

Maymun Çiçeği Hastalığının Cilt Lezyon Görüntüleri Üzerinden Yapay Zekâ Algoritmaları İle Sınıflandırılması

Artificial Intelligence–Based Classification of Monkeypox Disease from Skin Lesion Images

Fırat BULAK¹

 0009-0006-6482-3163

Onur KOÇAK¹⁻² *

 0000-0002-8240-4046

¹ Biyomedikal Mühendisliği Anabilim Dalı, Başkent Üniversitesi, Ankara, Türkiye

² Bilgisayar Mühendisliği Bölümü, Başkent Üniversitesi, Ankara, Türkiye

firatblk54@gmail.com

okocak@baskent.edu.tr

Özetçe— Maymun çiçeği hastalığı, 2022 yılında küresel ölçekte ciddi bir salgın riski oluşturarak Dünya Sağlık Örgütü (DSÖ) ve ulusal otoritelerin hızlı önlem süreçleri geliştirmesine neden olmuştur. Teşhis aşamasında genellikle laboratuvar testleri kullanılmasına rağmen, hastalığın yüksek bulaşıcılığı nedeniyle destekleyici tanı yöntemlerine ihtiyaç duyulmaktadır. Bu çalışmada, açık kaynaklardan elde edilen 510 maymun çiçeği ve 749 maymun çiçeği olmayan cilt görüntüsünden oluşan toplam 1259 görsel, veri artırma yöntemleriyle zenginleştirilerek 8.533 görüntüden oluşan bir veri setine dönüştürülmüştür. Maymun çiçeği enfeksiyonu taşıyan ve taşımayan cilt görsellerinin sınıflandırılmasında sekiz farklı önceden eğitilmiş derin öğrenme mimarisi eğitilmiş ve test edilmiştir. Elde edilen sonuçlara göre, yüksek doğruluk oranlarına sahip DenseNet169, DenseNet201 ve Xception modellerinden çıkarılan özellik vektörleri birleştirilerek, yığınlama temelli topluluk öğrenmesi yaklaşımıyla yeni bir model tasarlanmış ve test veri seti üzerinde %99.30 doğruluğa ulaşılmıştır. Modelin detaylı performans analizleri sunulmuş ve sınıflandırma yaparken odaklandığı bölgeleri tespit etmek için de Gradyan Ağırlıklı Sınıf Aktivasyon Haritalandırma (Grad-CAM) kullanılmıştır.

Anahtar Kelimeler — Maymun çiçeği, Derin öğrenme, Topluluk öğrenmesi, Grad-CAM, Görüntü sınıflandırma, Transfer öğrenme.

Abstract— Monkeypox posed a significant global outbreak risk in 2022, leading the World Health Organization (WHO) and national authorities to implement rapid preventive measures. Although laboratory tests are primarily used for diagnosis, the high transmissibility of the disease highlights the need for supportive diagnostic approaches. In this study, a dataset consisting of 1,259 skin images, including 510 monkeypox and 749 non-monkeypox cases obtained from open sources, was expanded to 8,533 images through data augmentation techniques. Eight pre-trained deep learning architectures were trained and evaluated for the classification of monkeypox and non-monkeypox skin images. Based on the experimental results, a new stacking-based ensemble learning model was developed by combining feature vectors extracted from the high-performing

DenseNet169, DenseNet201, and Xception architectures, achieving an accuracy of 99.30% on the test dataset. Detailed performance analyses were conducted, and Gradient-weighted Class Activation Mapping (Grad-CAM) was utilized to visualize the regions of interest influencing the model's classification decisions.

Keywords — Monkeypox, Deep learning, Ensemble learning, Grad-CAM, Image classification, Transfer learning.

1. Giriş

Maymun çiçeği virüsü ilk olarak 1958 yılında Kopenhag'da yer alan Statens Serum Enstitüsü'nde maymunlardan izole edilmiş, hastalık adını da buradan almıştır [1]. Maymun çiçeği hastalığı ise ilk kez 1970 yılında Demokratik Kongo Cumhuriyeti'nde tanımlanmıştır. Bu tarihten itibaren vakaların önemli bir kısmı hâlen Demokratik Kongo Cumhuriyeti'nden bildirilmektedir [2]. 1970'li ve 1980'li yıllarda bu zoonotik enfeksiyon üzerine yapılan kapsamlı çalışmalar, hastalığın büyük ölçüde sporadik (tekil, dağınık) olarak ortaya çıktığını, kişiden kişiye bulaşmanın sınırlı kaldığını ve genellikle iki nesilden öteye geçmediğini göstermiştir.

Dünya Sağlık Örgütü (DSÖ), 23 Temmuz 2022 tarihinde maymun çiçeği hastalığını “Uluslararası Öne Sıralı Halk Sağlığı Acil Durumu (PHEIC)” olarak ilan etmiştir. DSÖ raporlarına göre, hastalığın dünya genelinde yayılım gösterdiği ve birçok ülkede endemik hâle geldiği doğrulanmıştır. 23 Ağustos 2022 itibarıyla Avrupa Bölgesi'ndeki 41 ülkede 21.098 vaka ve iki ölüm bildirilmiştir. Vakaların büyük çoğunluğunun erkek bireylerde görüldüğü rapor edilmiştir [3]. Maymun çiçeği hastalığının yeniden ortaya çıkışı ve endemik olmayan bölgelerde artan vaka sayısı, küresel sağlık açısından giderek büyüyen bir tehdit oluşturmaktadır. Bu nedenle, virüsün doğru ve hızlı bir şekilde tespit edilmesi, krizin küresel boyutunun öngörülmesi ve gerekli koruyucu önlemlerin zamanında alınması açısından kritik öneme sahiptir [4].

Polimeraz Zincir Reaksiyonu (PCR) testleri, maymun çiçeği hastalığının kontrolü ve yönetimi açısından altın standart olarak kabul edilmektedir [5]-[11]. Ancak Afrika bölgesinde sınırlı laboratuvar altyapısı, test kitlerinin yetersizliği, nitelikli personel eksikliği ve yüksek maliyet gibi etmenler nedeniyle bu testlerin uygulanabilirliği oldukça sınırlıdır [12], [13]. Bu durum, özellikle Orta ve Batı Afrika'daki endemik bölgelerden Avrupa ve Amerika'ya yayılan yeni salgın dalgasıyla birlikte, hızlı, düşük maliyetli ve erişilebilir tanı yöntemlerine olan ihtiyacı artırmıştır. Son yıllarda, yapay zekâ tabanlı yaklaşımlar bu ihtiyaca yönelik umut verici çözümler sunmaktadır. Özellikle COVID-19 salgını sürecinde sağlık alanında yaygın biçimde kullanılan derin öğrenme algoritmaları, benzer şekilde maymun çiçeği hastalığının tespiti için de literatürde değerlendirilmiş; açık kaynak veri setleri üzerinde transfer öğrenme yöntemiyle eğitilen modellerin karşılaştırmalı performansları raporlanmıştır [7]-[10].

Bu çalışmanın amacı, geliştirilen veri seti ve topluluk öğrenmesi yaklaşımı ile maymun çiçeği hastalığına yönelik bir klinik karar destek sistemi geliştirmek ve maymun çiçeği hastalığının cilt lezyon görüntüleri üzerinden etkili ve hızlı bir şekilde tespitini sağlamaktır. Bu kapsamda, literatürden ve açık kaynak veri tabanlarından elde edilen maymun çiçeği, diğer cilt lezyonları ve normal cilt görselleri birleştirilerek bütünleşik bir veri seti oluşturulmuştur. Bu veri seti üzerinde literatürde öne çıkan sekiz farklı derin öğrenme modeli eğitilmiş ve test edilmiştir. Elde edilen performans sonuçlarına göre, DenseNet169, DenseNet201 ve Xception modellerinin ara katmanlarından çıkarılan özellik vektörleri birleştirilerek bir meta model tasarlanmış ve aynı veri seti üzerinde diğer modellere kıyasla en yüksek doğruluk değerine ulaşılmıştır. Son yıllarda yapılan çalışmalar, maymun çiçeği hastalığının tespitinde farklı derin öğrenme ve topluluk öğrenmesi modellerinin performanslarını kapsamlı biçimde incelemiştir. Bu yaklaşım, topluluk öğrenmesi (ensemble learning) yönteminin özellikle klinik uygulamalarda tanı süreçlerine anlamlı katkı sağlayabileceğini göstermektedir.

2 Literatüre Bakış

Ali ve arkadaşları (2022), internet üzerinden topladıkları 228 orijinal deri görüntüsünden oluşturdukları genişletilmiş veri seti üzerinde çeşitli derin öğrenme modellerini değerlendirmiştir. Veri artırma (data augmentation) yöntemi uygulanarak veri seti 3.192 örneğe çıkarılmıştır. Deneysel çalışmalarda VGG16, ResNet50, InceptionV3 ve hibrit modeller test edilmiş; ResNet50 modeli %82,96 doğruluk (accuracy) oranıyla en yüksek performansı göstermiştir. Diğer modellerde ise VGG16 (%81,48), hibrit (%79,26) ve InceptionV3 (%74,07) doğruluk değerleri elde edilmiştir [9].

