

TRANSFER ÖĞRENME KULLANILARAK DERİ LEZYON GÖRÜNTÜLERİNDEN MAYMUN ÇİÇEĞİ HASTALIĞININ TESPİTİ

Hüseyin FIRAT^{1*}, Hüseyin ÜZEN²

¹Dicle Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Diyarbakır, 21280, Türkiye

²Bingöl Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Bingöl, 12000, Türkiye

Geliş Tarihi/Received Date: 29.12.2023 Kabul Tarihi/Accepted Date: 30.04.2024 DOI: 10.54365/adyumbd.1411927

ÖZET

Maymun çiçeği, ağırlıklı olarak Orta ve Batı Afrika'da bulunan ve maymun çiçeği virüsü enfeksiyonundan kaynaklanan viral bir hastalıktır. Bulaşma, enfeksiyon kapmış kişilerle yakın temas yoluyla meydana gelmektedir. Grip benzeri semptomlar ve deri döküntüleri şeklinde kendini göstermektedir. Çoğunlukla su çiçeği veya kızamığa benzer ve dolayısıyla yanlış teşhis riskini arttırmaktadır. Etkili tıbbi müdahale için zamanında ve kesin tanı çok önemlidir. Son zamanlarda, derin öğrenmeye dayalı transfer öğrenme yöntemleri, maymun çiçeğini benzer hastalıklardan doğru bir şekilde ayırt etmek için umut verici bir araç olarak ortaya çıkmıştır. Bu çalışma, tıbbi görüntülerden ilgili özellikleri çıkararak sağlam teşhis modelleri oluşturmak için VGG16, ResNet modelleri, Xception, Inception modelleri, DenseNet121 ve DenseNet201 dahil olmak üzere önceden eğitilmiş evrimsel sinir ağlarından yararlanmaktadır. Bu modelleri değerlendirmek için Kaggle'daki iki sınıftan (MaymunÇiçeği ve diğerleri) oluşan "Maymun Çiçeği Cilt Lezyonu Veri Seti" kullanılmıştır. Deneysel bulgular, DenseNet201 modelinin %95.56'ya ulaşarak en yüksek sınıflandırma doğruluğuna ulaştığını ve mevcut literatürle karşılaştırıldığında etkinliğini öne çıkardığını ortaya koymaktadır.

Anahtar Kelimeler: Derin öğrenme, Maymun çiçeği hastalığı, Transfer öğrenimi, Sınıflandırma

MONKEYPOX DISEASE DETECTION FROM SKIN LESION IMAGES USING TRANSFER LEARNING

ABSTRACT

Monkeypox is a viral disease predominantly found in Central and West Africa, resulting from infection with the monkeypox virus. Its transmission occurs through close contact with infected individuals, manifesting as flu-like symptoms and skin rashes, often resembling chickenpox or measles, thus increasing the risk of misdiagnosis. Timely and precise diagnosis is crucial for effective medical intervention. Recently, deep learning-based transfer learning methods have emerged as a promising means to accurately differentiate monkeypox from similar diseases. This study leverages pre-trained convolutional neural networks, including VGG16, ResNet models, Xception, Inception models, DenseNet121, and DenseNet201, to create robust diagnostic models by extracting pertinent features from medical images. The "Monkeypox Skin Lesion Dataset" on Kaggle, comprising two classes (Monkeypox and others), was employed to assess these models. Experimental findings revealed that the DenseNet201 model achieved the highest classification accuracy, reaching 95.56%, highlighting its effectiveness when compared to existing literature.

Keywords: Deep learning, Monkeypox disease, Transfer learning, Classification

* e-posta¹ : hossein.firat@gmail.com ORCID ID: <https://orcid.org/0000-0002-1257-8518> (Sorumlu Yazar)

e-posta² : huzen@bingol.edu.tr ORCID ID: <https://orcid.org/0000-0002-0998-2130>

1. Giriş

Maymun çiçeği virüsünün neden olduğu çiçek hastalığı benzeri bir hastalık olan maymun çiçeği hastalığı, öncelikle Orta ve Batı Afrika'nın yağmur ormanlarında ortaya çıkmıştır [1]. Ancak Mayıs 2022'deki son salgından bu yana birçok ülkeye yayılmış ve küresel bir salgın olma tehdidi oluşturmuştur. Virüs, vücut sıvıları ve solunum damlacıkları ile temas yoluyla bulaşmaktadır. Enfekte kişiler genel olarak birkaç hafta boyunca ateş, şişmiş lenf düğümleri ve vücudun birçok bölgesinde, tipik olarak yüzde, kollarda, bacaklarda, gövdede ve bazen avuç içi ve ayak tabanlarında çok sayıda lezyon döküntüsü gibi tipik semptomlar göstermektedir [2]. Ayrıca baş ağrısı, yorgunluk, kas ağrısı, iştahsızlık ve zihinsel uyanıklıkta değişiklikler gibi nörolojik belirtilere de neden olabilmektedir [3]. Hastalık, etkilenen bireylerin çoğunda kendi kendini sınırlamakta ve sadece semptomatik tedavi gerektirmektedir. Bununla birlikte, mevcut tıbbi rahatsızlıkları olan ve bağışıklık sistemi zayıf olan hastalarda vakaların %3-5'inde ölümle sonuçlanan ciddi tıbbi komplikasyonlar ortaya çıkabilmektedir [4]. Şu anda maymun çiçeği virüsünün tedavisinde kullanılacak spesifik bir ilaç bulunmamaktadır. Bunun yerine, antiviraller ve vaccinia immün globin dahil olmak üzere yetişkinlerde çiçek hastalığının tedavisi için geliştirilen tedaviler, şiddetli maymun çiçeği enfeksiyonunun tedavisi için kullanılmaktadır [5].

Maymun çiçeği hastalığının teşhisi için testler, ABD Gıda ve İlaç Dairesi yönergelerine uygun olarak lezyon örnekleri üzerinde gerçekleştirilmektedir. Örnek almak için lezyon üzerine bir çubuk sürülmekte veya alternatif olarak lezyon kabuğu da örnek olarak alınabilmektedir. Daha sonra bu örnek bir miktar viral taşıma ortamı içine yerleştirilmekte ve polimeraz zincir reaksiyonu (Polymerase Chain Reaction - PCR) test sistemleri kullanılarak maymun çiçeği virüsünün incelenmesi için laboratuvara gönderilmektedir [6]. Ancak PCR testi ile elde edilen sonuçlar, virüsün kanda kısa bir süre kalması nedeniyle yetersiz olabileceğinden kesin değildir [7]. Ayrıca döküntülerin mevcut aşaması, hastanın yaşı, ateş ve lezyon döküntülerinin başlangıç tarihleri gibi ek bilgiler de gerekebilir. Bunun yanı sıra, maymun çiçeğinin teşhis testleri için gereken altyapı kırsal alanlarda da engelleyici bir faktör olabilmektedir [8][9]. Mevcut PCR test yöntemi, teşhis için lezyon örneklerinin alınması, iletilmesi ve test edilmesi sırasında virüsün bulaşma olasılığı yüksek olduğundan, maymun çiçeği virüsüne kişisel olarak maruz kalınmasını gerektirmektedir. Ayrıca, PCR testleri önemli ölçüde zaman almakta ve yanlış negatif sonuçlara da eğilim göstermektedir [10].

Maymun çiçeği tespiti için bilgisayar destekli otomatik sistemler, geleneksel PCR testi ile teşhis yöntemlerine kıyasla çeşitli faydalar sağlayabilmektedir [11]. Böyle bir sistemi geliştirmenin ana motivasyonlarından biri, teşhisin doğruluğunu ve hızını artırmaktır. Maymun çiçeği ateş, döküntü ve solunum sorunları gibi bir dizi belirtiyeye neden olabilen viral bir hastalıktır. Bu semptomlar su çiçeği ve kızamık gibi diğer viral hastalıklarla benzerlik gösterebilmekte ve bu da sağlık çalışanları için teşhisi zorlaştırmaktadır [12]. Yapay zeka, makine öğrenimi ve özellikle derin öğrenme algoritmalarını kullanan otomatik bir sistem, maymun çiçeğine özgü belirli kalıpları ve belirteçleri tanımlamak için büyük miktarda veriyi analiz edebilmekte ve böylece daha doğru bir teşhis sağlayabilmektedir. Ayrıca, otomatik bir sistem maymun çiçeği teşhisi için gereken süreyi kısaltarak hastaların daha hızlı tedavi edilmesine ve izole edilmesine olanak sağlayabilmektedir. Bu, özellikle salgın durumlarında önemlidir, çünkü hızlı tespit ve müdahale hastalığın yayılmasını önlemeye yardımcı olmaktadır [13].

