/bulunmayan deri lezyon resimleri yer almaktadır. Ayrıca MonkeypoxDataset4 ismiyle yayımlanan HIBRID veri kümesi train (eğitim) ve validation (test) dosyalarında Monkeypox ve Non Monkeypox

veri kümesi kullanıldı. Veri kümesinin eğitiminde 1088 Monkeypox, 1896 Non Monkeypox, test için 468 Monkeypox, 812 Non Monkeypox olmak üzere toplamda 4264 Monkeypox ve Non Monkeypox olan maymun çiçeği hastalığı bulunan/bulunmayan deri lezyon resimleri yer almaktadır. Veri dağılımına baktığımızda, görüntülerin yaklaşık olarak %30'u test için, %70'i ise eğitim için kullanılmıştır. Görüntüler belirlenen oranlara göre ayrılırken Python kodları kullanılarak random olarak dağıtılmıştır.

Validation (2 directories)		Train (2 directories)	
About this directory This file does not have a description yet.		About this directory This file does not have a description yet.	
Monkeypox 309 files	Non Monkeypox 292 files	Monkeypox 806 files	Non Monkeypox 690 files

Şekil 16: MSID Veri Kümesinin Dağılımı

Validation (2 directories)		Train (2 directories)	
About this directory This file does not have a description yet.		About this directory This file does not have a description yet.	
Monkeypox 468 files	Non Monkeypox 812 files	Monkeypox 1088 files	Non Monkeypox 1896 files

Şekil 17: HİBRİD Veri Kümesinin Dağılımı

Derin öğrenme modellerimizin nesne tespiti doğru bir şekilde gerçekleştirebilmesi için belirli değişkenler kullanmaktayız. Bu parametreler, kullandığımız modellerin eğitimi sırasında kullanılan değerleri içermektedir. Bu parametreler, Tablo 2'de listelenmiştir.

Tablo 2: Derin Öğrenme Modellerinde Kullanılan Değişkenler

Değişkenler	Değerler
Learning Rate	0.00001
Epochs	10
Batch	32

Tablodaki değerler incelendiğinde, yapılan çalışma sonucunda öğrenme oranı (Learning Rate) 0.00001, epoch sayısı 10 ve batch size 32 kullanıldığında başarılı sonuçların elde edildiği tespit edilmiştir.


5.1. DenseNet201 Modeli ile Gerçekleştirilen Analiz Sonuçları

Çalışmamızda bu kısımda kullanılan analiz yöntemi DenseNet201 yer almaktadır. Bu yöntem aracılığıyla, veri setimizdeki değişkenler arasındaki ilişkileri anlamak ve önemli bulguları ortaya çıkarmak için çeşitli istatistiksel testler uygulanmıştır.

Tablo 3: DenseNet201 Modelinin Performans Değerlendirmesi

Veri Kümesi	Doğruluk Değeri (Accuracy)	Kayıp Değeri (Loss)	Eğitim İçin Geçen Süre
MSID	0.9933	0.0302	3 s 11 dk 21.99 sn
HİBRİD	0.9851	0.0573	1 s 18 dk 56.93 sn


Tablo 3'te görüldüğü gibi, iki farklı veri kümesinde DenseNet201 modeliyle gerçekleştirilen eğitimle MSID veri kümesinde 3 s 11 dk 21.99 sn sürede 0.0302 oranlık kayıpla %99.33, HİBRİD veri kümesinde ise 1 s 18 dk 56.93 sn sürede 0.0573 kayıp oranı ile %98.51 doğruluk başarı oranı tespit edilmiştir. Yapılan analizde ilgili modelin değeri en iyi sonuç veren pool size değeri baz alınarak iki veri kümesinde de aynı pool size değeri (7, 7) DenseNet201 için tercih edilmiştir. Bu sonuç da modelimizin maymun çiçeği hastalığının deri lezyon görüntüleri üzerinden gerçekleşen eğitimin sonunda iki farklı veri kümesinde de başarı oranının iyi düzeyde olduğu görülmektedir. Başarı oranı MSID veri kümesinde daha yüksek olduğu görülmektedir. Eğitim ve test verilerine göre başarı oranı değişiminin yer aldığı grafik Şekil 18'de yer almaktadır. Değerlerin eğitim ve test verilerine göre değişimi incelendiğinde eğitimde kaybın test verilerine göre daha az olduğu, doğruluk oranının ise daha yüksek olarak gözlemlenmektedir. Grafikte eğitim değerlerinde artış ve azalışlarda dalgalanmalar olsa da genel olarak düzenli seyir izlediği dikkat çekmektedir.



Şekil 18: DenseNet201 Modelinin Eğitim İlerlemesi Grafiği

DenseNet201 modeli ile analiz sonucunda oluşan Şekil 19'da MSID veri kümesinde 309 monkeypox, 292 diğer ve HİBRİD veri kümesinde 468 monkeypox, 812 diğer test veri

kümesine ait karışıklık matris analizi gösterilmiştir. DenseNet201 modelinin matris analizlerine göre, MSID veri kümesinde 309 monkeypox görüntüsünün 307'sinin monkeypox ve 2'sini non monkeypox olarak tanımladığı ve 292 diğer görüntünün 290'ının diğer ve 2'sinin monkeypox; HIBRID veri kümesinde 468 monkeypox görüntüsünün 453'ünü monkeypox olarak sınıflandırdığı ve 812 diğer görüntünün 808'inin non monkeypox ve 4'ünü monkeypox olarak sınıflandırdığı görülmektedir. Modelin MSID veri kümesinde monkeypox görüntülerini ayırt etmede başarılı olurken, HIBRID veri kümesinde bu başarı oranı daha düşük olduğu ve küçük hatalar izlenmektedir.



Şekil 19: DenseNet201 Modelinin Karışıklık Matrisi Analizi

Tablo 4, DenseNet201 modelinin eğitimi sonucunda MSID ve HIBRID veri setlerine ait test ve eğitim verilerinin monkeypox ve non monkeypox olarak tanımlanmasında elde edilen kesinlik, geri çağırma ve F1-skor değerlerini içermektedir.