Ahsan ve arkadaşları (2022), anonim kaynaklardan elde ettikleri maymun çiçeği, suçiçeği, kızamık ve normal cilt görüntülerini kullanarak "Monkeypox2022" adında yeni bir veri seti oluşturmuştur. Çalışmada, ince ayarlama (fine-tuning) yöntemiyle optimize edilen VGG16 modeli sınıflandırma amacıyla eğitilmiş ve test veri seti üzerinde %83 doğruluk oranına ulaşmıştır. Ayrıca, modelin karar mekanizmasını yorumlayabilmek için LIME (Local Interpretable Model-Agnostic Explanations) algoritması uygulanmıştır [14].

Bala ve arkadaşları (2023), çalışmalarının ilk aşamasında farklı derin öğrenme modellerinden elde ettikleri özellikleri

(feature extraction) makine öğrenmesi sınıflandırıcılarıyla birleştirerek çok aşamalı bir sınıflandırma yapısı önermiştir. İkinci aşamada ise, modifiye edilmiş DenseNet201 mimarisinin hem orijinal hem de artırılmış veri setleri üzerindeki performansını değerlendirmiştir. Elde edilen sonuçlara göre, model orijinal veri setinde %91,91, artırılmış veri setinde ise %98,91 doğruluk (accuracy) oranına ulaşarak diğer modellere göre üstün performans göstermiştir [15].

Şahin (2022), Sitaula (2022) ve Altun (2023) tarafından yürütülen çalışmalarda, farklı derin öğrenme tabanlı mimariler karşılaştırmalı olarak incelenmiştir. Şahin ve arkadaşları (2022), açık kaynak veri seti üzerinde gerçekleştirdikleri deneylerde ResNet18, GoogleNet, EfficientNetB0, NasNetMobile, ShuffleNet ve MobileNetV2 modellerini test etmiş; MobileNetV2 modelinin 60 epoch sonunda %91,11 doğruluk oranına ulaştığını raporlamıştır [16].

Benzer biçimde, Sitaula ve arkadaşları (2022) transfer öğrenme yaklaşımıyla 13 farklı güncel derin öğrenme modelini çok sınıflı sınıflandırma amacıyla incelemiştir; ince ayarlama (fine-tuning) yapılan Xception ve DenseNet169 modellerinin sırasıyla %85,01 ve %84,07 doğruluk değerlerine ulaştığını bildirmiştir [17].

Öte yandan, Altun (2023) parametre ve katman mimarisinde yaptığı yapısal değişikliklerle geliştirdiği yeni MobileNetV3 modelinin, EfficientNetV2s, VGG19, ResNet50 ve DenseNet modellerine kıyasla daha yüksek sınıflandırma başarısı gösterdiğini belirtmiştir. Ayrıca, Altun'un çalışmasında kullanılan model eğitimi için temel veri kaynağı mobil cihazlar üzerinden elde edilmiştir [18].

Literatürde yer alan çalışmaların büyük çoğunluğunda, modelin aşırı öğrenmesini (overfitting) veya yetersiz öğrenmesini (underfitting) önlemek amacıyla veri artırma (data augmentation) yöntemleri uygulanmıştır. Araştırmacılar, model başarısında doğru hiperparametre optimizasyonunun kritik bir rol oynadığını vurgulamıştır. Bununla birlikte, mevcut veri setlerinin çoğunun sağlık kuruluşları tarafından paylaşılmadığı ve tıp uzmanları tarafından doğrulanmadığı ifade edilmiştir. Bu durum, literatürdeki modellerin klinik geçerliliğini sınırlayan önemli bir faktör olarak değerlendirilmektedir. Bazı çalışmalarda ise, YOLO ve Detectron2 gibi nesne tanıma (object detection) temelli yaklaşımların maymun çiçeği hastalığının tespitinde alternatif ve etkili sınıflandırıcılar olabileceği belirtilmiştir [18].

Literatürde son dönemlerde yer alan çalışmalar, klasik CNN mimarilerinden hibrit ve topluluk öğrenmesi tabanlı modellere doğru belirgin bir yönelim olduğunu göstermektedir. Taşpınar (2024), ince ayarlama (fine-tuning) yöntemiyle optimize ettiği VGG16 ve VGG19 modellerinin doğruluk oranlarını sırasıyla %95,61'den %96,87'ye ve %96,08'den %97,81'e yükselterek transfer öğrenmenin etkinliğini ortaya koymuştur [19].

Akram (2025), Bala ve arkadaşlarının internet tabanlı veri setini kullanarak LightGBM, Random Forest, Logistic Regression, Extra Trees, InceptionV3, Xception ve ResNet50 algoritmalarını eğitmiş, test etmiş ve bu modellerin bir arada kullanılmasıyla yüksek doğruluk oranları elde etmiştir [20].

Maqsood (2024), orijinal ve artırılmış verilerden oluşturduğu 8.689 görsellik veri setinde Evrişimli Seyrek Görüntü Ayrıştırma (Convolutional Sparse Image Decomposition) yöntemiyle

özellik birleştirme (feature fusion) işlemi gerçekleştirmiş, ardından geliştirdiği MOX-NET modelini M-SVM sınıflandırıcısı ile test ederek %90 üzeri doğruluk sağlamıştır [21]. Asif (2023) ise meta-sezgisel (meta-heuristic) tabanlı hibrit topluluk öğrenmesi yaklaşımıyla iki sınıfta %97,78, dört sınıfta ise %92,86 doğruluk elde ederek literatürdeki en yüksek performanslardan birini bildirmiştir [22]. Literatürdeki diğer araştırmalar da, tekil CNN tabanlı sınıflandırıcılara kıyasla topluluk (ensemble) ve hibrit yaklaşımların istikrarlı biçimde daha yüksek doğruluk ve genelleme performansı sunduğunu göstermektedir [23], [24].

Bu çalışmada;

- Yinelenen verilerden arındırılmış, hibrit “Maymun Çiçeği/Maymun Çiçeği Olmayan” veri havuzu oluşturulmuş,
- Farklı CNN mimarileri, geliştirilen veri seti üzerinde karşılaştırmalı olarak değerlendirilmiş,
- Özellik düzeyi yığılma topluluk öğrenmesi yaklaşımıyla oluşturulan meta modelin, tekil modellere kıyasla üstün doğruluk ve kararlılık sergilediği ortaya konmuştur.

Elde edilen bulgular, özellikle kaynak kısıtlı bölgelerde saha-yakın tarama ve ön değerlendirme amaçlı mobil/web tabanlı klinik karar destek sistemlerine entegre edilebilecek, hızlı, düşük maliyetli ve ölçeklenebilir bir çözüm çerçevesi sunmaktadır. Böylece PCR gibi altın standart doğrulama yaklaşımlarının yerini almadan, ön tarama ve triyaj basamaklarını güçlendirecek etkin bir yapay zekâ katmanı önerilmektedir.

3. Materyal ve Yöntem

Modellerin tahminleme performansını artırmak amacıyla, ilk aşamada farklı kaynaklardan elde edilen veri setleri bir araya getirilmiş ve yinelenen (duplike) veriler temizlenmiştir. Bu adım sonucunda, maymun çiçeği cilt lezyonları, diğer cilt lezyonları ve normal cilt görüntülerinden oluşan hibrit bir veri tabanı oluşturulmuştur. İkinci aşamada, benzersiz görseller üzerinde uygulanan veri artırma (data augmentation) işlemleriyle daha geniş bir veri seti elde edilmiştir. Takip eden aşamalarda, görüntü sınıflandırma problemini çözmek amacıyla farklı derin öğrenme modelleri kullanılmıştır. Bu modellerin özgün veri seti üzerindeki performansları karşılaştırılmış; en başarılı modeller seçilerek özellik düzeyi yığılma topluluk öğrenmesi (feature-level stacking ensemble learning) yöntemiyle yeni bir model geliştirilmiştir. Geliştirilen model, DenseNet169, DenseNet201 ve Xception mimarilerine göre daha yüksek sınıflandırma performansı göstermiştir.

3.1. Hibrit Veri Seti Oluşturma

Bu çalışmada, literatürdeki araştırmalar incelenmiş ve çevrimiçi klinik veri tabanları taranarak hibrit bir veri seti oluşturulmuştur. Literatürde, maymun çiçeği hastalığına yönelik tamamen doğrulanmış ve geniş kapsamlı bir açık veri seti bulunmamaktadır. Yapay zekâ temelli çalışmalar açısından, veri bilimi kritik öneme sahiptir; çünkü büyük ve çeşitli veri setleri, model performansını doğrudan olumlu etkilemektedir [25]. Bu nedenle, önerilen modelin başarısını artırmak amacıyla kapsamlı bir hibrit veri seti tasarlanmıştır. Çalışmada kullanılan örnek

maymun çiçeği ve maymun çiçeği olmayan görseller Şekil 1’de gösterilmektedir.



Şekil. 1. Veri Seti

Hibrit veri seti oluşturulurken, Bala ve arkadaşları (2023) tarafından geliştirilen dört sınıflı veri seti [15] (suçiçeği: 107, kızamık: 91, maymun çiçeği: 279, normal: 293; toplam 770 adet, 224×224 piksel), DermNet tarafından yayımlanan “Mpox Images” veri seti (28 adet maymun çiçeği lezyon görüntüsü) [26], Kaggle platformundaki “Data_monkeypox” veri seti [27] ve Ahsan ve arkadaşlarının (2022) açık kaynaklı “Monkeypox2022” veri seti [14] kullanılmıştır.