Son yıllarda, maymun çiçeği hastalığını teşhis etmek için derin öğrenme ve özellikle evrişimsel sinir ağlarını (ESA) kullanan çalışmalar yapılmaya başlanmıştır. Sitaula vd. [14] maymun çiçeği virüsünü teşhis etmek için derin öğrenmeyi kullanmıştır. Eğitim ve test işlemleri için önceden eğitilmiş on üç farklı model kullanılmıştır. Öncelikle bu on üç farklı model için sınıflandırma sonuçları hesaplanmıştır. Daha sonra bu modeller arasında, en iyi performans gösteren Xception ve DenseNet169 modellerinden elde edilen olasılıksal çıktılar üzerinde çoğunluk oylaması yaklaşımı kullanılarak topluluk öğrenimi modeli geliştirilmiştir. Deneysel çalışmalar halka açık bir maymun çiçeği veri seti üzerinde gerçekleştirilmiş ve önerilen topluluk öğrenimi modeli yardımıyla sırasıyla %85.44, %85.47, %85.40 ve %87.13 ortalama kesinlik, duyarlılık, F1-skoru ve doğruluk değeri elde edilmiştir. Ahsan vd. [15] maymun çiçeği, su çiçeği, kızamık ve hastalık olmayan normal sınıflara ait görüntüleri kullanarak,

maymun çiçeği hastalığının teşhisi için derin öğrenme tabanlı bir yöntem önermiştir. Daha sonra, iki tekniği göz önünde bulundurarak VGG16 modeli ile bir transfer öğrenme yaklaşımını da değerlendirmişlerdir. İlk teknikte, görüntüler maymun çiçeği ve suçiçeği olarak iki hastalık sınıfına ayrılmıştır. İkinci teknikte ise görüntülere veri arttırımı uygulanmıştır. Deneysel çalışmalarda, veri arttırımı olmadan maymun çiçeğini sınıflandırırken %97, veri arttırımı ile %78 doğruluk elde etmişlerdir. Ali vd. [16] ilk olarak maymun çiçeği, su çiçeği ve kızamığa ait deri lezyonu görüntülerinden oluşan maymun çiçeği deri lezyonu veri seti geliştirdiler. Bu veri setindeki görüntüler çoğunlukla web sitelerinden, haber portallarından ve halka açık vaka raporlarından toplanmıştır. Veri setindeki örneklem boyutunu arttırmak için veri arttırımı kullanılmış ve 3 katlı bir çapraz doğrulama deneyi oluşturulmuştur. Bir sonraki adımda, maymun çiçeği ve diğer hastalıkları sınıflandırmak için VGG16, ResNet50 ve InceptionV3 gibi önceden eğitilmiş derin öğrenme modelleri kullanılarak topluluk öğrenimi modeli oluşturulmuştur. Toplanan maymun çiçeği deri lezyon görüntüleri kullanılarak gerçekleştirilen deneysel çalışmalar sonucunda %79.26 sınıflandırma doğruluk değeri elde ettiler. Akin vd. [17] 12 farklı (ConvNeXt, ShuffleNetV2, ResNeXt50, MobileNetV3, MobileNetV2, GoogleNet, EfficientNetV2, EfficientNetB7, DenseNet161, VGG16, ResNet50 ve ResNet18) derin öğrenme modeli kullanarak maymun çiçeği deri lezyon sınıflandırılması gerçekleştirdiler. Kaggle platformunda halka açık iki sınıftan (maymun çiçeği ve normal) oluşan maymun çiçeği deri görüntüleri veri seti üzerinde gerçekleştirilen deneysel çalışmalar sonucunda en iyi sınıflandırma sonucunu %98.25 doğruluk değeri ile MobileNetV2 modeli ile buldular. Nayak vd. [9] deri lezyonu görüntülerinden maymun çiçeği teşhisi için önceden eğitilmiş beş derin sinir ağı (ResNet18, AlexNet, SqueezeNet, Places365-GoogLeNet ve GoogLeNet) üzerinde çalışmalar gerçekleştirdi. Kaggle platformunda yer alan ve halka açık maymun çiçeği deri görüntü veri seti üzerinde deneysel çalışmalar gerçekleştirilmiştir. Bu veri setinde maymun çiçeği ve maymun çiçeği olmayan hastalık olmak üzere iki sınıf bulunmaktadır. Orijinal veri seti üzerinde veri arttırımı uygulanarak deneysel çalışmalarda en iyi sınıflandırma sonucu %99.49 ile ResNet18 modelinde bulunmuştur. Nayak vd. [10] maymun çiçeği deri döküntülerine neden olan diğer benzer hastalıklardan (kızamık ve su çiçeği) teşhis etmek için dört transfer öğrenme modeli (SqueezeNet, ResNet10, ResNet18, ResNet50) kullandılar. Kaggle platformunda yer alan deri lezyon görüntüleri kullanarak gerçekleştirilen deneysel çalışmalarda maymun çiçeği sınıfı için ResNet18 ile %91.19 doğruluk ve %92.55 F1-skoru elde ettiler. Bala vd. [18] çok sınıflı deri görüntülerinden maymun çiçeğini sınıflandırmak için "MonkeyNet" adlı modifiye edilmiş DenseNet-201 tabanlı bir derin ESA modeli sundular. Deneysel çalışmalarda kullanılmak üzere maymun çiçeği, suçiçeği, kızamık ve normal görüntüler olmak üzere dört farklı görüntü sınıfından oluşan "Maymun Çiçeği Deri Görüntüleri Veri Seti" adlı tamamen yeni bir görüntü veri seti geliştirdiler. Daha sonra bu veri setine veri arttırımı uyguladılar. Bu veri seti üzerinde gerçekleştirilen deneysel çalışmalar sonucunda önerilen yöntem ile %98.91 doğruluk değeri elde ettiler.

Maymun çiçeği hastalığının en belirgin özelliği ciltteki lezyonlarıdır. Bu hastalık sonucu oluşan deri lezyonlarının diğer lezyon hastalıklarından hızlı bir şekilde ayırt edilmesi tedaviye erken başlanması açısından önemlidir. Bu bağlamda çalışmamızın amacı, küresel ölçekte hızla yayılmaya başlayan maymun çiçeğinin deri lezyonları üzerindeki etkisini transfer öğrenme yöntemleri ile hızlı ve yüksek doğruluk oranı ile ayırt ederek doğru bir şekilde sınıflandırmaktır. Bu doğrultuda bu çalışmada 9 farklı (VGG16, ResNet50, ResNet101, ResNet152, Xception, InceptionV3, InceptionResNetV2, DenseNet121 ve DenseNet201) transfer öğrenme yöntemi kullanılarak maymun çiçeği hastalık görüntüleri sınıflandırılmıştır. Transfer öğrenme yöntemlerinin sınıflandırma performans sonuçlarını görmek için iki sınıf (maymun çiçeği ve diğer hastalıklar (kızamık, suçiçeği ve normal)) içeren maymun çiçeği deri lezyonu veri seti kullanılmıştır [16]. Veri setinin orijinal görüntüleri toplam 228 görüntü içermektedir. Bunlardan 102'si maymun çiçeği sınıfına aittir ve kalan 126'sı diğer sınıfları, yani maymun çiçeği olmayan (su çiçeği ve kızamık) hastalıklarını temsil etmektedir. Ancak çalışma kapsamında veri arttırımı uygulanarak görüntü sayıları arttırılmıştır. Bu veri seti kullanılarak iki farklı deneysel çalışma yapılmıştır. İlk deneysel çalışmalarda 9 farklı derin öğrenme yöntemi sıfırdan eğitilmiş ve sonuçlar elde edilmiştir. İkinci deneysel çalışmalarda ise transfer öğrenimi kullanılmıştır. Sıfırdan eğitim sonucunda VGG16, ResNet50, ResNet101, ResNet152, Xception, InceptionV3, InceptionResNetV2, DenseNet121 ve DenseNet201 yöntemleri için elde edilen doğruluk değerleri sırasıyla şu şekildedir: %68.89, %71.11,

%68.89, %68.89, %62.22, %66.67, %71.11, %68.89 ve %64.44. Transfer öğrenme kullanılarak gerçekleştirilen deneysel çalışmalar sonucunda elde edilen doğruluk değerleri ise sırasıyla şu şekildedir: %77.78, %84.44, %80, %77.78, %91.11, %88.89, %88.89, %84.44 ve %95.56. Deneysel sonuçlar incelendiğinde transfer öğreniminin daha başarılı sonuçlar verdiği görülmektedir. Transfer öğrenimi yöntemleri arasında ise en iyi doğruluk değeri %95.56 ile DenseNet201 yöntemi ile elde edilmiştir.

Bu çalışmanın diğer bölümlerinin organizasyonu şu şekildedir: Bölüm 2’de, çalışmada kullanılan maymun çiçeği veri seti ve önerilen transfer öğrenimi yöntemleri yer almaktadır. Bölüm 3’te gerçekleştirilen deneysel çalışmalar kapsamlı bir şekilde ele alınmıştır. Bölüm 4’te ise çalışmanın genel bir değerlendirilmesinin yer aldığı sonuçlar bölümüne yer verilmiştir.

2. Materyal ve Metod

Bu bölümde çalışmada kullanılan veri seti, veri artırımı ve transfer öğrenme yaklaşımları detaylı açıklanmıştır.

