



Domates Yapraklarında Hastalık Tespiti İçin Transfer Öğrenme Kullanılması Ve Mobil Uygulamaya Entegre Edilmesi

Tahir Çağrı ÖZBEN^a, Osman GÜLER^{*b}

^a Çankırı Karatekin Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, ÇANKIRI, 18100, TÜRKİYE

^{b*} Çankırı Karatekin Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, ÇANKIRI, 18100, TÜRKİYE

MAKALE BİLGİSİ

Alınma: 22.04.2025
Kabul: 22.06.2025

Anahtar Kelimeler:

Yapay zeka, Transfer öğrenme, Mobil uygulama, Domates, Domates yaprak hastalığı.

*Sorumlu Yazar

osmanguler@karatekin.edu.tr

ÖZET

Bu çalışmada, tarımsal bitki sağlığı yönetiminde yapay zeka uygulamalarından faydalanılmaktadır. Özel olarak, domates bitkilerinde görülen dokuz farklı hastalık türü ve sağlıklı yaprakları tespit edebilmek için derin öğrenme tabanlı bir çözüm geliştirilmiştir. Toplam 16.011 görüntü içeren bir veri seti kullanılarak, MobileNetV1, MobileNetV2, MobileNetV3 Small ve MobileNetV3 Large mimarileri ile 20 eğitim devresi boyunca eğitimler gerçekleştirilmiştir. Eğitimler sonrasında en yüksek doğruluk oranına ulaşan model, Android platformunda çalışabilen bir mobil uygulamaya entegre edilmiştir. Uygulama, kullanıcıların domates yapraklarındaki hastalıkları gerçek zamanlı olarak tespit etmelerine olanak tanımaktadır. İlk denemeler, geliştirilen modelin yüksek doğrulukla hastalıkları tespit edebildiğini göstermiştir. Bu çalışma, mobil teknolojilerin tarımsal bitki hastalıklarını erken teşhis etmedeki potansiyelini vurgulamakta ve tarımsal verimliliği artırmaya yönelik yeni yollar sunmaktadır.

DOI: 10.59940/jismar.1681569

Using Transfer Learning for Disease Detection in Tomato Leaves and Its Integration into a Mobile Application

ARTICLE INFO

Received: 22.04.2025
Accepted: 22.06.2025

Keywords:

Artificial intelligence, Transfer learning, Mobile application, Tomato, Tomato leaf disease.

*Corresponding Authors

e-mail:
osmanguler@karatekin.edu.tr

ABSTRACT

In this study, artificial intelligence applications are utilized for agricultural plant health management. Specifically, a deep learning-based solution has been developed to detect nine different types of diseases observed in tomato plants, as well as healthy leaves. Using a dataset containing a total of 16,011 images, training was conducted over 20 epochs with MobileNetV1, MobileNetV2, MobileNetV3 Small, and MobileNetV3 Large architectures. Following the training, the model that achieved the highest accuracy was integrated into a mobile application compatible with the Android platform. The application enables users to detect diseases in tomato leaves in real time. Initial experiments demonstrated that the model could identify diseases with high accuracy. This study highlights the potential of mobile technologies in the early diagnosis of plant diseases and presents new avenues for improving agricultural productivity.

DOI: 10.59940/jismar.1681569

1. GİRİŞ (INTRODUCTION)

Tarım, küresel nüfusun artmasıyla birlikte gıda güvenliği sağlamada kritik bir rol oynamaktadır. Özellikle domates, dünya çapında geniş bir tüketim ağına sahip olup, önemli bir besin kaynağıdır. Ancak, hastalıkların erken teşhisi, verimliliği artırma ve ürün kayıplarını minimuma indirme açısından büyük zorluklar sunmaktadır. Türkiye, yılda ortalama 12,8 milyon tonluk domates üretmektedir. Türkiye, dünya domates üretiminde üçüncü sırada yer alırken, ihracat sıralamasında ise beşinci konumdadır [1]. Domates, toplam sebze tüketiminin yaklaşık %20'sini oluşturmaktadır ve yıllık kişi başı ortalama tüketim 20 kg civarındadır [2]. Dünya genelinde domates üretiminde öne çıkan ülkeler arasında Türkiye, Mısır ve Çin gibi ülkeler bulunmaktadır [3]. Yapılan araştırmalarda, özellikle Punjab ve Sindh bölgelerinde domates yapraklarında görülen hastalıkların, ürün kaybını %30 ile %40 arasında artırdığı belirtilmiştir [2]. Geleneksel tarım yöntemleri, hem zaman açısından verimsiz hem de hata yapmaya elverişli olabilmektedir. Bu nedenle, tarım sektöründe teknolojinin kullanımı giderek daha önemli hale gelmektedir.

Domates bitkileri, verimi ve kaliteyi önemli ölçüde etkileyebilecek çeşitli hastalıklara karşı hassastır. Bu hastalıkların erken ve doğru bir şekilde tanımlanması, etkili ürün yönetimi için çok önemlidir. Geleneksel hastalık tanımlama yöntemleri, zaman alıcı ve insan hatasına açık olabilen uzmanlar tarafından yapılan görsel incelemeye dayanır. Derin öğrenme alanındaki son gelişmeler, hastalık tanımlama sürecinin otomatikleştirilmesine olanak sağlayarak daha hızlı ve daha doğru bir alternatif sunmaktadır.