Ayrıca Shams Ali ve arkadaşlarının (2022) çalışmasındaki iki sınıflı veri seti [9] ve Google arama motoru üzerinden “monkeypox” anahtar kelimesiyle elde edilen yüksek çözünürlüklü görseller de veri havuzuna dahil edilmiştir. Erişilen veri tabanlarının URL adresleri ve erişim tarihleri kaynaklar kısmında belirtilmiştir. Kullanılan veri setleri, halka açık şekilde paylaşılmış, kişisel kimlik bilgisi içermeyen dermatolojik görüntülerden oluşmaktadır.

Çalışma açık erişimli ikincil verilerle yürütülen bilgisayarlı görü tabanlı bir yöntem geliştirme çalışmasıdır. Bu kapsamda etik kurul izni gerektirmediği değerlendirilmiştir. Bununla birlikte veri setleri, ilgili platformların kullanım koşulları çerçevesinde kullanılmış olup kaynaklar çalışmada belirtilmiştir.

Toplamda, 741 adet maymun çiçeği ve 1.124 adet diğer cilt görüntüsünden oluşan iki sınıflı bir hibrit veri seti elde edilmiştir. Farklı kaynaklardan derlenen verilerde yinelenen (duplike) görüntülerin bulunması nedeniyle, veriler Piksel Tabanlı Sağlama Toplamına Dayalı Yinelenme Önleme (Pixel-Based Checksum-Based Deduplication) yöntemiyle kontrol edilmiştir [28].

Görsellerin RGB değerleri hex formatına dönüştürülerek MD5 algoritmasıyla özet değerleri hesaplanmış, aynı piksel içeriğine sahip görseller silinmiştir. Ayrıca işlemin doğruluğunu teyit etmek için, HSV renk uzayında histogram tabanlı karşılaştırma (cv2.HISTCMP_CORREL) yöntemi kullanılmış ve tamamen aynı histogramlara sahip görseller kaldırılmıştır.

Duplike (tekrar eden) görüntülerin tespit edilip silinmesi amacıyla gerçekleştirilen işlemlerin pseudo code algoritması aşağıdaki gibi girdi görsel kümesi ve temizlenmiş çıktı görsel kümesi adımları ile birlikte uygulanmıştır. RGB formatına dönüşüm, piksel dizisi belirleme, histogram analizleri ile histogramdan elde edilen verilen korelasyonu adımları Algoritma 1’de görülmektedir.

Algoritma 1. Yinelenen Görsel Temizleme Süreci

Girdi: Görsel kümesi $I = \{I_1, I_2, \dots, I_n\}$, histogram benzerlik eşiği τ

Çıktı: Temizlenmiş görsel kümesi I_{clean}

1: HashTablo $\leftarrow$ boş sözlük (anahtar: MD5, değer: dosya_yolu)

2: AdayDuplikeler $\leftarrow$ boş liste (çiftler)

3: her görsel I_i için:

4: $img \leftarrow oku(I_i)$

5: $img_rgb \leftarrow RGB \text{ formatına dönüştür}$

6: $md5 \leftarrow MD5(img_rgb \text{ piksel dizisi})$

7: eğer $md5$ HashTablo'da varsa:

8: Aday Duplikeler'e (HashTablo[md5], I_i) ekle

9: aksi halde:

10: HashTablo[md5] $\leftarrow I_i$

11: Silinecekler $\leftarrow$ boş küme

12: her (A, B) çifti AdayDuplikeler için:

13: $hA \leftarrow HSV \text{ histogram}(A)$

14: $hB \leftarrow HSV \text{ histogram}(B)$

15: $s \leftarrow Korelasyon(hA, hB)$ (örn. $cv2.HISTCMP_CORREL$)

16: eğer $s \geq \tau$ ise:

17: Silinecekler'e B ekle (aynı içeriğin tekrarı kabul edilir)

18: $I_{clean} \leftarrow I \setminus \text{Silinecekler}$

19: çıktı olarak I_{clean} döndür

Yinelenen görüntülerin eğitim (train) ve test kümelerine dağılmasını önlemek amacıyla, veri seti bölme (train/validation/test ayrımı) işleminden önce tüm görseller üzerinde yinelenen (duplike) görüntü tespiti ve temizleme adımları uygulanmıştır. Bu kapsamda, piksel tabanlı özetleme ve içerik benzerliği kontrollerinden geçen ve benzersiz olduğu doğrulan görüntülerden oluşan nihai veri havuzu elde edilmiştir. Veri seti bölme işlemi yalnızca bu temizlenmiş veri havuzu üzerinde gerçekleştirilmiş olup, böylece aynı veya yüksek derecede benzer görüntülerin farklı veri kümelerinde yer almasının önüne geçilmiştir. Bu yaklaşım, olası veri sızıntısını (data leakage) engelleyerek model performansının tarafsız biçimde değerlendirilmesini sağlamaktadır. Bu işlemler sonucunda, veri seti 510 adet maymun çiçeği ve 749 adet diğer cilt görüntüsünden oluşan temiz ve benzersiz bir hâle getirilmiştir. Ayrıca, model eğitiminde kullanılacak maymun çiçeği ve maymun çiçeği olmayan tüm görsellerin, tanısal açıdan yeterli ve görsel kalite bakımından uygun olmasına dikkat edilmiştir. Bu kapsamda, düşük çözünürlüklü, aşırı bulanık, ciddi ışıklandırma problemi içeren, lezyon bölgesinin net olarak ayırt edilemediği veya görüntü üzerinde yoğun metin, çerçeve ve filigran (watermark) bulunan görseller veri seti dışı bırakılmıştır. Parlaklık dağılımı ve genel piksel değişkenliği incelenerek, görsel bilgi içeriği sınırlı olan örnekler elenmiştir. Ayrıca, görüntü netliğini değerlendirmek amacıyla kenar belirginliği dikkate alınmış; bulanıklık düzeyi yüksek ve ayırt edici yapısal özellikler içermeyen görüntüler ayıklanmıştır.

3.2. Veri Artırma ve Ön Hazırlık

Veri artırma (data augmentation), sınırlı veri miktarı bulunan veya modelin genelleme kabiliyetini geliştirmek istenen durumlarda yaygın olarak kullanılan bir tekniktir. Bu işlem Literatürdeki bulgular doğrultusunda, bu çalışmada veri uzayı

temelli artırma (data-space augmentation) yaklaşımı uygulanmış ve bu yöntemin, özellik uzayı temelli artırma (feature-space augmentation) yöntemlerine kıyasla daha etkili sonuçlar ürettiği gözlemlenmiştir [29]. Bu kapsamda, yoğun veri artırma (heavy data augmentation) teknikleri tercih edilmiştir [30]. Veri artırma işlemleri, Keras ImageDataGenerator yapısı kullanılarak çevrim içi (online) olarak gerçekleştirilmiştir. Veri artırımı ham verilere uygulanmamış olup her eğitim adımında rastgele dönüşümler uygulanarak veri artırımları sağlanmıştır. Veri seti, özgün görüntüler temel alınarak eğitim, doğrulama ve test kümelerine ayrılmıştır.

Görseller PNG formatında olup, model mimarileriyle uyumlu olacak şekilde 224×224 piksel boyutuna ölçeklenmiştir. Artırma işlemleri sonrasında veri seti, 3.682 adet maymun çiçeği cilt lezyon görüntüsü ve 4.851 adet diğer cilt görüntüsü olmak üzere toplam 8.533 örnekten oluşmuştur. Modelin eğitim ve değerlendirme aşamaları için veriler %81 eğitim, %9 doğrulama (validation) ve %10 test olacak şekilde rastgele bölünmüştür. Veri setinin eğitim, doğrulama ve test kümelerine rastgele bölünmesi sırasında, deneysel sonuçların tekrarlanabilirliğini sağlamak amacıyla sabit bir rastgelelik tohumu (random seed) kullanılmıştır. Bu çalışmada, tüm bölme işlemleri random seed = 42 değeri ile gerçekleştirilmiştir. Buna göre, 6.911 eğitim, 768 doğrulama ve 854 test örneği kullanılmıştır. Çalışmada kullanılan veri artırma parametreleri Tablo 1'de görülmektedir. Bu çalışmada veri artırma işlemleri, görüntü ön işleme hattında belirli bir sıraya göre uygulanmıştır. İlk olarak tüm görüntüler model giriş boyutuna uygun olacak şekilde 224×224 piksel çözünürlüğe yeniden boyutlandırılmıştır. Ardından rastgele yatay çevirme (horizontal flip), döndürme (rotation), kaydırma (width/height shift), kesme (shear) ve yakınlaştırma (zoom) işlemleri uygulanmıştır. Son aşamada ise piksel değerleri $[0,1]$ aralığına ölçeklenerek (rescale=1./255) normalize edilmiştir. Bu sıralı yapı sayesinde, geometrik dönüşümlerden sonra sayısal ölçekleme gerçekleştirilmiş ve veri bütünlüğü korunmuştur.