2.1. Maymun Çiçeği Deri Lezyon Görüntüleri Veri Seti

Transfer öğrenme modellerini eğitmek için kullanılan veri seti, maymun çiçeği deri lezyon veri seti (Monkeypox Skin Lesion Dataset) olarak adlandırılmıştır [16]. Maymun çiçeği ve Maymun çiçeği olmayan görüntüler için ikili bir sınıflandırma veri setidir ve Kaggle’da (veri bilimcileri ve makine öğrenimi uygulayıcılarından oluşan çevrimiçi bir topluluk) mevcuttur [19]. Veri seti, haber portalları, web siteleri ve kamuya açık vaka raporları gibi farklı web tarama araçlarından görüntülerin toplanması ve işlenmesiyle oluşturulmuştur. Maymun çiçeği deri lezyon veri setinin oluşturulması öncelikle maymun çiçeği vakalarını maymun çiçeği olmayan benzer vakalardan ayırt etmeye odaklanmıştır. Bu nedenle, 'Maymun Çiçeği' sınıfının yanı sıra, ikili sınıflandırma yapmak için 'Diğerleri' adlı başka bir sınıfa, başlangıç durumundaki maymun çiçeği döküntüsüne benzerliklerinden dolayı 'Suçiçeği' ve 'Kızamık' cilt lezyonu görüntüleri dahil edilmiştir. Orijinal görüntülerde, toplam 228 görüntü bulunmaktadır; bunlardan 102’si 'Maymun Çiçeği' sınıfına aittir ve geri kalan 126’sı 'Diğerleri' sınıfını, yani maymun çiçeği olmayan (su çiçeği ve kızamık) vakaları temsil etmektedir. Görüntüler 224x224x3 boyutundadır. Her iki sınıfa ait bazı görüntüler Şekil 1’de yer almaktadır.



Şekil 1. Veri setindeki örnek deri görüntüleri [9]

2.2. Veri Arttırımı

Veri arttırma, orijinal verilere rastgele dönüşümler uygulayarak bir veri setindeki görüntü sayısını arttırmak için kullanılan bir işlemdir. Elde edilen orijinal veri seti, veri setindeki görüntüleri toplayanlar tarafından arttırılmıştır. Veri arttırımı yapılmasının amacı, ağıın sınıflandırma performansını arttırmaktır. Döndürme, öteleme, yansıma, kesme, renk tonu, doygunluk, kontrast ve parlaklık titreşimi, gürültü ve ölçekleme gibi veri arttırma yöntemleri kullanılmıştır. Kaggle platformunda yer alan veri seti farklı klasörlerden oluşmaktadır. Çalışma kapsamında Fold1 klasöründeki eğitim-test ve doğrulama görüntüleri kullanılmıştır. Fold 1 klasöründe, orijinal görüntülerin yer aldığı veri setine üç kat çapraz doğrulama uygulanmıştır. Bu klasörde, yaygın olarak algılanan veri hazırlama uygulamasına göre, test veri seti yalnızca orijinal görüntüleri içerirken yalnızca eğitim ve doğrulama görüntüleri arttırılmıştır. Veri arttırımından sonra Fold1 klasöründe, eğitim için 2142, doğrulama için 420 ve test için 45 görüntü yer almaktadır. Veri arttırımından sonra elde edilen eğitim, test ve doğrulama görüntülerinin ayrıntılı dağılımı Çizelge 1'de verilmiştir. Çalışmada gerçekleştirilen deneysel çalışmalarda eğitim, test ve doğrulama oranları Çizelge 1'deki gibi alınmıştır.

Çizelge 1. Maymun çiçeği deri lezyon görüntülerinin veri arttırımı sonucunda dağılımı

| | Eğitim (Train) | Doğrulama (Validation) | Test |
|---------------|----------------|------------------------|------|
| Maymun Çiçeği | 980 | 168 | 20 |
| Diğerleri | 1162 | 252 | 25 |
| Toplam | 2142 | 420 | 45 |

2.3. Transfer Öğrenimi

Transfer öğrenimi, bir görev üzerinde eğitilen bir modelin farklı ancak ilgili bir görevi yerine getirmek üzere uyarlandığı veya ince ayarının yapıldığı bir makine öğrenimi tekniğidir. Yeni görevde sıfırdan bir model eğitmek yerine, transfer öğrenimi orijinal görevden öğrenilen bilgi ve özelliklerden yararlanmaktadır. Bu, eğitim sürecini önemli ölçüde hızlandırabilmekte ve özellikle yeni görev için sınırlı veriye sahip olduğunuzda genellikle daha iyi performansla sonuçlanabilmektedir. Transfer öğrenme süreci genel olarak şu adımları içermektedir. (1) Ön eğitim: Bir model başlangıçta bir kaynak görev için büyük bir veri seti üzerinde eğitilmektedir. Bu görev, görüntü sınıflandırma gibi genel bir görev olabilmektedir. (2) Özellik çıkarma: Önceden eğitilmiş model bir özellik çıkarıcı olarak kullanılmaktadır. Son sınıflandırma katmanından önceki katmanlar dondurulmakta ve model, hedef görevle ilgili yeni veri setinden özellikler çıkarmak için kullanılmaktadır. (3) İnce ayar: Önceden eğitilmiş model daha sonra değiştirilebilmektedir. Son katmanlar belirli hedef görev için değiştirilebilir veya yeniden eğitilebilmektedir. Bu ince ayar adımı, modelin öğrenilen özelliklerini yeni göreve uyarlamaktadır. Bu çalışma kapsamında ImageNet veri seti kullanılarak önceden eğitilmiş olan 9 farklı derin öğrenme yöntemi kullanılmaktadır. Bunlar, VGG16 [20], ResNet50-ResNet101-ResNet152 [21], Xception [22], InceptionV3 [23], InceptionResNetV2 [24], DenseNet121-DenseNet201 [25] yöntemleridir.

2.3.1. VGG16

VGG16, Oxford Üniversitesi'ndeki Visual Graphics Group (VGG) araştırmacıları tarafından önerilen derin bir evrişimli sinir ağı mimarisidir. Adını gruptan ve 16 katmana (13 evrişimsel katman ve 3 tam bağlantılı katman) sahip olmasından almaktadır. VGG16, 2014 yılında Karen Simonyan ve Andrew Zisserman tarafından yazılan "Very Deep Convolutional Networks for Large-Scale Image Recognition" başlıklı makalede tanıtılmıştır [20]. VGG16, basitliği ve tek tip mimarisiyle bilinmektedir. Çeşitli katman yapılandırmaları kullanan önceki derin öğrenme modellerinin aksine VGG16, özellik haritalarının uzamsal boyutlarını azaltmak için maksimum havuzlama katmanlarıyla birlikte ağı boyunca 3x3 evrişimsel filtreler kullanılmaktadır. Küçük 3x3 filtrelerin kullanılması, ağı daha karmaşık özellikleri öğrenmesini sağlamaktadır. Ayrıca, VGG16 nispeten çok sayıda parametreye sahiptir, bu da

onu eğitmek için hesaplama açısından pahalı hale getirebilmektedir. Bununla birlikte, bu büyük kapasite, verilerden karmaşık özellikleri yakalamasına ve öğrenmesine olanak tanımaktadır. VGG16, etiketli görüntülerden oluşan büyük bir veri seti olan ImageNet veri seti üzerinde önceden eğitilmiştir ve genellikle transfer öğrenimi için kullanılmaktadır. Araştırmacılar, önceden eğitilmiş VGG16 modelini alıp belirli bilgisayarla görme görevleri için ince ayar yapabilmektedir. Bu ince ayar işlemi, modelin ImageNet üzerinde öğrendiği bilgilerden yararlanarak görüntü ile ilgili diğer görevlerdeki performansını arttırabilmektedir.

2.3.2. ResNet50-ResNet101-ResNet152

ResNet (Artık Ağ), Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından 2015 yılında "Görüntü Tanıma için Derin Artık Öğrenme (Deep Residual Learning for Image Recognition)" başlıklı makalelerinde tanıtılan bir derin evrişimli sinir ağı mimarileri ailesidir [21]. ResNet, çok derin sinir ağlarında sıklıkla ortaya çıkan kaybolan gradyan sorununu ele alma konusundaki yeniliğiyle bilinmektedir. ResNet'in arkasındaki temel fikir, bilginin ağda daha kolay akmasını sağlayan artık bağlantıların veya atlama bağlantılarının kullanılmasıdır. Bu atlama bağlantıları esasen bir veya daha fazla katmanı atlayarak çok derin ağların eğitilmesini mümkün kılmaktadır. ResNet mimarisinin ResNet50, ResNet101 ve ResNet152 dahil olmak üzere, öncelikle derinlikleri, yani sahip oldukları katman sayısı bakımından farklılık gösteren çeşitli varyantları vardır. Bunlar aşağıdaki gibidir.

ResNet50: ResNet mimarisinin nispeten sığ bir çeşididir. Evrişimsel katmanlar, toplu normalizasyon ve tam bağlı katmanlar dahil olmak üzere toplam 50 katmana sahiptir. "50" ağdaki toplam katman sayısını göstermektedir. Bu model genellikle çok çeşitli bilgisayarla görme görevleri için kullanılmakta ve hesaplama kaynaklarının sınırlı olduğu durumlar için uygundur.

ResNet101: ResNet50'ye kıyasla ResNet'in daha derin bir çeşididir. Toplamda 101 katmana sahiptir, daha fazla derinlik ve bazı durumlarda daha iyi performans sunmaktadır. Daha derin ağlar daha karmaşık özellikleri yakalayabilmekte ve yeterli hesaplama kaynaklarının mevcut olması koşuluyla zorlu görevlerde daha iyi performans gösterebilmektedir.

ResNet152: Toplam 152 katmanıyla ResNet101'den bile daha derindir. Bahsettiğimiz üç varyant arasında en derin olanıdır. Artan derinlik, ResNet152'nin giriş verilerinden daha karmaşık ve ince taneli özellikleri yakalamasını sağlamaktadır. Ancak bu aynı zamanda daha fazla hesaplama kaynağı gerektirmekte ve eğitilmesi daha uzun sürebilmektedir.