Yapay zekâ teknolojileri, tarımda verimliliği artırmanın yanı sıra hastalık teşhis ve kontrolünde önemli bir dönüşüm potansiyeline sahiptir. Özellikle derin öğrenme, görüntü işleme ve analizinde büyük başarılar göstererek, bitkisel hastalıkların erken teşhisinde önemli bir araç haline gelmiştir. Mobilite ve erişilebilirlik, bu teknolojilerin tarım sektörüne adaptasyonunu daha da değerli kılmaktadır.

Domates yaprak hastalıklarına mantarlar, bakteriler, virüsler ve çevresel faktörler neden olabilir. Bu çalışmada, domates bitkileri üzerinde yaygın olarak görülen dokuz farklı hastalık türü ve sağlıklı bitkileri ayırt edebilmek amacıyla MobileNet mimarileri kullanılarak eğitimler gerçekleştirilmiştir. Toplam 16,011 adet görüntü üzerinden eğitilen modeller, Android platformunda çalışan bir mobil uygulama aracılığıyla saha koşullarında test edilmiştir. Uygulamanın, kullanıcıların domates

yapraklarını tarayarak hastalıkları gerçek zamanlı olarak tespit etme yeteneği, tarımsal faaliyetlerde verimliliği artırma ve erken müdahale olanağı sağlama potansiyeli taşımaktadır. Günümüzdeki tarım uygulamaları, bitki hastalıklarının teşhisinde genellikle mikroskop gibi ek ekipmanlar ve uzmanların yardımıyla çiftlik çalışanlarının görsel incelemelerine dayanmaktadır [2]. Ancak, tarım uzmanları sahada sürekli olarak bulunmadığından kapsamlı izleme yapmak mümkün olmayabilir. Ayrıca, çiftçilerin çoğu bu tür teşhis süreçlerini yürütebilecek uzmanlığa sahip değildir [2]. Bu nedenle, domates yapraklarında görülen hastalıkların tespiti için derin öğrenme yöntemleri literatürde sıklıkla kullanılmaktadır [4], [5]. Derin öğrenmenin en önemli avantajlarından biri, özellik çıkarımını otomatik olarak gerçekleştirerek karmaşık ve üst düzey özelliklerin keşfedilmesine olanak tanımasıdır [6].

Bu çalışma, bu teknolojilerin pratik uygulamalarını gözler önüne sermekte ve yapay zekânın tarım sektöründe nasıl bir dönüşüm yaratabileceğine dair önemli bilgiler sunmaktadır. Ayrıca, bu girişim, yapay zekâ tabanlı çözümlerin tarım pratiğine entegrasyonunun önündeki teknik ve pratik engelleri aşmada önemli bir örnek olarak değerlendirilmektedir.

2. İLGİLİ ÇALIŞMALAR (RELATED WORK)

Makine öğreniminin bir alt kümesi olan derin öğrenme, verilerden özellikleri otomatik olarak öğrenme yeteneği nedeniyle görüntü tanıma görevlerinde yaygın olarak benimsenmiştir. Evrişimli Sinir Ağları (CNN'ler) görüntü sınıflandırma görevlerinde yüksek performans göstermeleri nedeniyle yaprak görüntülerinden bitki hastalıklarını tespit etmek için uygun hale getirir. Tarım alanında hastalık tespiti, verimlilik tespiti vb. farklı birçok uygulamada yapay zekâ yöntemleri tarım uzmanlarına destek sağlamaktadır.

Kılıçarslan ve Paçal, domates yapraklarında görülen hastalıkların tespiti için DenseNet, ResNet50 ve MobileNet mimarilerini kullanarak çeşitli deneyler gerçekleştirmişlerdir. Yapılan çalışmalar sonucunda, DenseNet modelinin en yüksek doğruluk oranına ulaştığı belirtilmiştir. Bu model ile 0.0269 hata oranı, 0.9900 doğruluk, 0.9880 kesinlik, 0.9892 F1-skor ve 0.9906 duyarlılık değerleri elde edilmiştir [2].

Literatürdeki benzer bir çalışmada, PlantVillage domates veri kümesi kullanılarak domates hastalıklarının sınıflandırılması için en uygun makine öğrenmesi (ML) ve derin öğrenme (DL) modelleri araştırılmıştır [7]. Bu çalışmada, yerel ikili desen (LBP) ve gri seviye eş oluşturma matrisi (GLCM)

yöntemleriyle 105 renk özelliği çıkarılmıştır. Test edilen modeller arasında ResNet34 ağı, %99,7 doğruluk, %99,6 kesinlik, %99,7 duyarlılık ve %99,7 F1-skoru ile en iyi sonuçları vermiştir.

Cengil ve Çıkar tarafından yapılan bir başka çalışmada, Taiwan veri kümesi kullanılarak domates yaprağı hastalıklarının tespiti için AlexNet, ResNet50 ve VGG16 gibi transfer öğrenme modelleri değerlendirilmiştir. Deneyler sonucunda, ResNet50 modelinin %96,10 doğruluk oranı ile en yüksek başarıyı sağladığı raporlanmıştır [8].

Bir diğer araştırmada, bitki hastalıklarının belirtilerini sağlıklı dokulardan ayırt etmek amacıyla bir algoritma önerilmiştir [9]. Bu algoritma, HSV renk uzayındaki H kanalı ve CIELAB renk uzayındaki a kanalının histogramlarını kullanmaktadır. Algoritma, 19 bitki türü ve 82 hastalık görüntüsü içeren geniş bir veri seti üzerinde test edilmiştir. Sonuçlara göre, a kanalı geçiş bölgesini hastalıklı doku olarak sınıflandırma eğilimindeyken, H kanalı aynı bölgeyi sağlıklı doku olarak değerlendirmiştir. Ayrıca, a kanalının geçiş bölgesinin %50'sinden fazlasını hastalıklı olarak tanımladığı rapor edilmiştir.