Tablo 1. Veri Artırma Değerleri

Veri Çoğaltma Türü	Parametre Adı	Değer Açıklaması
Rastgele Döndürme	rotation_range	0 ile 40 derece arasında rastgele döndürme
Yatay Kaydırma	width_shift_range	Görüntünün genişliğinin %20'si oranında kaydırma
Dikey Kaydırma	height_shift_range	Görüntünün yüksekliğinin %20'si oranında kaydırma
Kesme (Shearing)	shear_range	Görüntüye 0.2 oranında kesme (açılı kaydırma)
Yakınlaştırma	zoom_range	Görüntüyü %20 oranında yakınlaştırma/uzaklaştırma
Yatay Çevirme	horizontal_flip	True $\rightarrow$ Rastgele yatay çevirme uygulanır.
Doldurma Modu	fill_mode	'nearest' $\rightarrow$ Boş kalan pikseller üzerinden en yakın piksel

Bu artırma parametreleri, modelin aşırı öğrenme (overfitting) eğilimini azaltmak ve sınıflar arası dengelyi güçlendirmek amacıyla belirlenmiştir.

3.3. Yapay Sinir Ağları

Yapay Sinir Ağları (Artificial Neural Networks – ANN), insan beynindeki biyolojik nöronlardan esinlenerek geliştirilen yapay zekâ modelleridir. Bu ağlar; örüntü tanıma, sınıflandırma ve tahminleme gibi görevleri yerine getiren çok katmanlı yapılar olarak tasarlanmıştır. Temel olarak girdi katmanı, gizli katman(lar) ve çıktı katmanından oluşurlar. Modelin bir iterasyonu, ileri besleme (forward propagation) ve geri yayılım (backward propagation) süreçlerinin tamamlanmasıyla gerçekleşir. Her iterasyonda ağ, hata oranını azaltmak ve genelleme kabiliyetini artırmak amacıyla ağırlıklarının güncellenmektedir. Şekil 2’de yapay sinir ağının genel yapısı şematik olarak sunulmaktadır [31].



Şekil 2. Yapay Sinir Ağlarının Genel Yapısı [32]

Evrişimsel Sinir Ağları (Convolutional Neural Networks – CNN), özellikle görüntü verilerinin analizi için optimize edilmiş çok katmanlı yapay sinir ağı mimarileridir. Klasik ANN yapılarından farklı olarak, CNN’ler görüntülerin yapısal özelliklerini doğrudan giriş verisinden çıkarabilme yeteneğine sahiptir. Bu mimarilerde, tam bağlantılı katmanlardan önce uygulanan filtreleme (convolution) işlemleriyle görüntülerin ayırt edici özellikleri yakalanır. CNN’ler tipik olarak şu bileşenlerden oluşur: evrişim katmanı (convolutional layer), havuzlama katmanı (pooling layer), aktivasyon katmanı (activation layer), düzleştirme katmanı (flatten layer) ve tam bağlantılı katman (fully connected layer) [33].

Evrişim (convolution) katmanı, CNN yapısının çekirdek bileşenidir. Bu katman, giriş verisi üzerinde hareket eden küçük boyutlu filtreler aracılığıyla mekânsal ilişkileri korur ve öznitelik (feature) haritaları üretir. Her filtre farklı bir görsel deseni veya dokusal özelliği algılamak üzere eğitilir. Evrişim işlemi Denklem (1)’de gösterilmektedir [34]:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) \cdot K(m, n) \quad (1)$$

Havuzlama (pooling) katmanı, evrişimli ağlarda boyut indirgeme ve öznitelik çıkarımını sağlayan bir katmandır. Bu katman, küçük konumsal kaymalara karşı dayanıklılık kazandırarak modelin genelleme kabiliyetini güçlendirir [35]. En sık kullanılan yöntemlerden maksimum havuzlama (max pooling), yerel bir alan içindeki en yüksek değeri seçerken, ortalama havuzlama (average pooling) her bölgedeki değerlerin ortalamasını alır. Ortalama havuzlama işlemi Denklem (2)’de tanımlanmıştır [33]:

$$f_{ave}(X) = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

3.4. Çalışmada Yer Alan Modeller

Bu çalışmada, literatürde yaygın biçimde kullanılan ve başarı göstermiş sekiz adet önceden eğitilmiş (pre-trained) derin öğrenme modeli deneysel olarak değerlendirilmiştir. Görseller, tüm modellerin giriş boyutlarıyla uyumlu olacak şekilde 224×224 piksel çözünürlüğe ölçeklenmiş ve veri ön işleme aşamasında normalize edilmiştir.

Sınıflandırma performansını karşılaştırmak amacıyla şu modeller kullanılmıştır: Xception, InceptionV3, MobileNetV2, DenseNet121, DenseNet169, DenseNet201, VGG16 ve VGG19. Bu modeller, farklı derinliklerde ve mimari yapılarda olmaları sayesinde, özellik çıkarımı (feature extraction) açısından geniş bir çeşitlilik sunmaktadır. Bu çeşitlilik, sonraki aşamada geliştirilen topluluk öğrenmesi (ensemble learning) tabanlı meta modelin temelini oluşturmaktadır. Bu modellerin seçilme nedeni, farklı derinlik düzeylerinde evrişimsel katman yapıları barındırmaları ve sınıflandırma performanslarının literatürdeki benzer çalışmalarda kanıtlanmış olmasıdır.

3.5. Eğitim Yapılandırması ve Optimizasyon Ayarları

Aşırı öğrenmeyi önlemek ve eğitim sürecini kararlı hâle getirmek için üç geri çağırım kullanılmıştır. EarlyStopping, monitor='val_loss', patience=10 ve restore_best_weights=True parametreleriyle yapılandırılmıştır. ReduceLROnPlateau, monitor='val_loss', factor=0.5, patience=5 ve min_lr=1e-7 olacak şekilde uygulanmıştır. En iyi model ağırlıklarını kaydetmek amacıyla ModelCheckpoint, monitor='val_accuracy', save_best_only=True, mode='max' ve verbose=1 ayarlarıyla kullanılmıştır.

3.6. Geliştirilen Model

Bu çalışmada, toplam sekiz önceden eğitilmiş derin öğrenme modeli üzerinde ince ayarlama (fine-tuning) işlemleri uygulanmış ve oluşturulan hibrit veri setiyle eğitim, doğrulama ve test süreçleri gerçekleştirilmiştir. DenseNet169, DenseNet201 ve Xception mimarileri, hem teorik hem de deneysel gerekçelere dayanarak seçilmiştir. DenseNet tabanlı mimariler, yoğun bağlantı (dense connectivity) yapıları sayesinde düşük seviyeli ve yüksek seviyeli özellikleri etkin biçimde birleştirerek özellikle tıbbi görüntülerde ince dokusal desenlerin yakalanmasında başarılıdır. Xception mimarisi ise derinlemesine ayrılabilir evrişim (depthwise separable convolution) yapısı sayesinde mekânsal ve kanal bazlı özellikleri ayırıştırarak tamamlayıcı bir temsil sunmaktadır. Deneysel sonuçlar incelendiğinde, bu üç modelin test veri kümesi üzerinde en yüksek doğruluk ve genelleme performansını sergileyen mimariler olduğu görülmüştür. Bu nedenle, bilgi çeşitliliğini maksimize etmek amacıyla performans açısından öne çıkan bu üç modelin özellik çıkarım katmanlarından elde edilen vektörler, özellik düzeyinde yığınlama (feature-level stacking) temelli topluluk öğrenmesi (ensemble learning) yaklaşımıyla birleştirilerek yeni bir meta model tasarlanmıştır. Geliştirilen meta model, bireysel modellere kıyasla daha yüksek doğruluk ve kararlılık göstermiştir. Algoritma beş temel aşamadan oluşmaktadır:


A. Model Hazırlığı ve Veri Yükleme: NumPy, Matplotlib ve Scikit-Learn kütüphaneleri çalışmaya dahil edilmiş; daha önce eğitilmiş DenseNet169, DenseNet201 ve Xception modellerinin ağırlık dosyaları load_model() fonksiyonu ile yüklenmiştir.

Görseller, `tf.keras.preprocessing.image.ImageDataGenerator` sınıfı kullanılarak 0–1 aralığında yeniden ölçeklendirilmiş (`rescale=1./255`) ve eğitim, doğrulama ve test dizinlerinden `flow_from_directory()` fonksiyonu aracılığıyla çekilmiştir. Görüntüler 224×224 piksel olarak yeniden boyutlandırılmış ve 32'lik mini-batch grupları halinde ikili sınıflandırma (binary classification) etiketleriyle işlenmiştir.