Tablo 4: DenseNet201 Modelinin Sınıflandırma Performans Analizi

		Precision (Kesinlik)	Recall (Geri Çağırma)	F1-score	Support
MSID	0	0.99	0.99	0.99	309
	1	0.99	0.99	0.99	292
	Macro avg	0.99	0.99	0.99	601
	Weighted avg	0.99	0.99	0.99	601
HIBRID	0	0.99	0.99	0.98	468
	1	0.98	1.00	0.99	812
	Macro avg	0.99	0.98	0.98	1280
	Weighted avg	0.99	0.99	0.99	1280

Tablo 4'te gösterildiği üzere, MSID veri kümesine ait eğitim verileri için geri çağırma, F1-skor ve kesinlik değerlerinde %99 başarı oranı gözlemlenmiştir. Test veri kümesi için, monkeypox (0) görüntüleri için kesinlik, geri çağırma ve F1-skor değerleri %99 eşit başarı oranı olarak elde edilmiştir. Non monkeypox (1) veri kümesi için ise kesinlik %99, geri çağırma %99 ve F1-skor %99 olarak elde edilmiştir.

HİBRİD eğitim verileri için, geri çağırma, F1-skor ve kesinlik değerlerinde %99 başarı oranı gözlemlenmiştir. Test veri kümesi için, monkeypox (0) görüntüleri için kesinlik, geri çağırma %99 ve F1-skor %98 başarı oranı olarak elde edilmiştir. Non monkeypox (1) veri kümesi için ise kesinlik %98, geri çağırma %100 ve F1-skor %99 olarak elde edilmiştir.


5.2. InceptionResNetV2 Modeliyle Gerçekleştirilen Analiz Sonuçları

Çalışmamızda bu kısımda kullanılan analiz yöntemi InceptionResNetV2 yer almaktadır. Bu yöntem aracılığıyla, veri setimizdeki değişkenler arasındaki ilişkileri anlamak ve önemli bulguları ortaya çıkarmak için çeşitli istatistiksel testler uygulanmıştır.

Tablo 5: InceptionResNetV2 Modelinin Performans Değerlendirmesi


Veri Kümesi	Doğruluk (Accuracy) Değeri	Kayıp (Loss) Değeri	Eğitim İçin Geçen Süre
MSID	0.9850	0.0531	5 saat 13 dk 45.6 sn
HİBRİD	0.9812	0.0724	0 saat 50 dk 27.32 sn

Tablo 5'te görüldüğü gibi, iki farklı veri kümesinde InceptionResNetV2 modeliyle gerçekleştirilen eğitimle MSID veri kümesinde 5 saat 13 dakika 45.6 saniye içerisinde 0.0531 oranlık bir kayıpla %98.50, HİBRİD veri kümesinde ise 0 saat 50 dakika 27.32 saniye de 0.0724 oranlık bir kayıpla %98.12 doğruluk oranı elde edilmiştir. Yapılan analizde ilgili modelin pool size değeri en iyi sonuç veren değeri baz alınarak iki veri kümesinde de aynı pool size değeri (5, 5) InceptionResNetV2 için tercih edilmiştir. Bu sonuç da modelimizin maymun çiçeği hastalığının deri lezyon görüntüleri üzerinden gerçekleşen eğitimin sonunda iki farklı veri kümesinde de başarı oranının iyi düzeyde olduğu görülmektedir. Başarı oranı MSID veri kümesinde daha yüksek elde edilmiştir. Test ve eğitim veri kümelerine göre değerlerin değişimi, Şekil 20'de açıkça görüldüğü gibi, eğitim veri kümesinde test veri kümesine kıyasla daha az kayıp ve daha yüksek doğruluk değeri olduğunu ortaya koymaktadır. Değerlerin eğitim süreci boyunca dalgalanmalar gösterse de genel olarak düzenli bir şekilde ilerlediği gözlemlenmektedir.



Şekil 20: InceptionResNetV2 Modelinin Eğitim İlerlemesi Grafığı

Şekil 21’de InceptionResNetV2 eğitim sürecinin sonunda oluşan MSID veri kümesinde 309 monkeypox, 292 non monkeypox ve HİBRİD veri kümesinde 468 monkeypox, 812 non monkeypox test verilerine özgü karışıklık matrisi gösterilmiştir. DenseNet201 modelinin karışıklık matrisine göre, MSID veri kümesinde 309 monkeypox görüntüsünün 304’sinin monkeypox ve 5’ini non monkeypox olarak sınıflandırdığı ve 292 non monkeypox görüntüsünün 288’inin non monkeypox ve 4’ünün monkeypox; HİBRİD veri kümesinde 468 monkeypox görüntüsünün 448’ini monkeypox ve 20’sini non monkeypox olarak sınıflandırdığı ve 812 non monkeypox görüntüsünün 808’inin diğer ve 4’ünü monkeypox olarak sınıflandırdığı görülmektedir. Modelin MSID veri kümesinde monkeypox görüntülerini ayırt etmede başarılı olurken, HİBRİD veri kümesinde bu başarı oranı düşük olup küçük hatalar izlenmektedir.



Şekil 21: InceptionResNetV2 Modelinin Karışıklık Matrisi Analizi

InceptionResNetV2 modeliyle gerçekleştirdiğimiz eğitim sonucunda MSID ve HİBRİD veri kümelerine ait eğitim ve test kümeleri monkeypox ve non monkeypox Tablo 6’da, sınıflandırma işlemi sonucunda elde edilen geri çağırma, F1-skor ve kesinlik değerleri

verilmiştir.

Tablo 6: InceptionResNetV2 Modelinin Sınıflandırma Performans Analizi

		Precision (Kesinlik)	Recall (Geri Çağırma)	F1-score	Support
MSID	0	0.99	0.98	0.99	309
	1	0.98	0.99	0.98	292
	Macro avg	0.98	0.99	0.99	601
	Weighted avg	0.99	0.99	0.99	601
HİBRİD	0	0.99	0.96	0.97	468
	1	0.98	1.00	0.99	812
	Macro avg	0.98	0.98	0.98	1280
	Weighted avg	0.98	0.98	0.98	1280

Tablo 6'dan gözlemlendiği üzere, MSID eğitim veri kümesi için kesinlik, geri çağırma ve F1-skor'u %98 eşit başarı oranı gözlemlenmiştir. Test veri kümesi için ise monkeypox (0) görüntüleri için kesinlik, F1-skor %99 ve geri çağırma %98 başarı oranı gözlemlenmiştir. Non monkeypox (1) verileri için ise %98 kesinlik, %99 geri çağırma ve %98 F1-skor değeri elde edilmiştir.