Derin öğrenme tekniklerinin kullanıldığı bir diğer çalışmada, Zaki ve arkadaşları [10] MobileNetV2 modelini kullanarak yaprak hastalıklarını tespit etmeyi amaçlamışlardır. Model, üç farklı domates hastalığını tanımak üzere ince ayarlanmış ve PlantVillage veri kümesinden alınan 4.671 görüntü üzerinde test edilmiştir. Sonuçlar, MobileNetV2'nin hastalıkları %90'ın üzerinde bir doğruluk oranıyla tespit edebildiğini ortaya koymuştur.

Diğer bir çalışmada ise, domatesler de dahil olmak üzere 14 mahsul türünde 26 hastalığı sınıflandırmak için derin öğrenme modeli kullanılmıştır [11]. Bu model, bitki hastalıklarının tanımlanmasında derin öğrenmenin etkili bir yöntem olduğunu ortaya koymuş ve yüksek doğruluk oranları elde etmiştir.

Sladojevic ve arkadaşları, domates yapraklarını etkileyen etmenleri de içeren bitki hastalıklarını tespit etmek ve sınıflandırmak amacıyla CNN tabanlı bir yaklaşım önermişlerdir [12]. Önerilen yaklaşım, 3.000 görüntüden oluşan bir veri setinde %96'nın üzerinde doğruluk oranı elde etmiştir.

Ferentinos, domatesler de dahil olmak üzere çeşitli bitkilerdeki hastalıkları tanımlamak için derin öğrenme modellerini kullanmıştır [13]. Bu çalışmada, farklı CNN mimarilerinin sınıflandırma başarıları karşılaştırılmış ve daha derin yapıya sahip ağların genellikle daha yüksek doğruluk oranlarına ulaştığı ifade edilmiştir.

Zhang ve arkadaşları, özellikle domates yaprağı hastalığının tanımlanması için tasarlanmış yeni bir CNN mimarisi önermişlerdir [14]. Önerilen model,

açık erişimli bir veri seti üzerinde yüksek doğruluk oranı ile başarılı sonuçlar elde etmiştir.

Karthik ve arkadaşları, domates bitkilerinde gerçek zamanlı hastalık tespiti için hafif bir CNN modeli önermişlerdir [15]. Model, mobil cihazlarda kullanım için optimize edilmiştir. Tarlada çalışan çiftçiler tarafından başarıyla kullanılmıştır.

Abbas ve arkadaşları, Koşullu Üretken Çelişkili Ağ (Conditional GAN – C-GAN) ile domates yapraklarının sentetik görüntülerini oluşturmuşlar ve derin öğrenmeye dayalı bir yaklaşım ile hastalık tahmini yapmışlardır [16]. Önerilen yaklaşım, açık erişimli PlantVillage veri kümesi üzerinde yapılan deneylerde sırasıyla 5 sınıfa, 7 sınıfa ve 10 sınıfa %99,51, %98,65 ve %97,11 doğruluk elde etmiştir.

Sanida ve arkadaşları, VGGNet ile çok nitelikli tanımlama görevi için iyileştirilmiş kategorik çapraz entropi kaybı fonksiyonu kullanan bir yaklaşım önermişlerdir [17]. Önerilen yaklaşım domates hastalık tespiti için %99,23 doğruluk değeri elde etmiştir.

Nag ve arkadaşları, AlexNet, ResNet-50, SqueezeNet-1.1, VGG19 ve DenseNet-121 gibi CNN mimarileri ile PlantVillage veri setinden domates yapraklarında akıllı hastalık tespiti için mobil uygulama tabanlı bir sistem önermişlerdir [18]. DenseNet-121 modeli %99,85 doğruluk oranı ile en iyi performansı göstermiştir.

3. MATERYAL VE METOD (MATERIALS AND METHODS)

3.1. Veri Seti ve Görüntü Toplama (Dataset and Image Collection)


Bu çalışmada kullanılan veri seti, domates yapraklarına ait 16.011 adet görüntü içermektedir. Veri seti, sağlıklı yapraklar ve dokuz farklı hastalık türü olmak üzere toplam on sınıfa (Bacterial_spot, Early_blight, Late_blight, Leaf_Mold, Septoria_leaf_spot, Spider_mites, Two-spotted_spider_mite, Target_Spot, Yellow_Leaf_Curl_Virus, Mosaic_virus ve Healthy) ayrılmıştır. Görüntüler, tarla koşullarında farklı zamanlarda ve farklı açılardan çekilmiştir, böylece modelin gerçek dünya koşullarına adaptasyonu artırılmıştır.

Veri setindeki sınıf dağılımı homojen değildir. Sınıf dağılımı şu şekildedir: Tomato_Yellow_Leaf_Curl_Virus sınıfı 3.209, Tomato_Bacterial_spot 2.127, Tomato_Late_blight 1.909, Tomato_Septoria_leaf_spot 1.771,

Tomato_Spider_mites 1.676, Tomato_healthy 1.591, Tomato_Target_Spot 1.404, Tomato_Early_blight 1.000, Tomato_Leaf_Mold 952 ve Tomato_Tomato_mosaic_virus 373 görüntü içermektedir.