B. Özellik Çıkartımı (Feature Extraction): Her modelin en zengin bilgi taşıyan katmanları analiz edilerek, Global Average Pooling (GAP) katmanlarının çıktıları özellik vektörleri olarak seçilmiştir. Elde edilen vektörlerin boyutları sırasıyla DenseNet201 için (None, 1920), DenseNet169 için (None, 1664) ve Xception için (None, 2048) olarak belirlenmiştir. Literatürde, benzer biçimde VGG16 ve ResNet50V2 modellerinden çıkarılan özellik vektörlerinin birleştirilmesiyle geliştirilen modellerin %95 doğruluk oranına ulaştığı gösterilmiştir [36], [37]. Bu çalışmada, üç derin mimarinin GAP katmanlarından elde edilen özellik vektörlerinin birleştirilmesiyle bilgi çeşitliliği artırılmıştır. Özellik düzeyi yığılma (feature-level stacking) aşamasında, DenseNet169, DenseNet201 ve Xception modellerinin Global Average Pooling (GAP) katmanlarından elde edilen özellik vektörleri kullanılmıştır. Bu vektörlerin boyutları sırasıyla 1664, 1920 ve 2048'dir. Her bir modelden elde edilen özellikler, birleştirme (concatenation) işleminden önce Batch Normalization katmanı ile normalize edilmiştir. Bu normalizasyon işlemi, farklı mimarilerden gelen özelliklerin ölçek farklarını azaltarak birleşik temsilin daha kararlı hâle gelmesini sağlamıştır. Birleştirilen özellik vektörü, çok katmanlı yoğun (Dense) bloklar üzerinden işlenmiştir. Bu bloklarda, gradyan kaybını önlemek ve derin temsil öğrenimini güçlendirmek amacıyla residual (kısa yol) bağlantılar kullanılmıştır. Residual bağlantılar, belirli yoğun katmanların girişlerinin doğrudan sonraki katmanların çıkışlarına eklenmesi prensibine dayanmaktadır. Bu yapı sayesinde, ağır daha derin katmanlarında bilgi kaybı azaltılmış ve optimizasyon süreci daha kararlı hâle getirilmiştir. Residual mimari, özellikle yüksek boyutlu özellik uzaylarında öğrenme verimliliğini artıran etkili bir strateji olarak literatürde yaygın biçimde kullanılmaktadır.

C. Meta Model Tasarımı: Her dal (DenseNet169, DenseNet201, Xception) kendi özellik vektörünü işlerken sırasıyla Yoğun Katman (Dense Layer), Toplulaştırma Katmanı (Batch Normalization), Sızıntılı Doğrusal Birim (Leaky ReLU) ve Bırakma (Dropout) katmanlarından geçirilmiştir. Katmanlar arasında kısa yol (residual) bağlantılar eklenerek gradyan kaybı önlenmiştir. Üç dalın çıktıları Concatenate işlemiyle birleştirilmiş ve ardından ek Dense–Dropout bloklarıyla güçlendirilmiştir. Çıkış katmanında tek nöronlu sigmoid aktivasyon fonksiyonu kullanılarak ikili sınıflandırma gerçekleştirilmiştir. Şekil 3'de meta model girdi – çıktı akışı eklenmiştir. Ayrıca özelliklerin nasıl normalize edildiği açıklanmıştır. Ayrıca Leaky ReLU aktivasyonu Denklem (3)'te verilmiştir [38]:

$$f(x) = \begin{cases} -x, & x > 0 \\ ax, & x \leq 0 \end{cases} \quad (3)$$



Şekil 3. Meta-Model Girdi-Çıktı Akışı

D. Eğitim ve Optimizasyon: Meta model eğitiminde `binary_crossentropy` kayıp (loss) fonksiyonu kullanılmıştır. Meta model, AdamW optimizatörü, Erken Durdurma (EarlyStopping), Öğrenme Oranını Azaltma (ReduceLROnPlateau) ve ModelCheckpoint geri çağrılarını ile eğitilmiştir. Hiperparametreler sırasıyla: epoch = 100, batch size = 32, öğrenme oranı = 0.0005, dropout oranları = 0.3, 0.4, 0.5 olarak belirlenmiştir. Eğitim sonrası model, test seti üzerinde değerlendirilmiş ve tüm metriklerde (accuracy, precision, recall, F1-score) aynı modellere kıyasla anlamlı iyileşme sağlamıştır.

Eğitim süreci boyunca modelin eğitim ve doğrulama kayıplarının epoch bazlı değişimi incelendiğinde, başlangıç aşamasında her iki kayıp değerinin birlikte ve düzenli biçimde azaldığı görülmüştür. Bu durum, modelin veri setindeki ayırt edici örüntüleri etkin biçimde öğrenmeye başladığını göstermektedir. İlerleyen epoch'larda eğitim kaybı azalmaya devam ederken doğrulama kaybının daha sınırlı değişimler göstermesi, model öğrenmesinin doygunluk aşamasına yaklaştığını işaret etmektedir. Bu aşamada devreye giren erken durdurma (Early Stopping) mekanizması, doğrulama kaybındaki iyileşmenin durduğu noktada eğitimi sonlandırarak modelin genelleme yeteneğinin korunmasına katkı sağlamıştır.

Modelin aşırı öğrenme eğilimini azaltmak ve genelleme yeteneğini artırmak amacıyla birden fazla düzenleme (regularization) stratejisi birlikte kullanılmıştır. Yoğun katmanlarda uygulanan L2 ağırlık cezası ($\lambda = 0.0001$), ağırlıklarının aşırı büyümesini sınırlandırarak daha pürüzsüz bir karar yüzeyi elde edilmesini sağlamaktadır. Buna ek olarak, farklı katmanlarda uygulanan Dropout (0.3–0.5 aralığında), eğitim sırasında rastgele nöron devre dışı bırakılması yoluyla birlikte uyumlanan (co-adaptation) özelliklerin oluşmasını engelleyerek modelin daha genellenebilir temsiller öğrenmesine katkı sağlamıştır. Batch Normalization katmanları ise aktivasyon dağılımlarını dengeleyerek öğrenme sürecini kararlı hâle getirmiştir.

E. Sonuç: Elde edilen topluluk tabanlı meta model, DenseNet169, DenseNet201 ve Xception ağlarının birlikte kullanılmasıyla yüksek genelleme başarısı göstermiştir. Modelin eğitim ve test performanslarına ilişkin ayrıntılı bulgular, Bölüm 4'te sunulmaktadır.

4. Sonuçlar ve Tartışma

Bu çalışmada, literatür ve açık kaynaklı veri tabanlarından elde edilen görsel veriler bir araya getirilerek maymun çiçeği hastalığına yönelik bütünleşik bir veri seti oluşturulmuştur. Yinelenen (duplike) görüntüler ayıklanarak özgün bir veri havuzu elde edilmiştir. Ardından sekiz farklı önceden eğitilmiş derin öğrenme modeli ve önerilen meta model kullanılarak, cilt lezyon görüntüleri üzerinden maymun çiçeği hastalığının tespiti amaçlanmıştır. Tüm modellerin sınıflandırma performansları detaylı metriklerle değerlendirilmiş ve önerilen modelin ayrı ayrı kullanılan modellere göre üstün sonuçlar verdiği gösterilmiştir. Eğitim ve test süreçleri Google Colab Pro ortamında, 16 GB GDDR6 belleğe sahip NVIDIA Tesla T4 GPU (Turing mimarisi) kullanılarak yürütülmüştür. Bu donanım konfigürasyonu, yüksek çözünürlüklü görüntüler üzerinde verimli eğitim yapılmasını sağlamıştır (bkz. Tablo 2).

Tablo 2. NVIDIA Tesla T4 GPU Özellikleri

Özellik	Açıklama
GPU Mimarisi	NVIDIA Turing (TU104)
CUDA Çekirdek Sayısı	2.560
Tensor Çekirdek Sayısı	320
Bellek Kapasitesi	16 GB GDDR6
Bellek Bant Genişliği	320 GB/s
Bellek Arayüzü	256-bit

Görüntüler, maymun çiçeği pozitif ve maymun çiçeği olmayan negatif olmak üzere iki ana sınıfa ayrılmıştır. Pozitif sınıfta 3.682, negatif sınıfta ise 4.851 örnek (maymun çiçeği, suçiçeği, kızamık ve normal cilt görüntülerinden oluşan) yer almakta olup, sınıflar arasındaki dağılım modelin dengesiz veri sorununa maruz kalmadan eğitilmesini sağlamıştır. Veriler, rastgele ancak dengeli biçimde %81'i eğitim, %9'u doğrulama ve %10'u test seti olacak şekilde ayrılmıştır. Tüm klasör ve görüntü dosyaları Google Drive™ ortamında saklanmış ve algoritmaya dosya yolları aracılığıyla dahil edilmiştir.

Derin öğrenme modelleriyle yapılan deneysel çalışmalar sonucunda, sekiz temel mimarinin ve önerilen topluluk modelinin performans metrikleri karşılaştırmalı olarak değerlendirilmiştir. Önerilen model, test veri seti üzerinde %99,30 doğruluk (accuracy), %99,31 kesinlik (precision), %99,30 duyarlılık (sensitivity) ve %99,30 F1 skoru elde ederek en yüksek sınıflandırma başarısına ulaşmıştır. Karşılaştırmalı sonuçlar Tablo 3'te sunulmuştur ve önerilen modelin, tekil CNN tabanlı yaklaşımlara kıyasla anlamlı ölçüde daha yüksek doğruluk ve genelleme performansı sergilediği görülmektedir. Bu sonuçlar, modelin hem pozitif hem de negatif sınıfları yüksek güvenle ayırt edebildiğini göstermekte ve önerilen mimarinin güçlü genelleme kapasitesini doğrulamaktadır.