HİBRİD eğitim veri kümesi için ise kesinlik, geri çağırma ve F1-skor %98 eşit başarı oranı gözlemlenmiştir. Test veri kümesi için monkeypox (0) görüntüleri için %99 kesinlik, %96 geri çağırma ve %97 F1-skor değeri elde edilmiştir. Non monkeypox (1) verileri için ise %98 kesinlik, %100 geri çağırma ve %99 F1-skor değeri elde edilmiştir.

5.3. InceptionV3 Modeliyle Gerçekleştirilen Analiz Sonuçları


Çalışmamızda bu kısımda kullanılan analiz yöntemi InceptionV3 yer almaktadır. Bu yöntem aracılığıyla, veri setimizdeki değişkenler arasındaki ilişkileri anlamak ve önemli bulguları ortaya çıkarmak için çeşitli istatistiksel testler uygulanmıştır.

Tablo 7: InceptionV3 Modelinin Performans Değerlendirmesi

Veri Kümesi	Doğruluk Değeri	(Accuracy)	Kayıp Değeri	(Loss)	Eğitim İçin Geçen Süre
MSID	0.9733		0.0814		2 saat 29 dk 24.16 sn
HİBRİD	0.9679		0.1167		0 saat 55 dk 23.87 sn


Tablo 7'de görüldüğü gibi, iki farklı veri kümesinde InceptionV3 modeliyle gerçekleştirilen eğitimle MSID veri kümesinde 2 saat 29 dakika 24.16 saniye de 0.0814 kayıp oranı ile %97.33, HİBRİD veri kümesinde ise 0 saat 25 dakika 25.38 saniye içerisinde 0.1167 oranlık bir kayıpla %96.79 doğruluk oranı gözlemlenmiştir. Yapılan analizde ilgili modelin pool size değeri en iyi sonuç veren değeri baz alınarak iki veri kümesinde de aynı pool size değeri (5, 5) InceptionV3 için tercih edilmiştir. Bu sonuç da modelimizin maymun çiçeği hastalığının

deri lezyon görüntüleri üzerinden gerçekleşen eğitimin sonunda iki farklı veri kümesinde de başarı oranının iyi düzeyde olduğu görülmektedir. Başarı oranı MSID veri kümesinde daha yüksek elde edilmiştir. Şekil 22'de açıkça görüldüğü gibi, test ve eğitim veri kümelerine göre değerlerin değişimi incelendiğinde, eğitim verilerinde test verilerine kıyasla daha az kayıp ve daha yüksek doğruluk değeri olduğu gözlemlenmektedir. Değerlerin eğitim süreci boyunca dalgalanmalar gösterse de genel olarak düzenli bir şekilde ilerlediği görülmektedir.



Şekil 22: InceptionV3 Modelinin Eğitim İlerlemesi Grafiği

InceptionV3 modeliyle eğitim sonucunda Şekil 23'de MSID veri kümesinde 309 monkeypox, 292 non monkeypox ve HİBRİD veri kümesinde 468 monkeypox, 812 non monkeypox test verilerine özgü karışıklık matrisi gösterilmiştir. InceptionV3 modelinin matris analizine göre, MSID veri kümesinde 309 monkeypox görüntüsünün 302'sinin monkeypox ve 7'sini non monkeypox olarak sınıflandırdığı ve 292 non monkeypox görüntüsünün 283'ünün non monkeypox ve 9'unun monkeypox; HİBRİD veri kümesinde 468 monkeypox görüntüsünün 438'ini monkeypox ve 30'unu non monkeypox olarak sınıflandırdığı ve 812 non monkeypox görüntüsünün 801'ini non monkeypox ve 11'ini monkeypox olarak sınıflandırdığı görülmektedir. Modelin MSID veri kümesinde monkeypox görüntülerini ayırt etmede başarılı olurken, HİBRİD veri kümesinde bu başarı oranı düşük olup küçük hatalar izlenmektedir.



Şekil 23: InceptionV3 Modelinin Karışıklık Matrisi Analizi

InceptionV3 modeli ile gerçekleştirdiğimiz eğitimde MSID ve HIBRID veri kümelerine ait eğitim ve test kümeleri monkeypox ve non monkeypox Tablo 8'de, sınıflandırma işlemi sonucunda elde edilen geri çağırma, F1-skor ve kesinlik değerleri verilmiştir.

Tablo 8: InceptionV3 Modelinin Sınıflandırma Performans Analizi

		Precision (Kesinlik)	Recall (Geri Çağırma)	F1-score	Support
MSID	0	0.97	0.98	0.97	309
	1	0.98	0.97	0.97	292
	Macro avg	0.97	0.97	0.97	601
	Weighted avg	0.97	0.97	0.97	601
HIBRID	0	0.98	0.94	0.96	468
	1	0.96	0.99	0.98	812
	Macro avg	0.97	0.96	0.97	1280
	Weighted avg	0.97	0.97	0.97	1280

Tablo 8'de görüldüğü üzere, MSID eğitim veri kümesi için geri çağırma, F1-skor ve kesinlik değerleri %97 eşit başarı oranı gözlemlenmiştir. Test veri kümesi için monkeypox (0) görüntü kümesi için kesinlik, f1-skor değeri %97 ve geri çağırma değeri %98 olarak gözlemlenmiştir. Ayrıca, non monkeypox (1) görüntü kümesi için geri çağırma, f1-skor değeri %97 ve kesinlik değeri %98 olarak gözlemlenmiştir. HIBRID eğitim veri kümesi için de kesinlik, geri çağırma ve F1-skor değerleri %97 oranı gözlemlenmiştir. Test veri kümesi için monkeypox (0) görüntü kümesi için kesinlik %98, geri çağırma %94 ve f1-skor değeri %96 olarak belirlenirken, non monkeypox (1) verileri için kesinlik %96, geri çağırma %99 ve f1-skor değeri %98 olarak gözlemlenmiştir.

5.4. Xception Modeliyle Gerçekleştirilen Analiz Sonuçları


Çalışmamızda bu kısımda kullanılan analiz yöntemi Xception yer almaktadır. Bu yöntem aracılığıyla, veri setimizdeki değişkenler arasındaki ilişkileri anlamak ve önemli bulguları

ortaya çıkarmak için çeşitli istatistiksel testler uygulanmıştır.