Ayrıca, eğitim sırasında veri artırma (data augmentation) teknikleri uygulanmıştır. Görüntüler döndürme, yatay çevirme ve parlaklık ayarı gibi işlemlerle çeşitlendirilmiş; bu sayede modelin genelleme yeteneği artırılmış ve aşırı öğrenme (overfitting) riski azaltılmıştır.

Şekil 1'de veriseti sınıflarına ait örnek görseller verilmiştir.



Şekil 1. Sağlıklı ve hastalıklı domates yaprağı görüntüleri (Images of healthy and diseased tomato leaves.).

3.2. MobileNet Mimarileri (MobileNet Architectures)

MobileNet modelleri, özellikle mobil ve gömülü sistemlerde yüksek performanslı derin öğrenme modellerinin kullanılmasını sağlamak amacıyla geliştirilmiş hafif evrişimli sinir ağı (CNN) mimarileridir. Sınırlı hesaplama kaynaklarına sahip cihazlarda gerçek zamanlı uygulamalar için optimize edilmişlerdir.

Bu çalışmada kullanılan MobileNet mimarisinin üç farklı versiyonu bulunmaktadır: MobileNetV1, MobileNetV2 ve MobileNetV3Small. Her bir versiyon, daha az parametre kullanarak daha hızlı çıkarım yapabilme amacıyla farklı derinlik düzeyleri ve blok yapıları sunar. MobilNet mimarileri, mobil cihazlarda verimli çalışma açısından yaygın olarak tercih edilmektedir.

3.2.1. MobileNetV1

MobileNetV1, Howard ve arkadaşları tarafından 2017 yılında tanıtılmıştır [19]. Bu modelde, standart evrişimli katmanlar yerine derinlik ayrılabilir evrişimler (depthwise separable convolutions) kullanılarak parametre sayısı ve hesaplama maliyeti önemli ölçüde azaltılmıştır. Derinlik ayrılabilir evrişimler, uzamsal filtreleme ve kanal birleştirme

işlemlerini ayrı ayrı gerçekleştirerek, standart evrişimlere kıyasla daha düşük hesaplama gereksinimi sağlar. Bu yapı sayesinde, MobileNetV1 düşük güç tüketimi ve yüksek işlem hızı sunarken, makul düzeyde doğruluk oranı da koruyabilmektedir. Ancak, derinlik ayrılabilir evrişimlerin doğruluk açısından bazı sınırlamalara sahip olduğu da literatürde rapor edilmiştir.

3.2.2. MobileNetV2

MobileNetV2, Sandler ve arkadaşları tarafından 2018 yılında geliştirilmiştir [20]. Bu modelde, MobileNetV1'in eksikliklerini gidermek amacıyla doğrusal darboğaz (linear bottleneck) ve ters çevrilmiş artık bağlantılar (inverted residual connections) gibi yeni mimari öğeler eklenmiştir. Doğrusal darboğaz, düşük boyutlu uzayda gerçekleştirilen doğrusal dönüşümler aracılığıyla bilgi kaybını azaltmayı hedeflerken, ters çevrilmiş artık yapılar daha geniş ara katmanlar sayesinde modelin temsil kapasitesini artırmaktadır. Bu yenilikler, MobileNetV2'nin hem hesaplama verimliliği hem de doğruluk performansı açısından MobileNetV1'den daha iyi performans göstermesini sağlamıştır. Özellikle, düşük çözünürlüklü girdilerde daha iyi sonuçlar elde edilmiştir.

3.2.3. MobileNetV3

MobileNetV3, Howard ve arkadaşları tarafından 2019 yılında tanıtılmıştır [21]. Bu model, MobileNetV2'nin temelini alarak, otomatik sinir ağı mimarisi arama ve donanım bilgili optimizasyonlar kullanılarak geliştirilmiştir. MobileNetV3, iki farklı versiyonla sunulmuştur: MobileNetV3-Small (MobileNetV3s) ve MobileNetV3-Large (MobileNetV3l). MobileNetV3s, daha küçük ve daha hızlı bir model olarak tasarlanırken, MobileNetV3l daha yüksek doğruluk oranları hedeflemiştir.

MobileNet serisi, mobil ve gömülü sistemler için hafif ve verimli derin öğrenme modelleri sunmaktadır. Her bir versiyon, önceki modelin eksikliklerini gidererek hem doğruluk hem de hesaplama verimliliği açısından önemli adımlar atmıştır. MobileNetV3, özellikle otomatik mimari arama ve donanım bilgili optimizasyonlar sayesinde, bu serinin en gelişmiş modeli olarak öne çıkmaktadır.

3.2.4. Model Eğitimi Süreci (Training Process)

Model eğitimi sürecinde, sınıflandırma başarımını artırmak ve aşırı öğrenmeyi (overfitting) önlemek amacıyla çeşitli stratejiler uygulanmıştır.

Optimizasyon algoritması olarak Adam tercih edilmiş; öğrenme oranı (learning rate) 0.0001 olarak belirlenmiştir. Eğitim işlemi, 16 görüntüden oluşan mini-batch'lerle (batch size = 16) toplam 19 epoch boyunca gerçekleştirilmiş, ardından modelin son katmanları serbest bırakılarak 1 epoch süreyle ince ayar (fine-tuning) yapılmıştır.