Tablo 3. Modellerin Performans Sonuçları


Model	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
VGG16	%84.89	%85.79	%84.89	%84.96
VGG19	%82.79	%83.36	%82.79	%82.86
DenseNet-121	%96.60	%96.62	%96.60	%96.60
DenseNet-169	%98.48	%98.49	%98.48	%98.48
DenseNet-201	%98.95	%98.95	%98.95	%98.95
Xception V3	%97.19	%97.22	%97.19	%97.19
Xception	%98.24	%98.24	%98.24	%98.24
MobileNet V2	%98.24	%98.24	%98.24	%98.24
Önerilen Model	%99.30	%99.31	%99.30	%99.30

Modelin eğitiminde kullanılan temel hiperparametre değerleri Tablo 4'te özetlenmiştir. Eğitim süreci, tüm veri seti üzerinde 100 epoch boyunca yürütülmüş ve her iterasyonda 32 örnek kullanılmıştır. Öğrenme oranı (learning rate) 0.0005 olarak belirlenmiş, doğrulama kaybı beş ardışık döngü boyunca iyileşme göstermediğinde öğrenme oranı %50 azaltılmıştır. Aşırı öğrenmeyi (overfitting) önlemek amacıyla, dal bloklarda dropout oranı 0.3–0.4, birleşik katmanlarda ise 0.5 olarak seçilmiştir. Modelin karar eşiği 0.82 olarak optimize edilmiş, her özellik dalında 1024 ve 512 nöronlu yoğun (Dense) katmanlar kullanılmıştır. Üç dalın çıktıları birleştirildikten sonra 512, 256 ve 128 nöronlu tam bağlantılı katmanlardan geçirilmiştir. Bu yapı, modelin derin özellikleri yakalayarak yüksek doğrulukta sınıflandırma yapabilmesini sağlamıştır.

Tablo 4. Önerilen Model Hiperparametre Değerleri

Döngü	Yığın Boyutu	Öğrenme Oranı	Düşürme (Dropout)	Eşik Değeri	Nöron Sayısı
100	32	0.0005	0,3, 0,4, 0,5	0.82	512, 256, 128


Modelin test verisi üzerindeki karışıklık matrisi Şekil 4'te gösterilmiştir. Toplam 854 örnek içerisinde model, 485 negatif ve 363 pozitif örneği doğru şekilde sınıflandırmıştır. Yanlış pozitif (false positive) örnek tespit edilmemiş, yalnızca 6 yanlış negatif (false negative) gözlemlenmiştir. Buna göre, doğru negatif (TN) = 485, doğru pozitif (TP) = 363, yanlış pozitif (FP) = 0 ve yanlış negatif (FN) = 6'dır. Yanlış pozitif oranı %0.00, yanlış negatif oranı ise %1.63 olarak hesaplanmıştır. Bu sonuçlar, modelin özellikle pozitif örnekleri yüksek doğrulukla ayırt edebildiğini ve yanlış alarm üretmeden güçlü bir genel performans sergilediğini göstermektedir.



Şekil 4. Önerilen Model Karışıklık Matrisi

Önerilen modelin eğitim ve doğrulama eğrileri Şekil 5’te verilmiştir. Eğitim doğruluğu (training accuracy) döngüler ilerledikçe kademeli biçimde artarak 1’e yaklaşmış, doğrulama doğruluğu (validation accuracy) ise genel olarak yüksek seviyelerde seyretmiş ancak doğal dalgalanmalar göstermiştir. Bu durum, modelin aşırı öğrenme (overfitting) eğiliminde olmadığını ve doğrulama performansının istikrarlı şekilde korunduğunu göstermektedir. Eğitim kaybı (training loss) döngüler boyunca sürekli azalarak sıfıra yakınsamış, doğrulama kaybı (validation loss) da düzenli bir düşüş eğilimi sergilemiştir. Son epoch’larda her iki kayıp eğrisinin de düşük seviyelerde birbirine yakın değerler alması, modelin genel dengeleme ve genelleme başarısının yüksek olduğunu ortaya koymaktadır.


Modelin sınıflandırma kararlarının görsel olarak açıklanabilirliğini değerlendirmek amacıyla Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) yöntemi uygulanmıştır (Şekil 7). Her iki sınıftan en az üç örnek ve ayrıca yanlış sınıflandırılan örnekler için Grad-CAM çıktıları sunulmuştur. Isı haritaları, ilgili mimarinin son evrimsel katmanından türetilmiştir. Grad-CAM çıktılarında yüksek aktivasyon değerleri (sıcak renkler) çoğunlukla lezyon bölgeleriyle örtüşmüştü, bu durum modelin kararlarını arka plan yerine patolojik lezyon alanlarına dayandığını göstermiştir. Yanlış sınıflandırılan örneklerde ise aktivasyonların düşük kontrastlı veya atipik lezyon bölgelerine yoğunlaştığı görülmektedir.




Şekil 5. Önerilen Model Doğruluk Kayıp Grafikleri

Önerilen nihai meta modelin sınıflandırma başarımı, test veri kümesi üzerinde Alıcı İşletim Karakteristiği (Receiver Operating Characteristic – ROC) eğrisi kullanılarak değerlendirilmiştir.

Şekil 6’da sunulan ROC eğrisi altında kalan alan (AUC) değeri 0.9994 olarak elde edilmiştir. Bu yüksek AUC değeri, geliştirilen meta modelin maymun çiçeği ve maymun çiçeği olmayan cilt lezyonlarını ayırt etme konusunda son derece güçlü bir ayırt edicilik kapasitesine sahip olduğunu göstermektedir.



Şekil 6. Önerilen Model ROC Eğrisi



Şekil 7. Önerilen Model Grad-CAM Analizi

Literatürde yer alan önde gelen çalışmaların doğruluk performansları Tablo 5’de özetlenmiştir. Önerilen yöntem (tabloda Ö.Y. şeklindedir), %99,30 doğruluk oranı ile tüm referans modellerden daha yüksek bir başarı elde etmiştir. Bu çalışmada test seti üzerinde en yüksek genelleme performansını sunan DenseNet169, DenseNet201 ve Xception modellerinden çıkarılan derin özellikler birleştirilerek özellik düzeyinde yığınlama topluluk öğrenmesi (feature-level stacking ensemble learning) yöntemiyle yeni bir meta model geliştirilmiştir. Bu yaklaşım, tekil modellerin güçlü yanlarını bir araya getirerek doğruluk, kesinlik ve kararlılık açısından istikrarlı biçimde üstün sonuçlar üretmiştir.

Elde edilen bulgular, geliştirilen hibrit veri seti ve topluluk öğrenmesi mimarisinin yalnızca maymun çiçeği hastalığının tanısında değil, genel olarak tıbbi görüntü tabanlı tanı sistemlerinde de kullanılabilecek yenilikçi ve ölçeklenebilir bir çerçeve sunduğunu göstermektedir. Bu nedenle önerilen yöntem, literatürde özellik düzeyinde topluluk öğrenmesine dayalı ilk hibrit veri seti üzerinden maymun çiçeği/maymun çiçeği olmayan sınıflandırma modeli olma niteliği taşımaktadır.

Tablo 5. Sonuçların Literatür Karşılaştırması

Ref.	Model	Doğruluk	Duyarlılık	Kesinlik	F1
[14]	VGG 16	%97.00	%97.00	%97.00	%97.00
[15]	Derin CNN Modeli	%98.91	%98.91	%98.91	%98.91
[9]	ResNet50	%82.96	%83.00	%87.00	%84.00
[16]	MobileNet V2	%91.11	%90.00	%90.00	%90.00
[17]	Oylama Topluluk Öğrenmesi [DenseNet169 + Xception]	%87.13	%85.47	%85.44	%85.40
Ö.Y.	Önerilen Model	%99.30	%99.30	%99.31	%99.30

5. Genel Değerlendirme ve Gelecek Çalışmalar

Bu çalışma kapsamında, literatür ve açık kaynak veri tabanlarından derlenen görüntüler birleştirilerek maymun çiçeği hastalığının cilt görüntülerinden tespitine yönelik yenilikçi bir hibrit veri seti oluşturulmuştur. Veri setinin büyüklüğü sayısal olarak sınırlı olmakla birlikte, farklı kaynaklardan elde edilen görüntülerin lezyon tipleri, cilt tonları ve görüntüleme koşulları açısından sunduğu çeşitlilik, modelin ayırt edici örüntüleri öğrenmesine önemli ölçüde katkı sağlamıştır. Bu bağlamda, model karmaşıklığı yalnızca örnek sayısı temelinde değil, veri setinin içerdiği bilginin çeşitliliği birlikte dikkate alınarak ele alınmıştır. Görüntü işleme ve veri artırma adımlarının ardından, sekiz farklı önceden eğitilmiş derin öğrenme modeli transfer öğrenme yaklaşımıyla değerlendirilmiş; en yüksek performansı sergileyen DenseNet169, DenseNet201 ve Xception mimarilerinden elde edilen özellikler birleştirilerek özellik düzeyinde yığınlama topluluk öğrenmesine dayalı bir meta model geliştirilmiştir. Önerilen model, literatürde raporlanan referans çalışmalarla karşılaştırıldığında daha yüksek bir doğruluk oranı (%99,30) elde etmiştir.