Tüm bu ResNet varyantları, görüntü sınıflandırma, nesne algılama ve diğer bilgisayarla görme görevlerinde oldukça etkili sonuçlar üretmektedir. Genellikle büyük görüntü veri setleri üzerinde önceden eğitilmiş modellerin belirli uygulamalar için ince ayarının yapıldığı transfer öğrenme için temel olarak kullanılırlar. Araştırmacılar, önceden eğitilmiş ResNet modellerini alıp bunları görüntüyle ilgili farklı görevlere uyarlayarak sıfırdan eğitime kıyasla zaman ve kaynak tasarrufu sağlayabilmektedirler. ResNet50, ResNet101 ve ResNet152 arasındaki seçim, görevin özel gereksinimlerine, mevcut hesaplama kaynaklarına ve istenen model derinliği seviyesine bağlıdır.

2.3.3. Xception

Xception, Keras derin öğrenme kütüphanesinin oluşturucusu François Chollet tarafından "Deep Learning with Depthwise Separable Convolutions" başlıklı 2017 yılında yayınlanan bir araştırma makalesinde tanıtılan bir derin evrişimli sinir ağı mimarisidir. "Xception" ismi "Extreme Inception" anlamına gelmekte ve Inception sinir ağı mimarileri ailesiyle olan ilişkisini göstermektedir [22]. Xception, özellikle derinlemesine ayrılabilir evrişimler kullanarak evrişimlere getirdiği yeni yaklaşımla bilinmektedir. Tüm giriş görüntüsüne tek bir evrişimsel filtre uygulayan geleneksel evrişimlerin aksine, derinlemesine ayrılabilir evrişim işlemi uygulanmaktadır. Bu işlem geleneksel evrişimi iki aşamaya ayırmaktadır: derinlemesine evrişim ve noktasal evrişim. Derinlemesine evrişimde, giriş görüntüsünün her kanalına bağımsız olarak ayrı bir evrişim işlemi uygulanmaktadır. Bu işlem, aynı filtrenin tüm giriş kanallarına uygulandığı geleneksel evrişimlere kıyasla hesaplama maliyetini önemli ölçüde azaltmaktadır. Noktasal evrişim, derinlemesine evrişimden sonra çıkış kanallarını birleştirmek için noktasal evrişim olarak da bilinen 1x1 evrişim uygulanmaktadır. Bu adım, çıkış kanallarının doğrusal

kombinasyonlarına izin vererek karmaşık desenlerin yakalanmasına yardımcı olmaktadır. Xception'da derinlemesine ayrılabilir evrişimlerin kullanılması, model parametrelerinin ve hesaplama kaynaklarının daha verimli kullanılmasını sağlamaktadır. Bu mimari seçim, son derece etkileyici ve verimli bir derin öğrenme modeliyle sonuçlanmaktadır. Xception ayrıca ResNet mimarilerine benzer şekilde kaybolan gradyan sorununu hafifletmek için atlama bağlantıları kullanmaktadır.

Xception sinir ağı, 71 katman derinliğe sahip bir ESA mimarisidir. Xception mimarisi, ağı özellik çıkarma sürecinin temelini oluşturan toplam 36 evrişimli katman içermektedir. Evrişimli katmanlar toplam 36 katman olacak şekilde 14 modül halinde gruplandırılmıştır. İlk ve son modüller hariç tüm modüller kendilerini çevreleyen doğrusal artık bağlantılara sahiptir. Xception mimarisi, artık bağlantılara sahip, derinlemesine ayrılabilir evrişim katmanlarının doğrusal bir yığından oluşmaktadır. Xception modeli, 1000'den fazla sınıfa ait 14 milyon görüntünün yer aldığı ImageNet'te %94.5 doğruluk elde etmiştir [22].

2.3.4. InceptionV3

InceptionV3, Inception mimarisi kullanılarak bir araya getirilen ve GoogleNet olarak da bilinen InceptionV1'in geliştirilmiş versiyonudur. InceptionV3, Google araştırmacıları tarafından 2015 yılında "Rethinking the Inception Architecture for Computer Vision" başlıklı bir makalede tanıtılmıştır [23]. InceptionV3'ün arkasındaki temel fikir, ağı farklı uzamsal ölçeklerdeki bilgileri verimli bir şekilde yakalamasını sağlayan Inception modüllerinin kullanılmasıdır. Bu modüller, giriş verilerini aynı anda farklı çözünürlüklerde işlemek için aynı katman içinde birden fazla boyutta (1x1, 3x3, 5x5, vb.) filtreler kullanmaktadır. Bu, ağı giriş görüntülerinden çok çeşitli özellikler öğrenmesini sağlayarak görüntü sınıflandırma görevlerinde doğruluğun artmasına yol açmaktadır. InceptionV3 ayrıca aşırı öğrenmeyi azaltmaya ve modelin genellemesini iyileştirmeye yardımcı olan toplu normalleştirme ve çarpanlarına ayrılmış 7x7 evrişimler de içermektedir. Mimari, giriş görüntülerinden karmaşık desenleri ve hiyerarşik özellikleri yakalayabilen derin bir ağ oluşturarak üst üste yığılmış bu türden birden fazla Inception modülü içermektedir.

2.3.5. Inception-ResNetV2

Inception-ResNetV2, Inception mimarisi ve ResNet'ten artık bağlantılar kavramlarını birleştiren derin bir evrişimli sinir ağı mimarisidir. Christian Szegedy, Sergey Ioffe, Vincent Vanhoucke ve Alexander A. Alemi tarafından 2016 yılında "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning" başlıklı makalede tanıtılmıştır [24]. Inception-ResNetV2, hem Inception mimarisinin hem de ResNet mimarisinin bir uzantısıdır. Inception modüllerinin çok dallı mimarisinden yararlanırken, kaybolan gradyan sorununu ele almak ve çok derin ağların eğitimini sağlamak için artık bağlantılar içermektedir. Orijinal Inception mimarisine benzer şekilde, Inception-ResNetV2 çeşitli ölçeklerdeki özellikleri yakalamak için paralel olarak farklı boyutlarda çok ölçekli evrişimsel filtreler kullanmaktadır. Bunun yanı sıra, kısayol bağlantılarının bir veya daha fazla katmanı atlayarak eğitim sırasında gradyanların daha kolay akmasına izin verdiği artık bağlantıları kullanmaktadır. Bu, gradyanların kaybolma riski olmadan çok derin ağların eğitimine yardımcı olmaktadır. Ayrıca, hesaplama maliyetini azaltmak için çarpanlara ayrılmış evrişimler kullanmaktadır. Çarpanlara ayrılmış evrişimler, daha büyük evrişimleri daha küçük, daha verimli işlemlere ayırarak parametre sayısını ve hesaplama karmaşıklığını azaltmaktadır. Son olarak, toplu normalizasyon, ağ içindeki aktivasyonları normalleştirmek için uygulanmakta ve eğitim sırasında daha hızlı yakınsamaya yardımcı olmaktadır.

2.3.6. DenseNet121-DenseNet201

DenseNet121 ve DenseNet201, özellikle bilgisayarla görme alanında derin öğrenme görevleri için tasarlanmış olan DenseNet (Densely Connected Convolutional Networks-Yoğun Bağlantılı Evrişimsel Ağlar) mimarisinin iki çeşididir. DenseNet'teki "Dense", her katmanın diğer her katmana ileri beslemeli bir şekilde bağlandığı ağ içindeki yoğun bağlantıyı ifade etmektedir [25].

DenseNet121: DenseNet mimarisinin özel bir çeşididir ve "121" sayısı ağıdaki toplam katman sayısını göstermektedir. Bu mimari, evrişimsel katmanlar, toplu normalizasyon ve tam bağlı katmanlar

dahil olmak üzere toplam 121 katmandan oluşmaktadır. Her katmanın bir bloktaki önceki tüm katmanlardan özellik haritaları aldığı yoğun bir bağlantı modeli kullanılmaktadır. Bu, özelliğin yeniden kullanılmasını sağlamakta, gradyan akışını iyileştirmekte ve yüksek verimli ve parametre açısından etkili modellerle sonuçlanmaktadır. DenseNet121 görüntü sınıflandırma, nesne algılama ve segmentasyon gibi çok çeşitli bilgisayarla görme görevlerinde yüksek doğruluk elde etme kabiliyetiyle bilinmektedir. ImageNet gibi büyük görüntü veri setleri üzerinde önceden eğitilmiştir, bu da onu çeşitli uygulamalarda transfer öğrenimi için uygun hale getirmektedir.


DenseNet201: DenseNet mimarisinin DenseNet121'e kıyasla daha derin bir çeşididir. Adındaki "201" toplam 201 katmandan oluştuğunu göstermektedir. Arttırılmış model derinliği sunarak giriş verilerinden daha karmaşık özelliklerin ve desenlerin yakalanmasına olanak tanımaktadır. Bu artan derinlik, zorlu bilgisayarlı görme görevleri için avantajlı olabilmektedir. DenseNet201, DenseNet121 gibi görüntü sınıflandırma ve nesne tanıma gibi görevler için uygundur. Derin mimarisi gelişmiş özellik öğrenme yetenekleri sağlamaktadır. DenseNet121 gibi, DenseNet201 modelleri de genellikle büyük veri setleri üzerinde önceden eğitilmekte ve transfer öğrenimi kullanılarak belirli görevler için ince ayarlar yapılabilmektedir.