Aşırı öğrenmenin önlenmesi için, eğitim veri kümesine yatay çevirme (horizontal flip), rastgele döndürme (random rotation), yakınlaştırma/uzaklaştırma (random zoom) ve kontrast değişikliği (random contrast) gibi veri artırma (data augmentation) teknikleri uygulanmıştır. Bu işlemler, modelin veri çeşitliliğine karşı daha dayanıklı hale gelmesini sağlamıştır. Ayrıca doğrulama kaybında belirli bir süre boyunca iyileşme gözlenmediğinde eğitimi sonlandıran erken durdurma (early stopping) yöntemi devreye alınarak aşırı öğrenme riski azaltılmıştır.

4. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

Bu çalışma kapsamında domates yaprak görüntülerini sınıflandırmak için keras kütüphanesinde yer alan MobileNetV1, MobileNetV2, MobileNetV3s ve MobileNetV3l modelleri kullanılmıştır. MobileNet mimarileri, hafifliği ve yüksek performansı nedeniyle mobil cihazlarda kullanım açısından uygundur. Modeller, Python programlama dili ile TensorFlow ve Keras kütüphaneleri kullanılarak geliştirilmiştir. Eğitim süreci 20 epoch boyunca gerçekleştirilmiştir. Veri seti %80 eğitim ve %20 doğrulama olacak şekilde ikiye ayrılmıştır. Ayrıca, modelin genelleme kabiliyetini artırmak amacıyla veri artırma teknikleri uygulanmıştır. Veri artırma sürecinde, eğitim veri kümelerinde yer alan görüntüler üzerinde çeşitli uzamsal dönüşümler uygulanarak orijinal görüntüye benzer ancak küçük farklılıklar içeren yeni görüntüler üretilir. Bu işlem, eğitim verilerinin çeşitliliğini ve miktarını artırarak derin öğrenme modellerinin daha geniş bir veri yelpazesinde eğitilmesini sağlar. Böylece, veri çeşitliliği artırılarak modelin daha geniş bir örneklem üzerinden eğitilmesi sağlanmıştır. [22].


MobileNet modelleriyle 20 epoch süresince gerçekleştirilen eğitimlerin sonuçları Tablo 1'de, eğitim doğruluklarına ait grafikler ise Şekil 2'de sunulmaktadır.

Tablo 1. Deneysel sonuçlar (Experimental Results)

Model	Train Acc.	Val. Acc.	Train Loss	Val. Loss	Epoch Time
MobileNetV1	0.9973	0.9978	0.8741	0.8732	144s 112ms

MobileNetV2	0.9973	0.9975	0.8751	0.8756	382s 298ms
MobileNetV3s	0.9942	0.9928	0.8841	0.8862	141s 110ms
MobileNetV3l	0.9991	0.9972	0.8711	0.8742	146s 114ms

Tablo 1, incelendiği zaman, MobileNetV3l modeli en yüksek eğitim doğruluğu (%99.91) ve en düşük kayıp değerleriyle (0.8711) öne çıkarak en iyi performansı sergilerken, MobileNetV3s modeli daha düşük doğruluk (%99.28) ve daha yüksek kayıp değerleri (0.8862) göstererek daha sınırlı bir kapasiteye sahip olduğunu ortaya koymaktadır. MobileNetV1 ve MobileNetV2 ise benzer doğruluk ve kayıp değerleriyle dengeli bir performans sergilemektedir. Epoch süreleri açısından MobileNetV3s ve MobileNetV1 en hızlı modeller olurken, MobileNetV2 daha uzun eğitim süreleri gerektirmektedir.



Şekil 2. Doğruluk grafikleri (a) MobileNetV1, (b) MobileNetV2, (c) MobileNetV3s, (d) MobileNetV3l
(Accuracy graphs: (a) MobileNetV1, (b) MobileNetV2, (c) MobileNetV3 Small, (d) MobileNetV3 Large).

Eğitimler sonucunda modellerin başarısını ölçmek için yapılan test sonuçları ve ölçülen performans metriklerine ait sonuçlar Tablo 2'de gösterilmiştir. Modellerin tahminlerini gösteren karmaşıklık matrisleri Şekil 3'de gösterilmiştir. Şekil 4'de ise eğitimden sonra yapılan test sonuçlarına ait görseller verilmiştir.

Tablo 2. Performans metrikleri sonuçları (Performance Metric Results)

Model	Test Accuracy	Classes	Precision	Recall	F1 skor
MobileNet V1	0.91	Bacterial Spot	0.93	0.93	0.93
		Early Blight	0.86	0.76	0.80
		Late Blight	0.86	0.91	0.88
		Leaf Mold	0.89	0.87	0.88