Elde edilen bulgular, geliştirilen mimarinin yalnızca maymun çiçeği hastalığının tespitinde değil, farklı tıbbi görüntü tabanlı tanı ve triyaj sistemlerinde de uygulanabilir bir yapay zekâ çerçevesi sunduğunu göstermektedir. Bu yaklaşım, PCR gibi altın standart laboratuvar yöntemlerinin yerini almadan, saha yakın tanı ve ön değerlendirme basamaklarını destekleyebilecek hızlı, düşük maliyetli ve ölçeklenebilir bir karar destek mekanizması olarak değerlendirilebilir. Dolayısıyla çalışma, topluluk öğrenmesi temelli derin özellik birleştirme (feature-level ensemble) stratejisinin klinik karar destek sistemlerinde tanı doğruluğunu artırmada etkili bir yöntem olduğunu ortaya koymaktadır.

Çalışmanın güçlü yönlerinden biri, farklı derin evrimsel mimarilerden elde edilen tamamlayıcı özelliklerin özellik düzeyi yığınlama yaklaşımıyla bir araya getirilmesi ve model performansının doğruluk, duyarlılık, kesinlik ve F1 skoru gibi çoklu metrikler üzerinden kapsamlı biçimde değerlendirilmiş olmasıdır. Ayrıca, Grad-CAM tabanlı açıklanabilirlik analizleri, modelin karar mekanizmasının görsel olarak yorumlanabilmesine olanak tanıyarak klinik güvenilirliği desteklemiştir.

Bununla birlikte, çalışmanın bazı sınırlılıkları da bulunmaktadır. Kullanılan veri setinin örnek sayısının sınırlı olması ve görüntülerin farklı açık kaynaklardan elde edilmesi, gerçek klinik ortamlarda karşılaşılabilecek dağılım farklılıklarını tam olarak yansıtamayabilir. Ayrıca, profesyonel klinik

değerlendirme ve piksel düzeyinde anotasyonların bulunmaması, sonuçların klinik doğrulama açısından yorumlanmasında dikkatli olunmasını gerektirmektedir. Gelecek çalışmalarda, veri seti çeşitliliğini artırmaya yönelik gelişmiş veri büyütme ve sentetik veri üretim yöntemlerinin kullanılması, veri gizliliğini koruyarak çok merkezli eğitim imkânı sunan federated learning yaklaşımlarının uygulanması planlanmaktadır.

Buna ek olarak, önerilen modelin gerçek zamanlı sistemlerde ve mobil platformlarda uygulanabilirliğinin değerlendirilmesi, gelecekteki çalışmalar için önemli bir araştırma alanı olarak görülmektedir. Bu kapsamda, modelin daha hafif mimarilerle uyumlu hâle getirilmesi, hesaplama maliyeti açısından optimize edilmesi ve çevrimdışı veya yarı çevrimdışı karar destek senaryolarında kullanılabilirliğinin incelenmesi hedeflenmektedir.

Kaynaklar

- [1] Guarner, J., Del Rio, C. and Malani, P. N., “Monkeypox in 2022—What Clinicians Need to Know”. *JAMA*, 328(2), 139–140. <https://doi.org/10.1001/jama.2022.10802> (2022).
- [2] Kantele, A., Chickering, K., Vapalahti, O. and Rimoin, A.W., “Emerging diseases—the monkeypox epidemic in the Democratic Republic of the Congo” *Clinical Microbiology and Infection*, Volume 22, Issue 8, 658 – 659, 2016.
- [3] Vaughan, A. M., Cenciarelli, O., Colombe, S., Alves de Sousa, L., Fischer, N., Gossner, C. M., Pires, J., Scardina, G., Aspelund, G., Avercenko, M., Bengtsson, S., Blomquist, P., Caraglia, A., Chazelle, E., Cohen, O., Díaz, A., Dillon, C., Dontsenko, I., Kotkavaara, K., Fafangel, M. and Haussig, J. M., “A large multi-country outbreak of monkeypox across 41 countries in the WHO European Region, 7 March to 23 August 2022” , *Eurosurveillance*, 27(36). <https://doi.org/10.2807/1560-7917.ES.2022.27.36.2200920>, 2022.
- [4] Nakhaie, M., Arefinia, N., Charostad, J., Bashash, D., Abdolvahab, M.H. and Zarei, M., “Monkeypox virus diagnosis and laboratory testing,” *Rev Med Virol*, vol. 33, no. 1, Jan. 2023. <https://doi.org/10.1002/rmv.2404>
- [5] Qu, J., Zhang, X., Liu, K., Li, Y., Wang, T., Fang, Z., Chen, C., Tan, X., Lin, Y., Xu, Q., Yang, Y., Wang, W., Huang, M., Guo, S., Chen, Z., Rao, W., Shi, X. and Peng, B., “A Comparative Evaluation of Three Diagnostic Assays for the Detection of Human Monkeypox”, *Viruses*, 16(8), 1286. <https://doi.org/10.3390/v16081286>
- [6] Oladipo, E.K., Ajayi, A.F., Odeyemi, A.N., Akindiya, O.E., Adebayo, E.T., Oguntomi, A.S., Oyewole, M.P., Jimah, E.M., Oladipo, A.A., Ariyo, O.E., Oladipo, B.B. and Oloke, J.K., “Laboratory diagnosis of COVID-19 in Africa: availability, challenges and implications”. *Drug Discoveries Therapeutics*, vol. 14, no. 4, pp. 153–160 <https://doi.org/10.5582/DDT.2020.03067>
- [7] Zhao, W., Jiang, W. and Qiu, X., “Deep learning for COVID-19 detection based on CT images”, *Sci Rep* 11, 14353 (2021). <https://doi.org/10.1038/s41598-021-93832-2>
- [8] Jaradat, A. S., Al Mamlook, R. E., Almakayee, N., Alharbe, N., Almuflih, A. S., Nasayreh, A., Gharaibeh, H., Gharaibeh, M., Gharaibeh, A. and Bzizi, H., “Automated Monkeypox Skin Lesion Detection Using Deep Learning and Transfer Learning Techniques”, *International journal of environmental research and public health*, 20(5), 4422, 2023. <https://doi.org/10.3390/ijerph20054422>
- [9] Ali, S.N., Ahmed, T., Paul, J., Jahan, T., Sani, S.M.S., Noor, N. and Hasan, T., “Monkeypox Skin Lesion Detection Using Deep Learning Models: A Feasibility Study” , *arXiv:2207.03342v1 [cs.CV]*, 2022. Dataset URL: <https://github.com/ShamsNafisaAli/Monkeypox-Skin-Lesion-Dataset> , Erişim Tarihi: 21 Aralık 2024