Tablo 9: Xception Modelinin Performans Değerlendirmesi

Veri Kümesi	Doğruluk Değeri (Accuracy)	Kayıp Değeri (Loss)	Eğitim İçin Geçen Süre
MSID	0.9866	0.0404	2 saat 10 dk 8.79 sn
HİBRİD	0.9703	0.1097	0 saat 55 dk 23.87 sn


Tablo 9’da görüldüğü gibi, iki farklı veri kümesinde Xception modeliyle gerçekleştirilen eğitimle MSID veri kümesinde 2 saat 10 dakika 8.79 saniye de 0.0404 kayıp oranıyla %98.66, HİBRİD veri kümesinde ise 0 saat 55 dakika 23.87 saniye süresinde ise 0.1097 kayıp oranı ile %97.03 doğruluk oranı gözlemlenmiştir. Yapılan analizde ilgili modelin pool size değeri en iyi sonuç veren değeri baz alınarak iki veri kümesinde de aynı pool size değeri (2, 2) Xception için tercih edilmiştir. Bu sonuç da modelimizin maymun çiçeği hastalığının deri lezyon görüntüleri üzerinden gerçekleşen eğitimin sonunda iki farklı veri kümesinde de başarı oranının iyi düzeyde olduğu görülmektedir. Başarı oranı MSID veri kümesinde daha yüksek elde edilmiştir. Şekil 24’te gösterilen eğitim ve test verilerine göre değişimlerden anlaşıldığı üzere, eğitim verilerinde test verilerine kıyasla daha az bir kayıp ve daha yüksek bir doğruluk elde edilmiştir. Değerlerin eğitim sürecinde dalgalanmalar gösterse de genel olarak düzenli bir şekilde artış ve azalışlar gerçekleşmiştir.



Şekil 24: Xception Modelinin Eğitim İlerlemesi Grafiği

Xception modeliyle eğitim sonucunda Şekil 25’de MSID veri kümesinde 309 monkeypox, 292 non monkeypox ve HİBRİD veri kümesinde 468 monkeypox, 812 non monkeypox test veri kümesine özgü karışıklık matrisi gösterilmiştir. Matrise göre Xception modelinin, MSID veri kümesinde 309 monkeypox görüntüsünün 303’ünü monkeypox ve 6’sını non monkeypox olarak sınıflandırdığı ve 292 non monkeypox görüntünün 290’ını non monkeypox ve 2’sini monkeypox; HİBRİD veri kümesinde 468 monkeypox görüntüsünün

440'ını monkeypox ve 28'ini non monkeypox olarak sınıflandırdığı ve 812 non monkeypox görüntünün 802'sini non monkeypox ve 10'unu monkeypox olarak sınıflandırdığı görülmektedir. Modelin MSID veri kümesinde monkeypox görüntülerini ayırt etmede başarılı olurken, HIBRID veri kümesinde bu başarı oranı düşük olup küçük hatalar gözlemlenmiştir.



Şekil 25: Xception Modelinin Karışıklık Matrisi Analizi

Xception modeliyle gerçekleştirdiğimiz eğitim sonucunda MSID ve HIBRID veri kümelerine ait eğitim ve test kümeleri monkeypox ve non monkeypox Tablo 10'da, sınıflandırma işlemi sonucunda F1-skor, kesinlik ve geri çağırma değerleri verilmiştir.

Tablo 10: Xception Modelinin Sınıflandırma Performans Analizi

		Precision (Kesinlik)	Recall (Geri Çağırma)	F1-score	Support
MSID	0	0.99	0.98	0.99	309
	1	0.98	0.99	0.99	292
	Macro avg	0.99	0.99	0.99	601
	Weighted avg	0.99	0.99	0.99	601
HIBRID	0	0.98	0.94	0.96	468
	1	0.97	0.99	0.98	812
	Macro avg	0.97	0.96	0.97	1280
	Weighted avg	0.97	0.97	0.97	1280

Tablo 10'da gösterildiği üzere, MSID eğitim veri kümesi için, monkeypox ve non monkeypox sınıflandırmasında f1-skor, geri çağırma ve kesinlik değerleri %99 eşit başarı oranı gözlemlenmiştir. Test veri kümesi için ise monkeypox (0) için f1-skor, Kesinlik değeri %99, ve geri çağırma değeri %98 olarak elde edilmiştir. Non monkeypox (1) veri kümesi için ise kesinlik %98, geri çağırma %99 ve f1-skor %99 olarak belirlenmiştir. HIBRID eğitim veri kümesi için ise, f1-skor, geri çağırma ve kesinlik değerleri %97 başarı oranı gözlemlenmiştir. Test veri kümesinde monkeypox (0) görüntü kümesi için kesinlik %98, geri çağırma %94 ve f1-skor %96 olarak belirlenirken, non monkeypox (1) veri kümesi için kesinlik %97, geri

çağırma %99 ve f1-skor %98 olarak bulunmuştur.


5.5. NasNetLarge Modeliyle Gerçekleştirilen Analiz Sonuçları

Çalışmamızda bu kısımda kullanılan analiz yöntemi NasNetLarge yer almaktadır. Bu yöntem aracılığıyla, veri setimizdeki değişkenler arasındaki ilişkileri anlamak ve önemli bulguları ortaya çıkarmak için çeşitli istatistiksel testler uygulanmıştır.

Tablo 11: NasNetLarge Modelinin Performans Değerlendirmesi


Veri Kümesi	Doğruluk Değeri (Accuracy)	Kayıp Değeri (Loss)	Eğitim İçin Geçen Süre
MSID	0.9883	0.1579	5 saat 33 dk 9.44 sn
HIBRID	0.9578	0.7200	2 saat 3 dk 51.28 sn

Tablo 11’de görüldüğü gibi, iki farklı veri kümesinde NasNetLarge modeliyle gerçekleştirilen eğitimle MSID veri kümesinde 5 saat 33 dakika 9.44 saniye içerisinde 0.1579 oranlık bir kayıpla %98.83, HIBRID veri kümesinde ise 2 saat 3 dakika 51.28 saniye de 0.7200 kayıp oranıyla %95.78 doğruluk oranı gözlemlenmiştir. Yapılan analizde ilgili modelin pool size değeri en iyi sonuç veren değeri baz alınarak iki veri kümesinde de aynı pool size değeri (7, 7) NasNetLarge için tercih edilmiştir. Bu sonuç da modelimizin maymun çiçeği hastalığının deri lezyon görüntüleri üzerinden gerçekleşen eğitimin sonunda iki farklı veri kümesinde de başarı oranının iyi düzeyde olduğu görülmektedir. Başarı oranı MSID veri kümesinde daha yüksek elde edilmiştir. Şekil 26’da gösterildiği üzere, bu değerlerin eğitim ve test veri kümelerine göre değişimi incelendiğinde, eğitim veri kümesinde kaybın test veri kümesine göre daha az olduğu ve doğruluk değerinin daha yüksek olduğu açıkça gözlemlenmiştir. HIBRID veri kümesinde ise test verilerinin kayıp değerinde aşırı dalgalanmalar yaşanmış olup eğitim süreci sağlıklı orak tamamlanamamıştır.