Hem DenseNet121 hem de DenseNet201, özelliklerin yeniden kullanımını destekleyen ve kaybolan gradyan sorunu gibi sorunları azaltmaya yardımcı olan yoğun bağlantı özelliğini paylaşmaktadır. Derin öğrenme alanına önemli katkılarda bulunmuşlardır ve etkileyici performansları ve verimlilikleri nedeniyle çeşitli bilgisayarla görme uygulamalarında yaygın olarak kullanılmaktadırlar. İkisi arasındaki seçim, görevin özel gereksinimlerine ve mevcut hesaplama kaynaklarına bağlıdır; DenseNet201 daha derin ve potansiyel olarak daha güçlüdür ancak daha fazla hesaplama kaynağı gerektirmektedir.

2.4. Önerilen Yöntem

Transfer öğrenimi için önceden eğitilmiş modellerin kullanıldığı önerilen yöntemin şeması Şekil 2'deki gibidir. Şekil 2'de gösterildiği gibi, girdi görüntüleri önceden eğitilmiş modellerin girişine verilmeden önce ilk olarak veri arttırımı uygulanmıştır. Daha sonra 224x224x3 boyutundaki girdi eğitim görüntüleri ayrı ayrı 9 farklı önceden eğitilmiş ağ modelleri kullanılarak eğitim işlemi gerçekleştirilmiştir. Çalışma kapsamında kullanılan önceden eğitilmiş ağ modelleri şu şekildedir: VGG16, ResNet50, ResNet101, ResNe152, Xception, InceptionV3, InceptionResNetV2, DenseNet121 ve DenseNet201. Her bir önceden eğitilmiş modelden sonra elde edilen çıktı özellik haritasına sırasıyla global ortalama havuzlama (GOH), toplu normalleştirme ve 0.3 dropout oranına sahip dropout (bırakma) katmanı uygulanmıştır. GOH, son sınıflandırma katmanından (softmax) önce özellik haritalarının uzamsal boyutlarını azaltmak için ESA'larda yaygın olarak kullanılan bir tekniktir. Tam bağlantılı katmanlar kullanmak yerine GOH, özellik haritasındaki tüm değerlerin ortalamasını hesaplayarak her özellik haritası için tek bir değer elde etmektedir. GOH kullanmanın bazı avantajları şu şekildedir: (i) Ağdaki parametre sayısını azaltarak, özellikle sınırlı miktarda eğitim verisi ile çalışırken önemli olan aşırı öğrenmeyi azaltmaya yardımcı olabilmektedir. Ayrıca bir tür düzenleme işlevi de görebilmektedir. (ii) Tam bağlantılı katmanlarla karşılaştırıldığında, GOH hesaplama açısından daha verimlidir. Tam bağlantılı katmanlar, özellikle yüksek çözünürlüklü özellik haritalarıyla uğraşırken çok sayıda parametre ve hesaplama kaynağı gerektirmektedir. GOH hesaplama karmaşıklığını önemli ölçüde azaltmaktadır. Bunun yanı sıra, GOH basit bir işlemdir ve uygulanması basittir. Eğitim sürecini basitleştirebilecek herhangi bir ek parametrenin öğrenilmesini gerektirmez. (iii) GOH, tamamen bağlı katmanlara kıyasla daha az bellek gerektirmektedir; bu da onu mobil veya yerleşik cihazlar gibi kaynakları kısıtlı uygulamalar için iyi bir seçim haline getirmektedir. (iv) Önceden eğitilmiş modellere ince ayar yapılırken, tamamen bağlı katmanların GOH katmanlarıyla değiştirilmesi yaygın bir uygulamadır. Bu, eğitim öncesi aşamada öğrenilen bilgileri korurken modeli farklı bir göreve uyarlamaya olanak tanımaktadır. Önceden eğitilmiş ağ modellerinde toplu normalleştirme kullanıldığında, (i) yeni görevler veya veri setleri üzerinde ince ayar yapılması sırasında modelin kararlılığının ve performansının korunmasına yardımcı olmaktadır. (ii) Modelin yakınsaması için gereken eğitim yinelemelerinin sayısını azaltarak eğitim sürecini hızlandırmaktadır. Bu, daha hızlı eğitimle sonuçlanmaktadır. Yani, eğitim sürecini hızlandırmak ve kolaylaştırmak için toplu

normalleştirme kullanılmaktadır. Önerilen modelde dropout (bırakma) katmanı kullanılmasının avantajları ise şu şekildedir: Dropout (Bırakma), aşırı öğrenmeyi önlemek için etkili bir düzenleme tekniği olarak hizmet etmektedir. Eğitim sırasında nöronların bir kısmını rastgele devre dışı bırakarak modelin yeni görevlere veya veri setlerine daha iyi genelleştirilmesine yardımcı olmaktadır. Bu bırakmanın neden olduğu rastgelelik, belirli öğrenilen özelliklere olan bağımlılığı azaltarak modeli ince ayar sırasında daha uyarlanabilir ve sağlam hale getirmektedir. Sonuç olarak, dropout (bırakma), modelin çeşitli veri dağılımlarına genelleme yeteneğini geliştirebilmekte ve transfer öğrenme senaryolarındaki performansını artırabilmektedir. GOH, toplu normalleştirme ve dropout katmanlarından sonra elde edilen özellik haritası sınıflandırma işlemi için softmax sınıflandırıcısının girişine verilmektedir. Softmax, sinir ağında sınıflandırma görevleri için son katman olarak kullanılmaktadır. Softmax sınıflandırıcı, girdi olarak rastgele gerçek değerli puanlardan oluşan bir vektörü almakta ve bunları birden fazla sınıf üzerinde bir olasılık dağılımına dönüştürmektedir. Softmax, girdi puanlarını üstelleştirerek bunları pozitif değerlere dönüştürmekte ve ardından bu değerleri tüm üstelleştirilmiş puanların toplamına bölerek normalleştirmektedir. Bu normalleştirme, elde edilen değerlerin 0 ile 1 arasında olmasını ve olasılıkları temsil eden toplamın 1'e kadar çıkmasını sağlamaktadır. Daha sonra en yüksek olasılığa sahip sınıf, çıktı sınıfı olarak tahmin edilmektedir.



Şekil 2. Önerilen yöntem

3. Deneysel Çalışmalar ve Sonuçları

Deneysel çalışmalar ve sonuçlar bu bölümde ayrıntılı olarak açıklanmıştır. Bu bölümün alt başlıklarından ilki deneysel çalışmalarda kullanılan hiperparametrelerin yer aldığı deneysel kurulum bölümüdür. İkinci bölümde, deneysel çalışmalarda kullanılan değerlendirme ölçütleri yer almaktadır. Son alt bölümde, çeşitli transfer öğrenme modelleriyle elde edilen deneysel sonuçlar açıklanmıştır.

3.1. Deneysel Kurulum

Deneysel çalışmalarda python programlama dili kullanılmıştır. Tüm python kodları Kaggle platformunda kodlanmıştır. Kaggle platformunda transfer öğrenme modellerinin eğitimi, doğrulanması ve testi için yürütme ortamı olarak GPU P100 kullanılmıştır. Kullanılan hiperparametreler ise şu şekildedir: batch size 128, öğrenme oranı 0.001, epok değeri olarak 100 alınmıştır. Optimizasyon yöntemi olarak Adam kullanılmıştır. Girdi görüntü boyutları 224x224x3 olarak ayarlanmıştır. Transfer öğrenme modellerinin eğitiminde Kategorik Çapraz Entropi (Categorical Cross Entropy) kayıp

fonksiyonu kullanılmıştır. Kategorik Çapraz Entropi kayıp fonksiyonu, sınıflandırma modellerinin eğitiminde ve değerlendirilmesinde kullanılan temel bir araçtır. Bu kayıp fonksiyonunun kullanım amacı, çok sınıflı bir sınıflandırma probleminde tahmin edilen sınıf olasılıkları ile gerçek sınıf etiketleri arasındaki farklılığı ölçmektir. Bu sayede modelin öğrenme sürecine rehberlik etmekte ve modelin daha iyi ve daha doğru tahminler yapmasına yardımcı olmaktadır. Tüm modellerde eğitim-doğrulama-test ayırımı veri arttırımından sonra elde edilen örnekler baz alınarak yapılmıştır. Veri arttırımından sonra elde edilen eğitim-doğrulama-test örnek sayıları Çizelge 1’de verilmiştir. Tüm deneysel çalışmalarda Çizelge 1’deki ayırım kullanılmıştır.

3.2. Değerlendirme ölçütleri

Deneysel çalışmada kullanılan transfer öğrenme modellerinin performansı, her deneme için ilgili karışıklık matrisinden elde edilen sonuçlar kullanılarak değerlendirilmiştir. Değerlendirme için kullanılan parametreler kesinlik, duyarlılık, doğruluk ve F1 skoru'dur.

Karışıklık matrisi: İkili sınıflandırma sırasında 2x2'lik bir matristir. Gerçek pozitifler, gerçek negatifler, yanlış pozitifler ve yanlış negatif değerlerden oluşmaktadır. Gerçek pozitif vakalar, 'Maymun çiçeği' sınıfı örneklerinin sayısı doğru şekilde tanımlandığında ortaya çıkmaktadır. Gerçek negatif vakalar, Maymun Çiçeği olmayan (diğerleri) vakalar doğru şekilde tanımlandığında ortaya çıkmaktadır. Yanlış pozitif ve yanlış negatif sonuçlar yanlış tahmin edilen sonuçlardır. Yanlış pozitif sonuçlar, Maymun çiçeği olmayanlar (diğerleri) yanlış tanımlandığında ortaya çıkmaktadır. Yanlış negatif, Maymun çiçeği vakalarının yanlış tahmin edilmesi durumunda ortaya çıkmaktadır. Yanlış pozitif ve yanlış negatif durumlar en aza indirildiğinde modeller iyi performans göstermektedir.