- [10] Siar, M. and Teshnehlab, M., "Brain Tumor Detection Using Deep Neural Network and Machine Learning Algorithm," , 2019 9th International Conference on Computer and Knowledge Engineering (ICCKE), Mashhad, Iran, 2019, pp. 363-368, doi: 10.1109/ICCKE48569.2019.8964846
- [11] Ahamed, A., Politza, A.J., Liu, T., Khalid, M.A.U., Zhang, H. and Guan, W., "CRISPR-based strategies for sample-to-answer monkeypox detection: current status and emerging opportunities", *Nanotechnology*, Volume 36, Number 4, DOI 10.1088/1361-6528/ad892b
- [12] McCollum, A. M. and Damon, I. K., "Human monkeypox", *Clinical infectious diseases : an official publication of the Infectious Diseases Society of America*, 58(2), 260-267, 2014. <https://doi.org/10.1093/cid/cit703>
- [13] Petti, C.A., Polage, C.R., Quinn, T.C., Ronald, A.R. and Sande, M.A., "Laboratory Medicine in Africa: A Barrier to Effective Health Care," *Clinical Infectious Diseases*, vol. 42, no. 3, pp. 377-382, Feb. 2006, <https://doi.org/10.1086/499363>
- [14] Ahsan, M. M., Uddin, M. R., Farjana, M., Sakib, A. N., Momin, K. A. and Luna, S. A., "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. Dataset URL: <https://github.com/mahsan2/Monkeypox-dataset-2022> , Erişim Tarihi: 21 Aralık 2024
- [15] Bala, D., Hossain, M. S., Hossain, M. A., Abdullah, M. I., Rahman, M. M., Manavalan, B., Gu, N., Islam, M. S. and Huang, Z., "MonkeyNet : a robust deep convolutional neural network for monkeypox disease detection and classification" , *Neural Networks*, 161,757-775, 2023. doi.org/10.1016/j.neunet.2023.02.022, Dataset URL: <https://data.mendeley.com/datasets/r9bfpnvxyr/6> Erişim Tarihi: 21 Aralık 2024
- [16] Sahin, V.H., Oztel, I. and Yolcu Oztel, G., "Human Monkeypox Classification from Skin Lesion Images with Deep Pre-trained Network using Mobile Application" , *J Med Syst* 46, 79 ,2022. <https://doi.org/10.1007/s10916-022-01863-7>
- [17] Sitaula, C. and Shahi, T.B., "Monkeypox Virus Detection Using Pre-trained Deep Learning-based Approaches" , *J Med Syst* 46, 78, 2022. <https://doi.org/10.1007/s10916-022-01868-2>
- [18] Altun, M., Gürtler, H., Özkaraca, O., Khan, F., Khan, J. and Lee, Y., "Monkeypox Detection Using CNN with Transfer Learning" , *Sensors*, 23(4), 1783, 2023. <https://doi.org/10.3390/s23041783>
- [19] Taspinar, Y. S., Cinar, I., Kursun, R. and Koklu, M., "Monkeypox Skin Lesion Detection with Deep Learning Models and Development of Its Mobile Application". *International Journal of Research in Engineering and Science, ISSN (Online): 2320-9364, ISSN (Print): 2320-9356, Vol(12), 1, pp 273-285, 2024.*
- [20] Akram, A., Jamjoom, A.A., Innab, N., Almujaally, N.A., Umer5, M., Alsubai, S. and Fimiani, G., "SkinMarkNet: an automated approach for prediction of monkeyPox using image data augmentation with deep ensemble learning models" , *Multimed Tools Appl* 84, 20177-20193 (2025). <https://doi.org/10.1007/s11042-024-19862-w>
- [21] Maqsood, S., Damaševičius, R., Shahid, S. and Forkert, N.D., "MOX-NET: Multi-stage deep hybrid feature fusion and selection framework for monkeypox classification," *Expert Syst Appl*, vol. 255, p. 124584, Dec. 2024, <https://doi.org/10.1016/j.eswa.2024.124584>
- [22] Asif, S., Zhao, M., Tang, F., Zhu, Y. And Zhao, B. "Metaheuristics optimization-based ensemble of deep neural networks for Mpox disease detection," *Neural Networks*, vol. 167, pp. 342-359, Oct. 2023, <https://doi.org/10.1016/j.neunet.2023.08.035>
- [23] Thieme, A.H., Zheng, Y., Machiraju, G. et al. , "A deep-learning algorithm to classify skin lesions from mpox virus infection", *Nat Med* 29, 738-747 , 2023.
- [24] Ahsan, M.M., Alam, T.E., Haque, M.A., Ali, S., Rifat, R.H., Nafi, A.N., Hossain, M. and Islam, K., "Enhancing Monkeypox diagnosis and explanation through modified transfer learning, vision transformers, and federated learning," *Inform Med Unlocked*, vol. 45, p. 101449, 2024.
- [25] Tripathi, M.K., Nath, A., Singh, T.P. et al., "Evolving scenario of big data and Artificial Intelligence (AI) in drug discovery" , *Mol Divers* 25, 1439-1460 , 2021. <https://doi.org/10.1007/s11030-021-10256-w>
- [26] (2023). Dermnet. Accessed: Sep. 2023. [Online]. Available: <http://www.dermnet.com/> , Dataset URL: <https://dermnetnz.org/images/mpox-images> Erişim Tarihi: 21 Aralık 2024
- [27] (2022). A. Nasayrah, "Data Monkeypox," Kaggle.com. (accessed: Sep. 8, 2025) , DatasetURL:<https://www.kaggle.com/datasets/ahmadnasayrah/data-monkeypox> , Erişim Tarihi: 21 Aralık 2024
- [28] Wahid, M., Ahmad, N., Zafar, M.H. and Khan, S., "On combining MD5 for image authentication using LSB substitution in selected pixels," *International Conference on Engineering and Emerging Technologies (ICEET), IEEE*, pp. 1-6, ISBN 9781538621707, 2018.
- [29] Malviya, A. V. and Ladhake, S. A., "Region duplication detection using color histogram and moments in digital image" , *International Conference on Inventive Computation Technologies (ICICT)*, Vol.1, pp. 1-4, 2016.
- [30] Wong, S.C., Gatt, A., Stamatescu, V. and McDonnell, M.D., "Understanding Data Augmentation for Classification: When to Warp?" , *International Conference on Digital Image Computing: Techniques and Applications (DICTA)*, IEEE, 2016, pp. 1-6, doi: 10.1109/DICTA.2016.7797091.
- [31] Perez, L. and Wang, J. "The Effectiveness of Data Augmentation in Image Classification using Deep Learning," *arXiv:1712.04621v1 [cs.CV]* 13 Dec 2017.
- [32] Sönmez, D., "Geri yayılım algoritması'na matematiksel yaklaşım," *DerinOglenme.com*, Jun. 28, 2018. [Online]. Available: "https://www.derinogrenme.com/2018/06/28/geri-yayilim-algoritmasinamatematiksel-yaklasim/.
- [33] LeCun, Y., Bengio, Y. and Hinton, G., "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, May 2015.
- [34] LeCun, Y., Bottou, L., Bengio, Y. And Haffner, P., "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998. 10.1109/5.726791
- [35] Goodfellow, I., Bengio, Y. and Courville, A., "Deep learning" , Cambridge, MA, USA: MIT Press, 2017.
- [36] Zafar, A., Saba, N., Arshad, A., Alabrah, A., Riaz, S., Suleman, M., Zafar, S. and Nadeem, M., "Convolutional Neural Networks: A Comprehensive Evaluation and Benchmarking of Pooling Layer Variants" , *Symmetry*, 16(11), 1516, 2024. <https://doi.org/10.3390/sym16111516>
- [37] Yao, J., "Vehicle Classification Enhancement Through Data Augmentation and Model Fusion: A Study of Deep Learning Approaches" , 4th International Conference on Digital Society and Intelligent Systems (DSInS), IEEE, pp. 449-453, 2024. DOI: 10.1109/DSInS64146.2024.10992194
- [38] Kunc, V. And Kléma, J., "Three Decades of Activations: A Comprehensive Survey of 400 Activation Functions for Neural Networks" , *arXiv:2402.09092v1 [cs.LG]* 14 Feb 2024.

Özgeçmiş



Fırat Bulak, Başkent Üniversitesi Biyomedikal Mühendisliği lisans ve tezli yüksek lisans programları mezunudur. Akademik çalışma hayatında medikal görüntü işleme, derin öğrenme ve sağlık yazılımları alanlarında çeşitli projelerin yürütücülüklerini gerçekleştirmiştir. Sektörde biyomedikal cihaz teknolojileri, sağlık bilişimi ve e-ihracat alanlarında aktif olarak çalışmıştır. Sağlık bilişimi tele radyoloji alanında sektörel projelerin kurulum, konfigürasyon ve yönetim süreçlerinde aktif olarak görev almaktadır. Görüntüleme teknolojileri ile PACS, DICOM ve HL7 gibi sağlık bilişimi standartlarında tasarım deneyimine sahiptir.

Hem teknik hem de ekip çalışmasına dayalı projelerde sorumluluk almayı, stres yönetimini ve hızlı karar alabilmeyi önemsemektedir. Sağlık teknolojileri alanında katma değer sağlayan projelerde yer almak ve uzmanlığını sürekli geliştirerek sektöre, ülkemize katkıda bulunmayı amaçlamaktadır.

Özgeçmiş



Onur Koçak, 2005 yılında Başkent Üniversitesi Biyomedikal Mühendisliği Bölümü'nden 3.31 genel not ortalaması ve bölüm üçüncülüğü derecesi ile mezun olmuştur. Doktora eğitimini 2014 yılında Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda tamamlamıştır.

2006 yılından itibaren Başkent Üniversitesi Bilgisayar Mühendisliği Bölümü'nde öğretim üyesi olarak görev yapan Koçak, 2025 yılı itibarıyla Başkent Üniversitesi Biyomedikal Mühendisliği Bölümü Bölüm Başkan Yardımcılığı görevini sürdürmektedir. Akademik çalışmaları; karar destek sistemleri, biyomedikal görüntü işleme ve biyomedikal sinyal işleme, biyomedikal elektronik sistemler, tıbbi cihaz tasarımı, sensör tabanlı ölçüm sistemleri ve mühendislik temelli sağlık teknolojileri alanlarında yoğunlaşmaktadır.

Bilimsel üretkenliği kapsamında 11'i SCI kapsamındaki dergilerde yayımlanmış olmak üzere, diğer indekslerde taranan 5 makalesi, ayrıca ulusal ve uluslararası kongrelerde sunulmuş 80'in üzerinde bilimsel bildirisi bulunmaktadır. Üniversite-sanayi iş birliği çerçevesinde tamamlamış olduğu 40'in üzerinde mühendislik projesi mevcuttur. Patent ve faydalı model çalışmalarının yanı sıra bilimsel kitap editörlüğü yapmıştır.

Sanayi ve girişimcilik alanında, 2011 yılından bu yana İBÜTEM – İleri Biyomedikal Mühendislik Teknolojileri Merkezi Ar.Ge. Ltd. Şti.'nin, 2018 yılından itibaren ise MARLA Teknoloji Mühendislik Ltd. Şti.'nin kurucusu ve tasarım mühendisidir.

TÜBİTAK, T.C. Sağlık Bakanlığı ve TÜSEB bünyesinde çeşitli bilim kurullarında görev almaktadır. Elektrik Mühendisleri Odası üyesidir.