Şekil 26: NasNetLarge Modelinin Eğitim İlerlemesi Grafiği

Şekil 27’de NasNetLarge modeliyle eğitim süreci sonunda elde edilen MSID veri kümesinde 309 monkeypox, 292 non monkeypox ve HIBRID veri kümesinde 468 monkeypox, 812 non monkeypox test veri kümesine ait karışıklık matrisi analizi gösterilmektedir. Xception modelinin matrisine göre, MSID veri kümesinde 309 monkeypox görüntüsünün 303’ünü monkeypox ve 6’sını non monkeypox olarak sınıflandırdığı ve 292 non monkeypox görüntünün 291’ini non monkeypox ve 1’ini monkeypox; HIBRID veri kümesinde çalışma düzensizliğinden sınıflama yapılamamıştır. Modelin MSID veri kümesinde monkeypox görüntülerini ayırt etmede başarılı olurken, HIBRID veri kümesinde sonuçlar elde edilememiştir.



Şekil 27: NasNetLarge Modelinin Karışıklık Matrisi Analizi

Tablo 12’de NasNetLarge modeli ile eğitim süreci sonucunda MSID ve HIBRID veri kümesine ait eğitim ve test veri kümeleri monkeypox ve non monkeypox olarak sınıflandırılmasıyla f1-skor, geri çağırma ve kesinlik değerleri gösterilmiştir.

Tablo 12: NasNetLarge Modelinin Sınıflandırma Performans Analizi

		Precision (Kesinlik)	Recall (Geri Çağırma)	F1-score	Support
MSID	0	1.00	0.98	0.99	309
	1	0.98	1.00	0.99	292
	Macro avg	0.99	0.99	0.99	601
	Weighted avg	0.99	0.99	0.99	601
HIBRID	0	-	-	-	468
	1	-	-	-	812
	Macro avg	-	-	-	1280
	Weighted avg	-	-	-	1280

Eğitim veril kümesine ait Tablo 12’deki sonuçlara göre, MSID veri kümesi için f1-skor, geri çağırma ve kesinlik değerlerinin %99 oranında olduğu gözlemlenmiştir. Test veri kümesi için ise, monkeypox (0) görüntüleri için %100 kesinlik, %98 geri çağırma ve %99 f1-skor değeri elde edilmiştir. Non monkeypox (1) verileri için ise kesinlik değeri %98, geri çağırma değeri

%100 ve f1-skor değeri %99 olarak elde edilmiştir. HIBRID eğitim verileri için ise sınıflandırma yapılamamış ve analiz gerçekleştirilememiştir.

5.6. Modellerin Performans ve Özellik Karşılaştırması

Çalışmamızda bu kısımda ise kullanılan tüm modellerin analiz sonuçları yer almaktadır. Bu yöntemler aracılığıyla, veri setimizdeki değişkenler arasındaki ilişkileri anlamak ve önemli bulguları ortaya çıkarmak için istatistiksel analizler karşılaştırılmıştır.

Tablo 13: Modellerin Performans Karşılaştırması

	Model Adı	Doğruluk	Kesinlik	Geri Çağırma	F1-Skor	Kayıp Değeri	Eğitim Süresi
MSID	DenseNet201	0.9933	0.99	0.99	0.99	0.0302	3 s 11 dk 21.99 sn
	InceptionResNetV2	0.9850	0.99	0.99	0.99	0.0531	5 s 13 dk 45.6 sn
	InceptionV3	0.9733	0.97	0.97	0.97	0.0814	2 s 29 dk 24.16 sn
	NasNetLarge	0.9883	0.99	0.99	0.99	0.1579	5 s 33 dk 9.44 sn
	Xception	0.9866	0.99	0.99	0.99	0.0404	2 s 10 dk 8.79 sn
HIBRID	DenseNet201	0.9851	0.99	0.99	0.99	0.0573	1 s 18 dk 56.93 sn
	InceptionResNetV2	0.9812	0.98	0.98	0.98	0.0724	0 s 50 dk 27.32 sn
	InceptionV3	0.9679	0.97	0.97	0.97	0.1167	0 s 25 dk 25.38 sn
	NasNetLarge	0.9578	-	-	-	0.7200	2 s 3 dk 51.28 sn
	Xception	0.9703	0.97	0.97	0.97	0.1097	0 s 55 dk 23.87 sn

Tablo 13'te yer alan eğitim sürelerini incelediğimizde, çalışmamızda kullanılan modellerin karşılaştırmasını yapmış bulunuyoruz. MSID veri kümesi üzerinde gerçekleştirilen analizlere göre, en kısa eğitim süresine sahip model Xception, toplamda 2 saat 10 dakika 8.79 saniye süresiyle belirlenmiştir. En uzun eğitim süresine sahip model ise NasNetLarge olup, toplamda 5 saat 33 dakika 9.44 saniye süreyle eğitilmiştir. Diğer modellere göre, DenseNet201 modeli 3 saat 11 dakika 21.99 saniye, InceptionResNetV2 modeli 5 saat 13 dakika 45.6 saniye ve InceptionV3 modeli 2 saat 29 dakika 24.16 saniye süresinde eğitim almıştır. Modelleri eğitim sürelerine göre sıraladığımızda, en kısa süreden en uzuna doğru sıralama şu şekildedir: Xception, InceptionV3, DenseNet201, InceptionResNetV2 ve NasNetLarge.