Model	Test Accuracy	Classes	Precision	Recall	F1 skor
		Septoria Leaf Spot	0.85	0.89	0.87
		Spider Mite	0.84	0.91	0.87
		Target Spot	0.86	0.87	0.87
		Curl Virus	0.99	0.96	0.97
		Mosaic Virus	0.97	0.87	0.92
		Healthy	0.99	0.94	0.96
MobileNet V2	0.91	Bacterial Spot	1.0	0.79	0.88
		Early Blight	0.92	0.64	0.76
		Late Blight	0.99	0.91	0.95
		Leaf Mold	0.85	1.0	0.92
		Septoria Leaf Spot	0.63	1.0	0.77
		Spider Mite	1.0	0.59	0.74
		Target Spot	0.75	0.93	0.83
		Curl Virus	1.0	0.96	0.98
		Mosaic Virus	0.73	1.0	0.84
		Healthy	0.96	0.99	0.98
MobileNet V3s	0.93	Bacterial Spot	0.97	0.88	0.92
		Early Blight	0.98	0.70	0.82
		Late Blight	0.96	0.94	0.95
		Leaf Mold	0.89	0.93	0.91
		Septoria Leaf Spot	0.85	0.94	0.89
		Spider Mite	0.90	0.92	0.91
		Target Spot	0.85	0.90	0.87
		Curl Virus	1.0	0.94	0.97
		Mosaic Virus	0.55	1.0	0.71
		Healthy	0.94	1.0	0.97
MobileNet V3l	0.99	Bacterial Spot	0.99	0.99	0.99
		Early Blight	0.96	0.93	0.94
		Late Blight	0.97	0.99	0.98
		Leaf Mold	1.0	0.99	1.0
		Septoria Leaf Spot	0.99	0.99	0.99
		Spider Mite	0.99	0.99	0.99
		Target Spot	0.97	1.0	0.99
		Curl Virus	1.0	0.99	1.0
		Mosaic Virus	1.0	0.98	0.99
		Healthy	1.0	0.99	1.0


Tablo 2’de sunulan performans metrikleri incelendiğinde, dört farklı MobileNet mimarisinin test verisi üzerindeki sınıflandırma başarısı detaylı olarak değerlendirilmektedir. MobileNetV1 modeli, genel test doğruluğu %91 olup özellikle *Curl Virus* ve *Healthy* sınıflarında yüksek precision (%99) ve recall (%94-96) değerleriyle başarılı sonuçlar vermiştir. Ancak *Early Blight* sınıfında precision (%86) ve recall (%76) değerlerinin diğer sınıflara

göre daha düşük olması, bu sınıfın ayırt edilmesinde güçlük yaşandığını göstermektedir.

MobileNetV2 modeli de %91 doğruluk değeri ile benzer bir genel performans sergilemiştir. Ancak bazı sınıflarda precision ve recall değerleri arasında belirgin farklılıklar gözlenmiştir. Örneğin *Spider Mite* sınıfında %100 precision ve %59 recall değeri, modelin bu sınıfı doğru tanıma konusunda düşük duyarlılığa sahip olduğunu göstermektedir. Benzer şekilde *Septoria Leaf Spot* ve *Mosaic Virus* sınıflarında da düşük precision veya recall değerleri dikkat çekmektedir.

MobileNetV3Small modeli %93 test doğruluğu ile daha iyi bir genel başarı sağlamıştır. Bu model, *Late Blight*, *Curl Virus* ve *Healthy* sınıflarında yüksek precision ve recall değerleri ile öne çıkmaktadır. Ancak *Mosaic Virus* sınıfında precision (%55) düşüktür; bu durum modelin diğer sınıflardan bazı örnekleri bu sınıfa atadığını göstermektedir.

MobileNetV3Large modeli %99 test doğruluğu ile en yüksek genel başarıyı göstermiştir. Tüm sınıflarda precision, recall ve F1 skor değerleri %97’nin üzerindedir. Özellikle *Leaf Mold*, *Curl Virus* ve *Healthy* sınıflarında ölçülen metrikler %99 ve üzerindedir. Bu sonuçlar, modelin sınıflar arasında yüksek ayırım gücüne sahip olduğunu göstermektedir. Sonuç olarak, MobileNetV3Large modeli, sınıf bazlı metriklerde gösterdiği yüksek ve dengeli performans ile en başarılı mimari olmuştur.



Şekil 3. Karmaşıklık matrisleri (a) MobileNetV1, (b) MobileNetV2, (c) MobileNetV3s, (d) MobileNetV3l (Confusion matrices: (a) MobileNetV1, (b) MobileNetV2, (c) MobileNetV3 Small, (d) MobileNetV3 Large).

Şekil 3’te sunulan karmaşıklık matrisleri, her bir MobileNet mimarisinin test verisindeki sınıflandırma performansını görsel olarak ortaya koymaktadır. MobileNetV1 matrisinde, özellikle *Healthy*, *Curl*

Virus ve Mosaic Virus sınıflarında doğru sınıflandırma oranlarının yüksek olduğu görülmektedir. Bununla birlikte Early Blight ve Spider Mite sınıflarında yanlış sınıflandırmaların diğer modellere kıyasla daha fazla olduğu gözlemlenmiştir.

MobileNetV2 matrisinde sınıflar arası karışıklık daha belirgindir. Özellikle Spider Mite, Early Blight ve Septoria Leaf Spot sınıflarına ait örneklerin, bazı durumlarda benzer semptomlara sahip diğer sınıflarla karıştırıldığı görülmektedir. Bu da modelin bazı sınıflar arasında ayırım yapmakta zorlandığını göstermektedir.

MobileNetV3Small modeline ait matris, genel olarak daha dengeli bir dağılım sergilemektedir. Mosaic Virus sınıfında bazı hatalı sınıflandırmalar bulunsun da diğer sınıflarda başarı oranları daha yüksektir. Healthy, Late Blight ve Curl Virus sınıflarının yüksek doğrulukla sınıflandırıldığı gözlemlenmektedir.

MobileNetV3Large matrisinde ise sınıflar arası karışıklığın en az olduğu görülmektedir. Tüm sınıflar yüksek doğrulukla sınıflandırılmış, yanlış sınıflandırma oranı oldukça düşmüştür. Bu durum, modelin yüksek duyarlılık ve seçicilikle çalıştığını ve sınıflar arasındaki sınırları net olarak ayırt edebildiğini göstermektedir.