Kesinlik: Gerçek pozitif ve yanlış pozitif sonuçlara vurgu yapan bir ölçümdür. Yanlış pozitif vakalar düşük olduğunda kesinlik yüksektir. Denklem (1) kullanılarak hesaplanmaktadır.

Duyarlılık: Gerçek pozitif ve yanlış negatif sonuçları vurgulayan bir ölçümdür. Yanlış negatif vakalar düşük olduğunda duyarlılık yüksektir. Denklem (2) kullanılarak hesaplanmaktadır.

F1 skoru: Hem kesinliği hem de duyarlılığı dikkate alan bir ölçümdür. İki ölçütün harmonik ortalamasıdır. Denklem (3) kullanılarak hesaplanmaktadır.

Doğruluk: Tüm örnekler arasında doğru tahmin edilen örnek sayısıdır (Hem maymun çiçeği hem de maymun çiçeği olmayan). Denklem (4) kullanılarak hesaplanmaktadır.

$$Kesinlik = \frac{Gerçek\ pozitif}{Gerçek\ pozitif + Yanlış\ pozitif} \quad (1)$$

$$Duyarlılık = \frac{Gerçek\ pozitif}{Gerçek\ pozitif + Yanlış\ negatif} \quad (2)$$

$$F1\ skoru = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (3)$$

$$Doğruluk = \frac{Gerçek\ pozitif + Gerçek\ negatif}{Gerçek\ pozitif + Yanlış\ pozitif + Gerçek\ negatif + Yanlış\ negatif} \quad (4)$$

3.3. Deneysel Sonuçlar

Bu çalışmada, maymun çiçeğini, su çiçeği ve kızamık gibi diğer benzer hastalıklardan sınıflandırmak için VGG16, ResNet50, ResNet101, ResNe152, Xception, InceptionV3, InceptionResNetV2, DenseNet121 ve DenseNet201 olmak üzere dokuz farklı önceden eğitilmiş derin öğrenme modeli kullanılmıştır. Deneysel çalışmalar iki sınıftan (maymun çiçeği ve diğerleri) oluşan maymun çiçeği deri lezyon görüntü veri seti üzerinde yapılmıştır. Çalışma kapsamında transfer

öğreniminin daha etkili olduğunu göstermek için iki farklı deneysel çalışma yapılmıştır. İlk deneysel çalışmada, dokuz farklı model sıfırdan eğitim işlemine tabi tutulmuş ve sonuçlar elde edilmiştir. Elde edilen sonuçlar Çizelge 2'deki gibidir. Çizelge 2'ye bakıldığında, en iyi doğruluk sonuçları %71.11 ile ResNet50 ve InceptionResNetV2 modelleri ile elde edildiği görülmektedir. Diğer modellerden, VGG16, ResNet101, ResNet152 ve DenseNet121 modelleri %68.89 doğruluk değeri elde etmiştir. Xception ile %62.22, InceptionV3 ile %66.67 ve DenseNet201 ile %64.44 doğruluk değerleri elde edilmiştir. Diğer değerlendirme ölçütleri incelendiğinde, en iyi kesinlik, duyarlılık ve F1 skor değerleri sırasıyla %77.08, %73.5, %75.25 ile InceptionResNetV2 modelinde elde edilmiştir. En kötü kesinlik, duyarlılık ve F1 skor değeri sırasıyla %62.02, %60 ve %60.99 ile Xception modelinde elde edilmiştir.

İkinci deneysel çalışmada, önceden eğitilmiş dokuz farklı model kullanılmıştır. Dört farklı değerlendirme ölçütüne göre sonuçlar Çizelge 3'te verilmiştir. Çizelge 3 incelendiğinde, en iyi doğruluk, kesinlik, duyarlılık ve F1 skor değerleri sırasıyla %95.56, %95.46, %96, %95.73 ile DenseNet201 modelinde elde edilmiştir. DenseNet201 modeline en yakın sonuçlar, %91.11 doğruluk, %91 kesinlik, %91.5 duyarlılık ve %91.25 F1 skoru ile Xception modeli ile elde edilmiştir. Diğer modeller incelendiğinde, InceptionV3 ile %88.89 doğruluk, %90 kesinlik, duyarlılık ve F1 skoru, InceptionResNetV2 ile %88.89 doğruluk, %88.97 kesinlik, %88.5 duyarlılık, %88.73 F1 skoru, DenseNet121 ile %84.44 doğruluk, %85.5 kesinlik, duyarlılık ve F1 skoru, ResNet50 ile %84.44 doğruluk, %84.23 kesinlik, %84.5 duyarlılık ve %84.36 F1 skoru elde edilmiştir. En kötü sınıflandırma sonuçları ise, sırasıyla, %77.78 doğruluk ve kesinlik, %77 duyarlılık ve %77.39 F1 skoru ile VGG16, %77.78 doğruluk, %78.27 kesinlik, %78.5 duyarlılık ve %78.38 F1 skoru ile ResNet152 modellerinde elde edilmiştir. VGG16 ve ResNet152'den sonra en kötü sonuçlar %80 doğruluk, %80.14 kesinlik, %80.5 duyarlılık ve %80.32 F1 skoru ile ResNet101 modelinde bulunmuştur. Çizelge 2 ve Çizelge 3 incelendiğinde, dokuz farklı modelin transfer öğrenimi kullanılarak daha başarılı sonuçlar elde ettiği açık bir şekilde görülmektedir.

Çizelge 2. Sıfırdan eğitim model sonuçları

| Model | Doğruluk (%) | Kesinlik (%) | Duyarlılık (%) | F1 skor (%) |
|-------------------|--------------|--------------|----------------|-------------|
| VGG16 | 68.89 | 69.35 | 69.5 | 69.42 |
| ResNet50 | 71.11 | 73.15 | 72.5 | 72.82 |
| ResNet101 | 68.89 | 71.53 | 70.5 | 71.01 |
| Xception | 62.22 | 62.02 | 60.00 | 60.99 |
| InceptionV3 | 66.67 | 67.5 | 67.5 | 67.5 |
| ResNet152 | 68.89 | 71.53 | 70.5 | 71.01 |
| InceptionResNetV2 | 71.11 | 77.08 | 73.5 | 75.25 |
| DenseNet121 | 68.89 | 75.85 | 71.5 | 73.61 |
| DenseNet201 | 64.44 | 70.44 | 67.00 | 68.68 |

Çizelge 3. Önceden eğitilmiş model sonuçları


| Model | Doğruluk (%) | Kesinlik (%) | Duyarlılık (%) | F1 skor (%) |
|-------------------|--------------|--------------|----------------|-------------|
| VGG16 | 77.78 | 77.78 | 77 | 77.39 |
| ResNet50 | 84.44 | 84.23 | 84.5 | 84.36 |
| ResNet101 | 80.00 | 80.14 | 80.5 | 80.32 |
| Xception | 91.11 | 91.00 | 91.5 | 91.25 |
| InceptionV3 | 88.89 | 90.00 | 90.00 | 90.00 |
| ResNet152 | 77.78 | 78.27 | 78.5 | 78.38 |
| InceptionResNetV2 | 88.89 | 88.97 | 88.5 | 88.73 |
| DenseNet121 | 84.44 | 85.5 | 85.5 | 85.5 |
| DenseNet201 | 95.56 | 95.46 | 96 | 95.73 |

Sınıflandırma problemlerinin değerlendirilmesi için karışıklık matrisleri kullanılmaktadır. Bunun yanı sıra doğruluk, kesinlik, duyarlılık ve F1 skor değerlerinin hepsi de karışıklık matrisinden elde edilmektedir. Matrisin boyutu sınıflandırma probleminin çıktı boyutuna bağlıdır. Bizim çalışmamızda çıktımız iki sınıf (Monkeypox (Maymun çiçeği) ve Others (Diğerleri)) olduğundan dolayı karışıklık matrislerimiz 2x2 boyutunda olacaktır. Karışıklık matrisi, sınıflandırma modeli için gerçek ve tahmin edilen çıktıları karşılaştırmaktadır. Karışıklık matrislerinin oluşturulması, sonuçların daha iyi anlaşılmasına olanak sağlamaktadır. Modelin değerlendirilmesinden sonra, bir karışıklık matrisi gerçek olumlu ve olumsuz yönleri ortaya koymaktadır. Bu, bize modeldeki doğru ve yanlış tahminlerin sayısını net bir şekilde anlamamızı sağlamaktadır. Karışıklık matrislerimizde toplam 45 test görüntümüzden iki sınıfa ait kaç tane görüntünün doğru şekilde tahmin edildiği rahat bir şekilde çıkarılabilmektedir. Şekil 3, 4 ve 5'te sıfırdan eğitim ve transfer öğrenimi kullanılarak önceden eğitilmiş dokuz farklı derin öğrenme modelinin karışıklık matrisleri verilmiştir. Dokuz farklı modelin karışıklık matrisleri incelendiğinde, sıfırdan eğitim sonucunda VGG16, ResNet50, ResNet101, ResNe152, Xception, InceptionV3, InceptionResNetV2, DenseNet121 ve DenseNet201 ile sırasıyla, 31, 32, 31, 31, 28, 30, 32, 31 ve 29 görüntünün doğru tahmin edildiği görülmektedir. Doğru tahmin edilen görüntü sayısının toplam test örneği sayısına oranı doğruluk değerini vermektedir. Bu sonuçlardan dokuz model için elde edilen doğruluk değerleri sırasıyla şu şekildedir: %68.89, %71.11, %68.89, %68.89, %62.22, %66.67, %71.11, %68.89, %64.44. Transfer öğrenimi kullanılarak önceden eğitilmiş modeller sonucunda doğru tahmin edilen görüntü sayıları ise sırasıyla şu şekildedir: 35, 38, 36, 35, 41, 40, 40, 38, 43. Elde edilen doğruluk değerleri ise şu şekildedir: %77.78, %84.44, %80, %77.78, %91.11, %88.89, %88.89, %84.44 ve %95.56. Tüm sonuçlar incelendiğinde, hem doğru tahmin edilen görüntü sayısı hem de doğruluk değerleri bakımından transfer öğreniminin sıfırdan eğitimden daha başarılı sonuçlar elde ettiği görülmektedir. Tüm modeller arasından önceden eğitilmiş DenseNet201 modeli, toplam 45 test görüntüsünden 43 görüntüyü doğru tahmin ederek %95.56 doğruluk değeri ile en başarılı modeldir.