Tablo 13'te yer alan eğitim sürelerini incelediğimizde, HIBRID veri kümesi üzerinde gerçekleştirilen analizlerde kullanılan modellerin karşılaştırmasını yapmış bulunuyoruz. En kısa eğitim süresine sahip model InceptionV3'dür ve toplamda 25 dakika 25.38 saniye

süresiyle eğitilmiştir. En uzun eğitim süresine sahip model ise NasNetLarge olup, toplamda 2 saat 3 dakika 51.28 saniye süreyle eğitim almıştır. Diğer modellere göre, DenseNet201 modeli 1 saat 18 dakika 56.93 saniye, InceptionResNetV2 modeli 50 dakika 27.32 saniye ve Xception modeli 55 dakika 23.87 saniye süresinde eğitim almıştır. Modelleri eğitim sürelerine göre sıraladığımızda, en kısa süreden en uzuna doğru sıralama şu şekildedir: InceptionV3, InceptionResNetV2, Xception, DenseNet201 ve NasNetLarge.

Tablo 13'te yer alan MSID veri kümesi üzerinde yapılan değerlendirmeler doğrultusunda, kullanılan modellerin doğruluk oranlarına göre incelenmiştir. En yüksek doğruluk oranı %99.33 ile DenseNet201 modeliyle elde edilirken, en düşük doğruluk oranı %97.33 ile InceptionV3 modeline aittir. Diğer modellerin doğruluk oranları ise sırasıyla %98.50 (InceptionResNetV2), %98.83 (NasNetLarge) ve %98.66 (Xception) şeklindedir. Doğruluk oranlarına bakıldığında, DenseNet201 modelinin diğer modellere göre daha başarılı olduğu görülmektedir. Bu durumda, modellerin doğruluk oranlarına göre sıralaması şu şekildedir: DenseNet201, NasNetLarge, Xception, InceptionResNetV2 ve InceptionV3.

Tablo 13'te yer alan HIBRID veri kümesi üzerinde yapılan değerlendirmeler doğrultusunda, kullanılan modellerin doğruluk oranlarına göre incelenmiştir. En yüksek doğruluk oranı %98.51 ile DenseNet201 modeliyle elde edilirken, en düşük doğruluk oranı %95.78 ile NasNetLarge modeline aittir. Diğer modellerin doğruluk oranları ise sırasıyla %98.12 (InceptionResNetV2), %96.79 (InceptionV3) ve %97.03 (Xception) şeklindedir. Doğruluk oranlarına bakıldığında, DenseNet201 modelinin diğer modellere göre daha başarılı olduğu görülmektedir. Bu durumda, modellerin doğruluk oranlarına göre sıralaması şu şekildedir: DenseNet201, InceptionResNetV2, Xception, InceptionV3 ve NasNetLarge.

Tablo 13'te gösterilen MSID veri kümesi üzerinde yapılan analizlere göre, kullanılan modellerin geri çağırma, kesinlik, kayıp ve f1-skor değerleri değerlendirilmiştir. DenseNet201, InceptionResNetV2, NasNetLarge ve Xception modellerinde geri çağırma, kesinlik ve f1-skor değerleri %99 olarak eşit ve InceptionV3'e göre daha yüksek bulunmuştur. InceptionV3 modelinde ise geri çağırma, f1-skor ve kesinlik değerleri %97 olarak gözlemlenmiştir. Modeller karşılaştırıldığında en düşük kayıp DenseNet201'de 0.0302 oranında, en yüksek olanı ise NasNetLarge'de 0.1579 oranında elde edilmiştir.

Tablo 13'te yer alan HIBRID veri kümesi üzerinde yapılan analizlere göre, kullanılan modellerin geri çağırma, kayıp, f1-skor ve kesinlik değerleri değerlendirilmiştir. DenseNet201 modelinde f1-skor, kesinlik ve geri çağırma değerleri %99 olarak

gözlemlenmiştir. InceptionV3, InceptionResNetV2, Xception ve NasNetLarge modellerine göre daha yüksek bulunmuştur. InceptionResNetV2 modelinde kesinlik, geri çağırma ve f1-skor değerleri %98 olarak gözlemlenmiştir. InceptionV3 ve Xception modellerinde ise kesinlik, geri çağırma ve f1-skor değerleri %97 olarak eşit bulunmuştur. NasNetLarge modelinde veri analiz bütünlüğünün bozulduğundan dolayı f1-skor, kesinlik ve geri çağırma değerleri elde edilememiştir. Modeller arasında kayıp değeri en düşük olanı ise DenseNet201'de 0.0573 oranında, en yüksek olanı ise NasNetLarge'de 0.7200 oranında elde edilmiştir.



6. SONUÇ VE ÖNERİLER

Salgın, hızla yayılan bir hastalığın belli bir bölge veya toplum içinde yayılması durumunu ifade eder. Salgınlar genellikle bulaşıcı hastalıkların neden olduğu enfeksiyonlardan kaynaklanır. Bu tür hastalıklar, bir kişiden diğerine kolaylıkla geçebilir ve hızla yayılarak büyük bir nüfusu etkileyebilir. Salgınlar genellikle toplum sağlığını tehdit eder ve birçok insanın hastalanmasına ve hatta ölmesine neden olabilir. Salgın hastalıklar, enfekte olan kişilerle temas, solunum damlacıkları, su veya gıda yoluyla bulaşabilir. Salgın hastalıkların yayılmasını önlemek için halk sağlığı önlemleri, karantina, hijyen uygulamaları, aşılar ve tedaviler gibi çeşitli önlemler alınır. Salgınlar, dünya genelindeki sağlık otoriteleri ve hükümetler tarafından yakından takip edilir ve kontrol altına alınmaya çalışılır. Özellikle küresel ölçekte yayılan salgınlar, uluslararası iş birliği ve koordinasyon gerektiren acil durumlar olarak kabul edilir. Örnek olarak, COVID-19 salgını ve Maymun Çiçeği Hastalığı, dünya genelinde büyük etkilere neden olan bir salgın örneğidir. Maymun çiçeği virüsü, ciddi hastalık belirtilerine neden olabilir ve sistemik hastalık riski taşıyan invaziv maruziyetlerden sonra daha yaygın olarak görülür. Hastalığın yayılma potansiyeli ve salgın potansiyeli vardır. Maymun çiçeği hastalığının kontrol altına alınması için kişisel koruyucu önlemler, hijyen uygulamaları ve aşılar önemlidir. Dünya Sağlık Örgütü (DSÖ), hastalığı izlemekte ve kontrol altına almak için çeşitli önlemler almaktadır. Küresel maymun çiçeği salgını, 23 Temmuz 2022'de uluslararası öneme sahip bir halk sağlığı acil durumu (PHEIC) ilan edildi. Salgın hastalıklarla mücadelede tıp ve teknoloji alanında ilerlemeler kaydedilmekte ve daha etkili önleme ve tedavi stratejileri geliştirilmesi hedeflenmektedir. Bu süreçte salgın hastalıkların etkileri en aza indirilmeye ve yayılmasının kontrol altına alınmaya çalışılmaktadır.