Genel olarak, karmaşıklık matrisleri, metrik tablosu ile paralel olarak MobileNetV3Large modelinin en yüksek sınıflandırma doğruluğunu sağladığını ve sınıflar arası ayırımı daha başarılı gerçekleştirdiğini göstermektedir.




Şekil 4. Eğitimden sonra yapılan test sonuçları (Test results after training)

Sonuç olarak, eğitim süresi, doğruluk değerleri, test sonuçları, performans metrikleri, eğitim ve karmaşıklık grafikleri incelendiği zaman MobileNetV3l modeli en etkili model olarak öne çıkmaktadır. Mobil uygulamada MobileNetV3l mimarisi kullanılmıştır.

4.1. Mobil Uygulama Entegrasyonu (Mobile Application Integration)

Eğitimden sonra, elde edilen model ağırlıkları, Android Studio ortamında geliştirilen bir mobil uygulamaya entegre edilmiştir. Uygulama, kullanıcıların akıllı telefonları aracılığıyla domates yapraklarını fotoğraflayıp, anında hastalık tespiti yapabilmelerini sağlar. Uygulama arayüzü, kullanıcı dostu ve etkileşimli özelliklerle donatılmıştır. Uygulama, çevrimdışı çalışabilme yeteneği sayesinde tarla gibi internet erişiminin sınırlı olduğu yerlerde de kullanılabilir.



Şekil 5. Uygulama tasarımı (a) Ana menü ekranı, (b) Fotoğraf seçim ekranı (c) Fotoğraf seçme-tahmin ekranı, (d) Tahmin sonuç ekranı (Application design: (a) Main menu screen, (b) Image selection screen, (c) Image selection and prediction screen, (d) Prediction result screen)

Şekil5’de gösterilen uygulama görüntülerinden uygulama ana menü ekranından select tuşu ile fotoğraf galerisine girilir. Galeri içerisinde daha önce fotoğrafını çekmiş olduğumuz domates yaprağını görüntüsünü seçeriz. Daha sonra seçilen görüntüden hastalık tahmini için predict butonuna basılarak tahmin sonucu görüntülenir, yeniden görüntü seçmek için select butonuna basılarak galeriye geri dönlür. Galeriden seçilen fotoğrafın hastalık tahmini yapılarak, sonuç ekranda gösterilir. Uygulama kullanıcı dostu olup işlemler çok basit şekilde yapılması için tasarlanmıştır.

5. SONUÇ (CONCLUSION)

Derin öğrenme, domates yaprak hastalıklarının tanımlanmasını otomatikleştirmede büyük bir potansiyel göstermiştir ve geleneksel yöntemlere göre daha hızlı ve daha doğru bir alternatif sunmaktadır. Zorluklar devam ederken, derin öğrenme tekniklerindeki devam eden araştırmalar ve gelişmelerin bu sistemlerin etkinliğini ve erişilebilirliğini daha da iyileştirmesi ve nihayetinde

çiftçilere ve tarım endüstrisine bir bütün olarak fayda sağlaması muhtemeldir.

Bu çalışmada, MobileNet mimarileri kullanılarak domates yapraklarındaki hastalıkları tespit etmek için bir mobil uygulama geliştirilmiştir. Elde edilen sonuçlar, modelin yüksek doğruluk oranları ile hastalıkları etkili bir şekilde tespit edebildiğini göstermektedir. Mobil uygulama, tarım profesyonelleri ve çiftçiler için değerli bir araç olarak öne çıkmakta, erken teşhis ve müdahalede büyük bir potansiyel sunmaktadır. Bu çalışma, domates yapraklarındaki hastalıkları tespit etmek için geliştirilen bir yapay zekâ tabanlı mobil uygulamanın potansiyelini ortaya koymaktadır. Model, yüksek doğruluk, duyarlılık ve özgüllük oranları ile dikkat çekici sonuçlar elde etmiştir. Bununla birlikte, modelin performansı çeşitli faktörlere bağlı olarak değişkenlik gösterebilir. Örneğin, görüntü kalitesi, çekim koşulları ve yaprakların hasar durumu gibi faktörler, modelin doğruluğunu etkileyebilir. Bu faktörlerin, modelin genel performansına olan etkilerinin daha detaylı incelenmesi gerekmektedir.

Model, özellikle Leaf Mold, Curl Virus ve Healthy sınıflarında %99'un üzerinde başarı sergileyerek güçlü bir ayırt edicilik yeteneği ortaya koymuştur. Elde edilen bu sonuçlar, literatürdeki benzer çalışmalardaki performanslarla karşılaştırıldığında oldukça rekabetçidir. Örneğin, Zhang et al. (2020) tarafından kullanılan InceptionV3 modeli %96 doğruluk bildirirken; Fuentes et al. (2018) çalışmasında Faster R-CNN tabanlı sistemin doğruluk oranı %93 olarak rapor edilmiştir. MobileNet mimarilerinin daha düşük hesaplama gereksinimiyle bu denli yüksek başarı elde etmesi, bu çalışmayı önemli kılmaktadır.

Geliştirilen mobil uygulama, çevrimdışı çalışabilme özelliği sayesinde internet erişiminin kısıtlı olduğu kırsal bölgelerde de etkin bir şekilde kullanılabilir. Bu yönüyle, küçük ölçekli çiftçiler ve tarım danışmanları için pratik ve ulaşılabilir bir araç niteliği taşımaktadır. Bu teknolojinin ilerletilmesi, tarımsal üretkenliği artırmak ve gıda güvenliğini desteklemek için kritik öneme sahiptir.