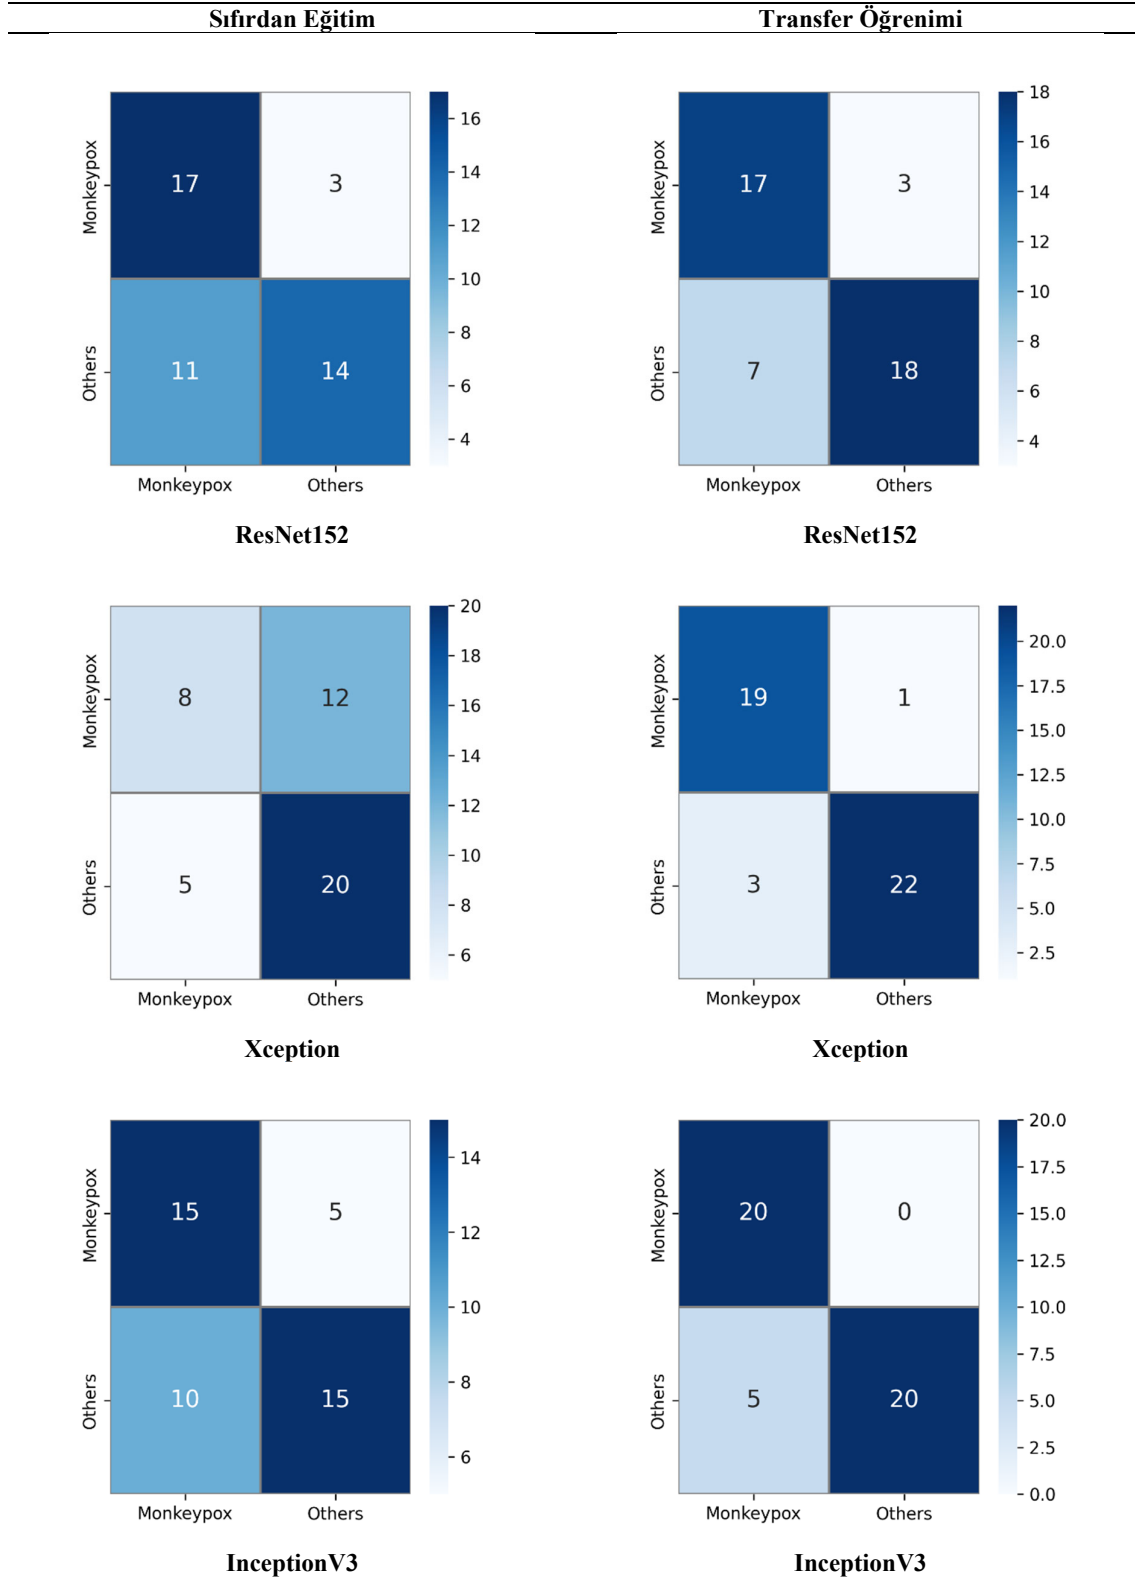
Literatürde aynı veri setini kullanarak gerçekleştirilen çalışmaların karşılaştırılması Çizelge 4'te verilmiştir. Önerilen DenseNet201 modeli ile %95.56 doğruluk, %95.46 kesinlik, %96 duyarlılık ve %95.73 F1 skoru elde edilmiştir. [12] nolu çalışmada, Inception V3, Xception ve DenseNet169 modelleri kullanılarak geliştirilen topluluk öğrenimi modeliyle %93.39 doğruluk, %88.91 kesinlik, %96.78 duyarlılık ve %92.35 F1 skoru elde edilmiştir. [14] nolu çalışmada, Xception ve DenseNet169 modellerinden elde edilen olasılıksal çıktılar üzerinde çoğunluk oylaması yaklaşımı kullanılarak geliştirilen topluluk öğrenimi modeli ile %87.13 doğruluk, %85.44 kesinlik, %85.47 duyarlılık ve %85.40 F1 skor değeri elde edilmiştir. [16] nolu çalışmada, VGG16, ResNet50 ve InceptionV3 modelleri birleştirilerek elde edilen topluluk öğrenimi ile %79.26 doğruluk, %84 kesinlik, %79 duyarlılık ve %81 F1 skoru elde edilmiştir. [26] nolu çalışmada, mobil bir uygulama kullanarak deri lezyonu görüntü verileriyle maymun çiçeği hastalığının tespiti için düşük modifiyeli bir MobilNetV2 modeli tanıtılmıştır. Gerçekleştirilen deneysel çalışmalar sonucunda %91.11 doğruluk, %90 kesinlik, duyarlılık ve F1 skoru bulunmuştur. Çizelge 4 incelendiğinde önceden eğitilmiş DenseNet201 modelinin karşılaştırmada kullanılan çalışmalardaki modellerden daha başarılı sonuçlar ürettiği açık bir şekilde görülmektedir.