Bu tez çalışmasının amacı, daha önce başarılı sonuçlar elde edilen derin öğrenme modelleriyle maymun çiçeği hastalığının tespitini gerçekleştirmek olduğunu belirtmektir. Ayrıca bu çalışmada, daha önce kullanılmamış bazı derin öğrenme modellerinin de yüksek doğrulukla kullanılması hedeflenmektedir. DenseNet201, InceptionResNetV2, InceptionV3, NasNetLarge ve Xception modellerini kullandığımız çalışmada maymun çiçeği hastalığı olan ve olmayan deri lezyon görüntülerinden oluşan MSID veri kümesi ve üç farklı veri kümesinde elde edilen verilerden oluşan HIBRID veri kümesi üzerinden çalışmada maymun çiçeği hastalığı olan ve olmayan deri lezyon görüntüleri iki farklı sınıfa ait verilerin yer aldığı veri kümesiyle çalışılmıştır. Toplam 2097 görüntüden oluşan MSID veri kümesi kullanılarak yapılan çalışmada, verilerin yaklaşık olarak %30'u test verisi, %70'i ise eğitim verisi olarak

kullanılmıştır. Modellerin eğitimi için Python dilinde ve Google Colab Pro'nun sunduğu Jupyter Notebook kullanılmıştır. Çalışma sonucunda, maymun çiçeği hastalığının tespitinde kullanılan modellerin performansı değerleri incelenmiştir. Elde edilen sonuçlara göre, DenseNet201 modeli %99.33 doğruluk, %99 f1-skor, geri çağırma ve kesinlik değeri ile en yüksek başarı oranını elde etmiştir. HIBRID veri kümesinde toplam 4264 görüntü bulunmaktadır. Bu veri seti üzerinde yaklaşık olarak %30'u test verisi ve %70'i eğitim verisi olarak kullanılmıştır. Modellerin eğitimi, Python programlama dili kullanılarak Google Colab Pro'nun sunduğu Jupyter Notebook ortamında gerçekleştirilmiştir. Eğitim süreci boyunca, doğruluk, eğitim süresi, kesinlik, geri çağırma ve f1-skor gibi metrikler dikkate alınarak analizler yapılmıştır. Yapılan analizler sonucunda, maymun çiçeği hastalığının tespitinde kullanılan modellerin performansı şu şekildedir: DenseNet201 modeli %98.51 doğruluk, %99 kesinlik, geri çağırma ve f1-skor değeri ile en yüksek başarı oranını elde etmiştir.

Yapılan analizler sonucunda MSID ve HIBRID veri kümesinde DenseNet201 modeli en başarılı model olup sırasıyla %99.33 ve %98.51 başarı oranı elde ederek tavsiye edebileceğimiz ve bu alanda yapılacak çalışmalara yol gösterici olacaktır. Maymun çiçeği hastalığı tespiti konusunda yaptığımız sınıflandırma işlemlerinde, kullanmış olduğumuz modellerle yüksek doğruluk sonuçları elde ettik. Derin öğrenme modelleri kullanarak deri lezyon görüntülerinden maymun çiçeği hastalığı olup olmadığı konusunda bilgi elde etmek mümkün oldu. Bu yöntemler, maymun çiçeği hastalığıyla ilgilenen kişilerin iş yükünün azaltılması ve hastalığın tespitinin kolaylaştırması açısından büyük önem taşımaktadır. Ancak gerçekleştirdiğimiz tez çalışmanın bazı sınırlılıkları bulunmaktadır.

Öncelikle, derin öğrenme modellerimiz için kullanılan veri setindeki görüntü sayısı büyük bir öneme sahiptir. Ancak, veri seti örneklerini elde etmek zaman alıcı bir süreç olduğundan, genellikle hazır veri setleri kullanmak zorunda kalıyoruz. Bununla birlikte, paylaşılan hazır veri setlerinin sınırlı olması, bazı kısıtlamalar getirebilmektedir. Bunun yanı sıra, gereken donanım kaynaklarının sağlanmasının zorluğu, gerçek sistemlerde modelin performansını değerlendirmeyi zorlaştırabilmektedir. Gelecekteki çalışmalarda, daha kapsamlı ve titizlikle hazırlanan veri setlerinin kullanılması, çeşitli derin öğrenme modelleriyle araştırma yapılması ve bu modellerin kullanılabilirliğinin test edilmesi için yeterli donanıma sahip gerçek zamanlı sistemlerin kullanılması planlanmaktadır. Bu şekilde, elde edilen veri toplama süreci kullanılarak daha çeşitli derin öğrenme modelleriyle çalışılabilir ve bu modellerin kullanılabilirliği yeterli donanım kullanılarak test edilebilir.

7. KAYNAKÇA

- Adem, K. (2022). Impact of activation functions and number of layers on detection of exudates using circular Hough transform and convolutional neural networks. *Expert Systems with Applications*, 203, 117583.
- Adem, K., Ozguven, M. M., & Altas, Z. (2023). A sugar beet leaf disease classification method based on image processing and deep learning. *Multimedia Tools and Applications*, 82(8), 12577-12594.
- 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.
- Akyel, C. (2023). Xception ile Histopatolojik Görüntülerden Oral Kanser Teşhisi. *Journal of Advanced Research in Natural and Applied Sciences*, 9(2), 283-290.
- 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.
- Altun, M. vd. "Monkeypox Detection Using CNN with Transfer Learning." *Sensors* 2023, 23, 1783. <https://doi.org/10.3390/s23041783>
- 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.
- Bingol, H. (2022). Classification of OME with Eardrum Otoendoscopic Images Using Hybrid-Based Deep Models, NCA, and Gaussian Method. *Traitement du Signal*, 39(4).
- 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 .
- Bunge EM, Hoet B, Chen L, Lienert F, Weidenthaler H, Baer LR et al. The changing epidemiology of human monkeypox—a potential threat? A systematic review. *PLoS*

Negl Trop Dis. 2022;16(2):e0010141.