6. Gelecek Çalışmalar (Future Work)

Gelecek çalışmalarda, modelin farklı domates çeşitleri üzerindeki başarısı test edilerek genelleştirilebilirliği artırılmalıdır. Bu, modelin farklı ekolojik ve genetik çeşitlilik gösteren bitkilerde de doğru sonuçlar verip veremeyeceğini değerlendirmek açısından önemlidir. Ayrıca, modelin daha fazla hastalık türü üzerinde eğitilmesi ve farklı iklim koşullarında uygulanabilirliğinin test edilmesi de önerilmektedir. Bu tür gelişmeler, yapay zekâ tabanlı

tarım uygulamalarının daha geniş ölçekli entegrasyonuna katkı sağlayacaktır.

REFERANSLAR (REFERENCES)

- [1] TEPGE, "Tarım Ürünleri Piyasaları," Ankara, Haziran 2021.
- [2] Kılıçarslan, S., & Pacal, I. (2023). Domates Yapraklarında Hastalık Tespiti İçin Transfer Öğrenme Metotlarının Kullanılması. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 5(2), 215-222.
- [3] Zhao, S., Peng, Y., Liu, J., & Wu, S. (2021). Tomato leaf disease diagnosis based on improved convolution neural network by attention module. *Agriculture*, 11(7), 651.
- [4] Mansoor, S., Khan, S. H., Saeed, M., Bashir, A., Zafar, Y., Malik, K. A., & Markham, P. G. (1997). Evidence for the association of a bipartite geminivirus with tomato leaf curl disease in Pakistan. *Plant Disease*, 81(8), 958-958.
- [5] Raza, A., Shakeel, M. T., Umar, U. U. D., Tahir, M. N., Hassan, A. A., Katis, N. I., & Wang, X. (2020). First report of tomato chlorosis virus infecting tomato in Pakistan. *Plant Dis*, 104(2036), 10-1094.
- [6] Karaman, A., Karaboga, D., Pacal, I., Akay, B., Basturk, A., Nalbantoglu, U., ... & Sahin, O. (2023). Hyper-parameter optimization of deep learning architectures using artificial bee colony (ABC) algorithm for high performance real-time automatic colorectal cancer (CRC) polyp detection. *Applied Intelligence*, 53(12), 15603-15620.
- [7] Tan, L., Lu, J., & Jiang, H. (2021). Tomato leaf diseases classification based on leaf images: a comparison between classical machine learning and deep learning methods. *AgriEngineering*, 3(3), 542-558.
- [8] Cengil, E., & Çınar, A. (2022). Hybrid convolutional neural network based classification of bacterial, viral, and fungal diseases on tomato leaf images. *Concurrency and Computation: Practice and Experience*, 34(4), e6617.
- [9] Barbedo, J. G. A. (2016). A novel algorithm for semi-automatic segmentation of plant leaf disease symptoms using digital image processing. *Tropical Plant Pathology*, 41(4), 210-224.
- [10] Zaki, S. Z. M., Zulkifley, M. A., Stofa, M. M., Kamari, N. A. M., & Mohamed, N. A. (2020). Classification of tomato leaf diseases using MobileNet v2. *IAES International Journal of Artificial Intelligence*, 9(2), 290.
- [11] Mohanty, S. P., Hughes, D. P. ve Salathé, M. (2016). Görüntü tabanlı bitki hastalığı tespiti için derin öğrenmenin kullanılması. *Frontiers in Plant Science*, 7, 1419.

[12] Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D. ve Stefanovic, D. (2016). Yaprak görüntü sınıflandırmasıyla bitki hastalıklarının derin sinir ağlarına dayalı tanınması. Hesaplamalı Zeka ve Sinirbilim, 2016.

[13] Ferentinos, K. P. (2018). Bitki hastalığı tespiti ve teşhisi için derin öğrenme modelleri. Tarımda Bilgisayarlar ve Elektronik, 145, 311-318.

[14] Zhang, S., Zhang, S., Zhang, C., Wang, X. ve Shi, Y. (2019). Küresel havuzlama genişlemiş evrişimli sinir ağı ile salatalık yaprağı hastalığı tanımlama. Tarımda Bilgisayarlar ve Elektronik, 162, 422-430.

[15] Karthik, R., Hariharan, M., Anand, S., Mathikshara, P., Johnson, A. ve Menaka, R. (2020). Domates yapraklarında hastalık tespiti için dikkat gömülü kalıntı CNN. Uygulamalı Yumuşak Hesaplama, 86, 105933.

[16] Abbas, A., Jain, S., Gour, M., & Vankudothu, S. (2021). Tomato plant disease detection using transfer learning with C-GAN synthetic images. Computers and Electronics in Agriculture, 187, 106279.

[17] Sanida, T., Sideris, A., Sanida, M. V., & Dasygenis, M. (2023). Tomato leaf disease identification via two-stage transfer learning approach. Smart Agricultural Technology, 5, 100275.

[18] Nag, A., Chanda, P. R., & Nandi, S. (2023). Mobile app-based tomato disease identification with fine-tuned convolutional neural networks. Computers and Electrical Engineering, 112, 108995.

[19] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861.

[20] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4510-4520).

[21] Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., ... & Adam, H. (2019). Searching for mobilenetv3. In Proceedings of the IEEE/CVF International Conference on Computer Vision (pp. 1314-1324).

[22] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. Journal of big data, 6(1), 1-48.