Çizelge 4. Literatürdeki farklı çalışmalar ile karşılaştırma


| Literatürdeki çalışma | Doğruluk (%) | Kesinlik (%) | Duyarlılık (%) | F1 skor (%) |
|-----------------------|--------------|--------------|----------------|-------------|
| [12] | 93.39 | 88.91 | 96.78 | 92.35 |
| [14] | 87.13 | 85.44 | 85.47 | 85.40 |
| [16] | 79.26 | 84.00 | 79.00 | 81.00 |
| [26] | 91.11 | 90.00 | 90.00 | 90.00 |
| DenseNet201 | 95.56 | 95.46 | 96 | 95.73 |



Şekil 3. Sıfırdan eğitim ve transfer öğrenimi kullanılarak önceden eğitilmiş modellerin karışıklık matrisleri (VGG16, ResNet50 ve ResNet101). Soldakiler sıfırdan eğitim sonucu elde edilen ve sağdakiler transfer öğrenimi kullanılarak elde edilen karışıklık matrisleridir



Şekil 4. Sıfırdan eğitim ve transfer öğrenimi kullanılarak önceden eğitilmiş modellerin karışıklık matrisleri (ResNet152, Xception ve InceptionV3). Soldakiler sıfırdan eğitim sonucu elde edilen ve sağdakiler transfer öğrenimi kullanılarak elde edilen karışıklık matrisleridir



Şekil 5. Sıfırdan eğitim ve transfer öğrenimi kullanılarak önceden eğitilmiş modellerin karışıklık matrisleri (InceptionResNetV2, DenseNet121 ve DenseNet201). Soldakiler sıfırdan eğitim sonucu elde edilen ve sağdakiler transfer öğrenimi kullanılarak elde edilen karışıklık matrisleridir

4. Sonuçlar

Maymun çiçeği hastalığı son zamanlarda birçok ülkeye yayılan ölümcül bir hastalıktır. Bu hastalık, görüntüleme kullanılarak kolayca teşhis edilebilecek deri döküntülerine neden olmaktadır. Bu nedenle, bu çalışmada, maymun çiçeği hastalığını, deri döküntülerine neden olan diğer benzer hastalıklardan (kızamık ve su çiçeği) teşhis etmek için dokuz transfer öğrenme tabanlı derin öğrenme modeli (VGG16, ResNet50, ResNet101, ResNe152, Xception, InceptionV3, InceptionResNetV2, DenseNet121 ve DenseNet201) kullanılmıştır. Tüm modellerin sınıflandırma performanslarının analizi için Kaggle platformunda yer alan maymun çiçeği deri lezyon veri seti (Monkeypox Skin Lesion Dataset) kullanılarak deneysel çalışmalar gerçekleştirilmiştir. Deneysel çalışmalarda orijinal veri setine veri arttırımı uygulanarak görüntü sayısı arttırılmıştır. Transfer öğrenimi kullanılarak önceden eğitilmiş modellerin daha iyi sınıflandırma performansı verdiğini göstermek için aynı veri seti ile modeller sıfırdan eğitilerek de deneyler gerçekleştirilmiştir. Sıfırdan eğitim işlemi sonucunda VGG16, ResNet50, ResNet101, ResNe152, Xception, InceptionV3, InceptionResNetV2, DenseNet121 ve DenseNet201 modelleri ile sırasıyla %68.89, %71.11, %68.89, %68.89, %62.22, %66.67, %71.11, %68.89, %64.44 doğruluk değerleri elde edilirken, önceden eğitilmiş modeller kullanıldığında sırasıyla %77.78, %84.44, %80, %77.78, %91.11, %88.89, %88.89, %84.44 ve %95.56 doğruluk değerleri elde edilmiştir. Doğruluk sonuçları göz önüne alındığında, transfer öğrenimi kullanılarak önceden eğitilmiş modellerin daha başarılı sınıflandırma sonucu elde ettiği açık bir şekilde görülmektedir. Önceden eğitilmiş modeller arasında ise en iyi doğruluk değeri ise DenseNet201 modeliyle elde edilmiştir. Literatürde aynı veri setini kullanan farklı çalışmalar ile gerçekleştirilen karşılaştırmalar sonucunda da DenseNet201 modelinin daha başarılı sonuç elde ettiği görülmektedir. Deneysel çalışmalar sonucunda, DenseNet201 modelinin maymun çiçeği hastalığının hızlı ve etkili teşhisine yönelik kullanılabilir bir yöntem olabileceği sonucuna varılmıştır.

Bu çalışmada kullanılan veri seti sınırlıdır. Gelecekteki çalışmalarda veri setindeki görüntü sayısının daha da arttırılarak geliştirilmesi planlanmaktadır. Ayrıca farklı ESA tabanlı mimariler kullanılarak sınıflandırma sonuçlarının arttırılması ve daha da güvenli bir sistemin oluşturulması da hedeflerimiz arasında bulunmaktadır.

Çıkar Çatışması Beyanı

Makale yazarları herhangi bir kurum, kuruluş, kişi ile kişisel ve finansal çıkar çatışması olmadığını beyan etmektedirler.

Kaynaklar

- [1] Mileto D. New challenges in human monkeypox outside Africa: A review and case report from Italy. *Travel Medicine and Infectious Disease* 2022;49:102386.
- [2] Thornhill JP. Monkeypox Virus Infection in Humans across 16 Countries — April–June 2022. *The New England Journal of Medicine* 2022;387:679–691.
- [3] Sepehrinezhad A, Ashayeri Ahmadabad R, Sahab-Negah S. Monkeypox virus from neurological complications to neuroinvasive properties: current status and future perspectives. *Journal of Neurology* 2023;270:101–108.
- [4] WHO. Monkeypox Outbreak 2022. 2022. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/monkeypox>. [Accessed: 25-Oct-2023].
- [5] Beeson MA. Mpox in Children and Adolescents: Epidemiology, Clinical Features, Diagnosis, and Management. *Pediatrics* 2023;151:e2022060179.
- [6] Altindis M, Puca E, Shapo L. Diagnosis of monkeypox virus – An overview. *Travel Medicine and Infectious Disease* 2022;50:102459.
- [7] Paniz-Mondolfi A. Evaluation and validation of an RT-PCR assay for specific detection of monkeypox virus (MPXV). *Journal of Medical Virology* 2023;95:1–12.
- [8] Fomenko A. Assessing severe acute respiratory syndrome coronavirus 2 infectivity by reverse-transcription polymerase chain reaction: A systematic review and meta-analysis. *Reviews in Medical Virology* 2022;32:1–13.

- [9] Nayak T. Deep learning based detection of monkeypox virus using skin lesion images. *Medicine in Novel Technology and Devices* 2023;18:100243.
- [10] Nayak T. Detection of Monkeypox from skin lesion images using deep learning networks and explainable artificial intelligence. *Applied Mathematics in Science and Engineering* 2023;31.
- [11] Chadaga K. Application of Artificial Intelligence Techniques for Monkeypox: A Systematic Review. *Diagnostics* 2023;13:1–16.
- [12] Pramanik R, Banerjee B, Efimenko G, Kaplun D, Sarkar R. Monkeypox detection from skin lesion images using an amalgamation of CNN models aided with Beta function-based normalization scheme. *PLoS One* 2023;18:1–21.
- [13] Almufareh MF, Tehsin S, Humayun M, Kausar S. A Transfer Learning Approach for Clinical Detection Support of Monkeypox Skin Lesions. *Diagnostics* 2023;13:1–16.
- [14] Sitaula C and Shahi T B. Monkeypox Virus Detection Using Pre-trained Deep Learning-based Approaches. *Journal of Medical Systems* 2022;46.
- [15] Ahsan MM, Uddin MR, Farjana M, Sakib AN, Al Momin K, Luna SA. Image Data collection and implementation of deep learning-based model in detecting Monkeypox disease using modified VGG16. 2022.
- [16] Ali S N. Monkeypox Skin Lesion Detection Using Deep Learning Models: A Feasibility Study. 2022:2–5.
- [17] Akın KD, Gürkan C, Budak A, Karataş H. Açıklanabilir Yapay Zeka Destekli Evrimsel Sinir Ağları Kullanılarak Maymun Çiçeği Deri Lezyonunun Sınıflandırılması. *European Journal of Science and Technology* 2022;40:106–110.
- [18] Bala D, MonkeyNet: A robust deep convolutional neural network for monkeypox disease detection and classification. *Neural Networks* 2023;161:757–775.
- [19] Tensorkitty. Monkeypox Skin Lesion Dataset. [Online]. Available: <https://www.kaggle.com/datasets/nafin59/monkeypox-skin-lesion-dataset/data>. [Accessed: 15-Oct-2023].
- [20] Simonyan K and Zisserman A. Very deep convolutional networks for large-scale image recognition. In 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings 2015.
- [21] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [22] Chollet F. Xception: Deep learning with depthwise separable convolutions. 30th IEEE Conference on Computer Vision and Pattern Recognition. 2017: 1800–1807.
- [23] Szegedy C, Vanhoucke V, Ioffe S, Shlens J, and Wojna Z. Rethinking the Inception Architecture for Computer Vision. Proceedings of the IEEE conference on computer vision and pattern Recognition 2016: 2818–2826.
- [24] Szegedy C, Ioffe S, Vanhoucke V, Alemi AA. Inception-v4, inception-ResNet and the impact of residual connections on learning. AAAI-17: Thirty-First AAAI Conference on Artificial Intelligence 2017:4278–4284.
- [25] Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Densely connected convolutional networks. Conference on Computer Vision and Pattern Recognition (CVPR) 2017: 2261–2269.
- [26] Sahin V H, Oztel I, Yolcu Oztel G. Human Monkeypox Classification from Skin Lesion Images with Deep Pre-trained Network using Mobile Application. *Journal of Medical Systems* 2022; 46.