C.Sitaula, T.B.Shahi, (2022, Eylül). Monkeypox Virus Detection Using Pre trained Deep Learning based Approaches., Journal of Medical Systems, 78. <https://doi.org/10.1007/s10916-022-01868-2>

c3.ai. (2022). Model Training. 29.12.2022 tarihinde <https://c3.ai/glossary/data-science/model-training/> sayfasından erişilmiştir.

Centers for Disease Control and Prevention (CDC). Multistate outbreak of monkeypox-- Illinois, Indiana, and Wisconsin, 2003. MMWR. 2003;52:537-40.

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.

Chollet, F. (2017). "Xception: Deep Learning with Depthwise Separable Convolutions." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 1251-1258.

Christian Szegedy, Sergey Ioffe, Vincent Vanhoucke, Alex Alemi. "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning" (2016).

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.

Çeçen, Ş., ve Özer, A. B. (2023, June). Patolojik Meme Kanseri Görüntülerinin YOLOv5 Algoritması ile Sınıflandırılması. In International Conference on Pioneer and Innovative Studies (Vol. 1, pp. 13-18).

Çetiner, H. Yaprak Hastalıklarının Sınıflandırılabilmesi İçin Önceden Eğitilmiş Ağ Tabanlı Derin Ağ Modeli. Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi, 8(15), 442-456.

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>

Diker, A. (2023, February). Derin Öğrenme Yöntemlerini Kullanarak Beyin Felcinin Otomatik Olarak Sınıflandırılması. In International Conference on Trends in Advanced Research (Vol. 1, pp. 182-186).

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.
- 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.
- Goodfellow, I., Bengio, Y., Courville, A., ve Bengio, Y. (2016). Deep Learning (Adaptive Computation and Machine Learning series). MIT Press.
- Grant R, Nguyen LL, Breban R. Modelling humanto-human transmission of monkeypox. Bull World Health Organ. 2020;98(9):638-40.
- 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>
- Hekim, M., Cömert, O., & Adem, K. (2020). A hybrid model based on the convolutional neural network model and artificial bee colony or particle swarm optimization-based iterative thresholding for the detection of bruised apples. Turkish Journal of Electrical Engineering and Computer Sciences, 28(1), 61-79.
- 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.
- K. He, X. Zhang, S. Ren, ve J. Sun, "Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification", 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, 2015, ss. 1026-1034, doi: 10.1109/ICCV.2015.123.
- 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.
- Kılıçarslan, S., Adem, K., & Çelik, M. (2021). An overview of the activation functions

used in deep learning algorithms. Journal of New Results in Science, 10(3), 75-88.

- Konca, M. S. (2020). Evriřimli 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.
- 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).
- Md Manjurul Ahsan vd. (2022, Temmuz). “IMAGE DATA COLLECTION AND IMPLEMENTATION OF DEEP LEARNING-BASED MODEL IN DETECTING MONKEYPOX DISEASE USING MODIFIED VGG16”. arXiv:2206.01862v1 [eess.IV] 4 Jun 2022
- Md. Enamul Haque vd. “Classification of Human Monkeypox Disease Using Deep Learning Models and Attention Mechanisms”. <https://arxiv.org/ftp/arxiv/papers/2211/2211.15459.pdf>
- 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). 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>
- 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>
- Nalca A, Rimoin AW, Bavari S, Whitehouse CA. Reemergence of monkeypox: prevalence, diagnostics, and countermeasures. Clin Infect Dis. 2005;41(12):1765-71.
- Nielsen, M. (2015). Neural Networks and Deep Learning. Determination Press.
- 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>
- 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.
- Pacal, I. (2023). Göğüs Röntgeni Görüntülerinden Otomatik COVID-19 Teşhisi için Görü Transformatörüne Dayalı Bir Yaklaşım. Journal of the Institute of Science and Technology, 13(2), 778-791.
- Reynolds MG, Yorita KL, Kuehnert MJ, Davidson WB, Huhn GD, Holman RC et al. Clinical manifestations of human monkeypox influenced by route of infection. J Infect Dis. 2006;194 (6):773- 80.
- S.N.Ali vd. (2022, Temmuz). Monkeypox Skin Lesion Detection Using Deep Learning Models: A Feasibility Study. Health Lab, Department of Biomedical Engineering, Bangladesh University of Engineering and Technology. Popular Medical College, Dhaka, Bangladesh. arXiv:2207.03342.
- 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>
- 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>
- Tüfekçi P., & GEZİCİ, B. (2023). Derin Öğrenme ile Göğüs Röntgeni Görüntülerinden COVID-19 ve Viral Pnömoni Tespiti. Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi, 23(1), 89-100.
- 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.
- V.H.Şahin vd. (2022, Temmuz). Human Monkeypox Classification from Skin Lesion Images with Deep Pre trained Network using Mobile Application. Journal of Medical Systems. 79.
- World Health Organization. Multi-country monkeypox outbreak in non-endemic countries. Erişim Tarihi 20 Haziran 2022: <https://www.who.int/emergencies/disease-outbreaknews/item/2022-DON385>.
- X. Yu, N. Zeng, S. Liu, and Y.-D. Zhang, “Utilization of DenseNet201 for diagnosis of breast abnormality,” Mach. Vis. Appl., vol. 30, no. 7, pp. 1135–1144, 2019, doi: 10.1007/s00138-019- 01042-8.

- 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.
- Yılmaz, E. K., Adem, K., Kılıçarslan, S., & Aydın, H. A. (2023). Classification of lemon quality using hybrid model based on Stacked AutoEncoder and convolutional neural network. *European Food Research and Technology*, 1-13.
- Yurdusev, A. A., Adem, K., & Hekim, M. (2023). Detection and classification of microcalcifications in mammograms images using difference filter and Yolov4 deep learning model. *Biomedical Signal Processing and Control*, 80, 104360.
- 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>
- Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning Transferable Architectures for Scalable Image Recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)* (pp. 8697-8710). [2] TensorFlow. (n.d.). Retrieved from <https://www.tensorflow.org/>.

EKLER



Aksaray Üniversitesi Tez Değerlendirme Formu		
Öğrencinin Adı Soyadı:		Evet
Kapak		
1	Tez Başlığı tutanaktaki başlıkla aynı mı?	
2	Kapaktaki 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